

NA ERA DA AUTOMAÇÃO

...

1ª EDIÇÃO

Ano 2020

volume **1**



Editora Poisson

Editora Poisson

Na era da Automação Volume 1

1ª Edição

Belo Horizonte
Poisson
2019

Editor Chefe: Dr. Darly Fernando Andrade

Conselho Editorial

Dr. Antônio Artur de Souza – Universidade Federal de Minas Gerais

Msc. Davilson Eduardo Andrade

Dra. Elizângela de Jesus Oliveira – Universidade Federal do Amazonas

Msc. Fabiane dos Santos

Dr. José Eduardo Ferreira Lopes – Universidade Federal de Uberlândia

Dr. Otaviano Francisco Neves – Pontifícia Universidade Católica de Minas Gerais

Dr. Luiz Cláudio de Lima – Universidade FUMEC

Dr. Nelson Ferreira Filho – Faculdades Kennedy

Msc. Valdiney Alves de Oliveira – Universidade Federal de Uberlândia

Dados Internacionais de Catalogação na Publicação (CIP)

N111

Na era da Automação -Volume 1/Organização
Editora Poisson - Belo Horizonte - MG:
Poisson - 2020

Formato: PDF

ISBN: 978-65-86127-20-1

DOI: 10.36229/978-65-86127-20-1

Modo de acesso: World Wide Web

Inclui bibliografia

1. Tecnologia 2. Automação 3. Engenharia
I. Título

CDD-620

O conteúdo dos artigos e seus dados em sua forma correção e confiabilidade são de responsabilidade exclusiva dos seus respectivos autores.

www.poisson.com.br

contato@poisson.com.br

SUMÁRIO

Capítulo 1: Reconfiguração de Redes de Distribuição de energia elétrica utilizando unineuron e nullneuron 06

Mariane Militão Santana, Pyramo Pires da Costa Júnior, Maury Meirelles Gouvêa Júnior, Fabrício Pereira Lucas

DOI: 10.36229/978-65-86127-20-1.CAP.01

Capítulo 2: Estudo da coordenação de relés de sobrecorrente e modelagem de proteção adaptativa considerando Geração Distribuída em Sistemas de Distribuição 21

Luis Henrique Pereira Vasconcelos, Aryfrance Rocha Almeida, Nelber Ximenes Melo, José Genilson Sousa Carvalho, Bartolomeu Ferreira dos Santos Júnior

DOI: 10.36229/978-65-86127-20-1.CAP.02

Capítulo 3: Sistema Eletrocinético para Desaguamento de Rejeitos Provenientes da Mineração 30

Raphael Henrique, Marcos Moraes Tavares Ronzani, Ana Carolina Ferreira, Saulo Neves Matos, Alan Kardek Rêgo Segundo, Lucas Deleon Ferreira, Paulo Marcos de Barros Monteiro

DOI: 10.36229/978-65-86127-20-1.CAP.03

Capítulo 4: Modelagem Matemática da Curva de Descarga da Bateria de um Quadrirotor Rolling Spider utilizando a Teoria de Identificação de Sistemas 37

Adriel de Oliveira Freitas, Lígia Rodrigues Machado, Francisco Alexsandro Silva Freitas, Vandilberto Pereira Pinto, Camila Tabosa de Souza Lima

DOI: 10.36229/978-65-86127-20-1.CAP.04

Capítulo 5: Termografia em um contexto de manutenção industrial eficiente 48

Phellipe Tocchetto Dinardi, Keven Soares da Costa, Israel Gondres Torné

DOI: 10.36229/978-65-86127-20-1.CAP.05

Capítulo 6: Implementação de um Módulo IoT para controle de luminárias LED baseado em espelho de corrente com chaveamento de ramos 56

Raimundo Cláudio Souza Gomes, Rubens de Andrade Fernandes, Lennon Brandão Freitas do Nascimento, Marcus Vinicius Martins Melo, Karolayne Barbosa Martins, Israel Gondres Torné

DOI: 10.36229/978-65-86127-20-1.CAP.06

Capítulo 7: Sistema de Manufatura Inteligente para seleção de mangas utilizando *Deep Learning* 69

Carine Ramos de Almeida Gottschall, João Erivando Soares Marques, Cleia Santos Libarino, José Alberto Diaz Amado

DOI: 10.36229/978-65-86127-20-1.CAP.07

SUMÁRIO

Capítulo 8: Controle de Suspensão Ativa Automotiva por Lógica Difusa 80

Neusa Valentim da Silva, Waldemar Bonventi Júnior

DOI: 10.36229/978-65-86127-20-1.CAP.08

Capítulo 9: Detecção de ilhamentos não intencionais em redes de distribuição com geração distribuída utilizando Redes Neurais Artificiais 90

Bruno Martins de Biaz, Thales Terrola e Lopes, Márcio Zamboti Fortes, Vitor Hugo Ferreira, Flávio Luis de Mello

DOI: 10.36229/978-65-86127-20-1.CAP.09

Capítulo 10: Identificação de gênero e contorno corporal para estimativa de somatotipo 99

Gentil Auer Neto, Patrick Marques Ciarelli, Evandro Ottoni Teatini Salles

DOI: 10.36229/978-65-86127-20-1.CAP.10

Capítulo 11: Reconhecimento de Ações por RNA em Aplicações de Robótica Social. 109

Kevin Braathen de Carvalho, Vitor Thinassi Basílio, Alexandre Santos Brandão

DOI: 10.36229/978-65-86127-20-1.CAP.11

Capítulo 12: Criação e validação de uma Base de Dados com elementos do trânsito brasileiro para veículos autônomos 129

Diego Haji Carvalho Campos, Elder de Oliveira Rodrigues, Erick Carvalho Campos

DOI: 10.36229/978-65-86127-20-1.CAP.12

Capítulo 13: Desenvolvimento de um software PIMS com comunicação OPC e acesso por navegador *Web* 139

Silas Martins Sousa, Michelle Mendes Santos, Isabel Ramos Henriques Oliveira

DOI: 10.36229/978-65-86127-20-1.CAP.13

Capítulo 14: Aplicações de técnicas de *Machine Learning* ao diagnóstico de falhas em processos de uma planta de cimento 151

Diego Assereuy Lobão, Luiz Alberto Pinto

DOI: 10.36229/978-65-86127-20-1.CAP.14

Autores:..... 172

Capítulo 1

Reconfiguração de Redes de Distribuição de energia elétrica utilizando unineuron e nullneuron

Mariane Militão Santana

Pyramo Pires da Costa Júnior

Maury Meirelles Gouvêa Júnior

Fabício Pereira Lucas

Resumo: A reconfiguração de redes de distribuição de energia elétrica é uma ferramenta indispensável no planejamento e operação do sistema de distribuição. O presente trabalho descreve uma metodologia multi-objetivo para reconfiguração de redes de distribuição, utilizando unineurons e nullneurons. A nova configuração deve minimizar a perda total de energia ativa e minimizar o carregamento do alimentador sem violar as restrições operacionais do sistema de distribuição. Os testes com os algoritmos foram realizados com o sistema elétrico IEEE 33 barras. Os resultados obtidos foram comparados com os da literatura, demonstrando que a metodologia desenvolvida é promissora e fornece bons resultados, levando em consideração todas as restrições físicas e operacionais do problema.

Palavras-chaves: Reconfiguração de carga; Rede de Distribuição; Rede Neural Artificial; Sistemas Nebulosos; Métodos Heurísticos.

1. INTRODUÇÃO

O sistema de distribuição de energia elétrica é um sistema complexo, cuja condição de operação pode não permanecer constante. As várias contingências como, grandes variações de carga, falta de componentes (linhas de transmissão, transformadores, geradores, etc.) são mais comuns (Romano et al., 2013). Qualquer uma dessas condições faz com que parâmetros do sistema excedam os limites de segurança, resultando em um sistema inseguro. As técnicas mais praticadas para alívio de sobrecarga são o reescalonamento de geradores e/ou a reconfiguração das cargas.

As redes do sistema de distribuição de energia elétrica são operadas em uma configuração radial. A presença de diversas interconexões, entre diferentes alimentadores na mesma rede de distribuição permite configurações diversificadas para fornecer energia às cargas. Sendo assim, a reconfiguração da rede de distribuição pode ser utilizada com o objetivo de minimizar as perdas elétricas, melhorar perfil de tensão e balancear a carga entre os alimentadores (Li et al., 2007).

Diversos trabalhos sobre reconfiguração de redes elétricas estão presentes na literatura desde 1970. A minimização das perdas de potência ativa é a principal função objetivo utilizada. Dentre as técnicas largamente aplicadas na solução do problema de reconfiguração de redes elétricas de distribuição se destacam as técnicas heurísticas e meta heurísticas. Técnicas heurísticas nem sempre possuem como alvo uma solução ótima do problema. Possuem como ponto de partida uma solução viável. Baseiam-se em sucessivas aproximações direcionadas a um ponto ótimo. Logo, esses métodos costumam encontrar as melhores soluções possíveis para problemas, e não soluções exatas (Oliveira, 2016). Já as técnicas metaheurísticas constituem-se da combinação de métodos heurísticos, aplicados em problemas gerais de alta complexidade e elevado espaço de solução. São geralmente aplicadas para buscas locais, porém suas características de busca inteligente, em muitos casos, permitem explorar novas regiões do espaço, podendo alcançar ótimos globais (Macedo, 2012).

Entre os métodos Heurístico e Metaheurísticos mais aplicados a problemas de otimização para reconfiguração de redes de distribuição, destacam-se, Branch and Bound (Merlin and Back, 1975; Romano et al., 2013) e Branch Exchange (Civanlar et al., 1988; Baran and Wu, 1989; Peponis and Papadopoulos, 1997; Bernardon et al., 2009; Junior, 2014) como métodos Heurísticos e PSO (Particle Swarm Optimization) (Tofis et al., 2017; Macedo, 2012; Atteya et al., 2017), Inteligência Artificial (Pandiarajan and Babulal, 2011; Bernardon et al., 2009; Berredo et al., 2011; Neto and Vellasco, 2016) e Colônia de formigas (Amin Heidari, 2017; Silva, 2010; Ghorbani et al., 2008) como métodos Metaheurísticos.

Um dos primeiros trabalhos relativo ao problema de reconfiguração de sistemas de distribuição de energia elétrica abordou a redução de perdas ôhmicas e foi proposto por Merlin and Back (1975). Neste trabalho é apresentado o método heurístico baseado na técnica de programação matemática inteira Branch and Bound.

Outra técnica heurística bastante utilizada é a Branch Exchange (Civanlar et al., 1988; Baran and Wu, 1989; Peponis and Papadopoulos, 1997; Bernardon et al., 2009; Junior, 2014). O método consiste em assumir inicialmente uma configuração radial e realizar a partir de então, vários procedimentos de comutação das chaves da rede na tentativa de produzir configurações novas e promissoras, sempre observando a radialidade da rede. O método se difere do Branch and Bound por garantir a radialidade do sistema e por estabelecer limites min/max de tensão.

Os métodos metaheurísticos são também bastante utilizados, apesar de apresentarem elevado esforço computacional. Dentre eles, estão os métodos ACO (Ant Colony optimisation) por otimização de colônia de formigas e por enxame de partículas ou PSO (Particle Swarm Optimization). Ambos são exemplos de algoritmos evolucionários baseados no conceito de inteligência computacional.

O PSO é uma técnica inspirada na simulação de um sistema social. Ele simula a migração e agregação de um bando de aves procurando por comida e/ou local seguro. O método foi aplicado por (Tofis et al., 2017; Macedo, 2012; Ghorbani et al., 2008) para reconfiguração de uma rede de distribuição de energia elétrica e apresentou a desvantagem de considerar apenas uma função objetivo. Atteya et al. (2017) propôs também uma modificação do PSO (MPSO), onde a diferença entre ele e o típico PSO está no espaço de busca seletiva aleatório filtrado para posição inicial, que é proposto para acelerar o algoritmo para alcançar a solução ótima.

Silva (2010), utiliza um novo algoritmo baseado na estrutura do método de otimização por colônia de formigas (ACO) para reconfiguração do sistema de distribuição. No método ACO, um conjunto de formigas artificiais (agentes) cooperam entre si a fim de encontrar soluções "ótimas" para problemas de otimização discreto e complexos.

O algoritmo não garante radialidade do sistema, limitando assim o espaço de soluções à somente o conjunto de todas as topologias radiais conexas (Silva, 2010). Amin Heidari (2017), utiliza os métodos ACO e PSO em conjunto para a solução do problema de reconfiguração de sistemas de distribuição. Os resultados simulados mostraram que o algoritmo é efetivo na solução do problema de reconfiguração.

Outros autores utilizam de métodos de Inteligência Artificial para solução do problema de reconfiguração de redes de distribuição (Pandiarajan and Babulal, 2011; Bernardon et al., 2009; Berredo et al., 2011; Neto and Vellasco, 2016). Pandiarajan and Babulal (2011) utilizou a lógica Fuzzy para realizar remanejamento de carga e aliviar a sobrecarga no sistema de energia, porém este método não apresentou capacidade de minimizar a quantidade de carga a ser transferida. Neto and Vellasco (2016) utiliza Lógica *Fuzzy* em conjunto com Busca Tabu para solução do problema, porém a metodologia proposta não descartou a possibilidade de uma solução ruim. Já Berredo et al. (2011) e Neto and Vellasco (2016) apresentam resultados de pesquisas sobre o uso da abordagem de Bellman Zadeh para a tomada de decisão em um ambiente nebuloso para resolver o problema de reconfiguração. A abordagem de Bellman Zadeh permite a realização de um método computacionalmente efetivo, bem como rigoroso (do ponto de vista de obtenção de soluções) de análise de modelos multicritério. Seu uso permite preservar uma medida natural de incerteza na tomada de decisões e considerar índices, critérios e restrições de caráter qualitativo.

O objetivo deste trabalho é apresentar uma abordagem para obtenção de novas configurações radiais para o sistema de distribuição de Energia Elétrica. As novas configurações devem minimizar as perdas de potência ativa totais, e minimizar o carregamento dos alimentadores, sem violar as restrições operacionais.

Este artigo está organizado como segue. A seção 2 apresenta a formulação matemática utilizada para realizar o remanejamento de carga. A seção 3 apresenta a metodologia utilizada na pesquisa. A seção 4 apresenta os resultados obtidos com a pesquisa e a seção 5 apresenta a conclusão final do artigo.

2. FORMULAÇÃO MATEMÁTICA DO PROBLEMA

A partir da possibilidade de alteração das configurações da rede de distribuição, surge o problema de otimização conhecido como problema de reconfiguração de rede. Seu objetivo principal consiste em encontrar uma estratégia de operação ideal. Uma solução eficiente para esse problema requer a seleção da topologia de operação mais apropriada entre todas as configurações disponíveis. Examinar todas as alternativas de configuração torna o processo inviável para sistemas de distribuição reais, uma vez que o número de configurações viáveis cresce exponencialmente com o número de barras do sistema. Esse fato é conhecido como explosão combinatória (Bernardon et al., 2009).

Sendo assim, é proposto neste trabalho uma técnica Heurística (Branch Exchange) em conjunto com um método eficiente de tomada de decisão baseado em neurônios nebulosos *Fuzzy*. Neurônios nebulosos foi abordagem escolhida por apresentar algumas vantagens em relação a abordagens alternativas, devido ao paralelismo inerente das redes neurais. O objetivo é reduzir a perda de potência ativa total e minimizar o carregamento dos alimentadores, garantindo a radialidade do sistema e mantendo níveis de corrente e tensão adequados, no sentido de atender as exigências da agência reguladora.

2.1. FUNÇÕES OBJETIVO E RESTRIÇÕES

A escolha das funções objetivo é uma etapa importante na modelagem do problema. Essa escolha deve refletir as necessidades do operador e auxiliar a tomada de decisão (Romano et al., 2013). Para o caso desenvolvido neste trabalho, foi considerado como função objetivo a minimização das perdas de potência ativa da rede elétrica e minimização do carregamento dos alimentadores em um problema de reconfiguração multiobjetivo.

Para minimização da perda de potência ativa do sistema de distribuição de energia elétrica, adotou-se como função objetivo a equação (1).

$$\min f_1(x) = \sum_{j=1}^{N_r} R_j I_j^2 \quad (1)$$

Para minimização do carregamento dos alimentadores, adotou-se como função objetivo a equação (2).

$$\min f_2(x) = \sum_{j=1}^{N_r} I_j \quad (2)$$

Onde I_j é a magnitude da corrente no ramo j , R_j a resistência do ramo j e N_r o conjunto de ramos do sistema. Para que as configurações possam ser consideradas como viáveis, esta deve atender a algumas restrições, como:

2.1.1. RADIALIDADE

O sistema é considerado radial quando a igualdade da equação (3) é satisfeita.

$$n_{linhas} = n_{barras} - 1 \quad (3)$$

Sendo, n_{linhas} o número de linha (chaves) do sistema radial e n_{barras} o número de barras do sistema.

2.1.2. A MAGNITUDE DA CORRENTE DE CADA ELEMENTO DEVE ESTAR DENTRO DE UM LIMITE PERMITIDO

$$|I_j| \leq I_{jmax} \quad (4)$$

Sendo I_{jmax} o limite máximo da corrente no ramo j

2.1.3. A MAGNITUDE DA TENSÃO DE CADA NÓ DEVE ESTAR DENTRO DE UM INTERVALO PERMITIDO

$$V_{jmin} \leq V_j \leq V_{jmax} \quad (5)$$

De acordo com a Agência Nacional de Energia Elétrica Brasileira (ANEEL), os limites de tensão nas barras da rede elétrica são divididos em três faixas, como apresentado na Tabela 1. Onde V_j é a tensão na j_{th} barra em p.u (Junior, 2014).

Tabela 1: Limites de Tensão

| Faixas de variação de Tensão | |
|------------------------------|--|
| Adequada | $0,91 \leq V_j \leq 1,04$ |
| Precária | $0,86 \leq V_j < 0,91$ ou $1,04 < V_j \leq 1,06$ |
| Crítica | $V_j < 0,86$ ou $V_j > 1,06$ |

2.2. CÁLCULO DE FLUXO DE POTÊNCIA

O fluxo de potência (FP) consiste de uma ferramenta básica para análise de sistemas elétricos de potência (SEP). Dado um sistema elétrico composto por subestação, alimentadores e barra de carga, utilizando o cálculo do fluxo de potência, é possível determinar valores de potência ativa e reativa, fasores de corrente e tensão, fator de potência e tensão elétrica em cada barra de carga (Chen et al., 2016; Yan et al., 2017; Macedo, 2012).

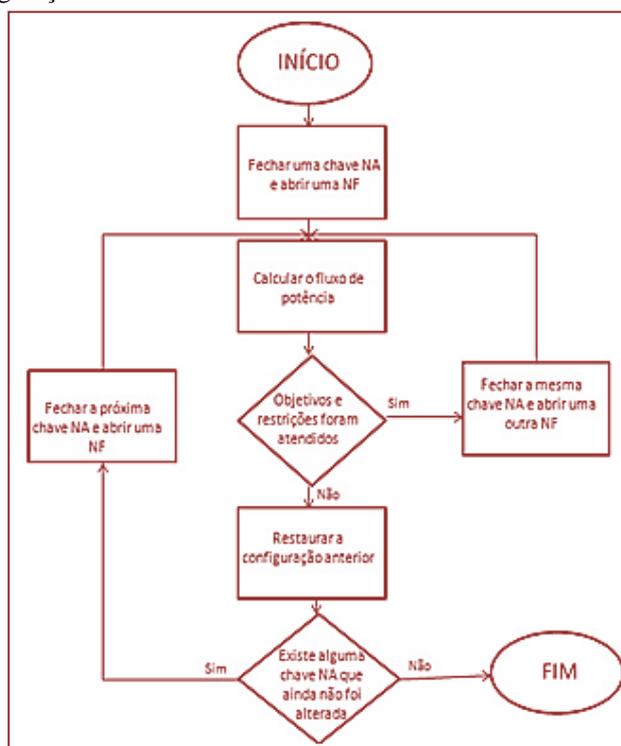
Para realizar o cálculo de fluxo de potência foi escolhido o pacote Matpower no Matlab (Zimmerman et al., 2011), que utiliza o método Newton Raphson, que consiste na expansão da série de Taylor para múltiplas variáveis

2.3. PROCEDIMENTO PROPOSTO PARA SELEÇÃO DE CONFIGURAÇÕES

Para seleção das configurações foi escolhido um procedimento de busca heurística, a qual é baseada na estratégia Branch Exchange. Portanto, uma configuração radial é assumida inicialmente e vários procedimentos de comutação são seguidos na tentativa de produzir configurações novas e promissoras, sempre observando a radialidade da rede. Estes procedimentos correspondem a um interruptor aberto e um interruptor fechado. Todas as configurações escolhidas pelo procedimento são classificadas de acordo com cada função objetivo definida e em relação as restrições estabelecidas, lembrando que soluções inviáveis são descartadas (Bernardon et al., 2009).

O fluxograma utilizado para selecionar a configuração candidata é mostrado na Figura 1. Onde, chave NA são as chaves normalmente abertas do sistema e chave NF são as chaves normalmente fechadas do sistema.

Figura 1: Seleção das configurações



2.4. MÉTODO DE BELLMAN ZADEH

Após definir quais as melhores configurações considerando cada função objetivo separadamente, é necessário definir quais configurações detêm os melhores resultados, uma vez que duas funções objetivo estão sendo consideradas. Por exemplo, quando uma configuração possui os melhores valores para perda de energia, mas existe uma outra melhor avaliada em relação ao carregamento dos alimentadores, é necessário decidir qual delas possui a melhor configuração geral, sendo assim, foi utilizado um algoritmo de tomada de decisão multicritério.

Em problemas de tomada de decisões multiobjetivo, diferentes funções objetivo podem ter diferentes naturezas e, conseqüentemente, são expressas em diferentes unidades e suas escalas não são comparáveis. Levando isso em consideração, a comparação da qualidade das soluções para cada função objetivo deve ser realizada em uma mesma escala (Junior, 2014). A equação (6) mostra a técnica utilizada para a transformação da função objetivo utilizadas neste trabalho. O resultado fornece a pertinência da função ao objetivo que será utilizado como entrada dos neurônios.

$$F_{p_2} = \frac{\min f_p(x)}{f_p(x)} \quad (6)$$

A equação é utilizada para minimização da função objetivo. Onde, F_p é o valor da função de pertinência, $f_p(x)$ é o valor da função objetivo $\max f_p$ é o valor máximo das funções objetivo e $\min f_p$ é o valor mínimo das funções objetivo.

O método de Bellman and Zadeh (1970) foi adotado como a primeira técnica de tomada de decisão neste trabalho, por apresentar eficiência no tratamento de critérios quantitativos e qualitativos na resolução de problemas. Quando é utilizada a abordagem Bellman Zadeh, toda função objetivo $f_p(x)$ é substituída por uma função objetivo nebulosa ou um conjunto nebuloso, como mostrado na equação (7).

$$F_p = \{X, \mu_{f_p}(x), p = 1, \dots, q\} \quad (7)$$

Onde $\mu_{F_p}(x)$ é uma função de pertinência de F_p .

Assim a solução nebulosa D é formada com a função de pertinência:

$$\mu_D(x) = \min_{p=1, \dots, q} \mu_{F_p}(x) \quad (8)$$

Sua utilização permite obter uma solução que prove o grau máximo de pertinência à solução nebulosa D .

$$\max \mu_D(x) = \max \min \mu_{F_p}(x) \quad (9)$$

Desta forma, a melhor configuração segundo o método de Bellman Zadeh é assumida quando ocorre a máxima intercessão entre as funções objetivo. Assim, do ponto de vista formal, o problema é multiobjetivo e substituído pelo problema max min, como mostra a equação (10)

$$X^0 = \operatorname{argmax} \min \mu_{F_p}(x), p = 1, \dots, q \quad (10)$$

No entanto, a busca por soluções baseadas na construção e solução de problemas maxmin representa uma visão pessimista em relação à avaliação da satisfação dos níveis de critérios, o que não é adequado em certas situações de tomada de decisão. Em particular, soluções em que um único objetivo tem um baixo

nível de satisfação e outros critérios têm altos níveis de satisfação são considerados soluções ruins (Junior, 2014).

Levando isso em consideração, a análise multicritério foi complementada utilizando unineurons e nullneurons.

2.5. UNINEURONS E NULLNEURONS

Unineurons e nullneurons são neurônios nebulosos baseado em neurônios lógicos AND e OR, propostos por Pedrycz and Rocha (1993). São neurônios que podem variar entre um neurônio lógico do tipo AND até um neurônio lógico do tipo OR de forma a melhor se adaptar às necessidades do problema a ser resolvido (Hell, 2008). Além disso, a abordagem proposta permite o uso de diversas formas de representação das informações fornecidas por um decisor. Este decisor identifica a importância de cada função objetivo, utilizando pesos diferenciados para cada objetivo (Junior, 2014).

Como o próprio nome já diz, os unineurons são baseados no conceito de uninorma enquanto os nullneurons no conceito de nullnorma.

Uma uninorma e uma nullnorma é um operador *fuzzy* que generaliza a T-norma e a S-norma. Tanto as T-normas quanto as S-normas satisfazem as seguintes propriedades:

- Comutatividade: $a \cup b = b \cup a$;
- Associatividade: $a \cup (b \cup c) = (a \cup b) \cup c$;
- Monotocidade: se $b \leq c$ então $a \cup b \leq a \cup c$;

2.6. UNINORMA

Uma uninorma U é um operador binário com um elemento neutro $g \in [0,1]$. O elemento neutro g é claramente único e pode ser qualquer número de um intervalo unitário. Uma uninorma difere das T-normas e S-normas apenas no que diz respeito ao elemento neutro. Para T-normas e S-normas, tem-se valores fixos para os elementos neutros, enquanto, para as uninormas, este valor pode ser escolhido no intervalo $[0,1]$.

Desta forma, a característica de uma uninorma pode variar suavemente de um *and* puro para um *or* puro quando o elemento identidade varia de 1 para 0. Quando $g = 1$ leva a uma T-norma, quando $g = 0$ leva a uma S-norma Yager and Rybalov (1996). Na literatura, é possível encontrar uma grande variedade de realizações de uninormas e nullnormas Yager and Rybalov (1996); Yager (2001). Uma das realizações mais usadas está vinculada à família de construtores mostrada na equação (11).

$$U(x, y; g) = \begin{cases} gT\left(\frac{x}{g}, \frac{y}{g}\right) & \text{sex, } y \in [0, g] \\ g + (1 - g)S\left(\frac{x-g}{1-g}, \frac{y-g}{1-g}\right) & \text{sex, } y \in [g, 1] \\ \min(x, y) \text{ ou } \max(x, y) & \text{caso contrario} \end{cases} \quad (11)$$

Onde T é uma T-norma, S uma S-norma, $x \in [0,1]^n$ e $y \in [0,1]^n$. Neste trabalho, a T-norma foi considerada como operador min, e a S-norma como operador max.

2.7. NULLNORMA

Uma nullnorma é um operador binário com um elemento de absorção $u \in [0,1]$. O elemento de absorção u é claramente único. A nullnorma também é uma generalização de T-normas e S-normas, pois, por definição, quando $u = 1$ leva a uma S-norma, quando $u = 0$ leva a uma T-norma (Yager and Rybalov, 1996).

Uma realização específica de nullnorma é apresentada e pode ser traduzida na família de construtores mostrada na equação (12).

$$N(x, y; u) = \begin{cases} uS\left(\frac{x}{u}, \frac{y}{u}\right) & \text{sex, } y \in [0, u] \\ u + (1 - u)T\left(\frac{x-u}{1-u}, \frac{y-u}{1-u}\right) & \text{sex, } y \in [u, 1] \\ u, & \text{casocontrario} \end{cases} \quad (12)$$

Para construir os neurônios unineuron e nullneuron, é necessário inicialmente propor-se uma pequena modificação na uninorma e na nullnorma, apresentada nas Equações (11) e (12).

2.8. UNINEURON

$$\tilde{U}(x, y; g) = \begin{cases} gT\left(\frac{x}{g}, \frac{y}{g}\right) & \text{sex, } y \in [0, g] \\ g + (1 - g)S\left(\frac{x-g}{1-g}, \frac{y-g}{1-g}\right) & \text{sex, } y \in [g, 1] \\ \varphi(x, y) & \text{casocontrario} \end{cases} \quad (13)$$

Onde:

$$\varphi(x, y) = \begin{cases} \max(x, y) & \text{seg} = [0, 0.5] \\ \min(x, y) & \text{seg} = [0.5, 1] \end{cases} \quad (14)$$

O processamento do unineuron é dado pela função $uni(x, y; g)$, onde $x \in [0,1]^n$ e $y \in [0,1]^n$ são definidos nas equações (15) e (16).

$$uni(x, y; g) = \tilde{U}[\tilde{U}(x_1, y_1; (1 - g)), \tilde{U}(x_2, y_2; (1 - g)), \dots, \tilde{U}(x_n, y_n; (1 - g)); g] \quad (15)$$

$$uni(x, y; g) = \tilde{U}_{i=1}^n[\tilde{U}(x_i, y_i; (1 - g)); g] \quad (16)$$

2.9. NULLNEURON

$$\tilde{N}(x, y; u) = \begin{cases} T(x, y) & \text{se } u = 0 \\ \frac{1}{2} & \text{se } u = \frac{1}{2} \\ S(x, y) & \text{se } u = 1 \end{cases} \quad (17)$$

Tem-se que para $0 < u < 0.5$, a função \tilde{N} se assemelha a uma T-norma e, para $0.5 < u < 1$ esta função se assemelha a uma S-norma. Assim o processamento do Nullneurônio é dado pela função $null(x, y; u)$, onde $x \in [0, 1]^n$ e $y \in [0, 1]^n$ são definidos nas equações (18) e (19).

$$null(x, y; u) = \tilde{N}[\tilde{U}(x_1, y_1; (1-u)), \tilde{N}(x_2, y_2; (1-u)), \dots, \tilde{N}(x_n, y_n; (1-u)); u] \quad (18)$$

$$null(x, y; u) = \tilde{N}_{i=1}^n [\tilde{N}(x_i, y_i; (1-u)); u] \quad (19)$$

As variáveis x e y correspondem as entradas do sistema, no presente trabalho equivale ao valor da perda e do carregamento dos alimentadores, para cada configuração, já normalizados utilizando a equação (6).

Neste trabalho os elementos identidade g e u foram inicializados aleatoriamente no intervalo $[0, 1]$ e este valor ajustado automaticamente de acordo com a necessidade do problema. O ajuste foi realizado através da equação (20) e (21).

$$g_{novo} = g_{antigo} + \Delta g \quad (20)$$

$$u_{novo} = u_{antigo} + \Delta u \quad (21)$$

Onde Δg é a variação do elemento identidade e calculado através das equações (22) e (23).

$$\Delta g = \delta \alpha_1 [1 - g] - (1 - \delta) \alpha_2 g \quad (22)$$

$$\Delta u = \delta \alpha_1 [1 - u] - (1 - \delta) \alpha_2 u \quad (23)$$

Sendo δ o sinal de reforço dado por $\delta = 1 - \epsilon$, ϵ é o erro que se deseja minimizar calculado como $\epsilon = 1 - y$, onde y é a saída do neurônio. α_1 e α_2 são a taxa de aprendizagem para os elementos identidade onde $0 < \alpha_1 \ll \alpha_2 < 1$.

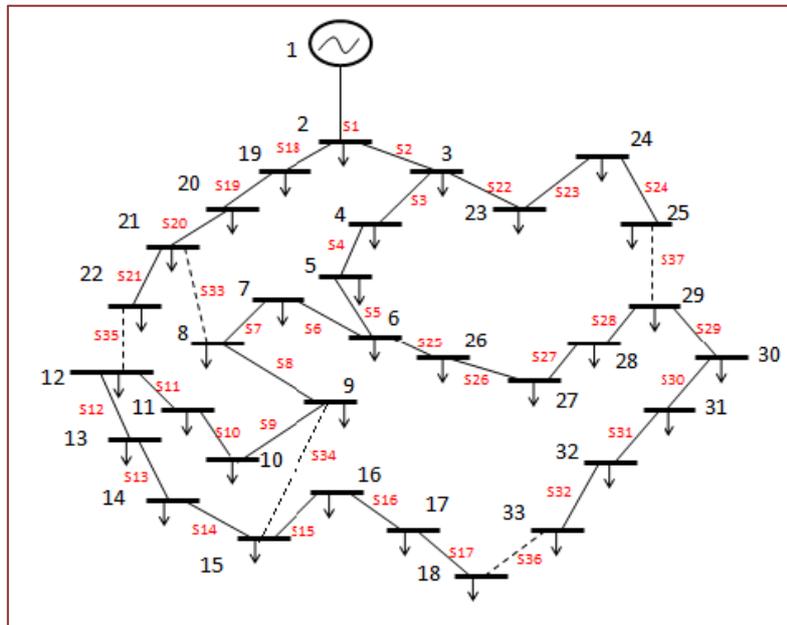
3. RECONFIGURAÇÃO UTILIZANDO UNINEURON E NULLNEURON

Para a aplicação do remanejamento de carga proposto, foi necessário primeiramente implementar, via simulação, uma rede de distribuição de energia elétrica. A rede de distribuição de 33 barras utilizada foi a rede proposta por Baran and Wu (1989).

O sistema consiste em uma rede de distribuição com 1 barra de subestação e 33 barras de cargas, carga ativa total de 3.715 kW, 32 chaves seccionadoras (normalmente fechadas) e 5 chaves de encontro

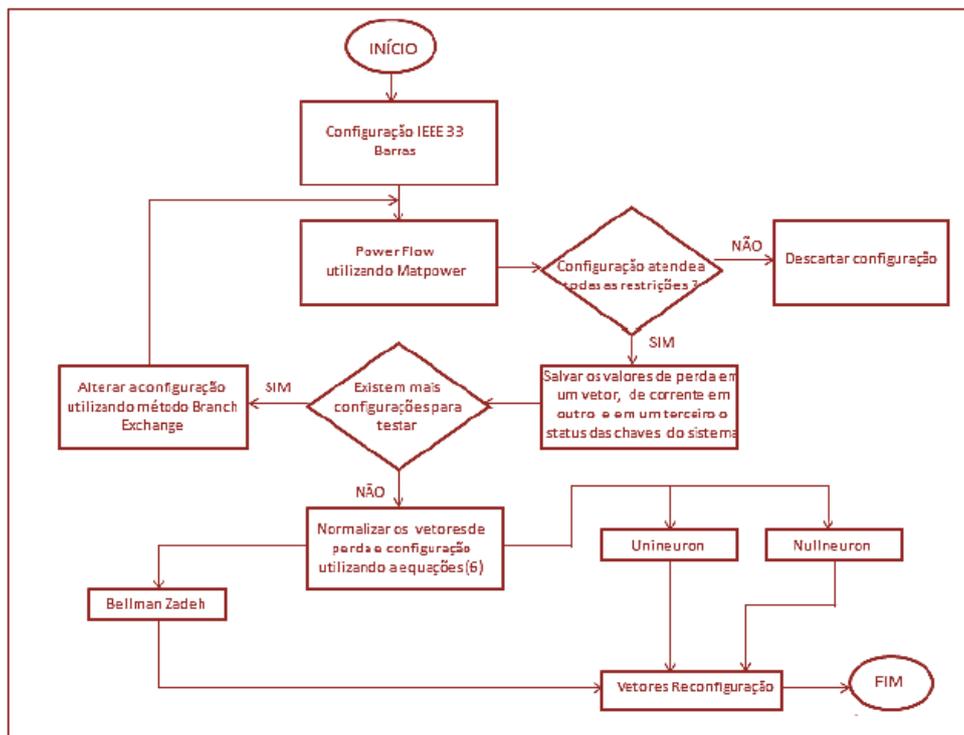
(normalmente abertas). A configuração inicial apresenta perda total ativa de 243,6 kW e Corrente total de 0,499 p.u. O diagrama é mostrado na Figura 2.

Figura 2: Sistema de 33 barras utilizado



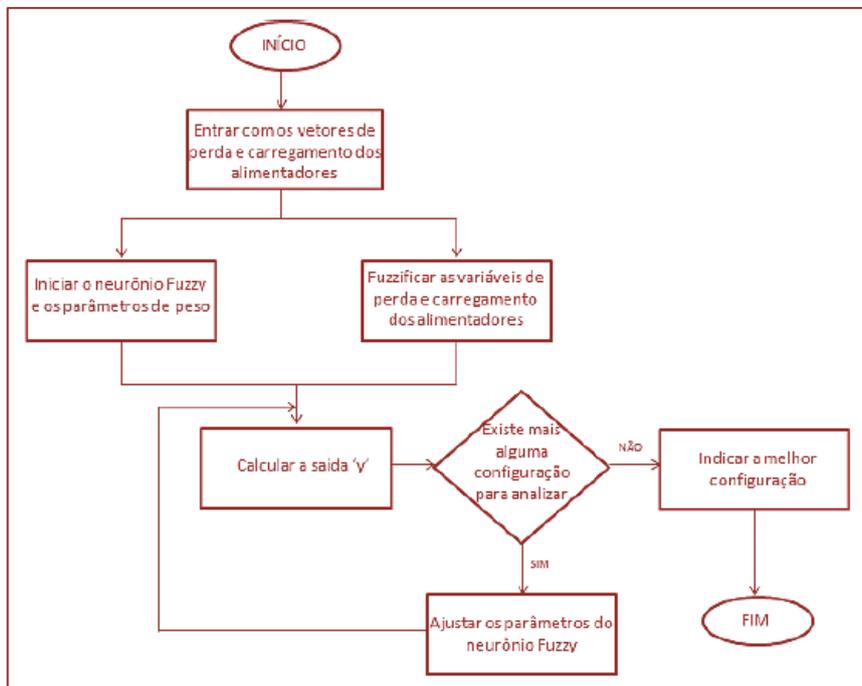
Após a definição da rede foi possível realizar os cálculos de fluxo de potência utilizando o MATPOWER (Zimmerman et al., 2011) e aplicar o método Heurístico Branch Exchange para seleção das configurações. O resultado obtido da aplicação do método foi utilizado como entrada dos algoritmos de Bellman Zadeh, unineuron e nullneuron. O passo a passo aplicado é detalhado no fluxograma da figura 3.

Figura 3: Metodologia adotada



O algoritmo do unineuron e nullneuron foi construído conforme detalhado no fluxograma da figura 4. A Fuzzificação dos vetores de entrada foi realizado utilizando a equação (6). Os valores de g e u foram inicializados aleatoriamente e, como dito anteriormente, ajustados utilizando as equações (20) e (21). Os valores de α_1 foi considerado igual a 0,000001 e de α_2 igual a 0,00005.

Figura 4: Metodologia unineuron e nullneuron



Os resultados utilizando os métodos propostos foram analisados. Estes resultados foram então comparados entre si e mostrados na seção seguinte.

4. RESULTADOS

A Tabela 2 mostra os resultados obtidos utilizando apenas o método Branch Exchange, considerando um problema monoobjetivo. A configuração que apresentou a menor perda de potência elétrica foi a de número 12, e a de número 25 apresentou menor carregamento dos alimentadores. O valor de pertinência mais alto indica uma maior satisfação da solução. Sendo assim, a melhor configuração considerando apenas minimização das perdas é a 12 e a melhor considerando apenas minimização dos alimentadores é a 25.

Tabela 2. Resultado de cada configuração analisada utilizando Branch Exchange

| n° | Chaves abertas | Perda (kW) | Corrente (p.u) | Pert. Perda | Pert. Carreg |
|----|----------------------|------------|----------------|-------------|--------------|
| 1 | S21,S33,S34, S36,S37 | 216,05 | 0,581 | 0,273 | 0,528 |
| 2 | S11,S33,S34, S36,S37 | 156,79 | 0,422 | 0,472 | 0,727 |
| 3 | S10,S33,S34, S36,S37 | 155,13 | 0,418 | 0,478 | 0,734 |
| 4 | S9,S33,S34, S36,S37 | 153,99 | 0,384 | 0,482 | 0,799 |
| 5 | S8,S33,S34, S36,S37 | 153,49 | 0,377 | 0,483 | 0,814 |
| 6 | S9,S20,S34, S36,S37 | 239,33 | 0,652 | 0,195 | 0,471 |
| 7 | S7,S9,S34, S36,S37 | 146,16 | 0,911 | 0,508 | 0,337 |
| 8 | S6,S9,S34, S36,S37 | 145,92 | 0,38 | 0,509 | 0,808 |
| 9 | S7,S8,S9, S36,S37 | 148,79 | 0,391 | 0,499 | 0,785 |
| 10 | S7,S9,S14, S36,S37 | 142,17 | 0,358 | 0,522 | 0,858 |
| 11 | S7,S9,S13, S36,S37 | 144,83 | 0,387 | 0,513 | 0,793 |
| 12 | S7,S9,S14, S32,S37 | 139,55 | 0,364 | 0,53 | 0,843 |
| 13 | S7,S9,S14, S31,S37 | 142,6 | 0,353 | 0,52 | 0,87 |
| 14 | S7,S9,S14, S17,S37 | 147,54 | 0,394 | 0,503 | 0,779 |
| 15 | S7,S9,S14, S24,S32 | 174,2 | 0,444 | 0,414 | 0,691 |
| 16 | S7,S9,S14, S28,S32 | 139,98 | 0,348 | 0,529 | 0,882 |
| 17 | S7,S33,S34, S36,S37 | 156,53 | 0,375 | 0,473 | 0,819 |
| 18 | S6,S33,S34, S36,S37 | 168,2 | 0,437 | 0,434 | 0,703 |
| 19 | S7,S21,S34, S36,S37 | 164,56 | 0,431 | 0,446 | 0,712 |
| 20 | S7,S8,S34, S36,S37 | 147,65 | 0,376 | 0,503 | 0,816 |
| 21 | S7,S9,S34, S36,S37 | 146,16 | 0,374 | 0,508 | 0,821 |
| 22 | S7,S8,S14, S36,S37 | 147,29 | 0,388 | 0,504 | 0,791 |
| 23 | S7,S8,S32, S34,S37 | 146,47 | 0,373 | 0,507 | 0,823 |
| 24 | S7,S8,S31, S34,S37 | 154,8 | 0,308 | 0,479 | 0,997 |
| 25 | S7,S8,S30, S34,S37 | 171,72 | 0,307 | 0,422 | 1 |
| 26 | S7,S8,S29, S34,S37 | 297,15 | 1,001 | 0 | 0,307 |
| 27 | S7,S8,S17, S34,S37 | 151,22 | 0,401 | 0,491 | 0,766 |
| 28 | S7,S8,S24, S30,S34 | 193,57 | 0,378 | 0,349 | 0,812 |
| 29 | S7,S8,S28, S30,S34 | 173,44 | 0,331 | 0,416 | 0,927 |

A tabela 3 mostra o resultado obtido após inserir os dados nos neurônios maxmin. A redução foi calculada relação a perda de potência elétrica da configuração inicial, que equivale a 202,68 kW e em relação ao carregamento inicial Utilizando unineuron e nullneuron, foi mostrado os resultados para diferentes pesos de cada objetivo. Os pesos utilizados foram 20% para perda e 80% para carregamento dos alimentadores, 50% para perda e 50% para carregamento dos alimentadores e 90% para perda e 10% para carregamento dos alimentadores. O resultado é mostrado na Tabela 4. Ambos os métodos apresentaram o mesmo resultado.

Tabela 3. Melhor configuração utilizando Bellman Zadeh

| n° | Chaves abertas | Perda (kW) | Corrente (p.u) | Red. Perda (%) | Red.. Carreg (%) |
|----|--------------------|------------|----------------|----------------|------------------|
| 12 | S7,S9,S14, S32,S37 | 139,55 | 0,364 | 31,15 | 27,05 |

Como já era de se esperar, quando o carregamento dos alimentadores foi o objetivo privilegiado em uma proporção bem maior (20/80), a configuração escolhida foi a que apresentou menor carregamento dos alimentadores, a configuração 25, uma redução na perda de 7,49% e no carregamento dos alimentadores de 38,48%. O mesmo ocorreu quando a perda foi privilegiada em uma proporção bem maior (90/10), a configuração 12 que apresentou a maior redução de perda foi a escolhida, uma redução de 28,20% na perda e de 30,26% de carregamento dos alimentadores.

Quando ambos os objetivos foram considerados em mesma proporção (50/50), a melhor configuração foi a que ocorreu uma redução na perda de 30,94% e redução no carregamento dos alimentadores de 30,26%. Sendo assim, ambos convergiram para a melhor topologia em que os objetivos de minimização de perda e minimização do carregamento dos alimentadores são atendidos (tabela 4).

Tabela 4. Melhores configurações utilizando utilizando unineuron e nullneuron para diferentes pesos

| Peso P/C (%) | n° | Chaves abertas | Perda (kW) | Corrente (p.u) | Red. Perda (%) | Red.. Carreg (%) |
|--------------|----|--------------------|------------|----------------|----------------|------------------|
| 20/80 | 25 | S7,S8,S30, S34,S37 | 171,72 | 0,307 | 15,28 | 38,48 |
| 50/50 | 16 | S7,S9,S14, S28,S32 | 139,98 | 0,348 | 30,94 | 30,26 |
| 90/10 | 12 | S7,S9,S14, S32,S37 | 139,55 | 0,364 | 31,15 | 27,05 |

A tabela 5 mostra uma comparação dos métodos utilizados neste trabalho com alguns presentes na literatura, como PSO (Particle Swarm Optimization), MPSO (Modified Particle Swarm Optimization) e ACO (Ant Colony Optimization). Os valores de PSO, presentes na tabela, foram retirados de [?], os de MPSO de [?] e os do método ACO de [?] Ambos os métodos aqui comparados, presentes na literatura, consideraram apenas a minimização da perda e utilizaram a mesma rede do IEEE de 33 barras. Os três métodos aplicados neste trabalho apresentaram uma configuração com maior redução de perda do que a utilizando PSO. Já para os métodos MPSO e ACO a configuração escolhida foi a mesma utilizando Bellman Zadeh, o que evidencia que o Método de Bellman Zadeh privilegia um único objetivo. O unineuron e nullneuron apresentaram menor redução de perda do que utilizando MPSO e ACO, o que é justificado pelo fato destes estarem considerando a minimização de dois objetivos em conjunto.

Tabela 5. Comparação com métodos presentes na literatura

| Método | Chaves abertas | Redução Perda (%) | Redução Carreg. (%) |
|---------------|--------------------|-------------------|---------------------|
| Bellman Zadeh | S7,S9,S14,S32,S37 | 31,15 | 27,05 |
| MPSO | S7,S9,S14,S32,S37 | 31,15 | 27,05 |
| ACO | S7,S9,S14,S32,S37 | 31,15 | 27,05 |
| Unineuron | S7,S9,S14,S28,S32 | 30,94 | 30,26 |
| Nullneuron | S7,S9,S14,S28,S32 | 30,94 | 30,26 |
| PSO | S8,S17,S28,S33,S34 | 30,92 | - |

5. CONCLUSÃO

Neste trabalho foi proposto um algoritmo baseado no método unineuron e nullneuron para a solução do problema de reconfiguração de sistemas de distribuição de energia elétrica. Os resultados obtidos foram comparados com os utilizando a abordagem de Bellman Zadeh e com alguns métodos presentes na literatura.

Utilizando Bellman Zadeh, apenas uma função objetivo foi privilegiada, no caso a minimização da perda, não se mostrando um método adequado para tomada de decisão multiobjetivo. Utilizando unineuron e

neuron os resultados mostraram soluções de boa qualidade, atendendo a todas as restrições físicas e operacionais do problema. É importante ressaltar que no contexto da tomada de decisões multiobjetivo, soluções consideradas de boa qualidade são aquelas que melhor representam as preferências do decisor. Ambos os métodos apresentaram também um tempo baixo de processamento computacional o que representa uma vantagem em relação aos métodos metaheurísticos.

REFERÊNCIAS

- [1] Amin Heidari, M. (2017). Optimal network reconfiguration in distribution system for loss reduction and voltage-profile improvement using hybrid algorithm of pso and aco. *CIREDE - Open Access Proceedings Journal*, 2017(1), 2458–2461. doi:10.1049/oap-cired.2017.1007.
- [2] Atteya, I.I., Ashour, H., Fahmi, N., and Strickland, D. (2017). Radial distribution network reconfiguration for power losses reduction using a modified particle swarm optimisation. *CIREDE - Open Access Proceedings Journal*, 2017(1), 2505–2508. doi:10.1049/oap-cired. 2017.1286.
- [3] Baran, M.E. and Wu, F.F. (1989). Network reconfiguration in distribution systems for loss reduction and load balancing. *IEEE Transactions on Power Delivery*, 4(2), 1401–1407. doi:10.1109/61.25627.
- [4] Bellman, R. and Zadeh, L. (1970). Decision-Making In a Fuzzy Environment. *Management Science Series BApplication*, 17(4), B141–B164.
- [5] Bernardon, D.P., Garcia, V.J., Ferreira, A.S.Q., Canha, L.N., and Abaide, A.R. (2009). New fuzzy multicriteria decision making algorithm to distribution network reconfiguration. In 2009 44th International Universities Power Engineering Conference (UPEC), 1–5.
- [6] Berredo, R.C., Ekel, P.Y., Martini, J.S.C., Palhares, R.M., Parreiras, R.O., and Pereira, Jr., J.G. (2011). Decision making in fuzzy environment and multicriteria power engineering problems. *International Journal of Electrical Power & Energy Systems*, 33(3), 623–632. doi:10.1016/j.ijepes.2010.12.020.
- [7] Chen, G., Wang, Y., Lu, G., Hu, J., You, D., Zhang, F., and He, Z. (2016). An improved load-shedding model based on power flow tracing. In 2016 12th World Congress on Intelligent Control and Automation (WCICA), 1590–1593. doi:10.1109/WCICA.2016.7578552.
- [8] Civanlar, S., Grainger, J.J., Yin, H., and Lee, S.S.H. (1988). Distribution feeder reconfiguration for loss reduction. *IEEE Transactions on Power Delivery*, 3(3), 1217–1223. doi:10.1109/61.193906.
- [9] Dahalan, W.M. and Mokhlis, H. (2012). Network reconfiguration for loss reduction with distributed generations using pso. In 2012 IEEE International Conference on Power and Energy (PECon), 823–828. doi:10.1109/PECon.2012.6450331.
- [10] Ghorbani, M.A., Hosseinian, S.H., and Vahidi, B. (2008). Application of ant colony system algorithm to distribution networks reconfiguration for loss reduction. In 2008 11th International Conference on Optimization of Electrical and Electronic Equipment, 269–273. doi:10.1109/OPTIM.2008.4602377.
- [11] Hell, M. (2008). Abordagem Neurofuzzy para Modelagem de Sistemas Dinâmicos Não Lineares. Tese de doutorado, Faculdade de Engenharia Elétrica e de Computação da Universidade Estadual de Campinas, Campinas.
- [12] Junior, J. (2014). Modelos e Metodos de Tomada de Decisões Multiobjetivo em Ambiente com Incertezas e Suas Aplicações. Tese de doutorado, Universidade Federal de Minas Gerais, Belo Horizonte.
- [13] Li, X., Zeng, Z., Zhang, Y., and Xu, X. (2007). A study of distribution load transfer operation based on gis. In 2007 International Conference on Machine Learning and Cybernetics, volume 3, 1428–1433. doi:10.1109/ICMLC.2007.4370369.
- [14] Macedo, L. (2012). Reconfiguração de sistemas de distribuição de energia elétrica para minimização de perdas ativas totais via otimização por enxame de partículas (pso).
- [15] Merlin, A. and Back, H. (1975). Search for a minimal-loss operating spanning tree configuration in an urban power distribution system. In Proceeding 5th Power System Conference, 18.
- [16] Neto, A. and Vellasco, M. (2016). Reconfiguração de redes de distribuição utilizando restrições fuzzy. *Revista de Inteligência Computacional Aplicada*, 10. Oliveira, C. (2016). Algoritmo para reconfiguração de sistema de distribuição de energia elétrica baseado em evolução diferencial.
- [17] Pandiarajan, K. and Babulal, C.K. (2011). Overload alleviation in electric power system using fuzzy logic. In 2011 International Conference on Computer, Communication and Electrical Technology (ICCCET), 417–423. doi:10.1109/ICCCET.2011.5762511.
- [18] Pedrycz, W. and Rocha, A.F. (1993). Fuzzy-set based models of neurons and knowledge-based networks. *IEEE Transactions on Fuzzy Systems*, 1(4), 254–266. doi:10.1109/91.251926.

- [19] Peponis, G.J. and Papadopoulos, M.P. (1997). New dynamic, branch exchange method for optimal distribution system planning. IEE Proceedings - Generation, Transmission and Distribution, 144(3), 333–339. doi: 10.1049/ip-gtd:19971135.
- [20] Romano, R., Gaspar, L., Guedes, L., Lisboa, A., and Vieira, D. (2013). Ferramenta multicriterio para reconfiguraç~ao de redes radiais de distribuiç~ao de energia eletrica. In Congresso de Inovaç~ao Tecnologica em Energia Eletrica (VII Citenel).
- [21] Silva, F. (2010). Reconfiguraç~ao otima de sistemas de distribuiç~ao de energia eletrica baseado no comportamento de colônia de formigas. Tese de doutorado, Escola de Engenharia de São Carlos de São Paulo, São Carlos.
- [22] Tofis, Y., Timotheou, S., and Kyriakides, E. (2017). Minimal load shedding using the swing equation. IEEE Transactions on Power Systems, 32(3), 2466–2467. doi: 10.1109/TPWRS.2016.2614886.
- [23] Yager, R. (2001). Uninorms in fuzzy systems modeling. Fuzzy Sets and Systems, 122(1), 167–175. doi: {10.1016/S0165-0114(00)00027-0}.
- [24] Yager, R. and Rybalov, A. (1996). Uninorm aggregation operators. Fuzzy Sets AND Systems, 80(1), 111– 120. doi:{10.1016/0165-0114(95)00133-6}.
- [25] Yan, J., Li, C., and Liu, Y. (2017). Adaptive load shedding method based on power imbalance estimated by ann. In TENCON 2017 - 2017 IEEE Region 10 Conference, 2996–2999. doi:10.1109/TENCON.2017.8228375.
- [26] Zimmerman, R.D., Edmundo Murillo-Sanchez, C., and Thomas, R.J. (2011). Matpower: Steady-State Operations, Planning, and Analysis Tools for Power Systems Research and Education. IEEE Transactions ON POWER SYSTEMS, 26(1), 12–19. doi:{10.1109/ TPWRS.2010.2051168}.

Capítulo 2

Estudo da coordenação de relés de sobrecorrente e modelagem de proteção adaptativa considerando Geração Distribuída em Sistemas de Distribuição

Luis Henrique Pereira Vasconcelos

Aryfrance Rocha Almeida

Nelber Ximenes Melo

José Genilson Sousa Carvalho

Bartolomeu Ferreira dos Santos Júnior

Resumo: Existe um crescente aumento do uso da Geração Distribuída com base em fontes alternativas para suprir o consumo de energia elétrica da população. No entanto, apesar das diversas vantagens que essa prática proporciona, existem alguns cuidados que devem ser tomados, principalmente no que diz respeito ao aspecto da proteção dos sistemas de transmissão e distribuição de energia. Este trabalho realiza a verificação dos impactos que a inserção de Geração Distribuída pode causar na coordenação dos relés de sobrecorrente e uma modelagem de relé com ajuste adaptativo para minimizar esses efeitos. Inicialmente, foi realizada a modelagem de um sistema de distribuição padrão do IEEE de 13 barras no software ATPDraw com todos os seus elementos principais como fonte, cargas, linhas de transmissão e transformadores de potência. Em seguida, foram adicionados ao sistema dois relés de sobrecorrente em cascata coordenados e obtidos seus respectivos tempos de atuação e margens de coordenação para correntes de curto-circuito mínima e máxima. Os mesmos testes foram realizados considerando a operação de gerações distribuídas conectadas em alguns pontos do sistema. Por fim, foi proposto um método de proteção adaptativa capaz de adequar a coordenação dos relés para diversos cenários, na qual um bloco de controle recebe como parâmetros as correntes de curto-circuito máxima e mínima para cada topologia e modifica o ajuste do relé a jusante conforme necessário, mantendo a seletividade e a velocidade da proteção.

Palavras-chave: Geração Distribuída; coordenação; relés; proteção adaptativa; ATPDraw.

1. INTRODUÇÃO

A principal função do Sistema Elétrico de Potência (SEP) é fornecer energia elétrica aos seus consumidores de forma confiável e econômica. Devido ao alto custo dos equipamentos que compõem um SEP, este representa um investimento considerável de capital. Por isso, para o retorno sobre este investimento ser maximizado, a margem de utilização do sistema deve ser a maior possível. No entanto, essa margem deve respeitar os limites de segurança para operação de um sistema elétrico confiável. A confiabilidade de um sistema de energia está diretamente relacionada com o desempenho de seus esquemas de proteção. Um sistema de proteção eficiente deve possuir cinco características essenciais, são elas: sensibilidade, velocidade, seletividade, estabilidade e confiabilidade (Rush, 2011).

O modelo de sistema elétrico baseado em uma única fonte de energia, para o qual o esquema de proteção contra curtos-circuitos foi projetado vem sendo rapidamente alterado pela conexão de unidades de Geração Distribuída (GD). Essa mudança de paradigma representa um desafio para a forma tradicional de eliminar falhas do sistema e, portanto, requer uma análise apurada dos impactos causados por essas conexões a fim de validar a adoção de novas filosofias de proteção pelas distribuidoras (Luiz, 2012). Alguns resultados de estudos sobre o efeito da inserção de unidades de GD no desempenho dos equipamentos de proteção são discutidos em trabalhos como Dugan and McDermott (2002), Britto et al. (2004) e Thong et al. (2007).

Como possibilidade de solução, a proteção adaptativa é uma filosofia que permite fazer ajustes no sistema de proteção para torná-lo mais adequado às condições variáveis do sistema elétrico. Os relés atuais permitem a configuração de vários conjuntos de ajustes de proteção, chamados de grupos de ajustes, que podem corresponder a diferentes situações operacionais ou topológicas às quais a rede de distribuição pode ser submetida (Luiz, 2012). Em trabalhos como Cheung et al. (2008), Yongli et al. (2009) e Chaves and Leão (2014), os autores propõem estratégias de proteção adaptativa capazes de alterar os ajustes dos equipamentos de proteção de acordo com a configuração do sistema, tornando o sistema de proteção mais eficiente.

Este documento tem como objetivo analisar os efeitos da geração distribuída para a coordenação dos relés de sobrecorrente em um sistema de distribuição, além de propor um método de ajuste adaptativo que utiliza os estados dos disjuntores das GDs para determinar a configuração de operação do sistema elétrico e, a partir das correntes de falta correspondentes de cada situação, calcula o ajuste adequado. Assim, é possível manter a seletividade e a velocidade da proteção independente da topologia de operação do sistema.

2. METODOLOGIA

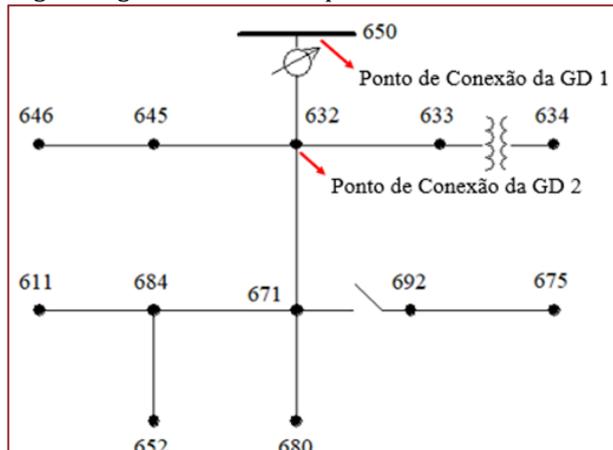
O software de simulação utilizado neste trabalho foi o ATPDraw, um dos programas mais usados na área acadêmica para estudos de distúrbios em sistemas elétricos (Miguel 2011). Primeiramente, realizou-se a modelagem do sistema de distribuição modelo do IEEE de 13 barras (Kersting, 1991). Em seguida, foram inseridos, nas barras 650 e 632, dois relés de sobrecorrente, coordenados de modo a obedecer aos critérios de seletividade. Então, foram obtidos seus tempos de atuação (t_{dR1} e t_{dR2}) e suas margens de coordenação (Δt) para as seguintes faltas: bifásica na barra 680, no qual a margem de coordenação é máxima, e trifásica no início da linha L632- 671, no qual a margem de coordenação é mínima. Todas as faltas neste trabalho foram aplicadas em 0,1 s de simulação.

Os testes foram realizados também para os casos com a GD inserida em duas localizações distintas (barras 650 e 632). Foram calculados, para os casos com GD, as diferenças percentuais das margens de coordenação (Dif. Δt) com relação ao caso sem GD. Por fim, foi modelado um bloco de controle responsável por alterar o ajuste do relé R1 (dial de tempo) de acordo com a presença da GD no sistema. Então, foram realizados novos testes utilizando o bloco de ajuste adaptativo e comparados os resultados para validação do método proposto.

2.1 MODELAGEM DO SISTEMA ELÉTRICO NO ATPDRAW

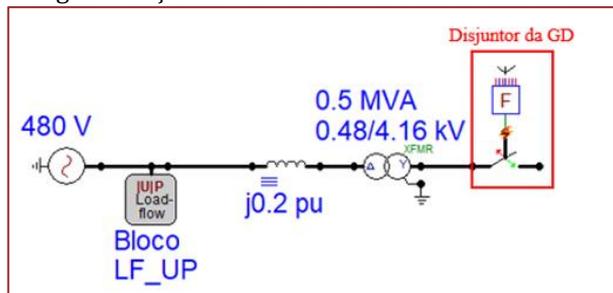
O circuito utilizado neste estudo corresponde ao sistema de distribuição padrão IEEE de 13 barras. A Fig. 1 apresenta o diagrama do circuito com as suas respectivas barras enumeradas e as indicações dos pontos de conexão das GDs.

Fig. 1 Diagrama do sistema padrão IEEE de 13 barras.



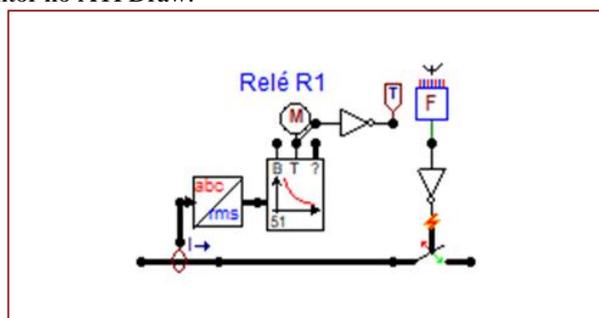
As duas GDs utilizadas neste trabalho possuirão características exatamente iguais. O tipo de gerador distribuído utilizado é uma máquina síncrona, que pode ser modelada simplesmente com uma fonte tensão e uma reatância (sub-transitória) em série. Um valor típico da reatância sub-transitória para geradores de pequeno porte é 0,2 pu, calculados na base de 480 V e 100 MVA (Kinderman, 2010). A potência instalada da GD é de 300 kW e foi fixada através do bloco LF_UP do ATPDraw. O transformador de conexão da GD utilizará ligação Delta-Estrela aterrado, pois é a forma de conexão mais adotada no caso de geração própria (Luiz, 2012). O componente TACS FORTRAN1 controlará a abertura e o fechamento do disjuntor da GD (0 = aberto e 1 = fechado). A Fig. 2 ilustra a modelagem da GD no ATPDraw.

Fig. 2 Geração Distribuída modelada no ATPDraw



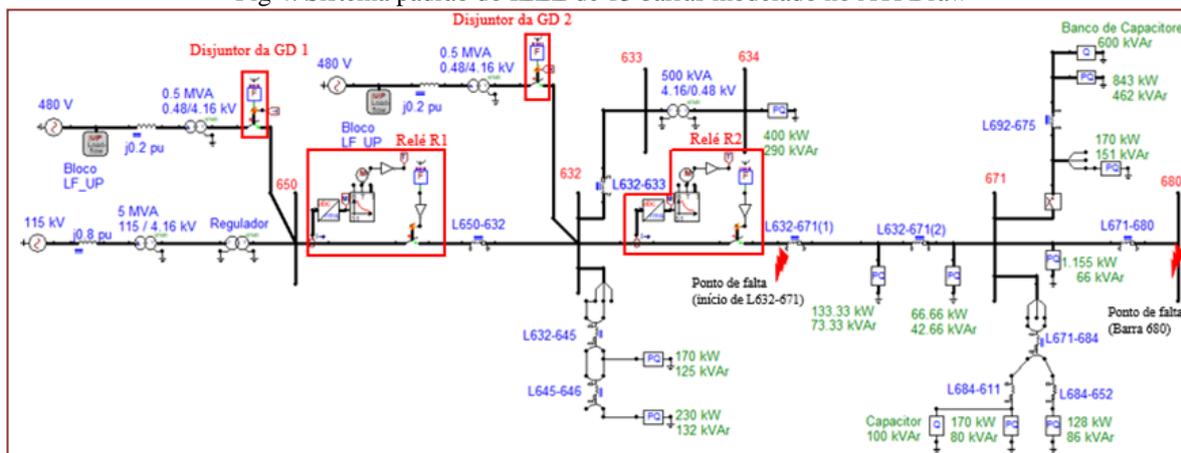
Os relés foram modelados através do componente W1RELAY51I do ATP que tem como parâmetros de entrada o dial de tempo, a corrente de pick-up e os valores das constantes A, B e Q que dependem do tipo de curva ao qual deseja-se utilizar. Por exemplo, para a curva IEC extremamente inversa (utilizada neste trabalho), temos: A = 80, B = 0 e Q = 2. Em conjunto com o relé, foi utilizado o componente MODELS ABC2RMS para fornecer o valor RMS da corrente no ponto de instalação do relé e os elementos TACS para acionamento do disjuntor conforme ilustrado na Fig. 3.

Fig. 3 Conjunto relé e disjuntor no ATPDraw.



Na Fig. 4 é ilustrado todo o sistema modelado no ATPDraw.

Fig 4. Sistema padrão do IEEE de 13 barras modelado no ATPDraw



2.2 PARAMETRIZAÇÃO DOS RELÉS SEM A GD INSERIDA NO SISTEMA

O primeiro relé (R1) localiza-se no início da linha L650-632, de forma a proteger a mesma e funcionar como relé de retaguarda do relé R2 para trechos mais à jusante. O relé R2 localiza-se logo após a barra 632 e antes da linha L632-671, protegendo desde o ponto de sua instalação até o final do alimentador. A curva de atuação escolhida para os relés foi a IEC extremamente inversa, por ser a mais indicada para sistemas de distribuição primária (Filho and Mamede, 2011). Esta curva obedece a seguinte equação:

$$td = \frac{80 \times DT}{\left(\frac{I_{cc}}{I_{aj}}\right)^2 - 1} \quad (1)$$

Onde

- td é o tempo de disparo do relé (s);
- DT é o dial de tempo (s);
- I_{cc} é a corrente de curto-circuito (A);
- I_{aj} é a corrente de ajuste do relé (A).

Inicialmente parametrizou-se o relé R2 conforme os critérios abordados em (Rush, 2011). O ajuste de corrente deve ser escolhido de forma que o relé não opere para a corrente de carga máxima no circuito protegido, mas que opere para uma corrente igual ou maior à corrente de falta mínima esperada. Como não existe nenhum dispositivo de proteção à jusante de R2 para coordenar, foi escolhido um dial de tempo (DTR2) arbitrário baixo de 0,1 para se trabalhar com valores baixos de tempo de simulação.

A parametrização de R1 foi feita de forma a garantir a coordenação com R2. De acordo com Filho and Mamede (2011), para garantir a seletividade da proteção, deve-se manter uma diferença mínima de 0,4 s entre os tempos de operação de dois relés em cascata, levando em consideração o tempo de operação do disjuntor, a tolerância do fabricante do disjuntor e o tempo de segurança do projeto. Em Rush (2011), a margem típica de coordenação entre dois relés é de 0,3 s para relés numéricos (neste estudo adotou-se 0,3 s). Após alguns testes, concluiu-se que as curvas dos relés aproximam-se, o que significa que a margem de atuação mínima deve ser estabelecida para a corrente de falta máxima percebida pelo relé mais à jusante (R2), que corresponde a uma falta trifásica no início da linha L632-671. Sendo assim, o tempo de atuação de R1 para a falta máxima detectada por R2 deve ser dado pela seguinte equação:

$$tdR1(I_{ccm\acute{a}x}) \geq tdR2(I_{ccm\acute{a}x}) + 0,3 \text{ s} \quad (2)$$

Onde:

- tdR1(I_{ccmáx}) é o tempo de disparo de R1 (s) para a falta máxima medida por R2
- tdR2(I_{ccmáx}) é o tempo de disparo de R2 (s) para a falta máxima medida por R2.

Como ambos os relés utilizarão a curva IEC extremamente inversa, substituindo (1) em (2), o dial de tempo mais adequado para o relé R1 deve ser dado por:

$$DR1_{\min} = \left(\frac{80 \times DTR2}{\left(\frac{I_{cc_max_R2}}{I_{ajR2}}\right)^2 - 1} + \Delta t \right) \times \frac{\left(\frac{I_{cc_max_R1}}{I_{ajR1}}\right)^2 - 1}{80} \quad (3)$$

Onde DR1_{mín} é o dial de tempo mínimo para o relé R1 (s); DTR2 é o dial de tempo do relé R2 (s); I_{cc_max_R1} é a corrente de curto-circuito máxima detectada por R1 (A); I_{cc_max_R2} é a corrente de curto-circuito máxima detectada por R2 (A); I_{ajR2} é a corrente de ajuste de R2 (A); e Δt é a margem de coordenação mínima (s).

Após seguir esses procedimentos de cálculos, foram utilizados os ajustes dos relés apresentados na Tabela 1.

Tabela 1. Ajustes dos relés (sem GD em operação)

| Parâmetros | R1 | R2 |
|------------------------|------|-----|
| Corrente de ajuste (A) | 675 | 514 |
| Dial de Tempo (s) | 0,17 | 0,1 |
| Tipo de Curva | EI | EI |

2.3 MODELAGEM DO CONTROLE DE AJUSTE ADAPTATIVO

A proteção adaptativa foi realizada a partir da criação de um componente em linguagem MODELS, denominado Controle. Esse bloco recebe como entradas os estados dos disjuntores das GDs (0 = aberto e 1 = fechado) e fornece como saída o valor do dial de tempo apropriado para a nova topologia do sistema que será utilizado pelo relé R1. Esse valor deve ser calculado de acordo com (3). O reajuste do relé consiste na alteração somente do seu valor de dial de tempo, o que significa movimentar verticalmente a sua curva de atuação.

Assim, para o caso em que a presença das GDs cause diminuição nas margens de coordenação, o reajuste do relé R1 aumentará a margem de coordenação mínima para valores adequados acima do critério de segurança (0,3 s), restaurando a característica de seletividade da proteção.

Por outro lado, caso a presença da GD aumente as margens de coordenação, o reajuste do relé R1 diminuirá essas margens e tornará sua atuação de retaguarda mais veloz. A presença de GD no sistema altera seus níveis de correntes de curto-circuito (Choi et al. 2008), portanto, o bloco de controle criado recebe como parâmetros de entrada as correntes de falta máximas detectadas pelos relés em cada caso, além das suas correntes de ajustes e do dial de tempo do relé R2, previamente calculados.

A Fig. 5 ilustra o Bloco de Controle para ajuste adaptativo modelado no ATPDraw. A Tabela 2 mostra o valor do dial de tempo fornecido pelo bloco de controle para cada caso, conforme os estados dos disjuntores das GDs.

Fig. 5 Bloco de Controle para ajuste adaptativo.

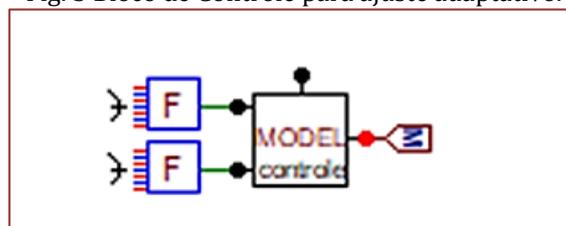
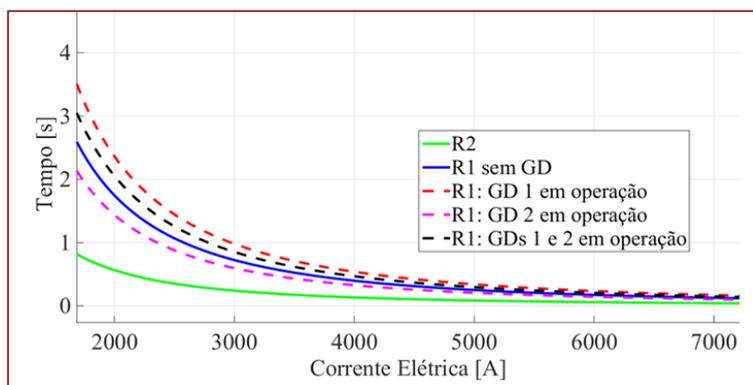


Tabela 2. Ajuste adaptativo do relé R1

| Estado Disjuntor | | DR1 |
|------------------|------|------|
| GD 1 | GD 2 | |
| 0 | 0 | 0,17 |
| 0 | 1 | 0,14 |
| 1 | 0 | 0,23 |
| 1 | 1 | 0,20 |

A Fig. 6 mostra a curva do relé R2 (dial fixo) e as curvas do relé R1 para os diferentes valores de dial mostrados na Tabela 2. Optou-se por limitar o eixo horizontal para valores de corrente dentro do intervalo de 2000 a 7000 A para melhor visualização das curvas.

Fig 6. Curvas de atuação dos relés R1 e R2.



3. RESULTADOS E DISCUSSÕES

As Figs. 7 e 8 apresentam os valores RMS das correntes na fase A medidas pelos relés em cada caso com faltas aplicadas no início da linha L632-671 (falta máxima).

Fig 7. Corrente RMS na fase A medida por R1.

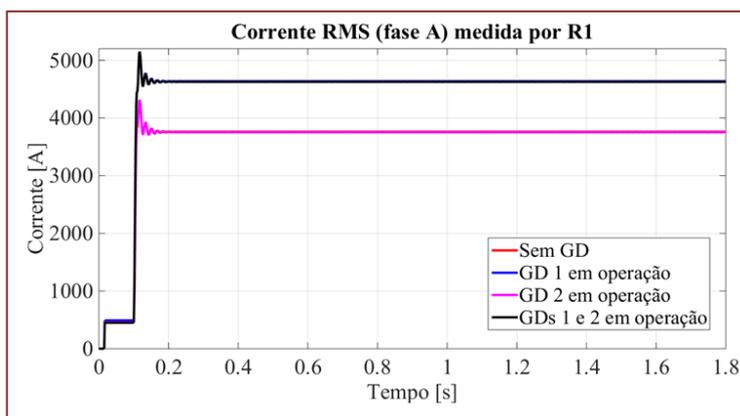
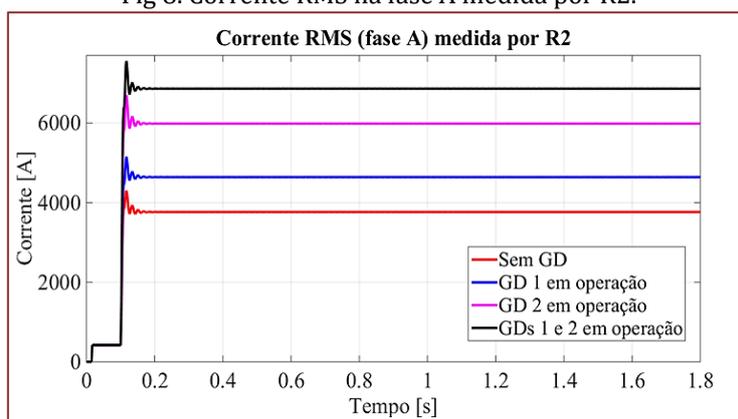


Fig 8. Corrente RMS na fase A medida por R2.



Nas tabelas deste trabalho, os valores de $I_{ccmín}$ e $I_{ccmáx}$ correspondem aos valores RMS das correntes de curto-circuito mínima (falta bifásica na barra 680) e máxima (falta trifásica no início da linha L632- 671) medidas no ponto de ocorrência da falta. Para o caso antes da inserção da GD no sistema, a Tabela 3 contém os tempos de atuação e margens de coordenação dos relés.

Tabela 3. Caso sem GD

| $I_{ccmín}$ (A) | td R2 (s) | td R1 (s) | Δt (s) |
|-----------------|-----------|-----------|----------------|
| 2378,22 | 0,392 | 1,145 | 0,753 |
| $I_{ccmáx}$ (A) | | | |
| 3749,71 | 0,153 | 0,454 | 0,301 |

Observou-se que os relés R1 e R2 estão devidamente coordenados obedecendo aos critérios de seletividade, pois a menor margem de coordenação dos relés é 0,301 s.

3.1 CASO COM SOMENTE A GD 1 EM OPERAÇÃO

A Tabela 4 contém os tempos de atuação e margens de coordenação dos relés no caso em que somente a GD 1 está em operação e não há uso do ajuste adaptativo para o relé R1.

Tabela 4. Caso com a GD 1 em operação sem ajuste adaptativo de R1

| $I_{ccmín}$ (A) | td R2 (s) | td R1 (s) | Δt (s) | Dif. Δt (%) |
|-----------------|-----------|-----------|----------------|---------------------|
| 2703,59 | 0,3 | 0,872 | 0,572 | 24,04 |
| $I_{ccmáx}$ (A) | | | | |
| 4626 | 0,1 | 0,296 | 0,196 | 34,9 |

Houve um aumento dos níveis de curto-circuito e redução nos tempos de atuação e margens de coordenação dos relés. Para a falta máxima, a margem de coordenação ficou abaixo do critério de segurança, o que prejudica a seletividade da proteção. O ajuste de R1 considerando somente a GD1 em operação foi calculado pelo bloco de controle utilizando os novos valores de correntes de falta, resultando em $DT = 0,23$.

A Tabela 5 contém os tempos de atuação e margens de coordenação dos relés no caso em que a GD 1 está em operação e há uso do ajuste adaptativo no relé R1.

Tabela 5. Caso com a GD 1 em operação com ajuste adaptativo de R1

| $I_{ccmín}$ (A) | td R2 (s) | td R1 (s) | Δt (s) | Dif. Δt (%) |
|-----------------|-----------|-----------|----------------|---------------------|
| 2703,59 | 0,3 | 1,18 | 0,88 | - 16,87 |
| $I_{ccmáx}$ (A) | | | | |
| 4626 | 0,1 | 0,4 | 0,3 | 0,33 |

É possível observar que, com a utilização do bloco de ajuste adaptativo, os tempos de atuação do relé R1 aumentam, o que faz com que as margens de coordenação aumentem e adquiram um valor mínimo igual a 0,3 s, ou seja, dentro do critério de seletividade.

3.2. CASO COM SOMENTE A GD 2 EM OPERAÇÃO

A Tabela 6 contém os tempos de atuação e margens de coordenação dos relés para o caso em que a GD 2 está em operação e não há uso do ajuste adaptativo para o relé R1.

Tabela 6. Caso com a GD 2 em operação sem ajuste adaptativo de R1

| Iccmín (A) | td R2 (s) | td R1 (s) | Δt (s) | Dif. Δt (%) |
|------------|-----------|-----------|----------------|---------------------|
| 3107,71 | 0,225 | 1,595 | 1,37 | - 81,94 |
| Iccmáx (A) | | | | |
| 5913,52 | 0,061 | 0,456 | 0,395 | - 31,23 |

Neste caso, as correntes de falta foram ainda maiores que no caso anterior (GD 1 em operação). No entanto, apenas R2 detectará a contribuição da GD e atuará em um tempo menor. Isso provoca um aumento nas margens de coordenação, o que faz com que os equipamentos do sistema fiquem submetidos por mais tempo a altos níveis de corrente, gerando perda de vida útil ou até danos mais críticos. Isso afeta a premissa de velocidade do sistema de proteção. Portanto, o ajuste de R1 considerando a GD na barra 632 deverá possuir um de dial de tempo menor. Este valor foi calculado pelo bloco de controle utilizando os novos valores de correntes de falta máxima e mínima e resultou em DT = 0,14. A Tabela 7 contém os tempos de atuação e margens de coordenação dos relés para o caso com a GD 2 em operação e aplicação do ajuste adaptativo para o relé R1.

Tabela 7. Caso com a GD 2 em operação com ajuste adaptativo de R1

| Iccmín (A) | td R2 (s) | td R1 (s) | Δt (s) | Dif. Δt (%) |
|------------|-----------|-----------|----------------|---------------------|
| 3107,71 | 0,225 | 1,31 | 1,085 | - 44,1 |
| Iccmáx (A) | | | | |
| 5913,52 | 0,061 | 0,37 | 0,309 | - 2,66 |

Nota-se que, com a utilização do relé com ajuste adaptativo, os tempos de atuação do relé R1 diminuíram. Isso gerou uma redução nas margens de coordenação, o que significa que a atuação de retaguarda de R1 tornou-se mais rápida.

3.3. CASO COM AS GDS 1 E 2 EM OPERAÇÃO

A Tabela 8 contém os tempos de atuação e margens de coordenação, dos relés para o caso em que ambas as GDS 1 e 2 estão em operação e não há uso do ajuste adaptativo para o relé R1.

Tabela 8. Caso com as GDS 1 e 2 em operação sem ajuste adaptativo de R1

| Iccmín (A) | td R2 (s) | td R1 (s) | Δt (s) | Dif. Δt (%) |
|------------|-----------|-----------|----------------|---------------------|
| 3341 | 0,194 | 0,882 | 0,68 | 9,69 |
| Iccmáx (A) | | | | |
| 6798 | 0,046 | 0,297 | 0,251 | 16,6 |

Para este caso, as correntes de falta aumentaram ainda mais. Porém, o relé R1 detecta somente a contribuição da GD 1. Mesmo assim, ambos os relés operam em pontos de suas curvas onde a margem de coordenação entre eles torna-se menor do que o valor mínimo de segurança, o que significa que o sistema de proteção perde sua característica de seletividade. O ajuste de R1 considerando as GDS 1 e 2 em operação foi calculado pelo bloco de controle utilizando os novos valores de correntes de falta, resultando em DT = 0,2.

A Tabela 9 contém os tempos de atuação e margens de coordenação, dos relés para o caso em que as GDS 1 e 2 estão em operação e há uso do ajuste adaptativo para o relé R1.

Tabela 9. Caso com as GDs 1 e 2 em operação com ajuste adaptativo de R1

| Iccmín (A) | td R2 (s) | td R1 (s) | Δt (s) | Dif. Δt (%) |
|------------|-----------|-----------|----------------|---------------------|
| 3341 | 0,194 | 1,4 | 1,206 | -4,8 |
| Iccmáx (A) | | | | |
| 6798 | 0,046 | 0,349 | 0,303 | -0,664 |

É possível observar que com o ajuste adaptativo, os tempos de atuação do relé R1 aumentam. Os relés passam a operar em pontos das curvas em que a margem de coordenação volta a ter valores iguais ou maiores que 0,3 s, o que significa obedecer ao princípio da seletividade.

4. CONCLUSÕES

Neste trabalho, foi possível fazer análises a respeito da coordenação de relés de sobrecorrente no contexto do uso de geradores distribuídos nos sistemas de distribuição nos dias atuais. Desenvolveu-se um método simples de proteção adaptativa baseado no reajuste do dial de tempo do relé de acordo com os estados dos disjuntores das GDs. O método mostrou-se eficaz pois foi capaz de manter as margens de coordenação dos relés em níveis adequados para as diferentes topologias do sistema.

AGRADECIMENTOS

Agradecemos à Universidade Federal do Piauí (UFPI), ao Departamento de Engenharia Elétrica – UFPI e ao Programa de Pós-Graduação em Engenharia Elétrica – UFPI pela parceria e apoio ao desenvolvimento desta pesquisa.

REFERÊNCIAS

- [1] Britto, T. M. de; Moraes, D. R.; Marin, M. A. et al. (2004). Distributed generation impacts on the coordination of protection systems in distribution networks. Transmission and Distribution Conference and Exposition: Latin América, IEEE/PES, pp. 623–628.
- [2] Chaves, R. C. P. and Leão, F. B. (2014). Sistema de proteção adaptativo para redes de distribuição com inserção de geradores distribuídos. Cigré, Belo Horizonte, MG, Brasil.
- [3] Cheung, H.; Hamlyn, A.; Wang, L. et al. (2008). Networkintegrated adaptive protection for feeders with distributed generations. Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century, IEEE., pp.1-8, 20-24 July.
- [4] Choi, J. H. et al. (2008). Adaptive protection schemes of distributed generation at distribution network for automatic reclosing and voltage sags. Sustainable Energy Technologies. Singapore: IEEE International Conference, pp. 810–815.
- [5] Dugan, R.C. and McDermott, T.E. (2002). Distributed generation. Industry Applications Magazine, IEEE vol.8, no.2, pp.19-25.
- [6] Filho, J. M. and Mamede, D. R. (2011). Proteção de Sistemas Elétricos de Potência. LTC, Rio de Janeiro, RJ.
- [7] Kindermann, G (2010). Curto-Circuito. 5a. ed. Florianópolis: Labplan, UFSC.
- [8] Luiz, C. M. (2012). Avaliação dos Impactos da Geração Distribuída para Proteção do Sistema Elétrico. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais (UFMG), Belo Horizonte.
- [9] Miguel, P. M. (2011). Introdução à Simulação de Relés de Proteção Usando a Linguagem "MODELS" do ATP. Rio de Janeiro: Ciência Moderna.
- [10] Rush, P. (2011). Proteção e Automação de Redes: Conceito e Aplicação (1ª ed.). São Paulo: Edgard Blücher.
- [11] Thong, V.V.; Driesen, J.; Belmans, R. (2007). Dispersed Generation Interconnection and Its Impact on Power Loss and Protection System. Universities Power Engineering Conference.
- [12] Yongli, Z.; Shaoqun, S.; Dewen, W.; (2009). Multiagents-based wide area protection with best-effort adaptive strategy. International Journal of Electrical Power & Energy Systems, Volume 31, Issues 2-3, February-March, Pages 94-99.
- [13] Kersting, W. (1991). Radial distribution test feeders. Power Systems, IEEE Transactions on, vol. 6, no. 3, pp. 975–985.

Capítulo 3

Sistema Eletrocinético para Desaguamento de Rejeitos Provenientes da Mineração

Raphael Henrique

Marcos Moraes Tavares Ronzani

Ana Carolina Ferreira

Saulo Neves Matos

Alan Kardek Rêgo Segundo

Lucas Deleon Ferreira

Paulo Marcos de Barros Monteiro

Resumo: A separação da água do rejeito proveniente do minério de ferro vem se tornando um dos temas mais importantes para as empresas mineradoras, devido ao dever de descomissionar barragens. Neste trabalho, apresenta-se o método de separação eletrocinético, bem como um circuito de acionamento automático para o sistema, com a finalidade de otimizar o processo de desaguamento de água. O circuito é baseado em um regulador de tensão controlado via PWM (Pulse Width Modulation), usado para se aplicar um gradiente de tensão elétrica em uma célula eletrocinética de maneira automática, almejando um desaguamento constante. Durante os ensaios, avaliou-se o desaguamento gerado por duas formas de acionamento diferentes: aplicando-se uma tensão constante e uma tensão intermitente à célula. Por fim, são apresentadas as perspectivas de trabalhos futuros para se realizar o controle de tensão e corrente aplicados à célula em malha fechada.

Palavras-chaves: Descomissionamento de Barragens; Método Eletrocinético; Desaguamento de Rejeito de Minério.

1. INTRODUÇÃO

Nos processos da mineração brasileira, o minério é transcrito por etapas úmidas para seu melhor aproveitamento, gerando rejeitos que, atualmente, são dispostos em barragens (Portes, 2013).

Com os problemas ambientais ocorridos com a disposição de rejeitos em barragens no Brasil, empresas do ramo minerador juntamente com as áreas de geotecnia das universidades, estão pesquisando novas técnicas de adensamento e desaguamento desses materiais úmidos, proporcionando maior segurança às barragens.

De acordo com Guimarães (2011), as separações sólido-líquido, como as operações de espessamento e filtragem, são processos de desaguamento para a recuperação da água e a operação da polpa restante. O espessamento é uma operação de sedimentação dos sólidos por gravidade, resultando em uma polpa de partículas no fundo do reservatório. Já a filtragem é um processo em que o rejeito num meio filtrante permite a passagem do líquido e retém a passagem dos sólidos. No entanto, ambos os processos são pouco eficazes para o desaguamento do líquido, pois o primeiro gera uma polpa ainda muito aquosa, e o segundo envolve um processo mais complexo, pois é necessário alguma operação anterior, como o espessamento ou ciclonagem, para garantir um teor mínimo de sólidos. Além disso, vale ressaltar que os filtros perdem a eficiência no decorrer do desaguamento, sendo inevitável trocá-los.

Com o intuito de promover novos métodos e expandir a área geotécnica, Ferreira (2016) desenvolveu um equipamento denominado célula eletrocinética, que permitiu explorar os conceitos do processo de eletrodessaguamento, em consequência do fenômeno de eletrodrenagem (Branco, 1978). Basicamente o fenômeno consiste na movimentação de um resíduo aquoso saturado com cátions e ânions, devido a aplicação de um campo elétrico, que dependendo da intensidade pode ser capaz de desassociar a água do resíduo.

Assim, neste artigo busca-se aprimorar o sistema de acionamento da célula de eletrocinese desenvolvida por Ferreira (2016). Na Seção 3 são explicados o funcionamento do projeto atual e de um projeto elaborado para o acionamento do sistema. Em seguida, na Seção 4, são apresentados os resultados obtidos em ensaios, utilizando um rejeito proveniente da mineração de minério de ferro e bauxita. Por fim, nas Seções 5 e 6, são apresentadas as conclusões e as recomendações para trabalhos futuros.

2. OBJETIVOS

2.1 OBJETIVOS GERAIS

O principal objetivo deste trabalho é otimizar o desaguamento de água de um resíduo derivado da mineração, por meio da aplicação de um gradiente elétrico de tensão em dois eletrodos, dispostos nas extremidades da célula.

2.2 OBJETIVOS ESPECÍFICOS

Os objetivos específicos deste trabalho compreendem as seguintes etapas:

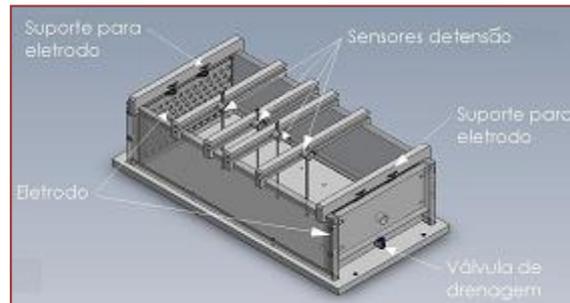
- Desenvolver um sistema de alimentação de energia para o equipamento (célula eletrocinética), visando tensões elevadas e, conseqüentemente, uma maior eficácia no processo de desaguamento;
- Avaliar a influência do gradiente elétrico (75, 100, 150 V/m) no processo de desaguamento /adensamento eletrocinético;
- Analisar os efeitos promovidos pela técnica da tensão intermitente (2/1; 3/1,5; 4/2 – minutos ligado/minutos desligado);
- Aprimorar o sistema regulador de tensão proposto por Ronzani (2018), elaborando uma lógica de controle automático da tensão, responsável por induzir uma vazão constante no processo de desaguamento;
- Analisar a técnica de tensão contínua no desaguamento eletrocinético. Nesse processo são avaliadas as conseqüências da aplicação de um valor constante de tensão elétrica, visando uma maior eficiência no desaguamento.

3. METODOLOGIA

A célula desenvolvida por Ferreira (2016) é constituída principalmente por: (i) por dois eletrodos que recebem o gradiente elétrico de tensão; (ii) suportes para os eletrodos, duas válvulas de drenagem de água nas extremidades da célula; e (iii) quatro sensores de tensão que amostram, em um software supervisor, a tensão em diferentes distâncias entre os eletrodos.

O projeto da célula, de forma esquemática, e o supervisor podem ser observados nas Figuras 1 e 2, respectivamente.

Figura 1: Esquemático da célula eletrocinética



Fonte: (Ferreira, 2016)

Figura 2: Sistema de supervisão de dados



Para realizar um ensaio, inicialmente realizou-se a caracterização do rejeito de minério de ferro ou bauxita, em que o teor de sólidos e a presença de argilas minerais que afetam a capacidade de troca catiônica são variáveis relevantes para o transporte de partículas sob o efeito da eletrocinética. Em seguida, realizou-se a montagem da célula, de acordo com o desenho esquemático da Figura 1. Após a inserção do material na célula, o sistema eletrônico é ativado e a válvula de drenagem é aberta, dando início ao experimento. A cada tempo predeterminado, é captado manualmente o volume de água proveniente do desaguamento até que essa porção de água seja quase nula, encerrando-se o experimento.

Atualmente o sistema elétrico é composto por uma fonte externa de 32 V, que energiza o sistema e alimenta os eletrodos da célula eletrocinética. O sistema também é capaz de realizar as configurações do experimento, como a aplicação de tensão intermitente ou contínua. No entanto, apesar desse sistema possuir acionamento eletrônico, as leituras de vazão e a regulagem de tensão na fonte externa são ajustadas manualmente, sem nenhum tipo de controle automático.

Para solucionar essa limitação, foi elaborado um circuito regulador de tensão no software Proteus, de acordo com o diagrama apresentado na Figura 3 e o esboço em 3D da Figura 4. Esse circuito recebe a alimentação de uma fonte externa de 32 V e um sinal PWM de uma placa Arduino MEGA2560. O sinal PWM passa por um filtro passa-baixa RC, transformando-o em um sinal de tensão constante, que varia de 0 a 5 V de forma proporcional à variação do ciclo de trabalho do PWM.

Esse sinal é amplificado pelo amplificador operacional LM324, na configuração não inversor, e aplicado ao terminal de referência do regulador de tensão ajustável LM317. Logo, a tensão de saída do circuito, aplicada aos eletrodos da célula eletrocinética, pode ser controlada, de forma automática, por meio do sinal PWM fornecido pelo Arduino.

Figura 3: Circuito regulador de tensão

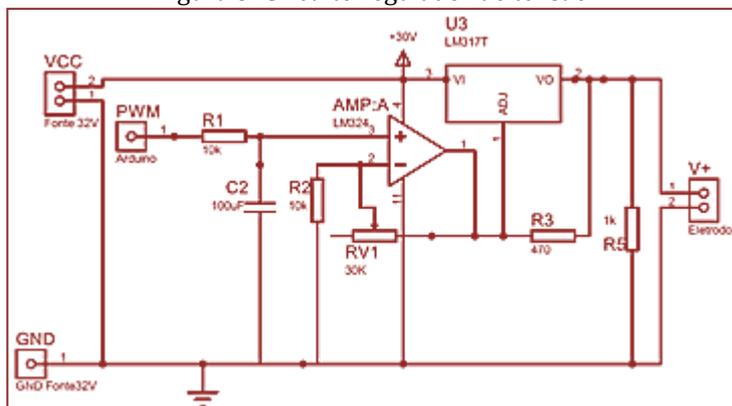
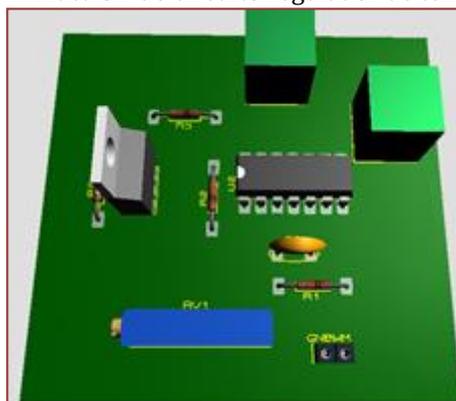
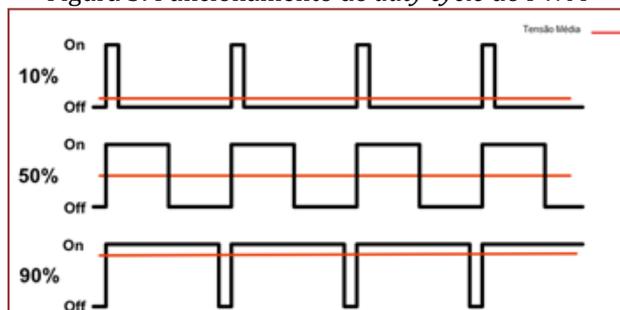


Figura 4: Placa 3D do circuito regulador de tensão



Com um código de programação na IDE da plataforma Arduino, é possível estabelecer as configurações do pino PWM do microcontrolador. Assim, de acordo com o decréscimo da vazão, aumenta-se o estado ativo (porcentagem) do duty cycle, como apresentado na Figura 5. Logo, eleva-se a tensão média de alimentação da placa reguladora e, conseqüentemente, aumenta-se o gradiente de tensão aplicado nos eletrodos.

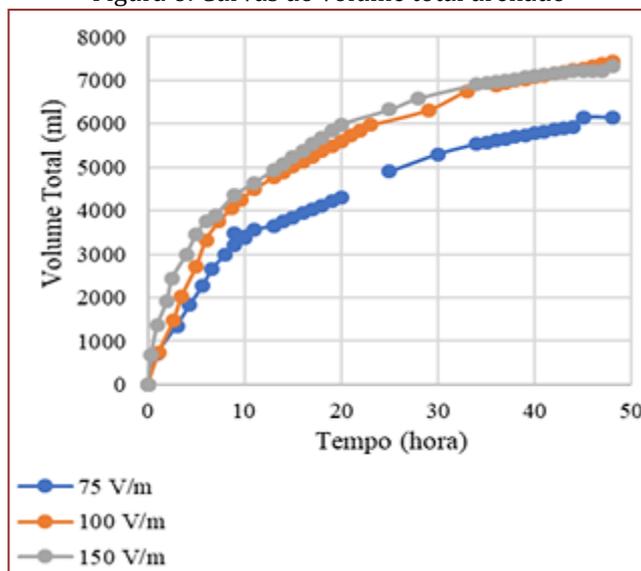
Figura 5: Funcionamento do *duty cycle* do PWM



4. RESULTADOS

Utilizando o sistema atual, o gráfico obtido em ensaios aplicando gradientes de tensão de 75, 100 e 150 V/m, é ilustrado na Figura 6, de cada gradiente pelo tempo. Nesse gráfico é possível visualizar que, quanto maior a tensão aplicada, maior é o volume drenado por hora, validando a técnica da eletro-drenagem em rejeitos advindos da mineração.

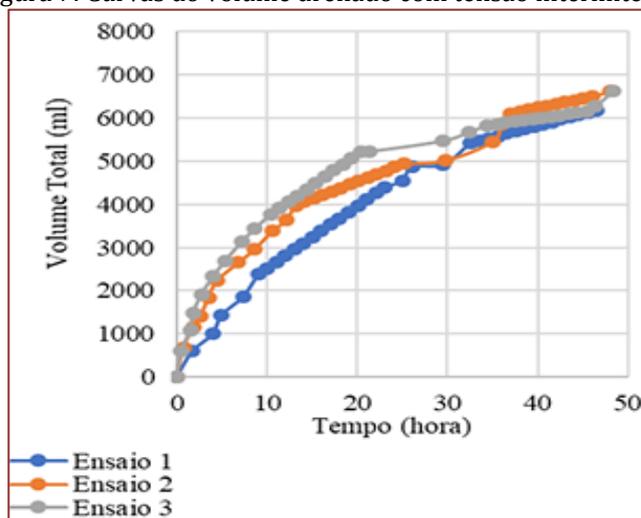
Figura 6: Curvas do volume total drenado



Se for empregado o sistema com a placa reguladora de tensão sem controle automático, não haveria mudança em relação à Figura 6, já que o sistema manteria o gradiente de tensão constante o ensaio inteiro, mas com o controle automático, é suposto que haveria um aumento de volume total drenado no tempo, além da inclinação da curva ser mais retilínea, com sua extremidade até superando 8000 ml drenadas, pois com o declínio do volume escoado, aumentaria a tensão aplicada.

Um das outras técnicas para eficiência da drenagem de água, é a aplicação da tensão elétrica intermitente, que seria alternar entre a ativação da tensão e seu desligamento. Na Figura 7, representa-se o gráfico do volume drenado ao longo do tempo, com as curvas de três configurações de tensão intermitente: Ensaio 1 (2 minutos ligado e 1 minuto desligado); Ensaio 2 (3 minutos ligado e 1,5 minutos desligado); e Ensaio 3 (4 minutos ligado e 2 minutos desligado).

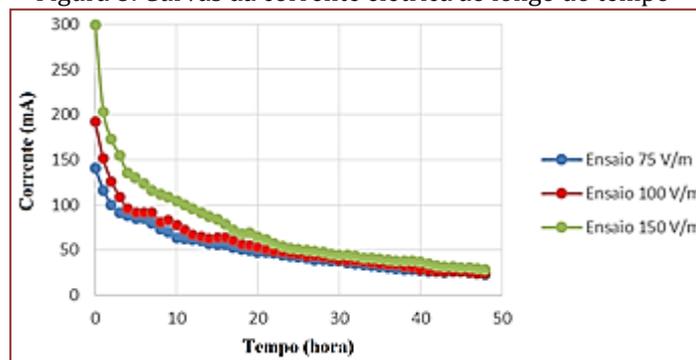
Figura 7: Curvas do volume drenado com tensão intermitente



Aplicando a técnica de tensão elétrica intermitente é possível visualizar que, apesar das curvas serem diferentes, no final dos ensaios o volume drenado é semelhante, tendo potencial para outra pesquisa em relação ao gasto energético

Como o sistema apresenta uma tensão constante, e com o decorrer do ensaio o desaguamento eleva a porcentagem de sólidos, a resistência do rejeito aumenta e, conseqüentemente a corrente decai para valores menores que 50 mA, como visto na Figura 8.

Figura 8: Curvas da corrente elétrica ao longo do tempo



5. CONCLUSÃO

Este artigo demonstrou a relevância do projeto da célula eletrocinética para a área de geotecnia, mais especificamente para o descomissionamento de barragens, apresentando resultados eficazes ao se aplicar um gradiente elétrico de tensão em uma porção de rejeito advindo da mineração. Também foi proposto um sistema de acionamento automático da tensão aplicada aos eletrodos da célula, visando a otimização do desaguamento.

6. TRABALHOS FUTUROS

Em trabalhos futuros, pretende-se desenvolver um controlador de vazão, em malha fechada, para o sistema. Para isso, a vazão será medida indiretamente por meio de um sensor de nível de coluna de água proveniente do desaguamento, pois a célula de pequeno porte construída por Ferreira (2016) apresenta vazão muito baixa, da ordem de ml/h, o que dificulta a realização da medição por meio de um sensor de vazão convencional.

Além disso, pretende-se investigar se corrente elétrica é uma variável relevante, pois na implementação do método eletrocinético em um complexo minerador, é fundamental ter uma análise detalhada das variáveis envolvidas. Para isso é proposto, como projeto futuro, o desenvolvimento de um sistema que controle de vazão baseado na corrente elétrica aplicada à célula, ao invés da tensão.

O sistema terá como base o amplificador operacional OPA549, um componente de baixo custo, com limiar de 0 a 10 A e entrada para sinal de controle. Assim, a tensão será uma variável livre, e a corrente uma variável que dependerá da vazão de água do desaguamento.

AGRADECIMENTOS

Os autores gostariam de agradecer ao professor Lucas Deleon Ferreira, da Universidade Federal de Ouro Preto, pela contribuição e apoio ao projeto, bem como à empresa Vale, pelo financiamento e fornecimento de material para os ensaios.

REFERÊNCIAS

- [1] Castello Branco, J. E. (1978). Estudo da eletro-osmose em solos finos. Dissertação mestrado, Universidade Federal do Rio de Janeiro, Rio de Janeiro.
- [2] Ferreira, L. D. (2016). Desenvolvimento de Equipamento de Laboratório para Estudo de Fenômenos Eletrocinéticos no Processo de Adensamento de Resíduos de Mineração. Dissertação doutorado, Universidade Federal de Ouro Preto, Ouro Preto.
- [3] Guimarães, N. C. (2011). Filtragem de rejeitos de minério de ferro visando à sua disposição em pilhas. Universidade Federal de Minas Gerais, Belo Horizonte.
- [4] Portes, A. M. (2013). Avaliação da disposição de rejeitos de minério de ferro nas consistência polpa e torta. Dissertação mestrado, Universidade Federal de Minas Gerais, Belo Horizonte.
- [5] Ronzani, M. M. (2018). Desenvolvimento de um Sistema de Controle em uma Célula de Adensamento/Desaguamento Eletrocinético de Rejeitos de Mineração. Dissertação mestrado, Universidade Federal de Ouro Preto, Ouro Preto.

Capítulo 4

Modelagem Matemática da Curva de Descarga da Bateria de um Quadrirotor Rolling Spider utilizando a Teoria de Identificação de Sistemas

Adriel de Oliveira Freitas

Lígia Rodrigues Machado

Francisco Alexsandro Silva Freitas

Vandilberto Pereira Pinto

Camila Tabosa de Souza Lima

Resumo: Os quadrirotos tem sido largamente utilizados em diversas aplicações, fazendo com que os estudos acerca destes sejam expandidos. O monitoramento da disponibilidade energética das baterias dos quadrirotos é realizado com base em conhecimentos relacionados a curva de descarga desses dispositivos armazenadores de energia. Este trabalho apresenta a aplicação de estruturas de modelos paramétricos lineares da teoria de identificação de sistemas, com o objetivo de identificar o modelo matemático que melhor representa a dinâmica de descarga de baterias utilizadas em quadrirotos Rolling Spider. Foram aplicadas as estruturas de modelos ARX, ARMAX, e BJ a partir de dados coletados em experimentos reais. Os modelos foram implementados com o auxílio da ferramenta computacional ident, presente no software Matlab/Simulink. Os resultados obtidos comprovam que os modelos paramétricos utilizados são eficazes para descrever o perfil de descarga das baterias utilizadas, sendo que o modelo BJ apresentou um melhor resultado quando comparado com os demais modelos.

Palavras-chaves: Quadrirotos, Identificação de Sistemas, Modelagem Matemática, Curva de Descarga.

1 INTRODUÇÃO

No cenário da aviação, diversos veículos aéreos têm sido desenvolvidos para uso civil e militar, contudo, a presença de um piloto em tais veículos sempre era obrigatória. Com o avanço tecnológico, sistemas de alta complexidade foram desenvolvidos, possibilitando o controle das aeronaves de forma remota ou autônoma. Surge, então, os veículos aéreos não tripulados (VANTs), uma aeronave munida de um sistema embarcado inteligente ligado a diversos sensores e atuadores, tornando esse veículo capaz de realizar diversas atividades com objetivo pessoal ou profissional (Silva and Cordeiro, 2011).

Além do desenvolvimento de protótipos de baixo custo, outros dois fatores contribuíram de forma significativa para o aumento da utilização de quadrirotores em diversas áreas. O primeiro fator consiste no aumento da contribuição de pesquisadores para o controle de trajetória e estabilidade deste tipo de aeronave (Silva, 2015). Já o segundo fator consiste na versatilidade obtida a partir do auxílio de uma fonte de energia denominada bateria (Romio et al., 2012). No projeto de quadrirotores o tempo de vida da bateria é considerado uma das características mais importantes, pois indica o tempo que a aeronave irá operar sem a necessidade de conectar a uma fonte externa.

A autonomia de voo deste tipo de aeronave está intrinsecamente ligado às limitações de tamanho, peso e capacidade de armazenamento da bateria acoplada em sua fuselagem. Assim é notório a necessidade, por parte dos fabricantes de baterias desenvolverem produtos que atendam a essas limitações e proporcionem uma maior capacidade de armazenamento (Romio, 2013), conseqüentemente uma maior segurança e autonomia de voo.

Outra necessidade importante é a utilização de métodos capazes de realizar o prognóstico do tempo de vida de baterias, para a referida previsão utilizam-se diversas técnicas para modelar as características de descarga de uma bateria, os modelos matemáticos com amplo destaque na literatura são os de enfoque analítico, elétrico, estocástico, híbrido e experimental (Douglas et al., 2018). O método experimental não tem sido utilizado no contexto de VANTs, por ser inviável do ponto de vista econômico, e pelo motivo apresentar dificuldades na implementação (Romio, 2013), pois o tempo de vida da bateria dos quadrirotores dependem também de fatores externos que atuam no sistema dinâmico da aeronave através de distúrbios.

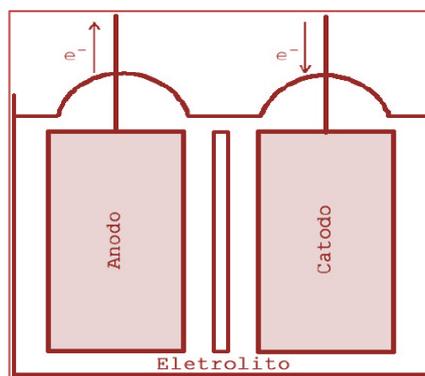
Neste contexto, o presente trabalho tem como objetivo aplicar técnicas de identificação de sistemas para obter um modelo acurado e versátil que caracterize a dinâmica de descarga da bateria de um VANT do tipo quadrirotor. Para tanto, será apresentado o estudo e aplicação dos modelos paramétricos lineares ARX, ARMAX e BJ a partir de dados obtidos em experimentos reais.

Assim, o artigo está organizado da seguinte forma. Na Seção 2 são descritos alguns conceitos importantes relacionados às baterias. Na Seção 3 são apresentados os modelos paramétricos lineares da teoria de identificação de sistemas que foram utilizados no presente trabalho, já na Seção 4 são apresentados a plataforma de testes utilizada para aquisição dos dados experimentais, além dos procedimentos utilizados para coletar os dados e estimação dos parâmetros. Na Seção 5 são apresentados os parâmetros estimados, a validação dos modelos matemáticos ARX, ARMAX e BJ, e a acurácia apresentada por cada modelo. E finalmente, na Seção 6 é apresentada a conclusão.

2 BATERIAS

Uma bateria é constituída de células eletroquímicas que podem ser conectadas em série, paralelo, e em ligações mistas. Nessas células ocorre o processo de reação eletroquímica e com isso a energia química armazenada nas células é transformada em energia elétrica. O esquema de composição de uma célula eletroquímica (Figura 1) é formada por dois eletrodos: ânodo e cátodos, e entre esses eletrodos tem um eletrólito que os separa (Romio, 2013).

Figura 1. Esquema de composição de uma célula eletroquímica.

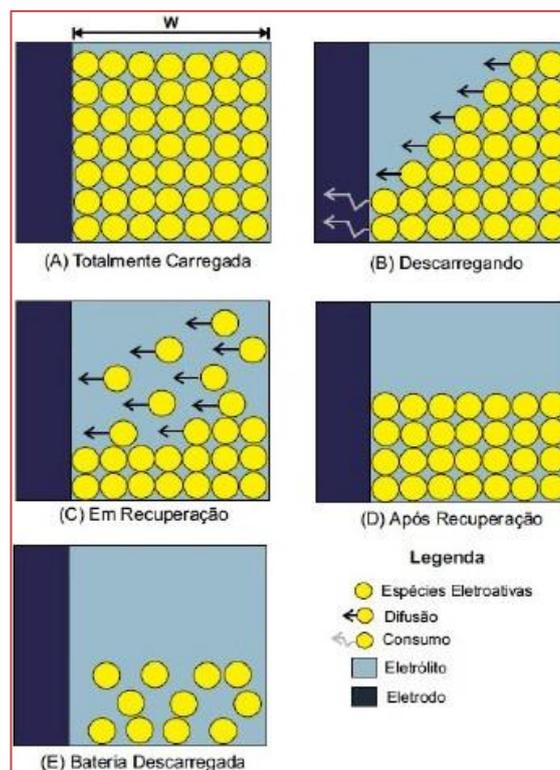


Quando ocorre o processo de descarga da bateria, na parte do ânodo acontece uma reação de oxidação, e na do cátodo o processo é uma reação de redução. Devido esses processos é que ocorre a troca de elétrons na célula eletroquímica. No processo de oxiredução, a Tensão (expressa em volts) e a capacidade (expressa em ampere-hora) são grandezas, que quando estudadas e feito o produto delas é possível mensurar o quanto de energia armazenada tem disponível na bateria. Considerando a grandeza Tensão no caso ótimo de descarga de uma bateria ideal é constante durante o período de descarregamento e tem uma queda instantânea a zero quando a bateria fica descarregada, com isso a capacidade ideal é constante no processo de descarga e toda a energia armazenada é utilizada no processo. Mas quando se trata de um caso real, aparecem variáveis não-lineares que devem ser estudadas pois elas influenciam no tempo de vida útil da bateria.

2.1 EFEITO DE RECUPERAÇÃO

Um dos efeitos não-lineares que devem ser estudados é o Efeito de Recuperação, que ocorre em períodos de relaxação da bateria, onde há pouca energia para ser escoada. Nesse período ocorre uma reestruturação dos elétrons nas células e com isso um aumento da capacidade da bateria, isso acontece quando se tem uma quantidade significativa de carga antes do sistema chegar no nível do cutoff. Na Figura 2, pode ser observados os estágios do efeito de recuperação da bateria, onde em 'A' a bateria está na sua totalidade de carga, onde pode ser observado que em todo comprimento do eletrólito se tem um agrupamento de espécies eletroativas. Em 'B' acontece um descarregamento, onde é diminuída as espécies eletroativas junto ao eletrodo. Depois disso, ocorre o momento de relaxação da bateria, que acontece quando a corrente de descarga se atenua, onde acontece a reestruturação dos elétrons, em 'C'. Assim, aumenta o número de espécies eletroativas próximas ao eletrodo novamente, até o gradiente de concentração ficar inexistente, com isso a capacidade efetiva da bateria é ampliada, onde pode ser visto em 'D'. Contudo, a quantidade de espécie eletroativas não consegue ser da mesma quantidade inicial, sendo menor do que tinha no início do processo. Em 'E' quando a bateria atinge um estágio inferior a carga, as reações eletroquímicas se findam e a bateria chega ao estágio de descarga (Romio et al., 2012).

Figura 2. Estágios de operação da bateria.



2.2 NÍVEL DE CUTOFF

Outro efeito não-linear que deve ser estudado é o Nível de Cutoff, ele é útil para estimar o tempo de vida da bateria. O nível de cutoff pode ser definido como o nível de capacidade mínima da bateria, pois toda bateria tem um nível de tensão para se manter funcionando e quando esse nível de tensão é atingido a bateria perde a funcionalidade e não consegue mais realizar as reações eletroquímicas nas células. Esse nível de cutoff não leva em consideração a descarga total, mas sim a possibilidade de manter as reações nas células.

2.3 EFEITO DE TAXA DE CAPACIDADE

O Efeito de Taxa de Capacidade também deve ser analisado, esse efeito leva em consideração a capacidade atual da bateria e a intensidade de corrente de descarregamento. Quando se tem correntes elevadas de descargas a capacidade efetiva é baixa, pois não tem tempo hábil para a reorganização das células, que é o Efeito de Recuperação. Já quando se tem cargas alternadas a capacidade efetiva aumenta, pois quando se tem um período sem fluxo de corrente os elétrons fazem um processo de reorganização aumentando assim a quantidade de carga na superfície do eletrodo. E assim aumentando a capacidade da bateria e por consequência um aumento da quantidade de energia disponível na bateria.

3 IDENTIFICAÇÃO DE SISTEMAS

Na literatura técnica há dois tipos de abordagem comumente utilizadas para modelar matematicamente a dinâmica de um sistema, sendo elas: a modelagem conceitual, e por identificação de sistemas (Romio et al., 2012). A abordagem conceitual é também conhecida como modelagem pela física ou natureza do processo, nela é necessário conhecer bem o sistema de estudo, bem como as leis da física que regem o sistema a ser modelado (Aguirre, 2007).

Conforme Aguirre (2007), na abordagem por identificação de sistemas é possível realizar a modelagem matemática tendo pouco ou nenhum conhecimento prévio do sistema. Nesta abordagem, quando não há nenhuma informação da física do sistema a identificação é denominada caixa preta. Já quando há alguma informação auxiliar, diferente das disponíveis no banco de dados utilizados, a identificação é

denominada caixa cinza. Contudo pode-se analisar um sistema dinâmico no domínio do tempo ou no domínio da frequência, logo a identificação pode derivar modelos (lineares ou não lineares).

No presente trabalho, para realizar a previsão da curva de descarga da bateria de um quadricóptero Rolling Spider, serão utilizados os modelos matemáticos paramétricos lineares ARX (Auto regressivo com entradas exógenas), ARMAX (Auto regressivo com média móvel e entradas exógenas), e BJ (Box Jenkins).

A estrutura geral representada em tempo discreto é dada pela seguinte equação (Aguirre, 2007, p. 125):

$$A(q)y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad (1)$$

Onde: q^{-1} é o operador de atraso, de modo que $y(k)q^{-1} = y(k-1)$, e $v(k)$ é considerado o ruído branco e $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ representam os polinômios definidos a seguir:

$$A(q) = 1 - a_1q^{-1} - \dots - a_{n_y}q^{-n_y} \quad (2)$$

$$B(q) = b_1q^{-1} + \dots + b_{n_u}q^{-n_u} \quad (3)$$

$$C(q) = 1 - c_1q^{-1} + \dots + c_{n_v}q^{-n_v} \quad (4)$$

$$D(q) = 1 - d_1q^{-1} + \dots + d_{n_d}q^{-n_d} \quad (5)$$

$$F(q) = 1 - f_1q^{-1} + \dots + f_{n_f}q^{-n_f} \quad (6)$$

Com base em (1), realizando devidas modificações, é possível obter os principais modelos paramétricos lineares, conforme descrito a seguir (Romio et al., 2012):

3.1 MODELO ARX

O modelo ARX (do inglês: Autoregressive with exogenous inputs), pode ser obtido a partir de (1), adotando $C(q) = D(q) = F(q) = 1$ sendo $A(q)$ e $B(q)$ polinômios arbitrários, tendo como resultado:

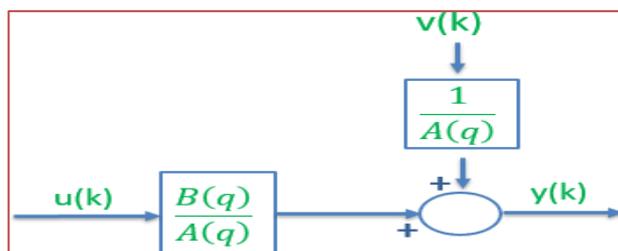
$$A(q)y(k) = B(q)u(k) + v(k) \quad (7)$$

A Figura 3 mostra a representação esquemática do modelo ARX, utilizando diagrama de blocos.

3.2 MODELO ARMAX

O modelo ARMAX (do inglês Autoregressive moving average with exogenous input), pode ser obtido a partir de (1),

Figura 3. Representação esquemática do modelo ARX.

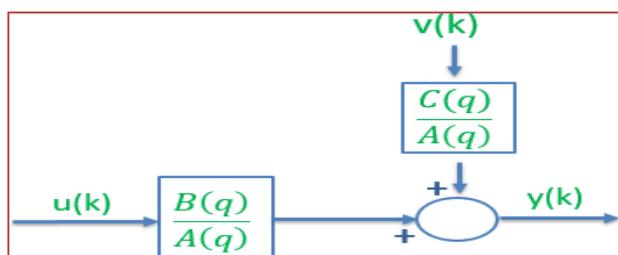


adotando $D = (q) = F(q) = 1$ e $A(q)$, $B(q)$ e $C(q)$ como polinômios arbitrários, tendo como resultado:

$$A(q)y(k) = B(q)u(k) + C(q)v(k) \quad (8)$$

A Figura 4 mostra a representação esquemática do modelo ARMAX, utilizando diagrama de blocos.

Figura 4. Representação esquemática do modelo ARMAX.



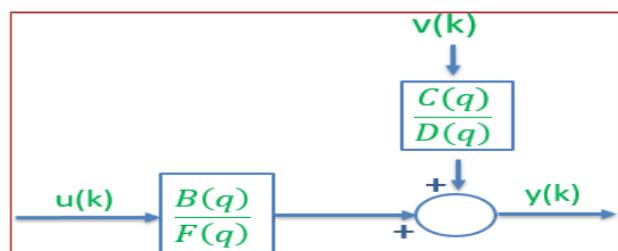
3.3 MODELO BJ

O modelo BJ (do inglês: Box-Jenkins) é obtido a partir de (1), adotando $A(q) = 1$. Todos os demais polinômios são arbitrários, obtendo como resultado:

$$y(k) = \frac{B(q)}{F(q)}u(k) + \frac{C(q)}{D(q)}v(k) \quad (9)$$

A Figura 5 mostra a representação esquemática do modelo BJ, utilizando diagrama de blocos.

Figura 5. Representação esquemática do modelo BJ.



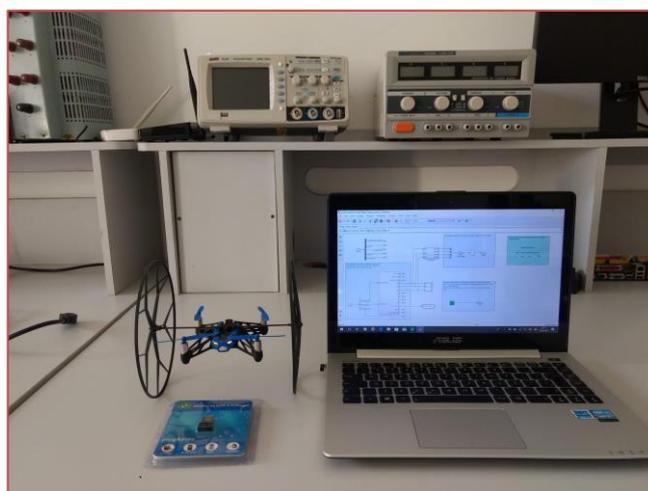
4 MATERIAIS E MÉTODOS

Nesta seção é apresentada a plataforma utilizada para realizar os ensaios e aquisição de dados característicos da descarga da bateria de um drone do tipo quadricóptero, assim como os materiais utilizados. Em seguida são apresentados os bancos de dados utilizados para estimar os parâmetros, e validar os modelos matemáticos: ARX, ARMAX, e BJ obtidos a partir da teoria de identificação de sistemas.

4.1 PLATAFORMA DE TESTES

Os dados apresentados neste trabalho foram obtidos a partir de uma plataforma de testes composta por um drone Parrot Rolling Spider, um Dongle Bluetooth USB 4.0, e um notebook em conjunto com o software Matlab/Simulink. O Dongle USB é responsável por estabelecer uma conexão bluetooth entre o notebook e o hardware do drone. Já o software Matlab/Simulink é utilizado para criar, modificar e enviar algoritmos de controle de voo e aquisição de dados do perfil de descarga da bateria, através da conexão da conexão bluetooth estabelecida. A Figura 6 a seguir apresenta uma foto do ambiente de testes:

Figura 6. Plataforma de Testes.



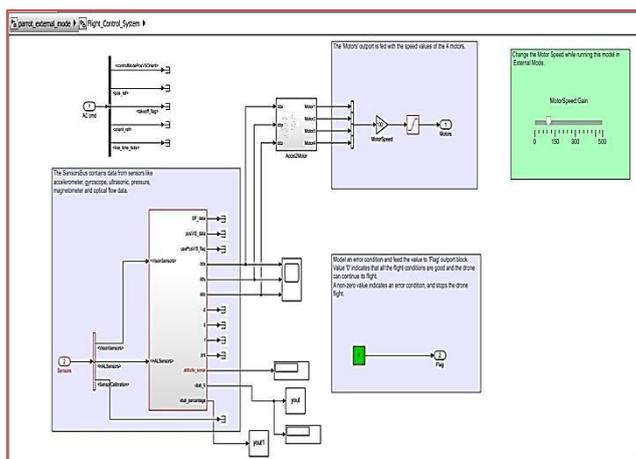
4.2 ENSAIOS E AQUISIÇÃO DOS DADOS EXPERIMENTAIS

Os ensaios foram realizados mantendo o drone pairando, onde simula a descarga da bateria em corrente constante. Para manter o quadricóptero pairando, e ao mesmo tempo utilizá-lo como uma carga não variável, é necessário que a velocidade de giro dos quatro propulsores sejam iguais durante todo processo de descarga.

Para a aquisição de dados foi utilizado o seguinte procedimento. Inicialmente as baterias foram submetidas a um processo de carga completo, conectando-as em uma fonte de carregamento externa. Após este procedimento, as baterias são desconectadas da fonte de carga externa e conectadas ao drone. Em seguida foi estabelecida uma conexão bluetooth entre o notebook e o quadricóptero. Por fim, algoritmos de controle e aquisição de dados foram enviados para o hardware do veículo aéreo com o objetivo de estabelecer uma velocidade de giro constante nos quatro propulsores, e registrar em tempo real os valores de tensão nos terminais da bateria. A Figura 7 mostra o diagrama de blocos utilizado para controlar a velocidade dos propulsores, e obter os dados do comportamento de descarga da bateria.

Os ensaios são realizados considerando 2 baterias de Li-Po novas da marca Shoot, modelo XT-412. Para cada bateria são realizados 5 ensaios, em cada um deles é registrado o perfil de descarga da bateria variando de 3,30V a 4,10V, em intervalos de 50(mV). Vale ressaltar que, para o veículo aéreo utilizado, o nível 0% de carga da bateria é mensurado em 3,20V. Já o nível 100% de carga da bateria é mensurado em 4,2V.

Figura 7. Diagrama de blocos utilizado.



Os dados experimentais obtidos neste processo são divididos em dois conjuntos de ensaios. O primeiro conjunto

é formado pelos resultados dos 5 ensaios experimentais realizados com a Bateria A, é utilizado para estimar os parâmetros dos modelos ARX, ARMAX, e BJ. Já o segundo conjunto é formado pelos resultados dos 5 ensaios experimentais realizados com a Bateria B, sendo utilizado para a validação dos modelos supracitados.

As Tabelas 1 e 2 apresentam os dados experimentais do primeiro e segundo conjunto de ensaios respectivamente, onde TBe_i é o tempo de vida experimental, i caracteriza o número do experimento, e $TBem$ é o tempo de vida experimental médio, sendo apresentados em minutos.

Tabela 1. Dados experimentais do primeiro conjunto de ensaios

| Tensão (V) | TBe_1 (min) | TBe_2 (min) | TBe_3 (min) | TBe_4 (min) | TBe_5 (min) | $TBem$ (min) |
|------------|---------------|---------------|---------------|---------------|---------------|--------------|
| 3.30 | 13,95 | 13,43 | 13,30 | 11,74 | 11,83 | 12,85 |
| 3.35 | 13,88 | 13,38 | 13,24 | 11,68 | 11,77 | 12,79 |
| 3.40 | 13,79 | 13,28 | 13,16 | 11,60 | 11,68 | 12,70 |
| 3.45 | 13,66 | 13,17 | 13,07 | 11,50 | 11,58 | 12,60 |
| 3.50 | 13,55 | 13,03 | 12,92 | 11,37 | 11,46 | 12,46 |
| 3.55 | 13,37 | 12,86 | 12,75 | 11,21 | 11,30 | 12,30 |
| 3.60 | 13,08 | 12,57 | 12,47 | 10,74 | 10,89 | 11,95 |
| 3.65 | 11,82 | 11,26 | 10,89 | 9,49 | 9,62 | 10,62 |
| 3.70 | 9,46 | 8,94 | 9,12 | 7,49 | 7,38 | 8,48 |
| 3.75 | 7,58 | 6,94 | 7,28 | 5,76 | 5,79 | 6,67 |
| 3.80 | 5,84 | 5,66 | 5,79 | 4,58 | 4,59 | 5,29 |
| 3.85 | 4,57 | 4,47 | 4,38 | 3,56 | 3,51 | 4,10 |
| 3.90 | 3,63 | 3,22 | 3,49 | 2,66 | 2,65 | 3,13 |
| 3.95 | 2,70 | 2,57 | 2,67 | 2,06 | 2,15 | 2,43 |
| 4.00 | 2,11 | 2,01 | 1,99 | 1,39 | 1,37 | 1,77 |
| 4.05 | 1,23 | 0,99 | 1,10 | 0,77 | 0,73 | 0,96 |
| 4.10 | 0,48 | 0,35 | 0,39 | 0,17 | 0,20 | 0,32 |

Tabela 2. Dados experimentais do segundo conjunto de ensaios

| Tensão (V) | TB_{e1} (min) | TB_{e2} (min) | TB_{e3} (min) | TB_{e4} (min) | TB_{e5} (min) | TB_{em} (min) |
|------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| 3,32 | 12,63 | 12,54 | 12,47 | 11,77 | 11,42 | 12,17 |
| 3,37 | 12,53 | 12,43 | 12,39 | 11,67 | 11,34 | 12,07 |
| 3,42 | 12,44 | 12,33 | 12,28 | 11,57 | 11,24 | 11,97 |
| 3,47 | 12,27 | 12,18 | 12,12 | 11,43 | 11,11 | 11,82 |
| 3,52 | 12,11 | 11,98 | 11,93 | 11,24 | 10,94 | 11,64 |
| 3,57 | 11,84 | 11,74 | 11,63 | 10,96 | 10,60 | 11,35 |
| 3,62 | 11,33 | 11,03 | 11,03 | 10,01 | 9,89 | 10,66 |
| 3,67 | 9,81 | 9,56 | 9,42 | 8,70 | 8,54 | 9,21 |
| 3,72 | 7,91 | 7,67 | 7,58 | 7,29 | 6,56 | 7,40 |
| 3,77 | 6,26 | 6,18 | 6,01 | 5,75 | 5,33 | 5,91 |
| 3,82 | 4,94 | 4,86 | 4,76 | 4,62 | 4,15 | 4,67 |
| 3,87 | 3,88 | 3,91 | 3,83 | 3,74 | 3,10 | 3,69 |
| 3,92 | 2,99 | 3,00 | 2,84 | 2,97 | 2,31 | 2,82 |
| 3,97 | 2,48 | 2,41 | 2,26 | 2,13 | 1,66 | 2,19 |
| 4,02 | 2,15 | 1,59 | 1,42 | 1,33 | 0,85 | 1,47 |
| 4,07 | 0,93 | 0,92 | 1,02 | 0,66 | 0,36 | 0,78 |

5 RESULTADOS E DISCUSSÕES

A partir dos dados experimentais apresentados na Tabela 1 é realizado a modelagem matemática da curva que representa a dinâmica de descarga das baterias, utilizando a teoria de identificação de sistemas. Os modelos paramétricos lineares foram obtidos utilizando o toolbox ident do software Matlab/Simulink. A seguir são apresentados os polinômios e equações correspondentes aos modelos para- métricos lineares ARX, ARMAX e BJ, obtidos a partir do toolbox ident :

Modelo ARX: Para este modelo foram estimados as seguintes polinômios:

$$A(q) = 1 - 1.523q^{-1} + 0.7659q^{-2}$$

$$B(q) = 376.8q^{-1} - 381.5q^{-2}$$

onde q^{-1} é o operador de atraso, conforme Aguirre (2007). Pode-se escrever a equação do modelo ARX (7) da seguinte forma:

$$y(q) = \frac{376.8q^{-1} - 381.5q^{-2}}{1 - 1.523q^{-1} + 0.7659q^{-2}}u(k) + \frac{1}{1 - 1.523q^{-1} + 0.7659q^{-2}}v(k)(10)$$

Modelo ARMAX: Para este modelo foram estimados as seguintes polinômios:

$$A(q) = 1 - 1.741q^{-1} + 0.9195q^{-2}$$

$$B(q) = 263.7q^{-1} + 267q^{-2}$$

$$C(q) = 1 - 0.04337q^{-1} + 0.9566q^{-2}$$

Pode-se escrever a equação do modelo ARMAX (8) da seguinte forma:

$$y(q) = \frac{263.7q^{-1} + 267q^{-2}}{1 - 1.741q^{-1} + 0.9195q^{-2}}u(k) + \frac{1 - 0.04337q^{-1} + 0.9566q^{-2}}{1 - 1.741q^{-1} + 0.9195q^{-2}}v(k)(11)$$

Modelo BJ: Para este modelo foram estimados as seguintes polinômios:

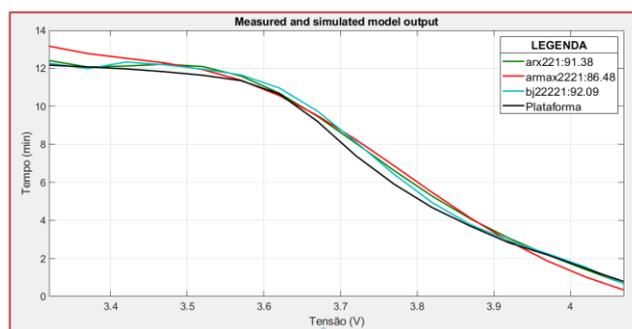
$$\begin{aligned}
 B(q) &= 710q^{-1} - 718.8q^{-2} \\
 C(q) &= 1 + 0,08084q^{-1} - 0,1916q^{-2} \\
 D(q) &= 1 - 0.3873q^{-1} + 0.2052q^{-2} \\
 F(q) &= 1 - 1.389q^{-1} + 0.805q^{-2}
 \end{aligned}$$

Pode-se escrever a equação do modelo BJ (9) da seguinte forma:

$$y(k) = \frac{710q^{-1} - 718.8q^{-2}}{1 - 1.389q^{-1} + 0.805q^{-2}} u(k) + \frac{1 + 0,08084q^{-1} - 0,1916q^{-2}}{1 - 0.3873q^{-1} + 0.2052q^{-2}} v(k) \quad (12)$$

Após a determinação dos modelos matemáticos que caracterizam a dinâmica de descarga da bateria de Vant do tipo quadrirotor, conforme (10), (11), e (12) é necessário realizar a validação de cada modelo. A própria ferramenta ident utilizada neste trabalho, dispõe de um ambiente para realizar a validação, para isto serão utilizados os dados experimentais apresentados na Tabela 2. Na Figura 8 são apresentadas as curvas dos resultados da validação dos três modelos matemáticos ARX, ARMAX, e BJ.

Figura 8. Resultados da validação dos modelos.



A partir da análise comparativa dos resultados apresentados na Figura 8, observa-se que a estrutura de modelo paramétrico BJ apresentou um melhor resultado quando comparado com os demais modelos simulados, ou seja, com o modelo BJ foi obtida uma acurácia de 92,09%, já com os modelos ARX e ARMAX a acurácia obtida foi de 91.38% e 86.48% respectivamente.

6 CONCLUSÃO

Neste trabalho foi realizado a modelagem matemática caixa cinza, da curva de descarga de baterias que alimentam um quadrirotor Rolling Spider, utilizando conceitos da teoria de identificação de sistemas e uma plataforma de testes e aquisição de dados composta por um drone Rolling Spider, um adaptador bluetooth 4.0, e um notebook em conjunto com o software Matlab/Simulink. As baterias utilizadas no processo de descarga, na plataforma de testes, são de Li-Po, da marca Shoot, modelo XT-412. A partir da ferramenta ident, foram obtidos os parâmetros dos modelos lineares ARX, ARMAX, e BJ que caracterizam a dinâmica de descarga das baterias utilizadas. A partir da análise dos resultados observou-se que o modelo paramétrico linear Box Jenkins apresentou um melhor resultado quando comparado com os demais modelos e os dados experimentais, com uma acurácia de 92.09%.

AGRADECIMENTOS

Este trabalho foi realizado durante um projeto de pesquisa na Universidade Federal do Ceará. Este trabalho recebeu apoio da Fundação Cearense de Apoio ao Desenvolvimento Científico e Tecnológico(FUNCAP).

REFERÊNCIAS

- [1] Aguirre, L. (2007). Introdução a` identificação de sistemas. UFMG, Belo Horizonte.
- [2] Douglas, J.B.F., Julia, G.Z., Airam, T.Z.R.S., and Paulo, S.S. (2018). Identificação de sistemas aplicada à predição do tempo de vida de baterias de lipo utilizadas em dispositivos móveis. Proceeding Series of the Brazilian Society of Computational and Applied Mathematics, São José dos Campos. doi:10.5540/03.2018.006.01.0377. Porciuncula, C.M.D. (2012). Aplicação de modelos elé- tricos de bateria na predição do tempo de vida de dis- positivos móvei 2012. 74 f. Mestrado em modelagem matemática, Programa de Pós-Graduação em Modela- gem Matemática, Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Rio Grande do Sul.
- [3] Romio, L.C. (2013). Modelagem matemática do tempo de vida de baterias utilizando a teoria de identificação de sistemas 2013. 84 f. Mestrado em modelagem matemá- tica, Programa de Pós-Graduação em Modelagem Ma- temática, Universidade Regional do Noroeste do Estado do Rio Grande do Sul, Rio Grande do Sul.
- [4] Romio, L.C., Sausen, A.T.Z.R., Sausen, P.S., and Reim- bold, M.M.P. (2012). Aplicação de identificação de siste- mas no tempo de vida de baterias de dispositivos móveis. 18–33. Revista de Ciências Exatas e Engenharias, Rio Grande do Sul.
- [5] Silva, L.P. and Cordeiro, C.S. (2011). Quadricóptero, aspectos gerais e análises da propulsão elétrica. In VIII Simpósio de Excelência em Gestão e Tecnologia, 14. Instituto Federal Fluminense, Espirito Santo.
- [6] Silva, L.T.G. (2015). Modelagem, simulação e controle de um vant quadrirrotor.

Capítulo 5

Termografia em um contexto de manutenção industrial eficiente

Phellipe Tocchetto Dinardi

Keven Soares da Costa

Israel Gondres Torné

Resumo: A indústria tem constantemente aliado a manutenção da sua planta como uma medida de otimização de lucros, custos e desenvolvimento de vantagens. Na disputa de mercado novas técnicas são necessárias para otimizar o processo de manutenção e o planejamento proposto nos métodos preditivos melhoram o gerenciamento e o controle das linhas de produção. A termografia propõe ser ferramenta aprimorada na manutenção preditiva. O objetivo deste trabalho é estudar as aplicações da termografia em uma instalação industrial verificando o tempo e a eficiência da ferramenta. Em análise de um sistema, com consumo de energia mensal aproximado de 165.652 kWh, capturou-se imagens térmicas e correlacionou-se com as filosofias de manutenção industrial e os relatórios do setor de manutenção da planta. Obteve-se desempenho com excelente agilidade no método de monitoramento e registro do sistema elétrico principal da fábrica com descrição dos defeitos, falhas e condicionantes discriminados pelo uso da termografia. Para trabalhos futuros recomenda-se a realização de coleta e cruzamento de medições acerca de equipamentos defeituosos, obtidas por métodos invasivos e por método termográfico, para dimensionar confiabilidade estatística e dados de operação.

Palavras-chave: Aplicação na Indústria, Manutenção industrial, Termografia.

1. INTRODUÇÃO

Desde 2007 a Comissão Europeia formou uma diretriz para regulamentar o desempenho energético dos edifícios na qual uma de suas medidas é os Certificados de Desempenho Energético, em inglês *Energy Performance Certificates* (EPCs), tornando-se obrigatório em muitos países da União Europeia (Arcipowska 2014). Em análise das ações legais e econômicas realizadas na União Europeia após 2007 estimasse que critérios e normas mais severos na investigação de eficiência energética e capacidade de poupar energia serão exigidos (FLIR 2014). No Brasil é previsto no Prontuário das Instalações Elétricas NR10, documento obrigatório para instalações elétricas principalmente em ambiente industrial e exigido por auditoria fiscal do Ministério do Trabalho e Emprego, o relatório de inspeção termográfica, (RES-CUE CURSOS, 2019).

Os termos termografia infravermelha e imagens térmicas, são termos comuns usados na visualização e quantificação de temperatura superficial, utilizando câmeras infravermelhas. Em indivíduos saudáveis, o padrão da temperatura superficial costuma se comportar de forma simétrica (Mercer 2014). A pesquisa do infravermelho limitou-se ao efeito de aquecimento provocado pela incidência dessa radiação em material, assim, seu prosseguimento dependeu em grande parte da evolução termométrica (Veratti 1984).

Recentemente, diversas pesquisas têm sido realizadas para enriquecer o universo termográfico e suas implementações tecnológicas como: Utilização de correntes parasitar para detecção de defeitos em materiais ferromagnéticos, método não destrutivo para teste que combina aquecimento por indução magnética e tecnologia térmica por infravermelho (Yan 2016); Previsão de corrente em uma subestação a fim de programar termografia para a qualidade do sistema, utilizando os dados de uma linha de subestação sueca num período de 10 anos (Westerlund 2016); Monitoramento de equipamentos para falhas relacionadas à temperatura utilizando câmeras de termografia, onde observa que o governo dos EUA está implementando programas e leis para garantir infraestruturas críticas tenham soluções de monitoramento e apresenta alternativa além dos métodos tradicionais de monitoramento que exigem medições de pontos pré-selecionados (Wang 2015).

Diversos setores industriais estão mostrando um interesse crescente na integração tecnológica da Indústria 4.0 em suas plantas para desenvolver estratégias de vantagem competitiva e de manutenção preditiva. No entanto, muitas abordagens de pesquisa destacam que o desenvolvimento de sistemas de manutenção preditiva precisa de melhorias significativas em termos de redução de custos para monitorar equipamentos e monitorá-los com maior precisão (Sezer 2018).

2. FILOSOFIAS DE MANUTENÇÃO INDUSTRIAL.

Segundo as normas brasileiras de regulamentação, manutenção é a combinação de ações técnicas e administrativas, incluindo supervisão, destinadas a manter ou recolocar um item em um estado no qual possa desempenhar uma função requerida (ABNT 5462 1994). É um ponto crucial para assegurar a eficiência da produção na indústria, pois a ocorrência de perturbações inesperadas leva à degradação do desempenho do sistema, ocasionando perda de produtividade e oportunidades de negócios. Porém, normalmente os custos associados às tarefas de manutenção em uma empresa de produção são extremamente significativos (Cachada 2018).

Relacionando os resultados obtidos aos custos de um sistema podemos estabelecer a eficiência do mesmo. E em análise a outros sistemas teremos, em média, um sistema mais eficiente que o outro, portanto esse processo produz mais, consumindo menos e com melhor qualidade. (Santos 2007). O melhor índice de resultados na manutenção é o Valor Global da Eficácia de Equipamento, em inglês *Overall Effectiveness of Equipment - OEE*, que pondera a disponibilidade do equipamento, a diminuição no retrabalho, a rejeição e a taxa de desempenho.

Alguns teóricos apresentam a manutenção detectiva como a atuação efetuada em sistemas nos quais as falhas ou alterações no funcionamento regular do equipamento não pode ser percebido pela equipe de operação e de manutenção (Carstens 2007), porém as manutenções frequentes em qualquer sistema industrial são a preventiva, corretiva e preditiva.

Após o surgimento de uma falha num sistema a execução esperada é a correção do defeito, a conservação deste ciclo de quebra e reparação é denominada manutenção corretiva. Sua execução está sujeita a aleatoriedade do aparecimento do defeito e contribui para a diminuição da vida útil do sistema (Camara 2012). Um método passivo e constante em um sistema, no qual objetiva reduzir a probabilidade de falha

do mesmo, maximizando a longevidade da vida útil do sistema e o benefício de sua operação para a planta é designado de manutenção preventiva (Knezevic 1996).

A Manutenção preditiva, encontrada em alguns teóricos sobre o nome de manutenção baseada na condição, busca um condicionante para deflagra a manutenção do equipamento, ou sistema, evitando um processo de falha futuro. Utilizando métodos de monitoramento como inspeção periódica para avaliar o correto funcionamento do equipamento/sistema ao longo da vida útil do mesmo. A limitação do método de manutenção está relacionada a disponibilidade técnica efetiva de monitoramento e o custo de sua implementação e continuidade (Nassar 2015).

Estratégias para corroborarem com o funcionamento de plantas industriais foram desenvolvidas ao redor do mundo com o passar do tempo e a integração do usuário da máquina no papel de manutenção foi sistematizada e apresentada ao universo industrial por meio do Instituto Japonês de Manutenção de Plantas sobre o nome de Manutenção Produtiva Total, em inglês *Total Productive Maintenance – TPM*. Seu objetivo propõe um projeto funcional de time para redução de perda de equipamento alvo mudando a compreensão das pessoas e seus hábitos de trabalho ao usar equipamentos, como a implementação de ferramentas instrucionais, enquanto se aproximam de uma performance de qualidade, restaurando e controlando a deterioração e corrigindo anormalidades (Suzuki 1994). Um estudo realizado em uma fábrica de manufatura buscou quantificar a eficácia da manutenção com foco no processo do TPM, onde ao final o custo e a qualidade foram significativamente aprimorados, reduzindo e minimizando a deterioração e as falhas do equipamento resultando em um OEE de 85% -90% (Wakjira 2012).

3 TERMOGRAFIA NA PRÁTICA INDUSTRIAL

Muitas indústrias tem percebido a importante conexão entre manutenção e confiabilidade, em consequência o foco das manutenções tem sido estudar, manter e melhorar a confiabilidade e regularidade de operação do sistema produtivo por meio de uma constantemente na busca por otimização na manutenção (Fogliatto 2011). Assim, é preciso que a manutenção deixe de ser eficiente para se tornar eficaz, ou seja, não basta apenas reparar o equipamento ou instalação tão rápido quanto possível, mas é preciso manter a função do equipamento disponível para a operação, reduzindo a probabilidade de uma parada de produção não planejada (Kardec 2009).

A termografia integra um método preditivo, no qual é possível detectar o surgimento de defeitos desde suas etapas iniciais agregando qualidade ao processo de manutenção e tornando o procedimento uma oportunidade de diferenciação da concorrência e aumento da competitividade ao reduzir a quantidade de manutenções preventivas que não agregam valor no produto final e significam maiores custos reduzindo a margem de lucro (Lemos 2011).

Para captura térmica de uma imagem, gerada por uma câmera infravermelha, é importante observar as matérias que compõem o cenário a ser fotografado bem como os objetos e o meio que está inserido pois cada uma dessas partes influenciarão as análises realizadas. A emissividade é uma propriedade radiativa de um objeto em relação a um corpo perfeitamente negro, no qual é o emissor perfeito. Se a energia emitida de um corpo negro é denotada como W_{bb} , e a emitida por um corpo normal na mesma temperatura for denotada como W_{obj} , a relação entre esses dois valores é descrita como a emissividade (Bramson 1968).

$$\varepsilon = \frac{W_{obj}}{W_{bb}} \quad (1)$$

Assim, a emissividade é um número entre 0 e 1. Quanto melhor as propriedades radiativas do objeto, maior sua emissividade. Um objeto que tenha a mesma emissividade para todos os comprimentos de onda é chamado de corpo cinza, em inglês denominado *grey body*, apesar de a maioria dos corpos não serem nem corpos negros a emissividade varia com comprimento de onda.

Como a termografia opera somente dentro de faixas espectrais limitadas, muitas vezes é possível tratar objetos como corpos de cinza. Em qualquer caso, um objeto pode ter emitância que varia fortemente com o comprimento de onda é chamado de radiador seletivo. O vidro é um exemplo de um radiador muito seletivo, comportando-se quase como um corpo negro para determinados comprimentos de onda, ao passo que é oposto para outros comprimentos de onda (Dos Santos 2006).

Entre a câmera e o objeto está a atmosfera, que tende a atenuar a radiação devido a absorção por gases e espalhamento das partículas. A quantidade de atenuação depende fortemente do comprimento de onda da radiação. Apesar de a atmosfera normalmente transmitir luz visível muito bem, neblina, nuvens, chuva e neve podem nos impedir de ver objetos distantes. O mesmo princípio se aplica a radiação infravermelha onde a atenuação atmosférica impede a radiação total de um objeto atingir a câmera. Se não for aplicada correção para atenuação, a medida aparente a temperatura será gradativamente menor com a distância aumentada. O Software da câmera IR corrige a atenuação atmosférica.

Uma análise bem sucedida no ensaio termográfico deve ser feito em condições atmosféricas/ambientais mais próximas do ideal possível, devem ser tomados cuidados em relação aos equipamentos que serão estudados, por exemplo transformadores, compressores, grupos geradores, nesse tipo de equipamento deve ser feita a termografia durante os ciclos de trabalho dos mesmos, vale salientar que além dos fatores ambientais e climáticos devemos levar em consideração o aspecto humano, o profissional que irá realizar o ensaio deve ser treinado, ou minimamente instruído, para que todas as precauções citadas anteriormente sejam consideradas durante a realização do ensaio (Snell 1992).

As radiações que atingem as lentes da câmera originam-se de três fontes diferentes e possuem suas fórmulas de absorção expressas pelo fabricante. A câmera recebe radiação do objeto de estudo, do seu entorno e do reflexo da superfície. Utilizando a equação 2 podemos obter uma fórmula que calcula a temperatura de um objeto que teve sua imagem capturada por uma câmera termográfica (FLIR, 2015).

$$EO = \varepsilon \times \tau \times W_{obj} \quad (2)$$

Onde “EO” é a emissão do objeto, ε é a emissividade do objeto e τ é a transmitância da atmosfera.

De forma similar a energia de uma fonte presente no ambiente será fotografada pela câmera e deve ter seu valor considerado para não interferir na correta medição de temperatura do objeto. Seu comportamento é descrito na fórmula seguinte.

$$EF = (1 - \varepsilon) \times \tau \times W_{amb} \quad (3)$$

Onde “EF” é a emissão refletida da fonte e $(1 - \varepsilon)$ é a refletância do objeto. E assumimos que a temperatura “Wamb”, é a mesma para toda superfície emissora.

Por fim, o meio entre a câmera e o objeto interage com a radiação liberada e emissão da atmosfera atenua ou agrava a radiação capturada. Pode ser calculada com a equação 4.

$$EA = (1 - \tau) \times W_{atm} \quad (4)$$

Onde “EA” é a emissão da atmosfera, $(1 - \tau)$ é a emissividade da atmosfera.

O somatório de todas as emissões que chegam a lente da câmera resulta na potência de radiação total apresentada na imagem capturada e pode ser escrita na equação abaixo.

$$W_{total} = EO + EF + EA \quad (5)$$

Ajustando à temperatura correta, o software da câmera requer como entrada a emissividade do objeto, atenuação atmosférica e de temperatura, e a temperatura do entorno. Dependendo das circunstâncias, esses fatores devem ser medidos, assumidos ou encontrados em uma tabela apresentada pelo fabricante, mas este processo de calibragem da câmera assegura qualidade nas interpretações possíveis com as imagens termográficas.

4 MATERIAIS E MÉTODOS

Realizou-se visita técnica nas instalações elétricas de distribuição, fotografando quadros de distribuição geral, possuindo sigla de QGD, e quadros gerais de baixa tensão, também denominado de QGBT, bem como a subestação composta por dois transformadores de 500 kVA, um transformador de 300 kVA e um transformador de 112,5 kVA além dos cabos de muflas. A média mensal do consumo de energia elétrica do sistema visitado no ano de 2018 é de 165.658 kWh.

O sistema possui alimentação radial simples, no qual o fluxo de potência tem sentido único da fonte para a carga. É o tipo mais simples de alimentação industrial e também o mais utilizado (Mamed Filho 2013).

4.1 ETAPA ESTRATÉGICA

Em contato com a equipe de manutenção das instalações elétricas obteve-se a rotina de manutenção do sistema e as falhas ocorridas nos últimos três meses bem como as investigações e métodos de mitigação das falhas existentes.

A equipe transmitiu completa ausência de práticas preditivas sendo 87% das atuações realizadas nos últimos três meses com caráter corretivo e o restante em medidas preventivas. A equipe, composta de seis funcionários, relataram acionamentos aleatórios do sistema de proteção em um dos blocos do sistema.

4.2 INSPEÇÃO TERMOGRÁFICA

Após levantamento de dados de consumo e dos equipamentos ligados ao sistema objetivou-se a captura de imagens térmicas dos principais sistemas de distribuição de energia elétrica do sistema onde nossa atuação se deu da entrada da subestação até os quadros de distribuição geral. Obtidas as imagens efetuou-se o tratamento das imagens e a calibração dos parâmetros apresentados na equação 5 para assegurar confiabilidade nas informações obtidas da instalação.

4.3 ANÁLISE DE DADOS

Por fim, aplicou-se uma análise quantitativa e qualitativa das imagens obtidas para filtrá-las selecionando os problemas recorrentes encontrados. Correlacionou-se as falhas relatadas pela equipe de manutenção com os condicionantes encontrados pela termografia avaliando o funcionamento do sistema e suas possíveis futuras falhas.

4 RESULTADOS E DISCUSSÕES

Após visita pelas instalações e compartilhamento de informações com o setor de manutenção procedeu-se com inspeção nas três subestações existentes, sendo uma delas desabrigada, nos cinco quadros gerais de baixa tensão e nos diversos quadros de distribuição geral. Num período de quatro horas foi possível monitorar todo o sistema existente com exceção dos maquinários e duas horas foram necessárias para tratar as imagens.

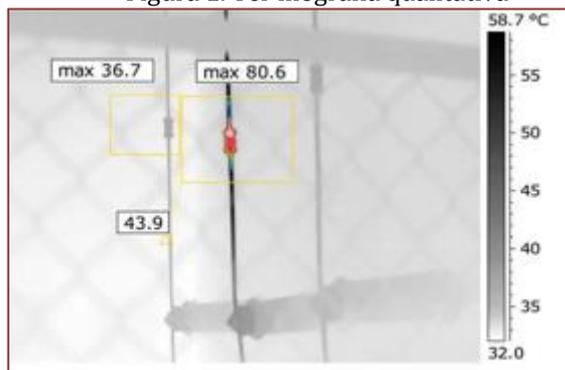
Concluída a etapa de aquisição dos termogramas passamos para a análise na qual os fatores técnicos citados anteriormente devem ser levados em consideração, e a partir de valores absolutos podemos partir para duas linhas de análise; um estudo quantitativo que baseia-se em valores de temperatura de trabalho tabelados, e uma análise qualitativa que no geral é feita de forma comparativa, comparando objetos trabalhando teoricamente nas mesmas condições, mas que apresentam discrepâncias em seus valores absolutos de temperatura

Os transformadores apresentaram-se em temperatura normais de funcionamento e os últimos relatórios de resistência ôhmica, isolamento, relação de transformação e análise do óleo também se apresentaram dentro da normalidade garantindo ao sistema vida útil mínima de 10 anos.

Na subestação abrigada observou-se condicionalmente de investigação, possivelmente falha na qualidade da energia entregue pela concessionária, no qual necessita de minucioso estudo das causas tendo em vista que podem prejudicar o bom funcionamento de qualquer planta industrial conforme apresentado na figura abaixo.

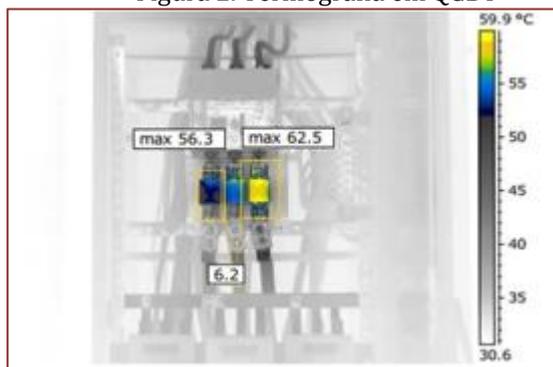
A figura 1 mostra os cabos de entrada de um transformador em uma cabine primária onde, após análise qualitativa, nota-se que no ponto em destaque, o ponto antes dos isoladores tipo pedestal, temos um aquecimento que teoricamente é aceitável para o tipo de material, afinal, trata-se de um condutor rígido, dimensionado para uma tensão de operação de 13,8 kV, no entanto, como pode ser visto na imagem se comparamos as temperaturas de duas fases, vemos uma diferença de 43,9°C entre uma fase e outra, o que pode representar um grave erro de desbalanceamento de carga, bem como alguma falha nas operações do transformador ou presença de harmônicos, algo que representa um perigo eminente para a segurança dos indivíduos que estiverem próximos a esse local e dos equipamentos ligados a essa rede.

Figura 1. Termografia qualitativa



Os quadros gerais de baixa tensão apresentaram-se regulares no funcionamento e segundo a equipe de manutenção não proporcionaram problemas nos últimos 5 anos. Com as imagens térmicas foi possível observar que apesar do funcionamento regular expansões de projetos ou ampliações de maquinários deverão ocasionar em falhas. A figura 2 apresenta uma temperatura diferenciada nos fusíveis de 400 A de um QGB, tal como descrito na equação 1, sendo necessário *retrofit*. O quadro necessitou ser documentado e estabeleceu-se um plano de acompanhamento e avaliação do seu funcionamento e das cargas instaladas nele para evitar falhas futuras no fornecimento destes circuitos.

Figura 2. Termografia em QGBT



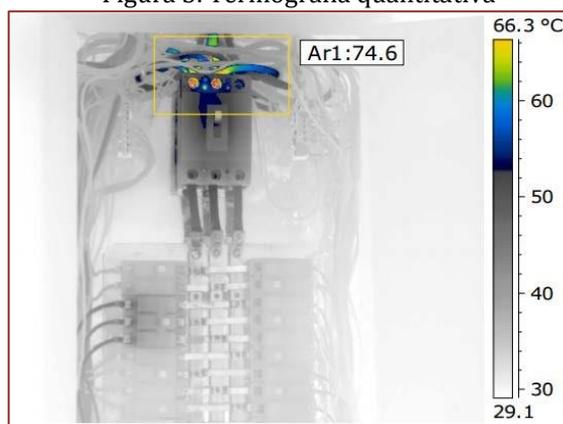
Por meio de inspeção visual foi possível constatar que os quadros gerais de distribuição possuíam diversas expansões, não prevista no projeto inicial, das quais alteravam o correto funcionamento do quadro colocando em risco a segurança dos usuários e aumentando a probabilidade de acionamento do sistema de segurança da linha. A maior parte dos quadros de distribuição geral apresentou algum aquecimento em tomadas de uso específica, mas dentro da faixa de temperatura de trabalho, e desbalanceamentos de carga com sobrecarregar constante na fase 'S'.

Durante o primeiro contato com o setor de manutenção do sistema foi apresentado aos pesquisadores o constante acionamento do sistema de proteção de um bloco secundário paralisando a linha de produção dependente daquele fornecimento, ocorrendo sempre nos momentos de pico de utilização e estando a equipe a duas semanas aferindo a causa da falha. Após captura termográfica do quadro de distribuição

geral que fornece energia para a construção observou-se aquecimento irregular no cabeamento de alimentação do disjuntor geral conforme demonstrado abaixo.

Na figura 3 temos um exemplo de uma conexão a parafuso de um disjuntor, e um cabo ligado a ela com revestimento de PVC, nesse termograma podemos fazer uma análise levando em consideração valores de mercado para esse tipo de cabo, e conexão a parafuso, olhando para a imagem podemos ver que a temperatura de pico de 74,6°C se encontra de fato no parafuso, pois é o ponto de maior destaque, nesse ponto a temperatura máxima é de 120°C, no entanto no cabo com revestimento PVC a temperatura máxima de trabalho é de 70°C, sendo esses 74,6°C a temperatura de entorno do cabo vemos um risco potencial, que deve ser estudado com bastante atenção para evitar possíveis danos aos equipamentos interligados a esse circuito e falhas em momentos críticos da operação do sistema.

Figura 3. Termografia quantitativa



Através da termografia identificou-se sintomas térmicos que possibilitaram identificar o real problema do mau funcionamento de um dos sistemas de proteção; o desbalanceamento de carga generalizado em mais de 80% dos quadros de distribuição geral pode ser aferido de forma rápida e precisa com destaque para as fases desbalanceadas em cada quadro; temperatura elevada em uma das fases do barramento primário da subestação apresentou diferença de 43,9°C necessitando estudo mais aprofundado em harmônicos da rede e na qualidade da energia fornecida pela concessionária além de se recomendar o estudo de massa pela concessionária.

5 CONCLUSÕES

Em meio a necessidade de tornar a manutenção mais eficiente e eficaz o estudo demonstrou que a termografia é um excelente método de monitoramento preditivo ao identificar, de forma não invasiva sem necessário desligamento do sistema, condicionantes que deflagrem uma atividade de prevenção ou correção de acordo com o identificado. Realizou-se uma avaliação geral no sistema elétrico com rápida execução e pequena equipe de pessoal.

Em alguns casos do estudo foi possível detectar sistemas que não possuíam problema aparente, mas dos quais o potencial de falha ao sistema era grande. No total verificou-se 11 irregularidades responsáveis por falhas na qual 5 foram de baixo risco sendo sugerido acompanhamento, 4 de médio risco com necessárias soluções preventivas e 2 de risco imediato apresentando urgência de correção. Observa-se que a integração de atividade termográfica na equipe de manutenção é otimizadora na eficiência de uma indústria gerando alta produtividade, excelência em qualidade, baixos custos, e precisão no tempo de manutenção despendido.

Para trabalhos futuros recomenda-se a realização de coleta e cruzamento de medições acerca de equipamentos defeituosos, obtidas por métodos invasivos e por método termográfico, para dimensionar confiabilidade estatística e dados de operação. Um estudo aprofundado sobre a sensibilidade termográfica a baixos índices de qualidade de energia e seus impactos nos equipamentos também devem ser executados.

REFERÊNCIAS

- [1] Arcipowska, A et al. Energy performance certificates across the eu – Bpie 2014.
- [2] Associação Brasileira de Normas TÉC-Nicas. Nbr 5462 - Confiabilidade e manutenção - Rio de Janeiro 1994.
- [3] Bramson, M. Infrared radiation: A handbook for applications – New York, Plenum Press 1968.
- [4] Cachada, A. et al. Maintenance 4.0: Intelligent and Predictive Maintenance System Architecture a. IEEE 23rd International Conference On Emerging Technologies and Factory Automation (Etf) 2018.
- [5] Camara, J. et al. Manutenção elétrica industrial - Ufrn 2012.
- [6] Carstens, I. O papel da gestão da manutenção na estratégia de operações – Pontifícia Universidade de Católica do Paraná 2007.
- [7] Dos Santos, L. Termografia Infravermelha em Subestações de Alta Tensão Desabrigadas – Universidade Federal de Itajubá 2006.
- [8] Flir. Thermal imaging guidebook for building and renewable energy applications – Flir 2014.
- [9] Flir. The Ultimate infrared handbook for r&d Professionals – Flir 2015.
- [10] Fogliatto, F. et al. Confiabilidade e manutenção industrial – Rio de Janeiro, Abepro 2011.
- [11] Kardec, A. et al. Manutenção, função estratégica – Rio de Janeiro, Qualitymark 2009.
- [12] Knezevic, J. Mantenimiento – Isdefe 1996. Lemos, M. et al. Qualidade na manutenção -Enegep 2011.
- [13] Mamed Filho, J. Instalações Elétricas Industriais– Rio de Janeiro, LTC 2013.
- [14] Mercer, J. et al. Thermography and thermal Symmetry - Ieee International Symposium On Medical Measurements and Applications (MeMeA) 2014.
- [15] Nassar, W. manutenção de máquinas e equipamentos – Universidade de Santa Cecília 2015.
- [16] Santos, A. et al. Eficiência Energética Teoria & Prática - Procel Educação, Universidade Federal de Itajubá 2007.
- [17] Sezer, E. et al. An Industry 4.0-enabled Low Cost Predictive Maintenance Approach for SMEs: A Use Case Applied to a Cnc Turning Centre - Ieee International Conference on Emerging Technologies and Factory Automation (Etf) 2018.
- [18] Snell, J. et al. Developing Operational Protocol for Thermographic Inspection Programs, Spie Vol. 1682, 1992.
- [19] Suzuki, T. TPM em indústrias de processos – TO- Kutarō Suzuki 1994.
- [20] Wang, Y. et al. Monitoramento de equipamentos para falhas relacionadas à temperatura utilizando câmeras de termografia - Ieee Petroleum And Chemical Industry Committee Conference (Pcic) 2015.
- [21] Wakjira, W. et al. Melesse. Total Productive Maintenance: A Case Study in Manufacturing Industry - Global Journal of Research In Engineering 2012.
- [22] Westerlund, P. et al. Prediction of current in a substation in order to schedule thermography - Ieee International Conference on Probabilistic Methods Applied to Power Systems (Pmaps) 2016.
- [23] Yan, H. et al. Research on the detection mechanism of defect in ferromagnetic materials using eddy current thermography – Ieee International Conference on Ubiquitous Robots and Ambient Intelligence (Ural) 2016.

Capítulo 6

Implementação de um Módulo IoT para controle de luminárias LED baseado em espelho de corrente com chaveamento de ramos

Raimundo Cláudio Souza Gomes

Rubens de Andrade Fernandes

Lennon Brandão Freitas do Nascimento

Marcus Vinicius Martins Melo

Karolayne Barbosa Martins

Israel Gondres Torné

Resumo: O paradigma de comunicação Internet das Coisas assumiu destaque para soluções específicas e globais nos mais variados sistemas, tendo como elemento principal a informação fluindo entre os diferentes processos. Uma área susceptível à aplicação de Internet das Coisas é a iluminação. Atualmente existe uma carência de soluções em luminárias inteligentes. Por isso, o objetivo deste artigo é propor uma solução que integre o conceito de Internet das Coisas e iluminação para a convergência em iluminação inteligente. Essa solução utilizará de conceitos relacionados a circuitos transistorizados responsáveis pelo controle de corrente em luminárias LEDs assim como o User Datagram Protocol, que é responsável pelas regras de comunicação do sistema. A implementação desse módulo será capaz de tornar as luminárias LEDs que atualmente são elementos passivos em edifícios em luminárias que disponibilizam ao usuário possibilidades de controle de iluminação através do Wi-Fi.

Palavras-chave: Luminárias Led; iluminação inteligente; sistemas de comunicação sem fio; internet das coisas; Espelho de Corrente; microeletrônica.

1. INTRODUÇÃO

Grande parte dos eletroeletrônicos atuais não possuem recursos que lhe habilitem estabelecer comunicação remota. Poucos deles são capazes de compartilhar dados entre si ou com as tecnologias de armazenamento em nuvem (Ala Al-Fuqaha 2015). A tecnologia que propicia a implementação de tais recursos é denominada Internet das Coisas, mais conhecida como IoT (acrônimo de Internet of Things).

A Internet das Coisas é um paradigma de comunicação em evidência atualmente. Ela adquiriu relevância na indústria e na comunidade acadêmica por ser um dos pilares para quarta revolução industrial, também denominada no Brasil como Indústria 4.0 (C. Perera et al 2014). Esse paradigma consiste na conexão de objetos comuns à internet ou virtualização dos mesmos. Esses objetos são dotados de transceptores para comunicação digital e pilhas de protocolos adequados que possibilitarão uma intercomunicação entre eles. A partir dessa perspectiva de comunicação entre dispositivos, o IoT dará a oportunidade de desenvolvimento de aplicações com diferentes finalidades que utilizem a quantidade significativa de dados gerados por esses dispositivos para assim disponibilizar aos usuários novos serviços (J.ChandraMohan 2017).

Aplicações de IoT são encontradas tanto na literatura e teoria quanto na parte de desenvolvimento prático. Atualmente já são observados no âmbito de transporte, veículos, agricultura, saúde, mercados e indústrias (A. A.-Fuqaha et al. 2015). Elas possuem suas particularidades de acordo com as áreas que estão inseridas. No caso da iluminação, existe o conceito da iluminação inteligente ou smart lighting. Existem grandes desafios para IoT nessa área, haja visto o número limitado de tecnologias desenvolvidas. Além disso, o custo das soluções existentes se torna uma barreira para transição de uma iluminação passiva para iluminação controlável e comunicável. Tendo isso em vista, será abordado neste artigo a implementação de um módulo IoT que fornecerá tais recursos, controlabilidade e comunicação, para as luminárias LED (Light Emissor Diode) comuns atualmente instaladas nas plantas de iluminação.

2. REFERENCIAL TEÓRICO

2.1 Diodo Emissor de Luz

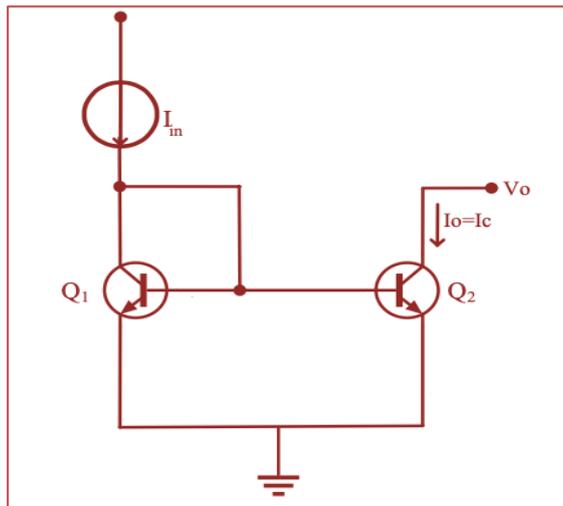
O Diodo Emissor de Luz ou LED é a tecnologia de fonte luminosa mais eficiente disponível atualmente, devido a sua eficácia e vida útil duradoura. Algumas de suas características são a alta corrente de operação e o fluxo luminoso que depende da corrente aplicada, a qual deve ser adequadamente regulada para manter a intensidade luminosa desejada.

Para representar a String de LEDs, foi utilizada uma luminária pública contendo um Chip on board (CoB) de LEDs de alto brilho de 50 W, que pode emitir até 5000 lm e possui eficiência luminosa de aproximadamente 90 lm/W. Ele pode trabalhar com até 36 V e 1,5 A.

2.2 ESPELHO DE CORRENTE

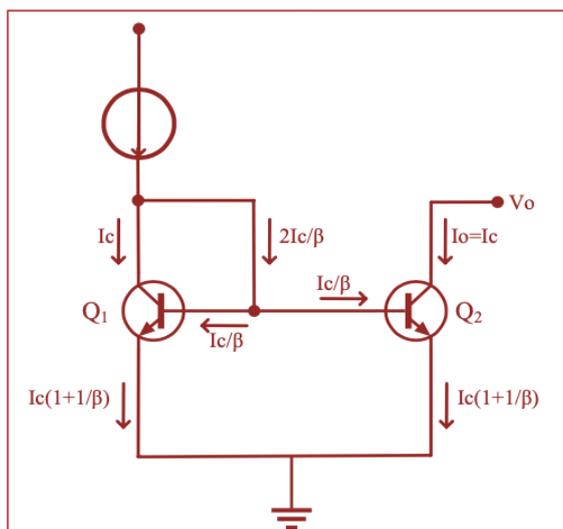
Os espelhos de corrente são estruturas com larga aplicação em projetos de circuitos analógicos, particularmente em amplificadores operacionais. Eles representam um método bastante utilizado para a obtenção de uma corrente de polarização constante para estágios diferenciais. O conceito acerca dessa técnica foi desenvolvido especificamente para a realização da polarização de circuitos integrados analógicos. Na figura 1 é mostrado um espelho de corrente simples aplicável em estágios de polarização de circuitos integrados.

Figura 1 - Espelho de corrente'



Para uma melhor análise acerca desta topologia, observa-se a figura 2. Garante-se que uma corrente constante gerada no primeiro transistor, seja espelhada no segundo, a fim de que o esforço para gerar uma corrente estável não seja repetido em cada estágio do circuito. Isso ocorre quando uma corrente de referência I_{ref} é aplicada no transistor Q_1 , que está ligado como diodo, estabelecendo uma tensão V_{BE} para ambos os transistores, e um mesmo valor de corrente de emissor. Assim, esse valor de tensão de base-emissor, forçará uma corrente no transistor Q_2 . Desprezando a corrente de base, para um valor de β bem elevado, pode-se garantir que a mesma corrente que passa por Q_1 está sendo espelhada em Q_2 (SEDRA, S. 2005).

Figura 2 - Espelho de corrente



Uma limitação desse tipo de espelho é que, para valores finitos de β , ou ∞ , uma pequena corrente circula pela base dos transistores, o que causa um erro na intensidade da corrente espelhada. Nesse caso, a corrente no coletor de Q_1 é calculada a partir da equação 1:

$$I_c = I_{ref} - \frac{2I_c}{\beta} \quad [1]$$

I_C é a corrente que passa no coletor de Q1. A partir desta equação, obtemos a equação 2, isolando I_{ref} :

$$I_{ref} = I_C + \frac{2I_C}{\beta} = I_C \left(1 + \frac{2}{\beta} \right) \quad [2]$$

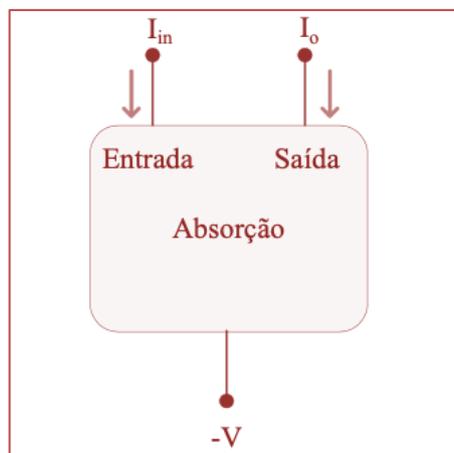
Dado que a corrente I_o que passa no coletor de Q2, é igual a corrente I_C que passa no coletor de Q1, obtém-se a razão de transferência de corrente

$$\frac{I_o}{I_{ref}} = \frac{I_C}{I_C \left(1 + \frac{2}{\beta} \right)} = \frac{1}{1 + \frac{2}{\beta}} \quad [3]$$

Para valores finitos de β é gerado um erro que aumenta à medida que a razão de transferência de corrente sobe.

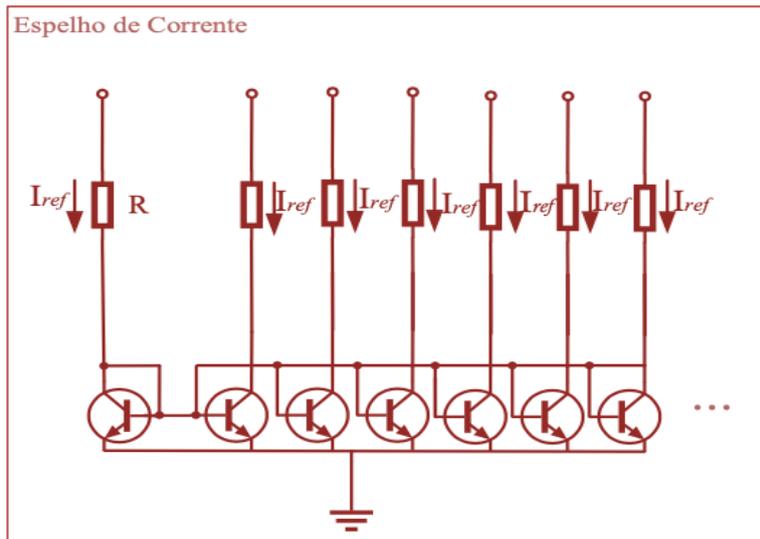
O espelho de corrente da figura 1 tem como finalidade que a corrente de saída I_{ref} seja igual a corrente de entrada I_{ref} . O circuito externo no qual a corrente de saída I_o flui contém a carga cuja será alimentada por essa corrente constante. A partir disso, com os espelhos de corrente é possível fazer cópias precisas de correntes, distribuindo a polarização pelos circuitos, sem a necessidade do uso de resistores e outros componentes passivos. Com esse comportamento, os circuitos dessa natureza podem ser generalizados conforme a figura 3 abaixo.

Figura 3 – Diagrama de bloco – Espelho de corrente



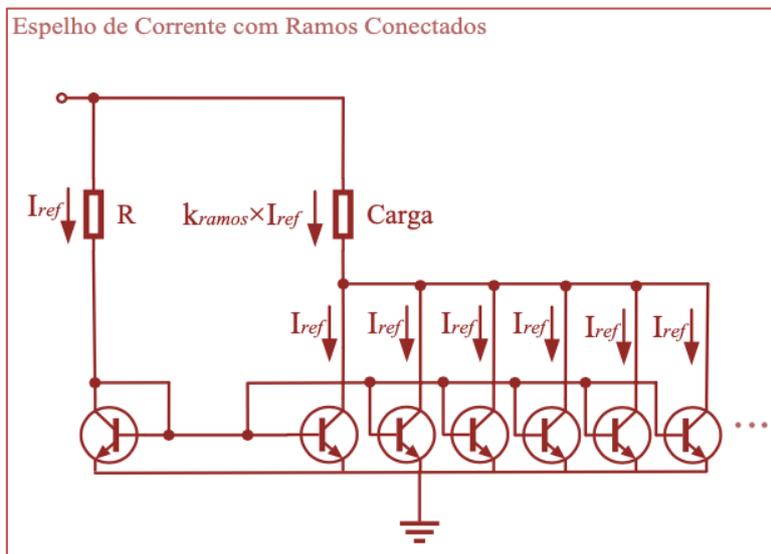
Conforme citado anteriormente, o espelho de corrente é muito utilizado em circuitos integrados. Na figura 2 é ilustrado como uma corrente é espelhada em um outro ponto de um circuito. Entretanto nos CIs existe a necessidade de obtenção de um valor de corrente em vários pontos do circuito. Para resolução desse problema, os ramos podem ser replicados de forma que sejam conectados em partes espalhadas pelo circuito. Essa topologia que consta na figura 4 possibilita o fornecimento de uma mesma corrente constante para diversos pontos do circuito.

Figura 4 – Espelho de corrente com cópias da corrente de referência



Além de realizar a cópia da corrente de referência, é possível obter como saída do espelho de corrente uma corrente maior que a de referência. Isso se torna possível quando os ramos se conectam em um mesmo nó. A partir de então, tem-se que a corrente de saída do espelho de corrente é igual corrente de referência conectado ao número de ramos. A figura 4 mostra exatamente esta última topologia de circuito. A corrente que flui pela carga é exatamente o produto entre o número de ramos (k_{ramos}) e a corrente de referência (I_{ref}) que é mostrada na equação 4.

Figura 5 – Espelho de corrente com cópias da corrente de referência



$$I_{carga} = k_{ramos} \cdot I_{ref} \quad [4]$$

Onde K é exatamente o número de ramos que os espelhos de corrente contem. Sendo assim, Corrente de saída I_{carga} é diretamente proporcional a corrente de entrada I_{ref} multiplicada pela quantidade de ramos do circuito.

2.3 TRANSISTORES

Como o sistema de LEDs utilizado possui corrente nominal elevada e os transistores utilizados em espelhos de corrente operam em regiões lineares, os transistores bipolares utilizados para testes devem possuir encapsulamento robusto e capacidade de condução de corrente considerável. Além disso, visando diminuir o erro gerado pela razão de transferência, ou seja, o valor da razão entre a corrente de coletor e a corrente de base do semiconductor escolhido deve ser suficientemente grande para minimizar este fator.

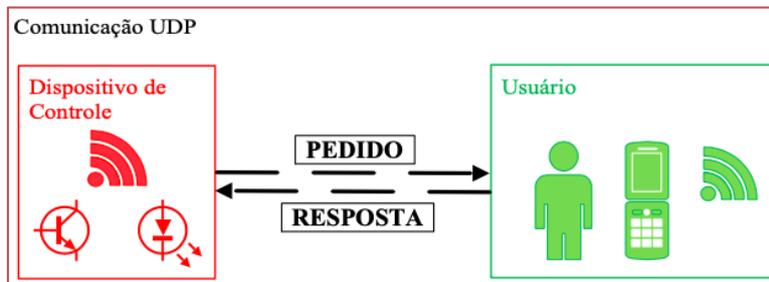
A chave eletrônica utilizada foi um transistor de efeito de campo de semiconductor de óxido metálico, ou do inglês MOSFET, que receberia então o sinal do GPIO, do inglês General Purpose Input/Output, para entrada do ramo ao sistema. O MOSFET escolhido também deve possuir baixo $R_{DS(on)}$ para reduzir as perdas de condução na corrente de base dos transistores bipolares.

2.4 PROTOCOLO UDP

O User Datagram Protocol, mais conhecido pela sigla UDP, é um protocolo que atua na camada de transporte. Juntamente com o Transmission Control Protocol (TCP), que foca na garantia de recebimento dos pacotes de dados e também sua integridade, o UDP é um dos protocolos mais usados na camada citada. (I. Coonjah, 2015). O protocolo UDP se destaca devido sua velocidade de trabalho com o fluxo de dados, mas, em contrapartida, não traz garantias quanto o recebimento e a integridade dos pacotes de dados. Sendo assim, é muito utilizado em aplicações onde há necessidade de uma comunicação em baixa latência, sem necessidade de alta precisão, ao contrário do TCP (A. R. Rind, 2006).

O protocolo UDP foi escolhido devido à necessidade de um enlace de forma rápida para que a dimerização fosse realizada em tempo real, mas também, sem que fosse necessário a confirmação do recebimento e integridade dos dados. A figura 6 apresenta o diagrama de comunicação UDP utilizado para conectar o usuário ao dispositivo de controle de iluminação.

Figura 6 - Protocolo UDP com o dispositivo móvel.



2.5 MÓDULO DE CONTROLE WIRELESS: ESP8266

De acordo com a fabricante Espressif Systems o ESP8266 é um System on Chip (SoC) com grande integração wireless, projetado para plataformas móveis com restrição de espaço e potência. Ele oferece capacidade de incorporar recursos de Wi-Fi dentro de outros sistemas, ou para funcionar como uma aplicação standalone, com o menor custo e com mínimo requisito de espaço (Espressif, 2018). O ESP8266EX integra switch de antena, RF Balun, amplificador de potência, amplificador de recepção de baixo ruído, filtros e módulos de gerenciamento de energia. O design compacto minimiza o tamanho da placa de circuito impresso e requer poucos circuitos externos.

Além das funcionalidades de Wi-Fi, o ESP8266EX também integra uma versão aprimorada do processador de 32 bits que opera em frequências ajustáveis de 80 a 160 MHz da Tensilica e SRAM no chip, do inglês Static Random Access Memory. Pode ser conectado com sensores externos e outros dispositivos através dos GPIOs. Esses recursos citados e as especificações do ESP8266 podem ser observados nas figuras 5 e 6 respectivamente: (Espressif, 2018)

Tabela 1. Especificações do ESP8266

| Componentes | Referências |
|----------------------|--|
| CPU | Tensilica L106 32-bit processor |
| Wi-Fi | 802.11 b/g n |
| Faixa de Frequência | 2.4 GHz |
| Protocolos de Rede | IPv4, TCP/UDP, HTTP/FTP, 802.11 b/g/n/, protocolo WLAN MAC |
| Periféricos | UART, SDIO, SPI, I2C, I2S. |
| | GPIO, ADC, PWM |
| Tensão de operação | 2,5V ~ 3,6V |
| Tensão de operação | 3.3 V |
| Corrente de operação | 80 mA |

2.6 FRAMEWORK PARA DESENVOLVIMENTO DO APLICATIVO: QT

Trata-se de uma multiplataforma baseada em linguagem de programação C++, responsável pelo desenvolvimento de interfaces gráficas. O QT é baseado em módulos, sendo os dois principais o QT essentials e o QT addon. O essentials carrega todas as bibliotecas responsáveis pelo funcionamento do programa e o addon apenas as bibliotecas adicionais que não são alocadas nas distribuições básicas, o que permite com que o produto evolua com o tempo e não se torne ultrapassado através da inserção de novas bibliotecas no módulo (Z. Gui-gen 2010). O QT também se trata de um programa de alta performance devido a linguagem no qual é baseado, por esse motivo e também por ser um programa de fácil aprendizado, conta com uma comunidade de mais de um milhão de desenvolvedores, o que nos dá acesso à uma comunidade de grandes proporções caso surjam problemas durante o desenvolvimento. Além disso, o framework possui diversas ferramentas de desenvolvimento e API's, que colaboraram para criação de um aplicativo com comunicação web baseado no protocolo UDP, cujo qual foi utilizado para realizar o controle dos níveis de iluminação.

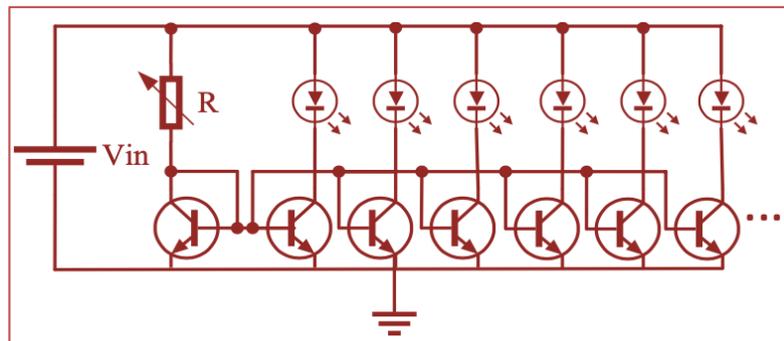
3. MODELAGEM E IMPLEMENTAÇÃO DO SISTEMA

O uso de espelhos de corrente é uma alternativa para homogeneizar a corrente nos aglomerados de LEDs, a fim de garantir que a corrente que circula em cada ponto de LED seja um reflexo da corrente de referência. O espelho de corrente evitará que o brilho total seja reduzido e que o brilho de cada string de LED se torne desigual (J. Kim and S. Park 2016). Como a corrente em todos os pontos será igual à corrente de referência, todos os LEDs apresentarão a mesma intensidade luminosa.

Vale ressaltar que ao utilizar o espelho de corrente o efeito de avalanche térmica é contornado. Esse efeito consiste no incremento de corrente de fuga no semicondutor das luminárias LED, que, que ocasiona o aumento da temperatura na junção, que conseqüentemente realimenta a corrente de fuga entrando em um ciclo onde ocorre realimentação autodestrutiva do dispositivo.

Para assegurar que os espelhos de corrente funcionem conforme o esperado é essencial que os transistores utilizados possuam as mesmas características construtivas. A figura 7 é um exemplo de circuito que utiliza espelho de corrente com múltiplos ramos para acender LEDs proposto por J. Kim and S. Park 2016.

Figura 7 - Circuito com espelho de corrente para acionamento de LEDs

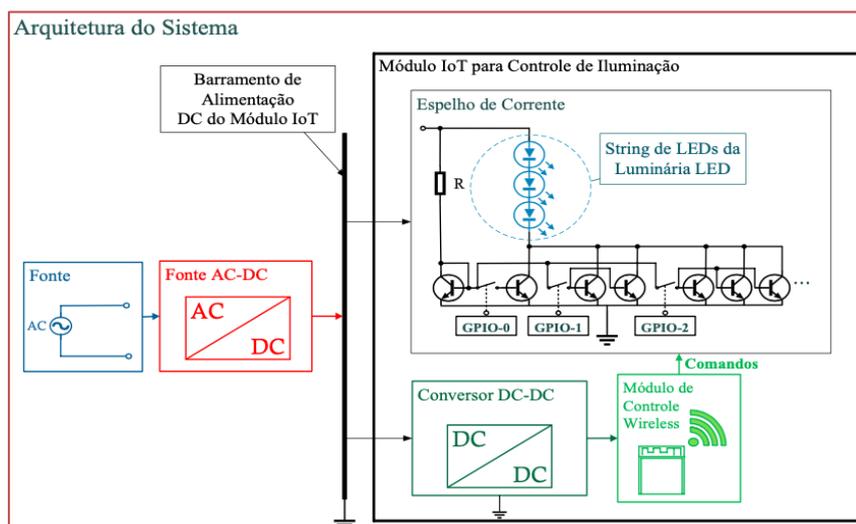


Para soluções similares à da figura 7, o controle do fluxo luminoso se dá pela variação do valor da resistência que se encontra no ramo principal. A partir disso, percebe-se a necessidade de utilizar um potenciômetro para tais aplicações. Todavia, as aplicações de IoT trazem em sua essência o controle remoto de dispositivos. Ao considerar esse fato, verifica-se a necessidade de utilização de um potenciômetro digital para que esse controle ocorra de forma remota. Entretanto potenciômetros digitais possuem custos monetário significativo ao considerar os demais elementos do circuito.

Em alternativa a isso, a modelagem proposta neste capítulo para controle de corrente e fluxo luminoso para os LEDs se deu pela escolha da quantidade de ramos no espelho de corrente. Na figura 5 onde os ramos possuem um nó em comum, foi verificado que quando há o aumento da quantidade de ramos, há, por consequência, o aumento no valor da corrente total que entra no nó comum a todos eles. Logo, ao selecionar a quantidade de k ramos conforme a equação 1, é possível variar a corrente. A figura 8 abaixo mostra a topologia do circuito de acordo com o esse conceito.

O uso de um circuito para controle de iluminação aplicado ao contexto de Internet das Coisas necessita de elementos de comunicação que possibilitem a interoperabilidade desse dispositivo com o usuário final. A figura 8 apresenta um diagrama em blocos que representa a arquitetura de hardware do sistema implementado.

Figura 8 - Visão geral da arquitetura de hardware do sistema.



O modelo apresentado na figura 3 apresenta as seguintes características:

A corrente I_c é regulada através do resistor R , no ramo principal;

O controle de iluminação é realizado mediante o acionamento individual de cada ramo do espelho de corrente projetado;

Um ramo do espelho de corrente pode conter um ou mais transistores bipolares, permitindo que cada acionamento possa levar a diferentes níveis de condução de corrente;

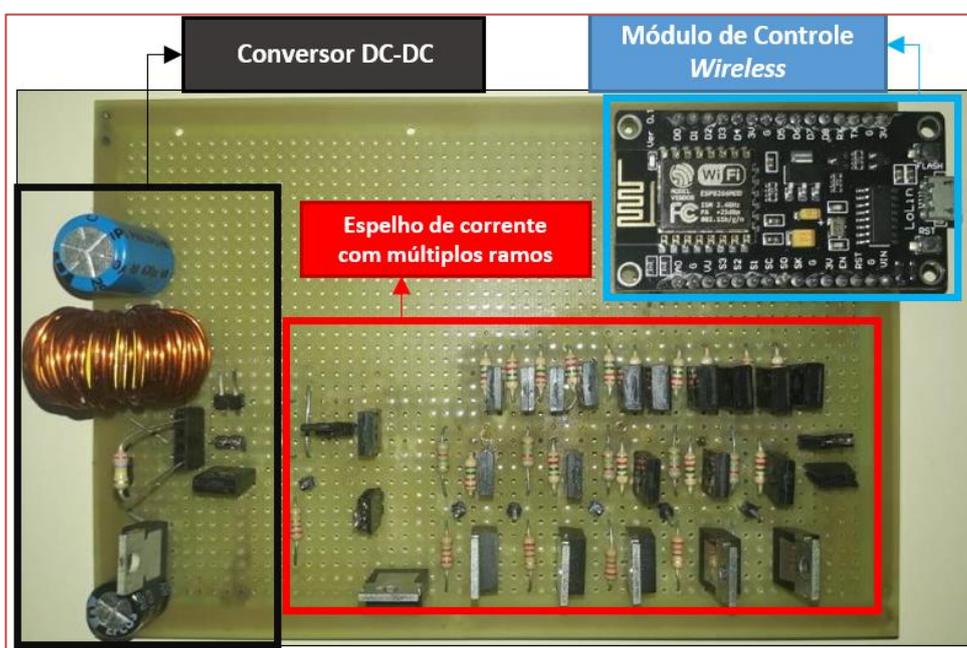
Cada ramo do sistema é acionado individualmente por um GPIO de um módulo de controle wireless, que irá controlar chaves eletrônicas responsáveis pela conexão dos ramos do espelho de corrente;

Através do módulo de controle wireless, o usuário poderá se comunicar em rede sem fio com o dispositivo. E então, controlar o fluxo luminoso dos LEDs de forma remota;

O microcontrolador recebe sua alimentação de um conversor DC-DC, que por sua vez, é alimentado por um barramento de tensão DC proveniente da saída do conversor AC-DC utilizado para alimentar o sistema;

Ademais, nota-se que o bloco que ilustra o Módulo IoT para Controle de Iluminação na figura 3 é composto por três sub-blocos que são: Conversor DC-DC, Módulo de Controle Wireless e o Espelho de corrente. Essa abordagem de visão arquitetural do sistema auxilia no entendimento do funcionamento do circuito. A figura 9 apresenta o protótipo implementado conforme a arquitetura mencionada.

Figura 9 - Protótipo de teste desenvolvido



Na imagem são visualizados os três blocos citados. O protótipo receberá alimentação em corrente contínua de 30V, que alimentará o bloco de conversão DC-DC e a entrada do espelho de corrente. O conversor DC-DC foi elaborado através de um circuito regulador step-down com o regulador LM2596, que abaixa a tensão de entrada para 5V, necessários para alimentação do Módulo de Controle Wireless. Através do módulo wireless, é possível se conectar a uma rede Wi-Fi local e, através do protocolo UDP, receber comandos do usuário por meio de um aplicativo. O firmware do módulo estava preparado para receber os pacotes, interpretá-los e acionar os GPIOs correspondentes, bem como o aplicativo deve enviar os dados corretamente para o controle de luminosidade.

Considerando estas características, o transistor bipolar escolhido para os ramos foi o BD135, que possui corrente nominal de coletor de até 1,5 A, com β de aproximadamente 150 para temperaturas de 25°C, suportando tensões entre coletor e emissor de até 45 V, o que o torna adequado para utilização em conjunto com o CoB escolhido. Vale ressaltar que β é a relação entre a corrente de coletor e a corrente de base, denominado ganho estático de corrente. O MOSFET utilizado foi o IRF3205, que possui $R_{ds(on)}$ de 8 m Ω .

Vale destacar que por ser constituído principalmente por elementos semicondutores, o dispositivo desenvolvido pode ser implementado em circuitos microeletrônicos integrados para o controle de corrente de forma digital, através de dispositivos de controle. O protótipo foi projetado com apenas 5

ramos no espelho, possibilitando a obtenção de diversos níveis de controle de fluxo luminoso com o dispositivo.

4. TESTE E VALIDAÇÃO

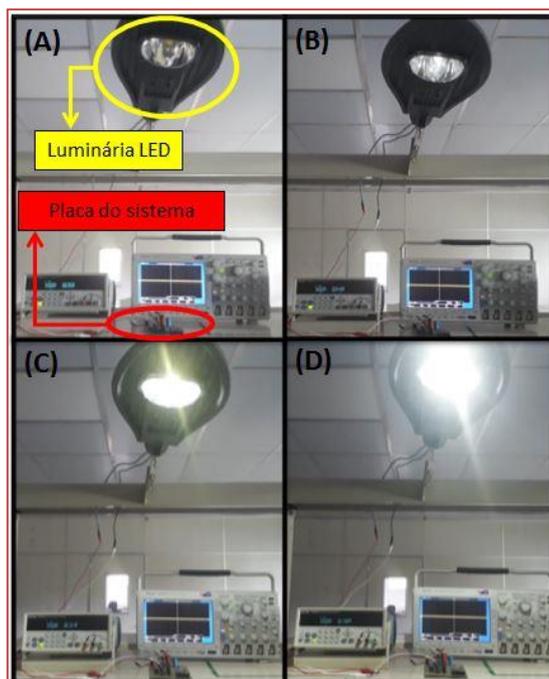
Conforme apresentado na arquitetura de hardware na figura 3, o protótipo desenvolvido é constituído por três unidades básicas: Um conversor DC-DC, um módulo de controle wireless e um circuito espelho de corrente com múltiplos ramos. A fim de testar e validar a integração dessas três unidades do sistema, foi montado um cenário de teste utilizado os itens relacionados abaixo:

- Uma alimentação de 30V proveniente de uma fonte DC regulável de bancada;
- Uma Luminária Publica LEDPétala 50W;
- Uma rede de área local Wi-Fi, onde os endereços de IP são previamente conhecidos;
- Um aplicativo elaborado no framework QT;
- O protótipo apresentado na figura 9;
- Um resistor no valor de 1 k Ω a fim de regular a corrente no ramo principal;
- Dois multímetros utilizado para medir os parâmetros de corrente e de tensão;

As pontas de prova dos multímetros foram acopladas na saída e na entrada do dispositivo, a fim de validar os parâmetros de eficiência do sistema pela relação de potência. Esta relação foi obtida através da coleta dos parâmetros de tensão e corrente correspondente a cada nível de luminosidade. A lâmpada foi acoplada ao protótipo conforme ilustrado na figura 3, cuja sua funcionalidade é a mesma que a String de LEDs da Luminária LED.

Na figura 10, é possível visualizar o cenário de teste com os itens relacionados acima, bem como a luminária utilizada sob alguns níveis de controle de iluminação realizados pelo dispositivo através do app. Na figura (A) o sistema está em nível 0, onde todos os ramos estão desativados e a luminária está desligada. Na figura (B) o sistema está em nível 1, na figura (C) em nível 7 e na (D) em nível 15, com maior luminosidade. Os resultados coletados foram obtidos através deste cenário de testes.

Figura 10 - Ambiente de testes. A: Sistema no nível 0. B: Sistema no nível 1. C: Sistema no nível 7. D: Sistema no nível 15.



A figura 11 apresenta a interface do aplicativo elaborado no QT para controle de iluminação. O aplicativo possibilita a regulação do nível de iluminação em uma escala de 0 a 15. Nessa imagem é possível visualizar um exemplo de três níveis diferentes selecionados pelo usuário.

Figura 11 - Interface do aplicativo desenvolvida para realizar o controle de iluminação.



Para realizar os testes, foi definido um resistor no valor de 1 kΩ a fim de regular a corrente no ramo principal, o que permitiu produzir uma corrente de aproximadamente 30 mA em cada transistor que compõe os ramos do espelho de corrente. No entanto, considerando o erro devido a razão de transferência, sabe-se que a corrente por transistor pode ser reduzida à medida que mais ramos do espelho são acionados.

5. RESULTADOS E DISCUSSÕES

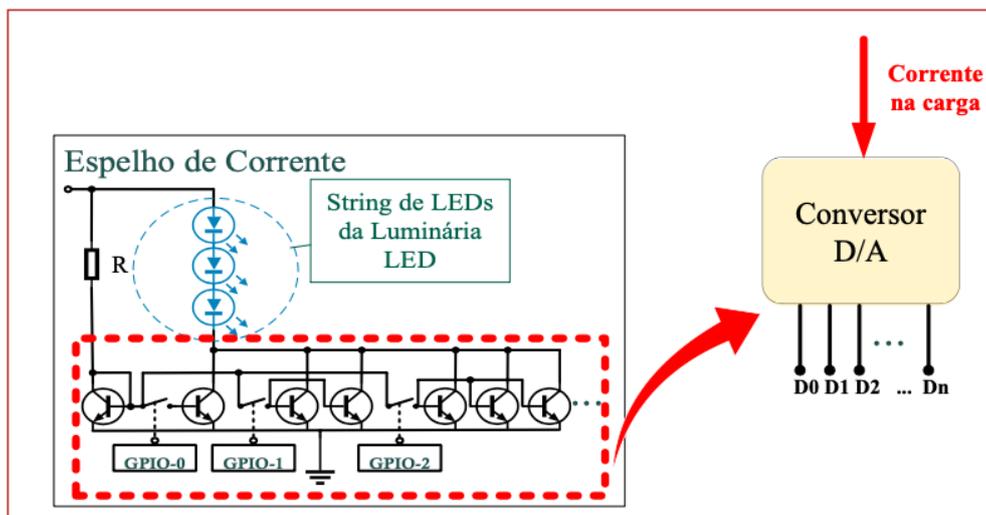
Conforme verificado na figura 10, os níveis de corrente no LED aumentaram a medida em que os GPIOs do ESP8266 nodeMCU comutavam para nível lógico alto. Comprova-se com este resultado o processo de controle de fluxo luminoso pelo sistema de forma remota. Além disso, fica evidente que este método possibilita a convenção de luminárias LED convencionais em uma carga controlável remotamente, caracterizando-se como um método de retrofit. A relação entre a variação de corrente, potência no CoB e eficiência do módulo, de acordo com o acionamento individual de cada GPIO, é apresentada na tabela 2.

Tabela 2. Variação de corrente e potência no CoB e eficiência do módulo IoT por GPIO de controle acionado

| Nº do GPIO | Corrente (mA) | Potência (W) | Eficiência (%) |
|------------|---------------|--------------|----------------|
| 0 | 30 | 0,82 | 42 |
| 1 | 59,2 | 1,63 | 58 |
| 2 | 88,5 | 2,45 | 72 |
| 3 | 114 | 3,20 | 74 |
| 4 | 142 | 4,02 | 75 |

Como previsto, com o acréscimo de transistores conectados, o incremento da corrente a cada acionamento foi reduzido. Isso pode ser visualizado na tabela 2 quando ocorre a conexão dos GPIOs 3 e 4, onde há redução no incremento da corrente no CoB de LEDs. Sabendo que a tipologia de circuitos reguladores por espelhos de corrente trabalha em regiões lineares de condução, os elementos semicondutores podem vir a dissipar energia na forma de calor, reduzindo a eficiência do circuito. A fim de contornar este fato, optou-se por não utilizar a capacidade total do CoB visando evitar o aquecimento destes componentes. Dessa forma, a eficiência deste sistema é dada através da razão entre a potência consumida pelo CoB de LEDs e a potência de entrada do sistema, indicando que os transistores, em suas respectivas regiões lineares, impactam diretamente na eficiência do sistema.

Figura 12. Modelo de conversor digital-analógico de corrente estabelecido com o método proposto.



De forma inédita, nesta aplicação, foi implementada a técnica de chaveamento de ramos para controle de fluxo luminoso em uma matriz de LEDs, estabelecendo um módulo conversor digital-analógico (DAC) que possibilita realizar o controle dos níveis de corrente contínua. Isso ocorre através do acionamento de ramos conforme uma palavra binária aplicada a entrada digital do sistema, tal como ilustrado na figura 12. Dado que na implementação do referido módulo foram utilizadas técnicas típicas de encapsulamento para semicondutores, baseando-se na tecnologia de módulos de chaveamento e espelhos de corrente, vislumbra-se a possibilidade de implementação integrada deste sistema em trabalhos futuros.

Na comparação desta técnica com o modelo de espelhos de corrente convencionais baseados em controle por potenciômetros digitais ou analógicos, tal como ilustrado na figura 7, a solução proposta apresenta-se como uma alternativa satisfatória para controle digital de forma remota e com menor custo de implementação. Isso a torna favorável para utilização em aplicações de internet das coisas.

6. CONCLUSÕES

O sistema proposto apresentou as funcionalidades e resultados condizentes com o esperado. Realizou-se o retrofit de uma luminária LED convencional, que não possuía recursos de conectividade ou possibilidade de controle remoto, em uma luminária LED com recursos capazes de oferecer serviços de acionamento remoto e variação de fluxo luminoso por meio de uma rede de comunicação wireless. Tudo isso baseando-se na adaptação do modelo tradicional de espelhos de corrente por uma topologia apta a regular a corrente contínua através do acionamento de cada ramo do espelho.

Essa nova abordagem para espelhos de corrente foi projetada, nesta aplicação, para o controle de iluminação. Contudo, esta técnica pode ser difundida para sistemas que necessitem de controle de corrente por meio de sistemas digitais, o que inclui tecnologias embarcadas capazes de se comunicar em redes de dados. Dessa forma, possibilita-se a inclusão de novos dispositivos dentro do contexto de internet das coisas.

Para trabalhos futuros, vislumbra-se a implementação de novas soluções de IoT utilizando o método de retrofit e a possibilidade da redução do protótipo físico no modelo proposto para espelhos de corrente em

um encapsulamento integrado dos semicondutores, empregados na concepção dos circuitos analógicos deste trabalho.

AGRADECIMENTOS

Gratidão à Universidade do Estado do Amazonas (UEA) por todo suporte, em especial ao centro de desenvolvimento “HUB: Inovação e Tecnologia”, por oferecer todo o aparato técnico para o desenvolvimento do protótipo e realização dos testes. Grato aos amigos Samuel Bruno e Ítalo Tony pelo apoio prestado.

REFERÊNCIAS

- [1] A.-Fuqaha et al., “Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications,” *IEEE Commun.Surveys & Tutorials*, vol. 17, no. 4, 4th qtr. 2015, pp. 2347–76.
- [2] R. Rind, K. Shahzad and M. A. Qadir, “Evaluation and comparison of TCP and UDP over Wired-cum-Wireless LAN,” 2006 IEEE International Multitopic Conference, Islamabad, 2006, pp. 337-342.
- [3] Ala Al-Fuqaha, Mohsen Guizani, Mehdi Mohammadi, Mohammed Aledhari, (2015), “Internet of Things: A Survey on Enabling Technologies, Protocols and Applications”, *IEEE Communications Surveys & Tutorials*, vol.3, no.5.
- [4] Perera et al., “A Survey on Internet of Things: From Industrial Market Perspective,” *IEEE Access*, vol. 2, Dec. 2014, pp. 1660–79. *Espressif 2018 - ESP 8266 Datasheet*
- [5] Coonjah, P. C. Catherine and K. M. S. Soyjaudah, “Experimental performance comparison between TCP vs UDP tunnel using OpenVPN,” 2015 International Conference on Computing, Communication and Security (ICCCS), Pamplemousses, 2015, pp. 1-5.
- [6] J.ChandraMohan, R.Nagarajan, K.Satheeshkumar, N.AjithKumar, P.A.Gopinath, S.RanjithKumar (2017) “Intelligent Smart Home Automation and Security System using Arduino and Wi-Fi”, *International Journal of Engineering and Computer Science*, vol 6,issue 3,pp.20694-20698.
- [7] J. Kim and S. Park, “12.8 Synchronized floating current mirror for maximum LED utilization in multiple-string linear LED drivers,” 2016 IEEE International Solid-State Circuits Conference (ISSCC), San Francisco, CA, 2016, pp. 232-233.
- [8] SEDRA, S.; SMITH, K. *Microeletrônica*. 4ª. Edição, Pearson Makron Books, São Paulo, Brasil, 2005.
- [9] Z. Gui-gen, W. Shuang, C. Lei and C. FuZhou, “The Implementation of oSIP Stack in Developing Qt Software in Embedded Linux,” 2010 First International Conference on Networking and Distributed Computing, Hangzhou, 2010, pp. 137-141.
- [10] Ben Pronk and Stefan Verbrugh, *Challenges of the Integration of Lighting Systems and Components in IoT*, 2018, pp. 50-76.

Capítulo 7

Sistema de Manufatura Inteligente para seleção de mangas utilizando Deep Learning

Carine Ramos de Almeida Gottschall

João Erivando Soares Marques

Cleia Santos Libarino

José Alberto Diaz Amado

Resumo: Este trabalho possui o intuito de desenvolver um sistema de manufatura inteligente capaz de classificar e selecionar mangas de acordo com o seu grau de maturação, utilizando redes deep learning, especificamente convolucionais, aliada a um processo de visão computacional. Para isso, foi construída uma base de dados utilizando imagens de mangas Tommy Atkins, Haden e Palmer, em três estágios de maturação distintos, verde, maduro e muito maduro. O sistema desenvolvido dispõe de uma esteira para transporte do fruto, um suporte para posicionamento dos dispositivos e três rampas de direcionamento. O desempenho da rede neural foi avaliado mediante a análise da acurácia e perdas nos testes de validação. Os resultados apresentados mostraram uma acurácia superior aos 99% no processo de seleção inteligente.

Keywords: Deep Learning; Convolutional Neural Networks; Computational Vision; Manufacturing System; RGB Images; Mangoes.

Palavras-chaves: Aprendizado Profundo; Redes Neurais Convolucionais; Visão Computacional; Sistema de Manufatura; Imagens RGB; Mangas.

1. INTRODUÇÃO

O avanço constante na computação e na robótica, decorrido maiormente após o ano 2000, viabilizou a execução de atividades noutro tempo impraticáveis e que favorecem as mais diversas áreas da ciência. Um campo de grande difusão da robótica e automação foi a agricultura. De acordo com o levantamento da Comissão Brasileira de Agricultura de Precisão (CBAP), 67% das propriedades agrícolas do país empregam algum tipo de tecnologia, seja na gestão dos negócios ou nas atividades de cultivo e colheita da produção (Brasil, 2017). No entanto, ainda há demanda por métodos mais eficientes, não somente no monitoramento da fase de cultivo, mas também, na inspeção e seleção dos produtos pós-colheita, para obter-se o melhor aproveitamento da produção.

O Brasil é um dos maiores produtores frutícolas, com destaque para as mangas, ocupando o 6º lugar no ranking de maiores produtores de mangas da Organização das Nações Unidas para Alimentação e Agricultura (FAO) em 2014 Comércio Exterior (COMEX, 2017), em contraposição a isso tem-se a recepção dos frutos pelo consumidor, que é afetada por grandes perdas ocorridas principalmente no período pós-colheita. Há ainda uma meta estipulada pela Organização das Nações Unidas (ONU) através do Objetivo de Desenvolvimento Sustentável (ODS) que prevê, dentre outras medidas, a redução das perdas nos sistemas de produção e abastecimento incluindo o momento pós-colheita até 2030. Diante disso, há necessidade da incorporação de processos mais eficientes aplicados à seleção e classificação de mangas, afinal, são esses procedimentos que definem se determinado fruto está ou não com a qualidade exigida pelo consumidor. Um importante indicador da qualidade da manga é a cor de sua casca, como analisado pela Empresa Brasileira de Pesquisa Agropecuária (Embrapa, 2000).

No caso da avaliação do estágio de maturação, os padrões são definidos em níveis, os quais indicam a aparência da fruta em uma dada etapa de seu desenvolvimento, como este processo compreende um fenômeno não linear e ainda modificável pelas condições ambientais e sendo a imagem da fruta também influenciada por estes fatores, uma vez que reproduz as condições da superfície dos frutos, se torna viável a utilização de imagens para determinar o estágio de maturação dos mesmos, como aponta Carvalho et al. (2014). Eles apresentaram um método baseado em inspeção visual automática para a classificação de mangas da variedade *Tommy Atkins* através da avaliação da cor da casca aplicando *Machine Learning* (ML). Os autores desenvolveram um método de classificação automático baseado na conversão de escala de cores *Hue Saturation Light* (HSL) com a descrição do percentual de cada componente da escala em histograma e a associação do valor do nível para cada percentual de cores. O histograma da imagem capturada da fruta era comparado ao histograma médio encontrado no passo anterior para rotular a mesma.

Um outro sistema de classificação de maturação de mangas utilizando ML foi desenvolvido por Silva et al. (2017), o qual aplicou Redes Neurais Artificiais (RNA) para realizar o processo de aprendizagem. O sistema permitia a distinção de três classes através da captura e pré-processamento das imagens para obtenção das porcentagens de cada componente da escala de cores *Red Green Blue* (RGB). Os trabalhos de classificação de frutas mais recentes, Sa et al. (2016), Puttemans et al. (2016), Bargoti e Underwood (2017), Muresan e Oltean (2018) e (Barth et al. 2018), empregam técnicas inteligente que permitem a análise do fruto pelo próprio algoritmo de aprendizagem sem a necessidade de um pré-processamento para extração das características a serem avaliadas. Isso é possibilitado mediante o emprego das *Convolutional Neural Networks* (CNN), que consistem em um método de aprendizagem profunda projetado para trabalhar com imagens (Lecun et al. 2001).

O trabalho desenvolvido por Sa et al. (2016) é aplicado a colheita robótica e tem como propósito identificar frutas em pomares, incluindo pimenta doce, melão, maçã, abacate, manga e laranja. O sistema utiliza a fusão do modelo RGB e *Near Infra Red* (NIR) e um algoritmo VGG-16 para treinamento, além adaptar uma rede convolucional bem mais rápida conhecida como *Faster R-CNN* que permitiu obter um desempenho superior às redes CNN já existentes e a identificação do posicionamento dos frutos, mesmo com a existência de planos de fundos barulhentos. Além disso, também utilizam uma técnica de transferência de aprendizado entre pomares, facilitando o processo de treinamento da rede.

Bargoti e Underwood (2017) apresentam uma proposta e abordagem semelhante aos autores anteriores para frutas do tipo manga, amêndoa e maçã, além do método de transferência de aprendizagem eles também empregam uma técnica de aumento de dados, resultando em uma redução maior que duas vezes no número de imagens de treinamento necessárias. Diante das análises feitas, os autores observam que um meio menos dispendioso de reduzir o erro de rotulagem seria usar a saída do detector treinado para limpar os dados de fundo da imagem com um ser humano no circuito.

Já Muresan e Oltean (2018) utilizaram uma rede neural convolutivas para classificação de 95 tipos de frutas distintas, com base de dados própria contendo imagens de frutas rotacionadas em 360 graus. As imagens eram pré-processadas para retirada do fundo ruidoso, de modo a reproduzir apenas o fruto. A arquitetura empregada foi implementada pelos próprios autores que também aplicaram técnicas de aumento de dados através da variação de matiz e saturação e inversão vertical e horizontal das imagens empregadas no treinamento do algoritmo, obtendo bom desempenho no que diz respeito a acurácia e perda tanto nas fases de treinamento como de teste.

O estado da arte ligado a esta temática apresenta diversas técnicas de aprendizagem de máquina aplicados a classificação e seleção de frutas. As técnicas de aprendizado profundo apresentam melhor desempenho tanto na classificação em si, quanto no tempo de processamento do sistema. No entanto, estes não propõem a avaliação da maturação das mangas aplicando redes CNN e sua seleção na etapa pós-colheita. Em vista disso, a contribuição deste trabalho está na implementação de um processo de seleção pós-colheita de mangas quanto ao seu grau de maturação, em: verdes, maduras ou muito maduras, utilizando *deep learning* por meio de uma rede CNN, aplicado a um sistema de manufatura automatizado. O artigo se encontra organizado da seguinte maneira: A Seção 2 apresenta os materiais e métodos empregados no desenvolvimento do sistema. A Seção 3 apresenta os resultados obtidos. As conclusões do trabalho são apresentadas na Seção 4.

2. Materiais e Métodos

O sistema foi construído e organizado em três blocos distintos: o sistema de visão computacional, o sistema de classificação e o sistema de seleção do fruto. Estes comunicam entre si de tal forma que o sistema de visão é responsável por capturar informações do processo, as imagens das mangas, que são aplicadas como entradas no sistema de classificação, o qual rotula o fruto de acordo a sua maturação. Por fim, esse resultado é utilizado para o controle de acionamento do sistema de seleção, a Figura 1 retrata o diagrama de funcionamento do sistema.

Figura 1: Diagrama esquemático de funcionamento do sistema inteligente



2.1. SISTEMA DE VISÃO COMPUTACIONAL

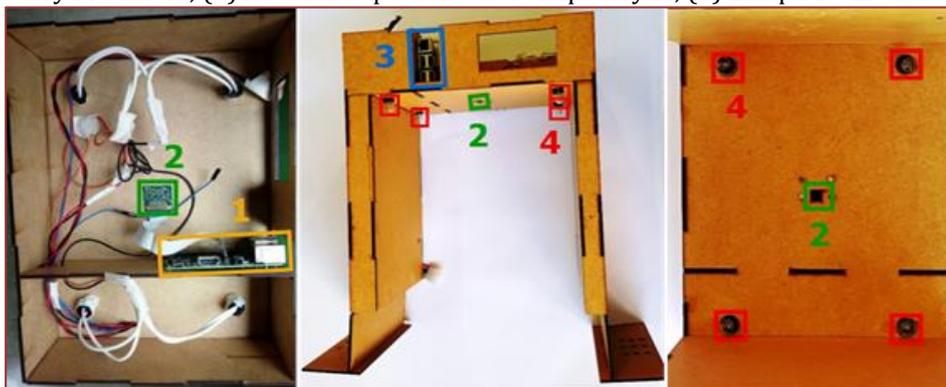
O sistema de visão computacional é composto por uma câmera que permite o sensoriamento e captura de características visuais do objeto de trabalho. Para a captura de imagens foi necessário um controle de iluminação garantindo um bom índice de reprodução de cor (IRC), o qual quantifica a fidelidade com que as cores de um objeto são reproduzidas sob determinada fonte de luz artificial. Assim utilizou-se um suporte simulando uma câmara escura sobre o qual foram dispostas quatro lâmpadas incandescentes, com IRC próximo a 100, nas extremidades do teto, eliminando o máximo possível a influência da iluminação ambiente, reduzindo a formação de sombras e a proporcionando a iluminação de toda a superfície do fruto.

Tanto o sistema de visão quanto o sistema de classificação exigem um computador para processar os dados. Optou-se por empregar o Raspberry Pi 3, por se tratar de um *System on Chip* (SoC), possuir compatibilidade com pacotes e *frameworks* necessários à aquisição e processamento de imagens e à execução dos algoritmos de rede, além de ser de fácil acoplamento a estrutura física do sistema.

As imagens das frutas foram coletadas através do módulo *Raspberry Pi Camera* modelo RP_ov5647, pelo fato deste possuir desempenho adequado à aplicação desejada e ser compatível com o microcomputador e o sistema operacional instalado.

A câmera foi acoplada através do cabo flat, diretamente à placa pela *Camera Interface Serial (CSI)* e posicionada no centro do teto inferior do suporte. A Figura 2 mostra a estrutura do suporte e o posicionamento da câmera e do sistema de iluminação sobre o mesmo.

Figura 2: Suporte e disposição do sistema de visão computacional e iluminação: (1) Raspberry Pi 3; (2) Raspberry Pi Camera; (3) Acesso aos periféricos do Rapberry Pi; (4) Lâmpadas incandescentes.



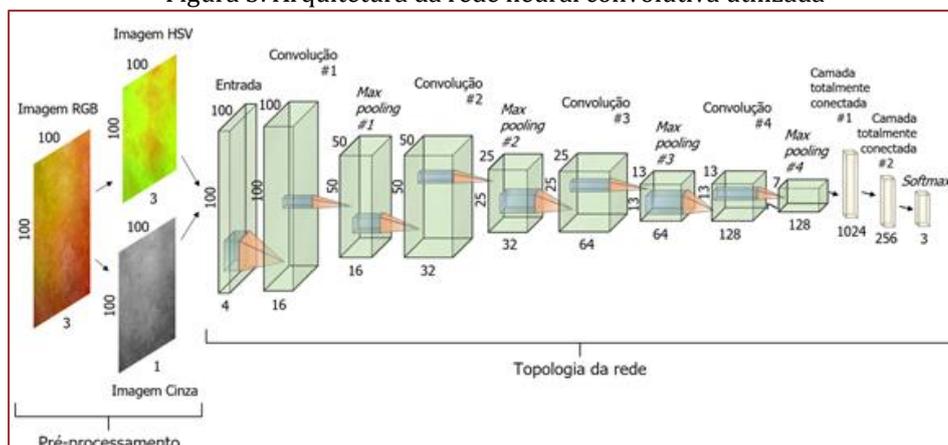
2.2. SISTEMA DE CLASSIFICAÇÃO DE MANGAS

A implementação do sistema de classificação de mangas decorreu com a definição da topologia de rede a ser empregue para categorizar a maturação das mangas, seguida da construção da base de dados, *Dataset*, do treinamento do modelo e dos testes de validação, os quais serão discorridos nas próximas subsecções.

2.2.1. IMPLEMENTAÇÃO DA REDE NEURAL CONVOLUTIVA

A arquitetura escolhida foi a construída por Muresan e Oltean (2018), pelo fato de possuir ótima *performance* e acurácia na classificação de 95 classes de frutas distintas. Outro ponto favorável do modelo é sua topologia, composta por apenas quatro camadas convolucionais que são capazes de extrair importantes características de padrões de coloração e dimensão das frutas e apresentam uma técnica de aumento de dados para expandir a quantidade de imagens de treinamento através da inversão vertical e horizontal das mesmas, melhorando o processo de treinamento. A rede recebe como entrada uma imagem com 100 *pixels* de altura e 100 *pixels* de largura com um formato .jpg e quatro camadas de profundidade. A profundidade da camada de entrada é proveniente de um pré-processamento da imagem RGB capturada pela câmera com 3 camadas de profundidade, que é filtrada para o sistema *Hue Saturation Value (HSV)* e escala de cinza, resultando em uma imagem HSV com três camadas de profundidade e uma imagem em escala de cinza com uma camada de profundidade, como mostra a Figura 3.

Figura 3: Arquitetura da rede neural convolutiva utilizada



Fonte: Adaptado de Muresan e Oltean (2018, p. 18)

2.2.2. CONSTRUÇÃO DA BASE DE DADOS

As imagens para treinamento e teste da rede foram capturadas através da Picamera e obtidas cerca de 40 fotos para 30 mangas diferentes, sendo elas verdes, maduras ou muito maduras, com a disposição de uma única fruta por vez sobre a esteira e com o sistema de iluminação acionado. As mangas utilizadas no Dataset foram do tipo *Tommy Atkins*, *Haden* ou *Adam e Palmer*, pois as mesmas apresentam características de cores semelhantes durante a maturação. Tanto para a coleta de dados quanto para a análise da manga, foi definido um único lado do fruto, visto que ao longo da sua superfície as tonalidades são variantes. A metodologia adotada para rotular as frutas foi baseada no padrão de coloração de estágios de maturação da Embrapa (Assis e Lima, 2008). O estágio 1, visto na Figura 4, corresponde ao rótulo verde, o estágio 2 ao rótulo madura e o estágio 3 ao muito madura.

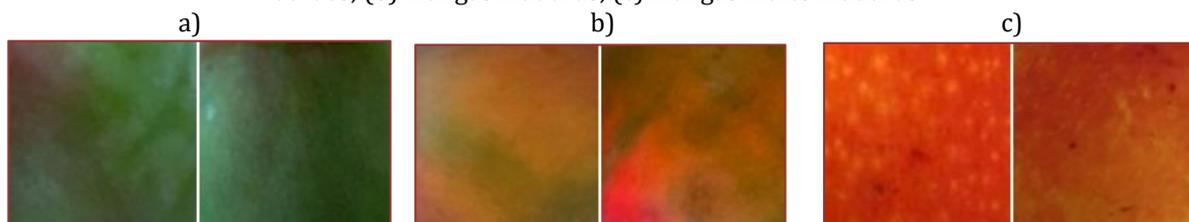
Figura 4: Escala de maturação da manga *Tommy Atkins* segundo a coloração da casca.



Fonte: Adaptado de Assis e Lima (2008).

A dimensão da captura das imagens foi de 1000 pixels de altura e 1000 pixels de largura. Para acrescentar à quantidade de imagens do *Dataset* e à variação dos padrões para cada estágio foram extraídas fotografias de mangas através do aplicativo Google Images, as quais ajustadas, no que diz respeito ao brilho, saturação, matiz e cor da imagem para melhor adequação aos padrões definidos. As imagens obtidas foram recortadas de modo a compreender apenas padrões de coloração do fruto sem contemplar sua forma, já que essa é invariante durante o processo de maturação do fruto. Posteriormente, redimensionou-se as imagens para 100x100 como mostrado na Figura 5 com representação de cores RGB.

Figura 5: Amostra de imagens 100x100 utilizadas para treinamento e validação de rede: (a) mangas verdes; (b) mangas maduras; (c) mangas muito maduras.



2.2.3. TREINAMENTO DA REDE NEURAL

No treinamento da rede neural empregou-se 3.598 imagens rotuladas, que após serem submetidas as técnicas de aumento de dados, teve sua quantidade triplicada para 10.794 imagens. Foram realizados quatro treinamentos nos quais aplicou-se uma taxa de aprendizado, *learning rate*, variante, para evitar o *overfitting*, impedindo que o modelo se ajuste aparentemente muito bem ao conjunto de dados observado, mas se mostre ineficaz para prever novos resultados. A taxa inicial foi de 0,001 e a final de 0,00001. Os treinamentos foram executados mediante um computador *laptop* com um processador CPU intel-core i7 e sistema operacional Windows 10. Foram utilizadas diferentes combinações de parâmetros, variando a quantidade de épocas e imagens no mini-lote, no intuito de dispor da melhor delas no processo de classificação. O modelo foi treinado para parada através de um número de épocas definido.

2.2.4. AVALIAÇÃO DO DESEMPENHO DA REDE NEURAL

Para avaliar o desempenho da rede foram adotados de quatro parâmetros: a perda e a acurácia do treinamento; a resposta da rede em relação à categoria de maturação predefinida para os dados de validação; e o teste prático, no qual a rede neural foi implementada no sistema e a esteira foi acionada, iniciando o transporte de mangas cuja maturação já era conhecida pelo operador, e posteriormente comparando com a maturação indicada pela predição da rede. A realização dos testes consistiu na restauração dos pesos treinados para imagens desconhecidas pela rede, ou seja, que não haviam sido utilizadas na etapa de treinamento. A quantidade de imagens empregadas para teste foi definida através de uma proporção de 70% das imagens da base de dados para a fase treinamento, 20% para testes de validação e 10% para testes individuais, a Tabela 1 apresenta a quantidade de imagens por rótulo e por etapa.

Tabela 1: Número de imagens para cada rótulo empregada em cada etapa.

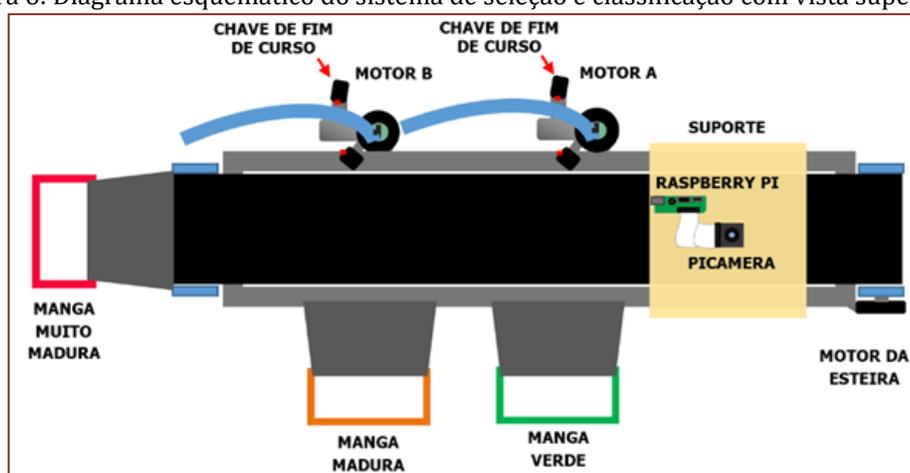
| Rótulo | Nº imagens treinamento | Nºimagens teste | Nº imagenstestes individuais |
|--------------|------------------------|-----------------|------------------------------|
| Verde | 1.200 | 340 | 170 |
| Madura | 1.195 | 340 | 170 |
| Muito madura | 1.203 | 340 | 170 |

2.3 SELEÇÃO DO FRUTO

O processo de seleção inicia-se após a predição da maturação da manga, a qual é transportada até o atuador correspondente para ser seja direcionada ao caminho adequado. Assim, foi implementado um controle de velocidade e acionamento da esteira, bem como dos atuadores de seleção. A movimentação da esteira procedeu-se mediante o acionamento de um motor DC de 12V, com um único eixo de tracionado. Para tanto aplicou-se um gerador de sinal *Pulse Width Modulation* (PWM) e uma chave ON/OFF com o fim de permitir a parada do processo e a permanência do fruto no local adequado, centralizado com a câmera, para captura da imagem e, logo após o processo de classificação, o religamento do motor, para o transporte da fruta sob a esteira até chegar ao local de seleção.

Foram elaborados selecionadores retangulares com comprimento curvo de plástico com 5 mm de espessura, 26 cm de comprimento e 5 cm de largura. Como o sistema distingue três classes de mangas, implantou-se dois selecionadores rotativos na estrutura, acoplados cada um ao eixo de um motor diferente, enquanto que, a terceira classe do fruto é transportada até o final da esteira e rola por uma rampa, como mostra a Figura 6.

Figura 6: Diagrama esquemático do sistema de seleção e classificação com vista superior.



A movimentação dos selecionadores se deu através de dois motores *Direct Current* (DC) de vidro elétrico de 12 V de lado direito com oito dentes e consumo de 1,3 A. O acoplamento com o eixo dos motores estabeleceu-se por meio de uma peça adaptativa de *durepoxi*, a qual, por sua vez, foi parafusada ao braço de plástico. Para a inversão de rotação dos dois motores empregou-se um módulo Ponte H L298N, com uma alimentação de 12V e para o controle de velocidade utilizou-se as saídas PWM da placa

Arduino. O mecanismo de seleção implantado foi baseado na retenção do fruto após a classificação, sendo ele verde ou maduro.

Para marcar o início e o fim de curso que delimita o movimento dos selecionadores na estrutura da manufatura, foram utilizadas chaves de fim de curso. Cada motor possui duas chaves de fim de curso, estrategicamente posicionadas como visto na Figura 6, que marcam o início e o fim de curso do motor e quando acionadas realizam a parada do motor no ciclo em que o mesmo se encontra. As frutas retidas pelos selecionadores continuam submetidas a velocidade do motor da esteira e devido ao ângulo e o formato do selecionador, como pode ser visto no diagrama da Figura 6, rola até cair pela rampa correspondente a sua classe. Caso a manga esteja muito madura ela é transportada até o final da esteira e desce por uma terceira rampa.

3. RESULTADOS E DISCUSSÕES

Foram executados vários cenários de treinamento da rede neural utilizando diferentes quantidade de imagens de mini-lote e de épocas. A cada 50 épocas ou passos, foi calculada a precisão através do método de *cross validation* ou entropia cruzada. Os resultados finais de acurácia e perda correspondente a cada cenário são apresentados na Tabela 2.

Tabela 2: Resultado do treinamento executado para diferentes configurações de parâmetros da rede

| Treinamento | | | Acurácia | Perda |
|-------------|-----------|-------------|----------|-------|
| T1 | Mini-lote | 60 | 99,00% | 4,24% |
| | Épocas | 10000 | | |
| | Duração | 12hrs 32min | | |
| T2 | Mini-lote | 40 | 99,14% | 5,34% |
| | Épocas | 8000 | | |
| | Duração | 6hrs 33min | | |
| T3 | Mini-lote | 70 | 99,08% | 5,24% |
| | Épocas | 7000 | | |
| | Duração | 7hrs 53min | | |
| T4 | Mini-lote | 80 | 99,58% | 3,59% |
| | Épocas | 8500 | | |
| | Duração | 10hrs 07min | | |

O tempo gasto no treinamento para configurações com uma quantidade maior de imagens de mini-lote é superior ao tempo gasto empregando mini-lotes menores, isso ocorre devido ao tipo de processador e a alocação de memória realizada pelo mesmo durante o processo. Como a CPU deve dividir as tarefas do seu processador para manter outras funcionalidades do computador, ou seja, não possui dedicação exclusiva ao treinamento do modelo e sendo as imagens do pacote de mini-lote agrupadas uma por uma na memória RAM, é exigido um tempo maior para que o processador seja capaz de alocar todas as imagens para o treinamento. Assim, a execução de uma época do algoritmo de rede é muito mais dispendiosa para a máquina no que diz respeito ao tempo de execução.

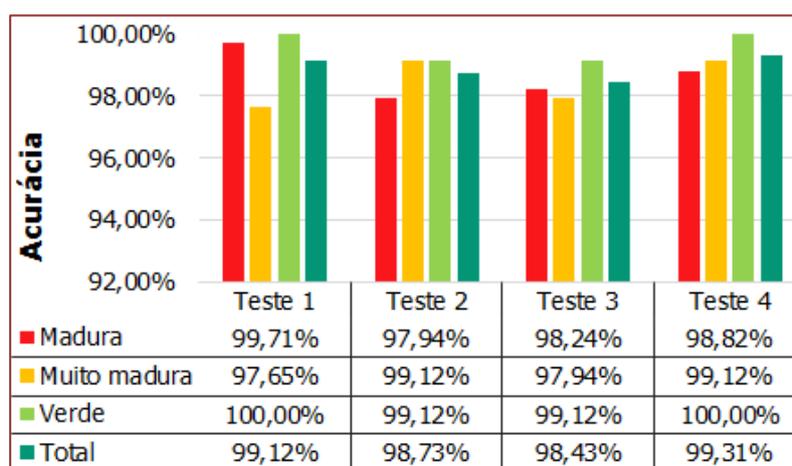
Ao comparar o resultado do treinamento T1 com o T2, é visto que, apesar do segundo apresentar uma acurácia maior, ou seja, maior proporção de predições corretas em relação ao tamanho do conjunto de dados, a perda na proximidade das distribuições de probabilidade retornada pela rede em relação a distribuição verdadeira é maior para T2. Dessa forma, a configuração que melhor contempla a base de dados obtida foi em T4, aplicando um número de mini-lote de 80 imagens e 8500 passos, pois apresenta uma acurácia superior às outras, além de uma menor perda na distribuição de probabilidade das classes. Nesse cenário uma maior quantidade de informações é processada por lote, assim a rede pode aprender vários recursos para classificar as imagens.

Após a avaliação de desempenho do treinamento da rede, foram feitos testes com a finalidade de validá-los. Para isso, restaurou-se os arquivos com os pesos de cada configuração distinta treinada e aplicou-se ao conjunto de testes, que é composto por 340 imagens de cada classe. Os resultados foram analisados segundo a acurácia, ou seja, as quantidades de predições corretas realizadas pela rede para cada cenário são apresentados na Tabela 3.

Tabela 3: Testes realizados para validar cada configuração treinada.

| Teste | | Classe | | | Total |
|-------|-------------|--------|-------------|-------|-------|
| | | Madura | Muitomadura | Verde | |
| T1 | Nº amostras | 340 | 340 | 340 | 1020 |
| | Nº acertos | 339 | 332 | 340 | 1011 |
| T2 | Nº amostras | 340 | 340 | 340 | 1020 |
| | Nº acertos | 333 | 337 | 337 | 1007 |
| T3 | Nº amostras | 340 | 340 | 340 | 1020 |
| | Nº acertos | 334 | 333 | 337 | 1004 |
| T4 | Nº amostras | 340 | 340 | 340 | 1020 |
| | Nº acertos | 336 | 337 | 340 | 1013 |

Figura 7: Acurácia resultante dos testes de validação para as quatro configurações de rede treinadas.

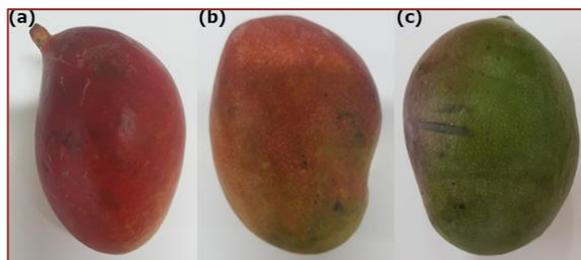


As configurações aplicadas em T2 e T3, apesar de apresentarem acurácia superior à T1 na etapa de treino, mostram com desempenho inferior nos testes, principalmente no reconhecimento de mangas maduras e verdes, sendo a pior *performance* exibida por T3. Isso é resultado do *overfitting* do modelo para os dados de treinamento e da falta de generalização para outras imagens. Os parâmetros empregados em T1 exibem acurácia semelhante para as etapas de treino e teste, menor erro inerente as probabilidades no treinamento e predição correta para todas as mangas verdes no teste.

O padrão de coloração apresentado no estágio de maturação para frutas verdes possui a menor variação de característica diante dos demais estágios, o que refletiu nos resultados de teste, sendo essa classe a que exibe mais predições corretas diante todas as avaliadas. A quarta configuração foi a que apresentou desempenho superior tanto para o treinamento quanto para os testes, mostrando um desempenho de 100% para as predições de mangas verdes e uma acurácia total de 99,31%, assim, optou-se por aplicá-lo para os testes práticos no sistema real de classificação.

Para verificar o grau de ligação que a análise dos dados de validação com a realidade, efetuou-se a implementação da rede já treinada no Raspberry Pi 3, juntamente com o *software* de controle do sistema, que realiza a coleta das imagens dos frutos, processamento e comunicação serial com o sistema de seleção. Foram utilizadas três mangas Palmer, uma para cada classe, mostradas na Figura 8, com a finalidade de averiguar o desempenho da rede para esse tipo de manga. Elas foram dispostas sobre a esteira sempre com o lado inferior voltado para câmera, com uma altura de 14 cm entre a câmera e a esteira.

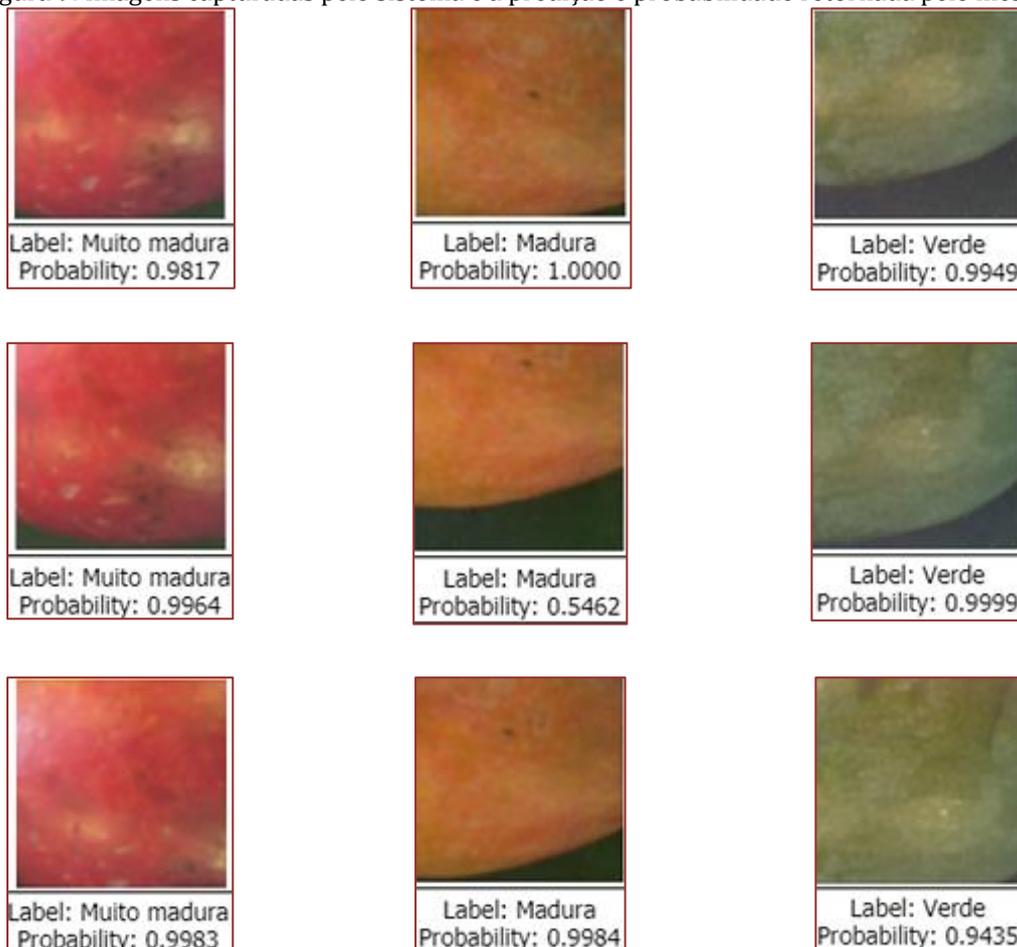
Figura 8: Mangas Palmer empregadas nos testes: (a) muito madura; (b) madura; (c) verde.



O sistema tem uma cadência de 12 segundos para coleta e classificação da imagem e um tempo de transporte e seleção de fruta de 5 segundos para as mangas verdes que são selecionadas pelo primeiro atuador e 7 segundos para as mangas maduras que acionam o segundo atuador, enquanto as frutas muito maduras levam 5 segundos para serem transportadas. As imagens capturadas, assim como a classificação e probabilidade das mesmas são apresentadas na Figura 9.

Como exposto na Figura 9, a rede foi capaz de classificar corretamente os estágios de maturação para a manga Palmer. Observou-se que a predição retornada ainda é afetada pela posição que o operador insere o fruto na esteira, para que seja capturada toda a superfície do fruto, como exposto na primeira linha e quinta coluna da Figura 9, apesar de rotular corretamente a maturação da manga, a rede responde com uma probabilidade baixa inerente a ela. A imagem obtida compreende uma boa parte da esteira afetando a probabilidade da predição. Para as demais capturas, o sistema apresentou uma boa distribuição de probabilidade, ou seja, uma perda muito pequena.

Figura 9: Imagens capturadas pelo sistema e a predição e probabilidade retornada pelo mesmo.



Nos testes realizados, a comunicação serial entre o Raspberry Pi e Arduino se deu de maneira eficiente, sem perdas de informação. O acionamento dos atuadores ocorreu como esperado, o primeiro selecionador, conseguinte ao suporte, foi movimentado na presença de mangas maduras, enquanto o selecionador subsequente foi acionado para a presença de mangas verdes, e por fim, nenhum selecionador foi acionado para as mangas muito maduras, que seguiram até o final da esteira, rolando pela terceira rampa. O protótipo referente ao sistema de manufatura desenvolvido se encontra na Figura 10.

Figura 10: Sistema de classificação e seleção de mangas.



4. CONCLUSÃO

A realização deste trabalho resultou na construção de um sistema inteligente capaz de classificar e selecionar mangas em três estágios de maturação predefinidos utilizando redes neurais convolucionais aplicada a um processo de manufatura automatizado. A definição e implementação dos algoritmos de reconhecimento das mangas, através de imagens 2D (altura x largura) utilizando aprendizado profundo e mais especificamente uma rede neural convolucional, permitiu o emprego da própria imagem como entrada da rede, sendo a extração das características mais relevantes executada pelo algoritmo de rede ao longo dos filtros aplicados nas camadas de convolução.

O treinamento da rede com os dados obtidos pela câmera e em pesquisa *online* e ainda aplicando técnicas de aumento de dados, com a inversão horizontal e vertical da imagem, permitiu o ajuste de pesos do algoritmo de classificação para a realização das previsões e uma probabilidade inerente a mesma. Os testes executados permitiram a validação do aprendizado da rede e ainda a definição da melhor configuração de mini-lote e número de passos para o desempenho considerando a acurácia e a perda no processo de predição. O maior desempenho do modelo de classificação foi exibido na predição das mangas verdes assim como a melhor distribuição de probabilidade.

A implementação do sistema de seleção permitiu o direcionamento adequado do mesmo de acordo com o estágio de maturação. O mecanismo empregado nesse processo foi capaz de efetuar a seleção das frutas de forma correta. Os testes realizados através da implementação do modelo treinado no sistema possibilitaram a definição da altura adequada da câmera em relação a esteira, a análise da intervenção do sistema de iluminação e interferência da iluminação do próprio ambiente em que se encontra o sistema e ainda a influência da resolução utilizada para captura da imagem, sobre o qual conclui-se que a aplicação de diferentes resoluções resulta na perda da distribuição de probabilidade da predição rede. A comunicação serial entre os subsistemas se mostrou eficiente e os atuadores foram acionados conforme previsto no projeto.

AGRADECIMENTOS

Ao IFBA e ao Grupo de Inovação e Pesquisa em Automação e Robótica (GIPAR) pelo suporte no desenvolvimento do trabalho.

REFERENCES

- [1] Bargoti e Underwood (2017)]Bargoti, S. and Underwood, J. (2017). Deep fruit detection in orchards. In IEEE. 2017, International Conference on Robotics and Automation (ICRA), pages 3626–3633, 2017.
- [2] Barth et al. 2018)]Barth, R., Ijsselmuiden, J., Hemming, J. and Henten, E. V. (2018). Data synthesis methods for semantic segmentation in agriculture: A capsicum annum dataset. *Computers and Electronics in Agriculture*, pages 284–296, 2018.
- [3] Brasil, 2017)]Brasil. (2017). Mais de 67% das lavouras usam tecnologia na produção agrícola: Instrumentos tecnológicos apoiam desenvolvimento da agricultura de precisão. Disponível em: <<http://www.brasil.gov.br/noticias/infraestrutura/2017/04/mais-de-67-das-lavouras-usam-tecnologia-na-producao-agricola>>. Acesso em: 09 de jan. de 2019.
- [4] Carvalho et al. (2014)]Carvalho, J. N., Gurjão, E. C., Mata, M. E. R. M. C. e Duarte, M. E. M. (2014). Classificação Automática de Frutas por Análise de Imagem: O caso da Manga Tommy Atkins. In WTA. 2014, Workshop de Tecnologia Adaptativa, 8th edition, 2014.
- [5] Comércio Exterior (COMEX, 2017)]Comércio Exterior - COMEX. (2017). Exportação: nos últimos três anos, a manga é a fruta que gera maior receita para o Brasil. Disponível em: <<https://www.comexdobrasil.com/exportacao-nos-ultimos-tres-anos-manga-e-fruta-que-gera-maior-receita-para-o-brasil/>>. Acesso em: 10 de jan. de 2019.
- [6] Embrapa, 2000)]Embrapa Brasileira de Pesquisa Agropecuária - Embrapa. (2000). Manga: Pós-colheita. Embrapa Comunicação para Transferência de Tecnologia, Brasília, 2000.
- [7] Lecun et al. 2001)]Lecun, Y., Bottou, L., Bengio, Y. and Haffner, P. Gradient-based learning applied to document recognition. In Haykin, S. and Kosko, B. *Intelligent Signal Processing*. IEEE Press, pages 306–351, 2001.
- [8] Muresan e Oltean (2018)]Muresan, H. and Oltean, M. (2018). Fruit recognition from images using deep learning. *Acta Univ. Sapientiae, Informatica*, volume 10, 1st edition, pages 26–42, 2018.
- [9] Puttemans et al. (2016)]Puttemans, S., Vanbrabant, Y., Tits, L. and Goedem, T. Automated visual fruit detection for harvest estimation and robotic harvesting. In IEEE. 2016, International Conference on Image Processing Theory, Tools and Applications (IPTA), pages 1–6, 2016.
- [10] Sa et al. (2016)]Sa, I., Ge, Z., Dayoub, F., Upcroft, B., Perez, T. and Mccool, C. (2016). DeepFruits: A Fruit Detection System Using Deep Neural Networks. *Sensors*, volume 16, doi: 10.3390/s16081222.
- [11] Silva et al. (2017)]Silva, F. S., Gottschall, C. R. A., Lima, D. S., Marques, J. E. S. and Amado, J. A. D. (2017). Desenvolvimento de um Controle Inteligente para Seleção de Mangas Aplicada a um Protótipo de Manufatura Robotizada. In MNR. 2017, Mostra Nacional de Robótica 2017, Anais, pages 703–707, 2017.

Capítulo 8

Controle de Suspensão Ativa Automotiva por Lógica Difusa

Neusa Valentim da Silva

Waldemar Bonventi Junior

Resumo: Foi desenvolvido o projeto de um controlador fuzzy para suspensão ativa automotiva, com seus parâmetros refinados por simulação. O modelo de suspensão utilizado foi de 1/4 de veículo (ônibus). Foram obtidos os parâmetros de sintonia do controlador PD fuzzy e o resultado comparado com um modelo PD convencional sintonizado. Como meta de controle, foram estipulados acomodação em menos de 5 segundos com menor número de oscilações.

Palavras-chaves: Controle Fuzzy PD; Suspensão Ativa Automotiva; Sistema Massa-Mola Amortecido; Modelo de 1/4 de Veículo; Método de Ziegler-Nichols; Método de Jantzen.

1. INTRODUÇÃO

O sistema de suspensão automotiva isola o veículo das irregularidades do piso e vibrações, para não transferi-los aos passageiros e a carga. Consiste em um conjunto amortecimento e restauração em cada roda, ou seja, um sistema massa-mola-amortecido (Halliday et al., 2002). Os objetivos de uma suspensão veicular são: (a) sustentar o peso da carroceria do veículo e proporcionar passeios confortáveis e seguros em vários tipos de superfícies rodoviárias; (b) isolar o corpo do veículo de distúrbios externos provenientes de superfícies irregulares e internos criados por curvas, aceleração ou desaceleração; (c) reagir a variações de carga, geradas por mudanças no número de passageiros e bagagem; (d) manter um contato firme entre a estrada e os pneus, garantindo que as rodas sigam o perfil rodoviário para um bom desempenho e segurança na condução.

As suspensões automotivas são classificadas em três tipos: passivas, semiativas e ativas, de acordo com os seus elementos constituintes e o desempenho fornecido. A suspensão ativa consiste em um atuador que compense os deslocamentos e vibrações da via. Essa é regulada por um algoritmo de controle usando dados de sensores conectados ao veículo. Também é composta por um atuador e uma mola mecânica, ou ambos mais um amortecedor. A mola suporta a carga estática da massa suspensa e o atuador de força fornece a força reativa necessária para minimizar ou absorver a deformação causada por irregularidades do solo. O atuador pode ser hidráulico, pneumático ou eletromagnético, ou ainda uma solução híbrida (Mulla and Unaume, 2013).

Com um controlador proporcional-integral-diferencial (PID) atuando entre a suspensão e a carroceria, Popovic et al. (2000) obtiveram, para os casos de um automóvel e um ônibus, com um sobressinal de cerca de 5%, e tempo de estabilização de aproximadamente 2,5 s, sendo a frequência natural do sistema cerca de 1 Hz. Pontelli (2012) estudou o controle das oscilações verticais da barra que sustenta os bicos pulverizadores de um equipamento agrícola (suspensão trapezoidal - quatro barras), com simulações em que a frequência imposta pelas oscilações do terreno variou de 0,1 a 2,0 Hz. Foram simulados controle PID e difuso, com oscilações tipo degrau, harmônica e randômica, não havendo grandes diferenças entre elas, exceto na oscilação randômica. Nesta, o controlador difuso apresentou um desempenho melhor. Em geral, as suspensões ativas hidráulicas ou pneumáticas são adequadas para aplicações de baixa largura de banda (de frações a poucos Hz). Corrigan et al. (1991) estudaram a otimização da constante elástica da mola e do coeficiente do amortecedor na suspensão hidráulica ativa para minimizar a potência necessária para sua operação. Strassberger and Guldner (2004) descreveram o sistema de barra estabilizadora ativa desenvolvido pela BMW, incorporado a suspensão hidráulica ativa. Outro exemplo comercial é dado pelo sistema de controle de corpo ativo (ABC – Active Body Control) da Mercedes-Benz. Este sistema também abaixa lentamente o veículo a velocidades mais altas (Daimler, 2016). A regeneração de energia do sistema de suspensão ativa eletromagnética foi investigada por Soleymani (2010), em veículos elétricos híbridos com base nos algoritmos de simulação desenvolvidos.

Na simulação de um sistema de suspensão, utilizam-se os modelos *full car* (apoio nas quatro rodas), *half car* (suspensão dianteira ou traseira) e de 1/4 de veículo (apenas um conjunto roda-amortecedor) (Mulla and Unaume, 2013). Empregamos aqui o modelo 1/4 (figura 1), reduzindo-o a um sistema massa-mola paralelo acoplado. Este apresenta dois graus de liberdade, os demais, acrescentam modos de vibração transmitidos pela rigidez da carroceria. O estudo do modelo 1/4 mostra o comportamento mais evidente da suspensão (em primeira ordem). Senthilkumar et al. (2018) desenvolveram um controlador *fuzzy* para o modelo *full car* acoplando quatro sistemas em paralelo e considerando a carroceria totalmente rígida. Changizi and Rouhani (2011) apresentaram um trabalho bastante similar ao realizado aqui, mas em geral, quando o controlador *fuzzy* diminuía o pico da oscilação, aumentava o tempo de acomodação. Al-Mutar e Abdalla (2015) realizaram uma sintonia nas funções de pertinência usando *Particle Swarm Optimization* reduzindo muito o pico de oscilação, mas os parâmetros físicos da suspensão estudada foram bem diferentes dos utilizados aqui. Em todas as simulações apresentadas por esses autores, o controle *fuzzy* ora melhorou o tempo de acomodação, ora reduziu o pico, *mas não em todos os casos*. Pode-se dizer em geral que o desempenho é próximo de um PID tradicional, as vezes um pouco melhor, as vezes pior.

Neste trabalho considerou-se o desenvolvimento de uma solução de malha fechada (Dorf and Bishop, 2009), devido à presença de sensores de deslocamento da posição relativa entre a carroceria e as rodas, que transmitem os dados ao controlador e que por sua vez atua no sistema mantendo essa posição nos limites definidos no projeto. Estudos com controladores difusos têm se ampliado, demonstrando sua viabilidade e equivalência com os controladores convencionais (Pontelli, 2012), (Crivellaro, 2008).

Com isto, o objetivo foi estudar e simular um sistema de controle ativo para suspensão automotiva usando lógica difusa (*fuzzy logic*), comparando-o com o controlador proporcional e derivativo (PD).

2. MODELAGEM DO SISTEMA

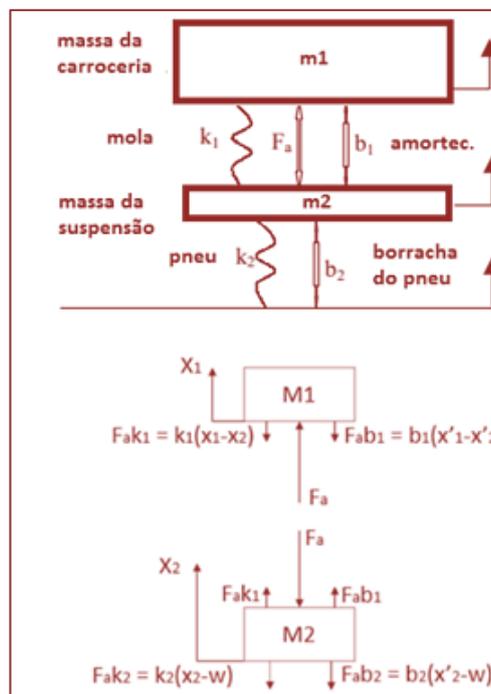
Ao analisar as oscilações do veículo, adotou-se os seguintes pontos de partida:

- O veículo está no movimento retilíneo a uma velocidade constante.
- As rodas estão sempre em contato com a estrada (contato em um ponto).
- A perturbação da estrada é a mesma na roda esquerda e direita e o carro é simétrico em relação ao eixo longitudinal.

No modelo da figura 1, o corpo 1 (m_1) e a parte da carroceria do veículo apoiada sobre uma roda e o corpo 2 (m_2) refere-se ao pneu e roda e sua respectiva suspensão. Este é um modelo de dois sistemas massa-mola em paralelo, acoplados em serie, o que justamente o difere dos modelos didáticos, que é um sistema simples massa-mola em serie (Ogata, 2010). Neste modelo, os elementos são:

- m_1 a massa da carroceria sobre a roda indicada, m_2 a massa do conjunto roda, pneu e suspensão, k_1 a mola e sua constante elástica,
- k_2 o pneu e sua constante elástica, b_1 a constante do amortecedor,
- b_2 a constante de amortecimento do pneu,
- F_a representa a força do atuador para restringir a distância $X_1 - X_2$ de oscilação entre a carroceria e a suspensão, e
- W o movimento dado pelas irregularidades da via.

Figura 1. Modelagem das forças do sistema na suspensão



Sensores enviam dados ao sistema de controle sobre as posições X_1 e X_2 . Quando o veículo está recebendo qualquer perturbação W da via, o corpo 1 não deve ter grandes oscilações, as quais devem se dissipar rapidamente. Dado que a distância $X_1 - W$ é muito difícil de medir e a deformação do pneu $X_2 - W$ é desprezada, usou-se a distância $X_1 - X_2$ em vez de $X_1 - W$ como resultado nesse modelo. O distúrbio da via W normalmente é simulado por um sinal de entrada tipo degrau. Esse sinal poderia representar o veículo que sai de um buraco com borda aguda. O objetivo é projetar um controlador para que a saída $X_1 - X_2$ tenha um sobressinal (*overshoot*) inferior a 5% e um tempo de acomodação (*settling time*) menor que 5 segundos. Quando o veículo sobe em um degrau de 10 cm de altura, o corpo oscilar dentro de uma faixa de 5 mm e retornar a um percurso suave em até 5 segundos.

A partir da figura 1 e utilizando a 2ª lei de Newton, obtêm-se as equações dinâmicas 1 e 2:

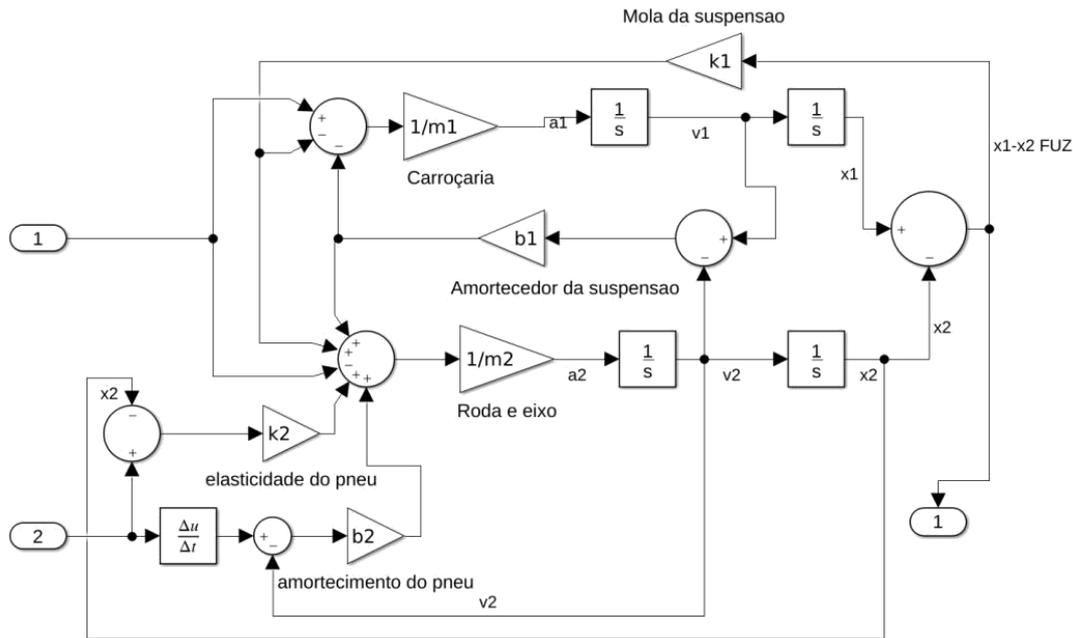


Figura 2. Modelagem da suspensão no Simulink

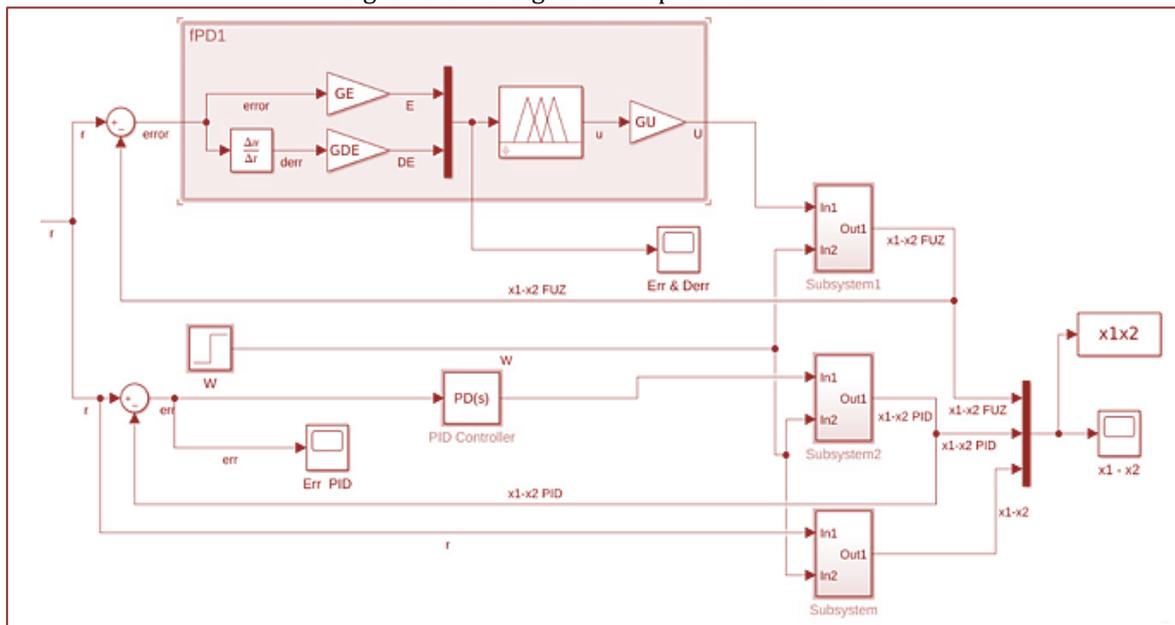


Figura 3. Modelagem dos sistemas de controle no Simulink. Os subsistemas são a suspensão da fig. 2

$$m_1 \ddot{x}_1 = -b_1(\dot{x}_1 - \dot{x}_2) - k_1(x_1 - x_2) + U \quad (1)$$

$$m_2 \ddot{x}_2 = b_1(\dot{x}_1 - \dot{x}_2) + k_1(x_1 - x_2) + b_2(\dot{W} - \dot{x}_2) + k_2(W - x_2) - U \quad (2)$$

Nestas equações, foi introduzida a ação U do controlador, atuando fisicamente entre m_1 e m_2 . A partir deste ponto, pode-se realizar uma abordagem que emprega as transformações de Laplace para se obter as funções de transferência. Neste trabalho, cujo objetivo é mostrar a fase de projeto e testes em simulador, optou-se modelar o sistema pelas equações dinâmicas 1 e 2.

2.1 DIAGRAMA DOS ELEMENTOS FÍSICOS

Este sistema foi modelado pela soma das forças atuando em ambas as massas (corpo e suspensão) e integrando as acelerações de cada massa para obter, na primeira integração as velocidades e, na segunda, as posições (Messner, Tilbury, 2016) - ver equações 3 e 4. O simulador empregado foi o Simulink, desenvolvido pela empresa MathWorks (MathWorks, 2014), que é um ambiente de programação gráfica para modelagem, simulação e análise de sistemas dinâmicos. Sua interface principal permite a diagramação de blocos gráficos, representando os diversos elementos básicos, contidos em uma biblioteca.

$$\iint \frac{d^2x_1}{dt^2} dt = \int \frac{dx_1}{dt} dt = x_1 \quad (3)$$

$$\iint \frac{d^2x_2}{dt^2} dt = \int \frac{dx_2}{dt} dt = x_2 \quad (4)$$

O modelo dinâmico desenvolvido está mostrado na figura 2, que contém os seguintes blocos principais:

- entradas 1 (do controlador) e 2 (da perturbação W do solo);
- saída 1 - sinal do sistema controlado;
- massas ($1/m_1$ e $1/m_2$) de cada modelo massa-mola;
- valores das constantes elásticas da mola da suspensão (k_1) e do pneu (k_2);
- constantes de amortecimento da suspensão (b_1) e do pneu (b_2);
- integrais $1/s$ no domínio de Laplace, convertendo acelerações a_i em velocidades v_i e estas em deslocamentos x_i ;
- derivada da posição x_2 para compor o termo $b_2.v_2$.

Os elementos da figura 2 recebem os sinais de perturbação do solo e de controle, que estão representados na figura 3 como subsistemas. Nesta figura, os blocos de interesse são os seguintes:

- fPD1 - controlador *fuzzy* desenvolvido neste trabalho;
- W - perturbação dada pelas irregularidades do solo;
- PD(s) - controlador PD utilizado para comparação;
- Subsystem 0, 1, 2 - modelo do sistema físico visto na figura 2.

3. MODELAGEM DOS CONTROLADORES

A modelagem de um controlador PID difuso é feita de modo a combinar os três sinais de controle proporcional, integrador e derivativo como em um PID convencional. Isto corresponde a gerar funções de pertinência em cada um dos três universos de discurso correspondentes. Na etapa seguinte, um conjunto de regras difusas de controle (*fuzzy reasoning*) devem ser projetadas de modo a reproduzir o comportamento de um controlador PID.

O modo de inferência *fuzzy* escolhido foi o de Mamdani. Para modelar e especificar sistemas *fuzzy*, pode-se por exemplo consultar Cox (1999). O número de regras geradas é igual ao produto cartesiano do número de funções de pertinência pelo número de grandezas (sinais) de controle. Se forem definidas cinco funções de pertinência por sinal de controle, são obtidas $5^3 = 125$ regras para serem associadas e combinadas em N funções de pertinência no sinal de saída do controlador. Como a concepção destas regras e a modelagem e sintonia das funções de pertinência dependem de especialista externo, optou-se por um modelo de controle PD, encorajado pelo fato de que a constante integrativa de controle resultou em valores bem baixos, em simulações preliminares deste sistema com PID convencional.

O controlador difuso PD (fPD) apresenta, então, dois sinais de entrada: proporcional ao erro (*err*) e proporcional a variação do erro - derivativo (*derr*), cujas regras difusas para o sistema de suspensão são vistas na tabela 1. A figura 4 (superior) mostra as funções de pertinência ajustadas para as grandezas *err* e

derr na entrada e, na inferior, as funções para a saída *u* do controlador. A escolha de sete funções de pertinência para cada parâmetro, quando poderiam ser menos delas, permite gerar transições mais suaves na superfície de controle, embora o esforço computacional seja maior. A construção das regras baseou-se nas premissas:

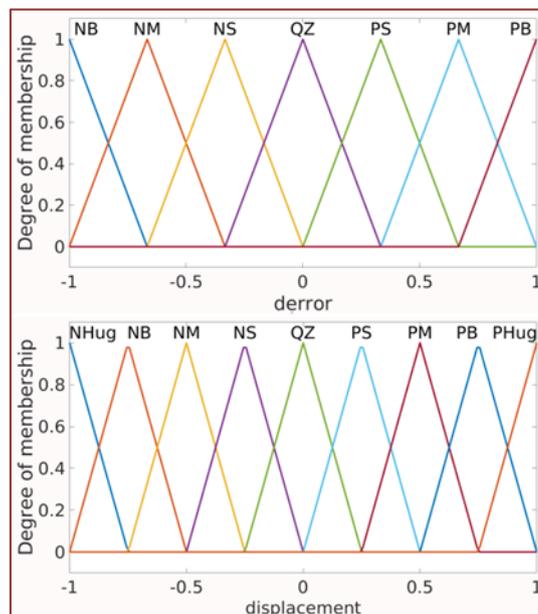
Tabela 1. Regras fuzzy do controlador PD

| | | derr | | | | | | |
|-----|----|------|----|----|----|----|----|----|
| err | | NB | NM | NS | QZ | PS | PM | PB |
| | NB | NH | NH | NH | NB | NM | NS | QZ |
| | NM | NH | NH | NB | NM | NS | QZ | PS |
| | NS | NH | NB | NM | NS | QZ | PS | PM |
| | QZ | NB | NM | NS | QZ | PS | PM | PB |
| | PS | NM | NS | QZ | PS | PM | PB | PH |
| | PM | NS | QZ | PS | PM | PB | PH | PH |
| | PB | QZ | PS | PM | PB | PH | PH | PH |

NB (negative big), NM (negative medium), NS (negative small), QZ (quasi-zero), PS (positive small), PS (positive medium), PS (positive big), NH (negative huge), PH (positive huge)

- Se o erro é negativo e a variação é positiva (ou vice-versa), então o sistema está retornando à posição de equilíbrio, logo a atuação deve ser mínima ou nula;
- Se o erro e sua variação forem positivas (negativas), a ação de controle deve ser proporcionalmente positiva (negativa).
- Demais regras tornam a superfície de controle suave.

Figura 4. Funções de pertinência de entrada e saída



Ajustes dos ganhos de entrada e saída

Dado que controladores difusos são não-lineares, Jantzen (1998) propôs um procedimento para ajustar os ganhos de controladores *fuzzy* a partir de controladores PID convencionais. O ajuste aqui utilizado baseou-se nesse procedimento, adaptado para controlador *fuzzy*-PD (fPD). Para que a sintonia ocorresse sistematicamente, todos os universos de discurso foram normalizados em [-1 1] na entrada e na saída, conforme figura 4. Deste modo, tanto as regras difusas (tabela 1) quanto as funções de pertinência geram

uma superfície de controle suave e simétrica. Deixando a sintonia do sistema apenas no ajuste dos ganhos, permite-se uma flexibilização tal que eles podem ser ajustados para cada sistema massa-mola amortecido em particular. A figura 3 destaca o controlador fPD e os blocos de ganhos GE (do erro), GDE (da variação do erro) e GU (do deslocamento do atuador).

O procedimento idealizado por Jantzen consiste basicamente em:

1 Calcular os parâmetros de sintonia de um controlador PID pelo método de Ziegler-Nichols de resposta em frequência (Dorf and Bishop, 2009) (Ogata, 2010).

2 Calcular os ganhos GE, GDE e GU do controlador fPD (tabela 2 na 3ª linha) conforme parâmetros obtidos no item anterior.

Desta maneira, os requisitos de controle de cada sistema amortecido em particular podem ser definidos pelo procedimento acima, mantendo-se a generalidade das regras *fuzzy* de controle e a normalização do universo de discurso das grandezas de entrada e saída.

4. RESULTADOS DAS SIMULAÇÕES

Para o tipo de veículo escolhido (ônibus), foram adotados os seguintes valores sugeridos por Messner and Tilbury (2016)

| | |
|---------------------------|-----------------------------|
| Carroceria e suspensão | roda e pneu |
| $m_1 = 2500 \text{ kg}$ | $m_2 = 320 \text{ kg}$ |
| $k_1 = 80000 \text{ N/m}$ | $k_2 = 500000 \text{ N/m}$ |
| $b_1 = 350 \text{ N.s/m}$ | $b_2 = 15000 \text{ N.s/m}$ |

4.1 ESTABILIDADE DINÂMICA DO SISTEMA

Com os parâmetros acima, verifica-se que o sistema é estável pelo critério de Routh-Hurwitz (Dorf and Bishop, 2009), (Ogata, 2010). Obtendo-se a função de transferência a partir do sistema de equações 1 e 2, os polos $33,3$ e 0 , e zeros $2,65 - 13j$ se encontram no semiplano esquerdo do diagrama *root locus*, demonstrando que o sistema é estável e subamortecido. Os cálculos foram realizados com o programa Matlab (Mathworks, 2015) pertencente a uma empresa na região do município. O gráfico do sistema da suspensão, sem ação de controle, é visto na figura 5. A carroceria do ônibus oscila por um tempo $> 20 \text{ s}$ com amplitude inicial de 8 cm . Não é uma oscilação confortável aos passageiros devido ao grande sobressinal e longo tempo de acomodação.

4.2 CONTROLE FUZZY-PD E CONVENCIONAL

Para encontrar os valores dos parâmetros proporcional k_P e derivativo k_D , pelo método de Ziegler Nichols, é necessário elevar k_P até que se encontre uma oscilação sustentada, o qual se torna o parâmetro crítico k_{CR} .

Obtém-se assim $k_P = 0,6 k_{CR}$, levando ao período crítico de oscilação PCR , de onde se obtém $TD = 0,125 PCR$. Estes valores estão relacionados a tabela 2, que foram os seguintes: $k_P = 832100$, $k_D = 208000$ e $TD = 0,25 \text{ s}$. O universo de discurso do erro está no intervalo $[-1 \ 1]$, por isso $GE = 1,0$, resultando nos ganhos do controlador fPD:

| | | |
|------------|---|--------------------------|
| GDE = 0,25 | e | GU = $k_P = GE = 832100$ |
|------------|---|--------------------------|

Tabela 2. Relações entre ganhos dos controladores convencional e fuzzy

| Controlador | K_P | $1/T_I$ | T_D |
|-------------|---------|---------|--------|
| fP | GE GU | | |
| fINC | GDE GDU | GE=GDE | |
| fPD | GE GU | | GDE=GE |
| fPD+I | GE GU | GIE=GE | GDE=GE |

Para a mesma perturbação de 10 cm para o caso não-controlado, o sistema apresentou uma oscilação inicial de 1 cm, rapidamente anulada (< 1 s), mas houve um *offset* residual de quase -1 cm. A solução proposta por Jantzen para eliminar isso foi somar à GU (saída de controle) um ganho proporcional ao termo integrador, denominado de controle fPD+I (tabela 2). No entanto, sem lançar mão desta solução, com a diminuição de GU para cerca de 500000, o *offset* reduziu para cerca de 3 mm, aceitável em um projeto deste porte (figura 6). Observa-se que o sistema estabilizou em cerca de 2 s com um pico inicial de -55 mm em resposta a um degrau de -10 cm.

A figura 7 mostra o mesmo sistema com controlador PD convencional ajustado. Aqui também o sistema se acomoda em menos de 2 s e o pico inicial < -10 mm representa uma resposta melhor em termos de absorção do impacto inicial, porem ocorrem mais oscilações, introduzindo uma breve, mas indesejável vibração no sistema.

Figura 5. Resposta ao degrau de 10 cm

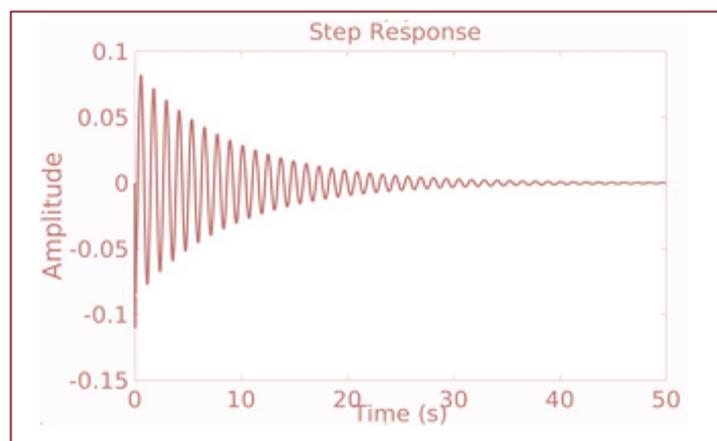
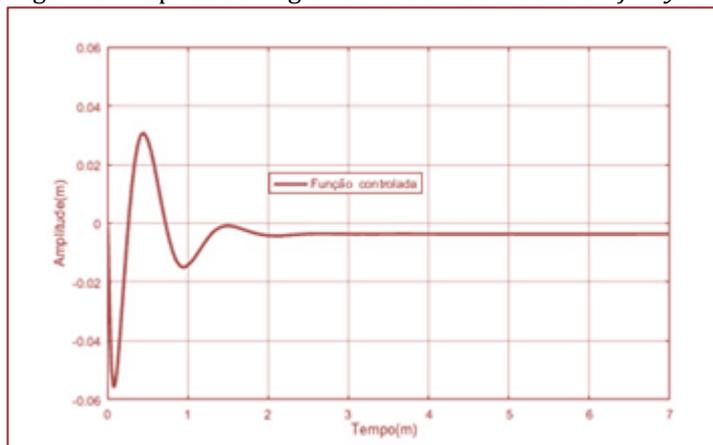


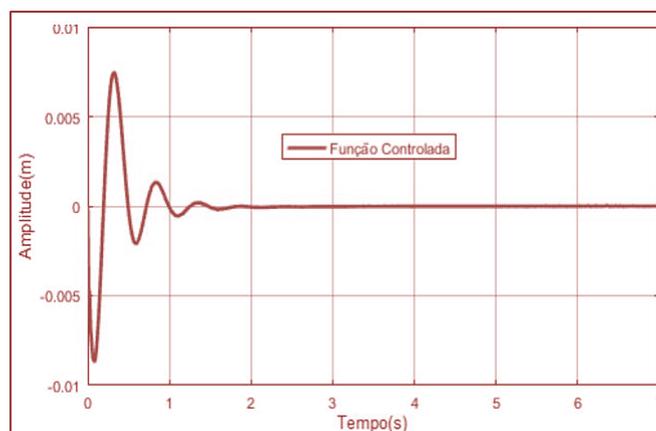
Figura 6. Resposta ao degrau de -10 cm com controle *fuzzy*-PD

5. DISCUSSÃO E CONCLUSÕES

Tanto o controlador PD tradicional quanto o *fuzzy*-PD forneceram condições suficientes para o controle da suspensão ativa automotiva apresentada neste trabalho. Fica claro que ainda é necessário melhorar o ajuste fino de ambos controladores, pois como foi visto, no sistema de suspensão ativa, seria necessário fazer um ajuste fino na saída do controlador FuzzyPD para melhorar o nível de referência. Ao contrário deste, no controlador PD tradicional o *setpoint* ficou dentro do especificado.

Embora um controlador puramente derivativo não seja implementável na prática, a ação derivativa, associada à ação proporcional, corresponde ao acréscimo de um zero ao sistema, atuando benéficamente no regime transitório, tendendo a aumentar a estabilidade relativa do sistema e reduzindo o tempo de acomodação. Contudo, ele aumenta o tempo de subida, e por não atuar no regime permanente, não corrige o erro de estado estacionário. Neste trabalho, esse problema foi minimizado com a introdução de um valor *offset* na saída do controlador.

Figura 7. Resposta ao degrau de -10 cm com controle PD convencional



A maior dificuldade encontrada para sintonizar esses dois controladores foi ajustar seus parâmetros, porque, além de envolver técnicas, experiência e conhecimento total do sistema a ser controlado, foram necessárias muitas simulações para atingir valores de sobressinal e acomodação razoáveis. O motivo disso é que o segundo método de Ziegler-Nichols não pode ser diretamente aplicado aos parâmetros do controlador Fuzzy, mas a solução proposta por Jantzen. A diretriz de projeto deste controlado fPD foi manter a normalização dos universos de discursos e a uniformidade na distribuição das funções de pertinência ao longo deles. Refinamentos na sintonia requerem alterações nesta distribuição e calibração nos limites dos universos de discurso, introduzindo muitos graus de liberdade (parâmetros ajustáveis) para a sintonia do controlador.

Trabalhos futuros

Por quê não foi utilizado um controlador PID? A adição do termo integrativo no controlador reduz o erro acumulado em vários ciclos. O equivalente *fuzzy* de um controlador PID implica em adicionar mais uma entrada no bloco fPD1 da figura 3 e, portanto, a inclusão de um universo de discurso com algumas funções de pertinência. Se for mantida a resolução de sete funções de pertinência, haveria 7^3 regras de inferência, cujo ajuste requer uma metodologia alternativa a de Jantzen, gerando uma superfície de controle mais complicada. Esta é uma abordagem a ser investigada em um trabalho posterior.

O ajuste alcançado com fPD foi bastante satisfatório ao reduzir uma oscilação em relação ao controlador PD.

REFERÊNCIAS

- [1] Al-Mutar, W.H. and Abdalla, T.Y. (2015). Quarter car active suspension system control using fuzzy controller tuned by PSO. *International Journal of Computer Applications*, 127(2), 38-43.
- [2] Changizi, N. and Rouhani, M. (2011). Comparing PID and fuzzy logic control a quarter car suspension system. *The Journal of Mathematics and Computer Science*, 2(3), 559-564.
- [3] Corrigan, G., Sanna, S., and Usai, G. (1991). An optimal tandem active-passive suspension system for road vehicles with minimum power consumption. *IEEE Transactions on industrial electronics*, 38(3).
- [4] Cox, E. (1999). *The fuzzy systems handbook: a practitioner's guide to building, using, and maintaining fuzzy systems*. AP Professional, 2 edition. URL <https://books.google.com.br/books?id=2udQAAAAMAAJ>.
- [5] Crivellaro, C. (2008). *Controle robusto de suspensão semi-ativa para caminhonetes utilizando amortecedores magneto-reológicos*. Dissertação de mestrado, Escola Politécnica da Universidade de São Paulo, São Paulo.
- [6] Daimler (2016). Active Body Control - ABC. <http://techcenter.mercedes-benz.com/en/abc/detail.html>. Access jun 15 2016.
- [7] Dorf, R.C. and Bishop, R.H. (2009). *Sistemas de controle modernos*. LTC, Rio de Janeiro.
- [8] Halliday, Resnick, and Walker (2002). *Física, volume 1*. LTC, Rio de Janeiro.
- [9] Jantzen, J. (1998). Tuning of fuzzy PID controllers. tech-report 98-H 871, Technical University of Denmark.
- [10] Mathworks (2015). Matlab. URL. <https://www.mathworks.com/products/matlab.html>.
- [11] Messner, B. and Tilbury, D. (2016). Control tutorials for Matlab & Simulink. Techreport, Michigan University, <http://ctms.engin.umich.edu/CTMS/index.php?example=Suspe>
- [12] Mulla, A.A. and Unaume, D.R. (2013). Active suspensions future trend of automotive suspensions. In *International Conference on Emerging Trends in Technology & its Applications, ICETTA 2013*.
- [13] Ogata, K. (2010). *Engenharia de controle moderno*. Pearson, 5 edition.
- [14] Pontelli, C.O. (2012). *Estratégias de controle para isolamento ativa de vibrações em barras de pulverizadores agrícolas*. Dissertação de mestrado, Universidade de São Paulo, Escola de Engenharia de São Carlos, São Carlos.
- [15] Popovic, V., Jankovic, D., and Vasic, B. (2000). Design and simulation of active suspension system by using Matlab. In *Seoul 2000 FISITA World Automotive Congress*, 1-8.
- [16] Senthilkumar, P., Sivakumar, K., Kanagarajan, R., and Kuberan, S. (2018). Fuzzy control of active suspension system using full car model. *Mechanika*, 24(2), 240-247.
- [17] Soleymani, M.M. (2010). Investigation of the energy regeneration of active suspension system in hybrid electric vehicles. *IEEE TRANSACTIONS ON INDUSTRIAL ELECTRONICS*, 57(3), 918-925.
- [18] Strassberger, M. and Guldner, J. (2004). BMW's dynamic drive: an active stabilizer bar system. *IEEE Control Syst. Mag*, 28-29.

Capítulo 9

Detecção de ilhamentos não intencionais em redes de distribuição com geração distribuída utilizando Redes Neurais Artificiais

Bruno Martins de Biaz

Thales Terrola e Lopes

Márcio Zamboti Fortes

Vitor Hugo Ferreira

Flávio Luis de Mello

Resumo: O objetivo deste trabalho é desenvolver uma metodologia baseada na aplicação da Rede Neural Artificial (RNA) para a detecção de ilhamentos não intencionais em redes de distribuição com a presença de geradores distribuídos. Demonstra-se que a metodologia proposta pode obter um desempenho superior ao método passivo convencional para detecção de ilhamentos, superando o problema das zonas de não detecção destes relés. As técnicas tradicionalmente empregadas para a detecção de ilhamentos são discutidas, abordando as vantagens e desvantagens das mesmas. Diferentes estados operacionais são levantados em um sistema de distribuição com presença de geração distribuída, tanto solar fotovoltaica quanto eólica, representando situações de ilhamento e não ilhamento da geração distribuída. Os dados obtidos com estas simulações são utilizados para treinar uma Rede Neural Artificial, capaz de identificar o estado operacional do sistema e assim evitar a operaçãoilhada do gerador distribuído.

Palavras-chaves: Geração Distribuída; Ilhamento Não Intencional; Zonas de Não Detecção; Redes Neurais Artificiais.

1. INTRODUÇÃO

A instalação de unidades geradoras de energia elétrica de pequeno ou médio porte em residências, condomínios, edifícios residenciais, comerciais ou pequenas indústrias já é uma realidade em muitos países da Europa, Ásia e América do Norte e tem se intensificado no Brasil nos últimos anos, após a promulgação da Resolução Normativa ANEEL nº482, no ano de 2012 (ANEEL - Agência Nacional de Energia Elétrica, 2012), que estabeleceu as diretrizes básicas para a conexão de micro e mini unidades geradoras distribuídas. Dentre as principais vantagens da inserção dos geradores distribuídos podemos citar o adiamento dos investimentos em expansão dos sistemas de transmissão e distribuição, o baixo impacto ambiental, a redução no carregamento das redes, diversificação da matriz energética, redução das perdas e a melhoria do perfil de tensão.

Em contrapartida, a interconexão da geração distribuída (GD) com os circuitos de distribuição de eletricidade agrega novos desafios ao projeto e a operação dos sistemas elétricos das concessionárias de energia elétrica. Tanto a concessionária, quanto o proprietário da GD, devem assegurar que a instalação seja projetada e construída para propiciar uma operação segura e confiável, sem prejudicar a operação do sistema de distribuição, o nível de qualidade de energia dos demais consumidores e a segurança das equipes técnicas que operam e mantêm o sistema elétrico.

A norma IEEE 1547/2003 (IEEE, 2003) fornece um conjunto de critérios e requisitos para a interconexão da GD ao sistema elétrico. Dentre eles, um dos requisitos que merece destaque, determina que caso ocorra à perda do suprimento elétrico da concessionária em um sistema de distribuição com a presença de GDs, estas devem ser automaticamente desconectados do sistema, permanecerem off-line até que o suprimento de energia da concessionária seja restabelecido. Este procedimento, nomeado como Ilhamento Não Intencional, visa impedir a formação de ilhas energizadas pelos geradores distribuídos, isoladas do restante do sistema de energia elétrica. Em uma região do sistema elétrico que sofreu um evento de ilhamento não intencional, a qualidade da energia fornecida para os consumidores da zona ilhada pode ficar comprometida, acarretando problemas para a concessionária que é a responsável legal pela mesma. Além disso, a configuração ilhada pode oferecer riscos às equipes de manutenção e aos consumidores em geral, pois certas áreas continuariam energizadas sem o prévio conhecimento da concessionária (González et al., 2010).

Dada à complexidade dos estados operativos dos sistemas de distribuição, e também devido às limitações das técnicas tradicionalmente aplicadas para a detecção das zonas com ilhamento não intencional, muitos esforços têm sido direcionados às pesquisas aplicando técnicas de machine learning. As Redes Neurais Artificiais (RNAs), Máquinas de Vetor Suporte e Árvores de Decisão são as técnicas que mais se destacam devido a singular capacidade de reconhecimento de padrões (Guan, 2015).

Neste contexto, este trabalho apresenta uma proposta singular para a detecção de ilhamentos não intencionais em redes elétricas dotadas de GD, se valendo da técnica de aprendizagem supervisionada utilizando as Redes Neurais Artificiais. Os dados utilizados na etapa de aprendizagem da RNA são obtidos através da realização de um conjunto de simulações que procuram descrever os diferentes cenários operativos de um sistema de distribuição real e que resultam em situações de ilhamento ou não ilhamento. Os diferentes cenários operativos contemplam situações normais de operação, faltas no sistema, abertura de disjuntores e chaveamento de cargas, obtidos no ponto de interconexão da GD ao sistema de distribuição. Os valores dos estados operativos no ponto de conexão da GD são as variáveis de entrada do sistema de aprendizagem supervisionada, enquanto a condição de ilhamento ou não ilhamento é a variável de saída. Demonstra-se que após a etapa de treinamento, a RNA irá apresentar um desempenho elevado na detecção de ilhamentos, auxiliando a mitigar as zonas de não detecção dos relés passivos tradicionais.

2. ILHAMENTO NÃO INTENCIONAL DE GD

Buscando padronizar o acesso dos clientes interessados em se tornar micro e mini geradores distribuídos, as concessionárias de energia elétrica emitiram normas de especificação técnica estipulando uma série de critérios referentes às conexões para consumidores que adotassem a GD. Dentre os critérios adotados, especificou-se que em caso da ocorrência de ilhamento do gerador distribuído por alguma eventual falha no sistema de distribuição, o mesmo deve se desconectar em até dois segundos, conforme pode ser verificado, por exemplo, em (Enel Distribuição Rio, 2016).

A Figura 1 ilustra um exemplo de ilhamento não intencional. Devido a um problema no sistema de distribuição, o sistema foi aberto em C. Caso a proteção da interconexão do gerador GD1 em E não atue, será formada uma zona ilhada.

3. TÉCNICAS APLICADAS PARA A DETECÇÃO DE ILHAMENTOS NA PRESENÇA DE GD

Diversas técnicas são aplicadas para a detecção de ilhamentos em geração distribuída, como ilustra a Figura 2, sendo classificadas em dois grandes grupos, segundo os seus princípios operativos: locais e remotas. Dentro de cada grupo existem variadas técnicas de detecção, sendo a adoção determinada pela viabilidade técnica e econômica, além da análise do tipo de instalação e configuração do sistema de distribuição (González et al., 2010).

Fig. 1 Zona de Ilhamento Não Intencional com GD1.

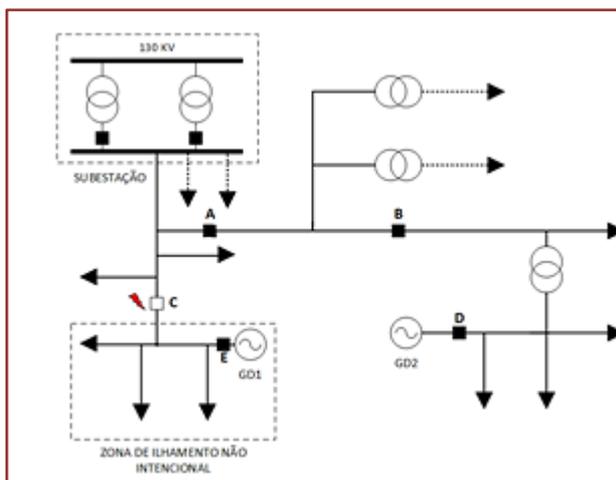
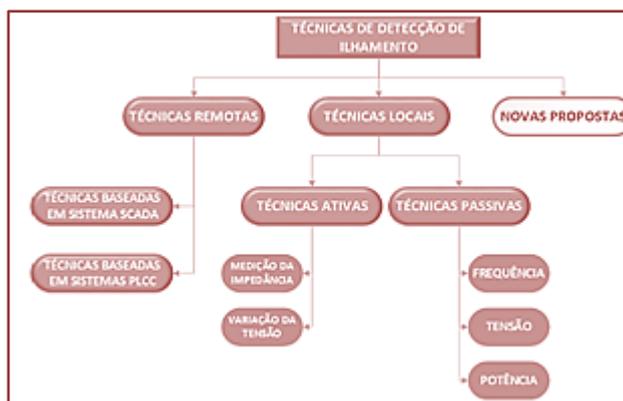


Fig. 2 Técnicas aplicadas para a detecção de ilhamentos em redes elétricas com Geração Distribuída.



As técnicas remotas envolvem algum tipo de comunicação entre a concessionária, os dispositivos de proteção presentes na rede elétrica e os geradores distribuídos. As principais técnicas remotas são baseadas em sistemas SCADA (Supervisory Control and Data Acquisition) e PLCC (Power Line Carrier Communication). Ambas as técnicas são eficientes para a detecção de ilhamentos, porém envolvem altos custos de instalação e intervenção no sistema de distribuição. Em virtude disto, as técnicas locais ganharam mais espaço no mercado, pois exigem apenas a instalação de equipamentos de detecção na localidade do GD, ficando a maior parte dos custos a cargo do consumidor.

As técnicas locais se subdividem em ativas e passivas. As técnicas ativas requerem que um equipamento alocado no GD injete sinais na rede, provocando pequenas alterações no comportamento do sinal elétrico.

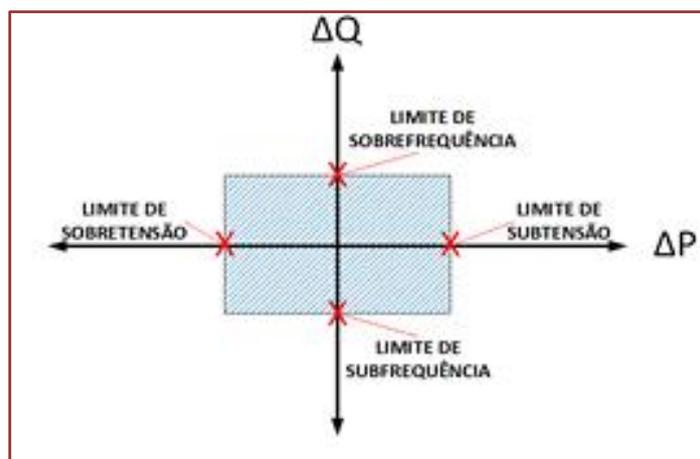
Estas alterações são constantemente monitoradas, e caso haja um ilhamento, o padrão de comportamento do sinal irá se alterar. Esta alteração é devidamente interpretada, e o gerador distribuído é desconectado da rede de distribuição. Caso o gerador distribuído seja o único em um trecho da rede de distribuição, este método apresenta eficácia, porém caso mais GDs sejam alocados no mesmo trecho, ocorrerá interferência entre os sinais injetados, prejudicando a correta identificação do status do sistema (González et al., 2010).

As técnicas passivas geralmente são baseadas na análise das medidas de frequência e tensão, obtidas no ponto de interconexão entre o gerador distribuído e o sistema elétrico. Caso haja um ilhamento, estas medidas irão sofrer alterações significativas em um curto espaço de tempo. Ao contrário das técnicas ativas, não injetam qualquer tipo de sinal na rede elétrica. Porém, as técnicas passivas não são totalmente eficazes para detectar as condições de ilhamento em todos os estados operativos do gerador e do sistema elétrico, devido às zonas de não detecção características dos relés de frequência\tensão, que podem assumir diferentes valores em função dos ajustes propostos por parte das concessionárias de distribuição. Ou seja, quanto mais sensível for o ajuste dos relés para mitigar as zonas de não detecção, maior será o número de acionamentos indevidos da proteção e vice-versa (González et al., 2010).

Na conjectura atual das redes de distribuição em operação no Brasil, os esquemas de proteção contra ilhamento que empregam relés baseados em medidas de frequência são os mais difundidos dentre as técnicas passivas. Nesta modalidade, se existe um grande desbalanço de potência entre a geração e a carga do subsistema ilhado, após o ilhamento ocorre uma variação significativa do valor da frequência elétrica no subsistema, o que possibilita a detecção da ocorrência do ilhamento pelo relé de frequência. Este modelo é atrativo devido ao seu baixo custo, porém o seu desempenho pode ser prejudicado caso a diferença de valores entre a geração e a carga não seja significativa, gerando zonas de não detecção. Os ajustes do relé devem ser criteriosamente realizados para minimizar a ocorrência de atuação indevida em situações de chaveamentos ou curtos-circuitos. Outro relé muito utilizado na proteção anti-ilhamento é o relé de taxa de variação de frequência (df/dt), pois acelera a detecção do ilhamento em situações onde a frequência varia lentamente (Gama et al., 2013).

Conforme apresentado em (Woyte et al., 2003) e (Ye et al., 2004), as zonas de não detecção são obtidas por meio de simulação dinâmica da rede elétrica e permitem mapear vários pontos de operação do sistema elétrico, representados no plano desbalanço de potência reativa versus desbalanço de potência ativa, para os quais os relés de frequência\tensão são ineficazes em detectar o ilhamento. A Figura 3 exemplifica esta metodologia.

Fig. 3 Zona de não detecção de relés baseados em medidas de frequência e tensão.



3.1 TÉCNICAS INOVADORAS

Nos últimos anos, muitos esforços têm sido direcionados à pesquisa e desenvolvimento de técnicas de machine learning aplicadas ao estudo dos estados operativos do sistema elétrico. Em (ElNozahy et al.,

2011) é apresentada uma técnica para a detecção de ilhamento de geradores distribuídos (GD) aplicando às Redes Neurais Artificiais, em combinação a transformada wavelet discreta. A abordagem proposta detecta o ilhamento usando os sinais transitórios das correntes nas três fases, vistas nos terminais da GD, utilizando a transformada de wavelet discreta para extrair o vetor de características, empregado para treinar uma rede neural artificial para detectar os ilhamentos.

Outra aplicação das Redes Neurais Artificiais na identificação de ilhamentos é descrita em (Moeini et al., 2011), contudo aplicada para o caso de geradores distribuídos síncronos. O método é baseado na rede neural do tipo Self-Organizing Map (SOM), usando o sinal de entrada do controlador automático de frequência como variável de entrada para treinar a rede neural e assim distinguir as várias ocorrências em categorias de ilhas e não ilhas. A referência (Abd-Elkader et al., 2014), por sua vez, propõe uma metodologia aplicável para turbinas eólicas conectadas a geradores de indução duplamente alimentados (DFIG), cujas componentes simétricas obtidas a partir do segundo harmônico dos sinais de tensão e corrente medidos na rede elétrica são empregados para alimentar uma rede neural artificial para a detecção de possíveis ilhamentos. Uma revisão abrangente e uma análise comparativa entre as técnicas tradicionais e as técnicas inteligentes aplicadas para a identificação de ilhamentos é apresentada em (Laghari et al., 2014). Neste trabalho, os autores comentam que as técnicas que consideram a aplicação de Sistemas de Inferência Neuro Fuzzy e Controle Fuzzy com árvore de decisão, alcançaram os melhores desempenhos na identificação de ilhamentos.

4. MODELAGEM DA REDE NEURAL ARTIFICIAL PARA A IDENTIFICAÇÃO DE ILHAMENTOS NÃO INTENCIONAIS

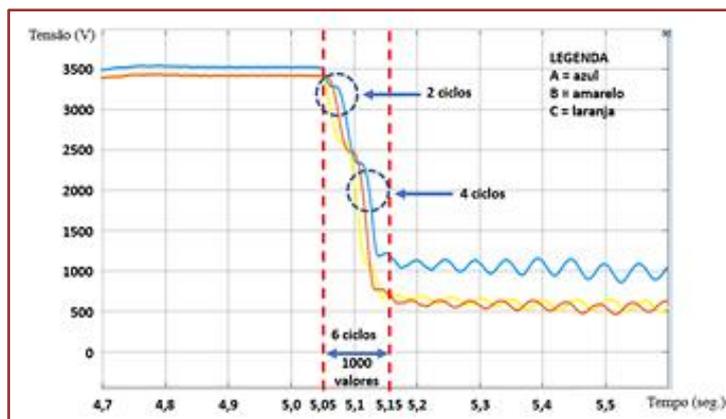
A base de dados empregada para o treinamento da RNA foi obtida através do armazenamento de uma série de variáveis que representam diferentes estados operativos da rede elétrica no ponto de interconexão dos geradores distribuídos, considerando diferentes cenários de inserção de GD na rede elétrica. Estas variáveis foram obtidas através de simulações no domínio do tempo no sistema de distribuição IEEE 13 barras, descrito no próximo tópico. As variáveis monitoradas são dadas na Tabela 1.

Tabela 1. Variáveis monitoradas.

| Nome | Variável | Unidade |
|--------------------------|-----------------------------------|---------|
| X1 = F_GD | Frequência no GD | Hz |
| X2 = $\Delta F/\Delta t$ | Taxa de variação da frequência | Hz/s |
| X3 = Vrms | Tensão eficaz na barra de conexão | V |
| X4 = $\Delta V/\Delta t$ | Taxa de variação da tensão | V/s |
| X5 = I | Corrente no barramento de conexão | A |
| X6 = P_Inst | Potência ativa instantânea na GD | W |
| X7 = $\Delta P/\Delta t$ | Taxa de variação da potência | W/s |
| X8 = Q_GD | Potência reativa instantânea | Var |
| X9 = $\Delta Q/\Delta t$ | Taxa de variação da pot. reativa | Var/s |
| X10=VTHD | Distorção harmônica na tensão | V |
| X11=ITHD | Distorção harmônica na corrente | A |

Para cada estado operativo simulado em cada cenário, coleta-se uma faixa de 1000 valores posteriores ao início do ilhamento não intencional ou do distúrbio realizado no sistema, como faltas ou chaveamento de cargas. Para a coleta destes valores aplicou-se um tempo de amostragem de 0,1 segundos ou 6 ciclos de onda. Por exemplo, caso um ilhamento se inicie no instante $t = 5,05$ seg., conforme pode ser observado na Figura 4, coletam-se os dados das onze variáveis monitoradas do sistema no período entre $t=5,05$ e $t=5,15$ seg., abrangendo os regimes subtransitório e transitório da onda senoidal da variável monitorada.

Fig. 4 Faixa amostral de dados para os valores da tensão na GD, entre 5,05 e 5,15 seg.



Pelo fato das variáveis tensão, corrente, taxa de variação de tensão e taxa de distorção harmônica na tensão e na corrente serem trifásicas, resultam em 21 entradas para a RNA.

Para o desenvolvimento da RNA foram avaliadas duas metodologias de treinamento: Backpropagation (BP) e Bayesian Regularization (BR), sendo aplicado o critério de parada Early Stopping (ES) na etapa de treinamento.

Segundo o Teorema da Aproximação Universal (Cybenko, 1989), uma rede neural do tipo perceptron de múltiplas camadas com uma única camada oculta com número suficiente de neurônios tem capacidade para aproximar com precisão arbitrária qualquer função contínua. Portanto, nesse trabalho será utilizada uma RNA com uma camada oculta apenas. A função de ativação tangente hiperbólica foi adotada para os neurônios da camada oculta, restringindo a amplitude de saída entre $[-1,1]$. Os dados de entrada, com valores distintos, também foram normalizados para o intervalo $[-1, 1]$.

A fim de se obter o melhor resultado na avaliação da RNA, diversos níveis de estrutura foram testados, alterando-se o número de neurônios na camada oculta, de 1 a 100. A situação com o número de neurônios que resultou no menor gradiente ao final da etapa de treinamento teve os seus dados armazenados para a composição da RNA.

A estrutura final da RNA possui uma camada de entrada composta por 21 neurônios, uma camada oculta e uma camada de saída com um neurônio. Caso a RNA interprete um estado como ilhamento, a saída será 0, caso interprete como não ilhamento, a saída será 1. Para ambas as metodologias de treinamento, Backpropagation (BP) e Bayesian Regularization (BR), a estrutura com os melhores resultados é composta de 15 neurônios na camada oculta.

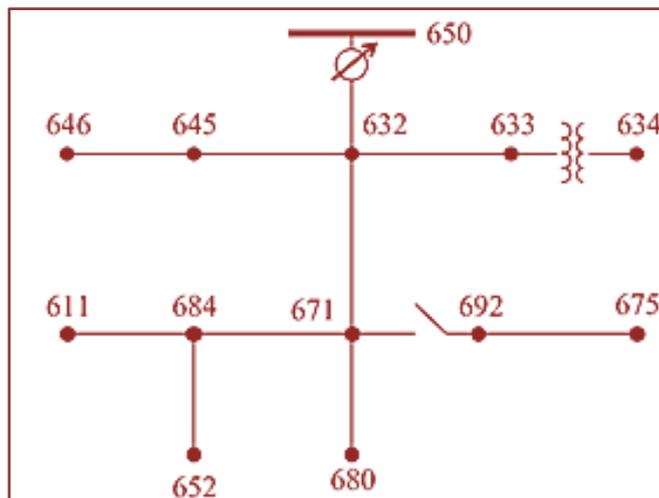
A base de dados obtida através das simulações da rede elétrica, considerando as variáveis monitoradas, foi dividida da seguinte maneira: 75% para treinamento e validação, e 25% para testes. A base de treinamento e validação foi subdividida em 75% para treinamento e 25% para validação.

5. DESCRIÇÃO DO SISTEMA ELÉTRICO E DAS PREMISSAS ADOTADAS PARA A RNA

O desempenho da RNA foi averiguado através do sistema teste de distribuição radial IEEE 13 barras, proposto em (Kersting, 1991) e ilustrado na Figura 5. O sistema IEEE 13 barras foi modelado no MATLAB\Simulink. Neste sistema foi realizada a inserção de distintas fontes de geração distribuída, que podem resultar em diferentes cenários operacionais, que caracterizam ilhamentos não intencionais e não ilhamentos. Foram utilizados geradores eólicos e fotovoltaicos, em quatro cenários distintos de penetração, com diferentes capacidades de geração e barramentos de conexão.

O sistema IEEE 13 barras da Figura 5 é composto de um transformador abaixador de 115 kV para 4,16 kV, com 5 MVA, estando conectado na saída do mesmo regulador de tensão. Entre os barramentos 633 e 634 há um transformador de 500 kVA, que reduz a tensão para 480 V no seu secundário, criando uma rede de baixa tensão. Foram inseridos seccionadores trifásicos e geradores de falta em diversos pontos do sistema, a fim de simular o maior número de cenários operativos possíveis. Apesar do sistema IEEE 13 barras ser de pequeno porte, ele apresenta características muito interessantes para o estudo, pois permite diferentes configurações de carregamento e conexão de geradores distribuídos em média e baixa tensão.

Fig. 5 Sistema de distribuição IEEE 13 barras avaliado.



Os modelos dos geradores distribuídos fotovoltaico e eólico encontram-se na biblioteca *PowerSys* do MATLAB\Simulink. É modelada uma usina eólica de 9 MW, que consiste de 6 geradores eólicos de indução duplamente alimentados com 1,5 MW, conectados à rede de distribuição através de um transformador que eleva a tensão de 575 V para 4,16 kV. O gerador fotovoltaico possui potência máxima de 100 kWp, para 1000 W/m² de irradiação solar, conectado ao sistema de distribuição através de um transformador de 260/480V. Este sistema utiliza 330 módulos fotovoltaicos SunPower, modelo SPR-305E-WHT-D, com potência individual de 305 Wp.

Para fins de comparação dos resultados obtidos pela RNA na detecção dos ilhamentos não intencionais, com as técnicas passivas tradicionais, foram modelados relés de frequência e tensão, conforme as Normas de Conexão de Acessantes da Enel (Enel Distribuição Rio, 2016), atendendo aos pontos de ajuste e atuação estipulados pela concessionária.

Foram simulados 4 cenários distintos de inserção de geração distribuída e em cada cenário são levantados 20 estados operativos diferentes, totalizando 80 situações de operação da geração distribuída, considerando as fontes eólica e fotovoltaica, conectadas em média e baixa tensão. Dos 80 padrões levantados, 40 representam situações de ilhamento e 40 de não ilhamento. Em cada um dos 80 padrões levantados, foram armazenadas as 21 variáveis de estado definidas no tópico 4, considerando a taxa de amostragem do sinal senoidal de 6 ciclos de onda. Obteve-se ao final, uma base de dados com 120.000 variáveis. Os cenários avaliados foram:

- Cenário 1: foi utilizada apenas a geração solar fotovoltaica em baixa tensão em B634;
- Cenário 2: foi utilizada apenas a geração solar fotovoltaica em média tensão em B675;
- Cenário 3: foi utilizada a geração solar fotovoltaica em baixa tensão em B634 e a geração eólica em média tensão em B650;
- Cenário 4: foi utilizada a geração solar fotovoltaica em baixa e média tensão em B634 e B675, e também a geração eólica em média tensão em B650.

Os 80 estados operativos executados para a composição da base de dados da RNA se mostraram eficazes na produção de múltiplas situações operacionais ocasionadas pela geração distribuída, em situações de ilhamento, não ilhamento, faltas, desconexões de barras, chaveamento de cargas e alterações de potência no sistema. Em determinados estados operativos, modelaram-se as zonas de não detecção dos relés passivos tradicionais, caracterizadas pelo equilíbrio entre a geração e a carga na região ilhada.

Ao final da simulação dos 80 estados operativos, obteve-se uma base de dados com 120.000 variáveis, cada uma associada a uma situação de ilhamento ou não ilhamento. Para os cenários 1 e 2 havia apenas um gerador distribuído monitorado, resultando em 20.000 variáveis para cada cenário. Nos cenários 3 e 4 haviam duas GDs monitoradas, resultando em 40.000 variáveis para cada cenário.

6. AVALIAÇÃO DOS RESULTADOS

Após a definição da estrutura final, avaliou-se o desempenho das RNAs treinadas e o desempenho dos relés tradicionais de tensão e frequência simulados, para cada dado de testes alocado. Foram utilizados 29.250 dados para testes, ou seja, 25% da base total de dados.

A taxa de assertividade na identificação dos estados operativos considerando o total de pontos identificados corretamente pelo relé tradicional, baseado em medidas de tensão e frequência, comparado às RNAs modeladas, pode ser verificada na Tabela 2.

Tabela 2. Taxa de assertividade dos métodos de identificação de ilhamentos não intencionais

| | % ACERTO BP | % ACERTO BR | % ACERTO RELÉ |
|-----------|-------------|-------------|---------------|
| Nº Pontos | 28.668 | 29.163 | 22.628 |
| (%) | 98,01% | 99,71% | 77,36% |

Verifica-se o pior desempenho nos relés passivos de frequência e tensão, com falhas na atuação em 21 dos 80 estados avaliados. A RNA Bayesian Regularization apresentou erros em 10 dos 80 estados. Dos 40 estados de não ilhamento avaliados, os relés passivos tradicionais acionaram indevidamente em 17 estados, com uma taxa de assertividade de 57,5%. A RNA acionou indevidamente em 8 estados, representando uma taxa de assertividade de 80%.

A Tabela 3 apresenta uma pequena amostra comparativa do resultado de cada metodologia na detecção do ilhamento não intencional. Os doze dados de teste da Tabela 3 foram escolhidos considerando estados operativos que resultaram em situações de erros e acertos pelas RNAs e relés de frequência. Uma descrição do estado operacional associado ao dado é feita na segunda coluna desta tabela. Os resultados de cada metodologia foram comparados com as saídas esperadas.

Tabela 3. Resultado da detecção do ilhamento para o sistema IEEE13 barras

| Dado | Descrição | Saida esperada | Bp | Br | Relé |
|------|---|----------------|----|----|------|
| 9 | Desconexão b632 | 0 | 1 | 1 | 0 |
| 80 | Gd 2 - cenário 4 - desconexão em b632-671 - cargas abertas em b675 | 0 | 0 | 0 | 0 |
| 55 | Gd 1 - cenário 3 - rede off - b632-671 e b645 off 20fv | 0 | 0 | 0 | 0 |
| 74 | Gd 1 - cenário 4 - rede off e saída b632-671 | 0 | 0 | 0 | 0 |
| 45 | Gd 1 - cenário 3 - desconexão entre b632 e b671 e das cargas b690 e b634 | 1 | 1 | 1 | 1 |
| 14 | Rede off, b650 e b671 off | 0 | 0 | 0 | 0 |
| 77 | Gd 2 - cenário 4 - desconexão da geração eólica b690 - 611, 652 e 645 off | 1 | 1 | 1 | 1 |
| 67 | Gd 2 - cenário 4 - abertura cargas em 692,675 e 634 | 1 | 1 | 1 | 0 |
| 59 | Gd 1 - cenário 3 - rede off - b645 e 632-671 off 2x eolica e 20gd | 0 | 0 | 0 | 0 |
| 54 | Gd 1 - cenário 3 - rede off-b632-671off | 0 | 1 | 0 | 0 |
| 67 | Gd 2 - cenário 4 - abertura cargas em 692, 675 e 634 | 1 | 1 | 1 | 0 |
| 15 | B671 off | 1 | 1 | 0 | 0 |

7. CONCLUSÕES

Este trabalho teve por objetivo a elaboração de um sistema complementar para a detecção de ilhamentos não intencionais na presença de geração distribuída, utilizando as Redes Neurais Artificiais. Procura-se minimizar os erros de detecção das técnicas passivas empregadas, caracterizadas por zonas de não

detecção. O método proposto, modelado no MATLAB\Simulink, utiliza os estados operacionais da rede de distribuição, no ponto de interconexão do gerador distribuído, para treinar uma RNA com o propósito de identificar as situações de ilhamentos não intencionais.

Vale destacar que a taxa de amostragem de dados utilizada neste trabalho é superior à utilizada pelos relés passivos convencionais, o que potencializou os resultados, permitindo à RNA identificar com mais precisão os estados operativos do sistema.

O desempenho do sistema foi considerado satisfatório quando comparado aos sistemas de detecção de ilhamentos passivos, pois além de identificar com mais precisão as situações de ilhamento não intencional, apresentou um reduzido número de desligamentos desnecessários decorrentes de erros de identificação dos estados operativos do sistema elétrico.

Em continuidade aos desenvolvimentos deste trabalho, pretende-se avaliar a metodologia em um alimentador real de uma concessionária de distribuição, dotado de múltiplas GDs, instaladas em média e baixa tensão, e com a geração sujeita as variações da radiação solar diária. Deve-se ressaltar que as possibilidades de cenários de operação são praticamente infinitas e não é possível treinar a RNA para todas, mas o conjunto de operações de treinamento deverá obedecer a um critério padronizado, segundo estatística operacional.

REFERÊNCIAS

- [1] Abd-Elkader, A. G., Allam, D. F. & Tageldin, El., 2014. Islanding detection method for DFIG wind turbines using artificial neural networks. *International Journal of Electrical Power & Energy Systems*, november, Vol. 62, pp. 335-343.
- [2] ANEEL - Agência Nacional de Energia Elétrica, 2012. Resolução Normativa 482.
- [3] Commission, E., 2003. New ERA for electricity in Europe – Distributed Generation: Key Issues, Challenges and Proposed Solutions. *General Bulletin Information*, pp. 1-29.
- [4] Cybenko, G., 1989. Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control Signals Systems (1989)*, pp. 303-314.
- [5] ElNozahy, M. S., El-Saadany, E. F. & Salama, M. M. A., 2011. A robust wavelet-ANN based technique for islanding detection. *IEEE Power and Energy Society General Meeting*, 24 julho.
- [6] Enel Distribuição Rio, 2016. Conexão de Micro e Minigeração Distribuída ao Sistema Elétrico da AMPLA/Coelce.
- [7] Gama, P. H. R. P.; Aoki, A. R.; Martins, C.; Vicentini, E.; Souza, M. E. M.; Dias, R. B.; Neto, T. V. M., 2013. Comparação dos Requisitos das Distribuidoras para Inserção de Acessantes de Geração Distribuída. *Cigré Brasil*.
- [8] González, J., Dyško, A. & Lloyd, G., 2010. The Impact of Renewable Energy Sources and Distributed Generation on Substation Protection and Automation. *CIGRE Working Group B5.34*.
- [9] Guan, Z., 2015. A New Islanding Detection Method Based On Wavelet-transform and ANN for Inverter Assisted Distributed Generator. *Master's Thesis, University of Kentucky, USA*.
- [10] IEEE - Institute of Electrical and Electronics Engineers, 2003. 1547-2003 - IEEE Standard for Interconnecting Distributed Resources with Electric Power Systems.
- [11] Kersting, W. H., 1991. Radial distribution test feeders. *IEEE Transactions on Power Systems*, Agosto, vol. 6, ed. 3.
- [12] Moeini, A., Darabi, A., Rafiei, S. & Karimi, M., 2011. Intelligent islanding detection of a synchronous distributed generation using governor signal clustering. *Electric Power Systems Research*, february, 81(2), pp. 608-616.
- [13] Woyte, A., Belmans, R. & Nijs, J., 2003. Testing the islanding protection function of photovoltaic inverters. *IEEE Transactions on Energy Conversion*, 18(1), pp. 157 - 162.
- [14] Ye, Z., Kolwalkar, A., Zhang, Y., Du, P., Walling, R., 2004. Evaluation of anti-islanding schemes based on nondetection zone concept. *IEEE Transactions on Power Electronics*, 19(5), pp. 1171 - 1176.

Capítulo 10

Identificação de gênero e contorno corporal para estimativa de somatotipo

Gentil Auer Neto

Patrick Marques Ciarelli

Evandro Ottoni Teatini Salles

Resumo: Nas áreas da saúde e educação física, algumas abordagens com pacientes e atletas são definidas de acordo com o somatotipo dos indivíduos, cuja classificação automática baseada em imagens do corpo tem sido pesquisada com foco em diminuir a complexidade dos exames. Uma das dificuldades dessa abordagem é a necessidade de controle de iluminação e de um fundo homogêneo distinto do corpo humano. O presente trabalho consiste em aplicar a técnica Mask R-CNN em imagens de pessoas em ambientes não controlados para obter duas informações importantes para a estimativa do somatotipo: o gênero do indivíduo e o contorno corporal a nível de pixel. Para avaliar o desempenho do método, foram testadas imagens de população geral e de fisiculturistas. A classificação atingiu 95,4% de acurácia para o gênero masculino e 87,7% para o feminino. Os contornos corporais foram segmentados corretamente mesmo em imagens de ambiente não controlados.

Palavras-chaves: Somatotipo; Segmentação; Classificação; Redes Neurais Convolucionais; Mask R-CNN

1. INTRODUÇÃO

Detecção e segmentação de pessoas em imagens são temas bastante discutidos na área de visão computacional. Sistemas de vigilância e controle de acesso, sistemas de apoio ao motorista, aplicações médicas, inspeções industriais e localização de pessoas são algumas das áreas exploradas.

Somatotipo é o termo utilizado para representar a estrutura física do corpo humano, sendo formado pela combinação de três folhetos embrionários: endomorfismo, mesomorfismo e ectomorfismo (Sheldon et al., 1940). Na área de educação física e saúde, a identificação do somatotipo de cada indivíduo é uma métrica relevante na análise de pacientes e atletas, sendo possível observar o efeito de determinadas doenças e características de nutrição de crianças no corpo humano através do somatotipo, bem como auxiliar na orientação de treinamentos (Da Silva et al., 2003). Na prática, também é possível identificar por exemplo o esporte mais indicado para cada indivíduo visando benefícios para a saúde, ou ainda prever o potencial de crianças para determinadas modalidades que possuam características corporais bem definidas em seus atletas (Gonçalves, 2017) e (Jakšić e Cvetković, 2009).

O método clássico para obter o somatotipo utiliza aparelhos antropométricos, como balanças, adipômetros e fitas, que nem sempre são portáteis ou facilmente acessíveis, além de tomar um considerável tempo para a obtenção das medidas e requisitar profissionais treinados. Em Gonçalves (2017) foi proposto um método para a identificação automática de somatotipo por imagens, resultando em medidas muito próximas aos valores obtidos pelo método clássico, com as vantagens de ser muito mais rápido e não necessitar de profissionais experientes. Entretanto, algumas das limitações do método proposto são que as imagens deveriam ser obtidas em ambientes controlados e previamente preparados, com iluminação uniforme, fundo homogêneo e distinto do corpo humano, uma pessoa por imagem, etc., além de ser fornecido por meio externo o peso e o gênero do indivíduo.

Falhas de iluminação, presença de ruídos, sobreposição de objetos, falta de padronização de posicionamento, além de grande variabilidade nos cenários e planos de fundo são barreiras que vêm sendo vencidas, possibilitando a extração de características e construção de conhecimento baseado em imagens obtidas nesses ambientes desafiadores (Parolin, 2011).

Algumas técnicas de aprendizado de máquina possibilitam detectar objetos, como faces, e rapidamente descartar fundos de imagens (Viola et al., 2004), ou ainda estimar características dimensionais de objetos em imagens abordando conceitos de profundidade monocular e modelos probabilísticos (Saxena et al., 2005).

Inovações recentes têm proporcionado soluções cada vez mais robustas, motivadas pela grande variedade de aplicações baseadas em CNN – Convolutional Neural Networks (Fukushima, 1988 e LeCun et al., 1989). Um exemplo são as redes neurais profundas, que são compostas por várias camadas de processamento não linear, onde a saída de cada camada anterior alimenta a entrada de sua camada posterior (Deng, 2014).

Nos últimos anos, avanços nas pesquisas utilizando redes profundas, por exemplo, com os algoritmos R-CNN – Region with CNN features (Girshick et al., 2014), FCN – Fully Convolutional Networks (Long et al., 2015), Fast R-CNN – Fast Region-based Convolutional Network (Girshick et al., 2015), Faster R-CNN (Ren et al., 2015), FCIS – Fully Convolutional Instance-aware Semantic Segmentation (Li et al., 2017) e Mask R-CNN – Mask Region-based Convolutional Network (He et al., 2018) possibilitaram resultados promissores na segmentação de pessoas e classificação de objetos em ambientes não controlados, aliando ainda avanços relevantes em aspectos de custo computacional e acurácia.

Este trabalho visa dar continuidade à metodologia proposta por Gonçalves (2017), de forma a reduzir as suas limitações e facilitar a automatização da estimativa do somatotipo. Sendo assim, o objetivo deste trabalho é aplicar técnicas de redes neurais profundas em imagens de pessoas em ambientes não controlados, segmentar os contornos corporais e estimar o gênero. Para a segmentação apropriada dos indivíduos é proposto usar a rede neural profunda Mask R-CNN, pois ela realiza a segmentação em nível de pixel, sendo bastante precisa a sua segmentação, mesmo em condições adversas. Torna-se um estudo que, aliado ao proposto em (Gonçalves, 2017), avançará no sentido de complementar uma técnica robusta e automática de obtenção do somatotipo, ampliando possibilidades de ambientes para captura de imagens para realização de exames de pacientes e atletas, inclusive possibilitando avaliar em uma única imagem mais de um indivíduo, continuando o trabalho desenvolvido por Gonçalves (2016 e 2017).

A estrutura deste trabalho é tal que na Seção 2 é apresentado o embasamento teórico, na Seção 3 é descrita a técnica abordada, na Seção 4 é detalhada a metodologia de realização deste trabalho, na Seção 5 são apresentados os resultados e na Seção 6 é feita a conclusão e apresentados trabalhos futuros.

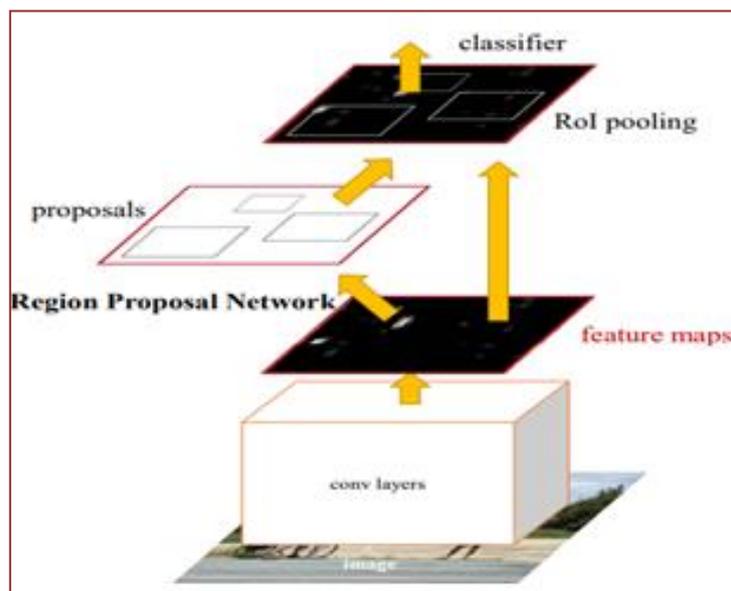
2. EMBASAMENTO TEÓRICO

Existem técnicas que utilizam redes neurais convolucionais para determinar se uma imagem contém um determinado objeto. Um exemplo é a AlexNet, uma arquitetura contendo cinco camadas de convolução, algumas delas seguidas por camadas de max-pooling e três camadas do tipo totalmente conectadas (Krizhevsky et al, 2012). Foi a arquitetura vencedora do ILSVRC 2012 (ImageNet Large-Scale Visual Recognition Challenge), e a responsável por popularizar as redes neurais convolucionais (CNN).

Outras arquiteturas mais avançadas indicam onde o objeto se encontra na imagem, realizando buscas por regiões de interesse, algo que foi introduzido pela R-CNN (Girshick et al. 2013), que funciona com três etapas: primeiro é feita a proposição de regiões candidatas, depois a extração de características de cada região utilizando uma CNN e finalmente é realizada a classificação de cada região utilizando support vector machine (SVM). A segunda etapa pode funcionar com diferentes arquiteturas de redes convolucionais, dentre elas a já citada AlexNet. Um problema dessa abordagem é o custo computacional, uma vez que para cada imagem de entrada são geradas aproximadamente duas mil regiões de interesse a serem processadas e classificadas.

Anos depois foi desenvolvida a Faster R-CNN (Ren et al., 2015), que para reduzir o custo computacional substituiu a busca seletiva por regiões de interesse por um modelo de rede convolucional pré-treinado que atua diretamente na imagem de entrada e gera um mapa de características, sendo posteriormente aplicado a uma segunda rede denominada Region Proposal Network (RPN), que funciona como uma janela deslizante que analisa o mapa de características, realiza supressão de não-máximos e evita o excesso de regiões candidatas por meio da técnica de pooling da região de interesse (RoI). A Figura 1 mostra um diagrama esquemático do RoI pooling, que funciona redimensionando as imagens para um tamanho fixo, depois obtém um novo vetor de características para cada RoI, prediz a categoria do objeto e o associa à sua localização na imagem original.

Fig. 1 Region Proposal Network e RoI pooling (Ren et al., 2015)



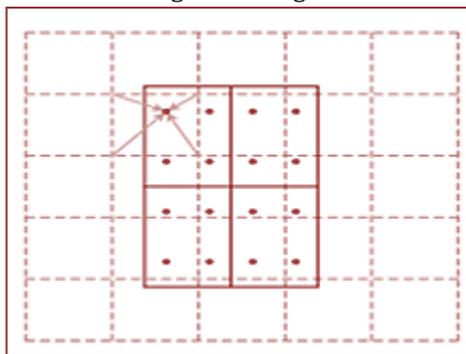
Indo além, recentemente foi desenvolvido um algoritmo capaz de detectar e segmentar objetos em nível de pixels chamado Mask R-CNN (He et al., 2018), capaz de realizar tal tarefa para múltiplas instâncias de objetos em uma imagem, inclusive quando há sobreposição entre eles. Em outras palavras, ele levou a Faster R-CNN para o nível de pixel. Uma descrição mais detalhada dela é apresentada na Seção 3.

3. TÉCNICA ABORDADA

Dada uma imagem de entrada, a Mask R-CNN tem como saídas as classificações dos objetos identificados nela, seus bounding boxes e suas máscaras, que são exatamente a aproximação mais fiel possível encontrada para representar o contorno do objeto, isto é, em nível de pixel. Ela é uma extensão da Faster R-CNN e adiciona uma ramificação responsável por realizar a segmentação de instâncias. Funcionando em duas etapas principais, primeiramente ela encontra regiões candidatas de maneira semelhante à Faster R-CNN, implementando uma RPN. No segundo estágio é que entra a nova ramificação citada, responsável por paralelamente prever e classificar a máscara do objeto.

Mask R-CNN realiza o alinhamento pixel a pixel da máscara utilizando uma técnica criada por seus autores denominada RoI Align. Ela atua sobre cada RoI do mapa de características obtido da imagem original e o divide em partes menores, depois seleciona um determinado número de pixels da fronteira de cada parte, dependendo do tamanho da máscara usada, e calcula um novo valor para cada parte do mapa por meio de interpolação bilinear, prevalecendo no final o mais representativo deles em cada uma dessas regiões. A Figura 2 exemplifica um caso de RoI Align para um mapa de características de tamanho 5x5, em que quatro máscaras de tamanho 2x2 são aplicadas e, após a interpolação bilinear seguida de supressão de não máximos ou cálculo de média, resulta em uma representação 2x2 para a RoI. O tamanho da máscara do RoI Align é um hiperparâmetro fixo definido antes do treinamento.

Fig. 2 RoI Align

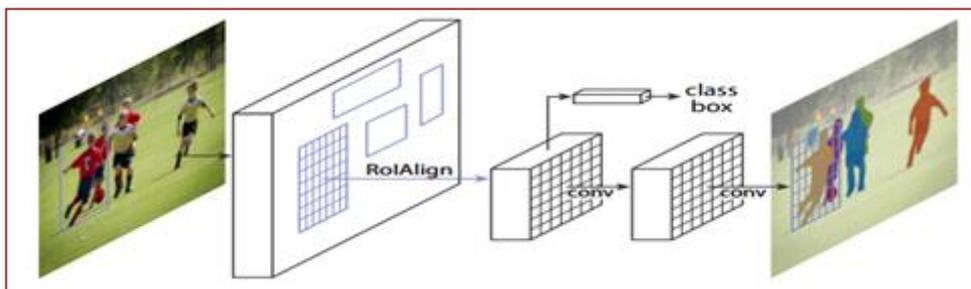


Fonte: (He et al., 2018)

Durante o treinamento, para cada RoI candidata é definida uma máscara de dimensão $m \times m$ utilizando uma rede FCN (Long et al., 2015). Uma RoI proposta é considerada positiva se a interseção dela com a região do objeto da imagem original for de pelo menos 50%, e quando isto ocorre é definida como uma máscara alvo. Uma máscara alvo é avaliada para todas as classes de treinamento, e por fim é definida uma probabilidade de ela estar associada a cada classe, prevalecendo a que possui o maior valor.

A Figura 3 mostra a arquitetura resumida da técnica Mask R-CNN, com a seleção de regiões de interesse seguida do alinhamento e finalizando com a segmentação e classificação de cada instância encontrada na imagem.

Fig. 3 Arquitetura Mask R-CNN



Fonte: (He et al., 2018)

Foram escolhidos dois backbones para a realização dos testes desse trabalho com a Mask R-CNN, sendo eles ResNet50 e ResNet101 (He et al., 2016). Com a ResNet foi introduzido o conceito de conexões de salto, responsáveis por atenuar o problema de desaparecimento do gradiente, que ocorre quando em redes com muitas camadas o valor do gradiente propagado é muito pequeno. Além disso, nela foi implementada uma função que garante que uma camada superior tenha um desempenho minimamente igual ao de uma camada inferior, e nunca pior.

4. METODOLOGIA

4.1 BASES DE DADOS

Para a realização do trabalho foram utilizadas duas fontes para montar a base de dados, sendo a primeira delas a base WIKI (Rothe et al., 2016), que disponibiliza imagens de forma gratuita na internet. Dela foram escolhidas 200 imagens de homens e 200 imagens de mulheres. A base WIKI pode ser acessada em <https://data.vision.ee.ethz.ch/cvl/rrothe/imdb-wiki/>.

A segunda fonte para a base de dados é a mesma utilizada por (Gonçalves, 2017), contendo imagens de atletas fisiculturistas, sendo 72 homens e 46 mulheres. A validação realizada nessa segunda base é a referência para trabalhos seguintes, rumo à automatização da estimativa do somatotipo.

Para a classificação de gênero foram definidos os rótulos masculino e feminino e geradas as máscaras de treinamento utilizando a ferramenta online LabelMe (Russel et al., 2008) nas imagens da base WIKI e também nas imagens dos fisiculturistas. O conjunto de dados de treinamento consiste, portanto, de imagens originais e dos bounding boxes gerados com o uso do LabelMe sob os objetos de interesse. A Figura 4 exibe duas imagens de treinamento.

Fig. 4 Imagens do conjunto de treinamento com máscaras para classificação de gênero baseada em face



Além disso, após alguns testes iniciais, foram inseridas ao grupo de treinamento 100 imagens da base WIKI sem nenhum indivíduo, portanto também sem rótulo, visando melhorar a acurácia do algoritmo, totalizando 618 imagens. Do total utilizado, 60% da base de dados foi separada para treinamento, e o restante foi utilizado para teste.

4.2. ESTRATÉGIA

A estratégia adotada nesse trabalho consiste em duas etapas: primeiro é feita a identificação e segmentação do corpo completo do indivíduo, e depois é feita a classificação do gênero analisando apenas a face. O objetivo é fornecer como saída do sistema duas informações: se o indivíduo é do gênero masculino ou feminino, além da imagem segmentada com o contorno o mais próximo possível do corpo real da pessoa, permitindo que esses dados sejam utilizados em um sistema posterior de estimativa do somatotipo.

Para essa tarefa foram utilizados como backbones da Mask R-CNN dois modelos ResNet. Para a detecção e segmentação de pessoas foi aplicado primeiramente um modelo ResNet50 e posteriormente um modelo ResNet101, ambos contendo pesos pré-treinados para segmentação de pessoas tendo sido treinados na base Common Objects in Context (COCO) (Lin et al., 2014).

Para a classificação de gênero foi aproveitado o modelo ResNet50, porém nessa etapa foi realizado o retreinamento da rede em quatro abordagens distintas.

Primeiro foi feito o treinamento completo do modelo e não foram utilizadas imagens de classe negativa, isto é, sem indivíduos nas fotos. Esse método é apresentado como sem transfer learning; sem classe negativa na Seção 5.

No segundo momento, foi inserida ao treinamento a classe negativa, o que aumentou ligeiramente a acurácia do algoritmo, diminuindo a ocorrência de falsos positivos. Esse método é apresentado como sem transfer learning; com classe negativa na Seção 5.

Na terceira abordagem, foi realizado o retreinamento apenas da última camada da rede, utilizando a técnica conhecida como transfer learning, com o objetivo de aproveitar o conhecimento retido no modelo pré-treinado e ainda acelerar os testes, pois dessa forma o custo computacional é reduzido substancialmente. Esse método é apresentado como transfer learning + classe negativa na Seção 5.

Por fim, além de transfer learning e inserção da classe negativa, também foi realizado um ajuste na base de treinamento, sobretudo nas marcações das máscaras e ajustes dos contornos faciais. Esse método é apresentado como transfer learning + classe negativa + máscaras reajustadas na Seção 5.

Para as quatro abordagens citadas, o objetivo era realizar a classificação do gênero, cuja análise do resultado é quantitativa e baseada na acurácia, bem como na comparação das taxas de falso positivo e falso negativo, com a obtenção da curva Receiver Operating Characteristics (ROC). A análise dos resultados da segmentação do contorno corporal é feita de forma qualitativa e visual.

4.3. MÉTRICAS

A avaliação quantitativa do método aplicado para classificação de gênero foi realizada através das medidas de acurácia. A acurácia mede a precisão geral do algoritmo, isto é, calcula o número de acertos dividido pelo total de amostras. Ela é aplicável a este estudo principalmente por conta da proporcionalidade entre os dados de cada classe aqui abordada.

Pela característica binária da classificação de gênero, cabe a aplicação da medida da área abaixo da curva ROC, que possibilita mensurar o desempenho do classificador avaliando a variação mútua entre a sensibilidade e a especificidade do modelo (Prati et al., 2008).

5. RESULTADOS E DISCUSSÕES

Todos os treinamentos desse trabalho foram realizados utilizando uma GPU Nvidia GTX 1070ti com 8GB de memória, processador Intel Core i5 8400 e 8GB de memória RAM.

A Figura 5 mostra alguns dos resultados obtidos para a segmentação de corpo inteiro das pessoas nas imagens. À esquerda, em azul escuro, estão os resultados obtidos com Mask R-CNN utilizando backbone ResNet50 e à direita, em azul claro, os resultados obtidos com ResNet101. É possível verificar que os contornos são obtidos quase que em sua totalidade com boa qualidade, principalmente após a utilização da rede mais profunda, exceto para o trecho da imagem entre os braços e o tronco, quando ambos estão pouco afastados, o que pode ser melhorado com pós-processamento ou ainda com uma boa prática de posicionamento do indivíduo.

Em testes realizados utilizando imagens obtidas de ambientes com adversidades como sombras e fundo heterogêneo também foram obtidos resultados interessantes de segmentação, mais uma vez demonstrando a eficácia do algoritmo nessa aplicação com tais condições, conforme mostra a Figura 6.

Fig. 5 Aplicação de Mask R-CNN com backbone ResNet50 (em azul escuro) e ResNet101 (em azul claro)

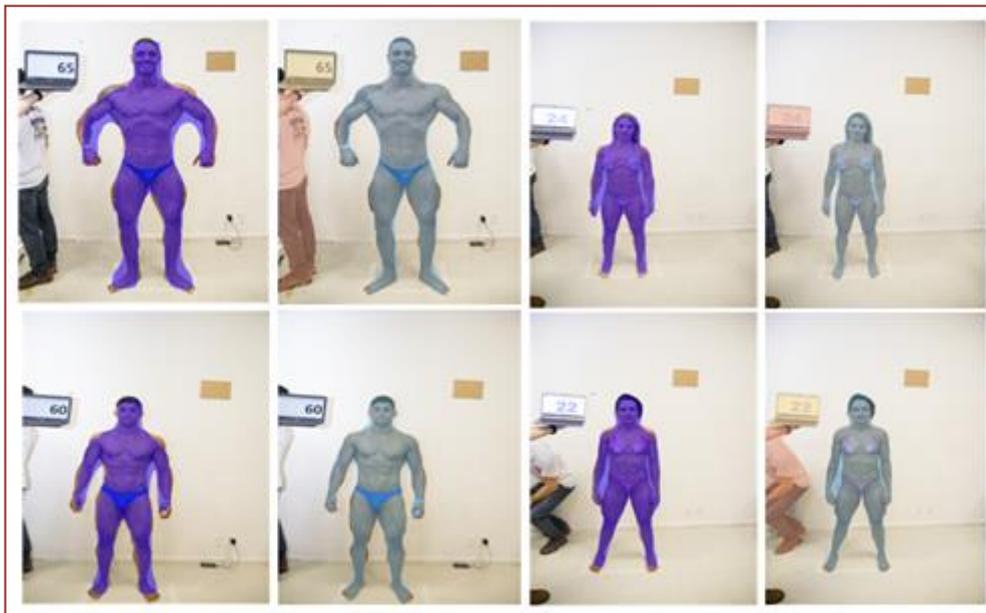


Fig. 6 Resultados da segmentação em fotos com sombras e fundo heterogêneo



Vale ressaltar que o algoritmo é robusto o suficiente para lidar com imagens contendo indivíduos em diferentes tamanhos e escalas, além de condições adversas de iluminação, inclusive com saturação e sombras, conforme pode ser observado na Figura 7.

Fig. 7 Segmentação de múltiplas instâncias em ambiente não controlado



Finalmente, a Figura 8 mostra alguns resultados obtidos para a segmentação de faces e classificação de gênero, onde foi possível obter bons resultados de classificação mesmo quando o contorno não é perfeitamente encaixado na face. A classificação de gênero é correta mesmo em casos que a pessoa não está com a face perpendicular para a câmera, ou está fazendo algum movimento como um sorriso ou uma rotação da cabeça em relação à câmera. É importante citar que na base de treinamento foram utilizadas imagens com essas características. Apesar disso, no caso da obtenção da imagem para a aplicação do somatotipo a pessoa sempre estará com a face perpendicular à câmera.

Fig. 8 Segmentação de face e classificação de gênero



A Tabela 1 mostra os resultados da acurácia de classificação.

Tabela 4. Acurácia da classificação de gênero

| | Acurácia | |
|--|----------|-------|
| | Masc | Fem |
| Sem transfer learning; sem classe negativa | 83,1% | 76,3% |
| Sem transfer learning, com classe negativa | 84,0% | 79,1% |
| Transfer learning + classe negativa | 85,0% | 79,0% |
| Transfer learning + classe negativa + máscaras reajustadas | 95,4% | 87,7% |

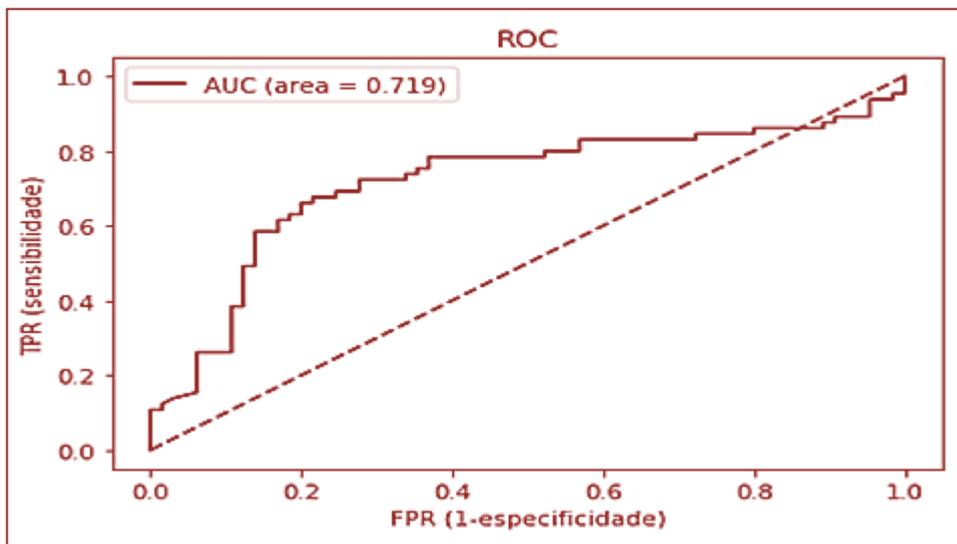
As abordagens realizadas sem transfer learning se mostraram menos eficazes, mesmo quando realizado treinamento com imagens da classe negativa, o que pode ser observado na primeira e segunda linha da Tabela 1. A inserção de imagens não rotuladas não resultou em melhoria significativa no resultado, apenas contribuiu com um aumento de aproximadamente 3% da acurácia para o gênero feminino.

A utilização do transfer learning isoladamente também não resultou em um aumento significativo da acurácia, a princípio. Por outro lado, a grande vantagem da terceira abordagem foi a diminuição do custo computacional, uma vez que todo o treinamento foi realizado com dez mil iterações e trinta épocas e a redução do tempo de treinamento foi de cerca de 50% do tempo demandado sem a utilização da técnica, resultando em aproximadamente quatro horas de treinamento. A quarta abordagem de treinamento

trouxo a melhoria mais perceptível nos resultados, após ser realizado um reajuste na base de treinamento, que consistiu no refinamento das bordas das máscaras, ajustando os contornos das faces e as coordenadas dos bounding boxes delas.

Com o modelo final treinado, além da métrica de acurácia, já citada, foi obtida a curva ROC para avaliação da qualidade do classificador, onde foi obtido um valor de 0,719 para a área sob a curva, o que demonstra que o método resultou em um bom classificador, porém ainda há um caminho a ser explorado para torná-lo excelente. Há a expectativa de que esse resultado possa ser melhorado utilizando imagens com resolução mais alta nos treinamentos e testes, bem como a aplicação de técnicas de data augmentation.

Fig. 8 Curva ROC obtida para o classificador de gênero



6. CONCLUSÕES

O objetivo desse trabalho foi aplicar a técnica Mask R-CNN utilizando backbones ResNet na tarefa de segmentação de pessoas e classificação de gênero analisando faces em imagens de ambientes não controlados, de forma a possibilitar a construção de um algoritmo que forneça dados essenciais para serem integrados a um sistema de avaliação automática de somatotipo.

Foi possível observar que a técnica testada é robusta e consegue realizar com boa qualidade a tarefa de segmentação de pessoas em ambientes não controlados, podendo servir de base para um sistema de baixo custo de classificação automática de somatotipo, contribuindo, portanto, para tal pesquisa em desenvolvimento. Além disso, foi concluído que foi possível alcançar um classificador com nível de acurácia que viabiliza a tarefa da obtenção do gênero com base em análise facial.

Como trabalhos futuros, propõe-se aplicar diferentes arquiteturas de redes profundas para a classificação de gênero e compará-las com a ResNet50. Depois, utilizar o resultado da segmentação dos contornos corporais como entrada de um sistema de estimativa de somatotipo, visando avaliar de forma quantitativa o resultado dessa segmentação no algoritmo de estimativa de somatotipo desenvolvido pelo trabalho de referência para essa pesquisa feito por Gonçalves (2017).

REFERÊNCIAS

- [1] Deng, L., (2014). A tutorial survey of architectures, algorithms, and applications for deep learning. APSIPA Transactions on Signal and Information Processing, v. 3, pp. 1–29
- [2] Da Silva, P. R. P.; Trindade, R.; De Rose, E. H., (2003). Composição corporal, somatotipo e proporcionalidade de culturistas de elite do Brasil. Rev Bras Med Esporte v. 9, n. 6, pp. 403–407
- [3] Fukushima, K. (1988). Neocognitron: A hierarchical neural network capable of visual pattern recognition. Neural networks 1.2 (1988): pp. 119-130

- [4] Girshick, R., (2014). R-CNN - Rich feature hierarchies for accurate object detection and semantic segmentation. The IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 2014.
- [5] Girshick, R. (2015). Fast R-CNN. ICCV '15 Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV), pp. 1440-1448.
- [6] Gonçalves, T. O.; Ciarelli, P. M.; Coco, K. F., (2016). Uma análise da viabilidade de estimar somatotipos de fisiculturistas através de medições em imagens. XXI Congresso Brasileiro de Automática - CBA2016, pp. 3416-3421.
- [7] Gonçalves, T. O., (2017). Identificação do Somatotipo de Fisiculturistas Através de Imagens Digitais. Dissertação de Mestrado, Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Espírito Santo, Vitória, Espírito Santo, Brasil.
- [8] He, K.; Zhang, X.; Ren, S.; Sun, J., (2016). Deep Residual Learning for Image Recognition. Conference on Computer Vision and Pattern Recognition (CVPR). June 2016.
- [9] He, K.; Gkioxari, G.; Dollár, P.; Girshick, R., (2017). Mask R-CNN. Conference on Computer Vision and Pattern Recognition (CVPR). June 2017
- [10] Jakšić, D.; Cvetković, M., (2009). Neural network analysis of somatotype differences among males related to the manifestation of motor abilities, *Acta Kinesiológica* **3**(1): 107-113
- [11] Krizhevsky, A.; Sutskever, I.; Hinton, G. E., (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, **60**(6): 84-90.
- [12] LeCun, Y.; Boser, B.; Denker, J.; Henderson, D.; Howard, R.; Hubbard, W.; Jackel, L. (1989). Backpropagation applied to handwritten zip code recognition. *Neural Computation* **1**(4): 541-551.
- [13] Li, Y.; Qi, H.; Dai, J.; Ji, X.; Wei, Y., (2017). Fully convolutional instance-aware semantic segmentation. Conference on Computer Vision and Pattern Recognition (CVPR), July 2017.
- [14] Long, J.; Shelhamer, E.; Darrell, T., (2015). Fully convolutional networks for semantic segmentation, Conference on Computer Vision and Pattern Recognition (CVPR), July 2015.
- [15] Parolin, A., (2011). Segmentação de imagens de pessoas em tempo real para videoconferências. Dissertação de Mestrado, Universidade do Vale do Rio dos Sinos, UNISINOS, Brasil.
- [16] R. C. Prati, G. E. A. P. A. Batista e M. C. Monard, (2008). Curvas ROC para avaliação de classificadores. *IEEE Latin America Transactions[S.l.]*, **6**(2): 215-222
- [17] Ren, S.; He, K.; Girshick, R.; Sun, J., (2015). Faster R-CNN: Towards real-time object detection with region proposal networks, *IEEE Transactions on Pattern Analysis & Machine Intelligence*, **39**(6): 1137-1149.
- [18] Rothe, R.; Timofte, R.; Gool, L.V., (2016). Deep expectation of real and apparent age from a single image without facial landmarks, *International Journal of Computer Vision*, v. 126, pp. 144-157.
- [19] Russel, B.; Torralba, A.; Murphy, K.; Freeman, W. T.; (2008). LabelMe: a database and web-based tool for image annotation, *International Journal of Computer Vision*, v. 77, p. 157-173
- [20] Saxena, A.; Chung, S. H.; Ng, A. Y., (2005). Learning Depth from Single Monocular Images, *NIPS'05 Proceedings of the 18th International Conference on Neural Information Processing Systems*, pp. 1161-1168
- [21] Sheldon, W. H., Stevens, S. S. e Tucker, W. B. (1940). *The varieties of human physique*. Oxford, England: Harper.
- [22] Viola, P. e Jones, M. J. (2004). Robust real-time face detection, *International Journal of Computer Vision* **2**(57): 137-154.

Capítulo 11

Reconhecimento de Ações por RNA em Aplicações de Robótica Social

Kevin Braathen de Carvalho

Vitor Thinassi Basílio

Alexandre Santos Brandão

Resumo: A Interação Humano-Robô vem ganhando mais espaço no meio acadêmico nos últimos anos. Esta é uma área de interesse devido ao seu grande leque de aplicações, tais como busca e resgate, entretenimento, auxílio militar e policial, exploração espacial, tarefas com veículos aéreos não tripulados e robótica socialmente assistiva. O último item pode ser mais detalhado com aplicações como ajuda à idosos, pessoas física ou mentalmente debilitadas, e até mesmo suporte educacional. Esse trabalho propõe um método de reconhecimento de ações para ser utilizado em situações de Robótica Socialmente Assistiva. O método proposto para interação é baseado em redes neurais artificiais e se apoia em redução da dimensionalidade da entrada por meio do uso de autovalores. A base de dados utilizada é própria, devido ao fato das bases de dados encontradas na internet não possuírem classes de ações desejadas para a aplicação proposta. A validação do método se dá através de comparação com o DTW (Dynamic Time Warping)). Testes online são realizados para assegurar que a base de dados não estava enviesada ou tendenciosa. Os resultados experimentais mostraram que o método de comunicação é eficaz, tendo 98% de acerto nos testes online, para 5 pessoas diferentes no seu banco de dados com 10 amostras de cada pessoa para cada classe. A estratégia é escalável para novos usuários e requer um número reduzido de 5 amostras de treinamento de cada pessoa para cada classe para alcançar resultados acima de 96%.

Palavras-chave: Reconhecimento de Ações, Robótica Socialmente Interativa, Redes Neurais Artificiais

1. INTRODUÇÃO

A Interação Humano-Robô (do inglês Human-Robot Interaction, HRI) tem continuamente ganhado mais atenção no meio acadêmico nos últimos 30 anos (Tsarouchi; Makris; Chryssolouris, 2016). Este é um campo de estudo importante devido à sua grande gama de aplicações, tais como busca e resgate, entretenimento, auxílio militar e policial, exploração espacial ou tarefas com veículos aéreos não tripulados (VANT).

Busca e resgate é uma aplicação que inerentemente se tem interação humano-robô, tendo em vista que o agente está procurando um humano em uma situação de desastre. No trabalho (MURPHY et al., 2008) para resumir a situação de robôs de busca, ele ambienta essa aplicação com as características básicas de um desastre e como que isso afeta o projeto de robótica e descreve os robôs utilizados em desastres famosos como o atentado ao World Trade Center em 2001, os furacões Katrina, Rita e Wilma em 2005 nos Estados Unidos e outros mais. Além disso os projetos mais promissores, conceitos e métodos de avaliação de desempenho são elucidados também. Por fim conclui-se sobre as dificuldades fundamentais dessa aplicação e seus problemas em aberto.

Para aplicações em entretenimento, o trabalho (Yoshida et al., 2015) propõe uma interface simples que permita a usuários criarem padrões de movimentos complexos para um robô dançar. Suas maiores contribuições são: que a interface desenvolvida é capaz de criar movimentações elaboradas sem a necessidade do usuário dar comandos de baixo nível, permitindo que usuários especializados em robótica ou não consigam operar o robô, permitir que esses padrões complexos sejam criados através de movimentos simples predeterminados e a sincronização automática entre a dança e os movimentos do robô. O trabalho foi desenvolvido para ser utilizado com dois tipos de robôs; um móvel e um humanoide. Os autores fizeram duas demonstrações públicas da interface que validou a facilidade da aplicação para leigos e especialistas no assunto.

Uma análise sobre o presente e o futuro de aplicações militares da robótica é vista em (MIES, 2010), onde o autor fala das primeiras tecnologias utilizadas nesse cenário e como elas podem auxiliar nas tarefas. Aplicações como permitir que tarefas que colocariam a vida de humanos executando elas, como desarmar uma bomba ou andar em lugares com escombros em perigo de desabamento, possam ser realizadas com segurança através de agentes robóticos tele operados, utilização de Veículos Aéreos Não Tripulados (VANTS) em combate moderno ou então para obtenção de informação e tarefas de vigília. Para o futuro, o autor menciona o desenvolvimento mais profundo de robôs terrestres melhorando nas aplicações de exploração e auxílio médico, de robôs marítimos com o mesmo intuito. Por fim, é mencionado que especialistas acreditam que o campo de atuação no espaço possa ganhar foco no futuro, tendo em vista que enviar humanos em risco para o espaço é ainda muito caro.

Exploração espacial é um tópico que a interação humano-robô se dá comumente por teleoperação em algum grau do robô. O trabalho (Yoshida, 2009) faz um apanhado geral das aplicações de robótica no espaço. Inicialmente é mencionado os avanços em robótica orbital, com aplicações como lidar com entulho espacial mudando a órbita de satélites ou utilização de robôs para tarefas de encontro ou para a realização de algum serviço, como manutenção ou manipulação de algo em um satélite. Em seguida é trabalhada a robótica planetária, exemplificando aplicações na Lua e em Marte e explicitando dificuldades recorrentes como o sensoriamento da odometria do agente e a compensação para deslizos e controle de tração. Por fim, as dificuldades de aplicações em asteroides são trabalhadas, como a aderência e locomoção do robô em lugares com campo gravitacional muito diferente da Terra.

Em (Monajjemi et al., 2013), pode-se ver o desenvolvimento de um sistema de interação humano-robô através de gestos e de detecção de onde o usuário está olhando para o comando de um grupo de VANTS. O sistema implementado permite que o usuário consiga manipular os VANTS individualmente ou adicionar e removê-los de grupos para que um mesmo comando seja dado para mais de um dos agentes. O trabalho não abrange a execução de tarefas em si, apenas a seleção de quais VANTS irão receber os comandos de se juntar ao grupo ou se separar e um comando simbólico de execução. O sistema de comunicação consegue ser utilizado por usuários não especializados nele de forma intuitiva, onde se seleciona o VANT que receberá o comando olhando para ele e os comandos de se juntar, separar ou executar a ação são dados por gestos.

Segundo Goodrich, Schultz et al. (2008) a interação entre humanos e robôs pode se agrupar nas seguintes categorias:

1-HRI Colaborativo, que envolve um robô e uma pessoa trabalhando juntos para completar uma tarefa simples (Park; Howard, 2013; Hinds; Roberts; Jones,2004; L'Angle; W'Orn, 2001; Cherubini et al., 2016; Maurice et al., 2017)

2-HRI Assistivo, onde o robô é utilizado para auxiliar pessoas através de assistência física, social e/ou cognitiva (Mccoll; Nejat, 2013; Feil-Seifer; Mataric,2011; Clabaugh et al., 2018).

3- HRI de Imitação, onde o robô ou pessoa tenta imitar comportamentos verbais ou não verbais de quem está interagindo. Isso pode ser utilizado para melhorar coordenação social entre as partes envolvidas (Bourgeois; Hess, 2008; Rakita; Mutlu;Gleicher, 2017)

4- HRI Geral ou de multi-tarefas, que envolve robôs desenvolvidos para interagir com pessoas em várias aplicações distintas utilizando comunicação bidirecional (Ishiguro et al., 2001)

Sobre a natureza da comunicação ou interação humano-robô, pode-se destacar diferentes abordagens, tais como:

1- Gestos ou Ações: adotados quando a liberdade de movimento é uma opção. Ademais, pode ser utilizado em situações tais como fisioterapia, onde o reconhecimento da posição e orientação de partes do corpo é vital, reafirmando a comunicação entre o usuário e o agente (Kanda et al., 2004; Chen et al., 2019; Bodirožza; Stern;EDAN, 2012).

2- Comandos de voz, através da linguagem natural utilizada regularmente no dia-a-dia para, neste caso, dialogar com o robô (Eriksson, 2004; Liu; Zhang, 2019).

3-Periféricos, tais como mouse , teclados ou touchscreens, os quais podem ser úteis em situações que gestos ou reconhecimento de voz seriam tediosos, tais como apontar uma localização em um mapa. Situações assim seriam lidadas de forma mais natural com a utilização de periféricos (Huttenrauch; Eklundh, 2002; Montemerloet al., 2002).

Esse trabalho tem foco em uma parte específica de HRI definida como Robótica Socialmente Assistiva (SAR), que é definida como a intersecção entre Robótica Socialmente Interativa (do inglês, Socially Interactive Robotics, SIR), inspirado pela comunicação entre o robô e o ambiente que ele está inserido, ou até mesmo entre mais de um robô (FONG;

Nourbakhsh; Dautenhahn, 2003; Feil-Seifer; Mataric, 2005),e a Robótica Assistiva (do inglês Assistive Robotics, AR), onde qualquer robô desenvolvido para assistir humanos de qualquer forma se enquadra (Feil-Seifer; Mataric, 2005),que pode ser exemplificada por tarefas como ajuda à idosos e a pessoas física ou mentalmente debilitadas, bem como em atividade de suporte educacional.

Esse trabalho propõe um algoritmo de reconhecimento de ações utilizando RNA para ser utilizado em aplicações de SAR. O seu desempenho é comparado utilizando método Dynamic time Warping (DTW) como baseline. Simulações e experimentos são feitos para realizar essa comparação.

Esse trabalho é dividido da seguinte forma: Na seção reconhecimento de ações é realizado um embasamento teórico em torno dessa área de atuação. Na seção Metodologia, é explicado como se realizou o trabalho propriamente dito, desde a criação da base de dados e a aplicação dos métodos proposto e do baseline. Na Seção Resultados e Discussões são mostrados e discutidos os resultados das simulações e experimentos. Por fim na seção Conclusões Finais, se conclui o trabalho e se propõe novos caminhos para projetos futuros.

2. RECONHECIMENTO DE AÇÕES

2.1. TERMINOLOGIA

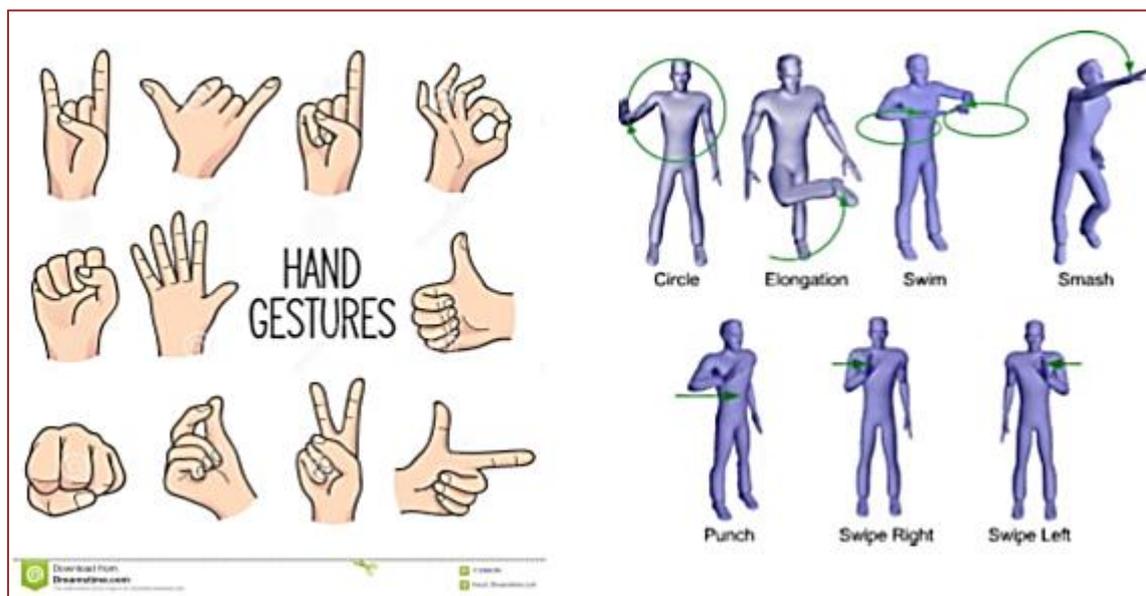
Na literatura quando se trata de movimentos com o corpo, são usados nomes diferentes para descrever a situação. Gestos, ações e gestos de corpo completo podem ser observados na literatura ao lidar com o que no dia a dia, é comumente referido como gestos.

No trabalho (Cabibihan; SO; Pramanik, 2012), é usado gestos de corpo completo para descrever gestos que são feitos com um ou dois braços, como aperto de mão, dirigir, andar (apenas vendo da cintura para cima) e balançando os braços. Nos trabalhos (Abdelnasser; Youssef; Harras, 2015; Murakami; Taguchi, 1991)} é utilizado o termo gestos para se referir a gestos feitos apenas com as mãos. No trabalho (LI; Zhang; Liu, 2010) o autor se refere aos gestos feitos com o corpo inteiro como ações e nos trabalhos

(Canal; Escalera; Angulo, 2016; Ibanez et al., 2014) é utilizado o termo gestos para se referir a gestos que são feitos com o corpo todo.

Tendo isso em vista, a terminologia não é muito bem definida na literatura, então para esse trabalho será utilizado a terminologia de “ação” para os sinais utilizados. “Gestos” serão vistos apenas como feitos apenas pelas mãos. A Figura 1 ilustra essa diferença.

Figura 9: Ilustração da terminologia utilizada. Fontes: Dreamstime(2019), Ibanez et al. (2014).



2.2. RECONHECIMENTO DE AÇÕES

Tendo sensores RGB-D (Red, Green, Blue -- Depth, ou seja, Vermelho, Verde, Azul -- Profundidade) de baixo custo tais como Intel RealSense e o Microsoft Kinect sendo desenvolvidos, o acesso à informação detalhada de cor e profundidade do ambiente ficou mais simplificada. Aliando isso ao fato de que reconhecimento de ações tem uma grande gama de aplicações, os esforços acadêmicos em pesquisas utilizando informação 3D de esqueletos para classificação de ações ou gestos têm aumentado nas últimas décadas (Patrona et al., 2018; Yang et al., 2017). Dentre algumas aplicações, pode-se citar: utilização em ambiente público para detectar atividades suspeitas, monitoramento médico, análise de performance atlética e também interação humano-robô avançada em aplicações de SAR (Sempena; Maulidevi; Aryan, 2011; Aggarwal; XIA, 2014)

Reconhecimento de ação pode ser dividido em duas partes: extração das características principais (do inglês, features) e classificação dessas features (Agahian; Negin; Kose, 2019).

Sensores de rastreamento em geral são Baseados em Visão (do inglês, Vision Based), ou de Captura de Movimento (do inglês, Motion Caption, MoCap). O primeiro utiliza imagens, que podem ter informação de cor (RGB) ou de profundidade, para processar o ambiente e suas particularidades para realização da classificação. O segundo baseia-se nas features, onde se extrai parâmetros específicos tais como informação 3D de esqueleto como posição, velocidade e/ou orientação das juntas, que podem ser adquiridas através de processamento das imagens ou tendo marcadores no corpo para extração direta dessas informações (Mitra; Acharya, 2007).

Após o rastreamento do esqueleto, métodos para a classificação de ações ou gestos devem ser aplicados. Várias técnicas são empregadas para isso, tais como:

1-**Dynamic Time Warping (DTW)** que compara séries temporais para encontrar seu grau de similaridade, isso é feito através da comparação de pontos em espaço de tempo próximo das duas séries. O cálculo pode usar várias métricas de distância, como Manhattan ou euclidiana. Isso confere uma robustez à distorções temporais entre as séries (Celebi et al., 2013; Raheja et al., 2015);

2- **Hidden Markov Model (HMM)**, que utiliza a quantificação da configuração do sistema através de um número finito de estados discretos, onde os valores armazenados representam uma aproximação da dinâmica do sistema. Esses estados podem ser um vetor de features contendo a informação espacial de cada característica dos objetos obtida através de uma auto-calibração (Kumar et al., 2017);

3-**Redes Neurais Artificiais (RNA)**, um tipo de técnica de aprendizado por supervisão, que utiliza um conjunto de treinamento para poder refinar seus parâmetros correlacionando suas entradas com as etiquetas das suas saídas.

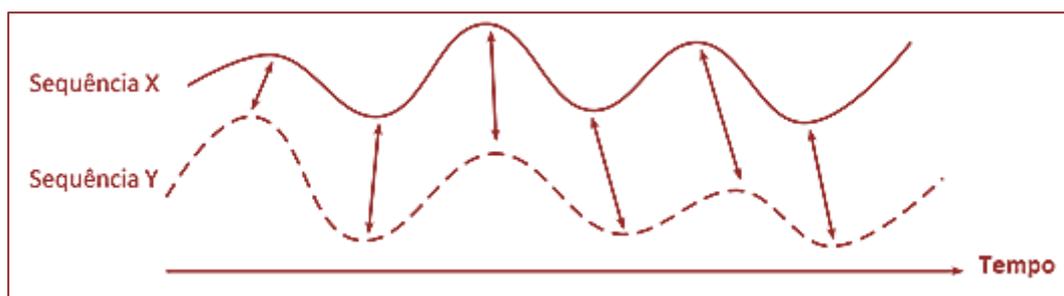
Existem diversas estruturas diferentes para essas redes, tais como Redes Neurais Recorrentes, mais usadas quando a entrada é uma série temporal (Veeriah; Zhuang; QI, 2015) Redes Neurais Profundas, onde várias camadas de neurônios são empregadas e é necessário um conjunto de treinamento extenso, mas isso confere à rede uma capacidade de extrair os features dos dados por conta própria (Ordóñez; Roggen, 2016) ou um tipo específico de redes profundas, as Redes Neurais Convolucionais onde as camadas subsequentes não são totalmente conectadas, permitindo que a rede seja profunda, mas com menos parâmetros do que se fosse composta apenas de camadas densas (Wang et al., 2018).

2.3. DYNAMIC TIME WARPING

A ideia principal do DTW é de comparar duas sequências dependentes do tempo. Essas sequências podem ser discretas (séries temporais) mas em geral elas são sequências amostradas com um tempo de separação constante. As sequências analisadas podem, inclusive, ter tamanhos diferentes. Na situação desse trabalho, uma ação pode ser representada como uma série temporal ao colocar as informações de cada junta em sequência com o crescimento do tempo, dessa forma cada elemento subsequente será uma informação a frente no tempo da anterior.

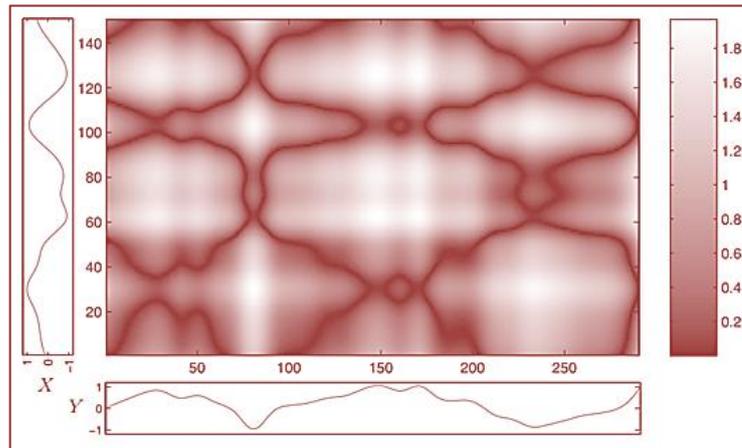
A Figura 2 mostra o alinhamento temporal de duas sequências distintas. As setas indicam o elemento próximo mais similar das duas sequências.

Figura 10: Alinhamento Temporal de Duas Séries. Fonte Muller(2007)



Como pode ser visto em (MULLER, 2007) o DTW clássico se dá ao procurar nas proximidades dos elementos de uma sequência, o ponto com a menor diferença, ou custo, (que pode ser calculada com distância euclidiana ou outras métricas) nos elementos da outra sequência. Isso pode ser mais facilmente visualizado com o esquema da Figura 3 também chamado de matriz de custo. Nela é possível ver o custo de cada elemento de cada sequência em relação a todos os elementos da outra sequência, como por exemplo uma linha nessa matriz indica o custo do elemento da sequência X referente àquela linha com todos os elementos da sequência Y.

Figura 11: Matriz de custo de duas seqüências, X na vertical e Y na horizontal. As regiões mais escuras tem custo mais baixo e as mais claras custo mais alto

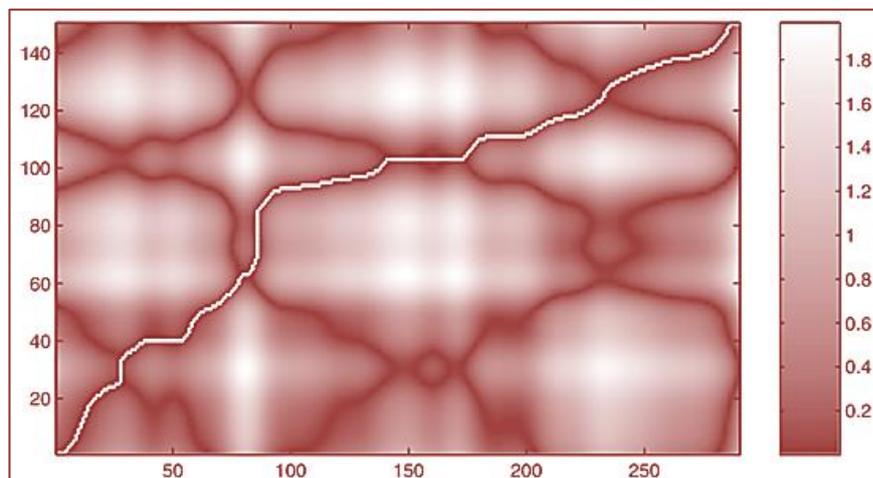


Ao analisar o custo de cada combinação de elemento, pode ser encontrado um caminho com o menor custo entre as seqüências. Esse caminho consiste em uma seqüência de pares, onde há um elemento de cada seqüência. Esses pares representam o mapeamento que relaciona um ponto de uma seqüência com o mais similar a ele nas suas proximidades com a outra seqüência. Esse caminho então é como se fosse um guia para relacionar os pontos de uma seqüência com os mais similares da outra. Esse caminho deve respeitar as seguintes condições:

- 1- Fronteira - o primeiro item do caminho deve ser feito pelo par dos elementos iniciais de cada seqüência e o último item do caminho pelos últimos itens de cada seqüência.
- 2- Monotonicidade - Dois pares seguidos no caminho (x_n, y_n) e (x_{n+1}, y_{n+1}) devem respeitar a seguinte relação: $x_n \leq x_{n+1}$ e $y_n \leq y_{n+1}$, garantindo que o caminho nunca compare elementos voltando no tempo e sim sempre estando no mesmo momento, ou avançando.
- 3- Tamanho do Passo - Como dito no texto, a procura pelo item de menor custo se dá nas proximidades do elemento de cada seqüência. O tamanho dessa proximidade não deve passar de um valor fixo, tanto para quanto se avança em uma seqüência quanto na outra. Não se deve dar passos irregulares nessa procura de um correspondente de menor custo para elementos diferentes.

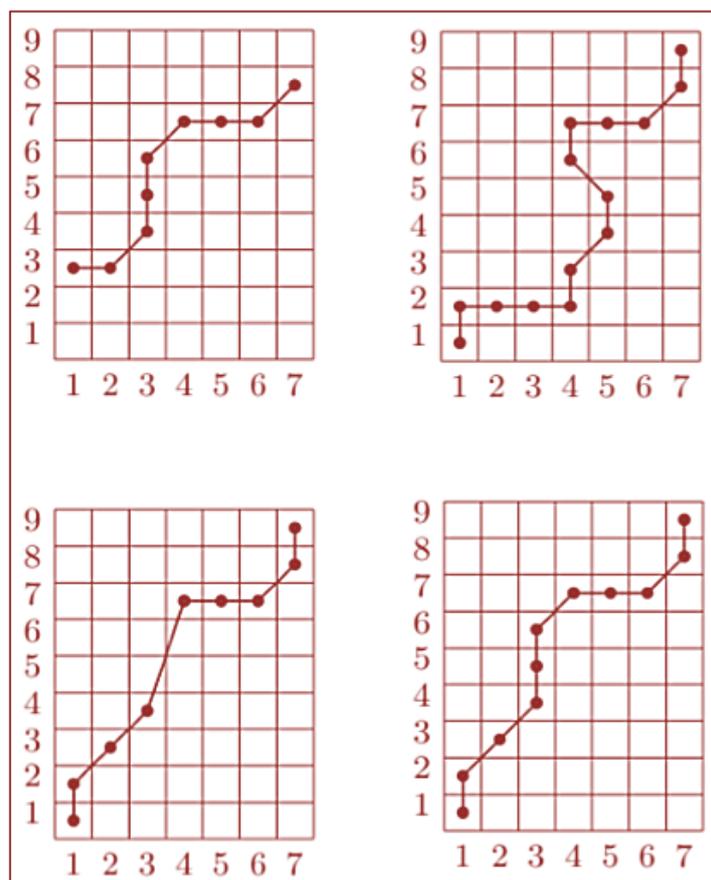
O caminho correto para a Figura 3 se encontra na Figura 4 onde se traça o caminho pelo “vale” de menores valores, começando no canto inferior esquerdo da matriz e terminando no canto superior direito, respeitando a condição de fronteira.

12 Caminho de menor custo para as Seqüências X e Y. Fonte: (Muller,2007).



Para melhor compreensão das regras, a Figura 5 ilustra quatro situações diferentes, mostrando caminhos que violam cada uma das condições separadamente e, por fim, um caminho que respeita todas.

Figura 13: Primeira imagem viola princípio 1, a segunda o princípio 2, a terceira princípio 3 e a quarta está correta. Fonte: (Muller 2007).



Na primeira imagem, o primeiro par do caminho corresponde ao item 3 da sequência na vertical e ao item 1 da sequência na horizontal, não começando no início das duas, violando a condição de fronteira. Na segunda imagem, é possível ver que depois do par (5,5), que liga o quinto item de cada sequência, o par seguinte é (4,6) retrocedendo em 1 na sequência horizontal, violando a condição de monotonicidade. Na terceira imagem, é possível ver que o maior passo em relação a sequência horizontal e vertical é sempre 1, como se pode ver nos primeiros pares do caminho: (1,1), (1,2), (2,3) e (3,4), onde o máximo que se avança em cada sequência é 1. Mas o par seguinte do caminho, (4,7) avança apenas 1 na sequência horizontal, mas avança 3 na vertical, violando a condição de tamanho do passo. Na quarta imagem é possível ver um caminho que respeita as 3 condições, pois começa com os itens iniciais de cada sequência e termina com os itens finais, os pares subsequentes do caminho não estão retrocedendo em seus índices e os passos estão sempre dentro do mesmo limite de 1.

Para fins de exemplo, o caminho ótimo para a quarta imagem da Figura 5, se dá pelos pares:

$$(1,1),(1,2),(2,3),(3,4),(3,5),(3,6),(4,7),(5,7),(6,7),(7,8),(7,9).$$

Então o custo final desse caminho se daria, utilizando distância euclidiana por:

$$C(H, V) = \sqrt{(H_1^2 - V_1^2)} + \sqrt{(H_1^2 - V_2^2)} + \sqrt{(H_2^2 - V_3^2)} + \sqrt{(H_3^2 - V_4^2)} + \sqrt{(H_3^2 - V_5^2)} + \sqrt{(H_3^2 - V_6^2)} + \sqrt{(H_4^2 - V_7^2)} \\ + \sqrt{(H_5^2 - V_7^2)} + \sqrt{(H_6^2 - V_7^2)} + \sqrt{(H_7^2 - V_8^2)} + \sqrt{(H_7^2 - V_9^2)}$$

Onde H é a sequência horizontal e V a sequência vertical, então C(H,V) é o menor custo, seguido pelo caminho ótimo, entre as duas séries e H_n e V_n são os valores dos n-ésimos elementos dessas sequências usadas para exemplificar o método.

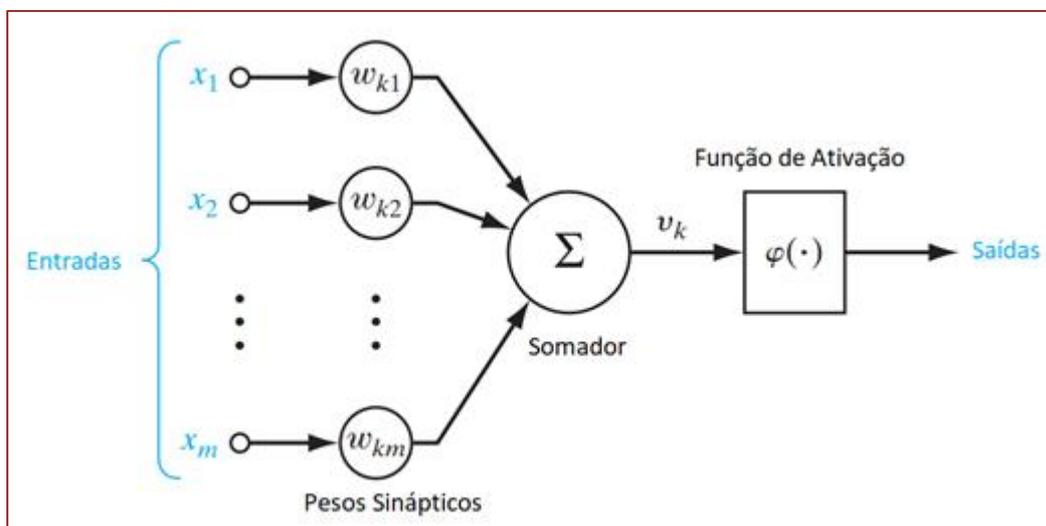
2.4. REDES NEURAIS ARTIFICIAIS

Haykin (1994) diz que uma Rede Neural Artificial é um processador massivamente distribuído e paralelo composto de unidades simples de processamento que tem a capacidade natural de armazenar conhecimento de experiências e de fazê-lo disponível para uso. Essa estrutura é inspirada no cérebro e se assemelha em dois aspectos fortes. O primeiro é que o conhecimento é adquirido pela rede por meio do ambiente em que está inserida e por meio de um método de aprendizagem. O segundo é que a força da conexão interneural, chamada de pesos sinápticos (ou apenas de pesos), são utilizados para armazenar o conhecimento adquirido.

O uso de redes neurais carrega consigo algumas vantagens, tais como a capacidade de atacar problemas não lineares e lineares, dado a capacidade do neurônio funcionar tanto de uma forma quanto da outra e a capacidade se adaptar, mudando os pesos de suas conexões frente à variações no seu ambiente.

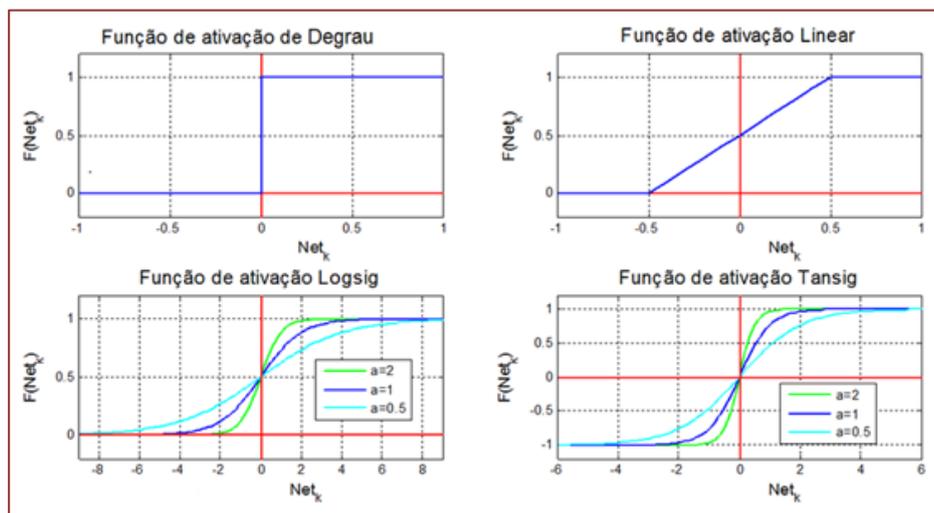
A Figura 6 mostra um esquema simples de um neurônio artificial.

Figura 14 Neurônio Artificial



Ele é composto de entradas, que são multiplicadas pelos seus respectivos pesos, então esses valores são somados e esse valor é aplicado à função de ativação, isso configura a saída do neurônio, que em uma rede neural pode estar interconectada a um ou mais neurônios e atrelada a pesos diferentes para cada um. A Figura 7 contém exemplos de funções de ativação.

Figura 15 Funções de Ativação.



Redes neurais aprendem de forma supervisionada, através de exemplos. Para poder armazenar o conhecimento obtido dessa forma nos pesos de suas conexões, algoritmos de treinamento devem ser empregados.

Um método bem conhecido é chamado de Backpropagation, que funciona com os seguintes passos extraídos e simplificados de (Haykin, 1994):

- 1-**Inicialização** - O início do treinamento se dá com valores aleatórios para os pesos das conexões entre os neurônios.
- 2- **Apresentação dos exemplos de treino** - Apresenta-se para a rede uma época de amostras para treino. Para cada exemplo nesse grupo deve ser aplicados os próximos dois passos.
- 3- **Cálculo da saída** - Aplica-se à entrada da rede a amostra em questão e compara a saída da rede, após a entrada passar por todos os pesos e funções de ativação da rede, compara-se o resultado esperado para a amostra com o resultado obtido pela saída da rede.
- 4 - **Backpropagation**- nessa etapa o erro obtido pela diferença do resultado esperado da amostra com a saída da rede é utilizado para modificar o valor dos pesos individuais das conexões, baseado na influência que ela teve para o resultado final.
- 5-**Iteração** - Realiza-se os últimos dois procedimentos para todas as amostras até que o critério de parada seja alcançado.

Para melhorar o desempenho do treinamento, esse trabalho utiliza o otimizador de Levenberg-Marquardt, que é um algoritmo que de forma adaptativa varia as atualizações dos pesos entre o que o método de gradiente descendente aponta e entre o que o método de Gauss-Newton aponta (Ranganathan, 2004).

3. METODOLOGIA

3.1. O SENSOR KINECT

O sensor Kinect foi desenvolvido pela Microsoft com o intuito de permitir que os usuários interagissem com seus corpos de maneira natural com os jogos. O sensor permite que o computador identifique a profundidade dos usuários e do ambiente, ele sabe quando as pessoas estão falando, andando e pode rastrear o posicionamento de cada pessoa em seu campo de visão. O impacto do Kinect foi muito mais extenso que apenas sua aplicação em jogos. Devido ao seu baixo custo e ampla disponibilidade, tem sido

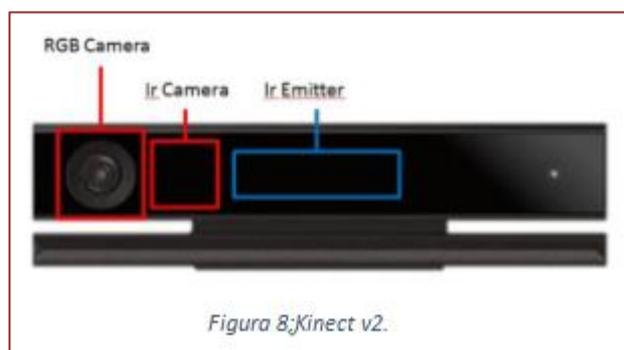
usado em pesquisas em ciência da computação, eletrônica e engenharia em atividades desde ajudar crianças com autismo até auxiliar médicos em operações (Zhang, 2012).

O Kinect é composto por vários sensores, como um projetor infra vermelho, uma câmera colorida, uma câmera infravermelha e um arranjo de quatro microfones que permitem captura corporal 3D completa, reconhecimento facial e reconhecimento de voz.

Outra das inovações do Kinect é sua capacidade de rastrear esqueletos, o que tem um grande leque de aplicações, pois o Kinect retorna a posição em um plano cartesiano de cada uma das vinte e cinco juntas do nosso corpo. Dessa forma, essa informação pode ser utilizada para reconhecimento de inúmeros gestos (Zhang, 2012).

Dentre as diversas versões disponíveis no mercado, o Kinect utilizado neste trabalho é o v2.0. Ele tem uma abertura horizontal de 70 graus e vertical de 60 graus, com uma resolução de 1920x1080 em sua câmera RGB e de 512x424 em sua câmera de profundidade, com capacidade de detecção de objetos entre 50 cm e 4.5m. Uma imagem do Kinect se encontra na Figura 8 indicando seus sensores principais.

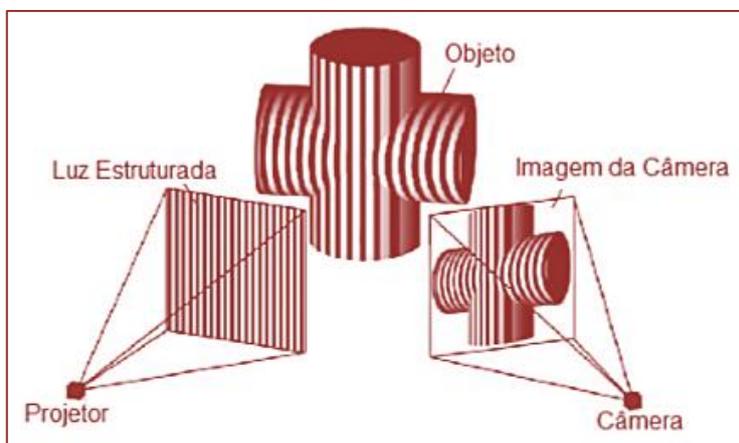
Figura 16:Kinect v2.



O Kinect utiliza a tecnologia Light Coding da empresa PrimeSens. Seu funcionamento é baseado em luz estruturada, isto é, ele emite uma luz com uma estrutura conhecida e bem definida, como linhas horizontas ou verticais, e baseado no padrão de reflexão dessa luz, é possível obter informações do ambiente com uma câmera.

Na Figura 9 é possível ver um projetor de luz estruturada, um objeto e uma câmera enxergando o padrão da luz refletida pelo objeto.

Figura 17: Esquema de detecção por luz estruturada.



Por fim, é importante ressaltar que nesse projeto será utilizado o Matlab que tem uma interação direta com o Kinect e uma grande gama de ferramentas já implementadas, sendo de grande relevância para o desenvolvimento deste trabalho.

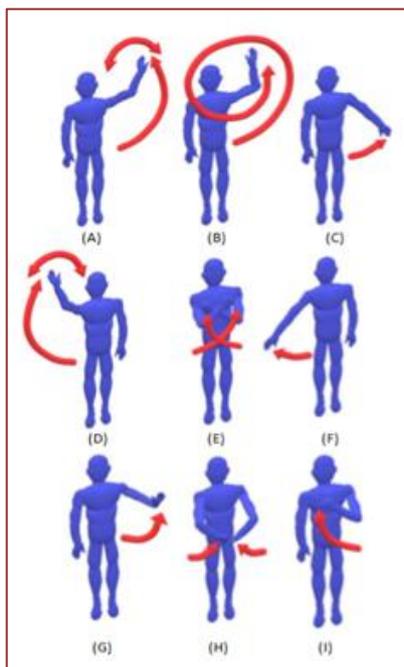
3.2. BASE DE DADOS

O foco deste trabalho é a Interação Humano-Robô para a realização de tarefas de auxílio ao usuário tais como segui-lo e ir para lugares predeterminados. Tendo em vista que os bancos de dados encontrados na internet tais como o utilizado por LI; Zhang; LIAO têm classes de ações incompatíveis para as tarefas pretendidas para este trabalho, optou-se pela criação de uma base de dados própria. No caso, nove classes de ações padrão foram escolhidas para integrar a base de dados, as quais podem ser vistas na Figura 10. Todas as ações começam da posição de descanso em pé e são feitas da seguinte forma: um gesto de “adeus” com o braço direito (A), elevar o braço direito e fazer um círculo em frente ao rosto (B), elevar o braço direito até que ele faça um ângulo de aproximadamente 45 graus com o torso (C), um gesto de “adeus” com o braço esquerdo (D), cruzar os dois braços em frente ao torso formando um X (E), elevar o braço esquerdo até que ele faça um ângulo de aproximadamente 45 graus com o torso (F), elevar o braço direito em frente de si fazendo um sinal de “pare” (G), colocar as duas mãos juntas na frente da cintura (H), elevar o braço direito com a palma direita para cima fazendo um gesto de “venha” (I).

Duas classes de ações neutras foram adicionadas, o que significa que quando elas forem identificadas o robô não receberá nenhum comando advindo dessas ações. A primeira classe contém amostras do usuário parado e a segunda com o usuário andando. Dessa forma o agente será capaz de distinguir essas ações neutras com movimentos naturais do usuário das ações padrão, não executando ação alguma quando uma delas for identificada.

Cada uma das ações padrão escolhidas para integrarem a base de dados tem uma motivação por trás. As classes A, D, G e I, são bastante intuitivas, dois sinais de “adeus”, um sinal bem claro de “venha” e um de “pare”. As classes C e F podem não parecer tão intuitivas à primeira vista, mas elas foram escolhidas pelo fato de serem um comando base para usuários do Xbox então são ações que o usuário já poderia ter feito ou visto antes, tornando-as mais familiares. As classes E e H, não são tão presentes no dia a dia, mas são simples de fazer, logo foram escolhidas. Já a ação B é mais elaborada e mais dinâmica que as outras, mas não o suficiente para ser desconfortável para os usuários. Ela foi adicionada para testar se o classificador seria capaz de distinguir uma ação mais elaborada.

Figura 18: Classes de Ação Padrão.



O Kinect é capaz de capturar quadros a uma taxa de 30 FPS (quadros por segundo), porém como esse projeto envolve o processamento de várias técnicas, como o pré processamento da imagem, a classificação da ação, os sinais de controle do robô, estimação de velocidade e desvio de obstáculos, foi definido que as ações fossem capturadas com uma taxa de 15 FPS, não colocando o Kinect no seu limite de trabalho para caso as outras técnicas tomassem uma parcela maior do processamento, a taxa de captura não seja danificada, comprometendo a classificação.

A janela de captura utilizada foi de 1,66 segundos. Isso foi obtido empiricamente, almejando uma janela grande o suficiente para fazer as ações de forma confortável, sem pressa. Em especial a ação padrão B, que é a mais complexa.

Dado a taxa de captura escolhida e a janela de captura, cada ação será representada por um total de 25 quadros (15 FPS por 1,66 segundos). Cada quadro consiste em um grupo de características, que são armazenadas em uma matriz de forma:

$$F_k = \begin{bmatrix} X_1 & Y_1 & Z_1 \\ \vdots & \vdots & \vdots \\ X_i & Y_i & Z_i \end{bmatrix}$$

onde k indica o quadro, indo até 25, e as colunas representam as coordenadas X, Y e Z da i-ésima junta do esqueleto, com i indo até 25.

Aos olhos de um observador humano, uma ação feita em diferentes posições podem ser assumidas como idênticas, o que não ocorre quando vistas pelo sensor Kinect. No caso, duas ações poderão ter coordenadas diferentes para suas juntas, mesmo que pertençam a mesma classe, simplesmente por terem sido feitas em lugares distintos. Para evitar este problema, por opção, todas as características são centralizadas em relação às coordenadas da junta do ombro esquerdo.

Após centralização, a ação completa é armazenada como a concatenação subsequente da matriz de características de todos os quadros, dado por:

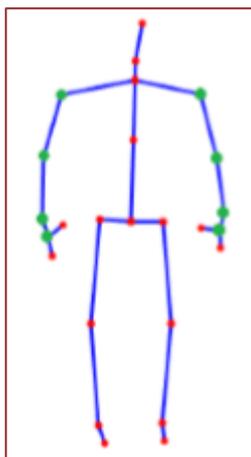
$$A_n = [F_1 \dots F_k]$$

A base de dados final do trabalho foi coletada por cinco pessoas e cada uma forneceu a mesma quantidade de amostras para cada uma das 11 classes. Essa base de dados contém 50 amostras de cada uma das classes padrão e neutras, dez por pessoa, totalizando 550 amostras. Esta redução foi possível em função da capacidade de generalização da estratégia proposta, a qual será detalhada posteriormente.

3.3. DYNAMIC TIME WARPING - DTW

Esse método consiste na comparação de séries temporais para compreender quão similares são. Este trabalho utilizou características extraídas pelo sensor Kinect para representar cada quadro da ação. Com intuito de selecionar apenas as características mais relevantes para a ação, apenas 8 juntas foram utilizadas, como mostra a Figura 11, em que os ombros, cotovelos, pulsos e mãos estão destacados no esqueleto com a cor verde. Foram escolhidas tais juntas por se tratarem das partes do corpo que mais se movem durante a realização das ações apresentadas na Figura 10.

Figura 19: Juntas de destaque para a etapa de classificação.



Cada quadro representa um esqueleto humano com suas juntas em um espaço tridimensional. A forma de armazenamento explicada na criação da base de dados, concatenando cada quadro subsequente de forma lateral, gera uma matriz onde ao se percorrer as colunas da i -ésima linha, está acompanhando a evolução temporal da posição tridimensional da i -ésima junta.

Para a classificação, tomou-se como exemplo uma amostra de cada classe. Para classificar uma amostra nova, ela é comparada com os exemplos de todas as classes, calculando sua função de custo. A classe com maior correspondência, isto é, com a menor função de custo, é associada à amostra a ser classificada.

3.4. REDES NEURAIS ARTIFICIAIS

Este trabalho propõe um método de reconhecimento de ações utilizando uma rede neural simples com um pré-processamento adequado às entradas, para que dessa forma possa identificar diferentes classes com alta precisão e uma base de dados reduzida.

De forma similar à utilizada na classificação DTW, apenas as 8 juntas da Figura 11 são utilizadas no processo de classificação, obtendo A_n com dimensão 8×75 . Na sequência, A_n é transformada em um vetor de característica, contendo seus autovalores λ , dados por $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_8$. O vetor λ é agora a informação de entrada do classificador.

A rede neural utilizada tem apenas uma camada escondida com 30 neurônios tendo suas camadas totalmente conectadas. A função de ativação usada é tangente sigmoid para a camada escondida e a função softmax para a camada de classificação. Por fim, o método de treinamento utilizado é Regularização Bayesiana com otimização de Levenberg-Marquadt.

4. SIMULAÇÕES E RESULTADOS

Para validar o classificador proposto nesse trabalho, foram feitos três testes, divididos em três testes offline (simulações), utilizando apenas simulações no computador com as informações da base de dados obtida e um teste online (experimento). Eles são:

Simulação Offline 1 - Essa simulação compara o desempenho do classificador baseline DTW com o desempenho do classificador proposto. A simulação é realizada usando a base de dados final, que foi obtida com uma distribuição homogênea das amostras de cada classe, tendo dez amostras de cada uma das cinco pessoas que participaram. Essa simulação visa uma comparação entre o desempenho dos dois classificadores num cenário que a base de dados tem distribuição homogênea das suas amostras, onde a base de dados contém mais pessoas e com um número total menor de amostras para cada classe.

Simulação Offline 2 - Essa simulação é feita utilizando uma base de dados reduzida. O classificador proposto é treinado com metade das amostras da base de dados final apenas e o seu desempenho é testado na outra metade das amostras da base de dados. Essa simulação visa analisar o desempenho do

classificador em um cenário que ele foi treinado com uma base de dados bem reduzida, tendo apenas cinco amostras de cada pessoa para cada classe.

Experimento Online Esse experimento foi feito com dois usuários reproduzindo trinta vezes cada classe em uma ordem aleatória. A classificação se deu em tempo real. Esse teste visa garantir que a base de dados obtida não esteja enviesada, analisando o desempenho do classificador com os usuários executando as ações de verdade.

Nas seções abaixo os experimentos são detalhados e seus resultados discutidos.

4.1. SIMULAÇÕES

As simulações foram realizadas usando apenas informações da base de dados obtida nesse trabalho. Todos os resultados se encontram em matrizes de confusão, onde os resultados se dão em porcentagem em relação ao total de amostras utilizadas, a última linha da tabela (FP) mostra a porcentagem de falsos positivos e a última coluna (FN) mostra a porcentagem de falsos negativos de cada classe. As colunas são as classes desejadas e as linhas as classes preditas pelo sistema inteligente.

4.1.1 SIMULAÇÃO 1

Nesta simulação utilizou-se a base de dados final obtida para esse trabalho. Ela tem uma distribuição homogênea entre suas amostras, isto é, cada um dos cinco usuários forneceu o mesmo número de amostras para cada classe. Ela contém um total de 50 amostras para cada classe (9 classes padrão e 2 classes neutras), totalizando 550 amostras.

Esta simulação tem o objetivo de comparar o desempenho do DTW com o método proposto num cenário com mais pessoas incluídas na base de dados e com uma distribuição homogênea das amostras de cada classe coletadas por cada pessoa.

Os testes com DTW tomaram um exemplo de cada classe como referência para calcular a função de custo de cada outra amostra. Para a rede neural, foi utilizada validação cruzada de 10-fold. Os resultados se encontram nas Tabelas 1 e 2. A primeira é dos resultados do DTW e a segunda do classificador proposto com RNA.

Tabela 1: Resultados das simulações do DTW para a simulação 1.

| | Classes Desejadas | | | | | | | | | | | | |
|----|-------------------|----|----|----|-----|-----|-----|----|----|-----|----|------|----|
| | A | B | C | D | E | F | G | H | I | J | K | FN | |
| A | 50 | - | - | - | - | - | - | - | - | - | - | - | - |
| B | 50 | 76 | - | - | - | - | - | - | - | - | - | - | 40 |
| C | - | - | 86 | - | - | - | - | - | - | - | - | - | - |
| D | - | - | - | 98 | - | - | - | - | - | - | - | - | - |
| E | - | - | - | - | 100 | - | - | - | - | - | - | - | - |
| F | - | - | - | - | - | 100 | - | - | - | - | - | - | - |
| G | - | - | 2 | - | - | - | 100 | - | - | - | - | - | 2 |
| H | - | - | - | - | - | - | - | 90 | - | - | - | - | - |
| I | - | 24 | - | - | - | - | - | - | 98 | - | - | - | 20 |
| J | - | - | 14 | 2 | - | - | - | 10 | 2 | 100 | 40 | 41 | - |
| K | - | - | - | - | - | - | - | - | - | - | 60 | - | - |
| FP | 50 | 24 | 14 | 2 | - | - | - | 10 | 2 | - | 60 | 87,1 | - |

Tabela 2: Resultados das simulações da RNA para a simulação 1.

| | Classes Desejadas | | | | | | | | | | | | |
|------------------|-------------------|-----|-----|----|-----|-----|-----|-----|----|-----|-----|------|---|
| | A | B | C | D | E | F | G | H | I | J | K | FN | |
| Classes Preditas | A | 96 | - | - | - | - | - | - | - | - | - | - | - |
| B | 2 | 100 | - | - | - | - | - | - | - | - | - | 2 | |
| C | - | - | 100 | - | - | - | - | - | - | - | - | - | |
| D | - | - | - | 96 | - | - | - | - | - | - | - | - | |
| E | - | - | - | - | 100 | - | - | - | - | - | - | - | |
| F | - | - | - | - | - | 100 | - | - | - | - | - | - | |
| G | 2 | - | - | 4 | - | - | 100 | - | 2 | - | - | 5,7 | |
| H | - | - | - | - | - | - | - | 100 | - | - | - | - | |
| I | - | - | - | - | - | - | - | - | 98 | - | - | - | |
| J | - | - | - | - | - | - | - | - | - | 100 | - | - | |
| K | - | - | - | - | - | - | - | - | - | - | 100 | - | |
| FP | 4 | - | - | 4 | - | - | - | - | 2 | - | - | 99,1 | |

Inicialmente é importante ressaltar a aplicação desse trabalho. Ele propõe um método de reconhecimento de ações para ser utilizado em uma aplicação de robótica social onde as ações do usuário serão as fontes de comando para o agente. Isso implica em dois pontos importantes: o primeiro é que ações neutras devem ter um rigor maior em relação à precisão, o agente estar executando um comando e confundir o usuário andando com uma ação padrão e mudar a tarefa sendo executada inviabiliza a aplicação. O segundo é que a taxa de acerto deve ser alta.

No âmbito de ações padrão, ter falsos negativos é algo extremamente indesejável, pois implica que ou o usuário pediu uma ação padrão e o agente executa outra, ou que o usuário fez uma ação neutra e o sistema irá interpretar como uma ação padrão. Para ações neutras, falsos positivos não são tão danosos, pois isso implica que ou o usuário fez uma ação neutra e o classificador a identificou como a outra, ainda sim não realizando nenhuma tarefa, ou então que uma ação padrão foi confundida com uma ação neutra, o que é indesejado, mas não tão grave quanto o contrário.

Comparando os valores das Tabelas 1 e 2 é possível observar que o DTW teve consideravelmente mais falsos negativos que o método proposto com RNA. As classes B, I, J tiveram o pior desempenho nesse aspecto.

Para a classe B, 40% das amostras classificadas como ela são falsos negativos, onde 50% das amostras da classe A são falsos positivos sendo classificadas como B, o que é bastante indesejável, pois esse cenário implica que uma ação padrão (A) será comumente interpretada como outra ação padrão (B), então o agente, em uma situação que ele deveria realizar uma tarefa, irá realizar uma outra que não foi requisitada.

A classe I teve 20% das amostras classificadas como ela como falsos negativos, onde 24% das amostras da classe B são falsos positivos sendo classificadas como I. Isso é um cenário altamente indesejável, pois além de ter uma taxa alta de falso negativo, o que, pelo mesmo motivo da análise dos falsos negativos da classe B, é bastante indesejável para a aplicação desse trabalho.

A classe J teve 41% das amostras classificadas como ela como falsos negativos, onde 40% das amostras da classe K são falsos positivos sendo classificadas como J. Isso não é tão ruim para a aplicação, pois gera uma situação em que uma ação neutra é confundida por outra, então o objetivo principal é que o agente não realize tarefa alguma e é o que acontece, mesmo confundindo as duas ações neutras. Outras parcelas importantes dos falsos negativos da classe J são os falsos positivos das classes C e H, estando em 14% e 10%, respectivamente, do seu total de amostras. Isso não é desejável pois nesse cenário, o robô deveria realizar tarefa alguma, dado que J é uma ação neutra, e ele irá realizar alguma, dado que C e H são ações padrão.

O método com RNA teve poucos falsos negativos e positivos tendo uma precisão de 99,1% e o DTW apenas 87,1%. Com isso pode ser concluído que o DTW não escalou tão bem com mais pessoas na base de dados enquanto a performance da RNA não foi danificada, tendo uma leve melhora. Além disso a RNA teve nenhum falso negativo nas classes neutras, o que sugere que aumentar o número de pessoas de duas para

cinco na base de dados surtiu um efeito positivo na generalização das classes neutras e uma leve melhoria geral de generalização.

4.1.2 SIMULAÇÃO 2

Nessa simulação utilizou-se a base de dados final obtida para este trabalho. Ela tem uma distribuição homogênea entre suas amostras, isto é, cada um dos cinco usuários forneceu o mesmo número de amostras para cada classe. Ela contém um total de 50 amostras para cada classe (9 classes padrão e 2 classes neutras), totalizando 550 amostras.

Essa simulação tem o objetivo de avaliar a capacidade de classificação da RNA com uma base de dados reduzida, usando apenas 25 amostras (5 de cada pessoa) de cada classe para seu treinamento.

A rede neural foi treinada com apenas metade da base de dados e foi aplicada na outra metade. Utilizou-se validação cruzada de 10-fold para obter os resultados dessa simulação, que se encontram na Tabela 3.

Tabela 3.: Resultados da simulação 2 para a RNA.

| | Classes Desejadas | | | | | | | | | | | | |
|------------------|-------------------|-----|----|----|----|----|----|----|----|-----|-----|------|---|
| | A | B | C | D | E | F | G | H | I | J | K | FN | |
| Classes Preditas | A | 96 | - | - | - | - | - | - | - | - | - | - | - |
| B | 4 | 100 | - | 4 | - | - | - | - | - | - | - | 7,5 | |
| C | - | - | 96 | - | - | - | - | - | - | - | - | - | |
| D | - | - | - | 96 | 4 | - | 8 | - | - | - | - | 11,2 | |
| E | - | - | - | - | 96 | - | - | - | - | - | - | - | |
| F | - | - | - | - | - | 96 | - | - | - | - | - | - | |
| G | - | - | - | - | - | - | 92 | - | - | - | - | - | |
| H | - | - | - | - | - | - | - | 96 | - | - | - | - | |
| I | - | - | - | - | - | - | - | - | 96 | - | - | - | |
| J | - | - | - | - | - | - | - | - | 4 | 100 | - | 3,9 | |
| K | - | - | 4 | - | - | 4 | - | 4 | - | - | 100 | 10,8 | |
| FP | 4 | - | 4 | 4 | 4 | 4 | 8 | 4 | 4 | - | 1 | 96,7 | |

Analisando as Tabelas 3 e 2 pode-se ver que o desempenho em relação ao treinamento utilizando a metade da base de dados e a base de dados inteira não foi tão discrepante. Houve uma leve piora no desempenho geral, caindo a média de acerto de 99,1% para 96,7%, porém pode se dizer que ainda teve um desempenho satisfatório dado o baixo número de falsos positivos e negativos e uma parcela significativa dos falsos negativos foram na classe neutra K, implicando que esses erros de classificação não irão levar o agente a fazer um comando incorreto ou não solicitado, apenas não realizar o comando que o usuário pediu.

4.2. EXPERIMENTO

Para realização do experimento, alguns pontos devem ser destacados. Por exemplo, uma aplicação de HRI requer que o agente seja capaz de identificar as ações do usuário assim que elas são realizadas. Neste caso, um gatilho foi implementado com o intuito de impedir que o algoritmo de classificação fique em execução o tempo inteiro, gerando possíveis classificações erradas. Então para sinalizar para o sistema que o usuário irá iniciar um gesto, ele deve abrir qualquer uma de suas mãos. Dessa forma, o algoritmo entende que deve começar a extrair as características para classificação. Esse gatilho é possível devido à uma funcionalidade do Kinect v2.0, que é capaz de retornar se a mão do usuário esta fechada, aberta, ou apenas com o dedo indicador e o do meio levantado.

Esse teste visa garantir que a base de dados obtida para esse trabalho não está enviesada, invalidando os bons resultados das simulações.

Para isso, duas pessoas que fazem parte da base de dados usada para o treinamento da RNA, foram requisitadas para realizar 30 vezes uma cada das 11 classes de ações. Com o intuito de evitar que ao longo do experimento, o usuário possa corrigir os erros de repetições recentes no caso de ter que fazer a mesma ação seguidas vezes, foi gerado uma lista de ordem aleatória com as 30 repetições de cada classe que cada usuário deveria fazer. Dessa forma evita ações repetidas sendo realizadas em sequência. Os resultados se encontram na Tabela 4.

Tabela 4::Resultados para os testes online

| | Classes Desejadas | | | | | | | | | | | |
|----|-------------------|------|------|-----|------|-----|------|-----|-----|-----|------|-----|
| | A | B | C | D | E | F | G | H | I | J | K | FN |
| A | 100 | 5 | - | - | - | - | 6,7 | - | - | - | - | 10 |
| B | - | 91,6 | - | - | - | - | - | - | - | - | - | - |
| C | - | - | 96,7 | - | - | - | - | - | - | - | 1,7 | 1,7 |
| D | - | - | - | 100 | - | - | - | - | - | - | - | - |
| E | - | - | - | - | 98,3 | - | - | - | - | - | - | - |
| F | - | - | - | - | - | 100 | - | - | - | - | - | - |
| G | - | - | - | - | - | - | 93,3 | - | - | - | - | - |
| H | - | - | - | - | 1,7 | - | - | 100 | - | - | - | 1,7 |
| I | - | 1,6 | - | - | - | - | - | - | 100 | - | - | 1,6 |
| J | - | - | - | - | - | - | - | - | - | 100 | - | - |
| K | - | 1,8 | 3,3 | - | - | - | - | - | - | - | 98,3 | 5 |
| FP | - | 8,4 | 3,3 | - | 1,7 | - | 6,7 | - | - | - | 40 | 98 |

É possível observar nos resultados desse experimento, que o método proposto nesse trabalho é confiável para aplicações práticas, dado sua alta taxa de acerto média de 98%. Com poucos falsos negativos, sendo que a maior parte deles é nas classes neutras J e K, o que leva a uma situação não tão grave, onde o usuário pede uma tarefa e o agente não realiza nenhuma.

5. CONCLUSÕES FINAIS

Esse trabalho apresenta um método de reconhecimento de ações baseado em redes neurais que se apoia em redução da dimensionalidade das entradas.

A validação se deu através da comparação do desempenho do método proposto com o DTW, que já é consolidado na literatura. Analisa-se a escalabilidade dos dois métodos para pessoas diferentes fazendo as mesmas ações. Testes Online foram realizados para assegurar a viabilidade de aplicação do método proposto e garantir que a base de dados não estava enviesada. A RNA final mostrou necessitar de poucas amostras na base de dados para ter um desempenho adequado para a aplicação.

Dado as necessidades particulares da aplicação em questão, onde é essencial que a taxa de acerto na classificação das ações padrões seja alta e a taxa de falsos positivos nas ações neutras seja baixa, conclui-se que o método proposto tem aplicabilidade e é eficiente, dado que ele teve um desempenho superior em todas as comparações com o DTW, e que em testes online ainda teve uma taxa de acerto alta, e poucos falsos negativos nas ações neutras.

Vale ressaltar que o sensoriamento para essa aplicação foi feito com dispositivos de baixo custo, como o Kinect, tornando mais acessível a reprodução do trabalho.

Pontos em abertos que podem ser endereçados no futuro incluem a escolha de gestos ou ações pelo usuário, isto é, criar um mecanismo que permita que a base de dados seja criada diretamente pelo usuário onde ele escolhe quais gestos irão ser atrelados a qual tarefa realizada pelo robô.

REFERÊNCIAS

- [1] Tsarouchi, P.; Makris, S.; Chryssolouris, G. Human robot interaction review and challenges on task planning and programming. *International Journal of Computer Integrated Manufacturing*, Taylor & Francis, v. 29, n. 8, p. 916-931, 2016.
- [2] Murphy, R. R. et al. Search and rescue robotics. *Springer handbook of robotics*, Springer, p. 1151-1173, 2008.
- [3] Yoshida, S. et al. Robojockey: Designing an entertainment experience with robots. *IEEE computer graphics and applications*, IEEE, v. 36, n. 1, p. 62-69, 2015.
- [4] Mies, G. Military robots of the present and the future. *Technology*, v. 9, n. 1, p. 125-137, 2010.
- [5] Yoshida, K. Achievements in space robotics. *IEEE Robotics & Automation Magazine*, IEEE, v. 16, n. 4, p. 20-28, 2009.
- [6] Monajjemi, V. M. et al. Hri in the sky: Creating and commanding teams of uavs with a vision-mediated gestural interface. In: *IEEE. 2013 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Tóquio, Japão, 2013. p. 617-623.
- [7] Goodrich, M. A.; Schultz, A. C. et al. Human-robot interaction: a survey. *Foundations and Trends R in Human-Computer Interaction*, Now Publishers, Inc., v. 1, n. 3, p. 203-275, 2008.
- [8] Park, H. W.; Howard, A. Providing tablets as collaborative-task workspace for human-robot interaction. In: *IEEE PRESS. Proceedings of the 8th ACM/IEEE international conference on Human-robot interaction*. Tóquio, Japão, 2013. p. 207-208.
- [9] Hinds, P. J.; Roberts, T. L.; Jones, H. Whose job is it anyway? a study of human-robot interaction in a collaborative task. *Human-Computer Interaction*, L. Erlbaum Associates Inc., v. 19, n. 1, p. 151-181, 2004.
- [10] L'Angle, T.; W'ORN, H. Human-robot cooperation using multi-agent-systems. *Journal of intelligent and Robotic Systems*, Springer, v. 32, n. 2, p. 143-160, 2001.
- [11] Cherubini, A. et al. Collaborative manufacturing with physical human-robot interaction. *Robotics and Computer-Integrated Manufacturing*, Elsevier, v. 40, p. 1-13, 2016.
- [12] Maurice, P. et al. Human-oriented design of collaborative robots. *International Journal of Industrial Ergonomics*, Elsevier, v. 57, p. 88-102, 2017.
- [13] Mccoll, D.; Nejat, G. Meal-time with a socially assistive robot and older adults at a long-term care facility. *Journal of Human-Robot Interaction*, Journal of Human-Robot Interaction Steering Committee, v. 2, n. 1, p. 152-171, 2013.
- [14] Feil-Seifer, D.; Mataric, M. J. Socially assistive robotics. *IEEE Robotics & Automation Magazine*, IEEE, v. 18, n. 1, p. 24-31, 2011.
- [15] Clabaugh, C. et al. Month-long, in-home case study of a socially assistive robot for children with autism spectrum disorder. In: *ACM. Companion of the 2018 ACM/IEEE International Conference on Human-Robot Interaction*. Chicago, IL, USA, 2018. p. 87-88.
- [17] Bourgeois, P.; Hess, U. The impact of social context on mimicry. *Biological psychology*, Elsevier, v. 77, n. 3, p. 343-352, 2008.
- [18] Rakita, D.; Mutlu, B.; Gleicher, M. A motion retargeting method for effective mimicry-based teleoperation of robot arms. In: *ACM. Proceedings of the 2017 ACM/IEEE International Conference on Human-Robot Interaction*. Viena, Áustria, 2017. p. 361-370.
- [19] Ishiguro, H. et al. Robovie: an interactive humanoid robot. *Industrial robot: An international journal*, MCB UP Ltd, v. 28, n. 6, p. 498-504, 2001.
- [20] Kanda, T. et al. Development and evaluation of interactive humanoid robots. *Proceedings of the IEEE*, IEEE, v. 92, n. 11, p. 1839-1850, 2004.
- [21] Chen, B. et al. Online control programming algorithm for human-robot interaction system with a novel real-time human gesture recognition method. *International Journal of Advanced Robotic Systems*, Sage Publications Sage UK: London, England, v. 16, n. 4, p. 1729881419861764, 2019.
- [22] Bodiro_ZA, S.; Stern, H. I.; Edan, Y. Dynamic gesture vocabulary design for intuitive human-robot dialog. In: *ACM. Proceedings of the seventh annual ACM/IEEE international conference on Human-Robot Interaction*. Boston, MA, USA, 2012. p. 111-112.
- [23] Eriksson, J. Hands-on robotics for post-stroke arm rehabilitation. Technical Report, 2004. Liu, R.; Zhang, X. A review of methodologies for natural-language-facilitated human-robot cooperation. *International Journal of Advanced Robotic Systems*, SAGE Publications Sage UK: London, England, v. 16, n. 3, p. 1729881419851402, 2019.

- [24] Huttenrauch, H.; Eklundh, K. S. Fetch-and-carry with zero: Observations from a long-term user study with a service robot. In: IEEE. Proceedings. 11th IEEE International Workshop on Robot and Human Interactive Communication. Berlin, Alemanha, 2002. p. 158-163.
- [25] Montemerlo, M. et al. Experiences with a mobile robotic guide for the elderly. AAAI/IAAI, v. 2002, p. 587-592, 2002.
- [26] Fong, T.; NOURBAKHSI, I.; Dautenhahn, K. A survey of socially interactive robots. Robotics and autonomous systems, Elsevier, v. 42, n. 3-4, p. 143-166, 2003.
- [27] Feil-Seifer, D.; Mataric, M. J. Designing socially assistive robotics. In: IEEE. 9th International Conference on Rehabilitation Robotics, 2005. ICORR 2005. Chicago, IL, USA, 2005. p. 465-468.
- [28] Cabibihan, J.-J.; SO, W.-C.; PRAMANIK, S. Human-recognizable robotic gestures. IEEE Transactions on Autonomous Mental Development, IEEE, v. 4, n. 4, p. 305-314, 2012.
- [29] Abdelnasser, H.; Youssef, M.; HARRAS, K. A. Wigest: A ubiquitous Wi-Fi-based gesture recognition system. In: IEEE. 2015 IEEE Conference on Computer Communications (INFOCOM). Hong Kong, China, 2015. p. 1472-1480. Murakami, K.; Taguchi, H. Gesture recognition using recurrent neural networks. In: ACM. Proceedings of the SIGCHI conference on Human factors in computing systems. Kawasaki, Japan, 1991. p. 237-242.
- [30] LI, W.; Zhang, Z.; LIU, Z. Action recognition based on a bag of 3d points. In: IEEE. 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition-Workshops. San Francisco, CA, USA, 2010. p. 9-14. Canal, G.; Escalera, S.; Angulo, C. A real-time human-robot interaction system based on gestures for assistive scenarios. Computer Vision and Image Understanding, Elsevier, v. 149, p. 65-77, 2016.
- [31] Ibanez, R. et al. Easy gesture recognition for Kinect. Advances in Engineering Software, Elsevier, v. 76, p. 171-180, 2014.
- [32] Patrona, F. et al. Motion analysis: Action detection, recognition and evaluation based on motion capture data. Pattern Recognition, Elsevier, v. 76, p. 612-622, 2018.
- [33] Sempena, S.; Maulidevi, N. U.; Aryan, P. R. Human action recognition using dynamic time warping. In: IEEE. Proceedings of the 2011 International Conference on Electrical Engineering and Informatics. Bandung, Indonesia, 2011. p. 1-5. Aggarwal, J. K.; Xia, L. Human activity recognition from 3d data: A review. Pattern Recognition Letters, Elsevier, v. 48, p. 70-80, 2014. Aggarwal, J. K.; Xia, L. Human activity recognition from 3d data: A review. Pattern Recognition Letters, Elsevier, v. 48, p. 70-80, 2014. Mitra, S.; Acharya, T. Gesture recognition: A survey. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), IEEE, v. 37, n. 3, p. 311-324, 2007.
- [34] Celebi, S. et al. Gesture recognition using skeleton data with weighted dynamic time warping. In: VISAPP (1). Barcelona, Espanha: [s.n.], 2013. p. 620-625. Raheja, J. et al. Robust gesture recognition using Kinect: A comparison between DTW and HMM. Optik, Elsevier, v. 126, n. 11-12, p. 1098-1104, 2015.
- [35] Kumar, P. et al. Coupled HMM-based multi-sensor data fusion for sign language recognition. Pattern Recognition Letters, Elsevier, v. 86, p. 1-8, 2017. Veeriah, V.; Zhuang, N.; Qi, G.-J. Differential recurrent neural networks for action recognition. In: Proceedings of the IEEE international conference on computer vision. Santiago, Chile: [s.n.], 2015. p. 4041-4049.
- [36] Ordóñez, F.; Roggen, D. Deep convolutional and LSTM recurrent neural networks for multimodal wearable activity recognition. Sensors, Multidisciplinary Digital Publishing Institute, v. 16, n. 1, p. 115, 2016.
- [37] Wang, P. et al. Depth pooling based large-scale 3-d action recognition with convolutional neural networks. IEEE Transactions on Multimedia, IEEE, v. 20, n. 5, p. 1051-1061, 2018.
- [38] Muller, M. Dynamic time warping. Information retrieval for music and motion, Springer, p. 69-84, 2007.

- [52] Haykin, S. Neural networks: a comprehensive foundation. USA: Prentice Hall PTR, 1994.
- [53] Barrientos, J.; Cataldo, E. Modelagem Estocastica da Voz e Classificação dos Sinais Obtidos Usando Redes Neurais Artificiais. 2015.
- [54] Ranganathan, A. The levenberg-marquardt algorithm. Tutorial on LM algorithm, v. 11, n. 1, p. 101-110, 2004.
- [55] Zhang, Z. Microsoft kinect sensor and its effect. IEEE multimedia, IEEE, v. 19, n. 2, p. 4-10, 2012.
- [56] Caruso, L.; Russo, R.; Savino, S. Microsoft kinect v2 vision system in a manufacturing application. Robotics and Computer-Integrated Manufacturing, Elsevier, v. 48, p. 174-181, 2017.
- [57] 3D Natives. 3D scanning through Structured Light. 2020. Disponível em: <<https://www.3dnatives.com/en/structured-light-projection-3d-scanning/>>. Acesso em: 08 de janeiro de 2020.

Capítulo 12

Criação e validação de uma Base de Dados com elementos do trânsito brasileiro para veículos autônomos

*Diego Haji Carvalho Campos
Elder de Oliveira Rodrigues
Erick Carvalho Campos*

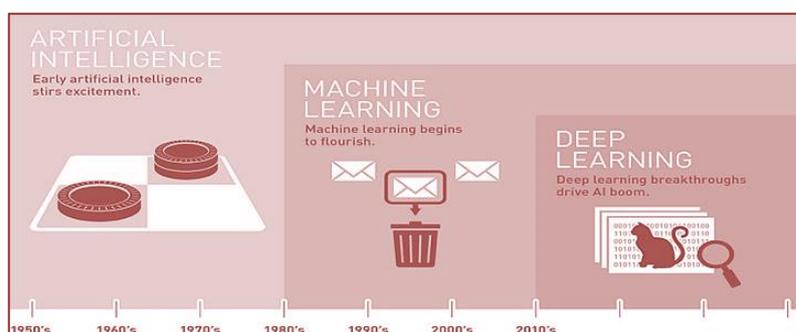
Resumo: A aprendizagem de máquina vem possibilitando o surgimento de novos produtos e recursos revolucionários, como veículos autônomos. Graças às redes neurais artificiais aplicadas à visão computacional, os sistemas conseguem reconhecer padrões de forma próxima à visão humana. Para o treinamento de redes neurais profundas (Deep Learning) é necessária uma base de dados numerosa para a compreensão de padrões visuais. Visando contribuir com as aplicações para veículos autônomos, este trabalho cria uma base de dados com alguns elementos do trânsito brasileiro. Para a validação e treinamento da base de dados foi utilizada a rede Yolo-v3 e realizados testes em diversos cenários, avaliando critérios como a quantidade de objetos detectados e a capacidade de identificação correta do tipo de objeto. Como resultado, para o ambiente virtual houve detecções de 21,5% de objetos, com 83% classificados corretamente. E para os cenários reais houve detecções de 61,8% de objetos, com 88% classificados corretamente.

Palavras-chave: Aprendizagem de Máquina; Veículos Autônomos; Redes Neurais Artificiais; Deep Learning; Yolo-v3; Base de Dados.

1. INTRODUÇÃO

Uma das tecnologias com maior destaque no ramo da computação contemporânea é Machine Learning (ML) ou aprendizado de máquina, que é um campo da inteligência artificial (IA) e fornece aos sistemas a capacidade de aprender e melhorar de forma autônoma a partir da experiência sem ser explicitamente programado. O cerne do campo, segundo Patterson and Gibson (2017) é a obtenção de descrições estruturadas a partir de dados brutos. De acordo com LeCun et al. (2015), a tecnologia de ML está inserida em muitos aspectos da sociedade moderna, como em motores de buscas na web, filtragem autônoma de conteúdo em redes sociais, nas recomendações em sites de comércio eletrônico, e está cada vez mais presente em produtos de consumo como câmeras e smartphones. Os sistemas de aprendizado de máquina são usados para identificar objetos em imagens em tempo real, interpretar linguagem falada e selecionar resultados relevantes da pesquisa de acordo com o contexto do usuário. Cada vez mais, essas aplicações fazem uso de um método de promoção de aprendizado de máquina denominada Deep Learning (DL). A figura 1, retirada de NVIDIA (2018b), apresenta de forma esquemática a relação entre IA, ML e DL.

Figura 1. Diferenças entre IA, ML, DL.



A definição de deep learning de acordo com Patterson and Gibson (2017) é um tipo de rede neural com um grande número de parâmetros e camadas em uma das arquiteturas de redes neurais básicas (redes pré-treinadas não-supervisionadas, redes neurais convolucionais, redes neurais recorrentes, redes neurais recursivas). O aspecto principal da técnica de Deep learning é que essas camadas de recursos não são projetadas por humanos: elas são construídas a partir de dados usando um procedimento de aprendizado para fins gerais LeCun et al. (2015)

De acordo com Krizhevsky et al. (2012), as abordagens atuais para o reconhecimento de objetos em visão computacional (VC) fazem uso essencial dos métodos de aprendizado de máquina, contribuindo diretamente com a evolução dos veículos autônomos. Devido a natureza visual das informações de trânsito, como as sinalizações que determinam regras de circulação das vias, os sensores convencionais como o radar não são suficientes para viabilizar um veículo efetivamente autônomo, necessitando de reconhecimento visual do ambiente para tal.

O DL como técnica computacional tem contribuído para a ampliação da capacidade de reconhecimento de objetos complexos em veículos autônomos e melhoria do tempo de resposta dos algoritmos de inteligência artificial, pois quanto maior a base de referências disponível mais apto o veículo estará para circular num ambiente real cuja variabilidade é inerente e as ações precisam ser em tempo real. Um marco nesse campo foi o lançamento do Firefly em 2015 (Waymo, 2019), o primeiro carro autônomo do Google, como visto na figura 2.

Figura 2. Firefly, o primeiro carro autônomo do Google



Segundo Rodrigues (2018) o Brasil possui atualmente universidades trabalhando em protótipos de carros autônomos, tendo em foco o desenvolvimento do veículo em si, não em uma base de dados, até o momento da pesquisa. Baseado no que foi encontrado na literatura, até o presente momento, percebe-se a necessidade de uma base de dados para qualquer trabalho dessa complexidade. Atualmente não existe uma base de dados com placas de trânsito brasileiras, como existe, por exemplo, a base de dados belga da Visics (2009) ou a alemã da Stallkamp et al. (2011), que são utilizadas geralmente para testes e validações de reconhecimento de objetos, mas não possuem a compatibilidade para o nosso país, uma vez que as placas são diferentes.

Este trabalho aborda a criação e a validação de uma base de dados de imagens feitas para o reconhecimento de alguns objetos presentes no trânsito brasileiro, expondo os métodos de criação da base de dados e a forma de validação através do uso de DL, juntamente com testes feitos em cenários virtuais e reais.

Assim, este trabalho justifica-se pela necessidade de uma base de dados, para treinamento e testes, com elementos de trânsito mais comuns no Brasil para auxiliar futuros veículos autônomos que possam vir à tráfegar no país. A forma de avaliação utilizada para a base de dados criada foi o desempenho da Yolo-v3, o estado da arte em detecção de objetos em tempo real (Redmon and Farhadi, 2018), ao ser treinada pela base.

2. MÉTODOS

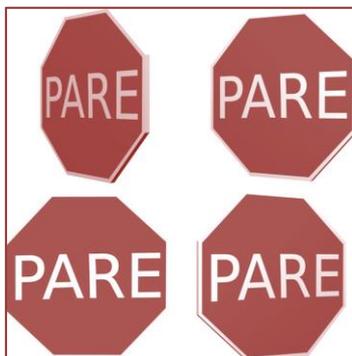
Para este trabalho foi criada uma base de dados contendo os objetos a serem detectados, sendo esses objetos divididos nas seguintes classes: cones, pedestres, bicicletas, ciclistas, veículos, motocicletas, motociclistas, semáforos, 11 placas de regulamentação, 20 placas de advertência, 6 placas de serviços auxiliares, 1 placa de identificação e 1 placa de indicação, totalizando 47 classes. Cada classe representa um conjunto de objetos que deve ser tratado como equivalentes. Apesar de existirem diferentes tipos de carros, estes são considerados uma única classe, pois não se faz necessária a distinção entre os tipos ou cores dos carros para que um sistema posteriormente produza uma instrução de reação à presença do mesmo. Por outro lado cada placa de trânsito possui um significado único, sendo necessário que um sistema gere respostas individualizadas para cada instrução percebida nas placas.

Para assegurar o aprendizado de máquina em VC é preciso que a rede neural seja abastecida com imagens do mesmo objeto em diversas condições visuais (iluminação, posição do observador, obstrução por outros objetos) para a plena compreensão dos padrões que o identificam e os diferenciam de outros elementos.

Para criar a base foram utilizadas 1200 imagens de buscadores online e 512 imagens do Google Streetview que retratavam o trânsito brasileiro em condições realistas. Foram utilizadas 2000 imagens de carros retiradas de Krause et al. (2013) e 1300 imagens de Worcester (2018) contendo semáforos. Devido à insuficiência de imagens de placas de trânsito brasileiras em nas diversas condições disponíveis abertamente para a instrução da rede neural, adotou-se a opção de criação de elementos em softwares de modelagem gráfica para aumentar a base de imagens em circunstâncias visuais diferentes. Tal abordagem é similar ao utilizado por Pen (2018), que demonstrou as vantagens de utilizar softwares de modelagem gráfica no processo de criação de imagens para treinamento em sistemas de VC. Softwares de modelagem, como o Blender3D 2.79, permitem a obtenção de imagens realistas e altamente precisas, tornando-os um valioso recurso para treinamento e validação em VC. O Blender 3D permitiu a criação de

placas diferentes, com diferentes iluminações e perspectivas em larga escala, como vistas na figura 3.

Figura 3. Imagens criadas no Blender 3D.



Após obter uma quantidade de, aproximadamente, 10000 imagens, foram aplicados filtros em todas essas imagens para que as mesmas tivessem variações para enriquecer o repertório como variação de brilho, contraste e temperatura da cor dentre outros, totalizando 79627 imagens disponíveis para posterior processamento.

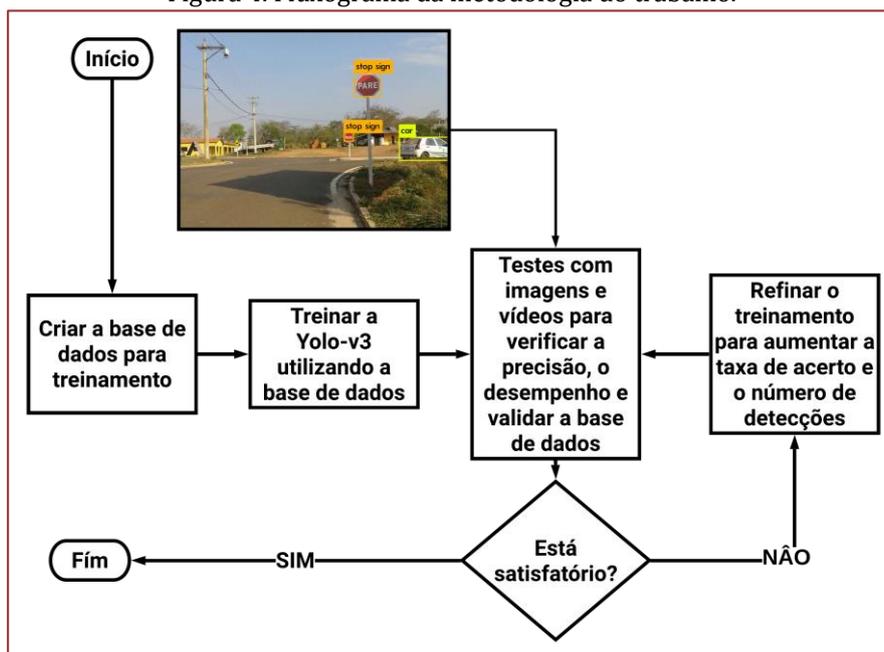
Após terminar a aquisição de imagens, foi utilizado o software Yolo mark AlexeyAB (2017) para a demarcação de objetos e rotulação em imagens em formato legível para o modelo sistema de detecção de objetos em tempo real Yolo-v3. Cada demarcação e rotulação exerce influência no treinamento, indicando o que a rede deve analisar para identificação de padrões. Toda a contraparte da demarcação se torna uma amostra negativa, que representa o que a rede neural deve ignorar, pois não faz parte do conjunto de objetos os quais deseja-se detectar. Quanto mais precisas, melhores as detecções; e quanto menos precisas, piores as detecções, podendo até mesmo não haver detecções por influência de informações inadequadas.

O modelo de rede neural convolucional (CNN) escolhida para este trabalho foi o Yolo-v3, que segundo Redmon and Farhadi (2018) é capaz de entregar alto desempenho em tempo real e com alta precisão. Para implementar a Yolo-v3 foi utilizado a API Darknet, que foi desenvolvida por Redmon and Farhadi (2018) para ser uma ferramenta otimizada na detecção de objetos em tempo real em conjunto com a Yolo-v3. O principal diferencial da Darknet em relação ao OpenCV e seu método baseado em Deep Neural Network (DNN) (biblioteca de DL do OpenCV), é sua compatibilidade com GPUs com Cuda Cores e Tensor Cores (NVIDIA, 2018a,c) visto que o uso de GPUs geram ganhos significativos de desempenho, enquanto o DNN da OpenCV se limita ao uso de CPUs. O OpenCV foi utilizado no apoio do desenvolvimento da base devido a suas bibliotecas que permitiam a visualização facilitada das saídas dos testes, no entanto não é uma biblioteca necessária para replicação dos resultados.

Foi feito o treinamento com a Yolo-v3, utilizando a extração do peso convolucional de um modelo pré-treinado, na resolução 608x608 pixels. A Yolo-v3 possui também um algoritmo de treino aleatório, que permite que diversas resoluções sejam treinadas em conjunto e 608x608 pixels foi o limite máximo estabelecido para um equilíbrio de taxa de frames e resolução para o hardware em questão.

A figura 4 contém o fluxograma simplificado da metodologia adotada durante a construção e validação da base.

Figura 4. Fluxograma da metodologia do trabalho.



Durante o treinamento foi impedido que ocorresse a retropropagação para aumentar a velocidade do treinamento e executar um ajuste fino ao invés de transferir conhecimento. As âncoras, que são os pontos iniciais de varredura da rede de treinamento para identificar os objetos também foram recalculadas, inicialmente com 79627 imagens e treinado por 500000 iterações; a partir desse momento foi adicionado ao modelo treinado uma parte da base de dados para aplicações em VC da Microsoft, COCO versão 2017 (COCO, 2018). Com essa adição de 120000 imagens, totalizando 196876 imagens, a rede neural foi treinada do ponto em que estava até 901800 iterações, com um tempo total de 543,47h. Foram utilizadas para avaliação de desempenho do treinamento da Yolo-v3, o Mean Average Precision (mAP) e o Intersection over Union (IoU), que segundo Padilha (2018), são ferramentas para a avaliação da precisão de redes neurais convolucionais.

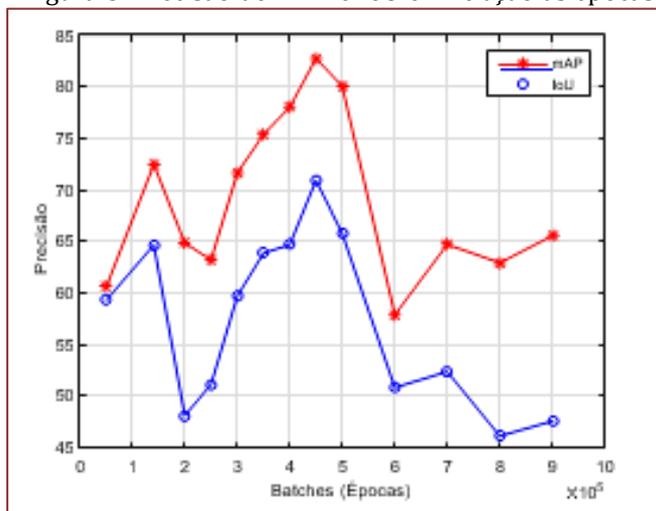
O processo de aferição do treinamento foi executado em cenários distintos onde houve a prévia contagem e rotulação de todos os elementos presentes. Para auxiliar no processo de validação do treinamento mais uma vez contou-se com a criação de cenários virtuais, a ferramenta de escolha foi a Unreal Engine 4 (UE4), que segundo Epic (2018), permite o treinamento de inteligência artificial de veículos autônomos com seus ambientes realistas. O fato da UE4 permitir o treinamento de IA's fez com que Shah et al. (2017) desenvolvesse o AirSim, uma plataforma cujo o objetivo é a pesquisa e o treinamento de Deep Learning, visão computacional e algoritmos de aprendizado reforçado para veículos autônomos, utilizando a UE4. Seguindo a mesma linha de pensamento, foram criados cenários virtuais para simular de forma controlada condições de circulação para teste da capacidade de detecção da rede neural, também utilizando a UE4.

O hardware utilizado foi um desktop com Processador Intel Core I5 6600K 4x @3.50 GHz, 32 GB de RAM DDR4 @2166 MHz, placa gráfica Nvidia RTX 2070 Gigabyte Gaming OC 8 GB GDDR6 e SSD Samsung EVO 860 250 GB. O sistema operacional foi Ubuntu 18.04 LTS com CUDA 10, cuDNN 7.4.2 e OpenCV 3.4.0.

3. RESULTADOS

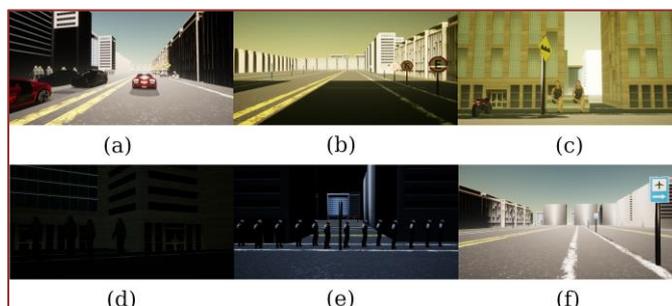
Após o treinamento, o modelo obteve um mAP final de 65.60% e um IoU de 47.63%, como visto na figura 5.

Figura 5. Precisão do mAP e IoU em relação às épocas.



A figura 6, contém exemplos de cenários virtuais que foram submetidas a testes, cujo resultados são apresentados na tabela 2.

Figura 6. Cenários virtuais. As características dos cenários são (a) há veículos, pedestres, placas e motocicletas, iluminação abundante; (b) há apenas placas de regulação e uma placa de serviço auxiliar, iluminação equivalente ao período da manhã; (c) há pedestres, motocicletas e placas de advertência, iluminação equivalente ao período da tarde; (d) há apenas pedestres, iluminação pobre; (e) há pedestres, uma placa de pare e uma placa de identificação, iluminação equivalente ao período noturno;



(f) há apenas placas de serviços auxiliares, iluminação abundante.

A tabela 1 apresenta a quantidade total de objetos presentes em cada cenário virtual dos testes. Estes objetos de testes através da biblioteca Yolo-v3, são exibidos como resultados na tabela 2 no formato total de objetos classificados em relação ao total de objetos detectados e na mesma tabela entre parênteses constam a taxa de objetos detectados em relação ao total possível.

Quando um objeto é durante um teste é dito que o objeto foi "detectado"; quando além de detectado o objeto for corretamente alocado a sua categoria é dito que ele foi "classificado".

Para testar a base em condições que simulasse o trânsito do veículo por ruas com diversas condições optou-se por criar vídeos (*cinematics*) utilizando a UE4. O vídeo foi processado pela Yolo-v3 como se fossem imagens captadas em tempo real. Na figura 6 é possível ver trechos dos diferentes cenários em que a foram realizados testes.

Na tabela 1 é possível identificar a quantidade de objetos presentes nos cenários, foi considerado a

quantidade de objetos possíveis de serem detectados em cada quadro na contagem total de objetos do cenário.

Tabela 1. Quantidade de Objetos por Cenário.

| Cenários | Quantidade total de objetos |
|----------|-----------------------------|
| a | 3247 |
| b | 302 |
| c | 900 |
| d | 969 |
| e | 2427 |
| f | 290 |

Na tabela 2 é possível identificar a quantidade de objetos detectados corretamente, ou seja, o objeto classificado com a classe correta. Desse montante estão excluídos os falsos negativos (quando um objeto pertencente a uma classe presente na base de dados não é identificado como tal) e inclusos os falsos positivos (quando objetos pertencentes a uma classe presente na base de dados e identificado equivocadamente como outro objeto). Na mesma tabela estão apresentados os valores de detecções máximas em cada cenário, permitindo identificar a taxa de sucesso.

Tabela 2. Quantidade de Acertos e Total de Detecções por Cenário.

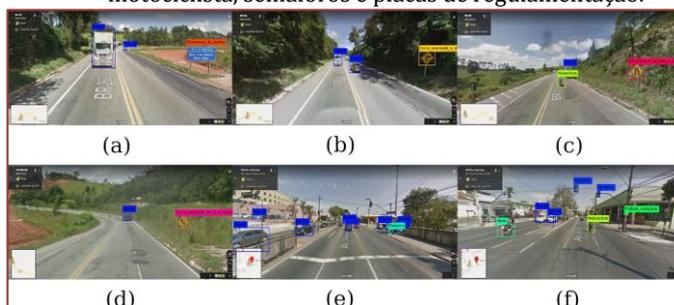
| C | M | T | N | MI | PI |
|---|-----------------|-----------------|---------------|-----------------|---------------|
| a | 737/737(0,23) | 520/520(0,16) | 328/332(0,1) | 1458/1459(0,44) | 186/188(0,05) |
| b | 37/70(0,12) | 64/65(0,21) | 25/38(0,08) | 72/81(0,23) | 11/11(0,04) |
| c | 72/73(0,08) | 69/71(0,08) | 44/45(0,05) | 119/122(0,13) | 56/56(0,06) |
| d | 564/570(0,58) | 620/631(0,64) | 106/106(0,11) | 615/617(0,63) | 471/472(0,49) |
| e | 1186/1186(0,49) | 1160/1160(0,48) | 679/679(0,28) | 1010/1010(0,42) | 791/791(0,33) |
| f | 0/0(0) | 0/0(0) | 0/1(0) | 1/1(0) | 0/0(0) |

Condições do cenário: M – Manhã; T – Tarde; MI – Muita Iluminação; PI – Pouca Iluminação, C - Cenários. Entre parênteses a relação do total de detecções com a quantidade de objetos por cenário.

A figura 7 contém exemplos de cenários reais que foram submetidas a testes, cujos resultados são apresentados na tabela 3.

Nos cenários reais foram utilizadas imagens retiradas do Google Streetview, pois estas representam melhor o trânsito brasileiro. Importante salientar que, por restrições de software, o Google Street view permite captar imagens diurnas e não noturnas. Os cenários reais, utilizando somente imagens, são exibidos, na figura 7.

Figura 7. Cenários reais. As características dos cenários são(a), três veículos e uma placa de identificação; (b), dois veículos e uma placa de advertência; (c), dois veículos, um motociclista e uma placa; (d), dois veículos, um motociclista e uma placa; (e), há diversos veículos, um motociclista e semáforos; (f), há diversos veículos, um motociclista, semáforos e placas de regulamentação.



Na tabela 3, é possível ver os resultados obtidos nos cenários reais, considerando a quantidade de objetos disponíveis, a quantidade de detecções realizadas, o percentual de detecções, o percentual de classificações e o tempo de detecção.

Tabela 3. Tabela demonstrando os resultados dos cenários reais.

| C* | TO | QD | PD | PC | T(ms) |
|----|----|------|------|-------|-------|
| a | 4 | 3/4 | 75% | 66,6% | 31 |
| b | 3 | 3/3 | 100% | 100% | 29 |
| c | 4 | 3/4 | 75% | 100% | 30 |
| d | 4 | 2/4 | 50% | 66,6% | 29 |
| e | 30 | 9/30 | 30% | 100% | 31 |
| f | 17 | 7/17 | 41% | 100% | 32 |

C – Cenários; TO – Total de objetos; QD – Quantidade de detecções;

PD – Percentual de detecções; PC – Percentual de classificações;

T - Tempo total por imagem em milissegundos

4. DISCUSSÕES

Em relação ao ambiente virtual houve uma detecção de 21,5% de objetos, o qual 83% destes foram classificados corretamente. É possível perceber também na tabela 2 que a iluminação possui uma grande influência na capacidade de detecção da rede neural. Como demonstrado, cenários com melhor iluminação possuem mais objetos detectados, enquanto cenários com iluminação mais precária possuem piores resultados.

A condição de baixa luminosidade é também um desafio para a visão humana, o que é natural devido à perda de informação visual. Os resultados para essas condições representam uma oportunidade de destaque aos veículos autônomos por permitirem a incorporação de equipamentos de visão noturna, tornando a circulação em condições de baixa luminosidade mais segura em veículos autônomos do que em veículos convencionais.

Em relação ao ambiente real houve uma detecção de 61,8% de objetos, o qual 88% destes foram classificados corretamente. Em relação a rodovias, onde geralmente há um número menor de elementos a serem detectados por quadro, o Yolo-v3 consegue bons resultados.

Para uma comparação do desempenho da base com outros trabalhos, Martins (2017) faz uso de métodos do OpenCV para detecção de 5 placas de regulamentação brasileiras com uma rede neural perceptron de múltiplas camadas, utilizando 250 imagens para treino com um tempo total de 7,5h de treinamento. O autor conseguiu atingir uma classificação de 96.6% na classificação e um tempo de predição de 93 ms com imagens.

O trabalho de Sobrinho et al. (2016) faz uso de DL para a detecção de 19 placas de trânsito brasileiras, sendo 17 de regulamentação e 2 de advertência. Foram utilizadas 1300 imagens sintéticas, sendo 533 para treinamento, 267 para validação e 500 para testes. Seu modelo obteve uma classificação de 99.98%, mas não foram testadas imagens de cenários reais.

Em comparação com trabalhos relacionados, este trabalho consegue uma precisão geral de 61,8% na classificação, com um conjunto maior de placas de trânsito com uma média de 30 fps.

O presente trabalho representa uma expansão do alcance das bases já desenvolvidas para o trânsito brasileiro, totalizando 39 classes. Valor bem acima das 19 classes da base desenvolvida por Sobrinho et al. (2016) e das 5 classes desenvolvidas por Martins (2017). O custo da expansão é a queda na taxa de precisão quando comparado aos outros trabalhos.

Suspeita-se que melhores resultados serão obtidos se ao invés de incorporar o modelo que estava sendo construído a um modelo já treinado (como foi feito nesse trabalho unificando parcialmente a COCO) se a base de imagens original for utilizada em conjunto com a base desenvolvida nesse trabalho para um treinamento único.

Foi possível explorar uma conjunção de outras tecnologias atuais para suprir restrições típicas da criação de uma base de dados, como a necessidade de grande volume de imagens para o treinamento eficiente. A solução foi a utilização de softwares de modelagem gráfica, que em seu estágio atual permitem a representação fidedigna de cenários reais.

A construção de cenários virtuais para treinamento de veículos autônomos tem sido adotada também por

empresas (Epic, 2018) despontando como uma tendência para desenvolvimento econômico de novas tecnologias.

Todo o material produzido neste trabalho encontra-se disponível em: <https://github.com/diegothaji/Base-de-dados-Transito-Brasileiro>

5. CONCLUSÃO

Este trabalho criou uma base de dados e a treinou para validá-la, obtendo uma detecção de 21,5% de objetos, o qual 83% destes foram classificados corretamente no cenário virtual; e uma detecção de 61,8% de objetos,

o qual 88% destes foram classificados corretamente no cenário real.

A API Darknet consegue uma taxa média de 30 FPS com uma resolução interna da rede de 608x608, com o hardware utilizado, o que significa que hardwares melhores conseguem uma taxa de quadros maior, possibilitando até mesmo aumentar a resolução interna da rede, que aumenta a capacidade de detecções, mantendo o mesmo desempenho. Em relação a detecção em imagens, a API consegue um tempo médio de 30 ms. Durante o treinamento e os testes foram constatadas algumas limitações:

- A biblioteca Yolo-v3 não consegue rastrear a movimentação dos objetos de um quadro a outro como faz o processamento de visão em seres humanos, impedindo que o cálculo de velocidade e a projeção de posição seja possível;
- Também em decorrência da detecção quadro a quadro sem rastreamento do objeto é que de um quadro para o outro o mesmo objeto pode deixar de ser detectado, principalmente quando a imagem apresenta elevada densidade de objetos;
- A geração e análise de relatórios não está implementada de forma suficiente nas ferramentas utilizadas, demandando ajustes próprios nas ferramentas capazes de analisar a massa de dados produzida.

A base de dados resultante deste trabalho representa um dos primeiros esforços de mapeamento da sinalização de trânsito brasileira para utilização em VC, algo essencial para viabilizar que veículos autônomos e similares possam trafegar nas vias. Neste contexto, trabalhos podem surgir como: expansões da base de dados e aprimoramentos para produzir resultados ainda melhores tanto em abrangência quanto na precisão da detecção de objetos.

Como proposta de trabalho futuro, tem-se o aperfeiçoamento da base e a implementação de capacidade de rastreamento de objetos entre quadros.

REFERÊNCIAS

- [1] AlexeyAB (2017). Yolo mark. URL https://github.com/AlexeyAB/Yolo_mark.
- [2] Coco (2018). Coco - common objects in context. URL <http://cocodataset.org/#download>.
- [3] Epic (2018). Unreal engine 4 - ia. URL <https://tinyurl.com/y3jxkm3m>.
- [4] Krause, J., Stark, M., Deng, J., and Fei-Fei, L. (2013). 3d object representations for fine-grained categorization. In 4th International IEEE Workshop on 3D Representation and Recognition (3dRR-13). Sydney, Australia.
- [5] Krizhevsky, A., Sutskever, I., and Hinton, G.E. (2012). Imagenet classification with deep convolutional neural networks. In Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1, NIPS'12, 1097–1105. Curran Associates Inc., USA. URL <http://dl.acm.org/citation.cfm?id=2999134.2999257>.
- [6] LeCun, Y., Bengio, Y., and Hinton, G.E. (2015). Deep learning. Nature, 521(7553), 436–444. doi:10.1038/nature14539. URL <https://doi.org/10.1038/nature14539>.
- [7] Martins, M.A. (2017). Identificação de placas de trânsito através da classificação de imagens usando redes neurais artificiais. URL <https://repositorio.ufu.br/bitstream/123456789/19551/1/IdentificacaoPlacasTransito.pdf>.
- [8] Nvidia (2018a). Cuda zone. URL <https://developer.nvidia.com/cuda-zone>.
- [9] Nvidia (2018b). Fundamentals of deep learning for computer vision. URL <https://courses.nvidia.com/courses/course-v1:DLI+C-FX-01+V2/about>.
- [10] Nvidia (2018c). Nvidia cudnn. URL <https://developer.nvidia.com/cudnn>.

- [11] Patterson, J. and Gibson, A. (2017). Deep Learning: A Practitioner's Approach. O'Reilly Media, Inc., 2nd edition.
- [12] Pen, M. (2018). Blender for computer vision machine learning. URL <https://blog.thepixelary.com/post/174286685782/blender-for-computer-vision-machine-learning>.
- [13] Redmon, J. and Farhadi, A. (2018). Yolov3: An incremental improvement. CoRR, abs/1804.02767. URL <http://arxiv.org/abs/1804.02767>.
- [14] Rodrigues, L. (2018). Carros autônomos já come, cam a virar realidade. URL <https://tinyurl.com/y34olr9y>.
- [15] Shah, S., Dey, D., Lovett, C., and Kapoor, A. (2017). Airsim: High-fidelity visual and physical simulation for autonomous vehicles. In Field and Service Robotics. URL <https://arxiv.org/abs/1705.05065>.
- [16] Sobrinho, M.V.O., Menezes, M.C., Nascimento, C.G.M., and Junior, G.B. (2016). Reconhecimento de sinais de trânsito utilizando deep learning. URL <http://sistemas.deinf.ufma.br/anaisjim/artigos/2016/201622.pdf>.
- [17] Stallkamp, J., Schlipsing, M., Salmen, J., and Igel, C. (2011). The German Traffic Sign Recognition Benchmark: A multi-class classification competition. In IEEE International Joint Conference on Neural Networks, 1453–1460.
- [18] Visics (2009). Traffic sign recognition. URL http://www.vision.ee.ethz.ch/~timofter/traffic_signs/. Waymo (2019). Waymo journey. URL <https://waymo.com/journey/>.
- [19] Worcester, Polytechnic, I. (2018). Wpi datasets. URL <http://computing.wpi.edu/dataset.html>.

Capítulo 13

Desenvolvimento de um software PIMS com comunicação OPC e acesso por navegador Web

Silas Martins Sousa

Michelle Mendes Santos

Isabel Ramos Henriques Oliveira

Resumo: Os sistemas de automação detêm uma gama de informações inerentes ao processo industrial. Essas informações podem ajudar os setores corporativos da indústria na tomada de decisões estratégicas. O presente trabalho trata do desenvolvimento de uma ferramenta de obtenção e armazenamento de dados dos sistemas de automação, conhecido como PIMS. O software desenvolvido neste trabalho utiliza o Padrão OPC permitindo a comunicação com os principais fabricantes de CLP. Essas informações são armazenadas em um banco de dados SQL Server. Por meio de um Web Site, também desenvolvido no trabalho, diversos setores da indústria podem visualizar os dados em gráficos e tabelas, gerar relatórios de dados e exportá-los nos formatos PDF, DOC e XLS. O software propõe uma solução economicamente viável para empresas de pequeno e médio porte no gerenciamento das informações do processo. Os testes mostraram que o software foi capaz de obter as informações e reproduzir os valores em uma interface Web.

Palavras-chave: Banco de dados; CLP; Padrão OPC; PIMS; SQL Server.

1. INTRODUÇÃO

A informação é uma ferramenta importante para gerenciar os ativos de uma planta industrial como a qualidade do produto, quantidade de matéria prima e parâmetros do processo de produção. Segundo STAIR (2002) “O valor da informação está diretamente ligado à maneira como ela ajuda os tomadores de decisões a atingirem as metas da organização”.

Com o advento da indústria inteligente, chamada “Indústria 4.0”, a informação assume papel principal integrando todos os setores de uma indústria a fim de alcançar o aumento da produção, redução de custos, eficiência energética e visão nas mudanças tecnológicas. Para isso a plataforma técnica deve estar estruturada com redes industriais, sistemas de otimização e banco de dados (JAZDI, 2016).

Por meio de informações os setores corporativos de uma indústria podem embasar suas decisões em dados reais do processo, que estão disponíveis em sua tela de computador ou até mesmo dispositivos *mobile* (SOUSA, 2014).

Cada setor da empresa tem um interesse específico em determinada informação. A manutenção precisa monitorar a vida útil dos motores com base nos dados de vibração e temperatura. Para o setor de produção, parâmetros como a qualidade e o consumo de matéria prima são essenciais para seu trabalho. Os dados de processo podem ser utilizados para medir índices de produção como é o caso do *Overall Equipment Effectiveness* (OEE) que mede a eficiência de equipamentos levando em conta três critérios: disponibilidade, desempenho e qualidade (KAO, 2016).

É imprescindível que os setores corporativos se comuniquem com o chão de fábrica, para isso são utilizadas as redes industriais que permitem a troca de informação. A Manufatura Inteligente é a utilização dos dados de produção em benefício dos setores corporativos de uma empresa (DANG, 2007).

A pirâmide da automação, Figura 20, mostra três níveis diferentes de informações. O primeiro é o nível de controle e supervisão, onde estão presentes os equipamentos que interagem diretamente com o processo, como instrumentação, CLP (Controlador Lógico Programável) e SCADA (*Supervisory Control and Data Acquisition*). O segundo nível é representado pelas ferramentas de gerenciamento da produção, PIMS (*Process Information Management System*) e MES (*Manufacturing Execution System*). PIMS é um sistema para armazenamento de informações do processo com ferramentas para análise de desempenho (CARVALHO, 2003). O MES é um sistema que auxilia no planejamento da produção. O último nível é representado pelo ERP (*Enterprise Resource Planning*), que engloba os diversos setores da empresa como estoque, financeiro, logística, produção e administração, auxiliando no gerenciamento de negócios.

Figura 20 - Pirâmide da automação com três níveis de informações do processo.



Adaptado de (SEIXAS, 2005).

A Figura 21 apresenta o fluxo de informações através dos níveis da pirâmide de automação. Quanto mais elevado é o nível na pirâmide mais filtrados e informativos ficam os dados, conseqüentemente o volume de dados diminui. Desta forma os dados brutos são transformados em informação útil, gerando conhecimento.

Figura 21 - Concentração dos dados em uma empresa e quantidade de dados.



Adaptado de (SEIXAS, 2005).

Muitas indústrias de pequeno e médio porte ainda possuem sua solução de automação voltada apenas a CLP e SCADA. Porém, cada vez mais, essas indústrias têm se mostrado a favor da manufatura inteligente para conseguirem melhores resultados. Os *softwares* existentes no mercado que desempenham essa função, como por exemplo, o InfoPlus e PI System, não são acessíveis a essas indústrias. Surge, então, uma lacuna no mercado com a necessidade de um *software* PIMS de baixo custo, que ofereça o suporte necessário para obter, armazenar e mostrar os dados do processo.

Até a década de 1990, cada fabricante de dispositivos para automação possuía *drivers* proprietários para realizar a comunicação entre seus dispositivos. Isso dificultava a utilização de dispositivos de diferentes fabricantes em um mesmo sistema. Para resolver esse problema empresas deste seguimento se uniram e criaram um protocolo chamado de OPC (*OLE for Process Control*). Com um protocolo padrão reduziram-se custos e tempo, além de promover a interoperabilidade (SHIMANUKI, 1999). A comunicação OPC é o padrão utilizado por mais de 300 fabricantes de equipamentos para automação e sistemas de controle (TAN, 2007).

A

Tabela 1 mostra os valores de venda de alguns PIMS utilizados em sistemas de automação. Todos os PIMS mostrados têm a função de comunicação OPC e geram relatórios de dados.

Tabela 1 - Preços e funções dos historiadores PIMS do mercado.

| Produto (Empresa) | Preço |
|-----------------------------------|--|
| Infoplus 21 (Aspentech) | R\$ 120.000/ano |
| PI System (OSI Software) | R\$ 600.000 (1º ano) + R\$ 120.000/ano |
| Wonderware Historian (Wonderware) | R\$ 20.995 (só a licença) |

Fonte: (CONTROL, 2014) e (TIERNEY, 2013).

Os valores referentes ao Infoplus 21 (da empresa Aspentech) e PI System (da OSI Software) contemplam a licença e a instalação/manutenção. A empresa Wonderware não presta os serviços de instalação/manutenção do PIMS, portanto o valor de venda do Wonderware Historian se refere apenas à licença comercial.

O objetivo deste trabalho é mostrar o desenvolvimento de um sistema de aquisição dos dados do processo industrial e seu armazenamento em banco de dados, disponibilizando-os aos gestores por meio de gráficos, tabelas e relatórios. Para testar o *software* criado neste trabalho foi utilizada uma planta didática de controle de temperatura e nível de tanques.

2. DESENVOLVIMENTO DO SOFTWARE PIMS

O sistema desenvolvido é composto de duas partes. A primeira é um *software* executável cuja função é realizar a comunicação com os sistemas de automação por meio do padrão OPC e obter os dados do processo (Cliente OPC). Esse *software* também deve armazenar os dados em um banco de dados. A segunda parte do sistema é um *Web Site* utilizado para visualização dos gráficos e tabelas.

2.1 EXECUTÁVEL LOCAL: SERVIDOR DO SOFTWARE PIMS

A primeira etapa de desenvolvimento do sistema consiste em criar um Cliente OPC, assim será estabelecido a comunicação com um Servidor OPC para buscar os dados do processo. Para criar aplicações com comunicação OPC é necessário ter profundo conhecimento das regras do padrão, contidas nas cartilhas da OPC Foundation (OPC FOUNDATION, 2018). Para facilitar o uso do OPC, desenvolvedores traduziram esse conjunto de normas e especificações em bibliotecas. Essas bibliotecas são disponibilizadas no formato *Dynamic Link Libraries* (DLL) e assim podem ser utilizadas mais facilmente, diminuindo o tempo de desenvolvimento da aplicação. As bibliotecas utilizadas para interpretar o padrão OPC são:

- OpcNetApi.dll;
- OpcNetApi.Com.dll;
- OpcNetApi.Xml.dll.

Essas bibliotecas foram disponibilizadas no site da Mesta Automation (MESTA, 2014). Elas foram desenvolvidas para a linguagem C# e para seu correto funcionamento devem ser declaradas no preâmbulo do código: *using Opc.Da*.

O Padrão OPC classifica seus objetos em Item (que contém a informação de uma variável de processo), Grupo (conjunto de itens) e o Servidor (fonte de dados). Durante a conexão o Cliente OPC cria um grupo de leitura de itens. Cada item deve ser adicionado ao grupo OPC para que sua leitura seja feita periodicamente. Também é necessário indicar o tipo de dado como, por exemplo, inteiro, binário, decimal ou texto. A cada período de atualização do Cliente OPC a função de tratamento dos dados é chamada. Essa função é responsável por dar algum destino aos dados obtidos. No caso do executável local, a cada atualização os dados são armazenados no banco de dados SQL (MICROSOFT, 2018).

Para realizar varreduras periódicas dos valores dos itens OPC é utilizado um temporizador (*timer*). Ele especifica a taxa de atualização dos dados. Cada aplicação pode ter uma necessidade diferente quanto ao tempo de atualização. Caso a taxa seja muito alta o desempenho do sistema pode ficar comprometido, bem como a capacidade do armazenador de dados.

Ao adicionar um item OPC o executável local cria uma tabela no banco de dados para armazenar as informações dessa variável, contendo as colunas *data time* e *valor* (conforme a Tabela 2). O banco de dados utilizado foi o Microsoft SQL Server.

Tabela 2 - Tabela do banco de dados para armazenar informações do item nível.

| data time | valor |
|---------------------|-------|
| 03/01/2018 09:15:09 | 78,90 |
| 03/01/2018 09:15:10 | 78,92 |
| 03/01/2018 09:15:11 | 79,04 |
| 03/01/2016 09:15:12 | 78,98 |

Para realizar as ações envolvendo o banco de dados são utilizados comandos de consulta (*queries*). Para conectar ao banco de dados é utilizado o comando SQL: *SqlConnection con = new SqlConnection("Data Source=ServidorSQL; User ID=Login; Password=Senha")*, em que *con* é a variável de conexão e o texto entre parênteses é a *string* de conexão. É nessa *string* que são passados os parâmetros de Nome do Servidor SQL, Login e Senha do Usuário.

O executável local foi desenvolvido no programa Visual Studio e possui a programação do Cliente OPC e Banco de Dados. As telas de navegação são utilizadas para configurar o servidor do *software* PIMS.

A Figura 22 mostra a tela de configuração do banco de dados, onde é possível testar a conectividade com o banco. Na parte inferior da Figura 22 pode-se observar a opção "Criar banco de dados e Tabelas". Esse comando cria todas configurações necessárias para o correto funcionamento do *software* PIMS, evitando que o usuário configure de forma incorreta algum parâmetro do banco de dados.

Figura 22 - Tela de Configuração de Conexão ao Banco de Dados.

Na Figura 22 também é possível observar o menu de acesso às outras telas do executável local:

- Conexão com o Servidor OPC;
- Itens OPC;
- Servidor OPC;
- Controle de acesso e logins;
- Tutorial de configuração do Servidor do *software* PIMS.

Por meio das telas, o usuário pode realizar as configurações do executável local conforme seu processo industrial. A tela “Tutorial do Programa” funciona como uma ajuda na configuração do *software* PIMS, para usuários que ainda não estão familiarizados com o executável local.

2.2 WEB SITE DE VISUALIZAÇÃO DOS DADOS

O *Web Site* do *software* PIMS acessa a base de dados SQL e apresenta os dados do processo ao usuário por meio de gráficos e tabelas. Para isso o usuário irá escolher as variáveis e também o período de visualização da informação.

O *Web Site* também foi feito em Visual Studio e conta com três ambientes de programação: Código, Visual e HTML. No ambiente de código é configurado o acesso ao banco de dados. O ambiente Visual é utilizado para desenvolver sua estrutura visual (*layout*). Para configurar as funcionalidades do *Web Site*, como a plotagem de gráficos e tabelas, é utilizado o ambiente de HTML. A

Figura 23 mostra a tela de visualização dos gráficos.

Figura 23 - Tela de visualização de gráficos do Web Site do software PIMS.



Por meio da interface gráfica é possível exibir gráficos de linha, coluna e de pizza. Outra informação importante que pode ser visualizada é a porcentagem de tempo de parada de uma máquina ou equipamento.

3. SISTEMA DE TESTE

Para fornecer dados ao *software* PIMS foi utilizada uma planta didática de controle de temperatura e nível de tanques, presente no laboratório de automação Industrial do Instituto Federal de Minas Gerais (IFMG) campus Formiga, conforme Figura 24.

Figura 24 - Planta didática de controle de temperatura e nível de tanques.



Foi utilizado como controlador do processo o CLP CompactLogix 5370 L2 (Rockwell Automation), o qual pode ser observado na Figura 25.

Figura 25 - CLP modelo CompactLogix5370 L2 da empresa Rockwell Automation.

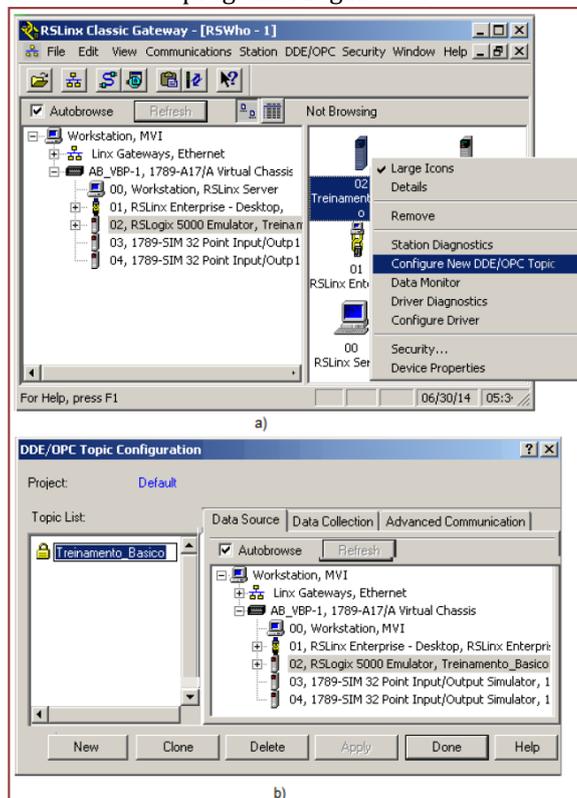


Fonte: (ROCKWELL, 2018).

O programa utilizado para promover a comunicação entre o CLP e o computador é o RSLinx da empresa Rockwell Automation. Este *software* disponibiliza os dados do CLP em padrão OPC e, portanto, é o Servidor OPC utilizado no sistema de teste.

A configuração de uma aplicação como fonte de dados OPC consiste em criar uma conexão (Figura 26a), associando o programa do CLP com o endereço da CPU do CLP (*path*). A Figura 26b mostra o programa do CLP “Treinamento Básico” (à esquerda da Figura 26b) sendo associado ao CLP que está no caminho: “02, RSLogix 5000 Emulator, Treinamento Basico” (à direita da Figura 26b).

Figura 26 - Configuração do Servidor OPC: a) Adicionando Conexão OPC e b) Associando o CLP ao programa Logix5000.



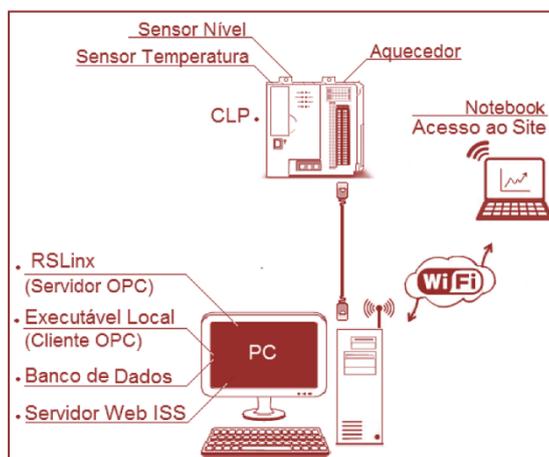
3.1 CONFIGURAÇÃO DE REDE DO SISTEMA DE TESTE

Foi montada uma configuração de rede para testar o *software* PIMS desenvolvido neste trabalho. A rede é constituída de três sistemas:

- CLP (Processo industrial);
- PC Servidor (Configuração do *software* PIMS);
- Visualização do *software* PIMS.

A primeira parte da rede é o CLP. Ele realiza a aquisição dos dados do processo industrial por meio de sensores. A segunda parte é um computador (PC), utilizado para as funções de Servidor OPC, Cliente OPC, Banco de Dados e Servidor IIS (hospeda o *Web Site* do *software* PIMS). A terceira parte é composta pelos dispositivos de acesso ao *Web Site*, que no caso do sistema de teste é um *notebook*. As três partes podem ser observadas no diagrama da Figura 27.

Figura 27 - Sistema de teste e configuração da rede.



A configuração de rede utilizada pode ser alterada para aplicação em um processo industrial, permitindo utilizar, por exemplo, o Servidor OPC e o Cliente OPC em um Computador e o Banco de dados e o Servidor IIS em outro computador.

4. ANÁLISE ECONÔMICA DO SOFTWARE PIMS

Comparar historiadores de processo não é uma tarefa fácil, pois muitos fatores devem ser levados em conta como, por exemplo, as funcionalidades básicas de um historiador na coleta, compressão, armazenamento e recuperação de dados, as ferramentas funcionais incorporadas ao historiador e também a utilização dos padrões da indústria como a comunicação OPC. A

Tabela 1 (na Seção 1) mostrou os preços dos historiadores PIMS do mercado.

O *software* PIMS desenvolvido neste trabalho possui características compatíveis com os grandes historiadores do mercado e foi capaz de oferecer soluções como: obtenção de dados por padrão OPC; armazenamento das informações em banco de dados; sem limitação de *tags*; visualização de gráficos e tabelas; relatórios nos formatos PDF, XLS e DOC e visualização dos dados pelo navegador Web. Essas características mostram que o *software* PIMS desenvolvido é tecnicamente competitivo com os seus principais concorrentes.

Além das funcionalidades um fator de extrema relevância para as empresas que adquirem esse tipo de produto é o preço a se pagar por ele. O custo de desenvolvimento do *software* PIMS consiste no tempo de engenharia gasto no seu desenvolvimento. Considerando o piso salarial de um Engenheiro como 8,5 vezes o salário mínimo (CONFEA, 1994) e o salário mínimo na data atual como R\$ 1.039,00 (BRASIL, 2020) então o salário de engenharia é igual a R\$ 8.483,00 por mês. Gastando o período de seis meses de desenvolvimento no *software* PIMS o Custo de Desenvolvimento (CD) fica conforme a Equação (1).

$$CD = (6 \times R\$8.831,50) = R\$52.989,00 \quad (1)$$

Para cada *software* PIMS vendido será necessário instalar e configurar o sistema na empresa cliente. O tempo de instalação varia com a quantidade de variáveis a serem armazenadas. O tempo médio de instalação e configuração é de uma semana. Cada sistema terá um custo operacional de R\$ 3.000,00. Isso inclui o valor de R\$ 2.108,25 para o desenvolvedor, despesas com transporte para deslocamento até o cliente e alimentação durante uma semana. Os valores que um investidor desse sistema irá receber está de acordo com a Equação (2).

$$Valor = n \times (PS - CO) - CD \quad (2)$$

Em que:

- n - Número de sistemas PIMS vendidos.
- PS - Preço cobrado por cada sistema.
- CO - Custo Operacional.

Com toda a solução do *software* PIMS sendo oferecida por R\$ 8.000,00 o retorno do investimento virá na venda do 11º *software* PIMS, Equação (3). Após essa venda o investidor consegue um lucro de 167 % por cada sistema vendido.

$$Valor = 11 \times (8.000 - 3.000) - 52.989 = R\$ 2.011,00 \quad (3)$$

O FactoryTalk Historian (versão com limitações de tags) é o historiador com menor preço dentre os listados na

Tabela 1. A solução completa do *software* PIMS desenvolvido neste trabalho (com licença, instalação e suporte) pode ser adquirida por um preço inferior ao dos demais concorrentes. Além disso, o preço do FactoryTalk Historian se refere apenas à licença de utilização. Para configurá-lo é necessária uma empresa de automação especializada em sistemas PIMS.

5. CONCLUSÕES

Este trabalho mostrou que as informações do processo produtivo podem auxiliar os setores corporativos de uma indústria na tomada de decisões estratégicas. A manufatura inteligente conecta a informações dos diversos setores de uma empresa e evita ilhas de informação, auxiliando no controle e gerenciamento do processo produtivo.

A comunicação OPC é o padrão mais utilizado por fabricantes de equipamentos para automação e controle de sistemas, assim, a utilização do OPC no *software* PIMS desenvolvido neste trabalho o torna compatível com grandes historiadores do mercado. Os testes mostraram que o cliente OPC do *software* PIMS pode se conectar aos diferentes Servidores OPC, devido à padronização da comunicação OPC. Essa característica o torna interoperável em sistemas de automação de diferentes fornecedores.

Por meio do *software* executável local, detalhado na seção 2.1, pôde-se configurar os Servidores e Itens OPC e também cadastrar os usuários para acessar o *Web Site*. Ao se fazer os testes, foi possível observar uma característica de flexibilidade em relação à arquitetura de rede, onde as partes não precisam estar funcionando, necessariamente, em um só computador. Isso permite que o sistema se adapte melhor à configuração de rede da indústria que utilizar o *software* PIMS.

No *Web Site* foi possível exibir gráficos de linha, coluna e de pizza, inclusive saber a porcentagem de tempo de parada de uma máquina ou equipamento. Os relatórios podem ajudar os gestores de uma empresa na elaboração de documentos técnicos embasados nas informações do processo.

A análise de custos e funcionalidades, em comparação com os principais concorrentes, mostrou que o *software* PIMS desenvolvido neste trabalho possui as principais características dos melhores historiadores

comercializados e pode ser vendido a um preço inferior, ponto importante para a proposta de oferecer esta solução às empresas de pequeno e médio porte.

Além dos ganhos quantitativos houve também ganhos qualitativos como, por exemplo, melhor organização dos dados, maior controle do processo, rapidez no acesso aos dados e também alta disponibilidade da informação de chão de fábrica.

Sugere-se, como trabalho futuro, a execução de uma avaliação de desempenho do *software* descrito neste trabalho. Isso pode ser realizado para efeito de comparação e completude, verificando se o sistema suporta grande volume de dados em curtos períodos de tempo. Além disso, pode-se pesquisar uma solução para o problema que acontece ao utilizar intervalos pequenos de coleta de dados, o que pode degradar o sistema. Uma proposta para isso é estudar a utilização de soluções distribuídas e escaláveis.

AGRADECIMENTOS

Agradecemos ao Instituto Federal de Minas Gerais (IFMG) campus Formiga por disponibilizar o laboratório de automação, a planta didática de controle de temperatura e nível de tanques e toda a estrutura necessária ao desenvolvimento desta pesquisa.

REFERÊNCIAS

- [1] Brasil (2020). Decreto de Lei assinado pelo Presidente Jair Bolsonaro em suas atribuições institui o salário mínimo do ano de 2020 como R\$ 1.039,00.
- [2] Carvalho, F.B., Torres, B.S., Fonseca, M.O., and Seixas, C.F. (2003). Sistemas PIMS, conceituação, usos e benefícios. VII Seminário de Automação de Processos da Associação Brasileira de Metalurgia e Materiais (ABM), Santos.
- [3] CONFEA (1994). O salário mínimo profissional! Uma conquista! Regulamentação do salário mínimo profissional de Engenheiros, Arquitetos e Agrônomos.
- [4] Control (2014). Global Online Community of Automation professionals. OSI PI Versus Aspen Info Plus 21.
- [5] Dang, T. (2007). Integration of power plant information system with business information system in the open electricity market: challenges and solutions. In 2007 5th IEEE International Conference on Industrial Informatics, volume 2.
- [6] Jazdi, N. (2016). Dynamic calculation of the reliability of factory automation applications: Industry 4.0 applications. In 2016 IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR).
- [7] Kao, Y.T., Chang, S.C., Blue, J., and Dautère-Pérès, S. (2016). Generalized overall equipment effectiveness for integrated scheduling and process control. In 2016 International Symposium on Semiconductor Manufacturing (ISSM).
- [8] Mesta (2014). Client OPC with C#. Biblioteca de interpretação do Protocolo OPC.
- [9] Microsoft (2019). SQL Server Express Edition, software de acesso ao banco de dados. Disponível em www.microsoft.com, acessado em 02 de março de 2019. OPC Foundation (2018). OPC Unified Architecture: The Interoperability Standard for Industrial Automation, 2 edition.
- [10] Rockwell, A. (2019). Controladores CompactLogix 5370 1769. Disponível em <http://ab.rockwellautomation.com/>, acessado em: 02 de março de 2019. Seixas, C.F. (2005). PIMS (Process Information Management System, uma introdução. Universidade Federal de Minas Gerais. Notas de aula.
- [11] Shimanuki, Y. (1999). OLE for process control (OPC) for new industrial automation systems. In IEEE International Conference on Systems, Man, and Cybernetics, volume 6, vol.6.
- [12] Sousa, S.M. and Santos, M.M. (2014). Desenvolvimento de um sistema PIMS com comunicação OPC e acesso por navegador web. Monografia apresentada ao Instituto Federal de Minas Gerais (IFMG) campus Formiga em 18 de Agosto.
- [13] Stair, R. and Reynolds, G. (2002). Princípios de sistemas de informação: uma abordagem gerencial. LTC.
- [14] Tan, V.V., Yoo, D., and Yi, M. (2007). Modern distributed data acquisition and control systems based on opc techniques. In 14th Annual IEEE International Conference and Workshops on the Engineering of Computer-Based Systems.
- [15] Tierney, S. (2013). Data Logging Options For CompactLogix and ControlLogix. FactoryTalk Historian SE.

Capítulo 14

Aplicações de técnicas de Machine Learning ao diagnóstico de falhas em processos de uma planta de cimento

Diego Assereuy Lobão

Luiz Alberto Pinto

Resumo: Este trabalho faz uma análise comparativa do desempenho de algoritmos de *Machine Learning* aplicados ao diagnóstico de falhas de processos relacionados a uma indústria de produção de cimento. Para os testes, os classificadores foram implementados com a utilização dos algoritmos *k-Nearest Neighbour*, *Árvore de Decisão*, *Support Vector Machine*, *Naive Bayes*, *Random Forest* e *Redes Neurais Artificiais*. Além disso, foi investigada a influência de métodos de redução de dimensionalidade sobre o desempenho dos modelos. Para essa análise, a redução de dimensionalidade utilizou técnicas baseadas em seleção de variáveis (*Predictor Importance* e *Relief-F*) e extração de variáveis (*Principal Component Analysis-PCA*). Estudos de caso foram realizados envolvendo dois processos (*Separação do Produto* e *Moagem*), e os resultados obtidos (98,4% e 100%, respectivamente), indicam a viabilidade da implementação de sistemas automáticos de diagnóstico de falhas em indústrias da mesma natureza da indústria estudada nesse trabalho.

Palavras-chave: Diagnóstico de falhas; reconhecimento de padrões; *machine learning*, indústria de cimento; seleção de características.

1. INTRODUÇÃO

No ramo industrial é indispensável obter uma alta disponibilidade e confiabilidade dos equipamentos para garantir a continuidade operacional das plantas de processos sem que ocorram paradas indesejadas ou emergenciais. Nesse aspecto, a gestão de manutenção tem um papel fundamental, e um bom plano de manutenção permite reduzir o número de paradas indesejadas e não programadas, aumentar a disponibilidade, continuidade operacional, produtividade, qualidade do produto, redução de gastos com peças de reposição e aumento do tempo de vida útil dos equipamentos. Desta forma, o gerenciamento eficiente da manutenção é extremamente importante para o sucesso das indústrias.

Além da interrupção do processo produtivo, a ocorrência de falhas pode provocar danos nos equipamentos de produção, comprometimento da segurança do pessoal, quebras de contratos com clientes e perda de produtividade. Deve ser levado em consideração que, em alguns processos, como operação de aeronaves e atividades hospitalares críticas, as falhas não são toleradas (Chambers, Johnston and Slack, 2002).

Entre as estratégias de manutenção existentes, a manutenção preditiva tem sido o enfoque de várias empresas. Nessa estratégia, o objetivo principal é a eliminação de falhas através do monitoramento das condições operacionais do equipamento através da medição das variáveis do processo. Dessa forma, falhas podem ser identificadas ainda em seu estágio inicial, possibilitando assim que as intervenções sejam realizadas conforme uma programação que concilie os objetivos de continuidade da produção, otimização da vida útil das peças a serem substituídas e redução do tempo de parada devido a falhas inesperadas.

Em diversos processos industriais de diferentes ramos da indústria produtiva, variáveis como temperatura, vibração, pressão, vazão e outros, estão presentes em uma variedade de equipamentos como compressores centrífugos ou parafuso, bombas centrífugas, ventiladores, motores, turbinas a gás ou vapor, entre outros. Em máquinas rotativas, a análise de vibração, há muito, tem sido aplicada ao diagnóstico de falhas iminentes. Com base no conhecimento e análise dos fenômenos medidos por sensores acoplados ao processo, é possível detectar níveis excessivos de vibração, e a partir da análise do sinal gerado pelos mesmos, elaborar o diagnóstico da provável falha ou fazer a estimativa da vida útil do equipamento antes de sua ocorrência. Nesse contexto, a análise da vibração é uma das abordagens mais promissoras quando se deseja realizar o monitoramento das condições operacionais de um equipamento e o diagnóstico de falhas eventuais, pois possibilita a intervenção prévia para substituição das partes em processo de desgaste, otimizando as intervenções para manutenção (Mohanty, 2014).

A evolução da tecnologia dos sensores, do hardware dos computadores, e o advento das técnicas de inteligência artificial abriram um campo promissor para o desenvolvimento de sistemas para elaboração automática de diagnósticos de falhas em processos industriais. Nas últimas décadas, devido a crescente complexidade dos problemas a serem tratados e do elevado volume de dados gerados por diferentes setores da indústria, tornou-se necessária a integração dos equipamentos de produção com ferramentas computacionais sofisticadas, que operando de forma autônoma, possibilitem a redução da necessidade de intervenção humana e a dependência dos especialistas da área de manutenção (Faceli et al., 2011).

Nesse contexto, a motivação para o desenvolvimento de tais sistemas é que, os mesmos, sem a intervenção direta dos especialistas, e através da análise do comportamento das variáveis de interesse (temperatura, pressão, vibração, fluxo, pH, etc), sejam capazes de: (i) reconhecer a existência de falhas ocorridas no processo, (ii) identificar a natureza, localização, intensidade e causa das falhas, (iii) monitorar as condições operacionais dos equipamentos e fazer a predição de falhas antes que as mesmas ocorram e, (iv) ser capaz de intervir de forma autônoma para restabelecer as condições operacionais do sistema.

Uma das abordagens para o desenvolvimento de sistemas automáticos de diagnósticos é a utilização de técnicas de *Machine Learning* e algoritmos de classificação. Nessa abordagem, métodos de reconhecimento de padrões são aplicados para a identificação de padrões de falhas em conjuntos de dados extraídos do processo em operação, e que contenham as assinaturas das condições de operação anormais que se deseja diagnosticar. O reconhecimento de padrões pode ser definido como o processo pelo qual um objeto desconhecido é atribuído a uma classe específica entre um conjunto de classes conhecidas (Haykin, 2007).

Nesse contexto, esse trabalho, apresenta um estudo sobre a aplicação de técnicas de *Machine Learning* ao desenvolvimento de sistemas de diagnóstico de falhas em dois processos de uma indústria de produção de cimento. Para a realização desses estudos, foram utilizadas duas bases de dados constituídas por medições pontuais de temperatura, pressão e vibração, obtidas em diversos locais da planta. Na etapa de

classificação foram utilizados os algoritmos *k-Nearest Neighbour (k-NN)*, Árvore de Decisão, Support Vector Machine (*SVM*), *Naive Bayes*, *Random Forest* e Redes Neurais Artificiais.

Na sequência, este trabalho está constituído pelas seguintes seções: a Seção 2 contém uma revisão bibliográfica sobre o diagnóstico de falhas; a Seção 3 faz uma descrição sucinta dos algoritmos de classificação empregados; a Seção 4 apresenta uma descrição das etapas executadas para a realização da pesquisa; a Seção 5 apresenta os resultados dos testes para redução de dimensionalidade; a Seção 6 reúne os resultados da classificação e a Seção 7 traz as conclusões finais.

2. REVISÃO BIBLIOGRÁFICA

O desenvolvimento de métodos automáticos para detecção de falhas em sistemas industriais tem sido objeto de pesquisas na área de *Machine Learning* há várias décadas. No que segue, essa seção apresentará alguns trabalhos recentes. Em (Palácios et al., 2016) os autores propõem uma metodologia para identificação de defeitos em motores de indução trifásicos. Pela metodologia proposta, os descritores utilizados foram extraídos com a versão discretizada dos sinais de tensão e corrente no domínio do tempo. Na etapa de classificação os autores aplicaram os algoritmos Redes Neurais Artificiais do tipo *Multilayer Perceptron (RNA/MLP)*, *k-Nearest Neighbors (k-NN)* e *Support Vector Machine com Sequential Minimal Optimization (SVM/SMO)*. As falhas diagnosticadas foram, curto-circuito nas bobinas do estator, barras quebradas no rotor e defeitos nos rolamentos. Os melhores resultados foram apresentados pelos classificadores implementados com os algoritmos *MLP* e *k-NN*, que apresentaram acurácia de 89% na identificação das falhas.

Basha et al. (2018), propuseram um método para detecção e diagnóstico de falhas baseado em três variações do *Interval Principal Component Analysis (IPCA)*. *IPCA* é uma extensão da *Principal Component Analysis (PCA)* convencional aplicada a conjuntos de dados de grande volume. Nesse trabalho, as três variações da *IPCA* utilizadas foram, *Centers IPCA*, *Midpoint-Radii IPCA* e *Symbolic Covariance IPCA*. Para a verificação do desempenho do método proposto, os autores, inicialmente utilizaram dados sintéticos e em seguida dados de processos reais. Os resultados obtidos pelos três métodos baseados em *IPCA* ultrapassaram de forma significativa aqueles obtidos pela *PCA (Principal Component Analysis)* clássica. Quando os três métodos foram comparados entre si, verificou-se que o *Centers IPCA* detecta alterações na média, enquanto o *Midpoint-Radii* detecta alterações na variância. Para a classificação, os resultados mostraram que a abordagem baseada no *Midpoint-Radii IPCA* obteve melhor desempenho quando comparado a todos os outros métodos.

Em (Liu et al., 2018), os autores fazem uma revisão da aplicação de técnicas de inteligência artificial ao diagnóstico de falhas em máquinas rotativas apresentando a fundamentação teórica dos métodos, bem como sua aplicação na indústria. O trabalho traz uma breve introdução de diferentes algoritmos de *Machine Learning*: *k-Nearest Neighbour*, *Support Vector Machine*, *Naive Bayes*, Redes Neurais Artificiais e *Deep Learning* e, baseado em uma ampla revisão bibliográfica de trabalhos recentes na área faz uma análise comparativa enfatizando as vantagens e as desvantagens de cada método. Como uma contribuição adicional, os autores abordam a aplicação de técnicas de processamento de sinais para a extração de descritores. Nesse aspecto, são enfatizadas as análises no domínio do tempo, no domínio da frequência, e no domínio tempo-frequência.

Han et al. (2019) realizaram testes para diagnóstico de falhas em um *Chiller* utilizando os classificadores *SVM (Support Vector Machine)*, *LS-SVM (Least Squares - Support Vector Machine)* e *PNN (Probabilistic Neural Network)*. O experimento analisou sete tipos de falhas, e utilizou oito descritores para descrevê-las. Das sete falhas investigadas, quatro são designadas falhas a nível de componentes e três a nível de sistema. O classificador baseado no *LS-SVM* apresentou desempenho superior, tanto em relação a taxa de classificação correta (99,63%), quanto em relação ao custo computacional, quesito em que foi 36,7% mais rápido que o *SVM*.

O trabalho apresentado por (Gangsar and Tiwari, 2019) propõe uma variação do algoritmo *SVM* para o diagnóstico de nove tipos de falhas (cinco de natureza elétrica e quatro de origem mecânica), em motores de indução. Para o diagnóstico, o método utiliza os sinais de vibração e corrente, por serem esses sinais associados a um grande grupo de falhas, sendo também indicadores de suas severidades. As assinaturas das falhas foram extraídas dos sinais de vibração e corrente para diferentes condições de carga e velocidade do motor, tendo sido as mesmas classificadas utilizando o algoritmo *SVM*. Inicialmente o diagnóstico é elaborado para as falhas nas mesmas condições de carga e velocidade em que os sinais foram obtidos. Posteriormente, uma estratégia de predição foi aplicada para estender o diagnóstico para

considerar as condições intermediárias de carga e velocidade. O valor da acurácia de 100% obtida na maioria das configurações de teste, mostram que o método proposto é capaz de diagnosticar com precisão todas as falhas para as mesmas condições de operação, e que o desempenho na predição para as condições intermediárias é promissor.

Trabalhos mais recentes têm utilizado técnicas de *Deep Learning* como em (Chen, Gryllias and Li, 2019), cujos autores aplicaram *Convolutional Neural Network (CNN)* e *Extreme Learning Machine (ELM)* ao diagnóstico de falhas. O trabalho foi realizado numa caixa de marchas automotiva no qual foram introduzidas falhas de rolamentos e engrenagens. A bancada experimental era composta por um motor acionador, um transdutor de torque, uma caixa de engrenagem e um motor de carga. Das cinco marchas existentes no sistema somente a quinta marcha foi utilizada nos testes de falha. Os sinais unidimensionais foram obtidos através de acelerômetros e, a partir desses, foram gerados escalogramas com a aplicação da Transformada Wavelet Contínua (TWC). Num segundo momento foi utilizado uma *CNN* para extrair os vetores de características das imagens e um classificador *ELM* para realizar a identificação das falhas. Durante os testes, foram reproduzidos sete tipos de falhas num total de 2100 amostras sendo 300 amostras para cada falha. O experimento obteve bons resultados de classificação se comparado aos métodos tradicionais de *Machine Learning* que utilizaram descritores extraídos a partir da transformada rápida de Fourier, o melhor resultado utilizando *CNN-ELM* obteve uma acurácia na faixa de 99%.

3. REFERENCIAL TEÓRICO

Diferentes algoritmos de *Machine Learning* têm sido utilizados para o desenvolvimento de sistemas de diagnósticos de falhas em processos industriais. Considerando o vasto domínio de aplicação para esses sistemas, que envolve processos e parques industriais diversos, e considerando também as estratégias adotadas por cada algoritmo, de forma geral, não é possível destacar uma solução que se adeque a todos os problemas. Nesse trabalho, os classificadores serão implementados utilizando os algoritmos *k-Nearest Neighbour*, *Árvore de Decisão*, *Support Vector Machine*, *Naive Bayes*, *Random Forest* e *Redes Neurais Artificiais*.

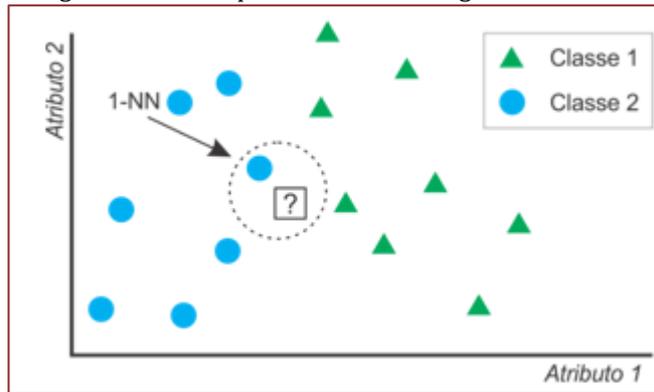
3.1 K-NEAREST NEIGHBOUR (K-NN)

O *k-NN* é um classificador não paramétrico que atribui a amostra desconhecida a mesma classe das *k* amostras mais próximas, segundo um critério de decisão. Sua simplicidade e eficácia fizeram com que fosse amplamente utilizado em muitos problemas de classificação (Fayed and Atiya, 2009). O princípio sobre o qual o *k-NN* se baseia é de que amostras similares tendem a se concentrar em uma mesma região do espaço. A implementação da estratégia de classificação requer a definição prévia do valor de *k* (número de vizinhos), que em problemas de classificação deve ser um valor ímpar para eliminar a possibilidade de que mais de uma classe seja atribuída a amostra desconhecida. Diversas métricas podem ser utilizadas para o cálculo das distâncias, tais como, *Mahalanobis*, euclidiana, *Chebychev*, entre outras, sendo a mais comum a métrica euclidiana. Uma regra de decisão deve ser aplicada para a definição da classe da amostra desconhecida. Por exemplo, uma regra de decisão pode consistir em atribuir a amostra desconhecida a mesma classe da maioria dos *k* vizinhos.

Uma vez que o método do algoritmo *k-NN* se baseia no cálculo de distâncias, seu desempenho pode ser afetado pela ordem de grandeza dos valores das medidas utilizadas, por exemplo, a representação do valor de uma variável em centímetros e outra em metros. Nesse caso, o classificador tende a atribuir maior peso às variáveis com maiores ordens de grandeza, ainda que elas não sejam as mais relevantes para a classificação. A solução desse problema pode ser obtida pela normalização das variáveis da base de dados (Faceli et al., 2011).

A Figura 3.1 apresenta uma ilustração de classificação utilizando o algoritmo *1-NN* em um problema de duas classes. Um conjunto de amostras pertencentes à *Classe 1 (triângulo)* ou *Classe 2 (círculo)* é representado pelo *Atributo 1* e *Atributo 2*. Nesse exemplo ilustrativo o objeto representado pelo símbolo “?” é a amostra desconhecida a qual é atribuída à *Classe 2*.

Figura 3.1 - Exemplo ilustrativo do algoritmo 1-NN.

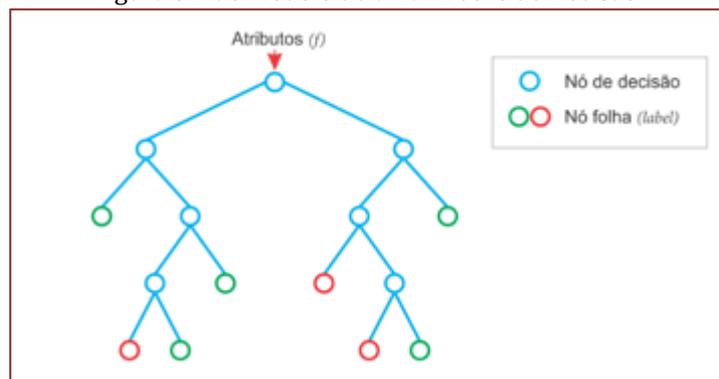


Fonte: Adaptado de (Faceli et al., 2011).

3.2 ÁRVORE DE DECISÃO

Árvores de decisão são métodos de aprendizado de máquinas supervisionado não-paramétricos, cuja estratégia consiste em dividir problemas complexos em problemas mais simples (estratégia dividir para conquistar), aos quais, recursivamente, é aplicada a mesma estratégia (Faceli et al., 2011). Uma árvore de decisão é constituída por nós de decisão, aos quais estão associadas às regras a serem utilizadas na classificação, e nós folhas ou terminais, aos quais estão associadas às classes. Para o problema de classificação, cada sub-região no espaço é representado por um nó, e através do particionamento recursivo do espaço, novos nós podem ser gerados (nós filhos). Desta forma, cada percurso da árvore, da raiz à folha, corresponde a uma regra de classificação. O processo de recursão para a busca na árvore é repetido até que um critério de parada seja alcançado. Os modelos obtidos por árvores de decisão utilizam divisões binárias para determinar o resultado da predição. Há diversos algoritmos que trabalham com árvores de decisão como ID3 (Quinlan, 1986), C4.5 (Salzberg, 1994), CART (Breiman et al., 1984) entre outros. Neste trabalho foi utilizado o algoritmo CART e como regra de divisão foi utilizada a Entropia e índice Gini. O critério de parada, que pode ser o número máximo de divisões da árvore, não foi definido nesse trabalho. A Figura 3.2 ilustra um modelo de árvore de decisão.

Figura 3.2 de modelo de uma Árvore de Decisão.



Fonte: Autoria própria.

3.3 MÁQUINAS DE VETORES DE SUPORTE

Máquinas de vetores de suporte (*Support Vector Machine - SVM*), são classificadores lineares binários não-probabilísticos que se baseiam na teoria de aprendizado estatístico (Cortes and Vapnik, 1995). Para a classificação, o algoritmo busca a fronteira (hiperplano) entre as duas classes, de forma a maximizar a distância de separação entre dois objetos mais próximos.

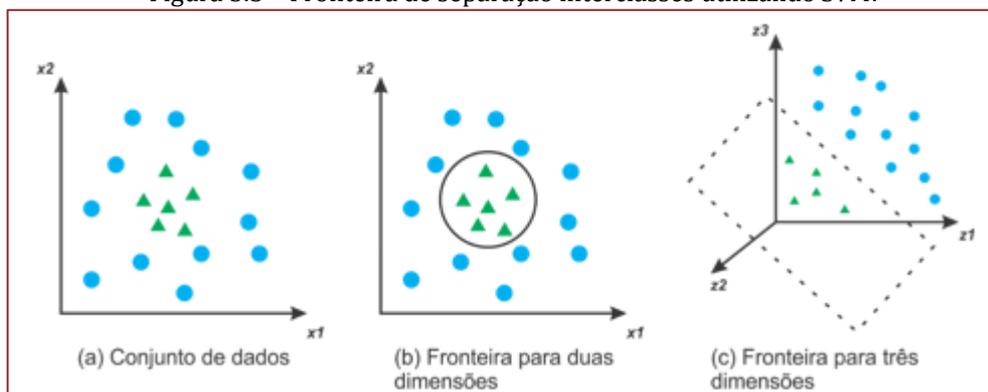
Para problemas não-lineares, o *SVM* utiliza funções *kernel* para a transformação dos dados não linearmente separáveis, encontrando uma fronteira de decisão linear. A Figura 3.3 mostra a transformação do espaço dimensional das amostras de \mathbb{R}^2 para \mathbb{R}^3 . Em 3.3(a) pode ser notado o espaço

dimensional original \mathfrak{R}^2 , em 3.3(b) observa-se a impossibilidade de encontrar uma fronteira linear no espaço original para a solução do problema e 3.3(c) ilustra o espaço dimensional \mathfrak{R}^3 que resultou da transformação, onde existe uma fronteira linear de separação entre as classes (Faceli et al., 2011). Nesta pesquisa foram utilizadas funções *kernel* do tipo *linear* e *gaussian*, cujas representações matemáticas são dadas pelas equações 3.1 e 3.2, respectivamente.

$$k(\bar{x}, \bar{y}) = \bar{x} \cdot \bar{y} \tag{3.1}$$

$$k(\bar{x}, \bar{y}) = e^{-\frac{|\bar{x}-\bar{y}|^2}{2\sigma^2}} \tag{3.2}$$

Figura 3.3 – Fronteira de separação interclasses utilizando SVM.



Fonte: Adaptado de (Faceli et. Al., 2011).

Na sua forma original, o classificador SVM considera problemas de duas classes, porém, através de métodos multiclasse, é possível resolver problemas cuja base de dados seja constituída por um número maior de classes. Os métodos multiclasse mais utilizados são (i) *one-vs-one* e (ii) *one-vs-all*, que estão descritos a seguir. Nesse trabalho foi utilizado o método *one-vs-one*.

- **One-vs-one:** também conhecido como todos-contra-todos, considerando que o problema de classificação envolva n classes, para a solução são gerados $\frac{n(n-1)}{2}$ classificadores binários sendo que cada um deles é responsável por determinar apenas um par de classes.
- **One-vs-all:** no método um-contra-todos, dado um problema com n classes, são gerados n classificadores binários, cada um especializado na sua classe. Essa técnica pode apresentar desvantagem quando ocorre um desbalanceamento considerável do conjunto de dados (Faceli et al., 2011).

3.4 NAIVE BAYES

O classificador *Naive Bayes* é um método probabilístico baseado no teorema de Bayes. Os métodos bayesianos assumem que a probabilidade de um evento A , dado um evento B , não depende apenas da relação entre A e B , mas também da probabilidade de observar A independentemente de observar B (Mitchell, 1993), como representado pela Equação 3.3.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \tag{3.3}$$

Para a adaptação desse teorema à problemas de classificação, os termos A e B na Equação 3.3 tornam-se as classes envolvidas no problema. A determinação da classe mais provável de uma nova amostra é a de maior probabilidade entre as classes possíveis, sendo essa atribuída à amostra desconhecida. O classificador *Naive Bayes* assume que os variáveis de uma amostra são independentes entre si, o que, geralmente é uma consideração irreal. Dessa forma, $P(x|y_i)$ pode ser decomposto no produto $P(x_1|y_i) \times$

... $\times P(x_j|y_i)$, onde x_j é o j -ésimo atributo de x . Portanto, o classificador *Naive Bayes* pode ser representado pela equação 3.4, no qual, a probabilidade de uma amostra pertencer à classe y_i é proporcional à expressão,

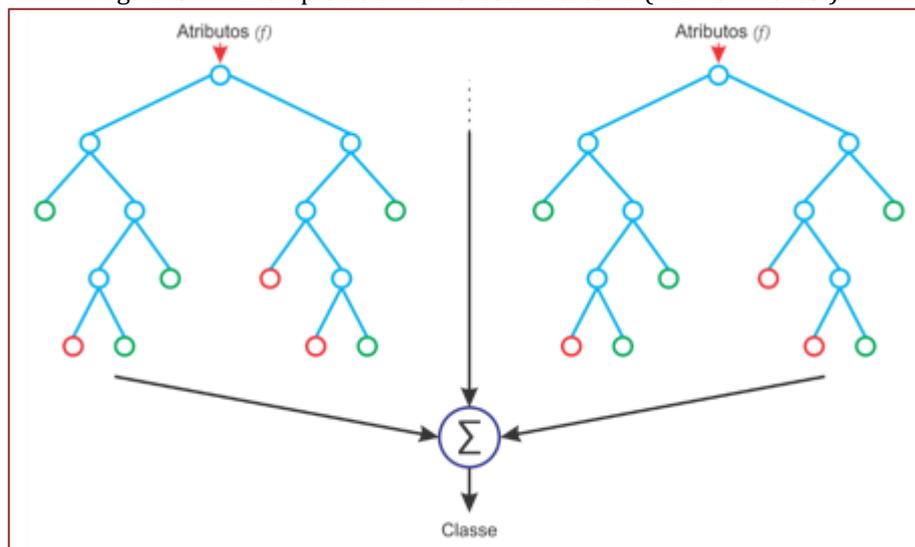
$$P(y_i|x) \propto P(y_i) \prod_{j=1}^d P(x_j|y_i) \quad (3.4)$$

3.5 FLORESTA ALEATÓRIA

As Árvores de Decisão são métodos relativamente simples e fáceis de se utilizar na prática, porém, geralmente oferecem pouca precisão para grandes conjuntos de dados. Como uma alternativa a utilização das Árvores de Decisão, a Floresta Aleatória (*Random Forest*), é usualmente aplicada à sistemas que possuem alta variância, cuja tomada de decisão é feita por votação (Hastie, Tinshirani and Friedman, 2009).

Introduzida por (Breiman, 2001), a Floresta Aleatória utiliza uma técnica chamada *bagging*, e é constituída por uma coleção de Árvores de Decisão (Breiman et al., 1984). Conforme visto na seção 3.2, esses modelos utilizam variáveis predictoras binárias para determinar o resultado da predição. De forma geral, comparativamente a Árvore de Decisão, as Florestas Aleatórias resultam em melhores desempenhos em problemas de classificação. A Figura 3.4 apresenta um exemplo de uma estrutura típica de *Floresta Aleatória*.

Figura 3.4 - Exemplo de uma Floresta Aleatória (Random Forest).



Fonte: Autoria própria

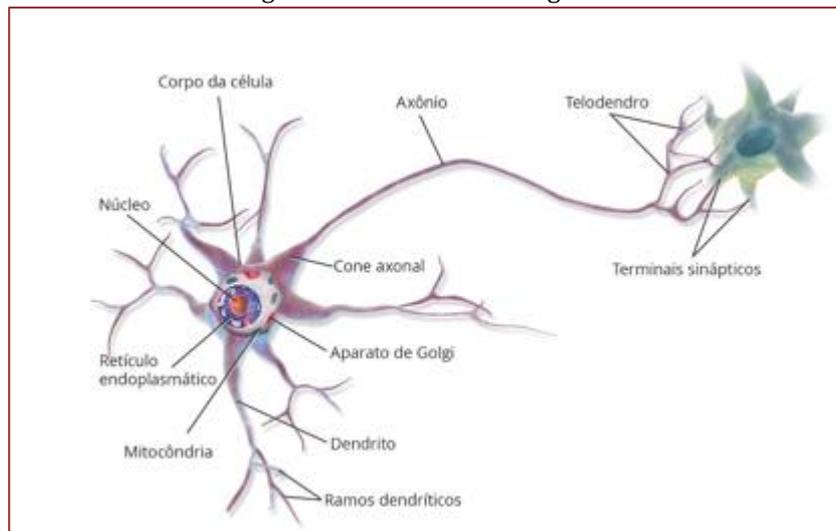
O *bagging* particiona o conjunto de treino em diversos subconjuntos. Para cada subconjunto, variáveis são selecionadas e um modelo é treinado formando diversas árvores, cujos resultados são combinados. Ao estimar uma entrada, cada árvore irá classificar o subconjunto de forma independente, sendo que a decisão a respeito da classe que a amostra desconhecida pertence será resultado de um processo de votação, e a classe atribuída será aquela com maior número de votos.

3.6 REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA) foram inspiradas na estrutura e funcionamento do sistema nervoso, com o objetivo de simular a capacidade de aprendizado do cérebro humano (Faceli et al., 2011). O sistema nervoso é um conjunto complexo de células, do qual a unidade principal é o neurônio, que se diferencia das outras células por apresentar excitabilidade, permitindo respostas a estímulos internos e externos.

Basicamente, os neurônios são compostos por dendritos, corpo celular e axônio. Os dendritos são responsáveis pela parte receptora de estímulos nervosos provenientes de outros neurônios ou do ambiente. Os estímulos são transmitidos para o corpo celular (soma), que coleta as informações recebidas e as processa. A depender da intensidade do estímulo recebido, o corpo celular gera um novo impulso e envia para o axônio, o qual é um prolongamento dos neurônios, responsável pela transmissão dos impulsos até outros neurônios. A Figura 3.5 mostra um neurônio biológico, a sinapse é a ligação entre o axônio de um neurônio e o dendrito de outro.

Figura 3.5 - Neurônio biológico

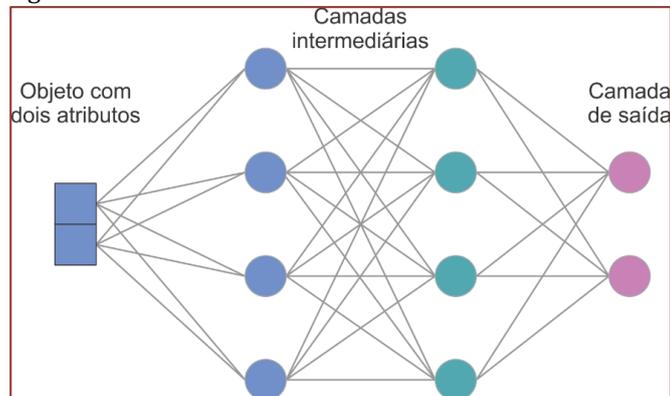


Fonte: (Géron, 2019)

As RNAs são compostas por três elementos principais: camada de entrada, camadas ocultas (*hidden layer*) e camada de saída. A primeira RNA a ser implementada foi a rede *perceptron* (Rosenblatt, 1958). Apesar de possuir apenas uma camada, a rede *perceptron* apresentava boa acurácia em problemas de classificação, porém se limitava apenas a problemas cujos objetos eram linearmente separáveis.

As redes *perceptron* multicamadas (*Multilayer Perceptron - MLP*), são compostas por uma ou mais camadas intermediárias de neurônios e uma camada de saída. A adição de camadas intermediárias foi a alternativa encontrada para resolver problemas não linearmente separáveis, pois permite a aproximação de qualquer função (Cybenko, 1989). A Figura 3.6 apresenta uma RNA do tipo *MLP* com dois atributos de entrada, duas camadas intermediárias e duas camadas de saída.

Figura 3.6 - Rede *MLP* com duas camadas intermediárias.



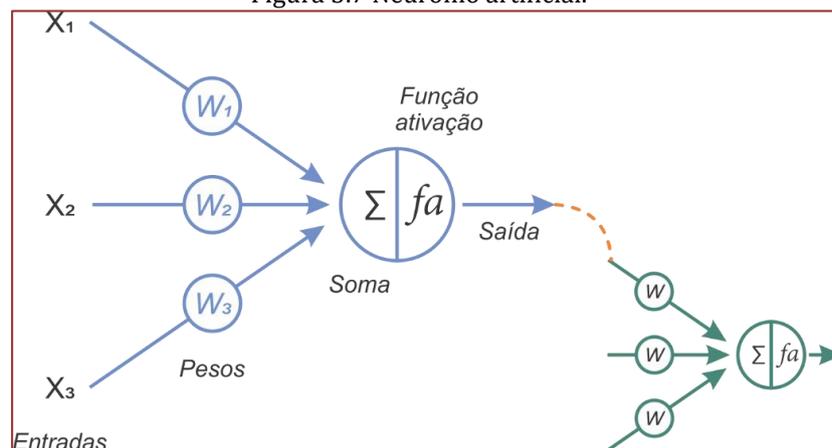
Fonte: Adaptado de (Faceli et al., 2011).

Fazendo uma analogia com o neurônio biológico, a entrada da rede realiza a função dos dendritos os quais recebem a informação. Através de funções de ativação os dados de entrada são processados e

transmitidos para as camadas consecutivas. A complexidade do processamento aumenta à medida que os dados processados alcançam as camadas intermediárias mais profundas da rede.

A arquitetura de uma RNA é apresentada na Figura 3.7. Cada entrada da rede recebe um valor x_i . Os valores de entrada são ponderados por pesos w_i , e combinados por uma função de ativação fa para produzir um valor de saída. Os tipos de função de ativação mais comuns são, *binária*, *linear* e *sigmoidal*. Como pode ser observada, a saída de um neurônio será a entrada de um neurônio subsequente. Os pesos “ w ” podem ser positivos (excitatório) ou negativos (inibitório), caso seja igual a zero significa uma ausência da conexão associada.

Figura 3.7 Neurônio artificial.



Fonte: Autoria própria.

Uma das técnicas utilizadas para ajustar os pesos de entrada de uma RNA é a utilização do algoritmo *back-propagation* (Rumelhart, Hinton and Williams, 1985). Cada neurônio da primeira camada recebe o objeto de entrada e aplica a função de ativação, e o valor de saída se torna a entrada para os neurônios da camada seguinte. O processo continua até alcançar a camada de saída. Em seguida o valor na saída da camada de saída é comparado ao valor desejado na saída desse neurônio. A diferença entre o valor desejado e o valor de saída gera o valor do erro da rede em relação àquela classe. O erro calculado é utilizado na fase conhecida como *backward*, na qual é realizado o ajuste que realimenta a primeira camada intermediária com a finalidade de ajustar os pesos de entrada. Existem diversas variações do algoritmo *back-propagation*, neste trabalho foi utilizado o algoritmo *Levenberg-Marquardt* (Hagan and Menhaj, 1994).

4. MATERIAIS E MÉTODOS

Na sequência, esse trabalho apresenta dois estudos de casos sobre a aplicação de técnicas de *Machine Learning* na elaboração automática de diagnóstico de falhas nos processos de *Separação do Produto* e *Moagem* de uma indústria de cimento. As etapas que constituíram a metodologia adotada para a execução do trabalho estão descritas a seguir.

4.1 DESCRIÇÃO DOS PROCESSOS

Separação do Produto: no processo de separação do produto, um conjunto denominado separador ou ciclopól, constituído de vários equipamentos controla a granulometria do produto acabado, mantendo-o dentro dos padrões de qualidade especificados. O conjunto separador é constituído pelo subconjunto de exaustão, que é formado por um rotor acionado por um motor de corrente alternada e uma válvula de controle de vazão de ar, cuja finalidade é dosar a vazão de ar de exaustão no interior do separador. Subconjunto de controle de velocidade, constituído por um motor de corrente contínua de velocidade controlada que aciona através de um redutor um rotor interno ao separador, onde efetivamente ocorre o controle da granulometria do produto. O redutor do motor de corrente contínua é lubrificado por um sistema de circulação de óleo em circuito fechado, acionado por um conjunto moto-bomba tendo instalado em sua linha um trocador de calor cuja finalidade é resfriar o óleo que lubrifica o redutor. Subconjunto ciclone que direciona o produto para a sequência do processo, ou retorna para a moagem o que se

encontra fora dos padrões de qualidade especificados. As variáveis do processo de separação do produto monitoradas são, vibração do mancal do subconjunto de exaustão, temperatura do óleo no interior do redutor e as pressões do óleo de lubrificação na entrada e saída do trocador de calor da linha de óleo de lubrificação do redutor.

Moagem: no processo de moagem ocorre o processamento da matéria prima bruta da qual se deseja obter o produto acabado. No início do processo, a matéria prima bruta (gesso, escória de alto forno, clínquer) alimenta o moinho de bolas e por exaustão percorre dois estágios. No primeiro estágio, a matéria prima alimenta a primeira câmara do moinho, e como o material se encontra em estado bruto, isto é, os grânulos possuem considerável volume, é necessário que sejam inicialmente britados, por isso, nessa câmara, as bolas de ferro que são os elementos que realizam a britagem da matéria prima, possuem grandes dimensões e peso. Após a britagem, o material semi-processado, agora constituído de grânulos de menor volume, alimenta a segunda câmara onde as bolas possuem menor dimensão e peso que na primeira. Nesse estágio ocorre efetivamente a moagem e mistura da matéria prima, resultando no produto que alimentará o segundo processo que é a separação do produto. O moinho de bolas é um equipamento de formato cilíndrico com 14,8 m de comprimento e 3,8 m de diâmetro, acionado através de redutores por dois motores de corrente alternada de 1960 cv que operam em paralelo. O processo de moagem da matéria prima é monitorado por vinte e dois sensores de temperatura, localizados em pontos estratégicos dos equipamentos como redutores, engrenagens, linhas de óleo de lubrificação.

4.2 DESCRIÇÃO DAS FALTAS

Separação do Produto: as faltas no processo de separação são representadas por amostras com as variáveis, vibração do mancal do subconjunto de exaustão; temperatura do óleo no interior do redutor do motor cc e as pressões do óleo de lubrificação na entrada e na saída do redutor do motor de corrente contínua. A base de dados com as faltas desse processo é constituída por 638 amostras, distribuídas por cinco classes, como mostrado na Tabela 4.1.

Tabela 4.1 – Faltas no processo de Separação do Produto.

| Classe | Natureza da falta | Nº de amostras |
|--------|--|----------------|
| C1 | Condição de funcionamento normal. | 233 |
| C2 | Falta no sistema de resfriamento de óleo do redutor. | 106 |
| C3 | Instabilidade na estrutura mecânica do exaustor. | 121 |
| C4 | Obstrução na linha de óleo de lubrificação do redutor. | 91 |
| C5 | Falta de natureza não identificada. | 87 |

Moagem: a Tabela 4.2 relaciona as classes de faltas para o processo de moagem. A base de dados contém 2418 amostras, constituídas por vinte e dois valores de temperatura medidas nos equipamentos do conjunto, como redutores, engrenagens, linhas de óleo de lubrificação.

Tabela 4.2 – Faltas no processo de Moagem.

| Classe | Natureza da falta | Nº de amostras |
|--------|--|----------------|
| C1 | Condição de funcionamento normal. | 1370 |
| C2 | Falta no sistema de lubrificação do redutor 2. | 228 |
| C3 | Falta no sistema de lubrificação do redutor 1. | 325 |
| C4 | Falta no sistema de resfriamento de óleo do redutor 2. | 167 |
| C5 | Falta no sistema de resfriamento de óleo do redutor 1. | 187 |
| C6 | Falta no sistema de lubrificação do mancal primário do moinho. | 141 |

4.3 REDUÇÃO DA DIMENSIONALIDADE E NORMALIZAÇÃO

A fim de eliminar descritores de pouca relevância para os modelos, foram aplicadas técnicas para redução da dimensionalidade dos dados dos processos de separação e de moagem. Além disso, para assegurar que todas as variáveis contribuíssem para a modelagem de acordo com sua relevância, as variáveis foram normalizadas para que tivessem a mesma ordem de grandeza.

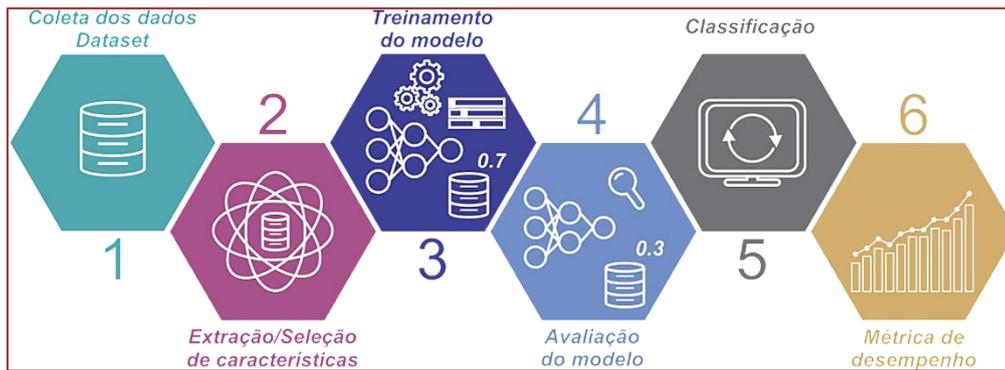
- **Redução da Dimensionalidade Baseada em Seleção:** os algoritmos selecionam entre variáveis do conjunto original as mais relevantes, de acordo com um critério específico. Nesse trabalho, foram utilizados: Predictor Importance (PI), algoritmo baseado em árvore de decisão que atribui a cada variável um score. Quanto maior o valor do score, mais representativo será o atributo para a modelagem. Relief-F (Kononenko and Robnik-Sikonja, 2003), estima o peso dos atributos em relação a classe de acordo com sua capacidade de distinguir as instâncias que estão mais próximas umas das outras.
- **Redução da Dimensionalidade Baseada em Extração:** técnicas baseadas em extração encontram novos descritores, que são obtidos através de combinações lineares dos descritores originais. Nesse trabalho, a técnica utilizada para redução de dimensionalidade baseada em extração foi a Análise de Componentes Principais (Principal Component Analysis - PCA).
- **Normalização:** para os testes, os dados foram normalizados a fim de evitar que os descritores com maiores valores absolutos fossem enfatizados, mesmo não sendo os mais relevantes para a classificação. O método de normalização utilizado foi o do intervalo unitário, que calcula os novos valores das variáveis no intervalo [0,0, 1,0].

4.4 TREINAMENTO DO CLASSIFICADOR

A Figura 4.1 ilustra a sequência das etapas executadas. Para a classificação, nos dois processos as bases de dados foram divididas em conjuntos de validação e teste, com 70% e 30% das amostras, respectivamente. Os modelos foram obtidos utilizando os algoritmos *k-NN*, *Árvore de Decisão*, *Support Vector Machine*, *Naive Bayes*, *Random Forest* e *RNA*. O desempenho dos classificadores foi avaliado pela técnica de validação cruzada (*k-fold cross-validation*), tendo o conjunto de treino sido particionado em 10 subconjuntos sendo que, em cada rodada de execução nove foram utilizados para treinar o modelo e um para verificar seu desempenho. O erro de validação cruzada é calculado como a média dos erros nas 10 rodadas. A métrica utilizada para a avaliação do desempenho dos classificadores foi a acurácia. A descrição das configurações dos parâmetros utilizados em cada algoritmo de classificação está descrita a seguir. Todos os testes foram realizados no Matlab®, 2019a.

- **k- Vizinhos-mais-próximos (k-NN):** foram utilizados diferentes de vizinhos, sendo k=1, 3 e 5, e a métrica euclidiana foi utilizada para o cálculo das distância.
- **Árvore de Decisão (Tree):** como critério de divisão dos nós foi utilizado a entropia e o índice gini. A quantidade de nós não foi limitada.
- **Support Vector Machine (SVM):** foi utilizado o método multiclass um contra todos (one-vs-one). Por definição de projeto, foi utilizado kernel do tipo gaussian (RBF) e linear.
- **Redes Neurais Artificiais (RNA):** a rede utilizada tinha duas camadas ocultas sendo a primeira com quarenta neurônios e a segunda com vinte neurônios. A rede foi treinada utilizando o algoritmo backpropagation do tipo Levenberg-Marquardt. O número de épocas foi limitado a 50.
- **Floresta Aleatória (Random Forest - RF):** o classificador implementado por meio do algoritmo Floresta Aleatória foi treinado com uma coleção de 100 árvores.
- **Naive Bayes (NB):** foram utilizadas configurações do tipo default no algoritmo Naive Bayes, ou seja, um modelo de distribuição gaussiana.

Figura 4.1 - Etapas de classificação.



Fonte: Autoria própria.

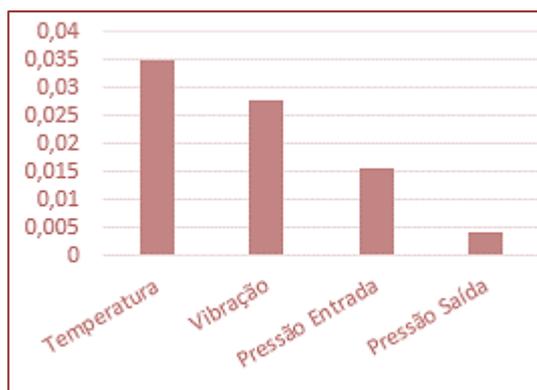
5. REDUÇÃO DE DIMENSIONALIDADE

Nessa seção estão apresentados os resultados da etapa de redução de dimensionalidade realizada por meio de seleção e extração de variáveis. Os resultados são apresentados separadamente para as bases de dados de *Separação do Produto* e *Moagem*.

5.1 SEPARAÇÃO DO PRODUTO

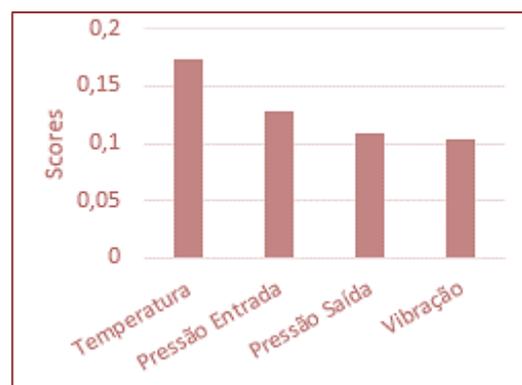
As Figuras 5.1 e 5.2 mostram, respectivamente, os resultados dos testes de seleção de variáveis utilizando os algoritmos *Predictor Importance* e *Relief-F*. Como pode ser notado, a variável “pressão de saída do óleo de lubrificação do redutor do motor de corrente contínua” é pouco relevante para a modelagem de acordo com o algoritmo *Predictor Importance*, podendo, portanto, ser removida na fase de modelagem. Já no método de seleção utilizando o algoritmo *Relief-F*, as variáveis “pressão de entrada”, “pressão de saída” e “vibração” possuem *scores* bem equilibrados, dessa forma, a remoção ou não de alguma variável deve ser avaliada.

Figura 5.1 - Seleção de descritores utilizando *Predictor Importance*.



Fonte: Autoria própria.

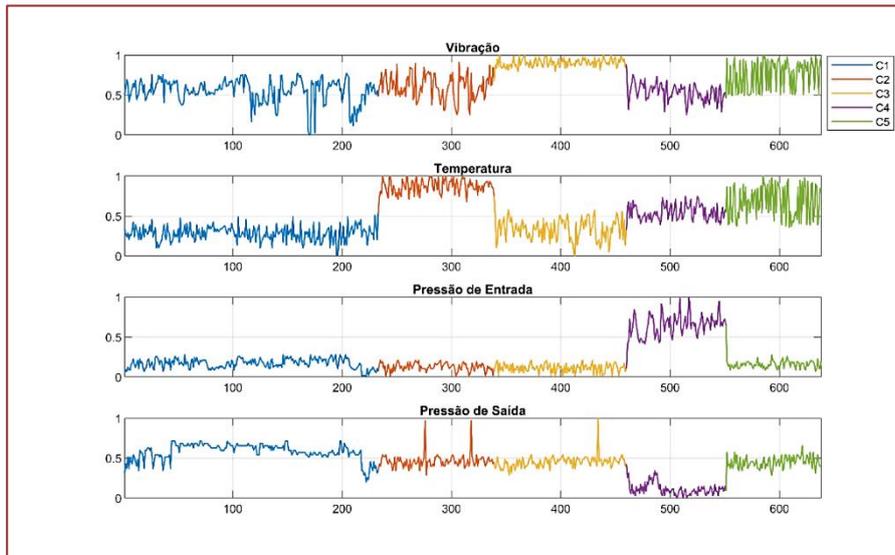
Figura 5.2 - Seleção de descritores utilizando *Relief-F*.



Fonte: Autoria própria.

A Figura 5.3 ilustra o conjunto amostral das variáveis do processo *Separação do Produto*. Os valores das variáveis estão normalizados e apresentados na forma de gráficos de linha, nos quais as classes são representadas por cores diferentes. Observando os gráficos nota-se o comportamento das variáveis para cada natureza de falha do equipamento, o que indica a possibilidade da obtenção de bom desempenho na etapa de classificação.

Figura 5.3 - Comportamento das variáveis no conjunto de dados Separação do Produto.

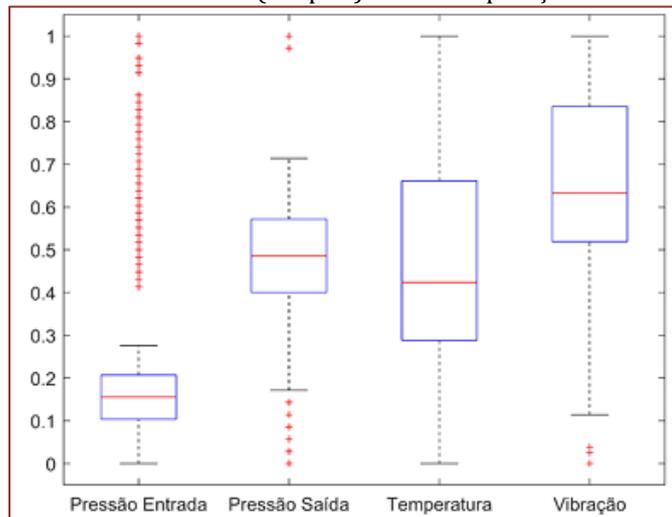


Fonte: Autoria própria.

Pelo gráfico da Figura 5.3 é possível notar que algumas variáveis como pressão de entrada e pressão de saída apresentam comportamentos anormais em alguns instantes da operação do processo. Entre outros motivos, essas anormalidades podem estar relacionadas a falhas de medição dos sensores, o que pode gerar valores divergentes das variáveis, isto é, valores que se diferenciam substancialmente da média das outras observações para a mesma variável, em análise multivariada de dados esses valores são designados outliers (Hair et al., 2009).

A Figura 5.4 mostra os gráficos de caixa (boxplot) das amostras normalizadas das classes do conjunto Separação do Produto. Esse método é considerado o mais adequado para obtenção de informações sobre a distribuição de uma variável e para a identificação de possíveis outliers, que nesse caso, são representados pelos pontos fora das caixas. Para a detecção de falhas, outliers podem ser associados às falhas do sistema, à ruídos de sensores, ou a outros ruídos do sistema. A existência de tais amostras, se não tratadas adequadamente, poderá afetar de forma significativa o desempenho dos classificadores. Contudo, a solução para tal problema não é trivial, e sua solução dependerá do conhecimento a priori que os especialistas possuem sobre o processo.

Figura 5.4 - Gráfico de caixas (boxplot) dataset Separação do Produto.

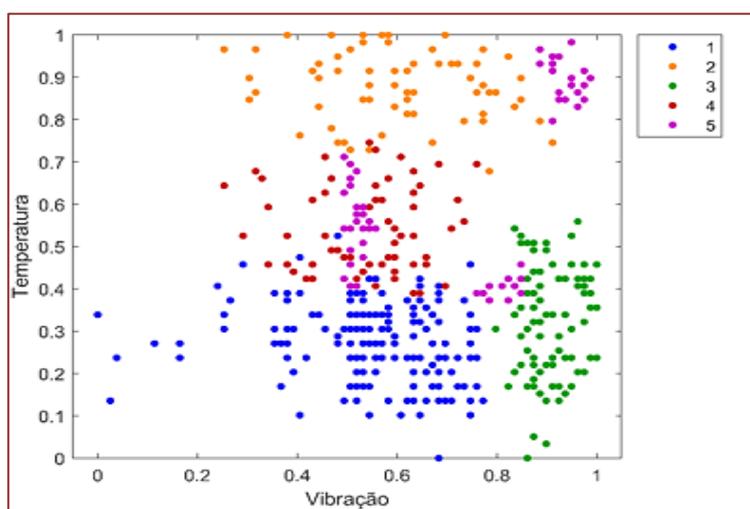


Fonte: Autoria própria.

As Figura 5.5 e 5.6 representam o espaço amostral das variáveis, após normalização, com redução de dimensionalidade de quatro para duas dimensões, obtidos com as abordagens de seleção de variáveis (Figura 5.5) e extração de variáveis (Figura 5.6), respectivamente. O gráfico da Figura 5.5 mostra o espaço bidimensional representado com as variáveis vibração e temperatura, que pela análise do algoritmo Predictor Importance, são consideradas as mais importantes para a modelagem. Observando a distribuição das amostras, nota-se que existe uma separabilidade interclasses entre as variáveis com algumas sobreposições nas bordas.

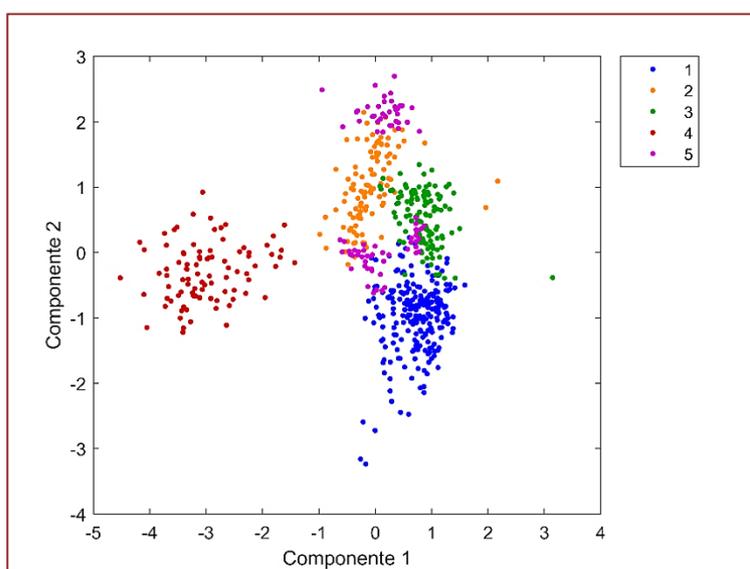
A Figura 5.6 ilustra o espaço amostral das variáveis, com a redução de dimensionalidade de 4 para 2 dimensões, obtido com a abordagem de extração de variáveis. No gráfico estão representadas as duas primeiras componentes principais após a aplicação da PCA. Nota-se que, nesse caso, ocorreu um agrupamento intraclasses, melhorando a separabilidade, o que pode favorecer o desempenho dos algoritmos de classificação.

Figura 5.5 – Espaço amostral bidimensional obtido com as variáveis vibração e temperatura.



Fonte: Autoria própria.

Figura 5.6 – Espaço amostral bidimensional com duas componentes principais com aplicação da PCA.

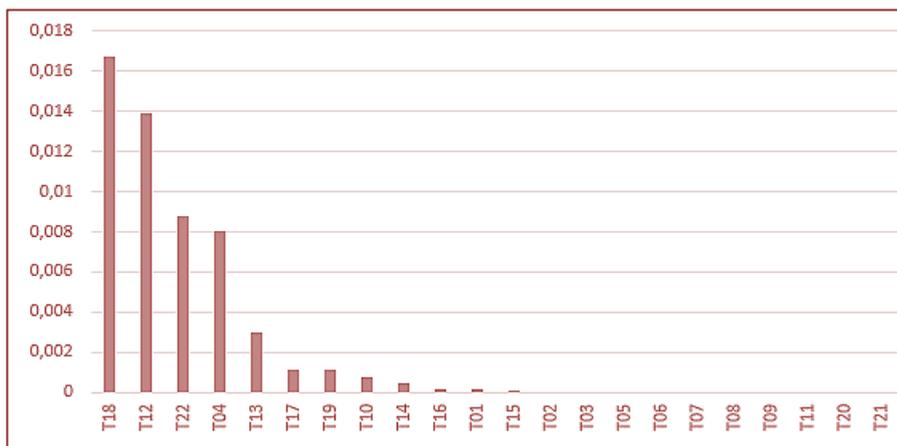


Fonte: Autoria própria.

5.2 MOAGEM

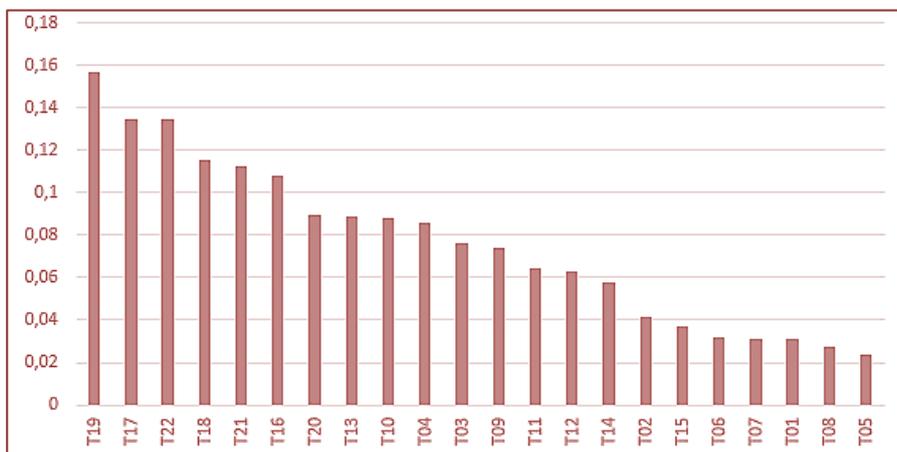
As Figuras 5.7 e 5.8 mostram os resultados da etapa de redução de dimensionalidade por seleção de variáveis para a base de dados do processo de moagem. Por uma decisão de projeto decidiu-se selecionar as dez variáveis mais relevantes, de acordo com os algoritmos Predictor Importance (PI) e Relief-F. A Tabela 5.1 reúne, em ordem decrescente de seus scores, as dez variáveis mais relevantes em cada caso. Observa-se que sete entre as dez variáveis são selecionadas por ambos os algoritmos, o que indica uma quase unanimidade dos algoritmos em relação a importância das variáveis para os modelos.

Figura 5.7 – Importância das variáveis de acordo com o algoritmo *Predictor Importance*.



Fonte: Autoria própria.

Figura 5.8 – Importância das variáveis de acordo com o algoritmo *Relief-F*.



Fonte: Autoria própria.

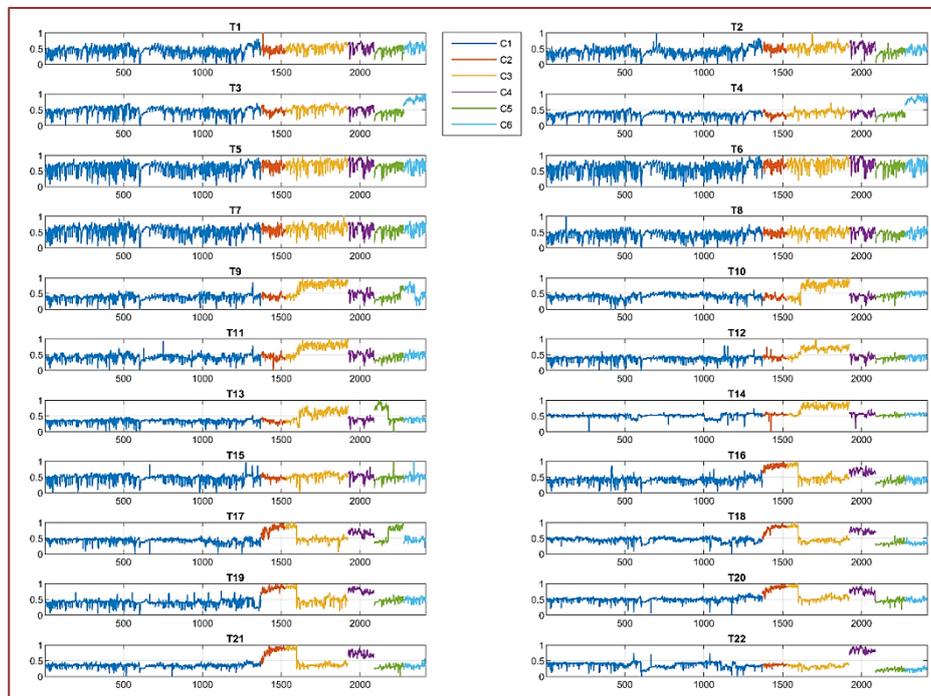
Tabela 5.1 - As dez variáveis com maiores *scores* após de seleção de características.

| Método de Seleção | Variáveis em ordem de relevância |
|-------------------|----------------------------------|
| <i>PI</i> | 18-12-22-04-13-17-19-10-14-16 |
| <i>Relief-F</i> | 19-17-22-18-21-16-20-13-10-04 |

A Figura 5.9 mostra o comportamento das variáveis no espaço amostral normalizado. Assim como no caso do conjunto Separação do Produto, em alguns instantes algumas variáveis apresentam comportamentos anormais. A Figura 5.10 apresenta o gráfico de caixas no qual é possível identificar a existência de

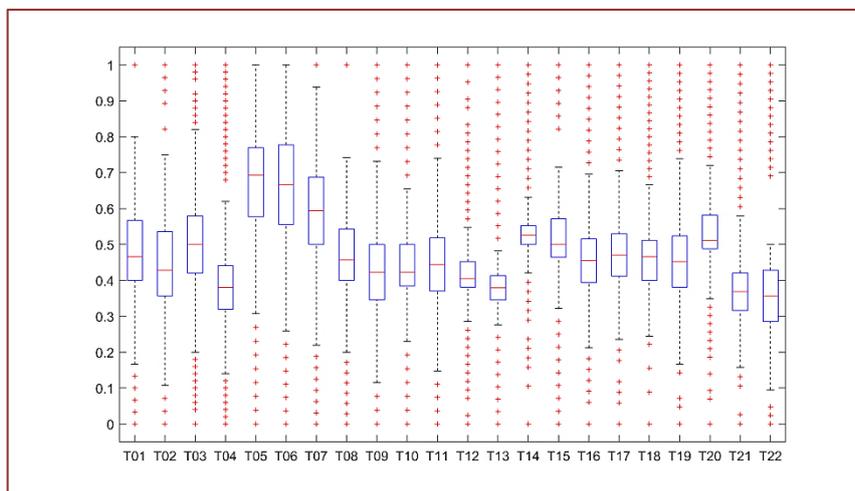
possíveis *outliers*, que podem estar associados a condições de falhas no processo, ou mesmo a ruídos de sensores.

Figura 5.9 – Comportamento das variáveis normalizadas T1 a T22 no conjunto de dados Moinho.



Fonte: Autoria própria.

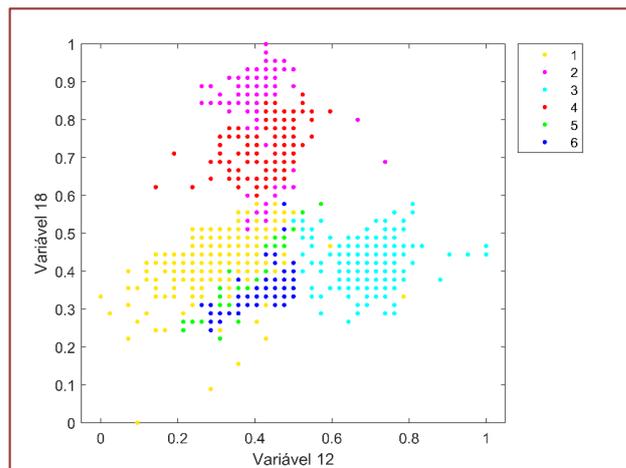
Figura 5.10 – Gráfico de caixas (*boxplot*) Moinho.



Fonte: Autoria própria.

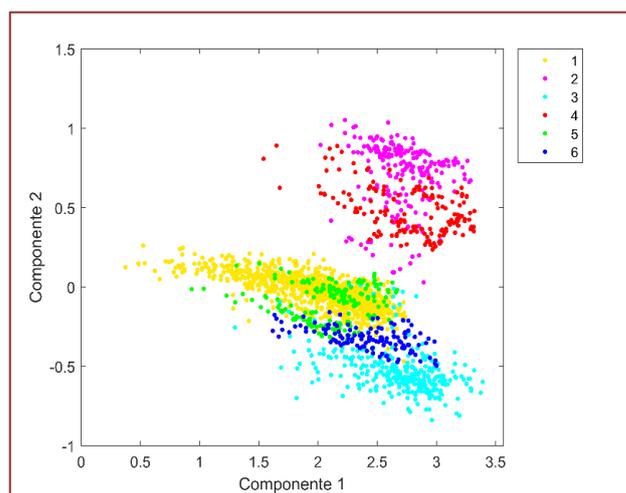
O espaço amostral das duas variáveis mais relevantes, obtidas por seleção de variáveis, de acordo com o método *Predictor Importance* pode ser visto na Figura 5.11. Nessa figura observa-se a grande dispersão dos dados mesmo após a normalização. A Figura 5.12 apresenta o espaço amostral das duas primeiras componentes após aplicação da *PCA*. Pelo gráfico é possível visualizar um melhor agrupamento intraclasses no espaço amostral, permitindo uma melhor separabilidade. Para fins de melhor visualização, a Figura 5.13 ilustra o espaço amostral representado pelas três primeiras componentes principais.

Figura 5.11 – Espaço amostral representado com duas variáveis no *dataset* Moagem.



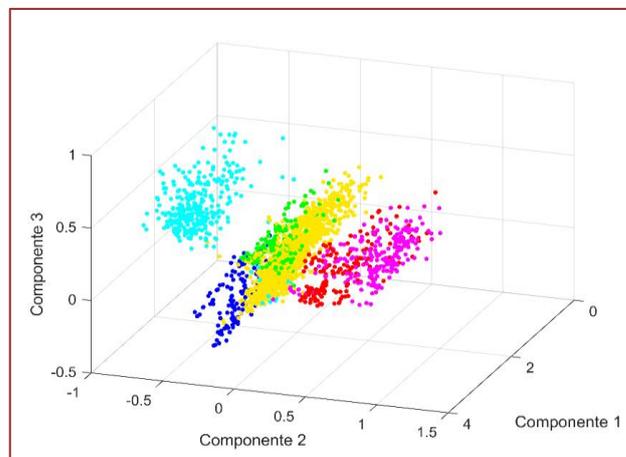
Fonte: Autoria própria.

Figura 5.12 – Espaço amostral representado com duas componentes principais no *dataset* Moagem.



Fonte: Autoria própria.

Figura 5.13 – Espaço amostral representado com três componentes principais no *dataset* Moagem.



Fonte: Autoria própria.

6. RESULTADOS

O desempenho no diagnóstico das falhas descritas na Seção 4.2 com os classificadores implementados por meio dos algoritmos descritos na Seção 4.4, está apresentado nas tabelas que seguem nessa seção. Vários testes com diferentes configurações de parâmetros dos classificadores foram realizados, e os resultados são apresentados separadamente para as bases de dados *Separação do Produto* e *Moagem*.

6.1 SEPARAÇÃO DO PRODUTO

Considerando o resultado da etapa de redução de dimensionalidade, os classificadores utilizados no processo de Separação do Produto foram treinados com três diferentes configurações de variáveis obtidas por técnicas de seleção ou extração. Na Tabela 6.1 está registrada o valor da acurácia nas etapas de treino e teste em cada caso. As designações *4-D*, *3-D* e *3-CP* representam, respectivamente, o conjunto de variáveis originais (*4-D*), as três variáveis mais relevantes selecionadas de acordo com os algoritmos *Predictor Importance* e *Relief-F* (*3-D*), e extração das três componentes principais pela *PCA* (*3-CP*). A primeira coluna (*Classificador*) identifica o tipo do classificador, bem como e sua configuração, de acordo com a descrição da Seção 4.4.

Tabela 6.1 - Desempenho dos classificadores medido pela acurácia *dataset* Separação do Produto.

| Classificador | 4-D | | PI 3-D | | Relief-F 3-D | | PCA 3-CP | |
|----------------|--------|-------------|-----------|-------------|-----------------|-------------|-------------|-------------|
| | Treino | Teste | Treino | Teste | Treino | Teste | Treino | Teste |
| 1-NN | 98.9 | 96.9 | 98.0 | 95.3 | 80.1 | 78.5 | 97.1 | 95.3 |
| 3-NN | 98.2 | 96.3 | 97.8 | 95.3 | 79.9 | 80.1 | 98.7 | 96.3 |
| 5-NN | 97.5 | 95.3 | 98.2 | 95.3 | 81.4 | 79.1 | 97.3 | 96.9 |
| Tree (entropy) | 95.1 | 97.4 | 96.2 | 96.3 | 76.1 | 80.6 | 93.3 | 92.1 |
| Tree (gini) | 94.6 | 93.2 | 94.0 | 94.2 | 77.0 | 81.7 | 94.0 | 94.2 |
| SVM (RBF) | 98.7 | 98.4 | 98.2 | 96.9 | 83.4 | 80.6 | 97.8 | 95.8 |
| SVM (Linear) | 93.5 | 92.1 | 93.7 | 90.6 | 78.3 | 75.9 | 91.3 | 91.6 |
| RNA | 99.5 | 95.3 | 98.2 | 93.7 | 87.7 | 79.1 | 98.2 | 94.2 |
| RF | 97.8 | 97.4 | 97.1 | 97.9 | 80.1 | 82.2 | 96.6 | 95.3 |
| NB | 91.3 | 88.0 | 91.3 | 87.4 | 77.4 | 75.4 | 91.5 | 89.0 |

Analisando a tabela 6.1, nota-se que, de forma geral, os classificadores que utilizaram o conjunto de variáveis originais (*4-D*), tiveram desempenho ligeiramente melhor do que os classificadores que utilizaram alguma técnica de redução de dimensionalidade. O melhor resultado geral foi obtido pelo classificador *SVM* (98,4%) com kernel *RBF* com configuração *4-D*. O melhor resultado geral foi obtido pelo classificador *SVM* (98,4%) com kernel *RBF*. Quando comparados os classificadores que utilizaram conjuntos de dados reduzidos, observamos que, o desempenho daqueles implementados por seleção e por extração de variáveis apresentaram desempenho equivalentes. Entre os classificadores implementados por seleção de variáveis, aqueles que utilizaram o algoritmo *Predictor Importance* (*PI*) apresentaram desempenho melhor que os que utilizaram *Relief-F*. De acordo com os melhores resultados para cada configuração das variáveis, que estão destacados na Tabela 6.1, nota-se que não houve um algoritmo que se mostrasse visivelmente superior aos demais. Contudo, baseado nos resultados, pode-se afirmar que o *Naive Bayes* (*NB*) foi o de pior desempenho. Como foi destacado na Seção 3.4, este classificador assume a independência das variáveis envolvidas na modelagem, o que não é uma consideração razoável em aplicações de diagnóstico de falhas, por exemplo, condições de vibração excessiva pode provocar aumento de temperatura em um processo.

6.2 MOAGEM

Para o diagnóstico de falhas no processo *Moagem* foram realizados testes com as seguintes configurações do *dataset*: (i) conjunto original de dados com vinte e dois atributos (*22-D*), (ii) seleção das dez (*10-D*), sete (*7-D*) e cinco (*5-D*) variáveis mais relevantes de acordo com os algoritmos *PI* e *Relief-F* e (iii) extração das dez (*10-CP*), sete (*7-CP*) e cinco (*5-CP*) primeiras componentes principais com a aplicação da *PCA* sobre o conjunto original. A Tabela 6.2 reúne os resultados dos testes com o conjunto original (*22-D*) e com a seleção pelo *PI*, e a Tabela 6.3 traz os resultados com o algoritmo *Relief-F* e extração de variáveis com *PCA*.

Tabela 6.2 - Desempenho dos classificadores medido pela acurácia *dataset* Moagem.

| Classificador | Predictor Importance | | | | | | | |
|----------------|----------------------|-------------|--------|-------------|--------|-------------|--------|-------------|
| | 22-D | | 10-D | | 7-D | | 5-D | |
| | Treino | Teste | Treino | Teste | Treino | Teste | Treino | Teste |
| 1-NN | 99.8 | 99.9 | 99.9 | 99.9 | 99.8 | 99.9 | 98.1 | 97.5 |
| 3-NN | 99.6 | 99.4 | 99.8 | 99.6 | 99.8 | 99.7 | 97.6 | 97.1 |
| 5-NN | 99.4 | 99.3 | 99.8 | 99.3 | 99.6 | 99.4 | 97.3 | 97.2 |
| Tree (entropy) | 99.2 | 99.3 | 99.4 | 99.3 | 98.5 | 99.4 | 97.5 | 96.3 |
| Tree (gini) | 99.2 | 98.8 | 99.3 | 99.2 | 99.0 | 99.3 | 97.0 | 96.4 |
| SVM (RBF) | 73.5 | 75.4 | 93.7 | 92.4 | 97.2 | 97.0 | 96.3 | 96.0 |
| SVM (Linear) | 99.8 | 99.6 | 99.5 | 99.4 | 99.4 | 99.7 | 96.2 | 96.3 |
| RNA | 100.0 | 99.9 | 99.9 | 99.6 | 99.9 | 99.9 | 99.1 | 96.8 |
| RF | 99.6 | 99.4 | 99.8 | 99.3 | 99.5 | 99.6 | 98.2 | 97.4 |
| NB | 96.4 | 96.1 | 96.5 | 96.8 | 96.3 | 97.5 | 93.4 | 94.2 |

Tabela 6.3 - Desempenho dos classificadores medido pela acurácia *dataset* Moagem.

| Classificador | Relief-F | | | | | | PCA | | | | | |
|----------------|----------|-------------|--------|-------------|--------|-------------|--------|--------------|--------|-------------|--------|-------------|
| | 10-D | | 7-D | | 5-D | | 10-CP | | 7-CP | | 5-CP | |
| | Treino | Teste | Treino | Teste | Treino | Teste | Treino | Teste | Treino | Teste | Treino | Teste |
| 1-NN | 99.8 | 99.3 | 91.4 | 92.8 | 89.4 | 92.3 | 99.8 | 100.0 | 99.7 | 99.6 | 98.5 | 98.9 |
| 3-NN | 99.5 | 99.2 | 91.3 | 93.9 | 89.8 | 91.9 | 99.7 | 99.6 | 99.6 | 99.4 | 98.7 | 98.9 |
| 5-NN | 99.5 | 99.3 | 90.8 | 92.7 | 90.3 | 92.0 | 99.4 | 99.4 | 99.4 | 99.3 | 98.6 | 98.6 |
| Tree (entropy) | 98.6 | 99.2 | 88.3 | 89.4 | 88.3 | 89.9 | 97.9 | 98.8 | 98.1 | 98.8 | 97.5 | 98.3 |
| Tree (gini) | 98.6 | 98.9 | 87.5 | 89.1 | 87.4 | 88.4 | 98.6 | 98.9 | 98.6 | 98.9 | 98.0 | 98.9 |
| SVM (RBF) | 93.7 | 93.5 | 90.7 | 92.3 | 91.4 | 92.1 | 88.5 | 87.0 | 96.1 | 96.1 | 98.1 | 98.2 |
| SVM (Linear) | 99.2 | 99.0 | 85.8 | 87.0 | 83.7 | 85.4 | 99.7 | 99.9 | 99.4 | 99.4 | 98.9 | 99.0 |
| RNA | 99.9 | 99.6 | 94.1 | 92.7 | 93.5 | 92.0 | 99.9 | 100.0 | 99.8 | 99.6 | 99.6 | 99.4 |
| RF | 99.5 | 99.2 | 91.8 | 92.8 | 91.3 | 92.8 | 99.6 | 99.4 | 99.6 | 99.3 | 98.9 | 99.2 |
| NB | 96.1 | 96.7 | 82.1 | 85.0 | 80.7 | 83.2 | 98.5 | 99.0 | 98.5 | 99.2 | 97.5 | 97.9 |

Em relação à configuração utilizando o conjunto original de variáveis (22-D), todos os modelos, com exceção do *SVM-RBF*, atingiram boa performance de classificação sendo que os algoritmos *1-NN* e *RNA* obtiveram os melhores resultados com acurácia de 99,9%. Examinando os resultados dos dez classificadores nota-se que a redução de dimensionalidade do conjunto, utilizando a *PCA* (10-CP) obteve o melhor desempenho geral com os algoritmos *1-NN* e *RNA* atingindo uma acurácia de 100%. Utilizando a redução de dimensionalidade com sete variáveis (7-D ou 7-CP) os melhores resultados foram alcançados utilizando os modelos *1-NN* e *RNA*, com acurácia de 99,9% pelo método de seleção baseado em Árvore de Decisão. A configuração utilizando somente cinco variáveis (5-D ou 5-CP) também obteve bons resultados, com destaque para o modelo implementado utilizando *RNA* na configuração (5-CP) no qual a taxa de acerto ficou em 99,4%.

De forma geral, todos os modelos tiveram boa performance na classificação das falhas com valores médios de acurácia acima de 90%. Assim como ocorreu no processo de *Separação do Produto*, o algoritmo de seleção *Predictor Importance* apresentou desempenho superior ao *Relief-F*. Em relação ao método de redução de dimensionalidade, os modelos obtidos por seleção e extração de variáveis apresentaram desempenho semelhantes. Os resultados indicam também que a redução da dimensionalidade pelo algoritmo *Relief-F* degrada mais significativamente o desempenho dos modelos à medida que se reduz o número de variáveis no modelo, o que não ocorre na seleção pelo *Predictor Importance* e *PCA*. Em relação ao desempenho das *SVM*, pode ser notado nas Tabelas 6.2 e 6.3 que os classificadores que utilizaram *kernel Linear* tiveram melhor desempenho para as mesmas configurações dos outros parâmetros.

7. CONCLUSÕES

Os resultados obtidos nos testes para diagnóstico das falhas mostram ser viável a implementação desses sistemas nos processos de *Separação do Produto e Moagem*. As amostras são separáveis pelos métodos de classificação investigados, o que foi confirmado pelo bom desempenho dos classificadores, que na maioria dos casos teve acurácia superior a 90%. Os melhores desempenhos em cada caso (98,4% para o processo de Separação do Produto e 100,0% para a Moagem) demonstram a possibilidade da elaboração de diagnósticos precisos e confiáveis.

Em todas as configurações dos classificadores, envolvendo o algoritmo utilizado para a classificação das falhas, bem como a estratégia para redução de dimensionalidade, foram obtidas elevadas taxas de acerto. Nesse contexto, a escolha da melhor configuração será uma solução de compromisso entre o tempo do diagnóstico e a sua precisão. Assim, a adoção de técnicas de redução de dimensionalidade pode favorecer a implementação de sistemas com capacidade de resposta mais rápida.

De forma geral, para o diagnóstico de falhas em processos industriais, classificadores como o *k-NN* e modelos de Redes Neurais Artificiais apresentaram melhor desempenho, uma vez que as funções densidade de probabilidade das classes do processo não são bem desconhecidas e seu modelo de distribuição não se assemelha a qualquer modelo conhecido. De forma geral, nenhum dos classificadores utilizados, cujas abordagens diferem entre si, apresentou desempenho superior, o que indica que aplicações idênticas à apresentada nesse trabalho sempre dependerão das especificidades dos processos investigados. Embora, as pesquisas atuais indiquem uma tendência crescente da utilização de técnicas de *Deep Learning* à detecção e diagnóstico de falhas em processos industriais, os resultados obtidos nesse trabalho mostram que os métodos tradicionais de *Machine Learning* podem ainda ser utilizados com sucesso.

REFERÊNCIAS

- [1] Basha, N., Nounou, M., and Nounou, H. (2018). Multivariate Fault Detection and Classification Using Interval Principal Component Analysis. *Journal of Computational Science*, v.27, 1–9.
- [2] Breiman, L. (2001). Random Forests. *Machine learning*, v.45, 5–32.
- [3] Breiman, L., Friedman, J., Stone, C.J., and Olshen, R.A. (1984). *Classification and Regression Trees*. CRC press.
- [4] Chambers, S., Johnston, R., and Slack, N. (2002). *Administração da Produção*. São Paulo: Atlas.
- [5] Chen, Z., Gryllias, K., and Li, W. (2019). Mechanical Fault Diagnosis Using Convolutional Neural Networks and Extreme Learning Machine. *Mechanical Systems and Signal Processing*, v.133, 106272.
- [6] Cortes, C. and Vapnik, V. (1995). Support-Vector Networks, *Machine learning*, v.20, pp. 273-297.
- [7] Cybenko, G. (1989). Approximation by Superpositions of a Sigmoidal Function. *Mathematics of Control, Signals and Systems*, v.2, 303–314.
- [8] Faceli, K., Lorena, A.C., Gama, J., and de Carvalho, A. (2011). *Inteligência Artificial - Uma Abordagem de Aprendizado de Máquina*. Ltc, Rio de Janeiro.
- [9] Fayed, H.A. and Atiya, A.F. (2009). A Novel Template Reduction Approach for the k-Nearest Neighbor Method. *IEEE Transactions on Neural Networks*, v.20, 890–896.
- [10] Gangsar, P. and Tiwari, R. (2019). A Support Vector Machine Based Fault Diagnostics of Induction Motors for Practical Situation of Multi-Sensor Limited Data Case. *Measurement*, v.135, 694–711.
- [11] Géron, A. (2019). *Hands-On Machine Learning With Scikit-Learn, Keras, and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems*. O’ReillyMedia.
- [12] Hagan, M.T. and Menhaj, M.B. (1994). Training Feed-Forward Networks With the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, v.5, 989–993.
- [13] Hair, J.F., Black, W.C., Babin, B.J., Anderson, R.E., and Tatham, R.L. (2009). *Análise Multivariada de Dados*. Bookman Editora.
- [14] Han, H., Cui, X., Fan, Y., and Qing, H. (2019). Least Squares Support Vector Machine (LS-SVM) Based Chiller Fault Diagnosis Using Fault Indicative Features. *Applied Thermal Engineering*, v.154, 540–547.
- [15] Hastie, T., Tibshirani, R., and Friedman, J. (2009). *The Elements of Statistical Learning: Prediction, Inference and Data Mining*. Springer-Verlag, New York.

- [16] Haykin, S. (2007). *Redes Neurais: Princípios e Prática*. Bookman Editora.
- [17] Kononenko, I. and Robnik-Sikonja, M. (2003). Theoretical and empirical analysis of *ReliefF* and *RReliefF*. *Machine Learning*, v.53, pp. 23–69.
- [18] Liu, R., Yang, B., Zio, E., and Chen, X. (2018). Artificial Intelligence for Fault Diagnosis of Rotating Machinery: A Review. *Mechanical Systems and Signal Processing*, v.108, 33–47.
- [19] Mitchell, J.S. (1993). *Introduction to Machinery Analysis and Monitoring*. PennWell Tulsa, Okla.
- [20] Mohanty, A. R. (2014). *Machinery condition monitoring: Principles and practices*. CRC Press.
- [21] Palácios, R. H. C., Da Silva, I. N., Goedel, A., Godoy, W. F., Da Silva, P. P. D., and Bazan, G. H. (2016). Diagnóstico Inteligente de Falhas no Rotor, Estator e Rolamento em Motores de Indução Trifásicos. XXI Congresso Brasileiro de Automática (CBA).
- [22] Quinlan, J.R. (1986). Induction of Decision Trees. *Machine Learning*, v.1, 81–106.
- [23] Rosenblatt, F. (1958). The Perceptron: a Probabilistic Model for Information Storage and Organization in the Brain. *Psychological review*, v.65, 386.
- [24] Rumelhart, D.E., Hinton, G.E., and Williams, R.J. (1985). Learning Internal Representations by Error Propagation. Technical report, California Univ San Diego La Jolla Inst for Cognitive Science.
- [25] Salzberg, S.L. (1994). C4. 5: Programs for Machine Learning by J. Ross Quinlan. Morgan Kaufmann Publishers, Inc., 1993.

Autores

ADRIEL DE OLIVEIRA FREITAS

- Mestrando em Energia e Ambiente pela Universidade da Integração Internacional da Lusofonia Afro-Brasileira(Unilab)
- Engenheiro Eletricista formado pela Universidade Federal do Ceará(UFC)
- Técnico em Eletromecânica pelo Serviço Nacional de Aprendizagem Industrial (SENAI)
- Técnico em Mecatrônica pelo Centro de Estudo e Pesquisa em Educação Profissional (CEPEP)
- Técnico em Eletrotécnica pelo Centro de Estudo e Pesquisa em Educação Profissional (CEPEP)

ALAN KARDEK RÊGO SEGUNDO

Possui graduação em Engenharia de Controle e Automação pela Universidade Federal de Ouro Preto (2008), mestrado em Engenharia Agrícola pela Universidade Federal de Viçosa (2010) e doutorado em Engenharia Agrícola pela Universidade Federal de Viçosa (2014). Atualmente é professor adjunto da Universidade Federal de Ouro Preto e coordenador do Programa de Pós-Graduação em Instrumentação, Controle e Automação de Processos de Mineração, em associação com o Instituto Tecnológico Vale - ITV. Tem experiência na área de Engenharia Elétrica, com ênfase em Circuitos Eletrônicos, Sistemas Embarcados e Instrumentação, atuando principalmente nos seguintes temas: microcontroladores, automação de processos e sistemas de monitoramento de parâmetros elétricos do solo.

ALEXANDRE SANTOS BRANDÃO

Possui graduação em Engenharia Elétrica pela Universidade Federal de Viçosa (2006) com ênfase em Automação e Sistemas de Potência. Realizou seu trabalho de monografia na área de Inteligência Artificial contemplando o tema: Redes Neurais Artificiais aplicadas ao reconhecimento de comandos de voz. Ainda nesta universidade, foi Tutor-Líder de Cálculo Diferencial e Integral durante seis semestres não consecutivos, onde aprimorou sua didática. Recebeu o título de Mestre em Engenharia Elétrica pela Universidade Federal do Espírito Santo (2008), com ênfase em Automação, atuando em Robótica Móvel, nos seguintes temas: controle não linear e robótica cooperativa. Em 2013, recebeu o título de Doutor em Engenharia Elétrica nessa mesma universidade, em regime de co-tutela com a Universidad Nacional de San Juan (UNSJ), Argentina, atuando no tema de Robótica Aérea. No Instituto de Automática (INAUT) da UNSJ, realizou parte das atividades de pesquisa de mestrado e de doutorado no âmbito do Colégio Doutoral Brasil-Argentina e recebeu o título de Doctor en Ingeniería de Sistemas de Control (2014). Atualmente, é Professor Adjunto da Universidade Federal de Viçosa, em regime de dedicação exclusiva, no curso de Engenharia Elétrica, cujo cargo foi assumido em 2010, e coordenador do Núcleo de Especialização em Robótica (NERO).

ANA CAROLINA FERREIRA

Engenheira Civil pela Universidade Federal de Ouro Preto- graduada em 2018. Durante a graduação exerceu trabalhos de iniciação científica no laboratório de ferrovias e asfalto e no laboratório de rejeitos. Mestrado em Geotecnia pelo Nugeo (Núcleo de Geotecnia - O.P), onde desenvolveu pesquisas relacionadas com o descomissionamento de barragens de rejeito provenientes da mineração.

ARYFRANCE ROCHA ALMEIDA

Atualmente é Prof. Adjunto II no curso de Engenharia Elétrica da Universidade Federal do Piauí - UFPI, na área de Sistemas Elétricos. Doutor em Engenharia Elétrica pela Universidade Federal do Ceará - UFC, na área de Sistemas de Energia Elétrica. Mestre em Engenharia Elétrica pela Universidade Federal do Maranhão - UFMA na área de Automação e Controle, graduado em engenharia elétrica pela Universidade Federal do Maranhão - UFMA. Atuando principalmente nas seguintes áreas de engenharia elétrica: Proteção de Sistemas Elétricos, Localização de faltas em Sistemas de Transmissão de Energia Elétrica, Qualidade da Energia Elétrica, Processamento de Sinais aplicados a Transitórios Eletromagnéticos em Sistemas Elétricos de Potência, Energia Solar Fotovoltaica, Sistemas Fotovoltaicos de Geração Distribuída e Energia Eólica.

BARTOLOMEU FERREIRA DOS SANTOS JUNIOR

Concluiu o doutorado em Engenharia Elétrica pela Universidade Federal de Santa Catarina em 2012. Concluiu o mestrado e o curso de graduação em Engenharia Elétrica pela Universidade Federal do Maranhão em 2007 e 2005 respectivamente. Atualmente é Professor Adjunto do Curso de Engenharia Elétrica da Universidade Federal do Piauí. Desenvolve pesquisas nas áreas de Sistemas Elétricos de Potência, Energias Renováveis, Qualidade de Energia Elétrica e Mercado de Energia Elétrica.

BRUNO MARTINS DE BIAZ

Mestre em Engenharia Elétrica pela Universidade Federal Fluminense (2018). Graduado em Engenharia Elétrica com ênfase Eletrotécnica pelo Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (2014) e graduado em Engenharia Elétrica com ênfase Computação pela Universidade Estácio de Sá (2009). Atualmente é Engenheiro Eletricista na Enel Distribuição Rio. Tem experiência na área de Engenharia Elétrica com ênfase em Distribuição de Energia Elétrica e Medição Eletrônica de Energia. Vasta experiência em Infraestrutura de TI.

CAMILA TABOSA DE SOUZA LIMA

- Graduanda em Engenharia Elétrica pela Universidade Federal do Ceará (UFC);
- Técnica em Mecânica Industrial pelo Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE).

CARINE RAMOS DE ALMEIDA GOTTSCHALL

Possui graduação em Engenharia Elétrica pelo Instituto Federal da Bahia (2018). Atualmente é mestranda em Engenharia Elétrica com ênfase em Sistemas Computacionais e Robótica pela Universidade Federal da Bahia. Suas áreas de interesse compreendem inteligência artificial, robótica, visão computacional e a inserção das mulheres na engenharia.

CLEIA SANTOS LIBARINO

Possui graduação em Engenharia de Computação pela Faculdade Independente do Nordeste - FAINOR (2007). Mestre em Engenharia Elétrica pela Universidade Federal da Bahia -UFBA (2012). Atualmente é Professora de Ensino Básico, Técnico e Tecnológico (EBTT) no Instituto Federal de Educação, Ciência e Tecnologia da Bahia. Integrante do grupo de Pesquisa GIPAR (Grupo de Inovação e Pesquisa em Automação e Robótica). Tem experiência na área de Engenharia Elétrica, com ênfase em Automação, atuando principalmente nas seguintes linhas de pesquisa: Aplicações com protótipos voltados para área de saúde. Aplicações com protótipos elétricos motorizados para navegação Autônoma.

DIEGO ASSEREUY LOBÃO

Engenheiro eletricista pela Faculdade Multivix e mestrando em Engenharia de Controle e Automação pelo Instituto Federal do Espírito Santo. Interesse em pesquisa: machine learning, deep learning, visão computacional, reconhecimento de padrões.

DIEGO HAJI CARVALHO CAMPOS

Graduado em Engenharia da Computação pelo CEFET-MG, mestrado em Ciência da Computação em curso na Universidade Federal de Minas Gerais. Tem experiência em modelagem 3D, engines de jogos como Unreal4 e Deep Learning voltado para visão computacional. Desenvolveu uma base de dados de placas de trânsito brasileiras para utilização em sistemas de veículos autônomos.

ELDER DE OLIVEIRA RODRIGUES

Graduado em Engenharia Elétrica pela Universidade Vale do Rio Doce - Univale (1994), Mestrado em Engenharia Elétrica pela Universidade Federal do Espírito Santo-UFES (1997) e Doutorado em Engenharia Mecânica pela Universidade Estadual de Campinas-UNICAMP (2005). Atualmente é professor efetivo do Centro Federal de Educação Tecnológica de Minas Gerais - CEFETMG, Campus Timóteo, curso Engenharia de Computação onde leciona disciplinas voltadas a área de sistemas digitais, circuitos, eletrônica e microcontroladores.

ERICK CARVALHO CAMPOS

Graduado em Engenharia Mecânica pela Universidade Federal de Viçosa, mestrado em Ciências Aplicadas à Saúde em curso na Universidade Federal de Juiz de Fora. Atualmente é Engenheiro Mecânico na Universidade Federal de Juiz de Fora - Campus Avançado de Governador Valadares. Possui experiência nas áreas de pesquisa aplicada e gestão de recursos públicos. Atualmente desenvolve projetos de IoT voltados para o gerenciamento de uso de condicionadores de ar e também para instrumentação de Unidades de Alimentação e Nutrição.

EVANDRO OTTONI TEATINI SALLES

Doutor em Engenharia Elétrica pela Universidade Estadual de Campinas, São Paulo, Brasil. Ele é um professor do Departamento de Engenharia Elétrica da Universidade Federal do Espírito Santo, Brasil. Suas áreas de interesse são processamento digital de imagens e sinais, reconhecimento de padrões e processamento de vídeo.

FABRÍCIO PEREIRA LUCAS

Mestre em engenharia elétrica e engenheiro de controle e automação pela Pontifícia Universidade Católica de Minas Gerais. Possui experiência em visão computacional, análise de big data, controle de processos, modelagem de sistemas elétricos de potência, inteligência computacional, aprendizagem de máquina, reconhecimento de padrões e computação granular.

FLÁVIO LUIS DE MELLO

Possui graduação em Engenharia de Computação pelo Instituto Militar de Engenharia (1998), mestrado em Engenharia de Sistemas (2003) e doutorado em Engenharia de Sistemas e Computação (2006) pelo Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia. Atualmente é Professor Associado da Universidade Federal do Rio de Janeiro, colaborador do Instituto Militar de Engenharia e do Centro de Defesa Cibernética. Tem experiência na área de Ciência da Computação, com ênfase em Teoria da Computação, atuando principalmente nos seguintes temas: inteligência artificial forte, inteligência de máquina, tecnologia da informação, defesa cibernética e modelos de computação.

FRANCISCO ALEXSANDRO SILVA FREITAS

Graduando em Engenharia Elétrica pela Universidade Federal do Ceará (UFC)

GENTIL AUER NETO

Bacharel em Engenharia Elétrica pela Universidade Federal do Espírito Santo, Brasil. Atualmente, ele é aluno do programa de Mestrado do Departamento de Engenharia Elétrica da Universidade Federal do Espírito Santo, Brasil. Suas áreas de interesse são processamento digital de imagens, aprendizado de máquinas e automação industrial.

ISABEL RAMOS HENRIQUES OLIVEIRA

Mestre em Engenharia Elétrica pela Universidade Federal de São João Del-Rei, na área de Eletromagnetismo Aplicado. Graduada em Engenharia Elétrica (Bacharelado) pelo Instituto Federal de Minas Gerais - Campus Formiga (2015). Atualmente professora do polo de inovação do Instituto Federal de Minas Gerais campus Formiga.

ISRAEL GONDRES TORNÉ

Possui Doutorado em Ciências Técnicas, na área de Engenharia Elétrica pela Universidade de Camaguey e revalidado pela Universidade Federal do Ceará. Mestrado em Engenharia Elétrica e Graduação em Engenharia Elétrica pela Universidade de Camaguey e reconhecido pela Universidade do Estado do Amazonas. Tem experiência na área de Engenharia Elétrica, com ênfase em Sistemas Elétricos de Potência e Eficiência Energética. Atualmente pertence ao Laboratório de Sistemas Embarcados, do centro de desenvolvimento HUB- Inovação e Tecnologia.

JOÃO ERIVANDO SOARES MARQUES

Possui graduação em engenharia mecânica pela Universidade Federal de Campina Grande(2004), graduação em Engenharia Elétrica pela Faculdade Independente do Nordeste(2018), mestrado em Engenharia Mecânica pela Universidade Federal da Paraíba(2006) e doutorado em Engenharia Mecânica pela Universidade Federal da Paraíba(2010). Atualmente é Professor do Instituto Federal de Educação Ciência e Tecnologia da Bahia. Atuando principalmente nos seguintes temas: Automação e Controle.

JOSÉ ALBERTO DIAZ AMADO

Possui graduação em Engenharia Eletrônica pela Universidade Católica Santa Maria (2003), revalidado como Engenheiro Eletricista pela Universidade Federal de Minas Gerais (2013). Mestre (2008) e Doutor (2013) em Engenharia Elétrica e Computação pela Universidade Federal do Rio Grande do Norte (UFRN). Pós-doutorado (2019) pelo Instituto de Ciências Matemáticas e de Computação da Universidade de São Paulo (USP). Atualmente é Professor de magistério superior no Instituto Federal de educação, Ciência e Tecnologia da Bahia (IFBA) e Pesquisador Associado da Universidade Católica San Pablo (UCSP - Peru). Tem experiência na área de Engenharia Elétrica, com ênfase em Automação, atuando principalmente nas seguintes linhas de pesquisa: Aplicações em robótica móvel Autônoma, Inteligência Artificial, Deep Learning, Visão Computacional, sistema auto-sustentáveis de energia, Aplicações com manipuladores robóticos, Aplicações de controle com técnicas de inteligência artificial.

JOSÉ GENILSON SOUSA CARVALHO

Formação em Eletrotécnica pelo Instituto Federal do Piauí - IFPI (2011-2013). Formação em Engenharia Elétrica pela Universidade Federal do Piauí em 2018. Atualmente, Eletrotécnico da Equatorial Energia Piauí, exercendo a função de controlador/operador de Subestações e linhas de transmissão no Centro de Operação Integrado - COI. No campo científico, mestrando do programa de pós graduação em Engenharia Elétrica UFPI na área controle e automação de sistemas, tendo como área de interesse a modelagem de alimentadores de distribuição e dos seus respectivos dispositivos de proteção, e a aplicação de técnicas de inteligência computacional para detecção, localização e classificação de faltas de alta impedância em redes de distribuição de energia.

KAROLAYNE BARBOSA MARTINS

Estudante de Engenharia Eletrônica na Universidade do Estado do Amazonas e graduada técnica em telecomunicações pela Fundação Matias Machline . Atua no setor de engenharia de testes e validação no Laboratório de Sistemas Embarcados (LSE), situado no centro de desenvolvimento "HUB - Inovação e Tecnologia". Participa de projetos de P&D para empresas do Polo Industrial de Manaus, nas áreas de indústria 4.0 e automação embarcada.

KEVEN SOARES DA COSTA

Acadêmico de Engenharia Elétrica pela Universidade do Estado do Amazonas e técnico em mecatrônica. Desenvolvedor de Hardware da empresa Vórtice Tecnologia e Inovação. Com experiência em projetos de automação elétrica, medição de energia, smart grids, sistemas embarcados e eletrônica. Auxiliar de engenharia elétrica, na empresa Genesys Serviços Técnicos LTDA, em 2017, onde adquiri experiência em manutenção elétrica predial e industrial, análise termográfica e SPDA.

KEVIN BRAATHEN DE CARVALHO

Graduado em Engenharia Elétrica pela Universidade Federal de Viçosa (UFV) e Mestre em Ciência da Computação também pela UFV. Durante sua graduação estudou 1 ano na Universidade de Brunel em Londres, onde contribuiu para a construção do braço robótico ambidestro dela. Seus interesses de pesquisa são nas áreas de robótica navegacional e social, interação humano-robô e inteligência artificial.

LENNON BRANDÃO FREITAS DO NASCIMENTO

Graduado em Engenharia Elétrica pela Universidade do Estado do Amazonas. Atua como pesquisador e desenvolvedor de hardware no Laboratório de Sistemas Embarcados (LSE) no centro de desenvolvimento HUB - Tecnologia e Inovação, situado na Escola Superior de Tecnologia da Universidade do Estado do Amazonas. Participa como desenvolvedor de hardware em projetos de pesquisa e desenvolvimento para empresas do Polo Industrial de Manaus (PIM), nas áreas de: Indústria 4.0; Automação Embarcada; Redes de Comunicação para Sistemas Embarcados; Eficiência Energética.

LÍGIA RODRIGUES MACHADO

Graduanda em Engenharia Elétrica pela Universidade Federal do Ceará (UFC)

LUCAS DELEON FERREIRA

Engenheiro Civil pela Universidade Federal de Ouro Preto e doutorado em Geotecnia pelo Núcleo de Geotecnia (NUGEO) da Escola de Minas da Universidade Federal de Ouro Preto. Professor da Universidade Federal de Ouro Preto (UFOP) e pesquisador colaborador do NUGEO. Desenvolve estudos nas áreas de Geotecnia Aplicada à Mineração; Fundações e Estruturas de Contenção.

LUIS HENRIQUE PEREIRA VASCONCELOS

Engenheiro Eletricista da Universidade Federal do Maranhão (UFMA). Mestrando na área de Controle e Automação de Sistemas do Programa de Pós-Graduação da UFPI. Possui especialização em Engenharia Elétrica com Ênfase em Instalações Industriais. Graduado em Engenharia Elétrica pela Universidade Federal do Piauí (UFPI). Foi membro atuante do grupo PET (Programa de Educação do Tutorial) do ano de 2015 ao de 2018, onde realizou atividades nas áreas de pesquisa, ensino e extensão. Estagiou como Engenheiro Eletricista no Tribunal de Justiça do Piauí. Tem interesse nas seguintes áreas: Transmissão e Distribuição de Energia Elétrica, Qualidade de Energia Elétrica em Sistemas de Potência, Automação de Sistemas Elétricos, Eficiência Energética, Energias Renováveis e Instalações Elétricas residenciais e industriais.

LUIZ ALBERTO PINTO

Engenheiro eletricista e mestre em informática pela Universidade Federal do Espírito Santo. Doutor em Engenharia Eletrônica e Computação pelo Instituto Tecnológico de Aeronáutica - 2011. Pós-doutorado no Intermedia Lab - Nano-Innov do Institut Telecom SudParis - França - 2015. Professor titular da Área de Controle e Automação do Instituto Federal do Espírito Santo. Interesse em pesquisa: machine learning, deep learning, visão computacional, reconhecimento de padrões.

MÁRCIO ZAMBOTI FORTES

Possui graduação em Engenharia Elétrica pela Universidade Severino Sombra (1991), Especialização em Manutenção pela UFRJ/UPADI (1999), MBA em Gestão de Negócios (IBMEC-2009), Mestrado em Engenharia de Energia pela Universidade Federal de Itajubá (2000) e Doutorado em Engenharia Elétrica pela Universidade de São Paulo (2007). É professor Associado II da Universidade Federal Fluminense (UFF) e atua nos Mestrados de Engenharia Elétrica e Telecomunicações e Profissional em Montagem Industrial. Tem experiência na área de Engenharia Elétrica, com ênfase em conservação e qualidade de energia, atuando principalmente nos seguintes temas: luminotécnica, geração distribuída, medição eletrônica, eletrônica de potência, gestão da manutenção e automação .

MARCOS MORAES TAVARES RONZANI

Graduação Engenharia Elétrica-Universidade Federal de Juiz de Fora – 2007. Mestrado Profissional em Instrumentação, Controle e Automação de processos de mineração – UFOP/ITV – 2018. Trabalhou na Usiminas como Engenheiro Eletricista Pleno. Atualmente como Engenheiro Eletricista Sênior pela VALE S.A.

MARCUS VINICIUS MARTINS MELO

Estudante de Engenharia Elétrica na Universidade do Estado do Amazonas e graduado técnico em eletrônica pelo Instituto Federal do Amazonas. Atua como gestor de projetos em equipes de extensão na Universidade do Estado do Amazonas. Interesse em projetos de sistemas embarcados, eficiência energética, automatização de processos e eficiência de desenvolvimento/produção.

MARIANE MILITÃO SANTANA

Graduada em Engenharia de Controle e Automação pela PUC-MG, Pós Graduada em Gerenciamento de Projetos pela PUC-MG e Mestre em Engenharia Elétrica pela PUC-MG. Atualmente, atua como Analista Pleno de Sistemas pela Accenture, fornecendo suporte ao sistema PIMS da Vale, dos fornecedores Osisoft e Aspentech. Possui inglês fluente. Organizada, comunicativa, responsável e com facilidade para aprender e trabalhar em equipe.

MAURY MEIRELLES GOUVÊA JÚNIOR

Graduação (1995) e mestrado (1998) em Engenharia Elétrica, com ênfase em sistemas de energia elétrica, pela Pontifícia Universidade Católica de Minas Gerais (PUC Minas) e doutorado em Inteligência Artificial, pela Universidade Federal de Pernambuco, em 2009. Foi professor visitante da Universidade de Strathclyde, Glasgow, Escócia, em 2007. É professor e pesquisador da PUC Minas desde 2003, onde conduz e participa de vários projetos de pesquisa e divulgação científica ligados ao planejamento e operação ótima de sistemas de energia elétrica e inteligência artificial. Suas áreas de interesse são estabilidade de sistemas elétricos, dinâmica de sistemas complexos, computação evolucionária e redes neurais.

MICHELLE MENDES SANTOS

Mestre em Engenharia Elétrica pela Universidade Federal de Minas Gerais, possui graduação em Engenharia de Controle e Automação pela mesma instituição. Atualmente é Docente do quadro efetivo do Instituto Federal de Educação Tecnológica de Minas Gerais (IFMG - Campus Betim) e coordenadora do curso técnico Integrado em Automação Industrial. Tem experiência nas áreas de Automação Industrial, Robótica Móvel, Visão Computacional e Redes de Sensores Sem Fio. Participou do grupo de Pesquisa e Desenvolvimento de Veículos Autônomos da UFMG (PDVA). Participa do Grupo de Pesquisa Prática em Tecnologia da Informação, Automação e Robótica do IFMG (PrATICAR).

NELBER XIMENES MELO

Professor Assistente do Curso de Engenharia Elétrica da Universidade Federal do Piauí, em Teresina. Mestre na área de Qualidade de Energia Elétrica e graduado em Engenharia Elétrica pela Universidade Federal do Ceará. Membro da Comissão Interna de Eficiência Energética da Universidade Federal do Piauí. Principais áreas de interesse: Sistemas Elétricos de Potência; Qualidade de Energia Elétrica; Smart Grids; Eficiência Energética e Fontes Alternativas de Energia.

NEUSA VALENTIM DA SILVA

Possui graduação em Tec. Mecânica, Modalidade Processos de Produção pela Faculdade de Tecnologia de Sorocaba(2003), graduação em Engenharia de Controle e Automação (Mecatrônica) pela Universidade Paulista(2010), especialização em MBA em Gestão de Projetos pela Anhanguera Educacional - Sorocaba - SP(2010) e mestrado-profissionalizante em Processos Tecnológicos e Ambientais pela Universidade de Sorocaba(2017). Atualmente é Professor II da Universidade de Sorocaba e Professora II da Universidade Paulista. Tem experiência na área de Engenharia de Produção, com ênfase em Engenharia do Produto.

PATRICK MARQUES CIARELLI

Doutor em Engenharia Elétrica pela Universidade Federal do Espírito Santo, Brasil. Atualmente, ele é um professor do Departamento de Engenharia Elétrica da Universidade Federal do Espírito Santo, Brasil. Suas áreas de interesse são processamento digital de imagens, aprendizado de máquina e recuperação de informação.

PELLIPE TOCCHETTO DINARDI

Acadêmico de Engenharia Elétrica pela Universidade do Amazonas e técnico em eletrotécnica. Pesquisador do laboratório INOVATEC-UEA em soluções para smart cities e indústria 4.0. experiência profissional como projetista e instalador de sistemas fotovoltaico, elétrica e automação industrial, geradores e subestações. Pesquisador em geração, distribuição e transmissão em sistemas elétricos com enfoque em smart city, smart gride e fontes renováveis. Pesquisador voluntário no Centro de Desenvolvimento de Tecnologias HUB - Tecnologia e Inovação durante o ano de 2018.

PYRAMO PIRES DA COSTA JÚNIOR

Possui graduação em Engenharia Elétrica pela Pontifícia Universidade Católica de Minas Gerais (1970), mestrado em Engenharia Elétrica pela Universidade Federal de Minas Gerais (1978) e doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas (1992). Atualmente é professor adjunto da Pontifícia Universidade Católica de Minas Gerais. Tem experiência na área de Engenharia Elétrica, com ênfase em Automação e Controle de Processos Elétricos e Industriais, atuando principalmente nos seguintes temas: redes neurais, power transformer, fault diagnosis based on dissolved gas, inteligencia computacional: em modelagem e identificação de sistemas, predição de series temporais, sistemas evolutivos na construção de cluster dinamico em "datamining".

RAIMUNDO CLÁUDIO SOUZA GOMES

Doutor pela Universidade Federal do Pará, pesquisando sobre Modelos de Smart Grids, tendo realizado estágio sanduíche de um ano na Politécnica da USP. Mestre pela Universidade Federal de Campina Grande na Paraíba e graduado em engenharia elétrica pelo Instituto de Tecnologia da Amazônia. Compõe o quadro de docentes da Escola Superior de Tecnologia da Universidade do Estado do Amazonas EST/UEA. É coordenador do Laboratório de Sistemas Embarcados (NSE) do centro de desenvolvimento "HUB - Inovação e Tecnologia", onde foi um dos colaboradores na criação e implantação do referido núcleo e atua em vários projetos de P&D para as empresas do Polo Industrial de Manaus. Desenvolveu trabalhos de P&D para as empresas do setor elétrico, tais como, El Paso e o Grupo Eletrobras (Manaus Energia e CEPISA) com pesquisas nas áreas de Smart Grid: sistemas eletrônicos de controle em redes de distribuição de energia elétrica, sistema de comutação suave de circuitos de baixa tensão para o balanceamento dinâmico de cargas monofásicas em sistemas elétricos trifásicos, desenvolvimento de sistemas de monitoramento, em tempo real, de transformadores de distribuição e de redes de baixa tensão. Por conta de quase trinta anos atuando na área tecnológica, acumula experiência de mais de dez anos no estudo de soluções de automação aplicadas em sistemas de distribuição de energia elétrica (incluído Smart Grids); dez anos no campo da tecnologia da informação (Teleprocessamento e Comunicações de Dados), três anos em engenharia de produtos e produção industrial, dez anos na coordenação de equipes de pesquisa, tendo realizado, ainda, trabalhos em sistemas distribuídos (pesquisa de mestrado) com aplicação em sistemas para inibição de furtos, empregando vinculação biométrica entre um indivíduo e a coleção de todos os seus bens tecnológicos dotados de recursos de controle e processamento eletrônico.

RAPHAEL HENRIQUE

Graduando de Engenharia de Controle e Automação, pela Escola de Minas de Ouro Preto (UFOP). Pesquisas de iniciação científica na área da elétrica, controle e instrumentação. Na equipe Inconidentes BAJA, desenvolveu estudos e aplicações de segurança automobilística e de aquisição de dados, envolvendo a parte elétrica do veículo.

RUBENS DE ANDRADE FERNANDES

Graduado em Engenharia Elétrica pela Universidade do Estado do Amazonas e técnico em eletrônica pelo Instituto Federal do Amazonas. Atua como pesquisador e desenvolvedor de hardware e software embarcado no Laboratório de Sistemas Embarcados (LSE) no centro de desenvolvimento HUB - Inovação e Tecnologia, situado na Escola Superior de Tecnologia da Universidade do Estado do Amazonas. Participa como arquiteto de desenvolvimento em projetos de pesquisa e desenvolvimento para empresas do Polo Industrial de Manaus (PIM), nas áreas de: Indústria 4.0; Automação Embarcada; Redes de Comunicação para Sistemas Embarcados; Eficiência Energética. Interesse em projetos de sistemas embarcados e hardware dedicado para incorporar sistemas inteligentes, automatização de processos e para melhorar eficiência energética.

SAULO NEVES MATOS

Técnico em Automação Industrial no Instituto Federal Minas Gerais - Campus Ouro Preto e é graduando em Engenharia de Controle e Automação pela Universidade Federal de Ouro Preto. Atuou em 2014 a 2016, na equipe de Aerodesign 12Bis na área de projeto elétrico, em que desenvolveu um sistema de telemetria. No ano de 2015, participou do programa pro-ativa, desenvolvendo um tutorial para criar um sistema de aquisição de dados remoto, alimentado por células fotovoltaicas. Desenvolveu os projetos de iniciação científica: Aperfeiçoamento e desenvolvimento dos sistemas de medição de nível e telemetria do veículo BAJA da UFOP no ano de 2017 e Desenvolvimento de sistema de controle para um motorgerador a diesel com injeção de gás de eletrólise, em 2018.

SILAS MARTINS SOUSA

Graduado em Engenharia Elétrica no IFMG campus Formiga/MG. Trabalhei com Automação Industrial em empresas integradoras de Sistemas de Automação e também na indústria CSN-Cimentos em Arcos/MG. Sou mestre em Engenharia Elétrica pelo CEFET-MG. Atuei como professor substituto no IFMG campus Ouro Preto/MG e atualmente sou instrutor no SENAI de São João del Rei/MG.

THALES TERROLA E LOPES

Possui graduação em Engenharia Elétrica pela UFSJ (2001) e mestrado e doutorado em Engenharia Elétrica, com ênfase em Sistemas de Energia Elétrica, pela UFJF (2003) e pela COPPE/UFRJ (2008), respectivamente. Atualmente, trabalha como Professor Adjunto AII na Universidade Federal Fluminense (UFF) e como Engenheiro Eletricista na Eletrobras. Já foi professor dos cursos de graduação em Engenharia Elétrica do CEFET-RJ, UFRJ e USU. Tem experiência em modelagem computacional para Sistemas de Elétricos de Potência, destacando-se o desenvolvimento de modelos de estimadores de estado, aplicação de técnicas inteligentes e modelos de otimização, e análise da estabilidade em regime permanente e transitório do sistema elétrico.

VANDILBERTO PEREIRA PINTO

Pós-doutorado no Instituto Tecnológico de Aeronáutica-ITA (2017), Doutorado em Engenharia Elétrica pela Universidade Federal do Ceará, mestrado em Engenharia Elétrica pela Universidade Federal do Ceará, Especialização em Matemática pela Universidade Estadual do Ceará, graduação em Matemática pela Universidade Federal do Ceará, formação Técnica e tecnológica Pelo Centro Federal de Educação Tecnológica do Ceará em Telecomunicações. Atualmente é professor Adjunto IV da Universidade da Integração Internacional da Lusofonia Afro-Brasileira (UNILAB) - Instituto de Engenharias e Desenvolvimento Sustentável (IEDS) e do Programa de Pós-graduação em Engenharia Elétrica e Computação da UFC (PPGEEC-UFC) da Universidade Federal do Ceará no Campus de Sobral.

VITOR HUGO FERREIRA

Possui graduação em Engenharia Elétrica com ênfase em Sistemas e Controle pela UNIFEI (2002), Mestrado (2005) e Doutorado (2008) em Sistemas de Potência pela COPPE/UFRJ. Atualmente é Professor Associado nível 2 da Universidade Federal Fluminense (UFF). É o atual coordenador do Comitê Técnico de Sistemas de Potência da Sociedade Brasileira de Automática (SBA). Atua como coordenador de projetos de pesquisa, desenvolvimento e inovação (P, D & I) desde 2008, contribuindo para o desenvolvimento de soluções de inteligência computacional para o setor de energia. Tem experiência em sistemas elétricos de potência, inteligência computacional e sistemas de apoio a decisão.

VITOR THINASSI BASILIO

Graduando em Engenharia Elétrica pela Universidade Federal de Viçosa. Fez iniciação científica na área de reconhecimento de ações por meio de RNA.

WALDEMAR BONVENTI JR.

Graduação em Física Bacharelado e Licenciatura pela USP (1988), mestrado em Física pela USP (1992) e doutorado em Engenharia Elétrica (Sistemas Digitais e Eng^a de Computação) pela USP (2005). Atualmente é professor da Universidade de Sorocaba (Pós-Graduação em Processos Tecnológicos e Ambientais) e professor Pleno II do Centro Estadual de Educação Tecnológica Paula Souza. Tem experiência na área da Computação, atuando principalmente nos seguintes temas: análise de dados, processamento de imagens, lógica fuzzy, absorção óptica e colorimetria, ensino de ciências, física e engenharia.



ISBN: 978-65-86127-20-1

CSL



9 786586 127201