

APLICAÇÕES DE GOAL PROGRAMMING NO SUPORTE À DECISÃO:

Projetos Integrados em Engenharia de
Produção

Renata Melo e Silva de Oliveira
Yvelyne Bianca Lunes Santos
Norma Ely Santos Beltrão
(Organizadoras)



Editora Poisson

1ª EDIÇÃO

2020

Renata Melo e Silva de Oliveira
Yvelyne Bianca Iunes Santos
Norma Ely Santos Beltrão
(Organizadoras)

Aplicações de *Goal Programming* no suporte à decisão:
Projetos Integrados em Engenharia de Produção

1ª Edição

Belo Horizonte
Poisson
2020

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
Ms. Valdiney Alves de Oliveira – Universidade Federal de Uberlândia

Dados Internacionais de Catalogação na Publicação (CIP)

A642

**Aplicações de Goal Programming no suporte à
decisão: Projetos Integrados em Engenharia
de Produção/ Organização: Renata Melo e
Silva de Oliveira, Yvelyne Bianca Iunes
Santos, Norma Ely Santos Beltrão - Belo
Horizonte - MG: Poisson, 2020**

Formato: PDF

ISBN: 978-65-86127-76-8

DOI: 10.36229/978-65-86127-76-8

Modo de acesso: World Wide Web

Inclui bibliografia

**1. Engenharia 2. Produção. I. Oliveira,
Renata Melo e Silva de. II. Santos,
Yvelyne Bianca Iunes. III. Beltrão, Norma
Ely Santos.**

CDD-658

O conteúdo do livro e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva do seu respectivo autor.

www.poisson.com.br

contato@poisson.com.br



ORGANIZADORAS

Renata Melo e Silva de Oliveira, D.Sc



Engenheira de Produção graduada na Universidade do Estado do Pará (UEPA) em 2005. Concluiu em 2007 o mestrado em Engenharia de Produção na Universidade Federal de Santa Catarina (UFSC). Em 2018, tornou-se doutora em Engenharia e Gestão Industrial na Universidade do Porto (UP) em Portugal. Desde 2009, é professora na UEPA e atua principalmente nas áreas de Pesquisa Operacional; Análise multicritério de apoio à decisão (MCDM/A), Avaliação de Desempenho e Gestão da Sustentabilidade. Renata é também professora colaboradora no Programa de Pós-Graduação em Ciências Ambientais (PPGCA) da UEPA. Além disso é investigadora do Núcleo de Pesquisas Aplicadas ao Desenvolvimento Regional (NUPAD), o qual ajudou a fundar em 2008. Desde 2013 desenvolve pesquisas na Faculdade de Engenharia da Universidade do Porto (FEUP) via INESC TEC (Portugal). Também colabora com professores do Departamento de Informática e Estatística (INE) da UFSC. Em 2019, foi prof.^a visitante em Lublin University of Technology (POLLUB) na Polônia.

Yvelyne Bianca Lunes Santos, D.Sc



Possui graduação em Engenharia Civil pela Universidade Federal do Pará (1995), mestrado em Engenharia Civil pela Pontifícia Universidade Católica do Rio de Janeiro (1998) e doutorado em Engenharia de Recursos Naturais da Amazônia pela Universidade Federal do Pará (2012). É Professora da Universidade do Estado do Pará (UEPA) e Coordenadora do Curso de Graduação em Engenharia de Produção da UEPA. Tem experiência na área de Engenharia de Produção, com ênfase em Pesquisa Operacional e Planejamento e Controle da Produção, atuando principalmente nos seguintes temas: Otimização de Processos Produtivos, Modelagem Matemática e Processos Estocásticos.



Norma Ely Santos Beltrão, D.Sc

Possui Pós-doutorado em Sensoriamento Remoto na Faculdade de Ciências da Universidade do Porto (FCUP), Portugal (2017-2019), doutorado em Economia Agrícola na Justus-Liebig-Universität Giessen na Alemanha (2008), mestrado em Engenharia de Produção pela Universidade Federal de Santa Catarina (1996), e graduação em Engenharia Civil pela Universidade Federal do Pará (1992). É professora da Universidade do Estado do Pará (UEPA) desde 1998, onde é professora permanente do Programa de Pós-Graduação em Ciências Ambientais (PPGCA). É líder do grupo de pesquisa Núcleo de Pesquisas Aplicadas ao Desenvolvimento Regional (NUPAD) e desenvolve pesquisas nas áreas de Desenvolvimento Regional, Política e Gestão Ambiental, Economia ambiental, Valoração ambiental, Serviços Ecossistêmicos e o uso de metodologias de Geoprocessamento e Sensoriamento remoto na identificação de variações ambientais em território Amazônico utilizando as seguintes ferramentas: QGIS, SNAP e Google Earth Engine.

Lista de Autores

Organização

D.Sc. Renata Melo e Silva de Oliveira

D.Sc. Yvelyne Bianca Lunes Santos

D.Sc. Norma Ely Santos Beltrão

Orientação dos Projetos

Prof.^a D.Sc. Renata Melo e Silva de Oliveira

Estudantes

Devisson Mesquita dos Santos

Fernanda Leandra Leal Lopes

Naira Gabriela do Nascimento Vieira

Nelane Araújo de Sousa

Pedro Matheus d'Oliveira

Syanne do Socorro Lobato Gonçalves

Thailon Tiago de Sousa Carneiro

Prefácio

Esse livro é recomendado pela coordenação do curso de graduação em Engenharia de Produção da Universidade do Estado do Pará (UEPA). Os estudos apresentados nessa obra são de caráter interdisciplinar e fundamentam-se nos domínios da Pesquisa Operacional, da Análise Multicritério de Apoio à Decisão (MCDM/A). A temática do Desenvolvimento Sustentável (DS) foi abordada nos estudos aplicados aqui reportados, cuja perspectiva adotada foi o da Agenda 2030 da Organização das Nações Unidas (ONU).

Os autores aplicam a técnica denominada *Goal Programming* (programação por metas) para abordar problemas multidisciplinares práticos observados na gestão pública. Dois dos estudos reportados foram desenvolvidos em 2019 no âmbito da disciplina integradora “Atividade de Formação Complementar III” em que foram desenvolvidos projetos integrados sob orientação da prof.^a D.Sc. Renata Melo e Silva de Oliveira.

Apesar do viés interdisciplinar, os alunos foram estimulados a desenvolver habilidades, competências e atitudes necessárias a vivência cotidiana do engenheiro de produção, e oportunizando relevantes aprendizados técnico-científicos.

Esse livro está estruturado em seis capítulos. O Capítulo 1 é introdutório e descreve alguns desafios lançados ao engenheiro de produção do século XXI. O Capítulo 2 contextualiza o paradigma da disciplina AFC III como instrumento de integração disciplinar no âmbito do curso de Engenharia de Produção da UEPA. O Capítulo 3 traz uma breve revisão conceitual sobre MCDM/A e *Goal Programming*. Os Capítulos 4, 5 e 6 são estudos de MCDM/A aplicada à gestão pública, especificamente nas áreas de Saúde, Planejamento Urbano e Educação Superior.

Em sua essência, essa obra constitui um presente aos nossos alunos e professores, os quais descobriram, de forma determinante e motivadora, seus potenciais de integração humana, superação de desafios e criatividade.

Yvelyne Bianca Iunes Santos, D.Sc.

Coordenadora do Curso de Graduação em Engenharia de Produção da UEPA

Sumário

Capítulo 1: Introdução	09
Renata Melo e Silva de Oliveira, Norma Ely Santos Beltrão DOI: 10.36229/978-65-86127-76-8.CAP.01	
Capítulo 2: O contexto dos projetos integrados	12
Renata Melo e Silva de Oliveira DOI: 10.36229/978-65-86127-76-8.CAP.02	
Capítulo 3: Definições de <i>Goal Programming</i>	15
Renata Melo e Silva de Oliveira DOI: 10.36229/978-65-86127-76-8.CAP.03	
Capítulo 4: Decisões sobre vacinação no SUS	29
Devisson Mesquita dos Santos, Fernanda Leandra Leal Lopes, Pedro Matheus d'Oliveira, Syanne do Socorro Lobato Gonçalves, Renata Melo e Silva de Oliveira DOI: 10.36229/978-65-86127-76-8.CAP.04	
Capítulo 5: Decisões no planejamento urbano	36
Naira Gabriela do Nascimento Vieira, Nelane Araújo de Sousa, Thailon Tiago de Sousa Carneiro, Renata Melo e Silva de Oliveira DOI: 10.36229/978-65-86127-76-8.CAP.05	
Capítulo 6: Decisões na educação superior	43
Renata Melo e Silva de Oliveira DOI: 10.36229/978-65-86127-76-8.CAP.06	

CAPÍTULO

01

Introdução

Renata Melo e Silva de Oliveira

Norma Ely Santos Beltrão

Esse livro foi idealizado por professores e pesquisadores do Núcleo de Pesquisa Aplicada ao Desenvolvimento Regional (NUPAD) da Universidade do Estado do Pará (UEPA) como uma iniciativa de popularização da ciência. Um dos objetivos principais do NUPAD é desenvolver conhecimento com viés interdisciplinar envolvendo prioritariamente as áreas de análise multicritério de apoio à decisão (MCDM/A), Geoprocessamento e Logística Reversa. O conhecimento do NUPAD é gerado por meio de pesquisas aplicadas, cujos resultados são comunicados à sociedade por meio de artigos científicos, de livros técnicos e da capacitação de pessoas.

O NUPAD é também vinculado ao Programa de Pós-Graduação em Ciências Ambientais (PPGCA) da UEPA. Portanto, também funciona como um ambiente de formação multidisciplinar que integra em atividades transversais professores, pesquisadores, alunos de pós-graduação e de graduação. Desde sua criação em 2008, o NUPAD é agente catalizador na organização de conteúdos técnico-científicos relevantes à atualidade, os quais enfocam temas considerados estratégicos para o desenvolvimento sustentável na região da Amazônia Brasileira.

Esse livro reporta aplicações de MCDM/A desenvolvidas no curso de Engenharia de Produção da UEPA com enfoque na Agenda 2030 da ONU. Especificamente, os estudos reportados nesse *e-book* estão associados aos seguintes Objetivos de Desenvolvimento Sustentável (ODS):

- Saúde e Bem-estar (ODS 3);
- Educação de Qualidade (ODS 4);
- Cidades e Comunidades Sustentáveis (ODS 11);
- Consumo & Produção Responsáveis (ODS 12).

Desde 2015, o curso incorporou em sua grade curricular alguns conteúdos associados ao Consumo & Produção Responsáveis. Portanto, passou-se a fomentar o desenvolvimento de soluções para problemas de engenharia orientadas à sustentabilidade. Essa mudança foi implementada no curso como forma de atender a demanda social por produtos de manufatura e de serviços que não comprometam o bem-estar das pessoas e dos ecossistemas.

Desenvolver e implementar sistemas de produção mais amigáveis ao meio ambiente e à sociedade representa ao mesmo tempo um compromisso ético e um desafio ao crescimento econômico. Por isso, essa

mudança de paradigma na Engenharia de Produção do século XXI traz consigo significativos impactos na forma de abordar problemas práticos. São exemplos desses impactos:

- Processos geridos de modo mais eficiente, auxiliando a criação de novos postos de trabalho empregos frente ao crescente nível de automação na manufatura, nos serviços e na gestão pública;
- O combate às mudanças climáticas e uso inteligente de fontes renováveis de energia;
- Desenvolvimento de soluções viáveis para o bem-estar da população, sem comprometer o bem-estar das gerações futuras.

Essa mudança também oferece oportunidades de atuação do Engenheiro de Produção em novas frentes. Por exemplo, ações em prol do bem-estar da população podem ser realizadas por meio de aplicações de otimização no planejamento urbano e na educação superior.

A otimização pode ser benéfica para construir e analisar cenários em que se simula a alocação de recursos naturais de forma mais racional. Nesse contexto, o conceito de cidades inteligentes emergiu na década de 2010 para definir áreas urbanas em que soluções tecnológicas mais verdes são implementadas para apoiar o desenvolvimento urbano sustentável. Portanto, as novas competências do Engenheiro de Produção podem ser necessárias para analisar esses sistemas urbanos (e.g., armazenamento e distribuição de energia ou água; mobilidade urbana; coleta e tratamento de resíduos; prevenção de epidemias).

Um dos problemas urbanos abordados nesse livro é a gestão de resíduos sólidos e atendimento da legislação ambiental no contexto do desenvolvimento sustentável. A gestão de resíduos sólidos em grandes centros urbanos ganhou notoriedade desde os anos 2000 por conta do seu alto impacto na saúde pública e também por causa da crescente pressão sobre o meio ambiente. No Brasil, esse problema pode se agravar com a iminência do esgotamento da capacidade instalada dos aterros sanitários e lixões.

Esse problema poderá ser mitigado pelo estabelecimento da simbiose entre distritos industriais e cidades inteligentes. A simbiose permitiria que alguns resíduos de centros urbanos sejam utilizados em um distrito industrial para reciclagem, reutilização ou geração de energia. Soluções como essa tem recebido atenção porque ao mesmo tempo em que fazem girar a economia circular, podem atenuar o problema da falta de capacidade instalada em aterros sanitários.

No caso saúde pública, o Brasil tem a meta de erradicar epidemias de doenças transmissíveis, dentre elas a AIDS, hepatite e o HPV até o ano de 2030. Essa meta foi definida na Agenda 2030 da Organização das Nações Unidas (ONU), mas a recente redução orçamentária para a saúde pública no país pode representar um obstáculo aos programas de imunização do Sistema Único de Saúde (SUS). As metas de vacinação e a redução orçamentária são considerados objetivos conflitantes na gestão pública.

Existe uma variedade das técnicas de MCDM/A que pode ser aplicada pelo engenheiro de produção e outros profissionais para auxiliar o alcance do desenvolvimento sustentável. Para tanto, faz-se necessário formar profissionais capazes de analisar tais problemas e de pensar em soluções viáveis para auxiliar no desenvolvimento da indústria e das cidades sem comprometer o suporte de vida no planeta.

Esse livro não pretende e nem é capaz de esgotar as discussões sobre o futuro da Engenharia de Produção. Porém, as ideias e modelos de otimização especificados em cada capítulo podem auxiliar na discussão entre praticantes e professores dessa engenharia sobre o uso de técnicas quantitativas para abordar problemas multidisciplinares relevantes à sociedade do século XXI.

Os projetos integrados de Engenharia de Produção 2019 foram desenvolvidos no contexto da disciplina “Atividade de Formação Complementar” (AFC III) na Universidade do Estado do Pará (UEPA). Ao cursarem a AFC III, acadêmicos do 6º semestre são desafiados a propor soluções funcionais a problemas práticos de engenharia. Esses projetos integrados são orientados por ao menos um professor com *expertise* em uma subárea da engenharia de produção.

O objetivo da AFC III na UEPA é desenvolver nos participantes a competência da perspectiva. Segundo Chiavenatto (2014), a competência da perspectiva consiste em transformar teoria em prática na presença de problemas reais. Nesse contexto, os projetos foram orientados para refletir a capacidade de pôr em ação os conhecimentos de Engenharia Organizacional e Pesquisa Operacional. O enfoque definido foi o de diagnosticar e propor soluções para questões associadas à sustentabilidade na gestão pública da saúde, no planejamento urbano e na educação superior.

Os objetivos traçados para AFC III/2019 foram baseados nas diretrizes curriculares nacionais para cursos de engenharia (CNE, 2018). Eles estão listados a seguir:

- Capacitar os acadêmicos a desenvolver atividades estruturadas através de um projeto que integre subáreas da engenharia de produção;
- Formular e solucionar problemas interdisciplinares associados à Pesquisa Operacional;
- Desenvolver a capacidade incorporar aspectos éticos, sociais, culturais e ambientais na formulação e solução de problemas de engenharia;
- Gerar soluções inovadoras de problemas práticos por meio da análise, síntese e otimização processos;
- Desenvolver de forma autônoma atividades técnicas na presença de equipes e temas interdisciplinares;
- Desenvolver a capacidade de comunicação técnica escrita e oral;
- Utilizar tecnologias da informação e comunicação (TICs).

Para alcançar os objetivos traçados, os participantes da AFC III foram convidados a utilizar os conhecimentos adquiridos ao longo do curso (e.g.; metodologia da pesquisa; métodos quantitativos;

informática aplicada) para formular e solucionar problemas de otimização multiobjectivo utilizando *Goal Programming*.

A técnica *Goal Programming* (GP) é considerada uma extensão da programação linear (PL). A GP tem como principal objetivo dar suporte a decisão no contexto da gestão organizacional. Desde os anos de 1960, a popularidade de GP em meio a gestores, analistas e acadêmicos tem aumentado devido a facilidade do seu uso e por ser capaz de gerar resultados de fácil interpretação.

Apesar de focar especificamente em *Goal Programming*, o conteúdo desse livro pode ser útil a profissionais interessados no uso de técnicas de apoio à decisão. Os exemplos ilustrativos aqui reportados são particularmente interessantes a educadores, acadêmicos e praticantes da Engenharia de Produção e gestores. Similarmente, interessados em estudar a aplicabilidade de métodos quantitativos para resolver problemas característicos da gestão pública e da gestão organizacional também poderão se beneficiar da leitura deste material.

O processo decisório na disciplina iniciou-se com a própria seleção de temas. Foram propostos seis temas aos participantes para que escolhessem aquele de maior interesse de cada equipe. Ao longo de um semestre, cada equipe de analistas efetuou as seguintes atividades:

- Seleção do tema e identificação de um problema multiobjectivo associado à Agenda 2030;
- Seleção de fontes e coleta de dados;
- Formulação de modelos de *Goal Programming*;
- Solução dos problemas formulados e especificação de cenários;
- Elaboração de um relatório técnico;
- Preparação de um vídeo tutorial para desenvolver algumas competências de comunicação usando tecnologias do século XXI;
- Opcionalmente, validação de resultados com um tomador de decisão.

Em 2019, a equipe de analistas selecionou dentre seis os seguintes três temas reportados na tabela 1.

Tabela 1 temas selecionados pelos participantes

Subárea de Engenharia de Produção	Aplicações
Engenharia da Sustentabilidade	Planejamento urbano da gestão de resíduos sólidos
Engenharia Organizacional	Alocação de recursos no contexto da saúde pública
	Alocação de recursos no contexto da educação pública

No Capítulo 3, o leitor encontra um material introdutório sobre a técnica *Goal Programming*, o qual é baseado na literatura internacional específica.

No Capítulo 4, apresenta-se uma aplicação de GP para avaliar cenários de decisão para distribuição de vacinas no SUS. Os resultados discutidos foram validados por um gestor público especialista na área de saúde.

No Capítulo 5, discute-se um modelo de GP formulado para avaliar a viabilidade de erradicar os lixões na Região Norte do Brasil, dentro do prazo definido na Política Nacional de Resíduos Sólidos. No modelo especificado, são consideradas estimativas da capacidade instalada de aterro e lixões; e o teto orçamentário para coleta de resíduos urbanos. Resultados ilustrativos são discutidos ao final.

No Capítulo 6, apresenta-se um modelo para avaliar a capacidade de atendimento da demanda por aulas em um departamento de uma universidade pública na região norte. Apesar do modelo ter sido validado por um tomador de decisão, os resultados gerados são ilustrativos. Ao final de cada um dos capítulos 4, 5 e 6, é conduzida uma apreciação crítica sobre os resultados obtidos em cada estudo e algumas implicações gerenciais.

3.1. INTRODUÇÃO

A Análise Multicritério de Apoio à Decisão (MCDM/A) surgiu ao final da década de 1950 nos campos da Ciência da Gestão e da Pesquisa Operacional (P.O.). Da interseção entre a P.O. e a Ciência da Gestão emergiu uma coleção de algoritmos matemáticos e estruturas lógicas que podem ser usados para resolver problemas complexos das organizações.

As origens da MCDM/A podem ser rastreadas até o surgimento da programação linear nos anos 1940 (SCHNIEDERJANS, 1995) quando o método simplex foi introduzido por Dantzig (1948) para solucionar problemas de programação linear (PL). A partir dessa época, passaram a ser desenvolvidas extensões metodológicas para resolver problemas multiobjectivo de gestão.

O crescente aumento da complexidade dos problemas de gestão passou a requerer a incorporação de recursos como a ponderação, definição de prioridades e análise de cenários. Nesse contexto, a tomada de decisão ocorre por meio de processos de escolhas racionais, baseadas em valores de julgamento expressos em termos quantitativos (LEE, 1971).

Portanto, a MCDM/A pode ser considerada como uma subárea de P.O. que compreende diferentes técnicas para abordar problemas que envolvem múltiplos critérios para tomada de decisão. Essas técnicas são particularmente relevantes quando os tomadores de decisão (*decision-makers*) apresentam diferentes pontos de vista sobre um determinado problema, incorrendo em falta de consenso. Nesses casos, frequentemente faz-se necessário construir uma “matriz de desempenho” de alternativas para que a decisão possa ser apoiada de modo mais transparente às partes interessadas (*stakeholders*).

Para fins ilustrativos, Campolina et al. (2017) elaboraram uma comparação das técnicas mais utilizadas no campo da MCDM/A, incluindo algumas aplicações recorrentes na literatura especializada (e.g., gestão organizacional, gestão ambiental, saúde, gestão pública). O resumo desse estudo está reportado na Tabela 2.

Além da escolha de alternativas envolvendo cenários de decisão, a MCDM/A é frequentemente utilizada em contextos de avaliação de desempenho e *benchmarking*. Por exemplo, no livro intitulado “Manual para construção de indicadores compósitos” (Nardo et al. 2008) recomendam o uso de uma variedade de técnicas de MCDM/A para avaliar a performance de países (e.g. AHP, DEA, PCA). Mais recentemente, el Gibari; Gómez; Ruiz (2019) elencaram os seguintes métodos para avaliar o desempenho das nações no contexto do desenvolvimento sustentável:

- Métodos elementares (e.g.; Experts' opinion, AHP);
- Métodos baseados em valor e utilidade (e.g.; MAUT, MAVT);
- Métodos de *outranking* (e.g.; ELECTRE, PROMETHEE);
- Métodos baseados em Análise Envoltória de Dados (*Benefit-of-the-Doubt, common weight MCDA-DEA*);
- Métodos baseados em funções de distância (e.g.; *Goal Programming*)

Nesse contexto, os métodos baseados em funções de distância rapidamente se tornaram populares desde os anos de 1960 (JONES; TAMIZ, 2010). Essa relativa popularidade pode ser atribuída à facilidade de formular matematicamente um problema multiobjectivo baseado em equações lineares. Nesse contexto, o *Goal Programming* (programação por metas ou programação por objetivos) firmou-se como um dos mais populares métodos de MCDM/A entre gestores, formuladores de políticas públicas e acadêmicos.

Tabela 2 Comparação das características de diferentes métodos utilizados em análise de decisão multicritério (MCDM/A)

Método ¹	Vantagens	Desvantagens	Aplicações observadas
MAUT	Considera incertezas. Pode incorporar preferências	Necessita de muitos <i>inputs</i> e requer precisão	Economia, finanças, ciências atuariais, gerenciamento de recursos hídricos e energéticos, agricultura, saúde
AHP	Facilidade de uso, versatilidade, estrutura com hierarquia, adaptabilidade	Pressupõe interdependência entre critérios e alternativas	Gerenciamento de recursos, gestão corporativa, gestão pública, planejamento estratégico
ELECTRE	Considera incerteza e situações "nebulosas"	A comparação par a par implica que as vantagens e desvantagens das alternativas não sejam identificadas diretamente	Economia, meio-ambiente, gerenciamento hídrico e energético, transporte
PROMETHEE	Facilidade de uso, não requer pressuposto de proporcionalidade dos critérios	Não proporciona um método claro de atribuição de pesos	Meio-ambiente, gerenciamento hídrico e energético, negócios e finanças, química, logística e transporte, sistemas de manufatura, agricultura
TOPSIS	Simplicidade de uso	Dificuldades na inter-relação de critérios e no processo de ponderação	Logística, engenharia, sistemas de manufatura, negócios, <i>marketing</i> , meio-ambiente, recursos humanos e gerenciamento de recursos hídricos
<i>Goal Programming</i>	Facilidade para lidar com problemas de larga escala. Infinitas alternativas	Não permite a ponderação de critérios, necessitando associação com outros métodos	Planejamento, saúde, análise de portfólio, sistemas de distribuição, planejamento energético, gerenciamento de recursos hídricos
MACBETH	Modela preferências, compara alternativas par a par	Não considera incerteza na mensuração de preferências (trabalha com preferências do tipo valor)	Saúde, gestão pública
<i>Fuzzy Set Theory</i>	Acomoda informações imprecisas e insuficientes	Dificuldade de desenvolvimento e necessidade de simulações para a implementação	Engenharia, economia, meio-ambiente, saúde, gestão
MPD	Pode lidar com informações imprecisas e insuficientes. Permite incorporar percepções dos <i>decision-makers</i>	Dificuldade para a compreensão dos resultados das análises	Engenharia, economia, meio-ambiente, saúde, gestão

Fonte: CAMPOLINA et al. (2017)

¹ AHP: *analytic hierarchy process*; ELECTRE: *Elimination Et Choix Traduisant la REalité*; MACBETH: *Measuring Attractiveness by a Categorical Based Evaluation Technique*; MAUT: *multi-attribute utility theory*; MPD: método paraconsistente de decisão; PROMETHEE: *Preference Ranking Organization Method for Enrichment of Evaluations*; TOPSIS: *Technique for Order Preferences by Similarity to Ideal Solutions*.

1.1 GOAL PROGRAMMING

Goal Programmin (GP), traduzido para o português como programação por metas, é uma técnica de otimização multiobjetivo que busca encontrar uma solução que atenda simultaneamente a uma variedade de objetivos quantitativos. Charnes e Cooper (1961) introduziram a GP para dar suporte a processos decisórios que envolvam problemas quantitativos e objetivos gerenciais conflitantes.

Como exemplo da aplicabilidade de GP no contexto da gestão organizacional, considere uma empresa que opera em um mercado competitivo e fortemente influenciado por *stakeholders* (e.g., reguladores, fornecedores, sindicatos, clientes).

Como esses *stakeholders* influenciam na formulação da estratégia competitiva organizacional, a empresa que deseja sobreviver necessita atender às expectativas de ao menos algumas dessas partes. Tais expectativas podem entrar em conflito com objetivos organizacionais clássicos de maximização do lucro ou de minimização de custos. Por exemplo, para se posicionar frente aos concorrentes, os gestores podem estabelecer como objetivos não orientados à eficiência financeira (e.g., ampliação da participação de mercado; minimização de emissões atmosféricas; adotar métodos de produção mais limpa). Como a GP foi desenvolvida para lidar com questões gerenciais desse tipo, ela pode auxiliar os *decision-makers* na tomada de ações apropriadas de curto, médio e de longo prazos.

Anteriormente já foi mencionado que a base de GP é a Programação Linear. Portanto, desde os anos de 1960, trabalhos seminais como os de Lee (1972), Ignizio (1976), Romero (1991), e muitos outros que introduziram algoritmos baseados no método simplex, os quais foram importantes para popularizar essa técnica.

Mais recentemente, trabalhos como os de Orumie; Ebong (2014) analisam uma extensa lista de algoritmos que objetivam solucionar problemas de GP com mais eficiência computacional. A notável popularidade dessa técnica em pesquisas aplicadas foi atestada em estudos de revisão em recentes anos (e.g., engenharia, MCDM/A; administração, políticas públicas e informática). Por exemplo, Caballero; Gómez; Ruiz (2010) conduziram uma revisão sistemática de publicações elaboradas entre 1970 e 2008 na qual se anteviu a integração de GP com outras técnicas de otimização e também com heurísticas para solucionar com robustez problemas estocásticos relevantes ao século XXI.

Diferentemente da programação matemática, também referida na literatura como programação linear (PL), a abordagem multiobjectivo não busca encontrar a solução ótima que garanta a eficiência de Pareto (1906) por meio da maximização ou da minimização de uma função objetivo. No lugar disso, busca-se um conjunto de soluções aceitáveis (soluções de compromisso) que permitam explorar cenários de decisão. Nesse contexto, um problema multiobjectivo de GP busca minimizar desvios dos valores-alvos (*targets*) definidos para cada meta (*goal*).

Na formulação de um problema de GP considera-se que tomadores de decisão devem estipular *a priori* um valor-alvo para cada meta considerada no problema multiobjectivo. Como as metas definidas podem ser conflitantes, deve-se admitir a existência de desvios positivos e de desvios negativos do valor-alvo. Finalmente, devem-se definir critérios de penalização aplicáveis aos desvios da meta.

Ahmed K. Rifai descreveu os principais procedimentos para formular adequadamente um modelo de programação por metas (RIFAI, 1996):

1. **Identificar o problema.** Esta etapa requer uma descrição precisa do problema e seus condicionantes. Em alguns casos, o problema é claro e pode ser quantificado facilmente. Em outros, requer muita pesquisa e discussão entre as pessoas envolvidas. No entanto, todos esses problemas devem ser resolvidos e esclarecidos por consenso dos tomadores de decisão.
2. **Quantificar problema.** Descrever o problema de maneira quantitativa (matemática) apropriada. A formulação adequada do problema e a construção de um ranking de importância para as metas são consideradas a etapa mais crítica da solução.
3. **Resolver o problema.** Obter um conjunto de soluções de compromisso compatíveis com as especificações dos tomadores de decisão. Essa etapa é considerada a mais simples de todas porque há muitos aplicativos e softwares disponíveis capazes de solucionar problemas de otimização multiobjectivo.

Após a resolução do problema, deve-se apresentar as soluções de compromisso aos tomadores de decisão, os quais deverão interpretar os resultados e escolher a solução de compromisso para implementar.

TERMINOLOGIA

Nessa seção são apresentadas alguns conceitos que sumarizam a filosofia por trás da MCDM/A. Maiores detalhes sobre cada conceito podem ser consultados no trabalho intitulado "*Practical Goal Programming*" (JONES; TAMIZ, 2010).

- a. **Decision-Maker (DM):** é uma pessoa, organização ou parte interessada no problema de decisão. É possível que o DM seja na verdade um grupo de pessoas, com quem o analista deve se comunicar para obter os atributos necessários à formulação do modelo de GP.
- b. **Variável de decisão:** uma variável de decisão é um fator sobre o qual o tomador de decisão tem controle. Por exemplo, o volume de produtos a ser fabricado no próximo mês em uma fábrica. O objetivo do modelo de GP deve ser visto como uma busca pelas possíveis combinações de valores de variáveis de decisão para determinar o ponto que melhor satisfaz as metas e as restrições do *decision-maker*.
- c. **Critério:** é uma medida única pela qual a validade de qualquer solução para um problema de decisão pode ser medida. Há critérios relevantes para diferentes domínios de conhecimento (e.g., custo, lucro, tempo, distância, performance, estratégia organizacional, segurança).
- d. **Objetivo:** é um critério acompanhado de informação sobre a orientação do modelo de GP (minimizar ou maximizar). Como um problema de otimização multiobjectivo considera

objetivos que não conseguem alcançar seus valores ótimos em simultâneo, a solução encontrada é chamada de solução de compromisso.

e. Solução Pareto-eficiente (ótimo de Pareto): Uma solução para um problema multiobjetivo é considerada Pareto-eficiente se não existir outra solução viável que melhore a performance de um dado objetivo sem piorar a performance de ao menos um dos demais objetivos. A solução Pareto-eficiente também pode ser chamada de **solução dominante**.

f. Solução Pareto-ineficiente (insucesso): Uma solução de um problema multiobjetivo é considerada Pareto-ineficiente se existir outra solução viável que melhore o desempenho de um determinado objetivo sem com isso reduzir a performance de nenhum outro objetivo. A solução insuficiente de Pareto também pode ser chamada de solução dominada.

A filosofia da MCDM/A considera como lei fundamental que nenhum DM escolheria conscientemente uma solução Pareto-ineficiente, se tiver conhecimento de uma solução Pareto-eficiente que a domina.

g. “Satisficing”: Neologia do idioma inglês que integra a palavra *satisfy* (satisfazer) e “*sufice*” (ser suficiente). Esse termo descreve um comportamento no qual os DMs devem atingir um conjunto de objetivos, sem com isso otimizar cada objetivo individualmente. Essa filosofia define os fundamentos da MCDM/A.

3.1.1 ESTRUTURA BÁSICA

O procedimento para a formulação de um problema de *Goal Programming* é muito similar aquele de formulação de um modelo de Programação Linear clássica. Um modelo de PL pode ser representado conforme a formulação (1).

$$\begin{aligned} \text{Max } z &= \sum_{j=1}^n c_j x_j && (1) \\ \text{s. t.} & \\ \sum_{j=1}^n a_{ij} x_j &\leq b_i && \forall i \in I \\ x_j &\geq 0 \forall j \end{aligned}$$

Em (1), z é a função objetivo (F.O.) representada por uma função linear. Z pode ter objetivo de maximizar ou minimizar o resultado da equação. O modelo (1) tem como único objetivo maximizar z , dadas as restrições especificadas na segunda linha do modelo.

Na seção anterior já se mencionou que a principal diferença está na especificação da função objetivo. O modelo de *Goal Programming* visa minimizar desvios entre os valores-alvo desejados e os resultados alcançados. Outra característica dos modelos de GP é que há os múltiplos objetivos, os quais

são priorizados conforme sua importância relativa na organização. As restrições do modelo representam as metas a serem envolvidas por restrições rígidas e restrições flexíveis. As restrições rígidas são inequações representando condições que necessitam ser satisfeitas antes das restrições da meta. As restrições flexíveis são equações que representam os objetivos organizacionais e as metas a serem alcançadas.

Para quantificar a priorização de objetivos as equações de restrição flexível incorporam variáveis de desvios, as quais podem ser positivas ou negativas. Variáveis de desvio positivo maiores que zero indicam que uma determinada meta foi ultrapassada. Variáveis negativas representam resultados abaixo da sua meta.

Um modelo básico de *Goal Programming* pode ser expresso da seguinte forma generalizada vide modelo (2).

$$\begin{aligned}
 \text{Min } Z &= \sum_{i=1}^r v_i d_i^+ + \sum_{i=1}^r u_i d_i^- & (2) \\
 & \text{s. t.} \\
 f_i(X) - d_i^+ + d_i^- &= g_i, \quad i = 1, \dots, r \\
 a_i x_i &\leq b_i \\
 -d_i^+, d_i^- &\geq 0, \quad \forall i \\
 X &\in F
 \end{aligned}$$

Na formulação (2), a F.O. Z busca minimizar a soma de todos os desvios positivos (d_i^+) e negativos (d_i^-). A cada desvio, são atribuídos pelo tomador de decisão (*decision-maker*) pesos não negativos (v_i e u_i). Na segunda linha, $f_i(X)$ é uma igualdade que representa todas as restrições flexíveis associadas às metas de gestão ($i = 1, \dots, r$). A variável g_i representa os valores-alvo (*targets*). Na terceira linha de (2), está representado o conjunto de restrições rígidas, as quais podem ser interpretadas de forma idêntica às restrições de um problema clássico de PL.

3.1.2 EXEMPLO 1: EQUACIONAMENTO DE METAS

Neste exemplo ilustrativo, um problema multiobjectivo de *Goal Programming* será formulado, considerando as seguintes condições. Os gestores de uma loja de varejo definiram como meta obter uma renda média mensal de R\$100 mil, levando-se em consideração que preço médio de venda de cada item q_1 é de R\$50.

Pede-se que o analista equacione as metas em termos de restrições rígidas e depois as convertas para restrições flexíveis. No caso da meta 1, por se tratar de uma receita pretendida, a inequação inicial foi formulada em (3) da seguinte maneira:

$$f1(q_1): 50 \times q_1 \geq 100\,000 \quad (3)$$

A inequação (3) pode ser convertida em restrição flexível por meio da inclusão das variáveis de desvio d_1^+ e d_1^- conforme reportado na formulação (4).

$$f1(q_1): (50 \times q_1) - d_1^+ + d_1^- = 100\ 000 \quad (4)$$

A loja também tem como meta manter os custos totais de armazenagem não abaixo de R\$ 20 mil mensais. Para isso, verificou-se que o custo unitário de armazenagem é igual a \$10/mês. A meta de custos deve ser, portanto, expressa da seguinte forma (5).

$$f2(q_1): 10 \times q_1 \leq 20\ 000 \quad (5)$$

Após a inclusão das variáveis de desvio, obtém-se a equação (6)

$$f2(q_1): (10 \times q_1) - d_2^+ + d_2^- = 20\ 000 \quad (6)$$

3.1.3 EXEMPLO 2: FORMULAÇÃO DE UM PROBLEMA E SOLUÇÃO PELO MÉTODO GRÁFICO

Esse exemplo tem dois objetivos. O primeiro objetivo é estabelecer uma relação entre o método de solução gráfica de um problema de PL clássico e um problema de *Goal Programming*. O segundo objetivo é ilustrar a mecânica de formulação e solução de um problema multiobjetivo de GP por meio da utilização do método gráfico.

Suponha que um *decision-maker* deseje maximizar as seguintes funções objetivos para aumentar sua lucratividade em uma dada organização.

$$f_1(x) = x_1 + 1.5x_2 \quad (7)$$

$$f_2(x) = 5x_1 + 2x_2 \quad (8)$$

As metas para cada função objetivo são respectivamente as seguintes $g_1 = 100$ e $g_2 = 350$. Ambas têm igual importância para o DM e sujeitas às seguintes restrições rígidas.

$$R1: \quad 2x_1 + 2x_2 \leq 160 \quad (9)$$

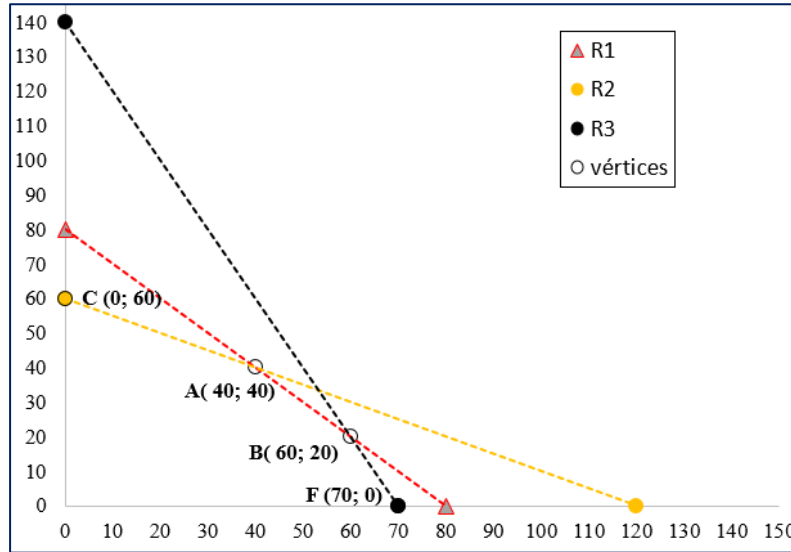
$$R2: \quad x_1 + 2x_2 \leq 120$$

$$R3: \quad 4x_1 + 2x_2 \leq 280$$

$$x_1, x_2 \geq 0$$

Independentemente da meta de gestão estipulada, as duas funções objetivo podem ser maximizadas separadamente por meio de 2 problemas de PL clássicos. Nesse caso, as soluções gráficas obtidas são baseadas no espaço de soluções possíveis, conforme reportado na Figura 1. Note que os valores de x_1 são representados no eixo horizontal e os valores de, no eixo vertical.

Figura 1 Espaço de soluções do exemplo 2



Ao aplicar os pares ordenados dos vértices nas funções $f_1(x)$ e $f_2(x)$, obtêm-se os seguintes resultados na Tabela 3.

Tabela 3 - soluções iniciais

Vértices	x_1	x_2	$f_1(x)$	$f_2(x)$	$d_1^- = g_1 - f_1(x)$	$d_2^- = g_2 - f_2(x)$	$d_1^- + d_2^-$
A	40	40	100*	280	0	70	70
B	60	20	90 ♥	340 ♥	10	10	20
C	0	60	90	120 ♣	10	230	240
F	70	0	70 ♣	350*	30	0	30

* Solução ótima

♥ Solução de compromisso

♣ Pior solução

Coincidentemente, as metas definidas pelo gestor, tem valor igual aos pontos ótimos de cada F.O. (i.e., $f_1^*(x) = 100$ e $f_2^*(x) = 350$). No entanto, analisando-se os resultados obtidos, nota-se que o resultado que maximiza $f_1(x)$ é o ponto A, o qual dá uma solução não satisfatória para $f_2(x)$. Similarmente, a solução que maximiza $f_2(x)$ é o ponto F, o qual reporta a pior solução para $f_1(x)$.

Nesse caso, para atender a demanda dos DMs, deve-se buscar uma solução de compromisso que atenda às duas funções objetivos de maneira satisfatória e com o menor desvio possível da meta definida *a priori*. Para fins didáticos, o problema de *Goal Programming* foi formulado em (10) de maneira a não admitir desvios positivos.

$$\text{Min } z = u_1 d_1^- + u_2 d_2^- \quad (10)$$

s.t.

$$f_1(x): x_1 + 1.5x_2 + d_1^- = 100$$

$$f_2(x): 5x_1 + 2x_2 + d_2^- = 350$$

$$2x_1 + 2x_2 \leq 160$$

$$x_1 + 2x_2 \leq 120$$

$$4x_1 + 2x_2 \leq 280$$

$$x_1, x_2 \geq 0$$

$$d_i^-, d_i^+ \geq 0, \forall i$$

Nesse exemplo, as duas metas têm igual importância para a gestão. Portanto, os pesos u_1 e u_2 devem ter o mesmo valor (e.g., $u_1 = u_2 = 1.0$). Em aplicações práticas, a definição desses pesos deve ser efetuada pelo *decision-maker* ou pelo analista do problema.

Para resolver o problema de GP utilizando as informações disponíveis na Tabela 3, deve-se observar que vértice proporciona o menor desvio total das metas. Nesse exemplo, a única solução que apresenta essa característica é dada pelo ponto B (i.e., $z = 20$; $f_1(x) = 90$; $f_2(x) = 340$). Portanto, o vértice B reflete uma solução de compromisso do problema multiobjectivo de *Goal Programming* e deve ser a recomendada pelo analista ao *decision-maker*.

Solução do Exemplo 2 utilizando o MS Excel Solver

O mesmo problema apresentado na seção anterior pode ser resolvido utilizando-se o MS Excel Solver do método simplex ou um software equivalente. Nessa subseção são apresentados os principais passos para obter-se a solução desejada.

Passo 1: inserir os dados do problema representando as variáveis de decisão e os parâmetros do problema de GP linear. Na figura 2, há um exemplo do *layout* da planilha.

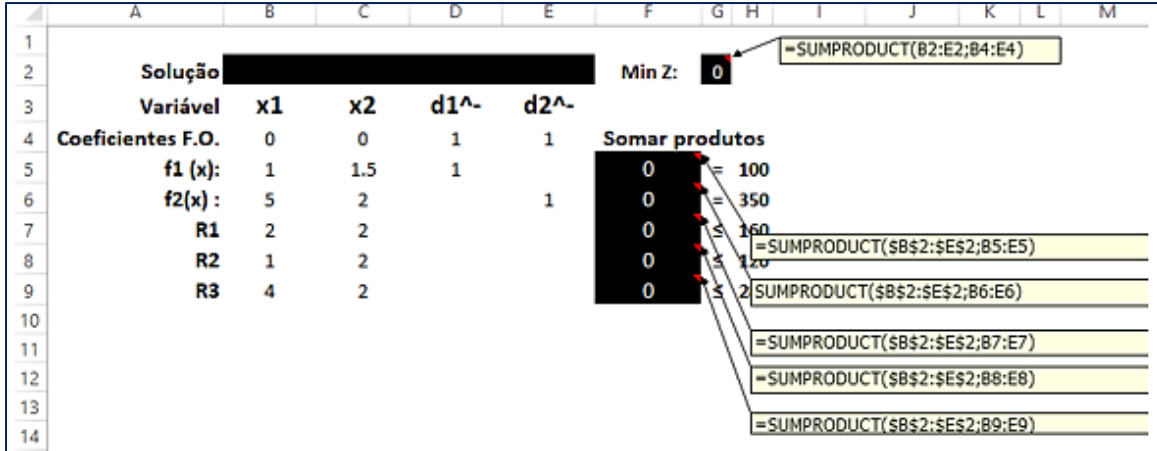
Figura 2 - Layout da Planilha

	A	B	C	D	E	F	G	H
1								
2		Solução				Min Z:	0	
3		Variável	x1	x2	d1 ⁻	d2 ⁻		
4		Coefficientes F.O.	0	0	1	1	Somar produtos	
5		f1 (x):	1	1.5	1		0	= 100
6		f2(x):	5	2		1	0	= 350
7		R1	2	2			0	≤ 160
8		R2	1	2			0	≤ 120
9		R3	4	2			0	≤ 280
10								
11								

Passo 2: A célula G2 foi selecionada como referência para a função objetivo. Portanto, aqui deverá ser adicionada uma fórmula representando equação linear do modelo (10).

Similarmente, no intervalo de F5 até F9 deverão ser inseridas as fórmulas que representam as equações lineares de metas ($f_{1(x)}$ e $f_{2(x)}$) e de restrições rígidas (R_i). Na Figura 3 há um exemplo de como proceder nesse passo.

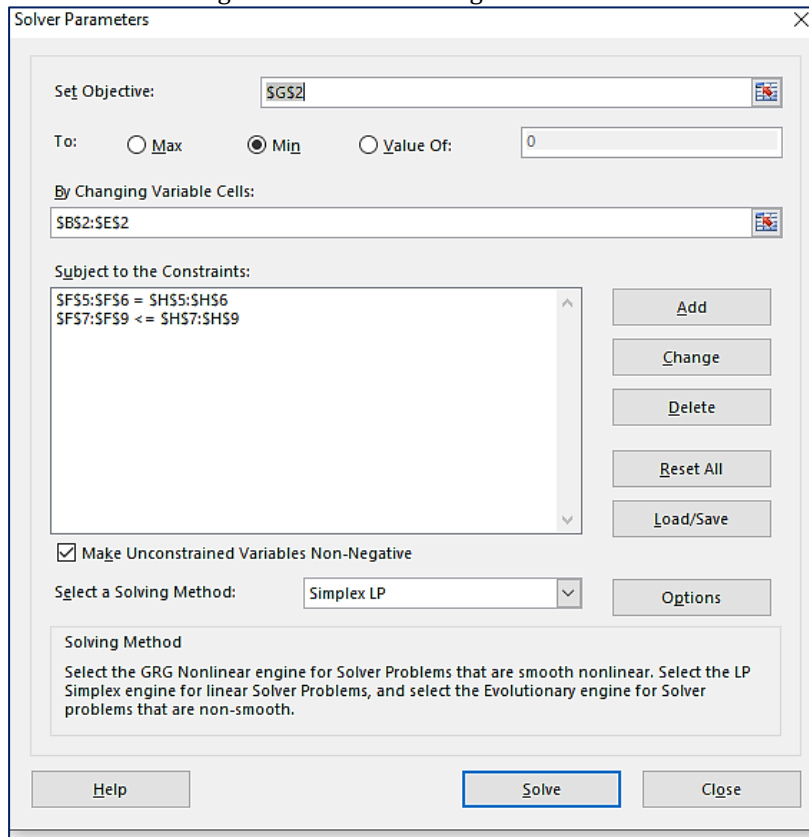
Figura 3 – Fórmulas de equações lineares



Passo 3: Selecionar o menu de DADOS Microsoft Excel. Clique no comando **SOLVER** para exibir a caixa de diálogo para inserir restrições no solver.

No campo da função objetivo indique a célula de referência e selecione o objetivo de minimizar (**min**) e preencha os demais campos conforme a Figura 4.

Figura 4 – caixa de diálogo do solver



Passo 4: Clicar no botão **SOLVE** para obter a solução de compromisso reportada na Figura 5.

Figura 5 – Solução de compromisso

	A	B	C	D	E	F	G	H
1								
2	Solução	60	20	10	10	Min Z:	20	
3	Variável	x1	x2	d1⁻	d2⁻			
4	coeficientes F.O.	0	0	1	1	Somar produtos		
5	f1 (x):	1	1.5	1		100	=	100
6	f2(x):	5	2		1	350	=	350
7	R1	2	2			160	≤	160
8	R2	1	2			100	≤	120
9	R3	4	2			280	≤	280
10								
11								

A solução $Z = 20$ na Figura 5 é idêntica àquela obtida no método gráfico. No entanto, o uso de planilhas para solucionar o problema de GP facilita o processo de explorar cenários de decisão. Por exemplo, como o *decision-maker* estabeleceu um ranking de prioridades para o atingimento das metas, definindo que $f_1(x)$ tem prioridade sobre $f_2(x)$, pode-se facilmente incorporar diferentes valores aos coeficientes das variáveis de desvio (u_1 e u_2). Na planilha, esses coeficientes correspondem ao intervalo E4:F4. Como desvios das metas são indesejáveis aos DM, os coeficientes atribuídos afetam o resultado obtido e podem aumentar o valor de Z. Portanto, eles podem ser interpretados como penalidades pelo não atingimento da meta.

3.1.4 EXEMPLO 3: EXPLORANDO CENÁRIOS

Essa subseção é baseada no problema proposto originalmente por Ignizio (1976). Uma pequena empresa de tintas fabrica dois tipos de produto: látex e esmalte. No setor de produção, a empresa utiliza 10 horas de trabalho para produzir 100 galões de látex e 15 horas de trabalho para produzir 100 galões de esmalte. A empresa possui jornada semanal de trabalho de 40 horas, além da possibilidade de alocar 30 horas extras por semana. A política de produção da empresa define que se for produzida tinta esmalte, também deve ser produzida tinta látex. Cada tinta gera um lucro à taxa de \$1.00 por galão.

A administração adotou e priorizou seus objetivos organizacionais na seguinte ordem.

1. Evitar o uso de horas extras
2. Alcançar um lucro semanal de \$ 1000
3. Produzir pelo menos 700 galões de tinta de esmalte por semana

Pede-se ao analista que formule um problema multiobjectivo refletindo as preferências e metas da administração dessa firma e que se estime uma programação da produção para o próximo período. Para a formulação das restrições rígidas do problema foi conduzida a seguinte análise na Tabela 4.

Tabela 4 – Formulação das restrições rígidas

Restrição	Formulação	Descrição
Rígida	$10 x_{latex} + 15 x_{Esmalte} \leq 70$	Restrição jornada de trabalho
Rígida	$x_{latex} \geq x_{Esmalte}$ Ou seja $x_{latex} - x_{Esmalte} \geq 0$	Restrição de produção

Na formulação e priorização das restrições flexíveis (metas), considere que g_1, g_2, g_3 são os valores-alvo associados a cada objetivo de gestão. Na Tabela 5, as metas estão equacionadas por ordem de prioridade.

Tabela 5 – formulação de metas

Ranking De Prioridades	Inequações (para 100 galões)		Equações das metas
1º	$10 x_{latex} + 15 x_{Esmalte} \leq 40$	\leftrightarrow	$10 x_{latex} + 15 x_{Esmalte} - d_1^+ = 40$
2º	$x_{latex} + x_{Esmalte} \geq \$ 1000$	\leftrightarrow	$x_{latex} + x_{Esmalte} - d_2^+ + d_2^- = \$ 1000$
3º	$7 x_{Esmalte} \geq 700$	\leftrightarrow	$7 x_{Esmalte} - d_3^+ + d_3^- = 700$

Considerando que a meta 1 não admite desvios negativos na jornada de trabalho, mas que as metas 2 e 3 permitem ambos os desvios positivos e negativos, a formulação da função objetivo de minimização resultou no reportado em (11).

$$\min z: v_1 d_1^+ + v_2 d_2^+ + v_3 d_2^- + v_4 d_3^+ + v_5 d_3^- \quad (11)$$

$$\begin{aligned} \text{S.t. } & 10 x_{latex} + 15 x_{Esmalte} - d_1^+ = 40 \\ & x_{latex} + x_{Esmalte} - d_2^+ + d_2^- = \$ 1000 \\ & 7 x_{Esmalte} - d_3^+ + d_3^- = 700 \\ & 10 x_{latex} + 15 x_{Esmalte} \leq 70 \\ & d_i, x_{latex}, x_{Esmalte} \geq 0 \end{aligned}$$

O problema (11) pode ser resolvido utilizando-se o MS Excel Solver, respeitando-se o ranking de preferências definido pelo *decision-maker*. Para garantir que a prioridade das metas (g_i) seja respeitada, o *decision-maker* deverá selecionar coerentemente os valores das penalidades de não atingimento das metas. Essas prioridades são expressas por meio dos pesos (v_i) das variáveis de desvio em Z.

Prioridades maiores atraem penalidades maiores. Portanto, a prioridade de evitar a ocorrência de horas extras de trabalho o *decision-maker* deverá definir para v_1 um valor mais expressivo que demais pesos. Os valores dos pesos são normalizados de modo a facilitar a interpretação da importância relativa de cada meta nos objetivos de gestão. Outra vantagem de usar valores normalizados para os pesos, é a possibilidade de incorporar no modelo metas quantitativas expressas em unidades de medida diferentes.

A Tabela 6 reporta exemplo de penalidades refletindo a prioridade das metas. Valores mais altos foram associados a metas mais importantes definidas pelo DM.

Tabela 6 – Exemplo de penalidades

Prioridade de g_i	Fator	Penalidade por deficiência (d_i^-)	Penalidade por excesso (d_i^+)
1	Jornada de Trabalho	-	5
2	Lucro	4	-
3	Volume mínimo de Produção	3	2

Incorporando os pesos reportados na Tabela 6 no modelo (11), a função objetivo resulta na equação (12). Os coeficientes dessa equação estão normalizados para facilitar a interpretação em termos percentuais.

$$z: 0.357 d_1^+ + 0.285 d_2^- + 0.214 d_3^+ + 0.142 d_3^- \quad (12)$$

Após incorporarem-se os valores de julgamento sobre as penalidades, o problema foi solucionado da seguinte maneira. Os resultados foram o seguinte: $x_{latex}=1.6$; $x_{Esmalte} = 1.6$; $d_1^+ = 0$; $d_2^- = 968$; $d_3^+ = 0$; $d_3^- = 688.8$; $Z = 864.8$. Note que, nesse cenário em que evitar as horas-extras é a prioridade máxima da gestão, a meta de lucratividade $g_2 = \$ 1000$ está aquém do desejado (\$ 968 unidades).

Sugere-se, portanto, consultar se esse resultado é aceitável para o DM em comparação com um cenário alternativo. Por exemplo, representar um cenário novo, em que a meta de produção for aproximadamente 7 vezes mais importante que evitar horas-extras; o volume de produção 2 vezes mais importante que a lucratividade e os pesos em Z forem alterados para (13). Para facilitar a interpretação, os pesos estão normalizados.

$$z: 0.05 d_1^+ + 0.16 d_2^+ + 0.16 d_2^- + 0.32 d_3^+ + 0.32 d_3^- \quad (13)$$

A solução encontrada para esse novo cenário é a seguinte: $x_{latex} = 2.8$; $x_{esmalte} = 2.8$; $d_1^+ = 30$; $d_2^+ = 0$; $d_2^- = 994.4$; $d_3^+ = 0$; $d_3^- = 680.4$; $z = 998.16$. Nesse cenário, o desvio da meta da lucratividade fica ainda mais acentuado.

REFERÊNCIAS

- Caballero, R.; Gómez, T.; Ruiz, F. *Goal Programming*: Realistic Targets for the Near Future. v. 110, n. January, p. 79–110, 2010.
- Campolina, A. G. et al. Análise de decisão multicritério para alocação de recursos e avaliação de tecnologias em saúde: tão longe e tão perto? *Cadernos de Saúde Pública*, v. 33, n. 10, out. 2017.
- Charnes, A.; Cooper, W. W. *Management Models and the Industrial Applications of Linear Programming*. New York: John Wiley & Sons, 1961.
- Chiavenatto, I. *Introdução à Teoria Geral da Administração*. 9ª ed. Rio de Janeiro: Manole, 2014.
- CNE. Diretrizes Curriculares Nacionais do Curso de Graduação em Engenharia Brasília Ministério da Educação, , 2019.
- Dantzig, G. B. Programming in a Linear Structure. *Econometrica*, v. 17, p. 73–74, 1949.
- El Gibari, S.; Gómez, T.; Ruiz, F. Building composite indicators using multicriteria methods: a review. *Journal of Business Economics*, v. 89, n. 1, 2019.
- Ignizio, J. P. *Goal Programming and extensions*. Lexington: Lexington Books, 1976.
- Jayashree, D. N.; Harish Babu, G. A. Optimum allocation of resources in university management through *Goal Programming*. *Global Journal of Pure and Applied Mathematics*, v. 12, n. 4, p. 2777–2784, 2016.
- Jones, D.; Tamiz, M. *Practical Goal Programming*. New York: Springer, 2010. v. 141
- Lee, S. M. Decision Analysis Through *Goal Programming*. *Decision Sciences*, v. 2, n. 2, p. 172–180, abr. 1971.
- Lee, S. M. S. M. *Goal Programming for Decision Analysis*. Philadelphia: Auerbach publishers, 1972.
- Nardo, M. et al. *Handbook on Constructing Composite Indicators*. 1. ed. Paris: OECD PUBLICATIONS, 2008.
- Orumie, U. C.; Ebong, D. A Glorious Literature on Linear *Goal Programming* Algorithms. *American Journal of Operations Research*, v. 04, n. 02, p. 59–71, 2014.
- Pareto, V. *Manual of political economy (translation of Manuale di economia politica (in italian))*. 2014. ed. [s.l.] Oxford University Press, 1906.
- Rifai, A. K. A note on the structure of the goal-programming model: assessment and evaluation. *International Journal of Operations & Production Management*, v. 16, n. 1, p. 40–49, 1996.
- Romero, C. *Handbook of Critical Issues in Goal Programming*. 1. ed. Cordoba: Pergamon Press, 1991.
- Schniederjans, M. J. *Goal Programming: Methodology and Applications*. Boston, MA: Springer US, 1995.
- Schniederjans, M. J.; KIM, G. C. A *Goal Programming* model to optimize departmental preference in course assignments. *Computers and Operations Research*, v. 14, n. 2, p. 87–96, 1987.

Decisões sobre vacinação no Sus : Um modelo para alocação de recursos na prevenção de mortalidade por câncer do colo de útero

Devisson Mesquita dos Santos

Fernanda Leandra Leal Lopes

Pedro Matheus d'Oliveira

Syanne do Socorro Lobato Gonçalves

Renata Melo e Silva de Oliveira

4.1. INTRODUÇÃO

Segundo o Instituto Nacional de Câncer (INCA, 2019), o câncer no colo de útero é o terceiro tumor maligno mais frequente na população feminina e a quarta causa de morte de mulheres por câncer no Brasil.

A prevenção do câncer cervical ocorre por meio da vacinação de crianças de ambos os sexos. Segundo o INCA (2019), Meninas de 9 a 14 anos e meninos de 11 a 14 anos podem tomar a vacina gratuitamente via Sistema Único de Saúde (SUS). Para os diagnosticados com o vírus HIV, a faixa etária é ampliada para o intervalo de 9 a 26 anos. O esquema vacinal é de três doses (intervalo de 0, 2 e 6 meses).

Esse estudo visa elaborar e avaliar cenários de decisão que garantam a maximização o número de vacinados, considerando-se a redução na meta orçamentaria do SUS para o ano de 2020. Modelo de *Goal Programming (GP)* formulado para essa finalidade considera metas de vacinação tanto de meninas quanto de meninos. O segundo objetivo é de minimizar os custos de aquisição de vacinas.

Para dar suporte à gestão, exploram-se cenários em que são alocadas diferentes prioridades para vacinação de meninos e de meninas. Parte-se do pressuposto de que o orçamento é insuficiente para cumprir em simultâneo as metas predefinidas pelos *decision-makers*.

Esse estudo está dividido em 6 seções. A segunda seção reporta o problema investigado. Na terceira seção, apresentam-se os procedimentos metodológicos que nortearam a pesquisa. A quarta seção contém a formulação de *Goal Programming* desenvolvida. A quinta seção apresenta o desenvolvimento da aplicação e discute as vantagens e desvantagens de cada cenário. A sexta seção discute os achados e as considerações finais desta investigação.

4.2 O PROBLEMA INVESTIGADO

O Câncer no Colo de Útero, também chamado de câncer cervical, possui como principal causa uma lesão invasiva intrauterina ocasionada principalmente pelo papilomavírus humano (HPV). A principal via de contágio do HPV ocorre por meio de relações sexuais desprotegidas. Pessoas com maior número de parceiros e com comportamentos de risco têm maior risco de contrair a doença.

Uma vez contaminado, o indivíduo pode levar anos para manifestar a lesão. Essa manifestação da lesão é identificada principalmente por meio de verrugas na vagina, pênis ou do ânus. Em alguns casos, a doença pode ser assintomática.

Apesar do uso de preservativo ser considerado uma medida preventiva ao contágio do vírus, sua eficácia é apenas parcial. O INCA (2019) reforça que contatos sexuais sem penetração também podem transmitir a doença (e.g., contato com a pele a vulva, região perineal, perianal e bolsa escrotal). Portanto, a principal forma de prevenção contra o HPV é a vacina em grupos populacionais que ainda não iniciaram sua vida sexual.

Desde 2014, foi implantado pelo Ministério da Saúde um calendário de vacinação tetravalente para meninas entre 9 e 14 anos. Em 2017, o calendário passou a incluir metas de vacinação para meninos de 11 a 14 anos.

Mediante a relevância da vacinação na prevenção de epidemias na população brasileira, este estudo tem como principal objetivo estudar o dilema de alocação de recursos orçamentários para vacinação, considerando-se as metas de vacinação estipuladas para o ano de 2020. Considera-se também que o orçamento de vacinação de 2020 é 7% menor que aquele do ano de 2019, mas que a meta para o número de vacinados em 2020 é ao menos igual àquela de 2019.

O segundo objetivo deste estudo é formular um problema de *Goal Programming orientado* a minimizar o custo total de vacinas contra o HPV no Brasil em 2020, mas que seja capaz de manter a meta do governo de vacinar 80% do público-alvo de meninas e meninos.

A formulação do problema de otimização multiobjectivo ocorreu no contexto da disciplina de “Atividades de Formação Complementar III”, em que projetos integrados de Engenharia de Produção são produzidos sob orientação de um professor com expertise em ao menos duas subáreas do curso de graduação. Com isso, as subáreas da Engenharia de Produção integradas neste trabalho correspondem à Pesquisa Operacional e Engenharia Econômica.

4.3 METODOLOGIA DA PESQUISA

O estudo foi desenvolvido em duas etapas. Portanto, a fase 1 teve a natureza predominantemente quantitativa e determinística. Foi utilizada uma abordagem quantitativa para construir o modelo baseado em Programação Linear (PL). Na fase 2 do estudo, o caráter da pesquisa é exploratório porque especifica cenários de decisão suportados no contexto de um estudo de caso enfocando a saúde pública no Brasil.

4.3.1 COLETA DE DADOS

Na primeira etapa do estudo definiram-se os dados necessários e o período a ser considerado na aplicação do modelo de GP. Posteriormente, realizou-se a coleta de dados em que se usou como fontes principais as bases de dados das seguintes instituições: Departamento de Informática do Sistema Único de Saúde (DATASUS); Instituto Nacional do Câncer (INCA); Ministério da Saúde e do Instituto de Geografia e Estatística (IBGE).

As informações obtidas na base do INCA inspiraram a motivação desse estudo, mas não se teve acesso a dados quantitativos para compor diretamente o *dataset*.

No DATASUS foram investigados o número de meninas vacinadas no período de 2014 a 2018 dos 9 aos 14 anos de idade e meninos dos 11 aos 14 anos. Essas duas faixas etárias representam o principal público-alvo das campanhas de vacinação.

Note-se que dados sobre a vacinação de meninos entre os anos de 2014 e 2016 foram descartados porque o SUS só estabeleceu metas de vacinação para eles a partir de 2017. Além disso, também é relevante ressaltar que a faixa etária de meninas naquele período era diferente da faixa atualmente enfocada. Dessa base de dados, também foi possível identificar as metas orçamentárias anuais para a vacinação contra o HPV.

Da base do Ministério da Saúde, foi possível coletar os dados referentes aos preços unitários das vacinas compradas pelo SUS entre os anos de 2014 e 2018. O TABNET DATASUS forneceu dados dos preços (R\$/dose) até o ano de 2018. Por isso, tomou-se como base o preço de R\$ 40,5 para cada dose de vacina.

Dados completos sobre o ano de 2019 não foram encontrados na altura de execução dessa pesquisa. Os dados sobre vacinados e orçamentos são reportados na Tabela 7.

Tabela 7 – Histórico de vacinados e orçamentos

Anos	Meninas Vacinadas	Meninos Vacinados	Custo Unitário	Quantidade de Vacinas compradas	Orçamento
2014	7.874.743	30.494	R\$31,02	15.000.000	R\$ 465.300.000,00
2015	5.774.727	18.512	R\$31,02	8.000.000	R\$ 248.160.000,00
2016	2.314.041	14.925	R\$31,02	6.000.000	R\$ 186.120.000,00
2017	3.074.076	3.128.905	R\$31,02	6.000.000	R\$ 186.120.000,00
2018	2.278.285	2.362.693	R\$40,50	14.000.000	R\$ 567.000.000,00
2019	-	-	R\$40,50	-	-
2020	-	-	R\$40,50	-	R\$ 510.300.000,00

Fonte: Adaptado de TABNET DATASUS (2019)

Da Base do IBGE, obtiveram-se dados reportando a projeção da população do público-alvo vivendo no Brasil em 2020. Essa informação foi importante para definir os valores-alvo para cada meta do modelo de GP. Portanto, esse estudo já desconsidera a população de meninas e meninos vacinados em anos anteriores. Dessa forma, a meta inserida no modelo de otimização multiobjectivo corresponde a 80%

da projeção de crianças vivendo no Brasil em 2020, as quais nunca foram vacinadas e que estão na faixa etária apropriada. Finalmente, foram selecionados para este estudo apenas dados validados externamente, os quais foram utilizados para construir o *dataset* reportado na Tabela 8. Essa tabela também reporta o quantitativo de crianças já vacinadas e que foram desconsideradas nesse estudo.

Tabela 8 – Projeções populacionais

Ano	População de meninas (9 a 14 anos)	População de meninos (11 a 14 anos)	Meninas vacinadas com as duas doses e dentro da faixa etária	Meninos vacinados com as duas doses e dentro da faixa etária
2014	9.422.324	6.639.285	-	-
2015	9.256.572	6.500.151	-	-
2016	9.085.969	6.387.790	-	-
2017	8.967.392	6.321.518	-	-
2018	8.864.924	6.242.278	-	-
2019	8.756.857	6.086.263	-	-
2020	8.658.631	6.086.263	3.333.062	1.130.306

Fonte: IBGE (2019)

4.3.2 MODELO DE GP PARA DECISÕES SOBRE VACINAÇÃO NA SAÚDE PÚBLICA

A principal decisão a ser tomada refere-se à quantidade de crianças a serem vacinadas contra o HPV devem ser compradas, considerando-se o teto orçamentário do ano de 2020.

As seguintes variáveis de decisão foram definidas para o modelo:

- x_1 : Quantidade de vacinas a serem compradas para meninas
- x_2 : Quantidade de vacinas a serem compradas para meninos
- d_1^+, d_1^- : Respectivamente desvio positivo e desvio negativo da meta de vacinação de meninas
- d_2^+, d_2^- : Respectivamente desvio positivo e desvio negativo da meta de vacinação de meninos

No que diz respeito às metas ($f_i(x)$) e aos valores-alvo (g_i) a serem alcançados, considere-se o seguinte:

- Meta 1: $f_1(x)$ – Fornecer duas doses de vacinas para ao menos 4.260.455 meninas brasileiras de 9 a 14 anos; ou seja $g_1 = 2 \times 4.260.455 = 8.520.910$
- Meta 2: $f_2(x)$ – Fornecer duas doses de vacinas a ao menos 3.964.766 meninos brasileiros de 11 a 14 anos; ou seja $g_2 = 2 \times 3.964.766 = 7.929.532$

O modelo de *Goal Programming* contendo o equacionamento das metas é reportado em por meio do modelo (12), que é composto pelas restrições de 12.1 a 12.5.

$$\text{Min } Z = v_1 d_1^+ + v_2 d_1^- + v_3 d_2^+ + v_4 d_2^- \quad (12.1)$$

$$F_1(x): x_1 - d_1^+ + d_1^- = 8.520.910 \quad (12.2)$$

$$F_2(x): x_2 - d_2^+ + d_2^- = 7.929.532 \quad (12.3)$$

$$40,5x_1 + 40,5x_2 \leq 510.300.000 \quad (12.4)$$

$$x_1 + x_2 \leq 20.563.052 \quad (12.5)$$

$$d_1^+, d_1^-, d_2^+, d_2^- \geq 0$$

$$x_1, x_2 \geq 0$$

A equação (12.1) representa o objetivo de minimizar os desvios das equações (12.2) e (12.3), as quais correspondem às metas de vacinação. Portanto quanto menor o valor de (12.1) mais próximo o resultado estará de atingir as metas estabelecidas de vacinação. Na função objetivo (12.1), v_1, v_2, v_3 e v_4 são pesos refletindo penalidades pelo não atingimento das metas definidas. Esses pesos devem ser definidos pelos tomadores de decisão ou pelos analistas, de acordo com o objetivo de cada cenário.

A primeira restrição rígida (12.4) está relacionada à estimativa do orçamento total para compra de vacinas HPV no ano de 2020. Já a segunda restrição rígida (12.5) diz respeito à projeção do número total de crianças em idade de vacinação habitando o Brasil em 2020, desconsiderando a população que já foi vacinada anteriormente.

4.4 RESULTADOS

O problema de GP (12) foi resolvido com auxílio do MS Excel Solver. Utilizando-se planilhas, foram explorados três cenários de decisão em que se avaliou a priorização de meninas ou de meninos na vacinação. Os resultados de cada cenário estão sumarizados na Tabela 9.

Tabela 9 – Resultados por cenário

Cenário	x_1	x_2	d_1^+	d_1^-	d_2^+	d_2^-	Z
A: $g_1 \neq g_2$	6.447.845	6.152.156	0	2.073.066	0	1.777.377	3.850.442
B: $3g_1 > g_2$	4.670.468	7.929.532	0	3.850.442	0	0	3.850.442
C: $g_1 < 3g_2$	8.520.910	4.079.090	0	0	0	3.850.442	3.850.442

No cenário A, considerou-se que ambas as metas têm igual importância ($g_1 \neq g_2$), a todos os desvios do modelo foi atribuído o peso $u_i = 1$. Esse cenário foi investigado porque nos anos 2000, cerca de 55% dos brasileiros entre 16 e 25 anos estavam infectados com o HPV, dos quais foi confirmado que 38,4% estava infectada HPV oncogênico (MINISTÉRIO DA SAÚDE, 2002). Também se levou em consideração que, apesar das vacinas estarem disponíveis gratuitamente nos postos de saúde, menos da metade do público-alvo foi imunizado em 2016 (INAC, 2019).

No cenário A observou-se uma distribuição das vacinas equilibrada entre ambas as populações. Portanto, a meta 1 para vacinação de meninas foi atendida em cerca de 75,67%. Enquanto na meta 2, cerca de 77,59% da população de meninos seria atendida. Apesar de estarem muito próximos do atingimento de ambas as metas, os desvios para cada grupo populacional indicam que se o cenário A fosse adotado cerca de 1.036.533 de meninas e de 888.689 meninos não seriam vacinados em 2020.

No cenário B, supôs-se que a meta de vacinação de meninos é 3 vezes mais importante para o tomador de decisão que a meta de vacinação de meninas ($3g_1 > g_2$). A formulação desse resultado tomou como base o argumento de Guiliano et al. (2011). Esses autores identificaram por meio de um estudo

realizado em 2011 com homens do Brasil, México e Estados Unidos, que cerca de 50% dos homens residentes nesses países têm o vírus HPV. Como os homens muitas vezes são o vetor do vírus que pode causar câncer cervical nas mulheres, a priorização de homens na vacinação pode fazer sentido a um tomador de decisão. Outro argumento em favor do cenário B, é que a faixa etária disponível para vacinação de meninos é menor que a das meninas, o que poderia representar uma potencial redução de custos operacionais de vacinação.

Os resultados obtidos para o cenário B permitiriam o atendimento de cerca de 55% da meta estabelecida para a vacinação de meninas. Se esse cenário fosse adotado, um total de 1.925.221 meninas não receberiam as doses necessárias à imunização. Em contrapartida, a meta 2 foi totalmente atingida.

No cenário C, especificou-se que a meta vacinação de meninas é considerada três vezes mais importante que a meta de vacinação dos meninos ($g_1 < 3 g_2$). Para embasar esse cenário de decisão, considerou-se que o câncer do colo de útero é o segundo tumor mais frequente entre as mulheres e a quarta causa de morte da população feminina por câncer no Brasil. Estima-se que houve cerca de 6.385 óbitos em 2017 por conta dessa doença (INCA, 2019).

Os resultados do cenário C permitiram o atingimento da meta 1. No entanto, se esse cenário fosse implantado, um total de 3.850.442 doses não seriam ministradas aos meninos em 2020. Portanto, quando a meta estabelecida para as meninas é atendida por completo, a meta para os meninos fica cerca de 50% aquém do estabelecido pelo governo federal.

Constatou-se com essa exploração de cenários que em nenhum caso se pode atingir simultaneamente as metas 1 e 2. Também se pôde constatar que se a meta 1 for atingida, os resultados da meta 2 são demasiados baixos e vice-versa.

Os três foram levados a um especialista que simulou o papel de um tomador de decisão para avaliar a viabilidade dos resultados. O especialista consultado é um médico que trabalha no atendimento básico de saúde no município da região metropolitana de Belém.

Depois de avaliar opções disponíveis, o médico recomendou a implantação do cenário A. A razão da escolha baseou-se no fato de que tanto homens quanto de mulheres serem potenciais transmissores do vírus. Da mesma forma, ambos os sexos podem desenvolver doenças causadas pelo HPV.

4.5 CONSIDERAÇÕES FINAIS

Este estudo ilustrou uma aplicação da técnica *Goal Programming* para dar suporte à decisão no contexto da alocação de recursos na saúde pública. Demonstrou-se a aplicabilidade dessa técnica para auxiliar a exploração de cenários de decisão na presença de objetivos de gestão conflitantes. Particularmente, foi explorado o problema de decisão de distribuição de vacinas HPV considerando uma redução do orçamento da saúde pública.

Sob a premissa de que o teto orçamentário de vacinas HPV em 2020 tornaria inviável atingir a meta de vacinar 80% do público-alvo, discutiu-se neste trabalho que era necessário encontrar uma

solução de compromisso para atender a população brasileira. Ainda, um especialista foi convidado a simular o papel de um tomador de decisão para avaliar as implicações de cada cenário proposto. O tomador de decisão escolheu o cenário A e justificou sua escolha baseado em argumentos técnicos.

Os cenários discutidos nesse trabalho devem ser analisados com cuidado e necessitam de estudos mais aprofundados antes de serem validados por um tomador de decisão do mundo real. Portanto, antevê-se que futuros estudos construam uma análise de sensibilidade dos pesos, além da exploração de potenciais novas variáveis de decisão a serem consideradas nesse problema. Outra recomendação é que seja avaliada a robustez do modelo proposto.

REFERÊNCIAS

Brasil. Ministério da Saúde. Instituto Nacional de Câncer. Viva Nacional - Programa Nacional de Controle do Câncer do Colo de Útero e de Mama. Rio de Janeiro, RJ, 2002.

Cauchick-Miguel, P. A. et al. Metodologia de pesquisa em Engenharia de Produção e gestão de operações. 3. ed. Rio de Janeiro: Elsevier, 2018.

Colapinto, Cinzia; Jayaraman, Raja; Marsiglio, Simone. Multi- criteriadecisionanalysiswithgoalprogramming in engineering, management and social sciences: a state-of-theartreview. *Annals Of Operations Research*, [S.l.], v. 251, n. 1-2, p.7-40.

Fabio Manzano. G1 Bem-Estar: Verba para vacinas será R\$ 400 milhões menor em 2020. Disponível em: <<https://g1.globo.com/bemestar/noticia/2019/09/19/>>. Acesso em: 20 set. 2019.

Guiliano, Anna R et al. Incidence and clearance of genital human papillomavirus infection in men (HIM): a cohort study. *The Lancet*, Londres, v. 377, n. 9769, p.932-940.

IBGE.Projeções da População do Brasil e Unidades da Federação por sexo e idade: 2010-2060.

INCA. Tipos de Cancer. Disponível em: <<https://www.inca.gov.br/tipos-de-cancer/cancer-do-colo-do-utero>>. Acesso em: 10 dez. 2019.

Lee, S. M. Decision Analysis Through *Goal Programming*. *Decision Sciences*, v. 2, n. 2, p. 172-180, abr. 1971.

Moretti, Bruno. Efeitos da EC 95: uma perda bilionária para o Sus em 2019. *Brasil Debate*, p.1-3, 24 set. 2018.

Tabnet Datasus. Imunizações - Doses Aplicadas - Brasil. Disponível em: <<http://tabnet.datasus.gov.br/cgi/tabcgi.exe?pni/cnv/DPniuf.def>>. Acesso em: 08 nov. 2019.

Decisões no planejamento urbano: Estudo de viabilidade para auxiliar a erradicação de lixões até 2021

Naira Gabriela do Nascimento Vieira

Nelane Araújo de Sousa

Thailon Tiago de Sousa Carneiro

Renata Melo e Silva de Oliveira

5.1. INTRODUÇÃO

O Plano Nacional de Resíduos Sólidos de 2010 (PNRS) define que os lixões deveriam ser erradicados e transformados em aterros sanitários até o mês de agosto de 2014 (BRASIL, 2010). O processo de recuperação dos lixões demandaria a criação de aterros sanitários ou conversão de lixões em aterros. Outra demanda para atender à determinação do PNRS é a de triagem e migração da massa dos lixões para aterros temporários. Apenas após a migração é que poderia ser feita a recuperação ambiental dos lixões.

No entanto, ao final do prazo de erradicação de lixões, a maioria dos municípios brasileiros não atingiram as metas definidas na lei (Brasil, 2016). O não atingimento da meta foi justificado pela falta de quadros técnicos e gerenciais qualificados e de insuficiência de recursos financeiros. Em vista a esse contexto, foi instituído o Projeto de Lei do Senado nº 425, de 2014 (PLS 425/2014) prolongando o prazo para erradicação dos lixões até julho de 2021.

Apesar da extensão do prazo, o Panorama de Resíduos Sólidos no Brasil 2017 reporta que cerca de 80% dos resíduos sólidos urbanos (RSU) gerados na Região Norte do Brasil foram coletados naquele ano (ABRELPE, 2019) e cerca de 35,6% do RSU coletado foi destinado inadequadamente a lixões. Esse quantitativo equivale a 4.523 toneladas por dia (ABRELPE, 2018). Esses marcadores estão abaixo da média nacional (MMA, 2018).

Nesse contexto, este projeto integrado enfocou o problema particular do processo de tomada de decisão sobre a destinação de RSU na Região Norte do Brasil. O objetivo é investigar a viabilidade de atender o prazo para erradicação de lixões na Região Norte.

As metas de erradicação dos lixões são conflitantes com a meta orçamentária para custear a coleta, triagem e destinação apropriada desses resíduos. Grande parte do problema concentra-se nas zonas metropolitanas nortistas, em que a taxa de geração *per capita* é recorrentemente superior à capacidade instalada dos aterros e lixões.

O contexto exposto motivou a especificação de um modelo de *Goal Programming* englobando esses dois objetivos gerenciais do planejamento urbano. Foram equacionadas duas metas: maximização do

uso de aterros (sanitários e controlados); minimização do uso dos lixões ainda em operação mediante as estimativas para o ano de 2021. Também foi equacionada a meta do teto orçamentário que deve ser respeitada. Note-se que os resultados extraídos com GP são ilustrativos, porém foi possível identificar *insights* associados a futuras ações, os quais são capazes de auxiliar gestores na tomada de decisão do planejamento urbano para 2021.

Esse estudo está dividido em seis seções. Na seção dois, apresenta-se o problema investigado. A seção três reporta aspectos metodológicos adotados durante a realização do projeto. A seção quatro engloba a modelagem do problema. Na seção cinco os resultados ilustrativos e os cenários de decisão são apresentados e discutidos. Finalmente, na seção seis são apresentadas as conclusões deste estudo.

5.2 O PROBLEMA INVESTIGADO

Este projeto integrado investiga o problema da destinação final dos RSU na região norte do Brasil. Foram diagnosticados desafios associados ao processo de transição do uso de lixões para aterros sanitários dentro do prazo definido. Outro desafio ao cumprimento da transição até o ano de 2021 é a capacidade instalada insuficiente dos aterros atualmente disponíveis comparada ao crescente volume de resíduos sólidos urbanos produzidos diariamente na região norte brasileira. A destinação inadequada desses resíduos representa riscos à saúde pública e também à segurança da população, além de danos ambientais.

5.3 METODOLOGIA DA PESQUISA

O estudo foi desenvolvido em duas etapas. Na primeira fase, o projeto foi predominantemente quantitativo. Foi utilizada uma abordagem determinística para construir o modelo multiobjectivo baseado em Programação Linear (PL).

Na segunda fase do estudo, o caráter da pesquisa foi exploratório porque especificou cenários de decisão suportados no contexto de um estudo de caso a gestão de RSU na Região Norte.

5.3.1 PROCEDIMENTOS DE COLETA DE DADOS

A principal fonte de dados utilizada para o compor o *dataset* desse estudo foi o relatório intitulado “Panorama dos Resíduos Sólidos no Brasil” da Associação Brasileira de Empresas de Limpeza Pública e Resíduos Especiais (ABRELPE, 2019). Essa associação tem apoio da Organização das Nações Unidas (ONU) e é considerada uma das principais organizações privadas dedicada à gestão de resíduos.

Também foram considerados dados de bases do setor público reportados pelo Instituto Brasileiro de Geografia e Estatística (IBGE) para estimar metas de custo por tonelada de RSU e a capacidade instalada nos aterros e lixões da região estudada. Para compor o *dataset* foram coletados dados sobre a geração, coleta e destinação dada aos RSU de anos de 2017 e 2018. As informações desses períodos foram

utilizadas como base para traduzir do PNRS de percentuais para valores absolutos. O resultado da coleta de dados está consolidado na Tabela 10.

Tabela 10 – Dados sobre RSU na Região Norte

Indicador	Unidade	2017	2018
Geração Total de RSU na Região Norte	ton/dia	15.634	16.073
Geração <i>per capita</i> de RSU na Região Norte	ton/(hab x dia)	0,872	0,884
Coleta <i>per capita</i>	ton/(hab x dia)	0,708	0,719
Orçamento para coleta e destinação (TOTAL)	Milhões R\$/ano	697	707
Disposição de RSU Região Norte	Unidade	2017	2018
Aterro Sanitário	ton/dia	4.410	4.613
Aterro Controlado	ton/dia	3.772	3.895
Lixão	ton/dia	4.523	4.561
Total Coletado	ton/dia	12705	13069

Fonte: ABRELPE (2019)

Na Região Norte espera-se um aumento na geração de RSU de aproximadamente 20% até 2021 (IBGE,2019), quando o volume total a ser coletado será $g_1 = 20.000$ ton/dia. A definição da meta orçamentária de diária de R\$ 1.936.986 (i.e., $\frac{R\$ 707 \text{ milhões}}{365 \text{ dias}}$) para destinação do RSU.

Note-se que a decisão sobre a estimativa orçamentária adotou o comportamento conservador de manter os valores observados em 2018.

Também foram extraídos da base de dados denominada Sistema Nacional de Informações Sobre Saneamento (SNIS, 2019) os valores de custo médio na Região Norte para operacionalizar a de destinação de RSU tanto para lixões quanto para aterros sanitários. Esses valores foram usados como coeficientes no modelo de otimização multiobjectivo (19.1). Em 2021, para custear uma tonelada destinada aos lixões, o custo médio estimado foi de R\$ 150,00. Já o custo médio para destinação aos aterros sanitários, o custo médio estimado foi de R\$ 250,00.

No que diz respeito à capacidade instalada e às metas de destinação para 2021, infere-se do relatório da ABRELPE (2019) que os lixões devem ter capacidade instalada de ao menos 30% do valor da demanda anual ($20.000 \text{ ton/dia} \times 0.3 = 6.000 \text{ ton/dia}$). Para os aterros sanitários, a capacidade mínima recomendada é de ao menos 50% da demanda, ou seja $20.000 \text{ ton/dia} \times 0.5 = 10.000 \text{ ton/dia}$.

5.3.2 FORMULAÇÃO DO MODELO DE GOAL PROGRAMMING

Nesse PIEP, foram selecionadas as seguintes variáveis de decisão para compor as equações metas e da função objetivo

- $x_{lixão}$: Total de RSU destinado a lixões
- $x_{aterros}$: Quantidade de RSU destinado a aterros
- d_1^+, d_1^- : Respectivamente desvio positivo e desvio negativo do valor-alvo g_1
- d_2^+, d_2^- : Respectivamente desvio positivo e desvio negativo do valor-alvo g_2

No contexto desse estudo a meta $f_1(x)$ em (13) representa a maximização do total de RSU coletados na Região Norte em 2021. Na equação (13), g_1 é o valor-alvo expresso em ton/dia. Nessa equação, desvios positivos em relação a g_1 podem ser interpretados como capacidade ociosa de coleta. Os desvios negativos podem ser interpretados como demanda reprimida de coleta.

A meta dois $f_2(x)$ em (14) representa a minimização de custos operacionais associados à coleta, triagem e destinação dos resíduos. Em (14), g_2 é o valor alvo expresso em R\$ por ton/dia.

$$f_1(x): x_{lixão} + x_{aterro} - d_1^+ + d_1^- = g_1 \quad (13)$$

$$f_2(x): 150 x_{lixão} + 250 x_{aterro} - d_2^+ + d_2^- = g_2 \quad (14)$$

As restrições rígidas do problema dizem respeito ao seguinte. A primeira restrição define a tolerância para o total de lixo não coletado no dia. A segunda restrição refere-se à capacidade instalada no aterro em 2021. A terceira restrição representa a capacidade instalada no lixão em 2021.

$$R_1: x_{lixão} + x_{aterro} \geq g_1 \quad (15)$$

$$R_2: x_{lixão} \leq C_{lixão} \quad (16)$$

$$R_3: x_{aterro} \leq C_{aterro} \quad (17)$$

O modelo de GP formulado para solucionar o problema proposto corresponde ao modelo (19).

$$\text{Min } Z = v_1 d_1^+ + v_2 d_1^- + v_3 d_2^+ + v_4 d_2^- \quad (19.1)$$

$$F_1(x): x_{lixão} + x_{aterro} - d_1^+ + d_1^- = 20\,000 \quad (19.2)$$

$$F_2(x): 150 x_{lixão} + 250 x_{aterro} - d_2^+ + d_2^- = 1\,936\,986 \quad (19.3)$$

$$x_{lixão} + x_{aterro} \geq 18\,000 \quad (19.4)$$

$$x_{lixão} \leq 6\,000 \quad (19.5)$$

$$x_{aterro} \geq 10\,000 \quad (19.6)$$

$$d_1^+, d_1^-, d_2^+, d_2^-, x_{lixão}, x_{aterro} \geq 0$$

A equação (19.1) representa o objetivo de minimizar os desvios das equações (19.2) e (19.3). Portanto quanto menor o valor de (19.1) mais próximo o resultado estará de atingir as metas estabelecidas para a gestão de resíduos sólidos urbanos. Na função objetivo (19.1), v_1, v_2, v_3 e v_4 são pesos refletindo penalidades pelo não atingimento das metas definidas. Esses pesos devem ser definidos pelos tomadores de decisão ou pelos analistas de acordo com suas preferências.

A inequação (19.4) foi especificada para assegurar que seja coletado ao menos 80% do RSU gerado na Região Norte em 2021 ($20.000 \text{ ton/dia} \times 0.8 = 18.000 \text{ ton/dia}$). A inequação (19.5) define que o total de RSU destinado a lixões não pode ultrapassar 30% do total gerado ($20.000 \text{ ton/dia} \times 0.3 = 6.000 \text{ ton/dia}$). Finalmente, a inequação (19.6) define que ao menos 50% do total de RSU gerado deve ser destinado a aterros sanitários, ou seja $20.000 \text{ ton/dia} \times 0.5 = 10.000 \text{ ton/dia}$. Para garantir maior proximidade com a realidade da Região Norte do Brasil, essas restrições foram formuladas conforme as recomendações e previsões reportadas pela ABRELPE (2019).

5.4 RESULTADOS ILUSTRATIVOS

Foram especificados três cenários de decisão em que foi explorado potencial de atingimento das metas. No cenário A, considerou-se que tanto a meta de coleta do RSU gerado quanto o teto orçamentário têm igual importância. Portanto, resultados abaixo ou acima de cada meta são igualmente penalizados na função objetivo ($A: g_1 \approx g_2$). Essa especificação constitui um cenário de indiferença entre as metas.

No cenário B, a meta da coleta de RSU é estritamente preferida sobre a meta do teto orçamentário ($B: g_1 \ll g_2$). Cenários como esse, partem do princípio de que a penalidade por não atender a população é muito maior do que a alternativa. Nesse caso, o que prevalece é garantir o atendimento da demanda, partindo-se do pressuposto de que é remanejar o orçamento para tal finalidade.

No cenário C, a meta orçamentária é estritamente mais importante que o atendimento da demanda ($C: g_1 \gg 2 g_2$). Esse cenário representa um contexto de crise econômica, em que não há orçamento suficiente para atender a demanda da população. Portanto, a penalidade de não respeitar o teto orçamentário é muito maior do que a alternativa.

Os resultados por cenários são reportados na Tabela 11.

Tabela 11 – Resultados por cenário

Cenário	RSU destinado a lixões (ton/dia)	RSU destinado a aterros (ton/dia)	Desvios RSU não coletado		Desvios da meta orçamentária		Soma pesada dos desvios
	$x_{lixão}$	x_{aterro}	d_1^+	d_1^-	d_2^+	d_2^-	Z
A: $g_1 \approx g_2$	6.000	12.000	-	2.000	1.963.014	-	7.854.056
B: $g_1 \ll g_2$	6.000	14000	-	-	2.463.014	-	6.000
C: $g_1 \gg 2 g_2$	-	7747,944	-	12252,06	-	-	61260,28

No cenário A, em que não há prioridade entre as metas, consegue-se atender a 90% demanda, desde que a capacidade instalada dos aterros sanitários seja de 12.000 ton/dia. No entanto seria necessário dobrar o orçamento para garantir o serviço à população. O custo de coleta e aterragem dos resíduos necessitaria de um acréscimo de R\$ 1.963.014 /dia para garantir a operação.

No cenário B, em que a meta do orçamento é mais importante do que a meta de coleta, o modelo (19) foi modificado de modo a não admitir desvios na restrição (19.2). Os resultados obtidos indicam que para coletar todo o RSU gerado em 2021, seria necessário uma capacidade instalada de ao menos 14.000 ton/dia nos aterros sanitários, 6.000 ton /dia nos lixões e um aumento de R\$ 2.463.014 no teto orçamentário. Esse cenário pode ser particularmente desafiador, por que requer que o Estado garanta ampliação de aterros e de frotas de coleta. E também, garantir que o orçamento aumentasse em 127% naquele ano.

No cenário C, o modelo (19) foi modificado de modo a não admitir desvios na restrição (19.3). Dessa forma, o orçamento prevaleceria sobre o atendimento da demanda. Observa-se nesse cenário uma potencial demanda reprimida de 12.252,06 ton/dia. Isso significa que apenas 40% do RSU gerado seria coletado em 2021. Esse cenário também apresenta desafios, pois a destinação inadequada de lixo urbano representa riscos à saúde pública e gera passivos ambientais.

Com base nos resultados obtidos e considerando as definições da PNRS para o ano de 2021, recomenda-se que se adote como base o cenário B para justificar a ampliação do orçamento e das operações para coleta e destinação de resíduos sólidos urbanos.

Embora *insights* tenham sido discutidos por meio dos cenários A, B e C, a tomada de decisão sobre gestão de resíduos sólidos requer uma análise mais aprofundada sobre a criação de novos aterros ou expansão dos aterros existentes. Outros estudos associados à redução do custo/ton podem também beneficiar o processo de planejamento para o alcance de cidades mais sustentáveis na região norte.

5.5 CONSIDERAÇÕES FINAIS

Este estudo teve como objetivo investigar a viabilidade na região norte de atender o prazo para erradicação de lixões até julho de 2021. Para isso, foram consideradas estimativas de capacidades instaladas tanto de lixões quanto de aterros (sanitários e controlados). Também se levou em consideração o teto orçamentário e a estimativa de geração dos RSU em 2021 na região.

Apesar dos *insights* discutidos, os resultados desse estudo são ilustrativos e devem ser avaliados com cautela. Portanto, ressalta-se que processo decisório dessa magnitude requer mais robustez e acurácia de dados. Os resultados indicaram que a capacidade instalada na região necessita de expansão imediata. Para isso, recomenda-se a realização de estudos mais detalhados sobre a criação de novos aterros e a recuperação ambiental dos lixões em operação.

Também se recomenda uma análise crítica sobre a alocação orçamentária destinada a coleta, triagem e destinação dos resíduos gerados. Nessa análise, pode ser benéfico à gestão pública investigar potencialidades de redução no custo por tonelada dos RSU coletados.

REFERÊNCIAS

Abrelpe. Panorama Nacional de Resíduos Sólidos 2018/2019. São Paulo. 2019. 74 p.

Brasil. Congresso. Senado. Lei nº 12305, de 02 de agosto de 2010. Institui a Política Nacional de Resíduos Sólidos; altera a Lei no 9.605, de 12 de fevereiro de 1998; e dá outras providências. Lei Nº 12.305, de 2 de Agosto de 2010. Brasília, DF, 02 ago. 2010.

Brasil. Congresso. Senado. Projeto de Lei nº 425, de 19 de dezembro de 2014. Prorroga o prazo para a disposição ambientalmente adequada de rejeitos de que trata o art. 54 da Lei nº 12.305, de 2 de agosto de 2010. Brasília, DF, 19 dez. 2014.

Miguel, P. A. C. et al. Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações. 3. ed. Rio de Janeiro: Elsevier, 2018.

Snis. Disponível em: <<http://www.snis.gov.br/>>. Acesso em: 30 dez. 2019.

CAPÍTULO

06

Decisões na Educação Superior: Um Estudo inicial sobre alocação de professores

Renata Melo e Silva de Oliveira

6.1. INTRODUÇÃO

Esse capítulo descreve um modelo de otimização multiobjectivo para abordar o problema de alocação de professores em uma instituição de ensino superior (IES) pública brasileira. O dilema de distribuição de carga horária de ensino não é raro em departamentos universitários, especialmente quando a demanda por atividades de ensino na graduação é maior do que o quantitativo de professores disponíveis.

Também está ligado a esse problema a alocação de tempo para o desenvolvimento de pesquisa, extensão, pós-graduação e gestão universitária. Nesse contexto, a solução natural para esse dilema seria ampliar o corpo de docentes. Porém, na esfera das universidades públicas, nem sempre é possível admitir novos professores com velocidade compatível à expansão do volume de alunos matriculados.

Diferentemente dos estudos de *timetabling*, que enfocam a necessária otimização de quadros de horários, o modelo descrito nesse estudo enfoca a alocação de carga-horária de professores para ajudar a atender, ainda que parcialmente, as demandas associadas às três missões das universidades.

Em muitos casos, a análise e solução do dilema de alocação fica sob responsabilidade do chefe de departamento. Consequentemente, nos casos em que o volume demandado de carga horária é maior que capacidade de atendimento do departamento, o problema de decisão pode vir acompanhado de objetivos conflitantes.

Nesse contexto, esse estudo descreve uma aplicação ilustrativa que envolve o uso da técnica *Goal Programming* (GP) para estimar potenciais necessidades de ampliação do corpo docente quando aumenta a demanda por disciplinas. O modelo especificado também permite avaliar o quantitativo de demanda reprimida e simular o impacto na instituição de adotarem-se diferentes critérios de alocação. Visa-se também identificar oportunidades de realocação de pessoal para auxiliar no alcance das metas do departamento para a demanda por aulas, execução de pesquisa e o exercício de funções administrativas na universidade.

Os cenários aqui reportados são ilustrativos, portanto representam um contexto hipotético em que a demanda é maior do que a capacidade instalada no departamento. A formulação de cenários hipotéticos serve para exemplificar a utilidade da informação extraída do modelo, a qual pode ser usada na prática para indicar demanda reprimida, prever a necessidade de ampliação ou redistribuição do quadro docente. Informações desse tipo podem auxiliar o atendimento de metas institucionais de uma universidade.

No Brasil, observa-se uma alta variabilidade na estrutura organizacional das universidades. Consequentemente, a alocação de professores em Instituições de Ensino Superior (IES) tem alta variabilidade. Essa peculiaridade cria um desafio à elaboração de um modelo universal de distribuição de carga horária de docentes. Apesar disso, observam-se alguns objetivos em comum; por exemplo o atendimento da demanda de aulas ao nível de graduação; o aumento da produção científica docente de qualidade; e a homogeneização da distribuição das funções administrativas de chefia.

Note-se que a produção científica docente é atribuída ao ensino e orientação em programas de pós-graduação *stricto sensu*. Portanto, as metas de pesquisa e ensino de graduação também podem ser conflitantes entre si quando o quantitativo de pessoal é insuficiente. Nesse contexto, o uso de técnicas de suporte à decisão baseadas em otimização pode ser benéfico para avaliar as prioridades e as necessidades organizacionais das universidades.

De fato, o estudo da alocação de recursos em departamentos ou institutos universitários ganhou notoriedade durante as décadas de 1970 e 1990. Por exemplo, Ignizio (1976) e Romero (1991) reportaram casos baseados em otimização para alocação de espaço e pessoal em universidades de acordo com os níveis de demanda e de produtividade dos departamentos. Outras Aplicações de GP relevantes ao escalonamento de horas podem ser observadas na literatura (e.g., SCHNIEDERJANS, 1995; SCHNIEDERJANS; KIM, 1987). Recentemente, essa abordagem foi revisitada para analisar a alocação de serviço considerando a titulação e hierarquia dentro de um departamento (e.g., JAYASHREE; HARISH BABU, 2016).

Esse trabalho está dividido em seis seções. Na seção 2, descreve-se o modelo de *Goal Programming* adotado nessa análise. Na seção 3 o detalhamento do problema de investigação é apresentado. Na seção 4, apresentam-se os cenários de decisão formulados e o *dataset* elaborado. Na seção 4, apresenta-se o modelo formulado. Na seção 5, discutem-se os resultados ilustrativos e as implicações gerenciais. Na seção 6, delinham-se algumas conclusões e oportunidades de melhoria na formulação são apontadas.

6.1.1 UM MODELO BASEADO EM GOAL PROGRAMMING

Nesse estudo, adotou-se um modelo básico de *Goal Programming* linear, representado pela formulação (20).

$$\begin{aligned} \text{Min } Z &= \sum_{i=1}^I v_i(d_i^+ + d_i^-) & (20) \\ f_i(x): \sum_{i=1}^I a_i x_i - d_i^+ + d_i^- &= g_i \\ AX &\geq p_i \\ AX &\leq c \\ d_i^+, d_i^-, x_i &\in R^+ \end{aligned}$$

Na formulação (20), Z é a função objetivo de minimizar as variáveis de decisão que representam os desvios positivos (d_i^+) e negativos (d_i^-) associados a cada valor-alvo (g_i). Os pesos de cada desvio (v_i)

são definidos pelo *decision-maker*. Esses pesos devem representar a prioridade de cada meta $f_i(x)$ estabelecida para o departamento. Nesse modelo, x_i é uma variável de decisão que representa a quantidade de carga horária destinada à demanda i .

O conjunto de restrições rígidas $A_i X_i \geq p$ define o mínimo de horas a ser provido para cada demanda i . O valor de p é escolhido pelo *decision-maker*. Finalmente, o conjunto de restrições $A_i X_i \leq c$ indica que o resultado do problema deve observar o limite de capacidade (c) do departamento. Note que esses dois conjuntos de inequações estão representados em notação de matricial.

6.1.2 O PROBLEMA INVESTIGADO

Neste problema de alocação de carga horária, há 18 professores doutores em um determinado departamento. A formação interdisciplinar dos docentes é considerada complementar e polivalente. Cada professor segue o regime de trabalho de 40 horas semanais, as quais podem ser distribuídas respectivamente nas seguintes em atividades: planejamento, ensino, pesquisa, extensão, pós-graduação e funções administrativas. Consequentemente, cada docente deverá ter disponibilidade 1600 horas anuais para conduzir suas atividades na universidade ($8 \frac{h}{dia} \times 200 \frac{dias}{ano} = 1600 h$).

Considera-se uma demanda anual confirmada 14500 horas-aula no ensino de graduação. Simultaneamente, observa-se a demanda anual de 90 hora-aula de ensino em programas de pós-graduação. As demandas de ensino para cursos de graduação e cursos de pós-graduação são prioritárias nesse problema de alocação. O provimento dessas horas de sala de aula não pode desconsiderar os requisitos de planejamento. Cada hora em sala de aula requer 0.5h de planejamento para graduação e 1h de planejamento para pós-graduação.

Portanto, 14500 h em sala requerem a disponibilidade anual de 21750 h (*i. e.*, $14\,500 h \times 1.5 = 21750h$) e na pós-graduação a disponibilidade deve ser de 180 h (*i. e.*, $90h \times 2 = 180h$).

Quanto às metas de produção científica, as quais implicam na elegibilidade para pleitear financiamentos, estima-se que o departamento deve alocar ao menos 10% da sua capacidade para atividades associadas à pesquisa, extensão universitária e cursos de especialização.

As atividades administrativas (e.g., comissões, coordenações, chefias, direções ou alta administração) devem ser consideradas caso a caso e de acordo com as regras das IES. Nesse problema, considerou-se que um dos professores desempenha a função de chefia de departamento a regime de 20h semanais. Portanto, o chefe de departamento não pode ser alocado para mais que 8 horas semanais de ensino em graduação. Em alguns cenários, foi incorporada a informação de que três professores desempenham funções de coordenação, além da chefia. O impacto dessa informação na capacidade instalada do departamento é discutido na seção de resultados.

6.1.3 EQUACIONAMENTO DO PROBLEMA

Foram formuladas quatro metas para o departamento refletindo a demanda por aulas de graduação, por aulas de pós-graduação, por orientações de trabalhos de conclusão de curso (TCC) e de teses/ dissertações. O resultado é exibido nas equações (21) - (24).

$$f_1(x): x_{grad} - d_1^+ + d_1^- = g_{grad} \quad (21)$$

$$f_2(x): x_{pos-grad} - d_2^+ + d_2^- = g_{pos-grad} \quad (22)$$

$$f_3(x): x_{TCC} - d_3^+ + d_3^- = g_{TCC} \quad (23)$$

$$f_4(x): x_{tese} - d_4^+ + d_4^- = g_{tese} \quad (24)$$

As restrições rígidas foram formuladas para refletir os limites da jornada de trabalho de 40 horas semanais por docente, bem como o limite de capacidade do departamento. Também foram incluídas na formulação algumas preferências do departamento quanto à alocação de horas para coordenação e execução de projetos universitários (pesquisa, extensão, pós-graduação *Lato Sensu*).

A restrição (25) do modelo garante que ao menos 50% da demanda por aulas na graduação seja atendida, em casos de ser observada demanda reprimida por causa do limite de capacidade do departamento. Na restrição (26), define-se que ao menos 10% da capacidade instalada semanal no departamento deve ser destinada à execução de projetos de pesquisa, extensão e especialização. Essa restrição foi adicionada para estimular a captação de financiamentos externos à IES.

$$R_1: AX \geq p_i \Leftrightarrow x_{grad} \geq 0.5 \times g_{grad} \quad (25)$$

$$R_2: AX \geq p_i \Leftrightarrow 4x_{proj} \geq 0.1 \times C_{dpto} \quad (26)$$

$$R_3: AX \leq c_{dpto} \Leftrightarrow 1.5 x_{grad} + 2x_{pos-grad} + 2 x_{TCC} + 4 x_{teses} + 4x_{proj} \leq C_{dpto} \quad (27)$$

Finalmente, a restrição (27) define que a alocação total de horas no departamento não pode superar a capacidade instalada. Os coeficientes foram definidos para refletir normativas sobre escalonamento de tempo para universidades públicas brasileiras. Por exemplo, para ministrar 1 hora-aula na graduação ($1 x_{grad}$) é necessária meia hora-aula de planejamento ($0.5 x_{grad}$), ou seja $1.0 x_{grad} + 0.5 x_{grad} = 1.5 x_{grad}$. No caso de orientações de TCC, deve-se alocar 2 horas-aula por semana ($2 x_{TCC}$) para cada trabalho.

6.2. DATASET

Foram estabelecidos três cenários de análise, nos quais foi avaliado o potencial impacto no departamento na presença de mudanças na capacidade ou nos valores-alvo (demanda). Os dados são reportados na Tabela 12.

O cenário 1 representa a capacidade instalada de 27680 horas efetivas associada a 18 professores doutores, no qual um docente desempenha a função de chefe do departamento.

O cenário 2 ilustra a situação em que três docentes têm jornadas reduzidas porque desempenham funções administrativas enquanto três outros docentes estão afastados por licença. Apesar da redução de

capacidade, a demanda considerada é a mesma para os cenários 1 e 2 (i.e., 14500 horas-aula de graduação e 90 horas-aula de pós-graduação).

O cenário 3 considera 18 docentes, dos quais 3 ocupam funções administrativas, 3 docentes afastados. Também se prevê um aumento de 360 horas-aula anuais na demanda da graduação por causa da abertura de um novo curso de graduação no ano próximo ano letivo.

Tabela 12 – Cálculo das capacidades

Corpo Docente	Cenário 1			Cenários 2 e 3		
	Qte	Jornada semanal (h)	Total anual	Qte	Jornada semanal (h)	Total anual
Em jornada integral	17	40	27200	12	40	19200
Em jornada parcial	1	12	480	3	12	1440
Afastamento total	-	2	-	3	-	-
Afastamento parcial	-	20	0	-	20	-
Capacidade anual instalada (C)	18	-	27680	18	-	20640

A Tabela 13 reporta os valores-alvo (demanda) para o departamento em cada cenário. A dimensão de tempo adotada foram as horas semanais. No cenário 1 por exemplo considerou-se o escalonamento de até 3 TCCs por professor (i.e., $g_{TCC} = 3 \times 2 \times 18 = 108$). Similarmente, foi estimada uma demanda de 7 teses no departamento. Nesse caso, cada tese consome semanalmente 4 horas-aula, por isso o valor-alvo é calculado da seguinte maneira: $g_{Tese} = 7 \times 4 = 28$.

Tabela 13 – Dataset dos cenários em horas semanais

Referência	Cenário 1	Cenário 2	Cenário 3
$f_1(x) = g_{grad}$	356	356	365
$f_2(x) = g_{pos-grad}$	4.5	4.5	4.5
$f_3(x) = g_{TCC}$	108	108	108
$f_4(x) = g_{Tese}$	28	28	28
$R_1: 0.5 \times g_{grad}$	178	178	182.5
$R_2: 0.1 \times C_{dpto}$	69.2	51.6	51.6
$R_3: C_{dpto}$	692	516	516

A prioridade das metas foi definida em entrevista estruturada com um *decision-maker* com experiência no exercício da chefia de um departamento em uma IES pública brasileira. Esse DM construiu um ranking expressando a importância relativa de cada meta de acordo com uma escala do tipo *Likert*. Nessa escala, a nota 5 representa a prioridade máxima e a nota 1 representa a prioridade mais baixa. As notas atribuídas foram convertidas em pesos normalizados, os quais foram incorporados como coeficientes na função objetivo do modelo (20). Os resultados da interação com o DM estão reportados na Tabela 14.

Tabela 14 – Cálculo de Prioridades

Meta $f_i(x)$	Prioridade informada	
	Escala <i>Likert</i>	Peso normalizado (u_i)
Ensino de graduação	5	0.3125
Ensino de Pós-graduação	3	0.1875
Orientação TCC graduação	5	0.3125
Orientação teses Pós-graduação	3	0.1875
Total	16	1

6.3.RESULTADOS

Tabela 15 sumariza os resultados gerados a partir do modelo (20). Em todos os cenários avaliados, observa-se o atendimento parcial da demanda confirmada dos cursos de graduação. No entanto, observa-se que ainda assim não é possível atender outras necessidades da IES sem a ampliação do quadro de professores. Todos os desvios positivos do modelo foram iguais a zero e por isso as variáveis d_i^+ não foram incluídas na Tabela 15.

Tabela 15 – Resultados em horas semanais

Descrição	Variável	Cenário 1	Cenário 2	Cenário 3
Demanda atendida graduação	x_{grad}	277.8 (77%)	206.4 (58%)	206 (56%)
Demanda reprimida	d_1^-	79.2	149.6	159
Demanda atendida PG	$x_{pos-grad}$	-	-	-
Demanda reprimida	d_2^-	4.5	4.5	4.5
Demanda atendida TCC	x_{TCC}	-	-	-
Demanda reprimida	d_3^-	108	72	72
Demanda atendida Teses	x_{Tese}	-	-	-
Demanda reprimida	d_4^-	28	28	28
Horas alocadas para projetos		69h (10%)	51.6h (10%)	51.6 (10%)
Total de horas não atendidas		125.6	231.2	244.7
Professores a contratar		4	6	7

Para manter a prioridade do atendimento de ensino de graduação e do provimento de professores em funções administrativas, recomenda-se que seja adotado o cenário 3. Desse cenário, extrai-se a informação de que é necessário contratar de imediato 7 professores doutores em regime de 40h semanais. Após essas contratações, seria possível atender à demanda de aulas para a graduação. Porém, ainda haveria déficits na alocação de pesquisa e orientações.

Caso o *decision-maker* optasse por atender a demanda da pós-graduação antes da graduação, o déficit de aulas e de orientações de trabalhos permaneceria. Inclusive, as metas para alocação de tempo para pesquisa não poderiam ser atendidas (Ver tabela 16).

Tabela 16 – Resultados com priorização da PG

Descrição	Variável	Cenário 1	Cenário 2	Cenário 3
Demanda atendida graduação	x_{grad}	196 (55%)	178 (50%)	183 (50%)
Demanda reprimida graduação	d_1^-	160	178	183
Demanda atendida PG	$x_{pos-grad}$	4.5	4.5	4.5
Demanda reprimida PG	d_2^-	-	-	-
Demanda atendida TCC	x_{TCC}	-	-	-
Demanda reprimida TCC	d_3^-	108	108	108
Demanda atendida Teses	x_{Tese}	28	28	28
Demanda reprimida Teses	d_4^-	-	-	-
Horas alocadas para projetos		69h (10%)	32 (6%)	30 (5%)
Total de horas não atendidas		240	267	436
Professores a contratar		6	10	11

Essa modificação nas prioridades de alocação pode prevenir a redução da oferta de bolsas de pesquisa em nível de pós-graduação. Pois a concessão de bolsas depende do funcionamento das aulas e de atividades de pesquisa. Entretanto, se a pós-graduação for priorizada, a necessidade de contratação de docentes seria ainda maior.

A recomendação para solucionar o problema seria contratar no mínimo mais 7 professores, para garantir o provimento dos serviços críticos de ensino e orientações. Porém, para garantir o funcionamento do departamento em logo prazo e suprir a necessidade de um novo curso, a necessidade de contratação seria de 11 professores (aumento de 61% no quadro).

6.4. CONSIDERAÇÕES FINAIS

Esse trabalho teve como objetivo ilustrar o uso da técnica *Goal Programming* para auxiliar a alocação de recursos humanos em um departamento de uma universidade. Foi formulado um modelo baseado em programação linear com o intuito de minimizar o *gap* entre a demanda por atividades de ensino, pesquisa, extensão e pós-graduação e a capacidade instalada no departamento.

O exemplo ilustrativo discutido explorou três cenários-base, em que a capacidade instalada do departamento foi alterada quando alguns professores foram designados para atividades administrativas. Também foi explorado o impacto de potenciais afastamentos docentes para cursar pós-graduação. Outro ponto discutido, foi o impacto da priorização de atividades da graduação ou da pós-graduação no atendimento das necessidades institucionais por aulas e orientações.

Os resultados mostraram que em todos os casos, haveria necessidade de ampliação do quadro docente. Também se chegou à conclusão de que atender primeiro as demandas menores de carga-horária pode ser uma solução temporária para amenizar o problema. No entanto, a solução mais adequada seria a ampliação do quadro em 61%.

Como oportunidades de pesquisa, sugere-se que estudos de capacidade e de alocação de recursos humanos sejam realizados em universidades com distintas estruturas organizacionais. Por exemplo, a lotação carga horária em universidades com estrutura múlti campi pode divergir da lotação de universidades com aulas concentradas em um único campus.

REFERÊNCIAS

- Caballero, R.; Goñmez, T.; Ruiz, F. *Goal Programming* : Realistic Targets For The Near Future. V. 110, N. January, P. 79–110, 2010.
- Campolina, A. G. Et Al. Análise De Decisão Multicritério Para Alocação De Recursos E Avaliação De Tecnologias Em Saúde: Tão Longe E Tão Perto? *Cadernos De Saúde Pública*, V. 33, N. 10, Out. 2017.
- Charnes, A.; Cooper, W. W. *Management Models And The Industrial Applications Of Linear Programming*. New York: John Wiley & Sons, 1961.
- Chiavenatto, I. *Introdução À Teoria Geral Da Administração*. 9ª Ed. Rio De Janeiro: Manole, 2014.
- Cne. *Diretrizes Curriculares Nacionais Do Curso De Graduação Em Engenharia* Ministério Da Educação, , 2019.
- Dantzig, G. B. *Programming In A Linear Structure*. *Econometrica*, V. 17, P. 73–74, 1949.
- El Gibari, S.; Gómez, T.; Ruiz, F. Building Composite Indicators Using Multicriteria Methods: A Review. *Journal Of Business Economics*, V. 89, N. 1, 2019.
- Ignizio, J. P. *Goal Programming And Extensions*. Lexington: Lexington Books, 1976.
- Jayashree, D. N.; Harish Babu, G. A. Optimum Allocation Of Resources In University Management Through *Goal Programming*. *Global Journal Of Pure And Applied Mathematics*, V. 12, N. 4, P. 2777–2784, 2016.
- Jones, D.; Tamiz, M. *Practical Goal Programming*. New York: Springer, 2010. V. 141
- Lee, S. M. Decision Analysis Through *Goal Programming*. *Decision Sciences*, V. 2, N. 2, P. 172–180, Abr. 1971.
- Lee, S. M. S. M. *Goal Programming For Decision Analysis*. Philadelphia: Auerbach Publishers, 1972.
- Nardo, M. Et Al. *Handbook On Constructing Composite Indicators*. 1. Ed. Paris: Oecd Publications, 2008.
- Orumie, U. C.; Ebong, D. A Glorious Literature On Linear *Goal Programming* Algorithms. *American Journal Of Operations Research*, V. 04, N. 02, P. 59–71, 2014.
- Pareto, V. *Manual Of Political Economy* (Translation Of *Manuale Di Economia Politica* (In Italian)). 2014. Ed. [S.L.] Oxford University Press, 1906.
- Rifai, A. K. A Note On The Structure Of The Goal-Programming Model: Assessment And Evaluation. *International Journal Of Operations & Production Management*, V. 16, N. 1, P. 40–49, 1996.
- Romero, C. *Handbook Of Critical Issues In Goal Programming*. 1. Ed. Cordoba: Pergamon Press, 1991.
- Schniederjans, M. J. *Goal Programming: Methodology And Applications*. Boston, Ma: Springer Us, 1995.
- Schniederjans, M. J.; Kim, G. C. A *Goal Programming* Model To Optimize Departmental Preference In Course Assignments. *Computers And Operations Research*, V. 14, N. 2, P. 87–96, 1987.



ISBN: 978-65-86127-76-8

CRL



9 786586 127768