

# Universidade Federal Fluminense Escola de Engenharia Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações

# Algoritmo Memético Multiobjetivo para Alocação de Bases e Dimensionamento de Equipes

Paulo de Morais Oliveira Filho

Niterói - Rio de janeiro, 25 de outubro de 2019

#### Paulo de Morais Oliveira Filho

# Algoritmo Memético Multiobjetivo para Alocação de Bases e Dimensionamento de Equipes

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense, como requisito parcial para a Obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações. Área de concentração: Sistemas de Energia Elétrica.

Orientador: Vitor Hugo Ferreira

Niterói - Rio de janeiro 25 de outubro de 2019

#### Ficha catalográfica automática - SDC/BEE Gerada com informações fornecidas pelo autor

Oliveira filho, Paulo de Morais

Algoritmo memético multiobjetivo para alocação de bases e dimensionamento de equipes / Paulo de Morais Oliveira filho;

Vitor Hugo Ferreira, orientador. Niterói, 2019. 92 p.: il.

Dissertação (mestrado)-Universidade Federal Fluminense, Niterói, 2019.

DOI: http://dx.doi.org/10.22409/PPGEET.2019.m.13667063741

1. Distribuição de energia. 2. Otimização. 3. Programação (matemática). 4. Algoritmo metaheurístico. 5. Produção intelectual. I. Ferreira, Vitor Hugo, orientador. II. Universidade Federal Fluminense. Escola de Engenharia. III. Título.

CDD -

#### PAULO DE MORAIS OLIVEIRA FILHO

# ALGORITMO MEMÉTICO MULTIOBJETIVO PARA ALOCAÇÃO DE BASES E DIMENSIONAMENTO DE EQUIPES

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica e de Telecomunicações da Universidade Federal Fluminense como requisito parcial para a Obtenção do Grau de Mestre em Engenharia Elétrica e de Telecomunicações.

Área de concentração: Sistemas de Energia Elétrica.

BANCA EXAMINADORA

Prof. Dr. Vitor Hugo Ferreira - Orientador

Universidade Federal Fluminense - UFF

Prof. Dr. Marcio Zamboti Fortes
Universidade Federal Fluminense - UFF

Prof. Dr. Bruno Henriques Dias

Universidade Federal de Juiz de Fora - UFJF

Niterói (outubro/2019)

### Agradecimentos

Agradeço primeiramente a Deus, o autor e consumador da vida, por ter me guardado, capacitado e suprido todas as minhas necessidades até aqui.

À minha família, por todo apoio e carinho, em especial aos meus pais, que sempre me educaram e me instruíram a seguir o caminho dos estudos.

A todos os amigos, pelas palavras de incentivo, apoio e encorajamento.

Ao meu orientador e amigo, Vitor Hugo Ferreira, por todos os conselhos e orientações, desde a gradução e durante o mestrado, com discussões sempre proveitosas para a elaboração deste trabalho.

Aos professores Marcio Zamboti Fortes e Bruno Henriques Dias, que gentilmente aceitaram o convite para compor a banca de avaliação deste trabalho.

Ao professor Bruno Soares Moreira Cesar Borba, pelas orientações valiosas na elaboração do artigo publicado no ISGT 2019.

Às equipes da HOC e do laboratório de logística integrada e sistemas (LOGIS) da UFF, em especial ao amigo Eduardo Queiroga, que esteve presente no projeto SIDEC desde o início.

Ao grupo Energisa pelo apoio financeiro para realização deste trabalho. E também ao programa de pós graduação em Engenharia Elétrica e de Telecomunicações da UFF, pelo apoio financeiro para apresentação de artigo em congresso acadêmico.

#### Resumo

Este trabalho aborda o problema de alocação de bases operacionais e dimensionamento de equipes para sistemas de distribuição de energia elétrica. Interrupções no fornecimento de energia são prejudiciais tanto à sociedade quanto às concessionárias de distribuição. Determinar a quantidade e posicionamento de bases operacionais para lidar com as interrupções de energia é uma maneira de melhorar a qualidade do serviço. Em uma segunda etapa, deseja-se dimensionar o número de equipes técnicas (eletricistas) para atendimento da demanda de serviço. Determinar o posicionamento de bases e o dimensionamento de equipes são etapas de planejamento estratégico (longo prazo) e tático (médio prazo), respectivamente, que têm por objetivo melhorar a qualidade do fornecimento de energia elétrica por meio da minimização do tempo de atendimento às diversas ordens de serviço (OSs). Do ponto de vista da distribuidora, os objetivos são, além de reduzir o tempo médio de atendimento às ocorrências, reduzir os custos operativos (OPEX) e os custos de investimento (CAPEX), através dos quais deseja-se otimizar os índices de continuidade individuais, que mensuram quanto tempo os clientes ficam sem o fornecimento de energia elétrica com apurações mensais, trimestrais e anuais, sendo estes índices bons indicadores para qualificar a confiabilidade do sistema elétrico. Dado que o CAPEX e a qualidade do serviço, representada pelos indicadores individuais de continuidade, são objetivos conflitantes, a metodologia apresentada neste trabalho faz a alocação de bases e dimensionamento de equipes simultaneamente, tratando o problema de forma multiobjetivo, com o intuito de fornecer uma gama de possíveis soluções que auxiliem na tomada de decisão de longo e médio prazos, no que diz respeito ao planejamento do sistema de distribuição de energia elética. Para resolução do problema, primeiro foram comparadas duas técnicas meta-heurísticas: MOPSO (do inglês Multiobjective Particle Swarm Optimization) e NSGA-II (do inglês Nondominated Sorting Genetic Algorithm). O MOPSO apresentou melhor desempenho quanto à quantidade de soluções e a diversidade das mesmas. Em seguida, para otimizar o processo de busca, foi agregado ao MOPSO um modelo de programação linear inteira mista (PLIM), resolvido com o algoritmo de branch and cut. A meta-heurística provê uma abordagem multiobjetivo e a técnica de programação matemática refina localmente e de forma ótima as soluções propostas pelo MOPSO. Os resultados mostram que a junção das diferentes técnicas possibilita encontrar maior quantidade de soluções, sendo estas soluções um conjunto ótimo de Pareto, quando comparado com a abordagem puramente meta-heurística.

Palavras-chaves: alocação de bases, distribuição de energia, otimização por enxame de partículas, algoritmos genéticos, programação matemática.

#### **Abstract**

This work addresses the problem of maintenance facility (depot) location and workforce planning for electric power distribution systems. Power interruptions can be harmful to both society and distribution companies. Determining the optimal number and sites of depot location to handle power interruptions in the long term can improve the quality of service. Next, it is necessary to scale the number of technical crews (electricians) to meet service demand. Determining depot location and workforce sizing are strategic (long-term) and tactical (mid-term) planning steps, respectively, which can improve the quality of electricity supply by minimizing service restoration time to the various work orders (WOs). From the distributor's point of view, the objectives are, in addition to reducing the average service restoration time, reduce operating expenses (OPEX) and investment resources (CAPEX), through which one wants to optimize individual continuity indicators, which measure how long costumers are without electricity supply with monthly, quarterly and annual calculations. These are good indicators to qualify the reliability of the electrical system. Since CAPEX and the service quality, represented by the individual continuity indicators, are conflicting objectives, the methodology presented in this work considers the depot location and workforce sizing simultaneously, treating the problem with a multiobjective approach, in order to provide a range of possible solutions to support long and mid-terms decision making regarding the planning of the electric power distribution system. To solve the problem, first, two metaheuristic approaches are compared: MOPSO and NSGA-II. MOPSO showed better performance regarding the number of solutions and their diversity. Next, to optimize the search process, MOPSO was combined with a mixedinteger linear programming model (MILP), solved by a branch and cut algorithm. The metaheuristic provides a multi-objective approach and, the mathematical programming technique solves the solutions proposed by MOPSO optimally. Results show that the combination of the different techniques makes it possible to find more solutions, and these solutions are an optimal set of Pareto when compared to the pure metaheuristic approach.

**Keywords**: depot location, power distribution, particle swarm optimization, genetic algorithms, mathematical programming

# Lista de ilustrações

Figura 1 – Estrutura básica da otimização mono e multiobjetivo	16
Figura 2 – Representação do vetor ideal para k=2	17
Figura 3 – Exemplo de frente de Pareto	18
Figura 4 $-$ Mapeamento das variáveis de decisão no espaço das funções objetivo. $\cdot$	19
Figura 5 – Árvore Branch-and-Bound.	22
Figura 6 – Procedimento do método NSGA-II	29
Figura 7 – Fluxograma do método NSGA-II	30
Figura 8 – Esquema de interação das partículas no PSO	32
Figura 9 – Esquema de interação das partículas no MOPSO	33
Figura 10 – Fluxograma MOPSO	34
Figura 11 – Exemplo de otimização da frente de Pareto	35
Figura 12 – Fluxograma MOPSO alterado	36
Figura 13 – Divisão de localidades	38
Figura 14 – Frente de Pareto com conjunto de possíveis soluções	47
Figura 15 – Fluxograma do modelo de alocação de bases e dimensionamento de	
equipes	54
Figura 16 – Mapa de localidades e bases de Sergipe	56
Figura 17 – Volume de OSs para o Sergipe	58
Figura 18 – Amostra de distribuição espacial de OSs para o Sergipe	58
Figura 19 – Comparação entre MOPSO e NSGA-II: 100 iterações e 20 partículas $$ .	61
Figura 20 — Comparação entre MOPSO e NSGA-II: 250 iterações e 50 partículas $$ . $$ .	62
Figura 21 – Evolução do NSGA-II para diferentes números de iterações	63
Figura 22 – Evolução do MOPSO para diferentes números de iterações $\dots$	63
Figura 23 – Evolução do repositório do MOPSO	65
Figura 24 – Evolução do repositório do MOPSO+PLIM	65
Figura 25 – Frentes de Pareto iniciais	66
Figura 26 – Frentes de Pareto atualizadas	67
Figura 27 – Frente de Pareto com viabilidade por solução	69

# Lista de tabelas

Tabela 1 –	Dados de localidades	57
Tabela 2 –	Quantitativo de eletricistas por base	59
Tabela 3 –	Parâmetros do MOPSO	60
Tabela 4 –	Parâmetros do NSGA-II	60
Tabela 5 –	Dados comparativos entre as duas abordagens	64
Tabela 6 –	Dados comparativos após atualização das frentes de Pareto	68
Tabela 7 –	Tabela com soluções viáveis	68

# Sumário

1	INTRODUÇÃO	1
1.1	Problema	. 1
1.2	Objetivo	. 2
1.3	Produção Científica	. 3
1.4	Sistema de Dimensionamento de Equipes de Campo (SIDEC)	. 3
1.5	Estrutura do Trabalho	4
2	REVISÃO DA LITERATURA	5
2.1	Planejamento da força de trabalho nos diferentes setores	. 5
2.2	Dimensionamento de equipes aplicado ao SEP	. 7
2.2.1	Planejamento estratégico	. 8
2.2.2	Planejamento Tático	. 9
2.3	Considerações	10
3	OTIMIZAÇÃO MULTIOBJETIVO	13
3.1	Mono objetivo x Multiobjetivo	13
3.1.1	Variáveis de decisão	16
3.1.2	Vetor ideal	. 17
3.2	Eficiência de Pareto	17
3.2.1	Definição 1 (Dominância de Pareto):	18
3.2.2	Definição 2 (Otimalidade de Pareto):	18
3.2.3	Definição 3 (Conjunto ótimo de Pareto):	. 19
3.2.4	Definição 4 (Fronteira de Pareto):	. 19
3.3	Programação matemática	19
3.3.1	Programação linear inteira e programação linear inteira mista	20
3.4	Visão geral de algoritmos de otimização multiobjetivo	23
3.4.1	Classificação dos métodos	23
3.4.2	Algoritmos clássicos	. 24
3.4.3	Considerações sobre os algoritmos clássicos	. 25
3.4.4	Técnicas meta-heurísticas	. 25
3.5	Métodos implementados	. 27
3.5.1	Método NSGA-II	. 28
3.5.2	Algoritmo de otimização por enxame de partículas (MOPSO)	31
3.5.3	Algoritmo memético proposto - MOPSO modificado	35
4	METODOLOGIA	37

4.1	Modelagem do problema	<b>37</b>
4.1.1	Função objetivo	38
4.1.2	Bases	39
4.1.3	Deslocamento	39
4.1.4	Compensações	39
4.1.5	Eletricistas	43
4.1.6	Formulação matemática	44
4.1.7	Abordagem multiobjetivo	46
4.2	Dimensionamento de eletricistas	48
4.2.1	Função objetivo	48
4.2.2	Formulação matemática	49
4.3	Análise de viabilidade	52
4.3.1	Premissas e metodologia de cálculo	52
4.4	Resumo	53
5	ANÁLISE DE RESULTADOS	55
5.1	Dados da distribuidora: Energisa Sergipe	55
5.1.1	Localidades e bases	55
5.1.2	Ordens de Serviço	56
5.1.3	Clientes e Eletricistas	59
5.2	Resultados	60
5.2.1	Comparação entre MOPSO e NSGA-II	61
5.2.1.1	Caso 1: 100 iterações e 20 partículas	61
5.2.1.2	Caso 2: 250 iterações e 50 partículas	61
5.2.2	Comparação entre MOPSO e MOPSO modificado	64
6	CONCLUSÕES E TRABALHOS FUTUROS	70

### 1 Introdução

A sociedade moderna é extremamente dependente da energia elétrica. Fornecimento de água, funcionamento de meios de transporte, hospitais, bancos e sistemas de comunicação são totalmente dependentes do bom funcionamento do sistema elétrico de potência, tornando-o um elo fundamental na infraestrutura da economia de um país [1], o que torna indispensável que os sistemas elétricos de potência possuam resiliência e confiabilidade. No contexto da indústria de energia elétrica, o conceito de resiliência engloba o desempenho antes, durante e após eventos que comprometam o fornecimento de energia elétrica. Em outras palavras, a resiliência pode ser definida como a habilidade de uma entidade em antecipar, resistir, absorver, responder e se adaptar após alguma perturbação [2]. No que diz respeito à confiabilidade, esta é medida essencialmente pela frequência e duração da interrupção do fornecimento de energia [3].

Algumas das causas que comprometem o fornecimento de energia estão ligadas a eventos não previstos, podendo ser citados aqueles relacionados a fatores climáticos, ambientais e falhas de equipamentos. [4],[5]. Em [6] é feita uma revisão dos blackouts ocorridos em diversos países, considerando o período de 2005 a 2015. Dentre os casos destacados, pode ser citado o blackout ocorrido no ano de 2011 no Nordeste do Brasil, no qual 40 milhões de pessoas ficaram sem energia elétrica por mais de três horas. Além dos impactos sociais, estes eventos acarretam em prejuízos econômicos significativos, que podem variar de acordo com a duração da interrupção. Estima-se que os Estados Unidos tenham um custo anual que varia entre \$20 e \$55 bilhões por ano [7] relacionado a interrupções de energia causadas por tempestades. Além de eventos catastróficos, as ocorrências mais comuns e frequentes, envolvem avaria de equipamentos, rompimento de cabos, corte e religação de clientes e etc. De acordo com a Agência Nacional de Energia Elétrica (ANEEL), órgão regulatório e fiscalizatório no Brasil, em 2018 as concessionárias brasileiras de distribuição de energia elétrica tiveram um prejuízo de R\$ 423.914.243,80 [8] em compensações creditadas aos consumidores, sendo a falta de energia uma das reclamações mais registradas junto à ANEEL [9]. As companhias de distribuição de energia têm então o desafio de minimizar a duração dessas interrupções, sendo um dos principais indicadores de confiabilidade a rapidez com que um sistema elétrico consegue se recuperar após um evento que interrompa o fornecimento de energia.

#### 1.1 Problema

O processo de reestabelecimento de um sistema elétrico é extremamente complexo e se divide em várias etapas, envolvendo uma sequência de decisões operacionais e restrições técnicas, tornando-o um problema combinatorial [5]. Ao longo dos últimos anos diversos algoritmos vêm sendo desenvolvidos para otimizar a resolução do problema de reestabelecimento do sistema elétrico [10],[11]. Em [12], os autores destacam que a mão de obra técnica é considerada como recurso resiliente, ou seja, coopera para a resiliência do sistema elétrico. O dimensionamento de mão de obra técnica, portanto, é descrito como uma das etapas no processo de reestabelecimento do sistema elétrico. Esta etapa consiste na alocação de mão de obra técnica para o reparo e manutenções preventivas do sistema. Quanto às etapas no processo de reestabelecimento, pode-se categorizá-las em: planejamento estratégico, planejamento tático e planejamento operacional [13]. O planejamento estratégico tem um impacto de longo prazo (por exemplo, anos) e as ações criadas pela administração da empresa podem envolver capacitação de funcionários, políticas de qualidade e localização de infraestrutura [14], [15]. Mais especificamente, decisões de planejamento estratégico para melhoria da confiabilidade incluem: capacidade de distribuição de subestações, configuração do sistema elétrico, estabelecimento de bases operacionais para alocação de recursos (físicos e humanos) e divisão geográfica da área de concessão, estabelecendo territórios de serviço [16]. O planejamento tático abrange um período de médio prazo (por exemplo, meses) e possui decisões mais detalhadas das ações da empresa, tais como determinação de níveis de estoque, taxa de produção, terceirização, contratação e alocação de funcionários [17], [18]. Por fim, em um horizonte de curto prazo (por exemplo, dias), o planejamento operacional executa as ações, através da divisão de tarefas, planos e cronogramas, a fim de garantir as metas traçadas [19].

Assim, com o objetivo de melhorar a confiabilidade do sistema elétrico, a primeira etapa no estudo de planejamento consiste em alocar bases operacionais. Esta etapa objetiva localizar da melhor maneira um conjunto de instalações, que podem servir de almoxarifado, alocação de equipes técnicas e ferramentas de uso das equipes. A localização ótima de bases investiga onde localizar fisicamente um conjunto de bases (recursos) de modo a minimizar o custo de atender um conjunto de demandas (clientes), sujeito a um conjunto de restrições. Dado que as decisões causam um impacto a longo prazo, a localização das bases afeta a flexibilidade do sistema para atender a demanda à medida que evolui ao longo do tempo [20]. No contexto do setor elétrico o objetivo é reduzir os custos operacionais (OPEX), custos de investimento (CAPEX) e melhorar os indicadores que qualificam os serviços prestados pela distribuidora, estabelecidos por norma [21]. Caso estes indicadores não sejam respeitados, a concessionária pode ser penalizada, gerando assim mais custos à companhia.

#### 1.2 Objetivo

Este trabalho apresenta uma metodologia aplicada essencialmente na primeira e segunda categorias do planejamento da manutenção de distribuidoras de energia, isto é, na

alocação de bases operacionais e dimensionamento de equipes. Portanto, o objetivo deste trabalho é apresentar um modelo matemático de posicionamento de bases operacionais e dimensionamento de equipes técnicas, com a meta de obter soluções que proporcionem a melhoria da qualidade do fornecimento de energia elétrica com redução de CAPEX e OPEX.

Para implementação do modelo foi adotada uma abordagem multiobjetivo, a partir de uma técnica meta-heurística de otimização multiobjetivo por enxame de partículas (MOPSO) para resolução do problema. A abordagem multiobjetivo será utilizada devido à existência de objetivos conflitantes no problema. Além disso, os algoritmos meta-heurísticos têm se mostrado bastante eficientes frente aos modelos matemáticos clássicos para resolução do problema de alocação de bases. Em conjunto com a abordagem multiobjetivo será utilizado um modelo de programação linear inteira mista, que atua no refinamento das soluções encontradas pelo MOPSO.

#### 1.3 Produção Científica

 Autores: Paulo de Morais Oliveira Filho, Vitor Hugo Ferreira, Bruno S. M. C. Borba, Rafael V. Tavares, Eduardo Queiroga, João Marcos P. Silva, Eduardo Uchoa, Níssia C. R. Bergiante, Bernardo Salgado Moreira, Pedro H. C. Machado, "A comparative Analysis Between Particle Swarm Optimization and Mathematical Programming for Optimal Location of Maintenance Facilities", ISGT 2019.

Neste trabalho foi feita uma comparação entre dois algoritmos para o problema de alocação de bases: otimização por enxame de partículas (PSO) e um modelo de programação matemática inteira mista. Para testar os modelos foram utilizados dados relativos ao estado do Tocantins, os quais foram disponibilizados pela Energisa Distribuição. A comparação foi feita para diferentes instâncias do problema, isto é, para diferentes números de localidades. Pôde-se observar que aumentar o número de localidades permite encontrar melhores soluções para o problema. Com o PSO foi possível encontrar soluções para grandes instâncias, enquanto que o modelo de programação matemática apresentou limitação para maiores instâncias, embora para menores instâncias o modelo de programação matemática tenha sido capaz de encontrar a solução ótima em menor tempo, quando comparado com o PSO.

#### 1.4 Sistema de Dimensionamento de Equipes de Campo (SIDEC)

O autor deste trabalho esclare que os modelos apresentados neste documento são resultado de um projeto de pesquisa e desenvolvimento (P&D ANEEL 00032-1704/2017) em parceria com a HOC Tecnologia da Informação LTDA e Grupo Energisa. O objetivo

do projeto é desenvolver uma ferramenta corporativa que visa atender às demandas apresentadas nos três níveis de planejamento: estratégico, tático e operacional. Assim, a ferramenta é capaz de fornecer estudos nos três níveis, funcionando como um instrumento de suporte ao planejamento da concessionária. A ferramenta produz estudos de alocação de bases operacionais, dimensionamento de equipes técnicas (eletricistas) e dimensionamento de escalas de trabalho das equipes.

O SIDEC é estruturado em 3 módulos: previsão, estratégico e tático/operacional. O módulo de previsão, com base nos dados históricos, faz previsão da demanda futura de serviços. O módulo estratégico fornece um estudo completo de alocação de bases, dimensionamento de equipes e escalas. O módulo tático/operacional fornece estudos tanto de equipes quanto de escalas, agregando dimensionamento de equipes e escalas em um único estudo. Os módulos estratégico e tático/operacional utilizam os dados de previsão do módulo previsor para realizar os estudos.

No entanto, os conteúdos apresentados neste documento não se resumem apenas em reprodução dos resultados do projeto, mas também apresentam as contribuições para o referido projeto, por meio das pesquisas e resultados específicos que serão apresentados no presente documento. Assim, os resultados apresentados neste trabalho utilizam informações de todos os módulos do projeto de P&D, mas com enfoque no posicionamento de bases e dimensionamento de equipes.

#### 1.5 Estrutura do Trabalho

Após o capítulo introdutório o trabalho está estruturado da seguinte maneira. O capítulo 2 apresenta a revisão da literatura. O capítulo 3 apresenta a teoria de otimização multiobjetivo, uma visão geral sobre programação matemática, algoritmos clássicos e técnicas metaheurísticas, e uma explicação mais detalhada dos algoritmos utilizados neste trabalho. O capítulo 4 apresenta a metodologia proposta, abordando a modelagem do problema, premissas adotadas e formulação matemática. Os resultados são apresentados no capítulo 5, bem como a análise crítica dos mesmos. Por fim, o capítulo 6 traz as conclusões e trabalhos futuros.

#### 2 Revisão da literatura

O objetivo desta seção é apresentar uma revisão dos trabalhos que tratam do problema de dimensionamento de equipes e alocação de bases. Será feita uma breve discussão sobre o problema nos diversos setores. Em seguida, são apresentados os trabalhos encontrados na literatura, com aplicação no setor elétrico. Por fim, alguns comentários são feitos em relação à revisão apresentada, destacando as limitações encontradas e fazendo um comparativo entre a metodologia proposta no presente trabalho e as metodologias comumente utilizadas na literatura.

#### 2.1 Planejamento da força de trabalho nos diferentes setores

O planejamento da força de trabalho é uma subárea de recursos humanos que começou a ser estudada nos anos de 1960. O objetivo é dimensionar e alocar de forma ótima as equipes para executar determinado serviço em uma escala de trabalho específica. Nesse sentido, o planejamento pode ser aplicado a qualquer tipo de companhia. Existem trabalhos voltados para coleta de resíduos [22], corpo de bombeiros [23], transporte [24], setor de saúde [25] e outros [26, 27, 28, 29, 30, 31, 32, 33, 13].

Em [34] é feita uma revisão sobre os dimensionamentos de equipes nos diversos setores. Nesta revisão os autores categorizam os estudos por área, destacando a área de enfermagem com maior quantidade de trabalhos (24%), seguida de áreas gerais (19%) e do setor de transportes (13%). Dentre os trabalhos revisados, observa-se que a maior parte considera custos médios para manutenção de um trabalhador. Outros trabalhos consideram outros aspectos nos custos com o objetivo de incluir restrições da realidade ao problema: habilidades do trabalhador, horas extras, deslocamento, custos de execução dos serviços e outros custos.

O dimensionamento de equipes pode ser abordado de três maneiras. A primeira abordagem é voltada para o planejamento estratégico com foco na instalação de bases operacionais. A segunda abordagem é direcionada ao planejamento tático, em que o problema envolve o dimensionamento e a alocação das equipes de trabalho. Finalmente, a terceira abordagem trata do planejamento operacional e lida com a distribuição de serviços e das escalas de trabalho das equipes.

Para exemplificar o planejamento estratégico, em [20] os autores exploram o caso de um território dividido por regiões de operação, sendo cada região servida por uma base. O objetivo é determinar a quantidade mínima de recursos nas diferentes bases para atender ao requisito de tempo de serviço no território. São utilizadas três variáveis

de decisão: localização das bases, alocação da demanda e quantidade de recursos. O problema é formulado utilizando uma Programação Inteira Mista Estocástica (PIM). Iannoni e Morabito [35], por sua vez, combinam extensões do modelo hipercubo de filas com algoritmos genéticos para otimizar a configuração e operação de sistemas médicos emergenciais em rodovias. Inicialmente é apresentado um método para localizar as bases de ambulâncias ao longo da rodovia, de forma a otimizar as principais medidas de desempenho do sistema. Em seguida, a abordagem é estendida para apoiar duas decisões combinadas: a localização das bases de ambulâncias e o dimensionamento das regiões de cobertura de cada base na rodovia. A abordagem permite determinar os locais para posicionar as bases de ambulâncias e dimensionar os tamanhos das suas áreas de atuação, tais que minimizem o tempo médio de resposta aos usuários e/ou o desbalanceamento das cargas de trabalho das ambulâncias do sistema. Outra forma de otimizar a localização de bases é através de métodos de agrupamentos, como utilizado por Stummer et al. [36], que determinam a localização de hospitais através do método k-means.

Do ponto de vista tático, são abordados o dimensionamento e a alocação das equipes de operação e manutenção nas bases operativas. O processo de gerenciar equipes de operação e manutenção é uma tarefa complexa, devido à combinação de incertezas envolvidas. Esse tipo de problema geralmente é resolvido de forma específica por um pequeno número de especialistas [37]. A primeira etapa do processo envolve a determinação da quantidade de trabalhadores a partir do dimensionamento das equipes. O dimensionamento de equipes é uma decisão que determina a quantidade ótima de funcionários para compor uma equipe, a fim de minimizar custos e atender níveis estipulados pela empresa ou por órgãos reguladores [38]. A segunda etapa do processo visa alocar, de forma ótima, as equipes nas bases de operação, objetivando minimizar custos e o tempo de atendimento das ocorrências.

Por fim, um fator que pode ser levado em consideração no dimensionamento de equipes são as habilidades de cada trabalhador. Considerando que as habilidades de um trabalhador contribuem para vantagem competitiva de uma empresa, as diferenças individuais devem ser levadas em consideração em uma contratação. Portanto, para minimizar os custos trabalhistas e atender critérios de desempenho, como qualidade ou velocidade de trabalho, as empresas se concentram no desempenho de pessoas com habilidades diferentes. Do ponto de vista do empregador, embora a diversidade de habilidades disponíveis nos trabalhadores permita que uma empresa ofereça uma gama mais ampla de serviços e, assim, expanda sua participação de mercado, tais vantagens podem ser anuladas, por exemplo, pela presença de trabalhadores inexperientes com baixo desempenho [39].

De Bruecker et al. [40] apresentam uma revisão e classificação da literatura sobre o dimensionamento de equipes incorporando as habilidades dos trabalhadores. As habilidades podem ser divididas em duas classes, hierárquica e categórica. As habilidades hierárquicas se referem à substituição de trabalhadores, isto é, um trabalhador mais habilidoso pode

exercer a função de um trabalhador menos habilidoso, porém o contrário não é válido. Trabalhadores mais habilidosos geralmente possuem grau de educação ou experiência maior. As habilidades hierárquicas podem ser definidas em um intervalo contínuo ou discreto em níveis. Alguns trabalhos consideram apenas dois níveis: qualificado ou não qualificado. No caso das habilidades categóricas, não há diferença no nível das habilidades, ou seja, as habilidades não são melhores ou piores, apenas referentes à uma determinada tarefa. Dessa forma, as habilidades categóricas são referentes ao treinamento cruzado, em que um trabalhador que possui diferentes habilidades é capaz de realizar tarefas diferentes. As habilidades mais recorrentes da literatura listada pelos autores são descritas como: idade e tempo de empresa; nível de experiência; grau de formação técnica e capacitação; licença, qualificação e títulos.

#### 2.2 Dimensionamento de equipes aplicado ao SEP

O planejamento da força de trabalho pode ser dividido em três níveis: operacional, tático e estratégico. O planejamento operacional trata principalmente da atribuição de trabalhadores para cobrir o requisito de mão-de-obra no nível operacional, envolvendo a distribuição de serviços e a escala dos funcionários. O planejamento tático geralmente considera decisões de médio prazo, na qual pode ser feita mensalmente, trimestralmente ou anualmente. O problema mais amplamente estudado neste nível é determinar a dimensão das equipes em cada período do horizonte de planejamento para atender as previsões de demanda de serviço. No nível estratégico, os pesquisadores lidam com decisões de longo prazo, como a localização das bases operacionais [4],[11],[13].

Em [41] é apresentada uma formulação para reestabelecimento do sistema elétrico com o objetivo final de alocação ótima de bases com o mínimo custo e menor tempo de reparo. O modelo é estruturado hierarquicamente em 3 etapas: um modelo operacional, um modelo tático e um modelo estratégico. Para o modelo operacional, considera-se o conhecimento prévio da quantidade de equipes disponíveis e das bases existentes. O objetivo é programar o despacho ótimo de equipes. No modelo tático o objetivo é determinar o despacho das equipes assumindo que o número de equipes é fixo. Por fim, no modelo estratégico deseja-se determinar o número de bases e equipes por base. Em todos os modelos o objetivo é minimizar os custos operacionais e tempo de reparo. Para resolução os autores utilizaram o software LINDO, que é um solver utilizado na resolução de modelos de programação linear, não linear, inteira e estocástica. As modelagens são baseadas em formulações e técnicas de otimização multicritério utilizando programação de metas. Assim, os múltiplos objetivos são combinados, convertendo o problema multicritério em uma formulação mono objetivo onde técnicas como programação linear podem ser aplicadas.

#### 2.2.1 Planejamento estratégico

No âmbito da distribuição de energia elétrica um planejamento estratégico pode ser visto como a alocação e dimensionamento de depósitos e equipes de reparo baseada na demanda futura [41, 42, 43, 44]. Um depósito é um local onde os recursos para restaurar a energia elétrica em determinada localidade são armazenados. Esses recursos incluem equipes de reparo, veículos, postes, transformadores e outros equipamentos. Os depósitos podem ter quantidades e recursos diferentes. O problema de localização de depósitos de recursos consiste em selecionar, simultaneamente, os locais apropriados para alocar depósitos com capacidades de recursos diferentes e determinar as quantidades de recursos enviados para vários locais ou clientes dispersos geograficamente, a fim de satisfazer as demandas e minimizar o custo total de transporte para a restauração de energia [11].

Observa-se que poucos trabalhos abordam o problema de alocação de bases no âmbito do sistema de distribuição elétrica. Porém, alguns autores analisam o planejamento estratégico, tais como [43], que desenvolvem e comparam duas modelagens, uma utilizando programação matemática e outra utilizando uma heurística, para posicionar depósitos a fim de gerenciar os recursos necessários para a restauração de energia elétrica de forma eficiente e econômica. O modelo consiste em determinar o número ideal, a localização e a quantidade necessária de recursos de cada depósito para minimizar os custos de transporte, custos fixos e custos para implementação das bases, onde a região em estudo é dividida em regiões menores, as quais servem de possíveis candidatas à recepção de uma base. É utilizado um modelo de programação linear inteira para solucionar o problema de forma ótima, porém o esforço computacional é elevado devido ao grande número de variáveis e restrições, sendo então proposta uma heurística para resolução do problema. Neste trabalho, no entanto, a heurística utilizada não é descrita. A modelagem heurística é dividida em duas fases. Na primeira é determinada a localização do depósito e na segunda é determinada a quantidade de recursos em cada depósito. Para a implementação do modelo heurístico duas matrizes são introduzidas, a matriz de custo total, chamada de TCC, e a matriz de custo de transporte, chamada de TCD. Os resultados para um problema com mesma dimensão para ambas as modelagens mostraram que o modelo heurístico tem resultados muito próximos ao ótimo, mostrando que o modelo serve bem para a solução do problema.

Em [44] os autores desenvolvem e discutem um método simples para a redução do tempo da restauração do sistema pelo posicionamento otimizado das bases de equipes de reparo. Para atribuir os locais, consideram-se os efeitos de fenômenos ambientais, econômicos e restrições técnicas. As informações levantadas são: topologia da rede de distribuição; localidades chave, divididas em pontos de carga, dispositivos de proteção nos alimentadores e prováveis locais de falta; impactos ambientais, tais como topologia e rios, fenômenos atmosféricos e qualidade das estradas e tráfego; o custo da terra e as

distâncias entre cidades e vilarejos são considerados como restrições econômicas. Tais variáveis são mapeadas qualitativamente utilizando o software ArcGIS em uma província do Irã. Porém estes mapas ainda necessitam de otimização, chamados de mapas descritivos. O motivo dessa alteração é, por exemplo, a distância das estradas, que não pode ser reconhecida visualmente ou usada para o planejamento. Mas quando as distâncias são apresentadas com camadas de cor, elas podem ser facilmente observadas e usadas para posicionamento. Essas camadas gráficas são criadas pelo ArcGIS, que descrevem a qualidade da acessibilidade às estradas de qualquer local. Esse processo é feito para todos os mapas. A modelagem, utilizando o software "Combination" do ArcGIS, combina os mapas descritivos em um conjunto de regras e procedimentos para representar um fenômeno ou previsão de um resultado onde cada entrada tem seu peso. Eles podem ser usados para prever o posicionamento ótimo para equipes de manutenção.

Em [45] os autores apresentam dois modelos de programação quadrática inteira mista. Um para alocação de um único recurso, e outro para alocação de múltiplos recursos. O objetivo é alocar bases, e para cada base alocar equipes e outros recursos utilizados no reparo do sistema elétrico em casos emergenciais. Os modelos são testados para pequenas instâncias do problema, ou seja, considerando pequenas quantidades de localidades para instalação de bases. Os autores concluem destacando que para pequenas instâncias o problema é resolvido de forma ótima, mas para grandes instâncias o problema torna-se intratável computacionalmente, devido à quantidade de restrições. Para este caso, os autores sugerem que uma heurística seria uma alternativa.

#### 2.2.2 Planejamento Tático

Uma das preocupações das distribuidoras de energia elétrica é minimizar, ou manter em um intervalo aceitável, a duração da interrupção de energia. No entanto, as tarefas de restauração de energia são essencialmente intensivas em mão de obra, e a força de trabalho utilizada possui elevada remuneração e qualificação em diferentes proficiências. Dessa forma, o planejamento tático envolve o dimensionamento e alocação das equipes de operação. A administração das empresas também deve se preocupar com os custos e a insatisfação dos trabalhadores e sindicatos em relação às frequentes contratações, demissões e realocações. Considerando todas essas questões, as distribuidoras de energia elétrica estabelecem um dimensionamento de equipes para lidar com as interrupções de energia de maneira oportuna, com custos anuais mínimos de mão de obra e duração mínima de interrupção do cliente. Para exemplificar a atuação do planejamento tático no âmbito da distribuição de energia elétrica, são apresentados alguns trabalhos desenvolvidos nesta área.

Em [46] os autores desenvolvem um planejamento do dimensionamento das equipes de reparo no sistema de distribuição em casos de falta de energia não planejadas. Os autores

propõem um método baseado em programação por restrições para o planejamento das equipes em turnos, em que se considera a reatribuição entre centrais de serviços, diferentes tipos de equipes, empregados contratados e temporários, e falta de energia em horários arbitrários. As variáveis de decisão utilizadas são: intervalo opcional para agendamento da tarefa de reparo, intervalo opcional para agendamento da tarefa de segurança pública, intervalo fixo para troca de equipe e função cumulativa do número de equipes movidas para a localidade. O objetivo é minimizar a soma ponderada entre os termos: atraso médio quadrático das tarefas de reparo, segurança pública, número total de tarefas de reparo agendadas, cumprimento das tarefas programadas e movimento total da equipe.

Em [4] os autores apresentam um modelo de dimensionamento de equipes com um estudo de caso para uma companhia de distribuição do Canadá. O modelo otimiza a quantidade de funcionários que devem estar disponíveis em cada base operacional, em diferentes situações climáticas, para cobrir as interrupções com custo mínimo de mão de obra e duração mínima de interrupção do cliente. Para isso, os autores apresentam uma estratégia de otimização dividida em duas etapas. O primeiro modelo está associado ao planejamento de longo prazo e o segundo atende aos requisitos de curto prazo. O primeiro e segundo modelos determinam a dimensão ótima das equipes de trabalho para situações normais e anormais de demanda, respectivamente. O segundo modelo também otimiza as decisões de deslocamento. Os custos considerados na função objetivo são: custos anuais, mensais e de realocação de eletricistas. Estes custos são diferenciados para mão de obra interna e externa. A mão de obra interna é fixa, enquanto que a externa pode ser necessária apenas em algumas épocas do ano. Os modelos matemáticos são resolvidos usando o algoritmo de branch and bound incorporado no software LINGO 10.0.

#### 2.3 Considerações

Os trabalhos encontrados na literatura tratam especificamente do problema de alocação de bases e dimensionamento de equipes no sistema elétrico. Em outras revisões não se apresenta nenhum tipo de metodologia para resolução deste problema, no entanto, o mesmo é citado como uma das etapas para reestabelecimento do sistema elétrico, como se observa em [11, 47], onde é feita uma revisão de modelos de otimização e metodologias para planejamento considerando a confiabilidade. Em [16] apresenta-se uma revisão de metodologias para problemas relacionados à confiabilidade e planejamento do sistema elétrico, onde o problema de alocação de bases também é citado no planejamento estratégico, como uma das etapas no planejamento para melhoria da confiabilidade do sistema.

Para os trabalhos que abordam o problema de alocação de bases no sistema elétrico observa-se a limitação dos modelos de programação matemática, sendo destacada pelos próprios autores a dificuldade em resolver o problema quando muitas localidades são

consideradas, visto que conforme eleva-se o número de localiades, estes modelos tornam-se limitados [43]. De fato, há trabalhos que apresentam o problema de alocação de bases em outros setores, nos quais utiliza-se alguma técnica meta-heurística ou algoritmo evolutivo para resolução do problema [48, 49, 50, 51], devido às limitações apresentadas pelos modelos clássicos de programação matemática. Em resultados preliminares [52] do presente trabalho foi feita uma comparação do algoritmo de otimização por enxame de partícula (do inglês particle swarm optimization - PSO), com um modelo de programação linear inteira mista (do inglês mixed integer linear programming - MILP) no problema de alocação de bases e dimensionamento de equipes no setor elétrico. As conclusões apontam que dividir o território de estudo em maior número de localidades permite encontrar melhores soluções a partir do modelo de programação matemática. No entanto, para grandes territórios, a divisão em muitas localidades pode tornar inviável o uso do modelo. Para este caso foi utilizado o PSO, que conseguiu encontrar soluções próximas àquelas encontradas pelo modelo de programação matemática. Além disso, a meta-heurística conseguiu resolver instâncias maiores do problema, para as quais o modelo de programação matemática não foi capaz de resolver.

Outra possibilidade que os algoritmos meta-heurísticos trazem é a possibilidade de modelar o problema considerando múltiplos objetivos a serem otimizados. Para o problema de alocação de bases e dimensionamento de equipes no setor elétrico, as metodologias encontradas utilizam modelos de programação matemática ou alguma meta-heurística, mas nas referidas metodologias o problema é tratado de forma mono objetiva, ou seja, considerando um único objetivo a ser otimizado. Portanto, a metodologia proposta no presente trabalho tem por objetivo tratar o problema de forma multiobjetiva, utilizando um modelo híbrido, que utiliza uma meta-heurística e um modelo de programação matemática, os quais serão apresentados nos capítulos 3 e 4. Mais especificamente, será apresentado um modelo que faz alocação de bases e dimensionamento de equipes simultaneamente. O objetivo é considerar os custos adicionais à implementação de uma base, isto é, considerar custos com recursos humanos, visto que em uma nova base será necessária a alocação de pessoal (técnica e/ou administrativa). Isto pode envolver contratação e/ou demissão de funcionários. Além disso, este trabalho se propõe a considerar o impacto da alocação de bases nos indicadores de continuidade [53], que além de qualificar o serviço prestado pelas distribuidoras de energia, também podem gerar encargos às mesmas. Dado que o objetivo em alocar novas bases é melhorar a qualidade dos serviços prestados, é necessário que haja investimento. Em termos práticos, a realidade de uma distribuidora se resume na necessidade em prover um serviço de qualidade, minimizando custos operativos (OPEX) e custos de investimento (CAPEX). Portanto, a análise multiobjetiva torna-se uma ferramenta auxiliar no processo de tomada de decisão, uma vez que esse tipo de análise fornece uma variedade de soluções. Desta maneira, o tomador de decisão pode escolher aquela que mais se adequa à realidade da concessionária, ao invés de ter apenas uma opção de solução, no

caso da análise mono objetiva, que pode não se adequar às limitações de investimento da concessionária.

## 3 Otimização Multiobjetivo

Problemas de otimização multiobjetivo têm sido abordados com o uso de algoritmos evolutivos (AEs) e técnicas meta-heurísticas. Apesar da variedade de técnicas desenvolvidas em Pesquisa Operacional (PO), a complexidade trazida pelos problemas pede por alternativas na resolução de problemas com múltiplos objetivos a serem otimizados. Os AEs e meta-heurísticas são capazes de fornecer uma gama de soluções em uma única simulação, o que traz variedade e poder de escolha para o tomador de decisão. Além disso, devido ao extenso espaço de busca de alguns problemas, evita-se o uso dos algoritmos clássicos de PO, já que os AEs e meta-heurísticas conseguem obter boas soluções sem explorar completamente o espaço de busca, otimizando desta forma o processo de busca. Portanto, nesta seção serão introduzidos os conceitos utilizados em otimização multiobjetivo, uma explicação geral sobre as metaheurísticas e sobre algoritmos classicamente utilizados para resolução de problemas multiobjetivo. Além disso, esta seção também traz uma breve explicação sobre Programação Matemática e Programação Linear, que será uma ferramenta utilizada em conjunto com o algoritmo multiobjetivo. Por fim, os algoritmos utilizados no presente trabalho serão apresentados em maiores detalhes. Ressalta-se que os conceitos apresentados sobre otimização foram elaborados baseando-se em [54], onde o leitor pode se aprofundar no assunto.

#### 3.1 Mono objetivo x Multiobjetivo

Em problemas de otimização, o objetivo é maximizar ou minimizar uma função ou conjunto de funções matemáticas, as quais representam o problema em estudo. No caso de otimização de um problema mono objetivo, deseja-se minimizar ou maximizar uma única função, que contém as variáveis que representam o problema. Ao otimizar-se a referida função deseja-se obter uma configuração de variáveis que atendem ao objetivo do problema. Considerando um problema de minimização, um problema de otimização mono objetivo possui a seguinte estrutura:

$$\min f(x) \tag{3.1}$$

Sujeito a

$$g(x) = [g_1(x), g_2(x), ..., g_m(x)]^T \le 0$$
(3.2)

$$h(x) = [h_1(x), h_2(x), ..., h_p(x)]^T = 0$$
(3.3)

$$x = [x_1, x_2, ..., x_n]^T \in X \tag{3.4}$$

em que:

x: vetor das variáveis de decisão de dimensão n;

f(x): função objetivo;

g(x): conjunto de restrições de desigualdade de dimensão m;

h(x): conjunto de restrições de igualdade de dimensão p;

No caso de problemas com múltiplos objetivos a serem otimizados, deseja-se minimizar ou maximizar mais de uma função. Estas funções normalmente são conflitantes entre si, ou seja, a medida que se otimiza uma função, outra função é penalizada. A título de exemplo, ao se analisar o custo de um carro, observa-se que quanto mais potente, mais alto é o custo. Neste caso, para se ter mais qualidade em termos de potência, é necessário despender de um maior investimento. Assim como um carro menos potente será mais barato. Temos portanto, dois objetivos conflitantes: o investimento e a qualidade. Se o objetivo é obter um carro potente, será necessário um maior investimento. Caso o objetivo seja obter apenas um carro de baixo custo, o investimento será menor, mas com um carro menos potente. No contexto do sistema elétrico, para melhoria dos indicadores de qualidade do serviço, por exemplo, é necessário que haja investimentos por parte das concessionárias. A medida que há investimentos, espera-se que haja melhoria dos indicadores de qualidade, significando incremento na qualidade do serviço, e quanto menos investimentos houver, também é de se esperar que a qualidade do serviço não melhore e, portanto, os indicadores piorem.

Mais precisamente, problemas de otimização multiobjetivo são aqueles onde o objetivo é otimizar, simultaneamente, um conjunto de funções. Isto pode envolver a minimização ou maximização de todas as funções, assim como pode envolver minimizar algumas funções e maximizar outras. A formulação matemática da otimização multiobjetivo é uma extensão da formulação apresentada para otimização mono objetivo, na qual havia apenas uma função a ser otimizada. Como na otimização multiobjetivo há um conjunto de funções a serem otimizadas, haverá também um conjunto de soluções, ao invés de apenas uma solução. Estas soluções são encontradas de acordo com a teoria de otimalidade de Pareto (vide seção 3.2). Considerando um problema de minimização, um problema de

otimização multiobjetivo possui a seguinte estrutura:

$$\min z = f(x) = [f_1(x), f_2(x), ..., f_k(x)]^T$$
(3.5)

Sujeito a

$$g(x) = [g_1(x), g_2(x), ..., g_m(x)]^T \le 0$$
(3.6)

$$h(x) = [h_1(x), h_2(x), ..., h_p(x)]^T = 0$$
(3.7)

$$x = [x_1, x_2, ..., x_n]^T \in X$$
 (3.8)

$$z = [z_1, z_1, ..., z_k]^T \in Z$$
 (3.9)

em que:

x: vetor das variáveis de decisão de dimensão n;

z, f(x): vetor das funções objetivo de dimensão k;

g(x): conjunto de restrições de desigualdade de dimensão m;

h(x): conjunto de restrições de igualde de dimensão p;

Observe que as equações 3.6 e 3.7 representam as restrições que precisam ser satisfeitas durante o processo de otimização (minimização ou maximização) de f(x). X contém todos os possíveis x que podem ser usados para satisfazer a avaliação de f(x) e suas restrições, onde x pode ser um vetor com variáveis contínuas ou discretas, bem como f(x) pode ser uma função contínua ou discreta. O espaço Z = f(x) é o conjunto imagem de X.

A Figura 1 resume os processos de otimização mono e multiobjetivo. Observa-se que a estrutura da otimização multiobjetivo é mais complexa que a otimização mono objetivo, contudo, isto confere ao tomador de decisão maior possibilidade na tomada de decisão no processo de otimização. O bloco de tomada de decisão é o que representa essa intervenção do agente decisor. Esta intervenção poder ser efetuada em diferentes fases do processo de otimização: inicialmente no modelo matemático, durante o processo de otimização ou após o processo de otimização, quando o método já determinou o conjunto de soluções ótimas para o problema.

Otimização Mono-objetivo Otimização Multiobjetivo Modelo matemático Modelo matemático  $\min \mathbf{f}(\mathbf{x}) = \left[ f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_k(\mathbf{x}) \right]^T$ Sujeito a  $\min f(\mathbf{x})$  $\mathbf{g}(\mathbf{x}) = \left[g_1(\mathbf{x}), g_2(\mathbf{x}), \dots, g_m(\mathbf{x})\right]^T \le \mathbf{0}$ Sujeito a  $\mathbf{h}(\mathbf{x}) = \begin{bmatrix} h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_p(\mathbf{x}) \end{bmatrix}^T = \mathbf{0}$  $\mathbf{g}(\mathbf{x}) = [g_1(\mathbf{x}), g_2(\mathbf{x}), ..., g_m(\mathbf{x})]^T \le 0$  $\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in \mathbf{X}$  $\mathbf{h}(\mathbf{x}) = \left[h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_p(\mathbf{x})\right]^T = 0$  $\mathbf{z} = \begin{bmatrix} z_1, z_2, \dots, z_k \end{bmatrix}^T \in \mathbf{Z}$  $\mathbf{x} = \left[x_1, x_2, \dots, x_n\right]^T \in \mathbf{X}$ Tomada de decisão Método de otimização Método de otimização Conjunto de soluções ótimas Solução ótima Solução final

Figura 1 – Estrutura básica da otimização mono e multiobjetivo

Fonte: [55]

#### 3.1.1 Variáveis de decisão

As variáveis de decisão representam uma possível configuração, a partir da qual estima-se o valor da função objetivo. No exemplo do carro, o seu custo pode ser dado em função, por exemplo, da potência, ano de fabricação e quilômetros rodados. Ao variar-se estes parâmetros, teremos diferentes custos associados. De forma generalizada, as variáveis de decisão são representadas como  $x_j$ , j=1,2...n.

O vetor de n variáveis de decisão é representado conforme 3.10.

$$x = [x_1, x_2, ..., x_n]^T (3.10)$$

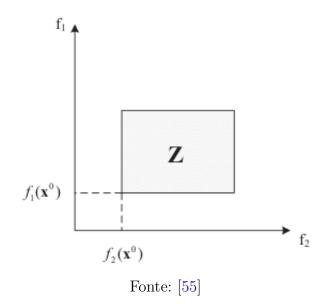
#### 3.1.2 Vetor ideal

O vetor  $x^0$  é dito ideal se e somente se:

$$x^{0} = min\{f_{j}(x) : x \in X\}, j = 1, 2, ..., k$$
(3.11)

O vetor ideal é aquele que permite que cada função objetivo k atinja seu valor ótimo, como mostrado na Figura 2, para k=2.

Figura 2 – Representação do vetor ideal para k=2.



#### 3.2 Eficiência de Pareto

O conceito de eficiência ou ótimo de pareto foi desenvolvido pelo economista italiano Valfredo Pareto. Tal teoria define que para dado estado de alocação de recursos, é impossível realocá-los de forma a melhorar a situação de um participante sem prejudicar a situação individual de outros participantes [56]. Os conceitos desenvolvidos por Pareto têm aplicações no campo da economia, informática, engenharia e ciências sociais. Nesta seção serão apresentadas algumas definições aplicadas à otimização multiobjeitivo.

Quando se deseja otimizar mais de uma função, o conceito de otimalidade muda, tendo em vista que não há apenas um objetivo, mas sim, um conjunto de objetivos representados em cada função. Portanto, o que que passa a ser estudado é o *trade-off* entre as funções, para dado conjunto de soluções. A seguir tem-se as seguinites definições utilizadas em otimização multiobjetivo.

#### 3.2.1 Definição 1 (Dominância de Pareto):

Dadas duas soluções  $\mathbf{x}, \mathbf{y} \in \mathbf{X}$ . Diz-se que  $\mathbf{x}$  domina  $\mathbf{y}$  se e somente se  $\mathbf{f}(\mathbf{x})$  é melhor que  $\mathbf{f}(\mathbf{y})$  em pelo menos um objetivo e não é pior em nenhum objetivo. A Figura 3 ilustra este conceito. Observando-se as soluções B e C, vê-se que  $f_2(B) < f_2(C)$  e  $f_1(B) < f_1(C)$ . A mesma conclusão é alcançada quando se compara as soluções A e C. Diz-se que C é uma solução dominada, pois ela não é melhor em nenhum objetivo, quando comparada com A ou B. No entanto, ao comparar-se as soluções A e B, observa-se que  $f_2(A) < f_2(B)$ , mas  $f_1(A) > f_1(B)$ . Neste caso, diz-se que as as soluções A e B são soluções não dominadas, as quais constituem a Frente de Pareto, isto é, o conjunto de soluções que não se dominam entre si e não são dominadas por outras soluções.

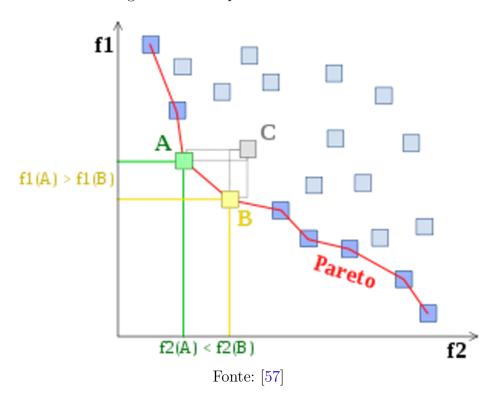


Figura 3 – Exemplo de frente de Pareto

#### 3.2.2 Definição 2 (Otimalidade de Pareto):

Um ponto  $\mathbf{x} \in \mathbf{X}$  é dito ótimo de Pareto se e somente se não existe outro ponto  $\mathbf{x}$ ' para o qual  $\mathbf{f}(\mathbf{x}')$  domine  $\mathbf{f}(\mathbf{x})$ . Em palavras, esta definição significa que o ponto  $\mathbf{x}$  é um ótimo de Pareto se não existe outra possível solução que reduza algum dos objetivos sem causar o aumento simultâneo de pelo menos um dos outros objetivos.

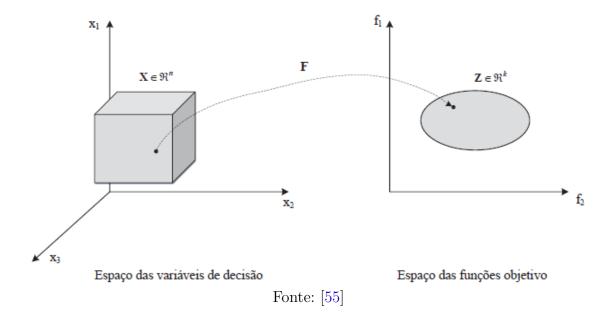
#### 3.2.3 Definição 3 (Conjunto ótimo de Pareto):

É o conjunto com todas as soluções não dominadas para dado problema de otimização. Este é um subconjunto de todas as soluções possíveis para o problema.

#### 3.2.4 Definição 4 (Fronteira de Pareto):

É a imagem do conjunto de soluções de Pareto no espaço das funções objetivo. Enquanto os problemas de otimização mono objetivo podem ter uma única solução ótima, problemas multiobjetivo normalmente apresentam muitas soluções na Frente de Pareto. Cada ponto da Frente ( $\mathbf{x} = x_1, x_2, ...x_n$ ) está associado a um vetor ( $\mathbf{y} = y_1, y_2, ...y_k$ ) que contém as variáveis de decisão. A figura 4 ilustra esses conceitos para  $\mathbf{n} = 3$ ,  $\mathbf{k} = 2$  e  $F: X \to Z$ .

Figura 4 – Mapeamento das variáveis de decisão no espaço das funções objetivo.



#### 3.3 Programação matemática

A modelagem matemática trata de problemas de decisão e faz uso de modelos matemáticos que procuram representar um problema. As variáveis são definidas e a relação matemática entre essas variáveis são estabelecidas de forma a descrever o comportamento do sistema [58].

Existem diversos algoritmos de programação matemática para resolver um problema de otimização, que são definidos de acordo com as características da função objetivo e das restrições. Assim, os problemas de otimização podem se dividir de diferentes formas, como por exemplo Programação Linear (PL), Programação Quadrática (PQ) e Programação

Não Linear (PNL). Algoritmos de otimização para problema de PL e PQ têm solução em um número finito de passos, já os algoritmos de PNL podem não ter solução em um número finito de passos, mas espera-se que a sequência gerada convirja (no limite) para um mínimo local. Portanto, um problema adicional no processo de otimização ocorre quando a função objetivo e as restrições são funções não lineares do vetor de variáveis.

Esta seção tem como objetivo apresentar os principais métodos matemáticos, tais métodos incluem Programação Linear Inteira (PLI) e Programação Linear Inteira Mista (PLIM).

#### 3.3.1 Programação linear inteira e programação linear inteira mista

Problemas de PLI possuem variáveis de decisão que assumem valores inteiros. Quando todas as variáveis de decisão são números inteiros, denomina-se Programação Linear Inteira Pura (PLIP). Em caso de apenas parte das variáveis de decisão estarem restritas a valores inteiros e outra parte corresponde a variáveis não inteiras (temperatura, peso, medida, distância), é considerado problema de PLIM. Destaca-se que muitos modelos práticos de PLI restringem algumas das variáveis inteiras para valores binários. Utilizando "0" como variável de decisão "não" e "1" para "sim". Neste caso, tem-se um problema de Programação Linear Inteira Binária (PLIB).

A PLI é utilizada quando há necessidade de resultados inteiros baseados em parâmetros integrais de decisão. Ou seja, os métodos tradicionais de PL não levam em conta restrições de integralidade (valores inteiros), havendo a necessidade de métodos que produzam respostas compatíveis com restrições desse tipo.

A PLIM é utilizada em problemas de programação de produção, pois os modelos matemáticos de otimização correspondentes envolvem variáveis contínuas e discretas que devem satisfazer um conjunto de restrições lineares de igualdade e desigualdade [59]. Os modelos baseados na PLIM têm solução mais complexa em relação àqueles que utilizam a PL. No caso da PL existem condições necessárias e suficientes de otimização que podem ser utilizadas para testar, de forma eficiente, se uma dada solução viável é uma solução ótima ou não. Estas condições têm sido utilizadas para desenvolver métodos algébricos, tais como o simplex [60] e método dos pontos interiores [61].

Para a PLI não existem condições de otimização conhecidas para testar se uma dada solução viável é ótima a não ser através da comparação explícita ou implícita desta solução com cada uma das soluções viáveis do problema. Assim, este método é resolvido por intermédio de métodos que buscam soluções ótimas no conjunto de soluções viáveis. O problema de PLI pode ser descrito conforme a Equação 3.12, a qual busca maximizar ou minimizar a função objetivo através de variáveis de decisão inteiras:

$$\max(ou\min)Z = \sum_{j \in N} c_j x_j, N = 1, ..., n$$
(3.12)

Sujeito a:

$$\sum_{i \in N} a_{ij} x_j \le b_i, i \in M = 1, ..., m \tag{3.13}$$

$$x_j \ge 0, j \in N \tag{3.14}$$

$$x_j inteira, j \in I \subseteq N$$
 (3.15)

Em que,  $c_j$ ,  $a_{ij}$  e  $b_i$  são constantes conhecidas para todo i e j, e  $x_j$  são variáveis não negativas. Para  $j \in I \subseteq N$ , o problema é de PLIM, pois desta forma nem todas as variáveis são inteiras.

A resolução para problemas de otimização linear inteira mista, entendida como a obtenção de uma solução ótima, pode ser difícil, pela sua natureza combinatória. Considerase que o espaço de soluções inteiras é constituído de um número finito de pontos. Na forma mais simples, os métodos de enumeração analisam todos os pontos possíveis, podendo ser adaptado para um modelo mais eficiente que analisa apenas parte das soluções candidatas, enquanto descarta pontos que não são promissores. A eficiência de um algoritmo de busca depende de sua capacidade em descartar pontos de solução não promissores. Dentre estas técnicas podem ser citadas: *Branch-and-Bound* (B&B) [62], Decomposição de Benders (DB) [63], [64] e enumeração implícita ou explícita (EI) [65]. Essas técnicas de otimização combinatória podem utilizar uma relaxação do problema para obter em tempo razoável uma estimativa para o valor da melhor solução que pode ser encontrada em cada ramo da enumeração.

A solução por enumeração explícita consiste em gerar e avaliar todas as soluções admissíveis. A enumeração implícita não gera todas as soluções admissíveis, porém elas são consideradas e implicitamente avaliadas.

Apesar de problemas de PLIM serem geralmente díficeis de resolver, a literatura da área avançou significativamente [66], tornando possível a resolução de problemas cada vez maiores quando comparado aos de outra natureza (p.e. problemas não lineares). A aplicação prática de um modelo PLIM possui baixo custo de implementação por meio de pacotes de software (ou solvers) disponíveis, como: IBM CPLEX [67], Gurobi [68] e COIN-Cbc [69]. Nestes pacotes é necessário descrever o modelo (variáveis de decisão, restrições e função objetivo) através de uma API fornecida e, em seguida, recuperar a solução ótima que o solver encontrou (se o tempo necessário foi dado). Estes solvers implementam técnicas avançadas de PLIM, tendo como base um algoritmo chamado de

branch-and-cut que combina duas das principais técnicas da área: branch-and-bound e cutting planes.

O branch-and-bound é um algoritmo exato que explora uma árvore de subproblemas gerada a partir da adição de restrições (branch) no modelo original (nó raiz da árvore) para separar o espaço de busca. Quando um nó da árvore comprovadamente não pode levar a solução ótima, sua expansão é proibida (bound), conforme ilustra a Figura 5. Este método faz uso da informação obtida após resolver a relaxação linear de cada subproblema (versão do subproblema onde variáveis inteiras são transformadas em variáveis reais) para gerar novos subproblemas (branch step) ou evitar a exploração de nós que não podem levar a solução ótima (bound step). Durante a execução, o branch-and-bound mantém atualizado um lower bound (LB) e um upper bound (UB), que garantem que a solução ótima não possui um valor menor que LB e maior que UB. Uma vez que LB=UB, pode-se concluir que a solução ótima foi encontrada. Para acelerar a aproximação entre LB e UB, essa técnica depende muito que a relaxação linear seja forte, ou seja, produza uma solução de valor próximo ao valor da solução do modelo não relaxado. Dessa forma, foi descoberto que a adição de desigualdades válidas (cut qeneration) durante o branch-and-bound (chamado branch-and-cut), ou seja, uso de restrições adicionais que servem apenas para fortalecer a relaxação linear dos subproblemas, pode acelerar consideravelmente o procedimento. A Figura 5 ilustra uma execução do algoritmo para um dado problema de otimização.

Z=39  $x_{j}=1.86$   $x_{2}=0$ Z=37.5  $x_{j}=1$   $x_{j}=1$ Impossível  $x_{j}=1$   $x_{j}=$ 

Fonte: [70]

Figura 5 – Árvore Branch-and-Bound.

#### 3.4 Visão geral de algoritmos de otimização multiobjetivo

Existem muitas metodologias utilizadas para resolução de problemas multiobjetivo. Nesta seção será feita uma apresentação básica de algoritmos classicamente utilizados e de algoritmos metaheurísticos. Além disso, os métodos utilizados neste trabalho serão apresentados em detalhes.

#### 3.4.1 Classificação dos métodos

Existems diferentes maneiras de se classificar os algoritmos multiobjetivos. A classificação apresentada neste trabalho se dá em relação à tomada de decisão, que é uma das etapas no processo de otimização multiobjetivo. Esta classificação é uma das mais populares na comunidade de PO [71]. Além disso, esta classificação vai de encontro à metodologia apresentada neste trabalho. Outros exemplos de classificação podem ser observados em [72]. De acordo com [71], os métodos podem ser classificados em três categorias:

#### • Métodos a priori

São caracterizados pela tomada de decisão antes de se iniciar o processo de busca. Nesta categoria o tomador de decisão pode atribuir elementos de preferência para os objetivos, aplicando pesos diferentes para cada objetivo, por exemplo. A vantagem desses métodos é que eles concentram os esforços computacionais na busca por soluções com base nas considerações feitas pelo tomador de decisão antes do processo de busca. Entretanto, novas execuções são necessárias caso seja necessária a inclusão de algum aspecto não considerado, ou caso a preferência por algum objetivo mude.

- Métodos a posteriori Nestes métodos a tomada de decisão é feita após o processo de busca. Nesta classe não há priorização de nenhum objetivo e ao final tem-se um conjunto ótimo de Pareto ou uma aproximação deste. Nesta categoria encaixam-se um grande número de algoritmos. Os algoritmos utilizados neste trabalho encaixam-se nesta categoria.
- Métodos interativos Os métodos desta categoria mesclam o processo de busca com a tomada de decisão, ou seja, a tomada de decisão é feita durante o processo de busca. A intervenção é feita pelo tomador de decisão de forma a nortear a busca das soluções de interesse. Os algoritmos categorizados como interativos integram as duas categorias citadas anteriormente, contudo, é necessária a intervenção humana, o que pode ser inapropriado para problemas de maior complexidade.

## 3.4.2 Algoritmos clássicos

Os algoritmos clássicos para otimização multiobjetivo transformam um problema multiobjetivo em um problema mono objetivo agregando os diversos objetivos em uma única função, atribuindo pesos diferentes para cada função. Estes parâmetros, no entanto, não são estabelecidos pelo tomador de decisão, mas são sistematicamente variados pelo algoritmo. Diversas simulações são realizadas e, para cada simulação, tem-se diferentes parâmetros para cada função. O objetivo é obter o conjunto ótimo de Pareto, ou uma aproximação deste [73]. Dentre as técnicas existentes, cita-se: método da soma ponderada, método  $\epsilon$  - restrito e método de programação por metas. A seguir dois destes algoritmos são apresentados como exemplo.

### • Método da Soma ponderada

Neste método o problema original de múltiplos objetivos é convertido em um problema de objetivo único, por meio da combinação linear dos objetivos, conforme mostra a equação 3.16 (para um problema de minimização).

$$\min f(\vec{x}) = \sum_{i=1}^{n} w_i \cdot f_i(\vec{x}) \tag{3.16}$$

Sujeito a:

$$\vec{x} \in X \tag{3.17}$$

onde  $w_i$  são os pesos de cada objetivo, os quais são normalizados de forma que  $\sum w_i = 1$ . Resolvendo um problema de otimização para diferentes pesos obtém-se um conjunto de soluções [73].

A principal desvantagem deste método é que não é possível gerar todas as soluções Pareto-ótimas em problemas com espaços de objetivos não convexos.

#### • Método $\epsilon$ - restrito

Esta metodologia transforma as n-1 funções em restrições, sendo n o número de funções objetivo. A função restante é a função objetivo, que pode ser escolhida arbitrariamente [73]. A formulação é mostrada a seguir (para um problema de minimização):

$$\min f_1(\vec{x}) \tag{3.18}$$

Sujeito a:

$$f_i(\vec{x}) \le \epsilon_i, i = 2, 3, ..., n$$
 (3.19)

$$\vec{x} \in X \tag{3.20}$$

em que  $\epsilon_i$  representa os limitantes superiores para cada função considerada como restrição.

## 3.4.3 Considerações sobre os algoritmos clássicos

O que torna as metodologias clássicas atrativas é o fato de que existem algoritmos bem desenvolvidos para resolução de problemas mono objetivo [73]. Estas metodologias transformam o problema multiobjetivo em um problema mono objetivo. No entanto, é necessário realizar diversas simulações, variando-se os parâmetros para obtenção de um conjunto de Pareto. Além disso, a distribuição uniforme dos parâmetros não garante a diversidade das soluções eficientes encontradas [74]. Neste caso, em problemas de otimização mono objetivo existem algoritmos metaheurísticos que lidam bem com esta complexidade dos parâmetros, por exemplo, algoritmos de busca randômica, algoritmos de busca local estocásticos, recozimento simulado, pesquisa tabu, dentre outros [73]. Ainda pode-se dizer que os métodos clássicos podem ser sensíveis ao formato da Frente de Pareto. Também pode ser necessário conhecimento prévio do problema em estudo, que pode ser desconhecido ou não estar disponível.

Recentemente AE e meta-heurísticas têm se apresentado como alternativa aos métodos clássicos. Como vantagens pode-se destacar que AEs e meta-heurísticas lidam bem com grandes espaços de busca e são capazes de produzir um conjunto de Pareto em uma única simulação. Além disso, não há restrições quanto à linearidade das funções objetivo, tendo em vista que boa parte dos algoritmos clássicos precisam linearizar as funções objetivo para resolver o problema.

#### 3.4.4 Técnicas meta-heurísticas

Esta seção traz uma visão geral sobre as técnicas meta-heurísticas. A partir de algumas dessas técnicas, que inicialmente foram desenvolvidas para tratar problemas mono objetivo, foram desenvolvidos algoritmos para resolução de problemas multiobjetivo. Para um estudo mais aprofundado sugere-se a leitura de [54],[75].

O termo metaheurística deriva de duas palavras: Heurística, que significa 'encontrar' e meta, que significa 'além' ou 'em um nível acima'. A área que estuda as metaheurísticas é um subcampo da área de otimização estocástica, que por sua vez, representa uma classe de algoritmos que empregam variáveis aleatórias para encontrar soluções tão ótimas quanto possível para problemas reconhecidamente difíceis [75].

As meta-heurísticas são métodos que coordenam processos de busca com objetivo de explorar de forma eficiente o domínio de busca, sem ter que explorar o domínio por completo e com mecanismos com potencial para superar mínimos locais. Os algoritmos meta-heurísticos se assemelham por possuírem as seguintes características:

- Muitos são baseados em aspectos observados na natureza (conceitos físicos, biológicos ou ecológicos
- Utilizam parâmetros estocásticos (variáveis aleatórias)
- Possuem parâmetros que necessitam ser especificados para o problema em questão (normalmente definidos por tentativa e erro).

Devido à complexidade dos problemas combinatoriais, diversos algoritmos metaheurísticos e clássicos vêm sendo desenvolvidos ao longo dos anos. Esses algoritmos são categorizados como completos ou aproximados. Os algoritmos completos fornecem uma solução ótima global, mas com um elevado custo computacional. Os algoritmos aproximados, no entanto, são capazes de garantir boas soluções com menor custo computacional, mas sem garantir otimalidade da solução [76].

Normalmente as meta-heurísticas são aplicadas em problemas sobre os quais há poucas informações. Não se sabe o que caracteriza uma solução ótima para este tipo de problema e/ou é inviável a exploração de todas as soluções devido ao espaço de busca ser muito grande. Porém, dada uma solução para o problema, esta pode ser analisada e testada quanto à sua aplicabilidade ao problema em estudo. A seguir, são apresentados alguns exemplos de técnicas populares na literatura.

• Otimização por enxame de partículas (PSO)

O algoritmo de otimização por enxame de partículas foi proposto em 1995 [77], [78]. Desde então tem sido amplamente utilizado para resolução de problemas de otimização e muitas variantes do algoritmo têm sido propostas a fim de melhorá-lo. O termo enxame é generalizado para representar um conjunto de indivíduos ou partículas, como um bando de pássaros, por exemplo. Cada partícula é inicializada com uma posição  $(x_i)$ , que representa uma possível solução para o problema em estudo, e uma velocidade  $(v_i)$ . Cada partícula também tem uma melhor posição  $(x_{ib})$ , representando a melhor solução encontrada pela referida partícula. Além disso, há uma melhor posição global  $(x_{gb})$ , que representa a melhor solução encontrada dentre as soluções de todas as partículas. A cada iteração a posição das partículas é atualizada, movimentando as partículas dentro espaço de busca. Ao final do processo iterativo o algoritmo retorna a melhor solução encontrada.

### • Algoritmos genéticos (GA)

Os algoritmos genéticos são uma classe particular de AEs que se baseiam em conceitos da biologia evolutiva, como hereditariedade, mutação, seleção natural e recombinação. São bastante populares e foram desenvolvidos por John Holland entre as décadas de de 1960 e 1970 [79]. Assim como o PSO, esta classe de algoritmos também possui uma população de indivíduos, que a partir dos conceitos de biologia evolutiva, sofrem mutação e se recombinam ao longo do processo iterativo, com o objetivo de obter soluções cada vez melhores.

### • Recozimento simulado

É um algoritmo de busca local, que evita mínimos locais, baseado no processo de aquecimento e resfriamento de metais (annealing), que consiste em aquecer um metal até o ponto de fusão e então resfriá-lo, lentamente, permitindo que as moléculas alcancem uma configuração de baixa energia e formem uma estrutura cristalina livre de defeitos [80]. É bastante utilizado quando o espaço de busca é discreto.

#### • Busca tabu

Tabu Search é um método de busca local que utiliza o conceito de tabu para tentar encontrar a melhor solução para uma função objetivo. Foi proposto por Fred Glover em 1989 [81]. O método mantém uma lista de soluções candidatas visitadas recentemente (lista tabu) e se recusa a visitar estas soluções até que um determinado tempo passe. Quando um máximo (ou mínimo) é encontrado, força-se uma busca para um ponto distante do corrente, pois não é permitida a permanência ou retorno para o máximo (ou mínimo). Isto faz com que uma área mais abrangente do espaço de busca seja visitada.

#### • Otimização por colônia de formigas

Esta técnica foi proposta por Marco Dorigo em 1992 em sua tese de doutorado [82], e baseia-se no comportamento das formigas, que saem em busca de comida e retornam ao formigueiro ao encontrar uma fonte de alimento. As formigas inicialmente buscam aleatoriamente por comida, ao encontrarem, retornam ao formigueiro deixando um rastro de feromônio, que serve para que as outras formigas sigam o caminho e cheguem ao alimento. Desta maneira, ao longo do tempo as formigas conseguem encontrar o caminho mais curto entre a comida e o formigueiro. Este algoritmo é indicado para problemas de roteamento e transporte urbano.

## 3.5 Métodos implementados

Nesta seção serão apresentados os dois algoritmos utilizados no trabalho. Estes algoritmos foram comparados a fim de observar qual obteve melhor desempenho para resolução do problema proposto. Além disso, para o algoritmo que apresentou melhor

desempenho, foi feito um acréscimo em sua formulação original com o objetivo de obter melhores resultados no processo de construção da frente de Pareto. Este acréscimo também será detalhado nesta seção.

### 3.5.1 Método NSGA-II

O método NSGA-II é um algoritmo genético proposto por Kalyanmoy Deb et al. [83]. A novidade que este algoritmo traz é a capacidade de lidar com problemas multiobjetivo a partir dos conceitos de dominância de Pareto. Assim como nos algoritmos genéticos, o NSGA-II possui uma população que evolui ao longo do processo iterativo, baseando-se nos conceitos de biologia evolutiva. O algoritmo funciona basicamente a partir de três mecanismos:

- O elitismo, que garante a propagação de boas soluções ao longo do processo de busca;
- O processo de *Fast Nondominated Sorting* (FNS), a partir do qual a população é organizada em diferentes frentes de Pareto;
- O processo de *Crowding Distance* (CDA), que promove diversidade nas soluções.

Uma população inicial, com N indivíduos, é gerada aleatoriamente com base nas restrições e no domínio do problema. Em seguida, inicia-se o processo FNS. Neste processo, para cada indivíduo p são atribuídos um contador np, que registra quantas soluções dominam p, e um conjunto Sp, que registra quantas soluções são dominadas por p. Este procedimento é executado para todos os indivíduos da população. Ao fim deste processo, as soluções são classificadas segundo a dominância, isto é, todos os indivíduos que possuem o contador np=0 não são dominados por nenhuma solução, e recebem um índice de classificação rank=1. Este procedimento é repetido até que todas as soluções sejam organizadas em diferentes frentes (rank=1,2,...,k). As soluções que possuem o mesmo valor do índice de classificação rank ficam na mesma frente.

Uma vez que o processo FNS é findado, o mecanismo CDA é responsável por classificar as soluções de uma mesma frente buscando obter diversidade. Este processo avalia a densidade de soluções em torno de cada solução de uma frente. Para dada solução p de uma mesma frente, calcula-se a distância média (distance) entre p e as soluções adjacentes, ao longo de cada função objetivo. Para as soluções localizadas nos extremos da frente atribui-se um valor de distância infinito. As soluções que possuem maiores valores de distância são soluções que estão em regiões com menor concentração de soluções, analogamente, as soluções com menores distâncias calculadas são soluções que estão em regiões com maior densidade de soluções. Assim, o algoritmo prioriza aquelas soluções com maiores valores de distance, com o objetivo de diversificar as frentes ao longo do processo iterativo. Este procedimento é realizado para todas as frentes geradas no processo FNS.

Após a classificação das soluções segundo os processos FNS e CDA, inicia-se o processo de seleção, através do operador *Crowded-Comparison Operator*, que compara duas soluções, priorizando aquelas com menor rank e, caso possuam o mesmo rank, escolhe-se aquela que possui maior valor de *distance*. Desta forma, garente-se o elitismo, isto é, as melhores soluções são priorizadas para geração de novas soluções. No processo de seleção uma parte das soluções é escolhida para gerar as novas a partir dos operadores genéticos.

De forma resumida, o funcionamento do NSGA-II consiste em gerar uma população inicial  $P_t$  de dimensão N. A partir dos operadores genéticos gera-se uma nova população  $Q_t$  também de dimensão N. Essas populações são combinadas gerando um conjunto  $R_t$  com  $2 \times N$  indivíduos. O conjunto  $R_t$  é então classificado segundo os métodos FNS e CDA. A próxima população  $P_{t+1}$  começa com os N indivíduos com menores índices de dominância (rank), os demais N indivíduos do conjunto  $R_t$  são descartados. Este procedimento está ilustrado na figura 6.

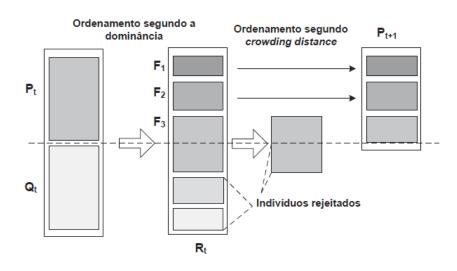


Figura 6 – Procedimento do método NSGA-II.

Fonte: [55]

Definida a nova população  $P_{t+1}$ , por meio dos operadores genéticos de seleção, recombinação e mutação gera-se uma nova população  $Q_{t+1}$ . Este processo é repetido até que o critério de parada seja satisfeito. O fluxograma do algoritmo pode ser observado na figura 7.

INÍCIO Parâmetros de entrada: dimensão da população (Npop), taxa de recombinação, taxa de mutação e critério de parada Gerar aleatoriamente a população inicial P<sub>0</sub> e calcular as funções objetivo de cada indivíduo. - Aplicar a Po os mecanismos FNS e CDA Gerar Q<sub>0</sub> a partir de P<sub>0</sub> por meio dos operadores genéticos de seleção, recombinação e mutação. Imprimir o Sim conjunto ótimo de O critério de parada foi satisfeito? Pareto. Não Calcular as funções objetivo para cada indivíduo de Q<sub>t</sub> Combinar P<sub>i</sub> e Q<sub>i</sub> para formar a população R<sub>i</sub> (dimensão 2xNpop) FIM Aplicar a R<sub>t</sub> os mecanismos FNS e CDA.  $(NP_{t+1} + NF_t) \le Npop$ Sim Acrescentar os indivíduos de F<sub>i</sub> em P<sub>t+1</sub>.  $NP_{t+1} = NP_{t+1} + NF_t$ i = i + 1Sim  $NP_{t+1} < Npop$  Adicionar a P<sub>t+1</sub> os (Npop – NP<sub>t+1</sub>) indivíduos Não de F, com maior valor do índice distance. Gerar  $Q_{t+1}$  a partir de  $P_{t+1}$  por meio dos operadores genéticos de seleção, recombinação e mutação.

Fonte: [55]

Figura 7 – Fluxograma do método NSGA-II.

## 3.5.2 Algoritmo de otimização por enxame de partículas (MOPSO)

O MOPSO é uma extensão do PSO, que é utilizado para resolução de problemas mono objetivo, o qual foi adaptado para tratar problemas multiobjetivo. O MOPSO foi proposto em 2002 por Carlos A. Coello [84]. Esta abordagem também baseia-se no conceito de população, mais especificamente um bando de pássaros. A novidade proposta é que o MOPSO considera um repositório, onde fica armazenado o conjunto de soluções não dominadas. Este conjunto têm a função de orientar o processo de busca para cada partícula do enxame. Enquanto que no PSO as partículas seguiam em direção à melhor solução, no MOPSO as partículas podem ser guiadas por diferentes soluções existentes no repositório, que podem ser escolhidas aleatoriamente ao longo do processo iterativo. Devido à analogia entre o PSO e os algoritmos evolutivos o uso do conceito de dominância de Pareto é uma forma de extrapolar o uso do enxame de partícula para a resolução de problemas multiobjetivo [85]. Ao fim do processo iterativo as soluções existentes no repositório compõem a frente de Pareto como resultado final.

A proposta de Coello tem como objetivo armazenar a experiência das partículas ao fim de cada iteração. Sempre que uma nova solução não dominada é encontrada, esta é acrescentada ao repositório de soluções e, a cada iteração, uma dessas soluções é escolhida (líder) para direcionar as partículas no processo de busca (Ressalta-se que existem diferentes métricas para escolher qual solução servirá de líder para guiar as partículas). De forma análoga, se após a atualização do repositório, alguma solução passa a ser dominada, esta é retirada do repositório. Neste trabalho, após experimentos com diferentes métricas na escolha do líder, aquela que apresentou melhor desempenho foi a escolha aleatória de uma das soluções existentes no repositório. Esta escolha é feita a cada iteração. Além disso, o tamanho do repositório utilizado neste trabalho é ilimitado. Em outras abordagens alguns autores utilizam o repositório com um tamanho fixo, o qual é composto por um número limitado de soluções. Idealmente, ao fim do processo iterativo a frente de Pareto seria constituída apenas por soluções ótimas (vetor ideal). No entanto, os algoritmos meta-heurísticos não garantem otimalidade das soluções.

Para fins de comparação e melhor entendimento do método, em 3.21 e 3.22 estão representadas, respectivamente, as equações de velocidade e posição da versão original do PSO. A equação de velocidade é responsável por representar o movimento da partícula i no espaço de busca e, a nova posição da partícula é atualizada a partir da equação 3.22. Observe que a movimentação da partícula é composta por três componentes: inércia, ótimo individual e ótimo global. Este mecanismo é melhor ilustrado na figura 8.

$$v_{t+1}^{(i)} = wv_t^i + c_1 r_1(p_t^i - x_t^i) + c_2 r_2(p_t^g - x_t^i)$$
(3.21)

$$x_{t+1}^{(i)} = x_t^i + v_{t+1}^{(i)} (3.22)$$

Onde:

w =Coeficiente de inércia;

 $v^i$  = Velocidade da partícula i no instante t;

 $p_t^i = \text{Melhor posição da partícula } i;$ 

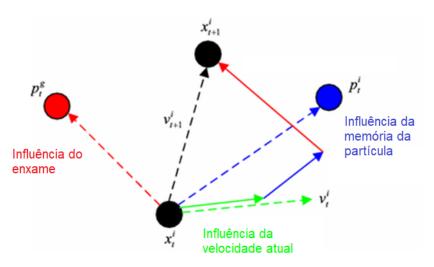
 $p_t^g = \text{Melhor posição de todo o enxame};$ 

 $x_t^i = \text{Posição da partícula } i \text{ no instante } t;$ 

 $r_1$  e  $r_2$  = Números aleatórios  $\in [0, 1]$ ;

 $c_1$  e  $c_2$  = Constantes de aceleração das partículas.

Figura 8 – Esquema de interação das partículas no PSO.



Fonte: Adaptado de [86]

Então, cada partícula movimenta-se em direção ao seu ótimo individual (memória da partícula), ótimo global (ótimo do enxame) e possui uma velocidade, que em conjunto com a inércia representa o movimento progressivo da partícula. O somatório dessas parcelas representa a nova posição da partícula. No MOPSO a diferença é que a partícula se desloca na direção da solução retirada do repositório, em vez de se deslocar em direção ao ótimo do enxame. Este conceito é intuitivo, pois não faz sentido considerar uma solução ótima em uma análise multiobjetiva, dado que existe um conjunto de soluções não dominadas. A equação 3.21 sofre uma leve modificação, assumindo a forma de 3.23. Analogamente à figura 8, a figura 9 ilustra o comportamento da partícula no MOPSO.

$$v_{t+1}^{(i)} = wv_t^i + c_1 r_1(p_t^i - x_t^i) + c_2 r_2 (REP_h - x_t^i)$$
(3.23)

REPh  $v_{t+1}^i$  Influência da memória da partícula  $x_t^i$  Influência da velocidade atual

Figura 9 – Esquema de interação das partículas no MOPSO.

Fonte: Adaptado de [86]

Tendo apresentado o funcionamento do MOPSO, o pseudocódigo usado para sua implementação de acordo com [84] é estruturado a seguir:

- 1. Inicialização da população: Vetor com a população POP[i] é inicializado
  - a) Para i = 0 até Max (tamanho máximo da população)
  - b) Inicializa POP[i]
- 2. Inicialização da velocidade: Cada indivíduo inicial em repouso, v=0, VEL[i]=0
  - a) Para i = 0 até Max
  - b) VEL [i] = 0
- 3. Avaliação de cada partícula no vetor POP, utilizando a função objetivo
- 4. Armazena as posições das partículas que são não dominadas no repositório REP
- Inicializa a memória de cada partícula (memória usada para guiar o indivíduo no espaço de busca)
  - a) Para i = 0 até Max
  - b) PBESTS[i] = POP[i]
- Loop principal: Enquanto número de iterações for menor que o máximo escolhido faça:
  - a) Calcula a velocidade de cada indivíduo pela expressão 3.23
  - b) Atualiza a posição de cada indivíduo a partir de 3.22

- c) Aplica limites superior e inferior para as posições das partículas, caso estas a partir da equação anterior extrapolem os limites do espaço de busca
- d) Avalia cada partícula da população usando a função objetivo
- e) Atualiza o conteúdo no repositório, removendo localizações dominadas e inserindo todas as soluções atuais não dominadas.
- f) Atualiza o valor de melhor posição de cada indivíduo, utilizando o critério de dominância de Pareto
- g) Incrementa o loop

### 7. Fim do Loop

Por fim, um fluxograma básico é apresentado na figura 10.

Inicialização Início (posição, velocidade) Atualiza Repositório Velocidade Atualiza Posição Avalia **Partículas** Nāo Atualiza Repositório Escolhe Líder Condição SIM Fim de término

Figura 10 – Fluxograma MOPSO.

Fonte: Adaptado de [87]

## 3.5.3 Algoritmo memético proposto - MOPSO modificado

Ao longo do processo iterativo do MOPSO a frente de Pareto é constantemente atualizada, até que seja atingido o critério de parada. Existem diferentes metodologias para estabelecer um critério de parada. Pode-se estabelecer, por exemplo, que se a fronteira de Pareto não sofrer nenhuma alteração durante vinte iterações, então o algoritmo deve parar. O objetivo é garantir que a fronteira de Pareto final seja a fronteira ótima, ou próxima da ótima. Ainda assim, não há garantia de que o conjunto final de soluções encontradas seja equivalente às soluções que compõem o conjunto ótimo de Pareto. Com o objetivo de acelerar a convergência da frente de Pareto, foi desenvolvido um algoritmo memético (ou híbrido) combinando o MOPSO com um modelo de programação linear inteira mista (PLIM). Para cada solução não dominada encontrada pelo MOPSO, o modelo matemático (PLIM) é responsável por refinar a referida solução. O refinamento é feito otimizando um dos objetivos e fixando os demais objetivos como restrição do problema. A figura 11 exemplifica este processo. A curva em azul seria o conjunto de soluções proposta pelo MOPSO. Em laranja, é ilustrada a curva otimizada com as soluções refinadas pelo modelo matemático. Esta figura é meramente ilustrativa. O processo de refinamento não é realizado após o término do processo iterativo e sim durante, ou seja, cada solução refinada é acrescentada ao repositório do MOPSO. Essas soluções são posteriormente utilizadas para guiar o processo iterativo na busca por novas soluções não dominadas.

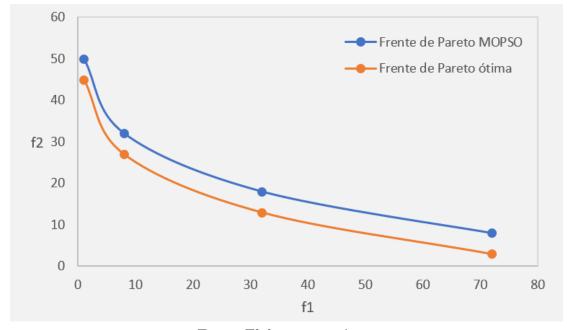


Figura 11 – Exemplo de otimização da frente de Pareto

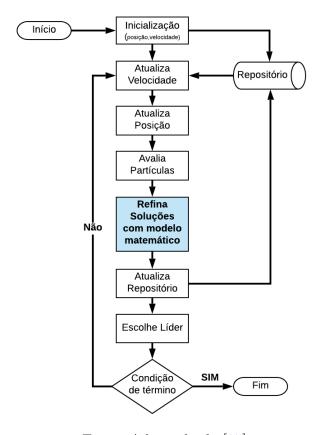
Fonte: Elaboração própria

O pseudocódigo do algoritmo original sofre uma pequena modificação na etapa 6, apresentada a seguir:

- Loop principal: Enquanto o número de iterações for menor que o máximo escolhido faça:
  - a) Calcula a velocidade de cada indivíduo pela expressão 3.23
  - b) Atualiza a posição de cada indivíduo a partir de 3.22
  - c) Aplica limites superior e inferior para as posições das partículas, caso estas a partir da equação anterior extrapolem os limites do espaço de busca
  - d) Avalia cada partícula da população usando a função objetivo
  - e) Refina a solução de cada partícula com o modelo matemático
  - f) Atualiza o conteúdo no repositório, removendo localizações dominadas e inserindo todas as soluções atuais não dominadas.
  - g) Atualiza o valor de melhor posição de cada indivíduo, utilizando o critério de dominância de Pareto
  - h) Incrementa o loop

A figura 12 resume o processo considerando a inclusão feita no MOPSO.

Figura 12 – Fluxograma MOPSO alterado



Fonte: Adaptado de [87]

# 4 Metodologia

Esta seção irá tratar da formulação matemática do problema, premissas adotadas e como a formulação foi dividida para tratar o problema de forma multiobjetiva. Para tal, a formulação será apresentada inicialmente de forma simplificada para facilitar o entendimendo do leitor. A partir disto, cada parcela da formulação será explicada em maiores detalhes. Em seguida, serão apresentadas a formulação matemática e a abordagem multiobjetiva do problema. Após introduzir o modelo multiobjetivo, será apresentado o modelo de dimensionamento de eletricistas e escalas, que é utilizado após a simulação multiobjetiva. Por fim, também será apresentada a metodologia utilizada para análise de viabilidade das soluções. Um resumo de todo o processo é apresentado ao fim da seção, para sintetizar toda metodologia desenvolvida.

## 4.1 Modelagem do problema

A modelagem do problema leva em consideração uma série de custos, considerando os recursos disponíveis e a configuração atual da concessionária, como quadro de equipes, bases operacionais e veículos utilizados pelas equipes técnicas. Tais custos são listados como: custo de instalação, manutenção e desmobilização de base operacional, custo de deslocamento, compensações, custo com equipes (manutenção), custo de treinamento de novos eletricistas, custo de demissão de eletricistas e custo de transferência de eletricistas.

Sendo assim, um dos objetivos do problema é minimizar o somatório dos custos que influenciam os planejamentos estratégico e tático, isto é, deseja-se minimizar os custos operacionais (OPEX) e capitais (CAPEX). O modelo propõe soluções de posicionamento de bases operacionais e, para cada base, a quantidade de eletricistas necessários para atender a demanda anual de serviços.

A figura 13 mostra como a divisão do território de concessão é feita. Esta divisão é comumente utilizada na literatura para formular problemas de alocação. Cada localidade é representada por uma latitude e uma longitude. As localidades que possuem base, são representadas pela latitude e longitude de suas referidas bases. Para representar as localidades que não possuem base, calcula-se uma latitude e longitude médias a partir da distribuição geográfica das ordens de serviço (OS) pertencentes às referidas localidades. A distância entre localidades é uma distância média, como se observa na imagem. Estas distâncias são pré calculadas e servem como dado de entrada para os algoritmos utilizados na resolução do problema. A imagem serve apenas para ilustrar. As distâncias utilizadas são as distâncias reais por estradas existentes, obtidas via API do Google. A partir destas distâncias são feitos outros cálculos para estimativa de outras variáveis do problema, que

serão apresentadas nas próximas seções. Por isso, o leitor deve ter em mente que sempre que se faz menção à distância entre duas localidades, a distância (real) considerada é aquela ilustrada na Figura 13, onde a linha pontilhada representa a estrada existente conectando as duas coordenadas geográficas destacadas em vermelho. As localidades que não possuem base são atendidas por alguma base existente em outra localidade. Portanto, esta mesma distância é considerada no deslocamento de equipes técnicas no atendimento das OSs nas diferentes localidades.

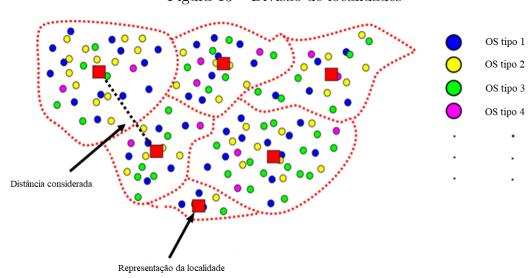


Figura 13 – Divisão de localidades

Fonte: Elaboração própria

## 4.1.1 Função objetivo

A equação 4.1 apresenta a função objetivo relacionada com todos os custos, em que  $C_{imd}$  é o custo de instalação, manutenção e desmobilização das bases operacionais,  $C_{des}$  é o custo de deslocamento,  $C_{omp}$  é a compensação,  $C_e$  é o custo com equipes,  $C_t$  é o custo de treinamento de novos funcionários,  $C_{dem}$  é o custo de demissão de funcionários e  $C_{transf}$  é o custo de transferência de eletricistas entre as bases.

$$f_{objetivo} = \sum C_{imd} + \sum C_{des} + \sum C_{omp} + \sum C_e + \sum C_t + \sum C_{dem} + \sum C_{transf}$$
 (4.1)

A equação 4.1 representa, de forma simplificada, o problema de alocação de bases e dimensionamento de equipes, que abrangem os planejamenos estratégico e tático. Portanto, a otimização da alocação de bases considera o impacto do custo dos eletricistas alocados. Desta maneira, ao se instalar uma nova base, leva-se em consideração o custo de contratação, demissão e/ou realocação de eletricistas. Dado que esta etapa consiste em planejamento com horizonte de anos a frente, tem-se apenas uma estimativa do número necessário de

equipes para atendimento da demanda de serviço. Posteriormente é utilizado outro modelo que faz uma estimativa mais precisa do número de eletricistas, o qual será apresentado posteriormente.

#### 4.1.2 Bases

A primeira parcela da função objetivo 4.1 é composta pelos custos de instalação, manutenção e desmobilização, todos relativos às bases operacionais. O custo de instalação refere-se ao investimento necessário para implantar uma nova base em determinada localidade. O custo de manutenção é relativo à manutenção anual de uma base e o custo de desmobilização representa o custo ligado à desinstalação de uma base operacional. Tais custos são importantes, pois são levados em consideração na tomada de decisão do posicionamento de novas bases ou desmobilização de bases existentes. Caso um destes custos não fosse considerado, o algoritmo teria liberdade para desmobilizar e/ou instalar novas bases de forma a minimizar apenas os custos de operação, distanciando-se, portanto, da realidade do problema.

### 4.1.3 Deslocamento

A segunda parcela da função objetivo 4.1 trata do custo relativo ao deslocamento das equipes na resolução das ordens de serviço. É considerado, no deslocamento, que as equipes saem de sua base de origem, atendem um volume de ordens de serviço e retornam. Além disso, também é considerada a quantidade de eletricistas disponíveis por base operacional e, a partir disso, calcula-se o custo de deslocamento para atendimento do total de ordens de serviço com os eletricistas disponíveis. Para as localidades que não possuem base operacional, a premissa adotada é de que são atendidas pela base mais próxima. Assim, o custo de deslocamento é minimizado.

## 4.1.4 Compensações

Para melhor entendimento sobre a modelagem da estimativa das compensações, algumas definições são apresentadas de acordo com o módulo 8 dos procedimentos de distribuição de energia elétrica (PRODIST) [88].

As compensações são calculadas com base na apuração dos indicadores individuais de continuidade, que em linhas gerais, mensuram quanto tempo cada cliente fica sem o fornecimento de energia elétrica. Essa apuração é feita mensalmente, trimestralmente e anualmente [89]. A seguir é apresentada a definição de cada indicador, bem como a fómula de cálculo, tal como se encontra no PRODIST:

• Duração de interrupção individual por unidade consumidora ou por ponto de conexão

(DIC):

$$DIC = \sum_{i=1}^{n} t(i) \tag{4.2}$$

 Frequência de interrupção individual por unidade consumidora ou por ponto de conexão (FIC):

$$FIC = n (4.3)$$

 Duração máxima de interrupção contínua por unidade consumidora ou por ponto de conexão (DMIC):

$$DIC = t(i) \max (4.4)$$

 Duração da interrupção individual ocorrida em dia crítico por unidade consumidora ou por ponto de conexão (DICRI):

$$DICRI = t_{critico} (4.5)$$

Onde:

DIC=duração de interrupção individual por unidade consumidora ou por ponto de conexão, expressa em horas e centésimos de horas;

FIC=frequência de interrupção individual por unidade consumidora ou por ponto de conexão, expressa em número de interrupções;

DMIC=duração máxima de interrupção contínua por unidade consumidora ou por ponto de conexão, expressa em horas e centésimos de horas;

DICRI=duração da interrupção individual ocorrida em dia crítico por unidade consumidora ou por ponto de conexão, expressa em horas e centésimos de horas; i=índice de interrupções da unidade consumidora ou por ponto de conexão no período de apuração, variando de 1 a n;

n=número de interrupções da unidade consumidora ou por ponto de conexão considerado, no período de apuração;

t(i)= tempo de duração da interrupção (i) da unidade consumidora considerada ou do ponto de conexão, no período de apuração;

t(i) max =valor correspondente ao tempo da máxima duração de interrupção contínua (i), no período de apuração, verificada na unidade consumidora ou no ponto de conexão considerado, expresso em horas e centésimos de horas;

 $t_{crítico}$ =duração da interrupção ocorrida em Dia Crítico.

Na modelagem não foram considerados o FIC e o DICRI. O FIC porque a frequência das interrupções não está ligada à quantidade de equipes ou posicionamento de bases, e sim ao bom funcionamento dos equipamentos do sistema elétrico, fatores climáticos, dentre outros. Em relação ao DICRI, este também não foi considerado devido à complexidade em se estimar um dia crítico. Além disso, a parcela mais representativa das compensações é devida aos indicadores DIC e DMIC.

Voltando à função objetivo, os custos de compensações apresentados na terceira parcela são calculados levando-se em conta o tempo estimado para atendimento das ordens de serviço, que é dado pelo somatório dos tempos médios de deslocamento (TMD) e de execução (TME), por tipo de serviço, além do tempo médio de preparação (TMP) da equipe ainda na base. O TMP é fixo, fornecido pela distribuidora. Este tempo considera o tempo em que uma equipe se prepara para atender uma ocorrência. O TMD é estimado por meio da distância média entre a base e as localidades (clientes afetados) e a velocidade média do veículo utilizado. No caso de uma base atendendo a própria localidade, ou seja, a localidade na qual a referida base está instalada, o TMD utilizado é um tempo médio calculado a partir da distância média da base às ordens de serviço existentes naquela localidade. O TME é extraído do histórico, pois varia de acordo com o tipo do serviço. Assim, o tempo médio de atendimento (TMA) é dado pela equação 4.6. Este tempo representa o tempo estimado que o cliente ou conjunto de clientes ficam sem o fornecimento de energia. A configuração apresentada para o TMA está de acordo com a metodologia utilizada pela ANEEL na avaliação do atendimento de ocorrências emergenciais [90]:

$$TMA = TMP + TMD + TME \tag{4.6}$$

Após o cálculo dos tempos de atendimento, tem-se os valores estimados de DIC e DMIC para cada cliente. A partir desses valores, em caso de violação dos limites, são computadas as compensações mensais, trimestrais e anuais, de acordo com o módulo 8 do PRODIST. Os limites para cada cliente são estabelecidos pela ANEEL, a depender do conjunto elétrico e do nível de tensão do cliente. A referência [91] apresenta esses limites nas tabelas de 1 a 5 do anexo I. Após a estimativa de DIC e DMIC dos clientes, esses valores são comparados com os limites e, caso sejam violados, as compensações são calculadas a partir das equações 4.7 e 4.8:

• Para o DIC:

$$Valor = \left(\frac{DIC_v}{DIC_p} - 1\right) \times DIC_p \times \frac{EUSD_{m\'edio}}{730} \times kei$$
 (4.7)

• Para o DMIC:

$$Valor = \left(\frac{DMIC_v}{DMIC_p} - 1\right) \times DMIC_p \times \frac{EUSD_{m\'edio}}{730} \times kei$$
 (4.8)

#### Onde:

 $DIC_v =$  duração de interrupção por unidade consumidora ou por ponto de conexão, conforme cada caso, verificada no período considerado, expressa em horas e centésimos de hora;

 $DIC_p$  = limite de continuidade estabelecido no período considerado para o indicador de duração de interrupção por unidade consumidora ou por ponto de conexão, expresso em horas e centésimos de hora;

 $DMIC_v =$  duração máxima de interrupção contínua por unidade consumidora ou por ponto de conexão, conforme cada caso, verificada no período considerado, expressa em horas e centésimos de hora;

 $DMIC_p$  = limite de continuidade estabelecido no período considerado para o indicador de duração máxima de interrupção contínua por unidade consumidora ou por ponto de conexão, expresso em horas e centésimos de hora;

 $EUSD_{médio} =$  média aritmética dos encargos de uso do sistema de distribuição correspondentes aos meses do período de apuração do indicador;

730 = número médio de horas no mês;

kei = coeficiente de majoração cujo valor deve ser fixado em:

i. 15 (quinze), para unidade consumidora ou ponto de conexão atendidos em Baixa Tensão;

ii. 20 (vinte), para unidade consumidora ou ponto de conexão atendidos em Média Tensão;

iii. 27 (vinte e sete), para unidade consumidora ou ponto de conexão atendidos em Alta Tensão.

Para o cálculo de compensações são consideradas apenas as ordens de serviço emergenciais, ou seja, aquelas que geram encargos para a concessionária caso não sejam atendidas dentro dos prazos estabelecidos pela ANEEL. Já no cálculo do custo de deslocamento são consideradas todas as ordens de serviço que necessitam da presença de uma equipe técnica.

Observa-se que a alocação de bases tem alto impacto no valor das compensações. Quanto maior a quantidade de bases alocadas, menor o tempo de atendimento das ordens de serviço, logo, o valor pago em compensações pelas concessionárias tende a ser reduzido. Por outro ladro, há um custo associado à instalação de novas bases, configurando dois objetivos conflitantes: custo com alocação e manutenção de bases versus compensações. Estes objetivos serão tratados separadamente na abordagem multiobjetiva do problema.

## 4.1.5 Eletricistas

As últimas quatro parcelas da função objetivo 4.1 estão ligadas aos custos de manutenção, contratação, demissão e realocação de eletricistas, sendo um dado de entrada do modelo a quantidade e perfil de eletricistas por base. O algoritmo otimiza o número de eletricistas por base, de forma a atender a demanda de serviço e reduzir os custos de operação. Em caso de insuficiência para atendimento do total de ordens de serviço, novos eletricistas podem ser alocados em determinada base, assim como pode haver demissão. Nestes casos, os custos relativos à contratação ou demissão são computados. No caso de haver demissão de eletricistas em determinada base, e contratação de eletricistas em outras, o algoritmo computa o custo de realocação, considerando que ao invés de demitir os eletricistas, os mesmos serão reposicionados em outra base. Os custos de contratação e demissão são computados de forma global, ou seja, se no fim da simulação, para dada solução, o número de eletricistas sugeridos for maior do que o existente, computa-se o custo de contratação para o excedente, caso contrário, computa-se o custo de demissão.

Em relação à estimativa da quantidade de eletricistas necessários para atendimento da demanda de serviços, como já salientado, o objetivo é considerar os custos da mão de obra técnica que irá compor o custo total relativo à implementação de uma nova base. Dado que este estudo é para um horizonte de planejamento estratégico, isto é, anos a frente, a quantidade de eletricistas necessários é calculada em função do volume de serviços ao longo de um ano. Assim, o número estimado de eletricistas em uma base para atender a demanda de serviços depende da quantidade de serviços que uma equipe consegue executar durante um dia de trabalho. Para isto, considera-se o TMD, a demanda de serviços e a quantidade de horas que os eletricistas estão efetivamente trabalhando (HH produtivo), isto é, desconsiderando o tempo que as equipes estão se deslocando e da ocisosidade. A partir dessas informações, tem-se a equação 4.9:

$$h_{ij} = \sum_{s \in S} \frac{OS_{si}}{OS_{si}^j} \tag{4.9}$$

Onde:

 $h_{ij}$ =Quantidade de eletricistas em uma base na localidade j necessários para atender a demanda de serviços da localidade i;

 $OS_{si}$  = Total de ordens de serviço (OS) do tipo s na localidade i ao longo do ano;

 $OS_{si}^{j}$  = Total de serviços do tipo s na localidade i que uma equipe da localidade j consegue executar ao longo do ano.

A estimativa de quantos serviços uma equipe consegue executar em um dia de trabalho é feita a partir do HH produtivo  $(HH_p)$  e do TME do tipo de serviço. Assim, para um ano de trabalho, a variável  $OS_{si}^j$  é dada por 4.10.

$$OS_{si}^j = \frac{HH_p}{TME_s} \times Q_d \tag{4.10}$$

Onde:

 $HH_p=$  Horas disponíveis para trabalho efetivo de uma equipe, para um dia de trabalho;  $TME_s=$  Tempo médio de execução do serviço do tipo s;

 $Q_d$ = Total de dias que uma equipe trabalha ao longo do ano.

## 4.1.6 Formulação matemática

Esta seção apresenta formalmente a formulação matemática, que está separada em três partes: dados de entrada, variáveis de decisão e a formulação propriamente dita. Comentários em relação aos dados serão apresentados na seção 5.

#### 1. Dados

- L: conjunto de localidades
- $\bullet$  S: conjunto de serviços
- $d_{ij}$ : distância da localidade i para a localidade j
- $c_s$ : custo por unidade de deslocamento (R\$/km)
- $f_1$ : custo de manutenção de uma base operacional
- $f_2$ : custo de instalação de uma base operacional
- $f_3$ : custo de fechamento de uma base operacional
- $m_{ij}$ : estimativa do total a ser pago com compensações financeiras pelo descumprimento de limites de interrupção de clientes se OSs na localidade i forem atendidas por uma base na localidade j.
- $h_{ij}$ : estimativa da quantidade de equipes necessárias na localidade j para atendimento do volume de OSs na localidade i. Esse valor depende do impacto do deslocamento  $d_{ji}$  na produtividade de uma equipe.
- $g_{ij}$ : custo estimado com equipes para atendimento de OSs na localidade i por uma base na localidade j.
- $q_{si}$ : quantidade de OSs do tipo s na localidade i
- $a_i$ : constante binária que indica (quando igual a 1) que a localidade i possui base atualmente
- $\beta_{sij}$ : número estimado de OSs do tipo s em i atendidas por rota trajeto definido pela saída de uma equipe da base, atendimento de OSs e retorno da equipe para base de uma base em j. Esse coeficiente tem o propósito de

evitar que o modelo considere o deslocamento para atendimento de apenas uma OS, que pode diferir da realidade.

- r: quantidade atual de eletricistas
- $n_t$ : quantidade de eletricistas por equipe
- T: custo de treinamento (contratação) de um eletricista
- D: custo de demissão de um eletricista

#### 2. Variáveis de decisão

O modelo tem as seguintes variáveis de decisão:

- $y_j \in \{0, 1\}$ : variável binária que indica (quando for igual a 1) a existência de uma base na localidade j
- $x_{ij} \in \{0, 1\}$ : variável binária que indica (quando for igual a 1) que a localidade i será atendida por uma base na localidade j
- $z \in \Re$ : variável auxiliar que mantém o número de equipes estimado na localidade j
- $w \in \mathbb{Z}^+$ : variável auxiliar que mantém o número total de eletricistas necessários
- $\alpha \in \Re$ : variável que mantém o número de eletricistas a serem contratados
- $\theta \in \Re$ : variável que mantém o número de eletricistas a serem demitidos

#### 3. Formulação matemática

Finalmente, a seguir tem-se a descrição completa da formulação matemática.

$$T_1 = \sum_{i \in L} \sum_{j \in L} \left( \left( \sum_{s \in S} \frac{(d_{ij} + d_{ji}) \cdot c_s \cdot q_{si}}{\beta_{sij}} \right) + m_{ij} \right) \cdot x_{ij}$$

$$(4.11)$$

$$T_2 = \sum_{j \in L} ((f_1 + (1 - a_j) \cdot f_2) \cdot y_j + a_j \cdot f_3 \cdot (1 - y_j))$$
(4.12)

$$T_3 = \sum_{i \in L} \sum_{j \in L} g_{ij} \cdot x_{ij} + \sum_{j \in L} (T \cdot \alpha + D \cdot \theta)$$

$$\tag{4.13}$$

$$\min \ T_1 + T_2 + T_3 \tag{4.14}$$

Sujeito a:

$$\sum_{j \in L} x_{ij} = 1 \qquad \forall i \in L, \tag{4.15}$$

$$x_{ij} \le y_j \qquad \forall i, j \in L, \tag{4.16}$$

$$y_j \le 1 \qquad \forall j \in L, \tag{4.17}$$

(4.27)

(4.28)

$$\sum_{\substack{k \in L, \\ d_{ik} > d_{ij}}} x_{ik} < 1 - y_j \qquad \forall i, j \in L, \qquad (4.18)$$

$$z = \sum_{i \in L} h_{ij} \cdot x_{ij} \qquad \forall j \in L, \qquad (4.19)$$

$$n_t \cdot z \le w \le n_t \cdot z + 1 \qquad \forall j \in L, \qquad (4.20)$$

$$\alpha \ge w - r \qquad \forall j \in L, \qquad (4.21)$$

$$\alpha \ge 0 \qquad \forall j \in L, \qquad (4.22)$$

$$\theta \ge r - w \qquad \forall j \in L, \qquad (4.23)$$

$$\theta \ge 0 \qquad \forall j \in L, \qquad (4.23)$$

$$\theta \ge 0 \qquad \forall j \in L, \qquad (4.24)$$

$$x_{ij} \in \{0, 1\} \qquad \forall i, j \in L, \qquad (4.25)$$

$$y_j \in \{0, 1\} \qquad \forall j \in L, \qquad (4.26)$$

 $\forall j \in L$ ,

 $\forall j \in L$ 

A função objetivo (4.14) é composta por três termos: (4.11) diz respeito aos custos com deslocamento e compensações por violações de indicadores de continuidade, (4.12) diz respeito aos custos com instalação, manutenção e fechamento de bases, e (4.13) diz respeito a custos de manutenção, contratação e demissão de eletricistas. Uma vez que cada termo produz um custo em reais, a função objetivo busca minimizar o custo total estimado. O conjunto de restrições (4.15) garante que cada localidade será atendida por exatamente uma base (que pode ser na própria localidade quando i = j). No conjunto de restrições (4.16), um atendimento definido por  $x_{ij}$  obriga a abertura de uma base em j. O conjunto de restrições (4.17) proibe a abertura de mais de uma base por localidade. O conjunto de restrições (4.18) garante que cada localidade será atendida pela base mais próxima. Ele é necessário, uma vez que os custos com demissão e contratação podem produzir uma solução que quebra esta premissa e possui difícil aplicação prática. No conjunto de restrições (4.19) e (4.20), o número total estimado de equipes e eletricistas são definidos, respectivamente. Os conjuntos de restrições(4.21) a (4.24) definem a quantidade de eletricitas contratados e demitidos. Note que se houver demissão não pode haver contratação, e o contrário também é verdade. Finalmente, as restrições (4.25) a (4.28) definem o domínio das variáveis de decisão.

## 4.1.7 Abordagem multiobjetivo

 $z \in \Re$ 

 $w, \alpha, \theta \in \mathbb{Z}^+$ 

É importante salientar que a ideia apresentada até o momento aborda o problema de forma mono objetiva, ou seja, todos os custos estão agrupados em uma única função, o que pode trazer limitações em termos práticos. Na abordagem mono objetiva tem-se apenas uma solução, que pode apresentar uma boa solução global para a função objetivo modelada, mas analisando-se os custos individualmente, uma solução pode não ser atrativa

para a concessionária. Por exemplo, o resultado final pode reduzir o custo relativo às compensações, mas ter um CAPEX ou OPEX elevado. Para contornar essa limitação, é utilizada uma abordagem multiobjetivo híbrida. A abordagem fornece uma gama de soluções, geradas pelo MOPSO modificado, dando ao usuário maior flexibilidade na tomada de decisões. A título de exemplo, a figura 14 ilustra uma frente de Pareto com um conjunto de possíveis soluções. Neste gráfico, o eixo dos custos representa CAPEX ou OPEX, por exemplo. O eixo das compensações representa a qualidade do serviço de acordo com os indicadores de continuidade. Quanto maior forem os investimentos, menores serão as compensações e, consequentemente, melhor será a qualidade do serviço. Por outro lado, conforme reduz-se os custos, o valor das compensações aumenta. Com essa abordagem o usuário pode optar pela solução que melhor satisfaz as necessidades da concessionária, de acordo com os recursos disponíveis para investimento, tanto de CAPEX quanto de OPEX.

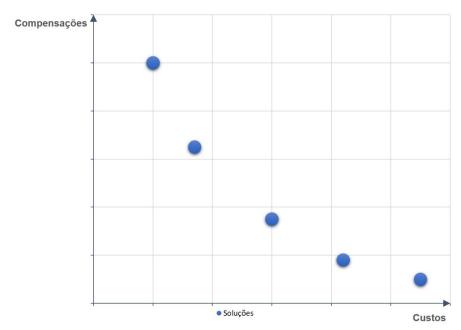


Figura 14 – Frente de Pareto com conjunto de possíveis soluções

Fonte: Elaboração própria

A equação simplificada da função objetivo (4.1) traz os custos todos agrupados em uma única função. Na otimização multiobjetivo tem-se então duas funções, uma representando as compensações e a outra contendo os custos restantes, ou seja, CAPEX e OPEX. Os objetivos ficam então representados tal como se vê nas equações 4.29 e 4.30.

$$Objetivo_1 = \sum C_{omp} \tag{4.29}$$

$$Objetivo_2 = \sum C_{imd} + \sum C_{des} + \sum C_e + \sum C_t + \sum C_{dem} + \sum C_{transf}$$
 (4.30)

A formulação do problema continua a mesma, a diferença é que os objetivos são tratados separadamente. Como explicado na seção 3.5.3, para cada solução proposta pelo MOPSO, o modelo de programação matemática recebe os valores de compensações, OPEX e CAPEX como parâmetros e resolve dois modelos mono objetivo considerando um dos objetivos como restrição e otimizando o outro objetivo. Por exemplo, se o MOPSO encontrar uma solução com custo de compensações de R\$ 500.000,00 e custo total (CAPEX e OPEX) de R\$ 1.000.000,00, por exemplo, o modelo de programação matemática mono objetivo tenta encontrar uma solução que minimize ainda mais o custo de compensações, com a restrição de que o custo total (CAPEX e OPEX) seja no máximo de R\$ 1.000.000,00. O mesmo processo é feito na tentativa de minimizar ainda mais o custo total (CAPEX e OPEX), tendo como restrição que as compensações não podem ultrapassar o valor de R\$ 500.000,00. As soluções encontradas pelo modelo de programação matemática são então armazenadas no repositório. Caso o modelo de programação matemática mono objetivo não consiga otimizar a solução, acrescenta-se ao repositório a solução sugerida pelo MOPSO e o processo iterativo continua.

## 4.2 Dimensionamento de eletricistas

Definido o posicionamento das bases e dimensionamento dos eletricistas em cada base, faz-se uso de outro modelo de programação linear inteira mista, que dimensiona o número de eletricistas necessários e escalas de serviço dos eletricistas. Apesar de a quantidade de eletricistas haver sido estimada no módulo estratégico, o modelo de escalas otimiza em um horizonte de tempo menor, com base na previsão de demanda horária de cada dia, sendo capaz de responder, com maior eficiência, à variações não esperadas nas previsões de demanda. Sendo assim, este módulo define, simultaneamente, as escalas e equipes necessárias para atendimento da demanda de serviço. Então, o modelo define para cada solução da frente de Pareto o número de eletricistas por base. Em seguida, o montante de custos relacionados aos eletricistas (contratação, demissão, manutenção e realocação) é substituído pelos novos custos gerados pela solução do modelo de escalas. Após a substituição destes custos, todas as soluções são avaliadas a fim de verificar se cada uma continua sendo não dominada pelas demais soluções. Aquelas que deixam de ser não dominadas são descartadas da frente de Pareto. A seguir, serão definidas a função objetivo e a formulação matemática do modelo de escalas.

## 4.2.1 Função objetivo

A equação 4.31 apresenta a função simplificada contendo os custos associados à definição de escalas e dimensionamento de equipes, em que  $C_e$  é o custo de manutenção das equipes disponíveis,  $C_{cont}$  é o custo relativo a contratação de eletricistas,  $C_{dem}$  é o custo de demissão de eletricistas e  $C_v$  é o custo dos veículos:

$$f_{escalas} = \sum C_e + \sum C_v + \sum C_{cont} + \sum C_{dem}$$
 (4.31)

Caso os veículos disponíveis não sejam suficientes para atendimento da demanda, esta parcela adiciona uma penalidade (em reais) à função, indicando a necessidade de que são necessários mais veículos em determinada base. Caso seja necessário contratar novos eletricistas para atender a demanda, computa-se o custo de contratação/treinamento de novos eletricistas.

O modelo de escalas considera apenas quatro custos, sendo três deles  $(C_e, C_{cont})$  e  $C_{dem}$ ) relacionados aos eletricistas, que também são custos considerados no modelo estratégico. O modelo de escalas, no entanto, também considera a disponibilidade de veículos nas bases para fazer o dimensionamento de equipes, uma vez que cada equipe necessita de um veículo para se locomover. Todavia, importante destacar que o dimensionamento de veículos, materiais e ferramentas não faz parte do escopo da metodologia.

## 4.2.2 Formulação matemática

A função objetivo do planejamento tático/operacional é dada por uma soma de quatro parcelas de custos, definidos como custo de manutenção das equipes disponíveis, custo dos veículos, custo relativo a contratação de funcionários e custo de demissão de funcionários. A equação 4.32 apresenta a função objetivo do planejamento tático/operacional para o dimensionamento das equipes de campos e definição das escalas de trabalho. O dimensionamento adequado de equipes nas bases operacionais requer o conhecimento das escalas. Dessa forma, as escalas e dimensionamento das equipes são definidos simultaneamente. A seguir, a formulação é dividida em três partes: dados de entrada, variáveis de decisão e a formulação propriamente dita. Comentários em relação aos dados serão apresentados na seção 5.

#### 1. Dados

- J: conjunto de tipos de funcionários
- S: conjunto de tipos de escalas de trabalho (incluindo escalas que possuem hora extra)
- T: conjunto de horas da semana (|T| = 24x7)
- TC: subconjunto de T apenas com horas da semana pertencentes ao horário comercial, onde é possível executar OSs não reguladas
- E: conjunto de perfis de equipe
- O: conjunto de tipos de OS

- V: conjunto de tipos de veículo
- $a_{st}$ : indica (0 ou 1) se t faz parte da escala s
- $q_{ie}$ : quantidade de funcionários do tipo j na equipe e
- $c_{oe}$ : indica se a equipe e atende OS o
- $d_{ot}$ : demanda pela OS regulada o no tempo t
- $b_{min}$ : demanda mínima para OSs não reguladas em HH (homem-hora)
- $c_{is}$ : custo de funcionários j na escala s
- $\gamma_{oe}$ : número de OSs o que a equipe e atende em 1 hora
- ullet  $r_e$ : indica o tipo de veículo necessário para a equipe e
- $k_v$ : quantidade de veículos do tipo v disponível na base
- $p_v$ : penalização por ultrapassar o número de veículos do tipo v (em veículo por hora)
- $r_j$ : quantidade atual de funcionários do tipo j
- $T_i$ : custo de um novo funcionário do tipo j (treinamento, contratação, etc.)
- $D_j$ : custo de demissão do funcionário do tipo j (indenizações)

#### 2. Variáveis de decisão

- $\bullet \ x_{js}$ : número de funcionários do tipo j contratados para seguir a escala s
- $y_{jt}$ : número de funcionários do tipo j disponíveis no tempo t
- $w_{et}$ : número de equipes e formadas no tempo t
- $z_{vt}$ : número de veículos do tipo v que faltaram no tempo t
- $f_{jt}$ : excesso, em HH, de funcionários do tipo j no tempo  $t \in TC$
- $\alpha_j$ : quantidade de novos funcionários do tipo j
- $\theta_j$ : excesso de funcionários do tipo j

#### 3. Formulação matemática

$$\min\left(\sum_{j\in J}\sum_{s\in S}c_{js}X_{js} + \sum_{v\in V}\sum_{t\in T}p_vz_{vt} + \sum_{j\in J}T_j\alpha_j + \sum_{j\in J}D_j\theta_j\right)$$
(4.32)

Sujeito a:

$$\sum_{s \in S} a_{st} x_{js} \ge y_{jt} + f_{it} \qquad \forall j \in J, \forall t \in TC$$
 (4.33)

$$\sum_{s \in S} a_{st} x_{js} \ge y_{jt} \qquad \forall j \in J, \forall t \in T/TC \qquad (4.34)$$

$$\sum_{e \in E} q_{je} w_{et} \le y_{jt} \qquad \forall j \in J, \forall t \in T$$
 (4.35)

$$\sum_{e \in E} \gamma_{oe} w_{et} \ge d_{ot} \qquad \forall o \in O, \forall t \in T$$
 (4.36)

$$\sum_{e \in E, r_e = v} w_{et} \le k_v + z_{vt} \qquad \forall v \in V, \forall t \in T$$

$$(4.37)$$

$$\sum_{i \in I} \sum_{t \in TC} f_{jt} \ge b_{min} \tag{4.38}$$

$$\alpha_J \ge \sum_{s \in S} x_{js} - r_j \qquad \forall j \in J \tag{4.39}$$

$$\alpha_j \ge 0 \qquad \forall j \in J \tag{4.40}$$

$$\theta_j \ge r_j - \sum_{s \in S} x_{js}$$
  $\forall j \in J$  (4.41)

$$\theta_j \ge 0 \qquad \forall j \in J \tag{4.42}$$

$$x_j \in \mathbb{Z}^+ \qquad \forall j \in J, \forall s \in S \tag{4.43}$$

$$y_{jt} \in \mathbb{R}^+$$
  $\forall j \in J, \forall t \in T$  (4.44)

$$w_{et} \in \mathbb{R}^+$$
  $\forall e \in E, \forall t \in T$  (4.45)

$$f_{jt} \in \mathbb{R}^+$$
  $\forall j \in J, \forall t \in T$  (4.46)

$$\alpha_j \in \mathbb{R}^+ \qquad \forall j \in J \tag{4.47}$$

$$\theta_j \in \mathbb{R}^+ \tag{4.48}$$

Em relação às restrições da função objetivo 4.32, o conjunto de restrições 4.33 é responsável por definir quantos homens-hora (HH) do tipo j estarão disponíveis no tempo t (em horário comercial) para demanda regulada e não regulada, ou seja, é a distribuição de HH contratada para demanda regulada e não regulada em horário comercial. Similarmente, o conjunto de restrições 4.34 é responsável por definir quantos HH do tipo j estarão disponíveis no tempo t (em horário não comercial) para demanda obrigatória, ou seja é a distribuição de HH contratada para demanda regulada e não regulada em horário não comercial. O conjunto de restrições 4.35 obriga a alocação (contratação do redistribuição) de eletricistas suficientes para a formação das equipes para cumprir a demanda regulada. O conjunto de restrições 4.36 obriga que existam equipes suficientes para suportar a demanda no tempo t para cada tipo de OS. O conjunto de restrições 4.37 limitam a formação de equipes para a frota de veículos existente na base. O excesso de veículos (violação) é atribuído em z. O conjunto de restrições 4.38 obrigam que tenha uma quantidade de HH mínima para demanda não regulada. Os conjuntos de restrições 4.39 e 4.40 registram a quantidade de novos eletricistas. Os conjuntos de restrições 4.41 e 4.42 registram o excesso de eletricistas. Por fim, os conjuntos de restrições 4.43,4.44,4.45,4.46,4.47,4.48 definem o domínio das variáveis.

## 4.3 Análise de viabilidade

Para auxiliar as análises, após o término da simulação com a frente de Pareto construída, foi implementada uma metodologia para cálculo de *payback*, que tem por objetivo estimar a viabilidade da implementação de cada uma das soluções da frente de Pareto. Esta breve seção apresenta as premissas adotadas e a metodologia de cálculo.

## 4.3.1 Premissas e metodologia de cálculo

A fim de estimar a viabilidade ao optar por determinada solução, foram considerados todos os custos utilizados na modelagem, listados a seguir:

- Contratação de eletricistas
- Demissão de eletricistas
- Realocação de eletricistas
- Manutenção de eletricistas
- Instalação de novas bases
- Desinstalação de bases existentes
- Manutenção de bases propostas
- Custo de deslocamento
- Custo estimado de compensações

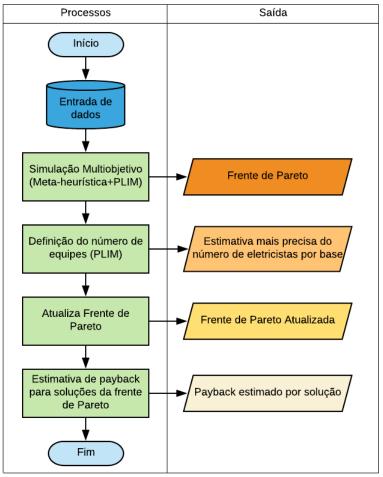
A análise faz consideração do investimento necessário, para dada solução, frente à redução de despesas esperada. A partir disso, faz-se o cálculo de *payback* descontado. A análise é realizada em relação à solução existente. Ou seja, considerando o quadro de eletricistas e posicionamento de bases atuais, faz-se o cálculo (estimado) de todos os custos de operação (OPEX), a partir da modelagem proposta. Em seguida, este valor é comparado com os custos de investimento e operativos (CAPEX e OPEX), a longo prazo, de todas as soluções existentes na frente de Pareto. A partir dessa comparação o *payback* é estimado.

Para realização do cálculo do *payback* é feito o cálculo do fluxo de caixa (anual) com base em custo atual (estimado). O *payback* é então dado em função do fluxo de caixa e CAPEX estimados para cada solução. A análise considera o horizonte de 5 anos a frente para cálculo do *payback* descontado, com uma taxa de atratividade de 12%. Esta taxa é parametrizável.

### 4.4 Resumo

Este capítulo apresentou como o problema foi modelado, premissas adotadas, formulações matemáticas e uma estimativa de payback para análise de viabilidade. O modelo considera, além dos custos comumente utilizados no posicionamento de bases, custos relacionados às equipes técnicas, que também precisam ser consideradas na instalação de novas bases. Simultaneamente, o modelo faz uma estimativa inicial do número de eletricistas necessários em cada base para atendimendo da demanda anual de serviços. Esta estimativa é feita a partir da quantidade de OSs que uma equipe é capaz de atender em um ano, com base no volume de OSs e no tempo médio necessário para executar um serviço, considerando os diversos tipos de serviço. Para resolução do problema é utilizada uma técnica meta-heurística, que trata o problema de forma multiobjetiva, fornecendo uma gama de soluções considerando dois objetivos conflitantes: compensações estimadas e custos operacionais e de investimento (OPEX e CAPEX). Ao longo do processo iterativo utiliza-se um modelo de PLIM para refinar as soluções encontradas pelo algoritmo meta-heurístico, sendo proposto um algoritmo memético a fim de otimizar o processo de busca e encontrar o conjunto ótimo de soluções para compor a frente de Pareto. Concluído o processo iterativo, em uma segunda etapa, outro modelo matemático (PLIM) é utilizado para estimar de forma mais precisa o número de eletricistas por base, e também as escalas de serviço, para cada uma das soluções da frente de Pareto. Em seguida, as soluções da frente de Pareto são atualizadas com o resultado provido pelo modelo de escalas. Por fim, com o conjunto final de soluções representadas na frente de Pareto, faz-se uma estimativa do payback para cada uma das soluções. O fluxograma da figura 15 ilustra de forma sintetizada todo o processo tratado no presente capítulo.

Figura 15 – Fluxograma do modelo de alocação de bases e dimensionamento de equipes



Fonte: Elaboração própria

## 5 Análise de Resultados

Esta seção apresenta as simulações e resultados, bem como uma análise crítica dos mesmos. Primeiro serão apresentadas informações sobre os dados utilizados para avaliação da metodologia proposta. Em seguida, serão apresentados resultados comparativos entre as duas meta-heurísticas apresentadas no capítulo 4. Por fim, os resultados do algoritmo memético proposto combinando o MOPSO com o modelo PLIM são apresentados.

Para implementação dos algoritmos foi utilizada a linguagem Python 3.6. As simulações foram executadas em uma máquina com as seguintes configurações: Intel® Core  $^{\rm TM}$  i5-8250U, 8 GB RAM em sistema operacional Linux. Para resolver os modelos matemáticos, foi utilizado o Coin-CBC [69], que é um *solver* gratuito que utiliza o algoritmo de *branch and cut* para resolver modelos de PLIMs. Para integração do algoritmo metaheurístico com o *solver* foi utilizada a biblioteca PuLP [92] disponível para Python.

## 5.1 Dados da distribuidora: Energisa Sergipe

O estudo apresentado neste trabalho utiliza os dados da Energisa Sergipe Distribuidora (ESE). Tais dados foram disponibilizados em função do projeto de pesquisa e desenvolvimento que vem sendo desenvolvido pela UFF (SIDEC - Sistema Inteligente para Dimensionamento de Equipes de Campo - PD ANEEL 00032-1704/2017). Os dados contêm informações sobre as localidades, bases operacionais, quadro de eletricistas, clientes e ordens de serviço referentes aos anos de 2016 e 2017. Mais detalhes serão apresentados a seguir.

### 5.1.1 Localidades e bases

O Sergipe é dividido em 64 localidades. Esta divisão é feita pela própria concessionária. Dessas localidades, 24 possuem uma base operacional, com exceção de Itabaiana, que possui duas bases, totalizando 25 bases em todo o estado. Dado que na formulação do problema cada localidade pode ter apenas uma base, foi necessário dividir a localidade de Itabaiana em duas localidades: Itabaiana e Itabaiana II. Com esta divisão foi necessário redistribuir os dados entre as duas localidades. Esta divisão, no entanto, não gera nenhum tipo de alteração nos dados. A tabela 1 contém os nomes das localidades, bem como as latitudes e longitudes que representam cada localidade e, na coluna 'BASE', se a localidade possui ou não uma base. A figura 16 ilustra o mapa do Sergipe, indicando as localidades, destacando também a localização das bases. Observa-se que no entorno de Aracaju há uma densidade maior do número de bases. Isto porque a capital contém maior concentração de

ordens de serviço.

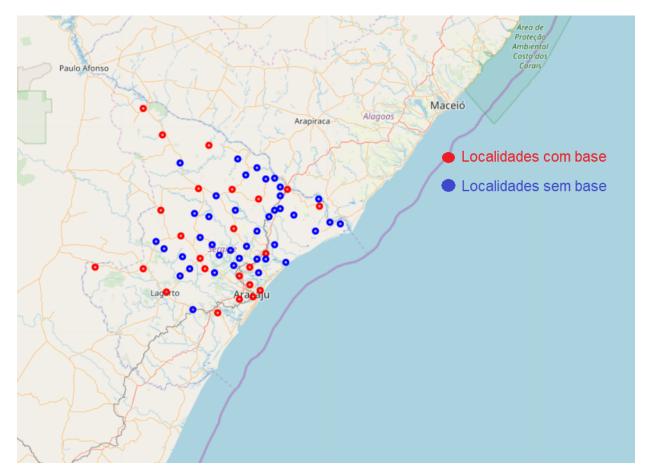


Figura 16 – Mapa de localidades e bases de Sergipe

Fonte: Elaboração a partir da ferramenta [93]

## 5.1.2 Ordens de Serviço

A companhia possui um Sistema de Gerenciamento da Operação da Distribuição (SIGOD). Neste sistema são armazenadas informações relativas às OSs, como localização, data em que a ocorrência foi registrada no sistema, data em que uma equipe resolveu o serviço e tempo de execução padrão por tipo de serviço. As OSs são categorizadas em comerciais e técnicas. Em geral, as comerciais estão ligadas a corte e religamento dos clientes, enquanto que as técnicas estão mais ligadas a problemas que podem causar a interrupção do fornecimento de energia. Apesar de não haver compensação financeira para alguns tipos de OSs, ainda assim há a necessidade da presença de uma equipe para execução do serviço, gerando custo de deslocamento. Então, o custo de deslocamento é computado para atendimento de todas as OSs. A figura 17 traz o quantitativo de OSs e a figura 18 ilustra uma amostra da distribuição espacial das OSs. Houve um total de 450.256 OSs em 2016 e 474.491 em 2017.

Tabela 1 – Dados de localidades

AMPARO DE SAO FRANCISCO	NOME LOCALIDADE	LAT.	LONG.	BASE
ARACAJU -10.94 -37.07 X AREIA BRANCA -10.78 -37.33 BARRA DOS COQUEIROS -10.90 -37.02 X BREJO GRANDE -10.45 -36.47 CAMPO DO BRITO -10.75 -37.50 CANHOBA -10.15 -36.98 CANINDE DE SAO FRANCISCO -9.67 -37.82 X CAPELA -10.50 -37.04 X CARIRA -10.36 -37.70 X CARMOPOLIS -10.65 -36.98 X CEDRO DE SAO JOAO -10.26 -36.88 CUMBE -10.36 -37.19 DIVINA PASTORA -10.68 -37.16 FEIRA NOVA -10.26 -37.32 FREI PAULO -10.53 -37.56 X GARARU -10.01 -37.17 GENERAL MAYNARD -10.69 -36.98 GRACHO CARDOSO -10.22 -37.21 X ILHA DAS FLORES -10.44 -36.54 ITABAIANA -10.68 -37.43 X ITABAIANA   10.75 -37.40 X ITABI -10.12 -37.12 ITAPORANGA D AJUDA -11.05 -37.31 X JAPARATUBA -10.59 -36.92 JAPOATA -10.39 -36.92 JAPOATA -10.39 -36.79 LAGARTO -10.91 -37.55 MALHADAOR -10.66 -37.30 MACAMBIRA -10.67 -37.55 MALHADAOR -10.69 -37.35 MALHADAOR -10.69 -37.35 MONTE ALEGRE DE SERGIPE -10.04 -37.37 NOSSA SENHORA DAS DORS PINHAO -10.21 -37.44 X NOSSA SENHORA DAS DORS PINHAO -10.59 -36.96 NOSSA SENHORA DAS DORS NOSSA SENHORA DAS DORS PINHAO -10.59 -37.35 NOSSA SENHORA DAS DORS NOSSA SENHORA DAS DORS PINHAO -10.66 -37.30 NOSSA SENHORA DAS DORS PINHAO -10.67 -37.68 PINHAO -10.57 -37.09 X NOSSA SENHORA DO SOCORRO -10.86 -37.09 X NOSSA SENHORA DAS DORES -10.48 -37.47 NOSSA SENHORA DAS DORES -10.48 -37.47 NOSSA SENHORA DAS DORES -10.48 -37.09 X NOSSA SENHORA DAS DORES -10.48 -37.09 X NOSSA SENHORA DAS DORES -10.48 -37.20 X NOSSA SENHORA DO SOCORRO -10.86 -37.09 X PACATUBA -10.57 -37.73 PIRAMBU -10.77 -37.73				
AREIA BRANCA	AQUIDABA	-10.28	-37.03	X
BARRA DOS COQUEIROS		-10.94	-37.07	X
BREJO GRANDE				
CAMPO DO BRITO         -10.75         -37.50           CANHOBA         -10.15         -36.98           CANINDE DE SAO FRANCISCO         -9.67         -37.82           CAPELA         -10.50         -37.04           CARIRA         -10.36         -37.70         X           CARMOPOLIS         -10.65         -36.98         X           CEDRO DE SAO JOAO         -10.26         -36.88           CUMBE         -10.36         -37.19           DIVINA PASTORA         -10.68         -37.16           FEIRA NOVA         -10.26         -37.32           FREI PAULO         -10.53         -37.56         X           GARARU         -10.01         -37.17           GENERAL MAYNARD         -10.69         -36.98           GRACHO CARDOSO         -10.22         -37.21         X           ILHA DAS FLORES         -10.44         -36.54           ITABAIANA         -10.68         -37.43         X           ITABORANGA D AJUDA         -11.05         -37.31         X           JAPORANGA D AJUDA         -11.05         -37.31         X           JAPOATA         -10.39         -36.79           LAGARTO         -10.91         -37			-37.02	X
CANINDE DE SAO FRANCISCO         -9.67         -37.82         X           CAPELA         -10.50         -37.04         X           CARIRA         -10.65         -37.70         X           CARMOPOLIS         -10.65         -36.98         X           CEDRO DE SAO JOAO         -10.26         -36.88         X           CUMBE         -10.36         -37.19         DIVINA PASTORA         -10.68         -37.16           FEIRA NOVA         -10.26         -37.32         FREI PAULO         -10.53         -37.56         X           GARARU         -10.01         -37.17         GENERAL MAYNARD         -10.69         -36.98         S           GRACHO CARDOSO         -10.22         -37.21         X         IIABAIANA         -10.68         -37.43         X           ITABAIANA         -10.68         -37.43         X         ITABAIANA         -10.68         -37.21         X           ITABORANGA D AJUDA         -11.05         -37.31         X         JAPARATUBA         -10.59         -36.92           JAPOATA         -10.59         -36.92         JAPOATA         -10.80         -37.16         X           MACAMBIRA         -10.67         -37.55         MALHADOR				
CANINDE DE SAO FRANCISCO         -9.67         -37.82         X           CAPELA         -10.50         -37.04         -37.04           CARIRA         -10.36         -37.70         X           CARMOPOLIS         -10.65         -36.88         X           CEDRO DE SAO JOAO         -10.26         -36.88         X           CUMBE         -10.36         -37.19         -37.16           DIVINA PASTORA         -10.68         -37.16         -37.32           FEIRA NOVA         -10.26         -37.32         -37.56         X           GARARU         -10.01         -37.17         -37.12         -37.12         -37.12         -37.21         -37.21         -37.21         -37.21         -37.21         -37.1				
CAPELA         -10.50         -37.04           CARIRA         -10.36         -37.70         X           CARMOPOLIS         -10.65         -36.98         X           CEDRO DE SAO JOAO         -10.26         -36.88         X           CUMBE         -10.36         -37.19         DIVINA PASTORA         -10.68         -37.16           FEIRA NOVA         -10.26         -37.32         FREI PAULO         -10.53         -37.56         X           GARARU         -10.01         -37.17         GENERAL MAYNARD         -10.69         -36.98           GRACHO CARDOSO         -10.22         -37.21         X           ILHA DAS FLORES         -10.44         -36.54         ITABAIANA         -10.68         -37.43         X           ITABAIANA II         -10.75         -37.40         X         ITAPORANGA D AJUDA         -10.12         -37.12           ITAPORANGA D AJUDA         -11.05         -37.31         X           JAPOATA         -10.39         -36.79           LAGARTO         -10.91         -37.66         X           LARANJEIRAS         -10.80         -37.16         X           MALHADOR         -10.67         -37.55           MALHADOR </td <td></td> <td></td> <td></td> <td></td>				
CARIRA         -10.36         -37.70         X           CARMOPOLIS         -10.65         -36.98         X           CEDRO DE SAO JOAO         -10.26         -36.88           CUMBE         -10.36         -37.19           DIVINA PASTORA         -10.68         -37.16           FEIRA NOVA         -10.26         -37.32           FREI PAULO         -10.53         -37.56         X           GARARU         -10.01         -37.17           GENERAL MAYNARD         -10.69         -36.98           GRACHO CARDOSO         -10.22         -37.21         X           ILHA DAS FLORES         -10.44         -36.54         ITABAIANA         -10.68         -37.43         X           ITABAIANA         -10.68         -37.43         X         ITABAIANA         III         -10.75         -37.40         X           ITABAIANA         -10.75         -37.40         X         ITABAIANA         III         -10.12         -37.12         ITAPORANGA D AJUDA         -11.05         -37.31         X           JAPOATA         -10.59         -36.92         -36.92         -36.92         -36.92         -36.92         -37.16         X           MACAMBIRA <t< td=""><td></td><td></td><td></td><td>X</td></t<>				X
CARMOPOLIS -10.65 -36.98 X CEDRO DE SAO JOAO -10.26 -36.88  CUMBE -10.36 -37.19  DIVINA PASTORA -10.68 -37.16  FEIRA NOVA -10.26 -37.32  FREI PAULO -10.53 -37.56 X  GARARU -10.01 -37.17  GENERAL MAYNARD -10.69 -36.98  GRACHO CARDOSO -10.22 -37.21 X  ILHA DAS FLORES -10.44 -36.54  ITABAIANA -10.68 -37.43 X  ITABAIANA -10.68 -37.43 X  ITABAIANA -10.75 -37.40 X  ITABORANGA D AJUDA -11.05 -37.31 X  JAPARATUBA -10.59 -36.92  JAPOATA -10.39 -36.79  LAGARTO -10.91 -37.66 X  LARANJEIRAS -10.80 -37.16 X  MACAMBIRA -10.67 -37.55  MALHADA DOS BOIS -10.36 -36.92  MALHADOR -10.66 -37.30  MARUIM -10.74 -37.09 X  MOITA BONITA -10.59 -36.92  MALHADOR -10.66 -37.35  MONTE ALEGRE DE SERGIPE -10.04 -37.57  MURIBECA -10.40 -36.96  NEOPOLIS -10.38 -37.47  NOSSA SENHORA DAS DORES -10.48 -37.20 X  NOSSA SENHORA DO SOCORRO -10.86 -37.09 X  PACATUBA -10.57 -37.73 PIRAMBU -10.77 -37.73				37
CEDRO DE SAO JOAO         -10.26         -36.88           CUMBE         -10.36         -37.19           DIVINA PASTORA         -10.68         -37.16           FEIRA NOVA         -10.26         -37.32           FREI PAULO         -10.53         -37.56         X           GARARU         -10.01         -37.17         GENERAL MAYNARD         -10.69         -36.98           GRACHO CARDOSO         -10.22         -37.21         X           ILHA DAS FLORES         -10.44         -36.54           ITABAIANA         -10.68         -37.43         X           ITABAIANA II         -10.75         -37.40         X           ITAPORANGA D AJUDA         -11.05         -37.31         X           JAPOATA         -10.59         -36.92           JAPOATA         -10.59         -36.92           JAPOATA         -10.91         -37.66         X           LARANJEIRAS         -10.80         -37.16         X           MACAMBIRA         -10.67         -37.55           MALHADOR         -10.66         -37.30         X           MOTTA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.40         -36.				
CUMBE         -10.36         -37.19           DIVINA PASTORA         -10.68         -37.16           FEIRA NOVA         -10.26         -37.32           FREI PAULO         -10.53         -37.56         X           GARARU         -10.01         -37.17           GENERAL MAYNARD         -10.69         -36.98           GRACHO CARDOSO         -10.22         -37.21         X           ILHA DAS FLORES         -10.44         -36.54           ITABAIANA         -10.68         -37.43         X           ITABAIANA II         -10.75         -37.40         X           ITABORANGA DAJUDA         -11.05         -37.31         X           JAPORANGA DAJUDA         -11.05         -37.31         X           JAPOATA         -10.39         -36.79         A           LAGARTO         -10.91         -37.66         X           LARANJEIRAS         -10.80         -37.16         X           MACAMBIRA         -10.67         -37.55           MALHADA DOS BOIS         -10.36         -36.92           MALHADOR         -10.66         -37.30           MARUIM         -10.74         -37.09           MONTE ALEGRE DE SERGIPE				X
DIVINA PASTORA				
FEIRA NOVA FREI PAULO				
FREI PAULO				
GARARU				V
GENERAL MAYNARD         -10.69         -36.98           GRACHO CARDOSO         -10.22         -37.21         X           ILHA DAS FLORES         -10.44         -36.54           ITABAIANA         -10.68         -37.43         X           ITABI         -10.75         -37.40         X           ITABI         -10.12         -37.12           ITAPORANGA D AJUDA         -11.05         -37.31         X           JAPARATUBA         -10.59         -36.92           JAPOATA         -10.39         -36.79           LAGARTO         -10.91         -37.66         X           LARANJEIRAS         -10.80         -37.16         X           MACAMBIRA         -10.67         -37.55           MALHADA DOS BOIS         -10.36         -36.92           MALHADOR         -10.66         -37.30           MARUIM         -10.74         -37.09         X           MONTA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.04         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47         X           NOSSA SENHORA DA				X
GRACHO CARDOSO			0	
ILHA DAS FLORES				v
ITABAIANA				Λ
ITABAIANA II		_		v
TTABI				
ITAPORANGA D AJUDA				Λ
JAPARATUBA				v
JAPOATA				Λ
LAGARTO         -10.91         -37.66         X           LARANJEIRAS         -10.80         -37.16         X           MACAMBIRA         -10.67         -37.55           MALHADA DOS BOIS         -10.36         -36.92           MALHADOR         -10.66         -37.30           MARUIM         -10.74         -37.09         X           MOITA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.04         -37.57           MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DE LOURDES         -10.48         -37.20         X           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				
LARANJEIRAS				v
MACAMBIRA         -10.67         -37.55           MALHADA DOS BOIS         -10.36         -36.92           MALHADOR         -10.66         -37.30           MARUIM         -10.74         -37.09         X           MOITA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.04         -37.57           MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DE LOURDES         -10.48         -37.20         X           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				
MALHADA DOS BOIS         -10.36         -36.92           MALHADOR         -10.66         -37.30           MARUIM         -10.74         -37.09         X           MOITA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.04         -37.57           MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DE LOURDES         -10.48         -37.20         X           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				Λ
MALHADOR         -10.66         -37.30           MARUIM         -10.74         -37.09         X           MOITA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.04         -37.57           MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				
MARUIM         -10.74         -37.09         X           MOITA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.04         -37.57           MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04         NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64         PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73         PIRAMBU         -10.71         -36.84				
MOITA BONITA         -10.59         -37.35           MONTE ALEGRE DE SERGIPE         -10.04         -37.57           MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04         NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64         PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73         PIRAMBU         -10.71         -36.84				Y
MONTE ALEGRE DE SERGIPE         -10.04         -37.57           MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				Λ
MURIBECA         -10.40         -36.96           NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				
NEOPOLIS         -10.33         -36.61         X           NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				
NOSSA SENHORA APARECIDA         -10.38         -37.47           NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				X
NOSSA SENHORA DA GLORIA         -10.21         -37.44         X           NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				
NOSSA SENHORA DAS DORES         -10.48         -37.20         X           NOSSA SENHORA DE LOURDES         -10.07         -37.04         X           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				X
NOSSA SENHORA DE LOURDES         -10.07         -37.04           NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84				
NOSSA SENHORA DO SOCORRO         -10.86         -37.09         X           PACATUBA         -10.50         -36.64           PEDRA MOLE         -10.62         -37.68           PINHAO         -10.57         -37.73           PIRAMBU         -10.71         -36.84		-10.07	-37.04	
PACATUBA -10.50 -36.64 PEDRA MOLE -10.62 -37.68 PINHAO -10.57 -37.73 PIRAMBU -10.71 -36.84		-10.86		X
PEDRA MOLE -10.62 -37.68 PINHAO -10.57 -37.73 PIRAMBU -10.71 -36.84				
PINHAO -10.57 -37.73 PIRAMBU -10.71 -36.84		-10.62		
PIRAMBU -10.71 -36.84	PINHAO			
POCO REDONDO -9.85 -37.69 X	PIRAMBU	-10.71		
	POCO REDONDO	-9.85	-37.69	X
POCO VERDE -10.74 -38.15 X	POCO VERDE	-10.74	-38.15	X
PORTO DA FOLHA -9.92 -37.37 X	PORTO DA FOLHA	-9.92	-37.37	X
PROPRIA -10.22 -36.83 X	PROPRIA	-10.22	-36.83	X
RIACHUELO -10.73 -37.20		-10.73	-37.20	
RIBEIROPOLIS -10.54 -37.43 X	RIBEIROPOLIS	-10.54	-37.43	X
ROSARIO DO CATETE -10.69 -37.04			-37.04	
SALGADO -11.03 -37.48				
SANTA ROSA DE LIMA -10.63 -37.22		-10.63	-37.22	
SANTANA DO SAO FRANCISCO -10.28 -36.62				
SANTO AMARO DAS BROTAS -10.78 -37.03				
SAO CRISTOVAO -10.96 -37.16 X				X
SAO DOMINGOS -10.80 -37.57				
SAO FRANCISCO -10.35 -36.88				
SAO MIGUEL DO ALEIXO -10.40 -37.37				
SIMAO DIAS -10.75 -37.82 X				X
SIRIRI -10.60 -37.11				
TELHA -10.20 -36.88	TELHA	-10.20	-36.88	

Fonte: Elaboração própria

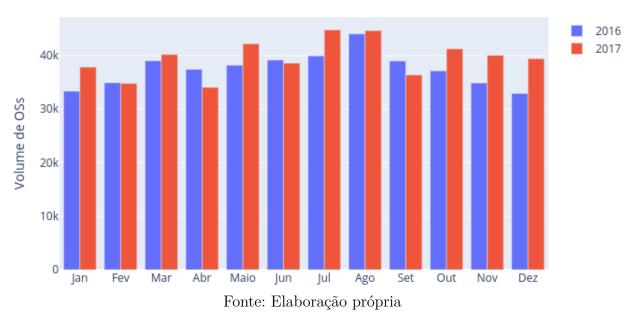
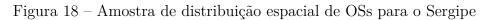
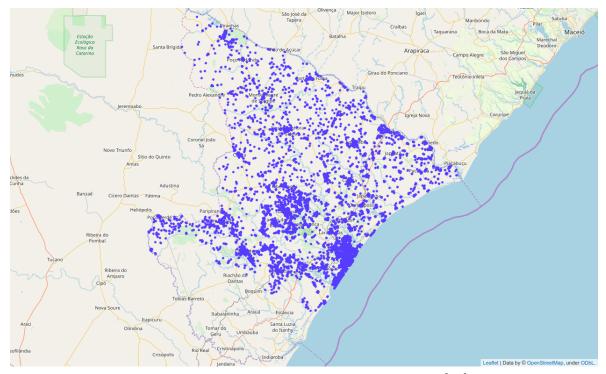


Figura 17 – Volume de OSs para o Sergipe





Fonte: Elaboração a partir da ferramenta [93]

Para fins de simplificação, as OSs foram separadas em 3 categorias: emergenciais, programadas reguladas e programadas não reguladas. As emergenciais são as OSs que precisam ser atendidas o mais breve possível. Dentro das programadas, existem aquelas que podem gerar compensações, mas têm um prazo maior para atendimento [94], diferente das emergenciais, que, a partir de três minutos sem o fornecimento de energia, começa-se a apuração do tempo em que o cliente ficou desligado. Esta apuração é contabilizada nos indicadores individuais para cálculo de compensações.

### 5.1.3 Clientes e Eletricistas

Em relação aos clientes, os dados fornecidos contêm informações de grupo de fornecimento de tensão (tensão contratada), a qual localidade o cliente pertence, limites dos indicadores de continuidade, dentre outras informações. Esses dados são necessários para a estimativa das compensações por cliente e localidade. Além dos clientes, o quantitativo de eletricistas por base também é um dado de entrada do algoritmo. As informações de eletricistas são utilizadas para contabilizar a quantidade de eletricistas novos e/ou demitidos por base. A tabela 2 apresenta a quantidade de eletricistas para as localidades que possuem base.

Tabela 2 – Quantitativo de eletricistas por base

NOME_LOCALIDADE	QTD_ELETRICISTAS		
ARACAJU	103		
BARRA DOS COQUEIROS	3		
NOSSA SENHORA DO SOCORRO	13		
ITABAIANA	25		
CARIRA	2		
FREI PAULO	2		
RIBEIROPOLIS	3		
LAGARTO	18		
POCO VERDE	3		
SIMAO DIAS	4		
MARUIM	17		
CARMOPOLIS	4		
LARANJEIRAS	3		
NOSSA SENHORA DAS DORES	17		
CANINDE DE SAO FRANCISCO	4		
GRACHO CARDOSO	2		
NOSSA SENHORA DA GLORIA	15		
POCO REDONDO	3		
PORTO DA FOLHA	4		
PROPRIA	17		
AQUIDABA	2		
NEOPOLIS	4		
SAO CRISTOVAO	20		
ITAPORANGA D AJUDA	4		
ITABAIANA II	5		
Total	297		
D + D11 ~	, .		

Fonte: Elaboração própria

Os eletricistas podem ser terceiros ou próprios. Os eletricistas terceiros podem ser utilizados durante períodos específicos do ano. Isto confere maior flexibilidade ao tomador

de decisão, dado que o processo de contratação e demissão de eletricistas próprios é mais custoso. Nas simulações e estudos realizados foram considerados somentes dois perfis: próprio e terceiro. No entanto, o modelo é capaz de lidar com outros perfis. Caso o usuário deseje, é possível criar um perfil específico, considerando por exemplo, funcionários menos capacitados e que, portanto, apresentam menor custo de manutenção. Assim, o modelo minimiza os custos com eletricistas, com base na previsão de demanda de serviço anual, levando em consideração os perfis disponíveis e garantindo que o quantitativo proposto de eletricistas será suficiente para atendimento da demanda prevista, respeitando todas as restrições e premissas adotadas na modelagem do problema.

### 5.2 Resultados

Esta seção traz os resultados e análise crítica dos mesmos. Primeiro é feita uma comparação entre duas meta-heurísticas: MOPSO e NSGA-II. Em seguida, os resultados da combinação da meta-heurística com o modelo de programação matemática são expostos, destacando as contribuições observadas com a inclusão do modelo de PLIM.

Em relação aos parâmetros utilizados nos algoritmos meta-heurísticos, as tabelas 3 e 4 mostram os valores utilizados em cada parâmetro, onde nPop é o número de partículas utilizadas. Estes parâmetros foram definidos empiricamente, dado que não há uma metodologia definida para especificá-los. O coeficiente de inércia w utilizado no MOPSO é um número aleatório, e muda a cada iteração.

Tabela 3 – Parâmetros do MOPSO

Parâmetro	Valor
$c_1$	1,5
$c_2$	1,5
nPop	50
$\overline{w}$	Aleatório $\in [0,1]$

Fonte: Elaboração própria

Tabela 4 – Parâmetros do NSGA-II

Parâmetro	Valor
Taxa de mutação	0,02
Taxa de recombinação	0,7
nPop	50

## 5.2.1 Comparação entre MOPSO e NSGA-II

A fim de comparar as duas abordagens, o número de iterações e número de partículas utilizados em cada algoritmo foi o mesmo. A partir disso, duas simulações diferentes foram realizadas: uma com 100 iterações e 20 partículas e outra com 250 iterações e 50 partículas. Os resultados são apresentados a seguir.

#### 5.2.1.1 Caso 1: 100 iterações e 20 partículas

Neste caso o algoritmo NSGA-II encontrou soluções melhores que o MOPSO, ou seja, soluções que dominam aquelas encontradas pelo MOPSO, conforme se observa na figura 19. Nesta figura o eixo Investimento representa a soma das despesas com OPEX e CAPEX. No entanto, o NSGA-II encontrou apenas 6 soluções, contra 16 soluções encontradas pelo MOPSO. Além disso, houve pequena diversificação nas soluções encontradas pelo NSGA-II, enquanto que o MOPSO conseguiu encontrar soluções mais diversificadas.

440k
420k
89
400k
360k
7.5M
8M
8.5M
9M
9.5M
10M
Investimento (R\$)

Figura 19 – Comparação entre MOPSO e NSGA-II: 100 iterações e 20 partículas

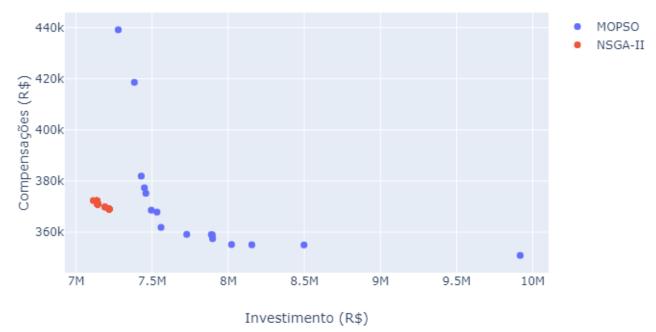
Fonte: Elaboração própria

#### 5.2.1.2 Caso 2: 250 iterações e 50 partículas

Neste caso, tanto o número de iterações quanto o número de partículas foram aumentados. A figura 20 apresenta o resultado. O número de soluções encontradas em relação ao caso 1 foi o mesmo para ambos os algoritmos. A diferença observada entre este caso e o caso anterior foi em relação à diversificação das soluções encontradas. No caso do NSGA-II, houve menor diversificação ainda, isto é, as soluções encontradas apresentam

custos muito próximos quando comparadas entre si. O MOPSO conseguiu melhorar a frente de Pareto em relação ao caso 1, além de manter a diversidade nas soluções encontradas. As figuras 21 e 22 demonstram a evolução de ambos os algoritmos nos dois casos apresentados.

Figura 20 – Comparação entre MOPSO e NSGA-II: 250 iterações e 50 partículas



NSGA-II\_100\_Iterações
NSGA-II\_250\_Iterações
NSGA-II\_250\_Iterações
7.2M 7.4M 7.6M

Custos

Figura 21 – Evolução do NSGA-II para diferentes números de iterações

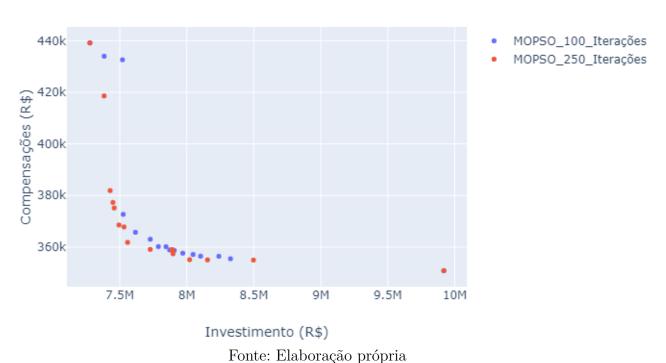


Figura 22 – Evolução do MOPSO para diferentes números de iterações

Como foi possível observar na análise gráfica, o MOPSO apresentou um desempenho melhor em relação ao NSGA-II. Apesar de o NSGA-II haver encontrado soluções melhores em termos teóricos, em termos práticos, pode ser que estas soluções não sejam viáveis. Por outro lado, o MOPSO foi capaz de oferecer maior variedade nas soluções encontradas. Além disso, houve uma evolução da frente de Pareto quando aumentou-se o número de partículas e iterações. Por esses motivos o MOPSO foi selecionado como uma das ferramenta para resolução do problema apresentado neste trabalho.

## 5.2.2 Comparação entre MOPSO e MOPSO modificado

Após a comparação entre as duas meta-heurísticas na seção anterior, foi incorporado ao MOPSO o modelo de PLIM, com o objetivo de otimizar ainda mais o processo de busca por meio da proposição de um algoritmo memético. Esta seção irá apresentar os resultados do algoritmo memético (MOPSO e PLIM), destacando as vantagens observadas na agregação das duas técnicas. Esta análise, no entanto, também incluirá as análises de viabilidade e o segundo modelo de PLIM, apresentado na metodologia, que serve para um dimensionamento mais preciso dos eletricistas.

O MOPSO foi executado com os mesmos parâmetros apresentados na tabela 3, enquanto que o algoritmo memético foi executado com apenas 20 iterações e 10 partículas. A figura 23 apresenta a variação do número de soluções no repositório de soluções do MOPSO ao longo das iterações. Observa-se que em alguns momentos o número de soluções aumenta e em outros diminui. Isto porque ao longo do processo iterativo o algoritmo pode encontrar novas soluções que dominem as soluções existentes no repositório. Ao fim das 250 iterações o MOPSO terminou com um total de 22 soluções no repositório. De forma semelhante, a figura 24 traz o mesmo gráfico para o algoritmo memético. Neste caso, a variação observada apenas aumenta o número de soluções no repositório, isto porque com o auxílio do modelo de PLIM as soluções encontradas são soluções ótimas. Outro ponto interessante é que ao fim da primeira iteração do algoritmo memético, já havia 26 soluções no repositório, ou seja, com apenas uma iteração o número de soluções encontradas foi maior do que aquele observado com o MOPSO. A tabela 5 contém dados comparativos entre as duas abordagens.

Tabela 5 – Dados comparativos entre as duas abordagens

Abordagem	Quantidade		Tempo de simulação (min.)		
Abordagem	Iterações	Partículas	Soluções	Tempo de simulação (mm.	
MOPSO	250	50	22	28,3	
MOPSO+PLIM	20	20	94	45,2	

Fonte: Elaboração própria

Conforme observa-se na tabela 5, apesar de o algoritmo memético levar maior tempo de execução, o número de soluções encontradas foi consideravelmente superior

22 20 20 18 8 90 16 14 90 12 10 50 100 150 200 250 Iterações

Figura 23 – Evolução do repositório do MOPSO

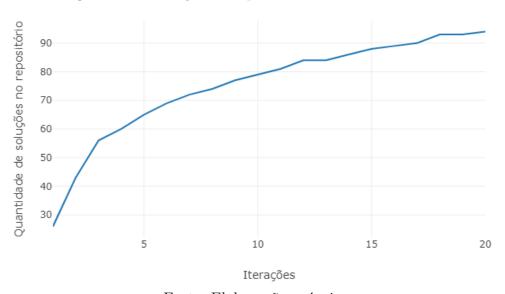


Figura 24 – Evolução do repositório do MOPSO+PLIM

(aproximadamente 4 vezes maior), comparado com a meta-heurística. Além disso, as soluções encontradas pelo algoritmo memético dominam aquelas encontradas pelo MOPSO, conforme apresentado na figura 25.

500k
480k
480k
440k
420k
8.4M
8.6M
8.8M
9M
9.2M
9.4M
Investimento (R\$)

Figura 25 – Frentes de Pareto iniciais

O conjunto de soluções apresentadas na figura 25 contém as soluções antes do cálculo do número de eletricistas com o modelo de PLIM. Após a atualização de todas as soluções, a figura 26 apresenta as novas frentes de Pareto, com as referidas soluções, para as duas abordagens. Observa-se que algumas soluções deixaram de compor as frentes. Isto porque após a atualização com o número mais preciso de eletricistas, essas soluções deixaram de ser não dominadas, sendo então retiradas da frente de Pareto. Os dados relativos às frentes de Pareto atualizadas são mostrados na tabela 6.

480k 480k 460k 420k 20M 25M 30M 35M 40M Investimento (R\$)

Figura 26 – Frentes de Pareto atualizadas

Tabela 6 – Dados comparativos após atualização das frentes de Pareto

Abordagem	Quantidade de soluções após atualização	Tempo de atualização (horas)
MOPSO	14	1,2
MOPSO+PLIM	56	5,2

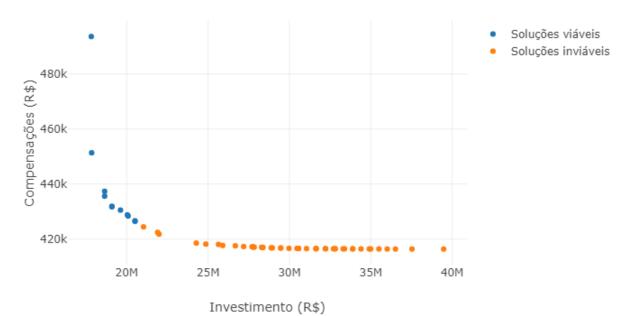
Apesar de levar mais tempo no processo de atualização das soluções, a abordagem com algoritmo memético ficou com 56 soluções, contra 14 do MOPSO. Além disso, apenas uma solução foi dada como viável dentre as soluções encontradas pelo MOPSO, enquanto que a abordagem híbrida forneceu 11 soluções viáveis.

Por fim, avaliando-se apenas as soluções da abordagem híbrida, a figura 27 mostra um gráfico destacando as soluções qualificadas como viáveis. O critério de viabilidade diz que uma solução é viável quando os custos de operação (estimados) são menores quando comparados com custos de operação atuais (estimados). Assim, a metodologia de viabilidade considera a redução dos custos operacionais e calcula o tempo (payback) para amortizar o custo de investimento (CAPEX). As soluções dadas como inviáveis, como se observa no gráfico da figura 27, são soluções que apresentam maior redução das compensações e, portanto, são soluções para as quais se espera maior redução dos indicadores individuais DIC e DMIC, no entanto, apesar de otimizar os indicadores de qualidade, essas são soluções que requerem maior investimento, isto é, contratação de mais eletricistas e instalação de novas bases. As soluções que foram apresentadas como viáveis não apresentaram muita variação em relação à configuraçao atual de bases e eletricistas da concessionária. A tabela 7 traz as soluções qualificadas como viáveis, além do caso real, para comparação. Nesta tabela estão indicados o payback descontado (estimativa), quantidade de eletricistas sugeridos e quantidade de bases sugeridas.

Tabela 7 – Tabela com soluções viáveis

Cenário	Quantidade		Payback descontado (anos)
Cenario	Eletricistas	Bases	1 ayback descontado (anos)
Atual	297	25	-
Sugestão 1	275	21	0,458418
Sugestão 2	276	21	0,471007
Sugestão 3	286	23	0,641964
Sugestão 4	286	23	0,64244
Sugestão 5	293	24	0,837109
Sugestão 6	293	24	0,837035
Sugestão 7	300	25	1,257264
Sugestão 8	306	26	2,138669
Sugestão 9	308	26	2,310033
Sugestão 10	314	27	8,354633
Sugestão 11	314	27	8,361899

Figura 27 – Frente de Pareto com viabilidade por solução



## 6 Conclusões e Trabalhos Futuros

Este trabalho apresentou um modelo de alocação de bases e dimensionamento de equipes, com uma modelagem voltada para o sistema de distribuição de energia elétrica, considerando suas características e restrições. Parte do conteúdo apresentado é resultado de um projeto de P&D, que tem por objetivo desenvolver uma ferramenta para apoio no planejamento da distribuição de energia elétrica.

De acordo com a pesquisa de estado da arte, não foram encontrados trabalhos que abordem o problema de forma multiobjetiva, agregando os diferentes horizontes de planejamento em uma única simulação. O modelo apresentado neste trabalho faz alocação de bases e dimensionamento de equipes simultaneamente. Posteriormente, faz-se uma estimativa mais precisa do número de eletricistas para as soluções encontradas, com auxílio de um modelo de programação linear inteira mista. O problema foi tratado de forma multiobjetiva, visando considerar a diminuição dos índices de continuidade e prover uma gama de soluções, que possibilitem uma melhor análise na etapa de planejamento.

Em relação às duas técnicas meta-heurísticas que foram comparadas, o MOPSO teve melhor desempenho em relação à diversidade de soluções, além de ter encontrado maior número de soluções. O NSGA-II apresentou melhores resultados em termos de custo, mas com menor número de soluções e menor diversificação das mesmas, quando comparado ao MOPSO. Aumentando-se o número de iterações o MOPSO também apresentou melhor evolução da frente de Pareto, em termos de número e diversidade das soluções. Outro ponto a se destacar é que o MOPSO possui menos parâmetros a serem especificados, pois este é um dos desafios trazidos por técnicas meta-heurísticas, não havendo uma metodologia definida para a estimação de seus parâmetros.

Dado o melhor desempenho do MOPSO para o problema apresentado, foi incorporado à sua estrutura um modelo de programação linear inteira mista, com o objetivo de otimizar o algoritmo na busca por soluções ótimas. A integração das duas abordagens trouxe duas principais vantagens quando comparada com a abordagem puramente metaheurística: possibilita encontrar maior número de soluções e, produz uma frente de Pareto dominante, quando comparada com a frente gerada pelo MOPSO. O tempo necessário para simulação, no entanto, é mais demorado, visto que para cada solução gerada pelo MOPSO, é necessário rodar o modelo mono objetivo de PLIM. Este tempo pode variar para cada caso. O estudo de caso apresentado neste trabalho, por exemplo, foi feito considerando-se o estado do Sergipe, que em comparação com outros territórios, apresenta pequena área geográfica. Conforme aumenta-se o problema, isto é, com maior número de localidades, torna-se mais difícil tanto para meta-heurística quanto para a técnica de programação

matemática encontrar boas soluções em tempo computacional aceitável. Ainda assim, a ferramenta apresenta-se bastante útil para estudos de planejamento, dado que um estudo para alocação de novas bases não é feito com a mesma frequência que um estudo de dimensionamento de equipes, o qual é resolvido muito mais rapidamente quando não se considera a otimização do posicionamento de bases. Ressalta-se também que o modelo de posicionamento de bases e dimensionamento de equipes apresentado neste trabalho possui robustez para considerar diferentes perfis de equipe (eletricistas), sendo possível especificar quais serviços o eletricista é capaz de executar, considerando desta forma a qualificação da mão de obra técnica, que se traduz em diferentes custos para a concessionária.

Uma inclusão importante na metodologia deste trabalho é o impacto do posicionamento das bases nos indicadores individuais de continuidade do fornecimento de energia elétrica, que geram encargos da ordem de milhões de reais todos os anos às distribuidoras. Com a análise multiobjetiva, o tomador de decisão dispõe de uma gama de soluções com diferentes impactos nos indicadores de qualidade e, a partir disso, pode estudar melhor qual ou quais soluções são factíveis de acordo com a disponibilidade de recursos para investimento e com os interesses da concessionária. Por fim, ressalta-se que a ferramenta apresentada neste trabalho deve ser enxergada como um instrumento de apoio à tomada de decisão a longo e médio prazos. Os benefícios para as distribuidoras podem ser qualificados através da minimização de custos operacionais e da melhoria dos indicadores de qualidade, os quais representam uma estimativa dos ganhos de confiabilidade do sistema. Particularmente no Brasil, se estes indicadores não forem respeitados, a companhia de distribuição corre o risco de perder o direito de concessão do serviço de distribuição de energia elétrica.

A metodologia apresentada neste trabalho considera o impacto do posicionamento de bases nos indicadores de qualidade. O autor deixa como sugestão para trabalhos futuros o estudo do impacto do dimensionamento das equipes nesses indicadores, pois a disponibilidade de equipes também exerce influência sobre a qualidade do serviço, dentre outros fatores. Além disso, outro desafio é determinar o número ótimo de localidades para dado território. A própria concessionária possui uma divisão, mas não há uma metodologia definida para responder se a divisão apresentada pela concessionária é a mais eficiente. Uma divisão mais adequada do território possibilita ao algoritmo encontrar soluções melhores. O problema de divisão terriorial pode ser classificado como um problema de clusterização, motivando o desenvolvimento de novas metodologias.

- [1] K. Navjot, S. Gurdip, M. Bedi, and B. Tejpal, "Evaluation of customer interruption cost for reliability planning of power systems in developing economies," *International Conference on Probabilistic Methods Applied to Power Systems*, 2004.
- [2] L. Yanling, B. Zhaohong, and Q. Aici, "A review of key strategies in realizing power system resilience," *Global Energy Interconnection*, vol. 1, pp. 70–78, 2018.
- [3] L. Cheng-Ching, "Distribution systems: Reliable but not resilient? [in my view]," *IEEE Power and Energy Magazine*, vol. 13, pp. 93–96, 2015.
- [4] N. Safaei, D. Banjevic, and A. K. S. Jardine, "Workforce planning for power restoration: An integrated simulation-optimization approach," *Trans. Power Syst.*, vol. 27, no. 1, pp. 442 – 449, 2012.
- [5] F. Qiu and P. Li, "An integrated approach for power system restoration planning," *Proc. IEEE*, vol. 105, no. 7, pp. 1234–1252, 2017.
- [6] V. Olga P. and S. Francisco, "Analysis of major blackouts from 2003 to 2015: Classification of incidents and review of main causes," *The Electricity Journal*, vol. 29, no. 7, pp. 42–49, 2016.
- [7] R. Campbell, "Weather-related power outages and electric system resiliency," Library of Congress, Congressional Research Service, Tech. Rep., 01 2013.
- [8] Agência Nacional de Energia Elétrica, "Indicadores de compensação de continuidade," p. 65, 2018. [Online]. Available: http://www.aneel.gov.br/indicadores-de-compensação-de-continuidade
- [9] —, "Informações gerenciais," 2018. [Online]. Available: http://www.aneel.gov.br/documents/656877/14854008/Boletim+de+Informa%C3%A7%C3%B5es+Gerenciais+-+3%C2%BA+trimestre+de+2018/9658018c-b292-4e62-5612-02452e28e959
- [10] A. Froger, M. Gendreau, J. E. Mendoza, Éric Pinson, and L.-M. Rousseau, "Maintenance scheduling in the electricity industry: A literature review," *Eur. J. Oper. Res.*, vol. 251, no. 3, pp. 695 706, 2016.
- [11] N. Perrier, B. Agard, P. Baptiste, J.-M. Frayret, A. Langevin, R. Pellerin, D. Riopel, and M. Trépanier, "A survey of models and algorithms for emergency response logistics in electric distribution systems part i: Reliability planning with fault considerations," Comput. Oper. Res., vol. 40, no. 7, pp. 1895–1906, 2013.

[12] B. Yanling, L.and Zhaohong and Q. Aici, "A review of key strategies in realizing power system resilience," *Global Energy Interconnection*, vol. 1, no. 1, pp. 71–78, 2018.

- [13] H.-C. Huang, L.-H. Lee, H. Song, and B. T. Eck, "SimMan A simulation model for workforce capacity planning," *Comput. Oper. Res.*, vol. 36, no. 8, pp. 2490 – 2497, 2009.
- [14] G. Willis, S. Cave, and M. Kunc, "Strategic workforce planning in healthcare: A multi-methodology approach," Eur. J. Oper. Res., vol. 267, no. 1, pp. 250 263, 2018.
- [15] D. G. Mogale, M. Kumar, S. K. Kumar, and M. K. Tiwari, "Grain silo location-allocation problem with dwell time for optimization of food grain supply chain network," *Transp. Res. Part E Logist. Transp. Rev.*, vol. 111, pp. 40 69, 2018.
- [16] N. Perrier, B. Agard, P. Baptiste, J.-M. Frayret, A. Langevin, R. Pellerin, D. Riopel, and M. Trépanier, "Models and methods for emergency response logistics in electric distribution systems," Second International Workshop on Successful Strategies in Supply Chain Management, pp. 57–68, 2009.
- [17] Y. Nemati, M. Madhoshi, and A. S. Ghadikolaei, "The effect of sales and operations planning (S&OP) on supply chain's total performance: A case study in an iranian dairy company," *Comput. Chem. Eng.*, vol. 104, pp. 323 – 338, 2017.
- [18] F. Quesnel, G. Desaulniers, and F. Soumis, "A new heuristic branching scheme for the crew pairing problem with base constraints," *Comput. Oper. Res.*, vol. 80, pp. 159 – 172, 2017.
- [19] M. Othman, N. Bhuiyan, and G. J. Gouw, "Integrating workers' differences into workforce planning," *Comput. Ind. Eng.*, vol. 63, no. 4, pp. 1096 1106, 2012.
- [20] D.-H. Lee, "Resource-based task allocation for multi-robot systems," *Robot. Auton.* Syst., vol. 103, pp. 151 161, 2018.
- [21] Agência Nacional de Energia Elétrica, "Qualidade do serviço." [Online]. Available: http://www.aneel.gov.br/qualidade-do-servico2
- [22] G. Fetter and T. Rakes, "Incorporating recycling into post-disaster debris disposal," Socio-Economic Planning Sciences, vol. 46, no. 1, pp. 14 – 22, 2012, special Issue: Disaster Planning and Logistics: Part 1.
- [23] X. Zhao, X. Zhao, Q. Shen, J. Yang, W. Yang, and X. Xie, "Application of particle swarm optimization algorithm in area target fire assignment," in 2017 9th International Conference on Modelling, Identification and Control (ICMIC), 2017, pp. 770–775.

[24] Bazargan-Lari, Gupta, and Young, "A simulation approach to manpower planning," in *Proceedings of the 2003 Winter Simulation Conference*, 2003., vol. 2, 2003, pp. 1677–1685 vol.2.

- [25] A. Elkhyari and A. Bellabdaoui, "Combining constraint programming and genetic algorithm for dynamic scheduling problems," in 2017 International Colloquium on Logistics and Supply Chain Management (LOGISTIQUA), 2017, pp. 19–24.
- [26] S. D. Thompson and W. J. Davis, "An integrated approach for modeling uncertainty in aggregate production planning," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 20, no. 5, pp. 1000–1012, 1990.
- [27] A. Azadeh, M. H. Farahani, H. Eivazy, S. Nazari-Shirkouhi, and G. Asadipour, "A hybrid meta-heuristic algorithm for optimization of crew scheduling," *Applied Soft Computing*, vol. 13, no. 1, pp. 158 164, 2013.
- [28] A. Prasad, A. Maeder, K. Samdanis, A. Kunz, and G. Velev, "Enabling group communication for public safety in lte-advanced networks," *Journal of Network and Computer Applications*, vol. 62, pp. 41 52, 2016.
- [29] S. Bojic, M. Martinov, D. Brcanov, D. Djatkov, and M. Georgijevic, "Location problem of lignocellulosic bioethanol plant - case study of serbia," *Journal of Cleaner Production*, vol. 172, pp. 971 – 979, 2018.
- [30] C. Ortiz-Astorquiza, I. Contreras, and G. Laporte, "Multi-level facility location problems," *European Journal of Operational Research*, vol. 267, no. 3, pp. 791 805, 2018.
- [31] R. Z. Farahani, M. SteadieSeifi, and N. Asgari, "Multiple criteria facility location problems: A survey," *Applied Mathematical Modelling*, vol. 34, no. 7, pp. 1689 1709, 2010.
- [32] T. S. Hale and C. R. Moberg, "Location science research: A review," *Annals of Operations Research*, vol. 123, no. 1, pp. 21–35, Oct 2003.
- [33] S. Gollowitzer, B. Gendron, and I. Ljubić, "A cutting plane algorithm for the capacitated connected facility location problem," *Computational Optimization and Applications*, vol. 55, no. 3, pp. 647–674, Jul 2013.
- [34] J. V. den Bergh, J. Beliën, P. D. Bruecker, E. Demeulemeester, and L. D. Boeck, "Personnel scheduling: A literature review," *European Journal of Operational Research*, vol. 226, pp. 367–385, 2013.

[35] A. P. Iannoni and R. Morabito, "Otimização da localização das bases de ambulânciass e do dimensionamento das suas regiões de cobertura em rodovias," *Production*, vol. 18, pp. 47 – 63, 00 2008.

- [36] C. Stummer, K. Doerner, A. Focke, and K. Heidenberger, "Determining location and size of medical departments in a hospital network: A multiobjective decision support approach," *Health Care Management Science*, vol. 7, no. 1, pp. 63–71, Feb 2004.
- [37] J. S. Wu, T. E. Lee, C. T. Tsai, T. H. Chang, and S. H. Tsai, "A fuzzy rule-based system for crew management of distribution systems in large-scale multiple outages," in 2004 International Conference on Power System Technology, 2004. PowerCon 2004., vol. 2, 2004, pp. 1084–1089 Vol.2.
- [38] Rodrigo José Pires Ferreira, "Modelos de decisão para dimensionamento de equipes de manutenção," 2006.
- [39] A. A. F. Fini, A. Akbarnezhad, T. H. Rashidi, and S. T. Waller, "Dynamic programming approach toward optimization of workforce planning decisions," *Journal of Construction Engineering and Management*, vol. 144, no. 2, p. 04017113, 2018.
- [40] P. D. Bruecker, J. V. den Bergh, J. Beliën, and E. Demeulemeester, "Workforce planning incorporating skills: State of the art," *European Journal of Operational Research*, vol. 243, no. 1, pp. 1 16, 2015.
- [41] M.-J. Yao and K. J. Min, "Repair-unit location models for power failures," *IEEE Trans. Eng. Manag.*, vol. 45, pp. 57–65, 1998.
- [42] A. Berg and H.-J. Haubrich, "Calculation of cost-minimal resources for the operation of electrical networks," *International Conference on the European Electricity Market*, vol. 5, pp. 1–5, 2008.
- [43] S. Wang, B. R. Sarker, L. Mann, and E. Triantaphyllou, "Resource planning and a depot location model for electric power restoration," Eur. J. Oper. Res., vol. 155, pp. 22–43, 2004.
- [44] B. Sedaghat and S. H. Hosseini, "Maintenance crew placement for reliable distribution network: Using 'geographic information systems," *Asia-Pacific Power and Energy Engineering Conference*, pp. 1–6, 2010.
- [45] B. R. Sarker, L. Mann, E. Triantaphyllou, and e S. Mahankali, "Power restoration in emergency situations," *Comput. Ind. Eng.*, vol. 31, pp. 367–370, 1996.
- [46] A. Koc, A. Singhee, H. Wang, A. Sabharwal, R. Mueller, and G. Labut, "Optimal spatio-temporal emergency crew planning for a distribution system," *IEEE Power Energy Society General Meeting*, pp. 1–5, 2015.

[47] N. Perrier, B. Agard, P. Baptiste, J.-M. Frayret, A. Langevin, R. Pellerin, D. Riopel, and M. Trépanier, "A survey of models and algorithms for emergency response logistics in electric distribution systems. part ii: Contingency planning level," Comput. Oper. Res., vol. 40, no. 7, pp. 1907–1922, 2013.

- [48] C. Boonmee, M. Arimura, and T. Asada, "Facility location optimization model for emergency humanitarian logistics," Int. J. Disaster Risk Reduct., vol. 24, pp. 485–498, 2017.
- [49] H. Jia, F. Ordóñez, and M. M. Dessouky, "Solution approaches for facility location of medical supplies for large-scale emergencies," Comput. Ind. Eng., vol. 52, pp. 257–276, 2007.
- [50] Y.-J. Zheng, S.-Y. Chen, and H.-F. Ling, "Evolutionary optimization for disaster relief operations: A survey," *Appl. Soft Comput.*, vol. 27, pp. 553–566, 2015.
- [51] N. Perrier, A. Langevin, and J. F. Campbell, "A survey of models and algorithms for winter road maintenance. part iii: Vehicle routing and depot location for spreading," *Comput. Oper. Res.*, vol. 34, pp. 211–257, 2007.
- [52] P. de Morais Oliveira Filho Filho et. all, "A comparative analysis between particle swarm optimization and mathematical programming for optimal location of maintenance facilities," *IEEE PES Innovative Smart Grid Technology Latin America*, 2019.
- [53] Agência Nacional de Energia Elétrica, "Qualidade do serviço." [Online]. Available: http://www.aneel.gov.br/qualidade-do-servico2
- [54] C. C. Coello, G. B. Lamont, and D. A. V. Veldhuizen, Evolutionary Algorithms for Solving Multi-Objective Problems. Springer Science, 2007.
- [55] R. S. Maciel, "Otimização multiobjetivo na análise da integração de geração distribuída às redes de distribuição"," Ph.D. dissertation, Universidade Estadual Paulista, 2012.
- [56] N. Barr, Economics of the welfare state. Oxford University Press, 2012.
- [57] Y. Hadas and O. Nahum, "Urban bus network of priority lanes: a combined multi-objective and multi-criteria approach," 07 2015.
- [58] P. Belfiore and L. P. Fávero, Pesquisa operacional: para cursos de engenharia, 2013.
- [59] L. F. L. Moro, "Técnicas de otimização mista-inteira para o planejamento e programação de produção em refinarias de petróleo," Ph.D. dissertation, Universidade de São Paulo, 2000.
- [60] F. A. Ficken, The simplex method of linear programming. Dove Publications, 2015.

[61] F. A. Potra and S. J. Wright, "Interior-point methods," Journal of Computational and Applied Mathematics, vol. 124, pp. 281–302, 2000.

- [62] S. Zionts, Linear and Integer Programming. Prentice-Hall, 1974.
- [63] R. Jeroslow, "Cutting-plane theory: Algebraic methods," Discrete Mathematics, vol. 23, pp. 121–150, 1978.
- [64] B. G. S. Gollowitzer and I. Ljubić, "A cutting plane algorithm for the capacitated connected facility location problem," *Computational Optimization and Applications*, vol. 55, pp. 647–674, 2013.
- [65] H. A. Taha, "Integer programming: Theory, applications and computations," ZAMM
   Zeitschrift für Angewandte Mathematik und Mechanik, vol. 57, pp. 562–563, 1977.
- [66] J. E. Beasley, Advances in Linear and Integer Programming. Clarendon Press, 1966.
- [67] IBM, "Cplex optimization studio." [Online]. Available: https://www.ibm.com/products/ilog-cplex-optimization-studio
- [68] G. optimization, "Gurobi." [Online]. Available: https://www.gurobi.com/
- [69] C.-O. Foundation, "Coin-cbc." [Online]. Available: https://projects.coin-or.org/Cbc
- [70] Érico de Oliveira Costa Zini, "Algoritimo genético especializado na resolução de problemas com variáveis contínuas e altamente restritos," 2009.
- [71] J. L. Colon and D. H. Marks, "A review and evaluation of multiobjective programing techniques," vol. 11, pp. 208–220, 1975.
- [72] L. Duckstein, New Directions in Optimum Structural Design. John Wiley and Sons, 1984.
- [73] E. Ziztler, ""evolutionary algorithms for multiobjective optimization: Methods and applications"," Ph.D. dissertation, Swiss Federal Institute of Technology Zurich, 1999.
- [74] E. de Andrade Amorim, "Fluxo de potência Ótimo em sistemas multimercados através de um algoritmo evolutivo multiobjetivo," Ph.D. dissertation, Universidade Estadual Paulista, 2006.
- [75] S. Luke, Essentials of Metaheuristics, 2nd ed. Lulu, 2013.
- [76] C. Blum and A. Roli, "Metaheuristics in combinatorial optimization: Overview and conceptual comparison," vol. 35, pp. 268–308, 2003.
- [77] J. Kennedy and R. Eberhart, "Particle swarm optimization," Proceedings of ICNN'95
   International Conference on Neural Networks, 2002.

[78] —, "A new optimizer using particle swarm theory," MHS'95. Proceedings of the Sixth International Symposium on Micro Machine and Human Science, 2002.

- [79] J. H. Holland, Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. Ann Arbor: University of Michigan Press, 1975.
- [80] C. D. G. J. S. Kirkpatrick and M. P. Vecchi, "Optimization by simulated annealing," no. 220, pp. 671–680, 1983.
- [81] F. Glover, "Tabu Search—Part I," ORSA Journal on Computing, vol. 1, no. 3, pp. 190–206, Aug. 1989. [Online]. Available: http://pubsonline.informs.org/doi/abs/10. 1287/ijoc.1.3.190
- [82] M. Dorigo and G. D. Caro, "Ant colony optimization: a new meta-heuristic," Proceedings of the 1999 Congress on Evolutionary, 1999.
- [83] K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A fast and elitist multiobjective genetic algorithm: Nsga-ii," *IEEE Transactions on Evolutionary Computation*, vol. 6, 2002.
- [84] C. A. C. Coello and M. S. Lechuga, "Mopso: A proposal for multiple objective particle swarm optimization," *Proceedings of the 2002 Congress on Evolutionary Computation.* CEC'02 (Cat. No.02TH8600), 2002.
- [85] D. E. Goldberg, Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley Longman Publishing Company, 1989.
- [86] D. T. Dongshu Wang and L. Liu, "Particle swarm optimization algorithm: an overview," Soft Computing, vol. 22, 2018.
- [87] H. A. da Silva, "Algoritmo de otimização multinível aplicado a problemas de planejamento de redes," Ph.D. dissertation, Pontifícia Universidade Católica, 2012.
- [88] Agência Nacional de Energia Elétrica, "Qualidade da energia elétrica." [Online]. Available: http://www.aneel.gov.br/documents/656827/14866914/M%C3%B3dulo\_8-Revis%C3%A3o\_10/2f7cb862-e9d7-3295-729a-b619ac6baab9
- [89] —, "Indicadores individuais de continuidade por município." [Online]. Available: http://www.aneel.gov.br/limites-dos-indicadores-de-continuidade-por-município
- [90] —, "Tempo de atendimento às ocorrências emergenciais." [Online]. Available: http://www.aneel.gov.br/tempo-de-atendimento-as-ocorrencias

[91] —, "Qualidade da energia elétrica," pp. 79–83. [Online]. Available: http://www.aneel.gov.br/documents/656827/14866914/M%C3%B3dulo\_8-Revis%C3%A3o\_10/2f7cb862-e9d7-3295-729a-b619ac6baab9

- [92] PyPI, "Pulp." [Online]. Available: https://pypi.org/project/PuLP/
- [93] Leaflet, "Folium." [Online]. Available: https://python-visualization.github.io/folium/
- [94] Agência Nacional de Energia Elétrica, "Qualidade do atendimento comercial." [Online]. Available: https://www2.aneel.gov.br/area.cfm?idArea=745&idPerfil=2