



## **Gestão de recursos energéticos em Smart-grid, considerando incertezas**

**WANDERLEY PARIS JUNIOR**

julho de 2024

# **Gestão de recursos energéticos considerando métricas de risco e incertezas**

**Wanderley Paris Junior**

**Dissertação para obtenção do Grau de Mestre em  
Engenharia Eletrotécnica, Área de Especialização em  
Sistemas Elétricos de Energia**

**Orientador: Dr. Bruno Canizes e Dr. Rubiara Cavalcante Fernandes**

**Coorientador: Dr. João Soares**

**Júri:**

Presidente:

Professor Doutor Fernando Maurício Teixeira de Sousa Dias, Instituto Superior de Engenharia do Porto

Vogais:

Doutor Bruno Miguel da Rocha Canizes, Instituto Superior de Engenharia do Porto

Doutora Tayenne Dias de Lima, Instituto Superior de Engenharia do Porto

Professor Doutor Rubiara Cavalcante Fernandes, Instituto Federal de Santa Catarina

Professor Doutor Ricardo Luiz Alves, Instituto Federal de Santa Catarina



Dedico este trabalho aos meus pais, pelo suporte incondicional ....



# Resumo

Nos últimos anos, as redes elétricas tradicionais passaram por uma transformação significativa, evoluindo para sistemas massivamente distribuídos com a integração de diversos tipos de recursos energéticos. A crescente penetração desses recursos distribuídos, especialmente os renováveis, introduz elevados níveis de variabilidade e incertezas nos sistemas elétricos, aumentando os desafios operacionais das redes. Diante desse cenário, as novas tecnologias associadas às Smart grids têm demonstrado a capacidade de criar um ambiente orientado ao mercado, apto a lidar com a alta penetração desses recursos e com a nova dinâmica do consumo de energia. No entanto, para uma operação eficiente e econômica do sistema, são necessárias ferramentas adequadas de gerenciamento de recursos energéticos. Neste contexto, este trabalho propõe duas metodologias para resolver o problema de gerenciamento de recursos energéticos em diferentes horizontes temporais. A primeira metodologia desenvolve um modelo estocástico baseado em uma métrica de risco para o horizonte do dia seguinte. Para isso, um conjunto de cenários é gerado por meio da Simulação de Monte Carlo. Para avaliar o risco, é utilizado a métrica *Conditional Value-at-Risk*, visando tornar a resposta do modelo mais segura e robusta diante de eventos extremos. A segunda metodologia propõe um modelo determinístico para o horizonte Intra Diário (hora seguinte), utilizando como ponto de partida a resposta do modelo do dia seguinte baseado no risco. Este modelo prevê um mercado local de energia como estratégia para satisfazer a equação de balanço energético, permitindo ao agregador recorrê-lo para satisfazer suas demandas interna. As metodologias serão testadas em uma rede distribuição real de 180 barramento, com alta penetração de recursos distribuídos. Serão previstos casos para diferentes níveis de exposição ao risco do agregador e erros de previsão dos recursos. Os resultados obtidos demonstram que o modelo para o dia seguinte, baseando no risco, é capaz de realizar decisões de agendamento não apenas com base no custo esperado, mas também considerando a mitigações dos riscos de eventos extremos. É observado reduções de custo de 12,60% na ocorrência de cenários críticos. Em relação ao modelo Intra Diário, os resultados obtidos permitem observar os impactos dos erros de previsão que próximo ao horizonte de operação, bem como os benefícios que são ofertados pelos sistemas de armazenamento de energia e o mercado local, sendo observados reduções de 3% a 19% no custo do agregador.

**Palavras-Chave:** Aversão ao risco, Agregadores, *Conditional Value-at-Risk*, Gestão de recursos energéticos dia seguinte, Gestão de recursos energéticos Intra Diário, Gestão de risco,



# Abstract

*In recent years, traditional electrical grids have undergone significant transformation, evolving into massively distributed systems with the integration of various types of energy resources. The increasing penetration of these distributed resources, especially renewables, introduces high levels of variability and uncertainties into power systems, thereby escalating the operational challenges of the grids. Against this backdrop, new technologies associated with smart grids have demonstrated the capability to create a market-oriented environment, capable of handling the high penetration of these resources and the new dynamics of energy consumption. However, for efficient and economic system operation, appropriate energy resource management tools are required. In this context, this study proposes two methodologies to solve the energy resource management problem across different time horizons. The first methodology develops a stochastic model based on a risk metric for the day-ahead horizon. For this purpose, a set of scenarios is generated through Monte Carlo Simulation. To evaluate the risk, the Conditional Value-at-Risk metric is used, aiming to make the model's response safer and more robust against extreme events. The second methodology proposes a deterministic model for the intra-day (next-hour) horizon, using as a starting point the response from the day-ahead risk-based model. This model envisions a local energy market as a strategy to satisfy the energy balance equation, allowing the aggregator to utilize it to meet internal demands. The methodologies will be tested on a real 180-bus distribution network with a high penetration of distributed resources. Cases will be projected for different levels of aggregator risk exposure and resource forecast errors. The obtained results demonstrate that the day-ahead risk-based model is capable of making scheduling decisions not only based on expected cost but also considering the mitigation of risks from extreme events, showing cost reductions of 12.60% in critical scenarios. Regarding the intra-day model, the results allow for observing the impacts of forecast errors close to the operational horizon, as well as the benefits offered by energy storage systems and the local market, with observed cost reductions for the aggregator ranging from 3% to 19%.*

**Keywords:** *Risk aversion, Aggregators, Conditional Value-at-Risk, Energy resources management day-ahead, Energy resources management intraday, Risk Management*



# Agradecimentos

Em primeiro, agradeço ao Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina (IFSC) pela formação acadêmica de excelência que me foi proporcionada através, principalmente, de seu corpo docente. Agradeço também ao Instituto Superior de Engenharia do Porto (ISEP/IPP) que, através do acordo internacional de Dupla Titulação e de seu corpo docente me proporcionaram um aprendizado técnico e social inenarrável. Agradeço ainda ao Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento (GECAD) pela estrutura proporcionada para o desenvolvimento de trabalhos voltados à pesquisa.

Gostaria de expressar meus sinceros agradecimentos ao Dr. Eng. Bruno Canizes, orientador desta dissertação. Aprecio profundamente sua constante disponibilidade, suas valiosas orientações e dicas ao longo do desenvolvimento deste trabalho. Sou especialmente grato pela sua confiança, persistência e paciência que demonstrou em momentos que eu estava perdido.

Não posso deixar de agradecer aos meus orientadores Dr. Eng. Rubiara Cavalcante Fernandes e Dr. Eng. João Soares, pelo apoio, organização e revisão deste trabalho.

Certamente agradeço muito aos colegas Me. Eng. José Almeida e Me. Eng. Fábio Castro pelo suporte valioso sempre que precisei. Agradeço a postura profissional e empenho desprendido para contribuir com o presente trabalho.

Gostaria de agradecer também a todos os meus colegas e amigos, os que me acompanham desde o começo e os que encontrei ao longo do caminho.

Aos meus pais, a Sra. Margarete Madalena e ao Sr. Wanderley Paris, dedico imensa gratidão e carinho por sempre me apoiar, acreditar em mim, me guiar e incentivar a seguir em frente. Sem eles nada seria possível, e por isso eu sou profundamente grato.

Também agradeço a Paola Maltauro e sua família, pela torcida e apoio em momentos que precisei.



# Índice

<b>1</b>	<b>Introdução</b>	<b>21</b>
1.1	Motivações	21
1.2	Objetivos	22
1.3	Publicações	22
1.4	Organização do documento	23
<b>2</b>	<b>Estado da arte</b>	<b>25</b>
2.1	Gestão de recursos energéticos	25
2.2	Smart grid	31
2.3	Geração distribuída	32
2.4	Veículos elétricos	37
2.5	Sistema de armazenamento de energia elétrica	42
2.6	Resposta à demanda	45
2.7	Métrica de risco	48
2.7.1	Definições teóricas	48
2.7.2	Exemplos de aplicações	51
2.8	Aspectos conclusivos	53
<b>3</b>	<b>Metodologia</b>	<b>55</b>
3.1	Metodologia 1 - Dia seguinte baseado no risco	55
3.1.1	Técnica de Otimização	61
3.1.2	Geração de cenários	63
3.2	Metodologia 2 - Intra diário	66
3.3	Aspectos conclusivos	71
<b>4</b>	<b>Casos de Estudos</b>	<b>73</b>
4.1	Rede de Distribuição	73
4.2	Casos de Estudo - Problema do dia seguinte	76
4.3	Casos de Estudos - Intra Diário	77
<b>5</b>	<b>Resultados</b>	<b>81</b>
5.1	Problema do dia seguinte baseado no risco	81
5.2	Problema do Intra diário	91
5.3	Aspectos conclusivos	101
<b>6</b>	<b>Conclusões</b>	<b>103</b>
6.1	Conclusões Finais	103

6.2	Trabalho Futuros .....	106
<b>7</b>	<b>Referências .....</b>	<b>108</b>

# Índice de Figuras

Figura 1 – Tipos de tecnologias de GD .....	33
Figura 2 – Classificação dos sistemas descentralizados .....	35
Figura 3 – Estoque global de VEs em determinadas regiões 2010 a 2022 .....	38
Figura 4 – Serviço fornecidos pelo VEs .....	40
Figura 5 – Custo total VS CVaR ( $\alpha = 0,99$ ) .....	52
Figura 6 – Diagrama da metodologia proposta DS .....	56
Figura 7 - Representação do VaR, CVaR e Zex .....	60
Figura 8 - Representação de árvore de cenários .....	64
Figura 9 - Diagrama da metodologia proposta ID .....	66
Figura 10 - Diagrama unifilar da rede de 180 barramentos.....	74
Figura 11 - Previsão de preços do mercado grossista e fornecedor externo .....	75
Figura 12 - Previsão da demanda de energia e da geração eólica e fotovoltaica.....	75
Figura 13 – Comportamento CVaR em relação $\beta$ e $\alpha$ .....	83
Figura 14 – Comportamento do CVaR ( $\beta$ ) x FO .....	84
Figura 15 - Comportamento do CVaR ( $\beta$ ) x Zex.....	85
Figura 16 – Custo esperado por cenários.....	85
Figura 17 – Escalonamento dos recursos – geração - $\alpha = 90\%$ e $\beta = 1$ .....	86
Figura 18 – Escalonamento dos recursos – cenário 40 - $\beta = 0$ .....	87
Figura 19 – Escalonamentos dos recursos – cenário 40 – $\alpha = 99\%$ e $\beta = 1$ .....	87
Figura 20 - Escalonamentos dos recursos – cenário 40 – $\alpha = 95\%$ e $\beta = 1$ .....	88
Figura 21 – Escalonamentos dos recursos – cenário 40 – $\alpha = 90\%$ e $\beta = 1$ .....	88
Figura 22 - Escalonamentos dos recursos – cenário médio – $\alpha = 99\%$ e $\beta = 1$ .....	90
Figura 23 - Escalonamentos dos recursos – cenário médio – $\alpha = 99\%$ e $\beta = 0$ .....	90
Figura 24 – FO ID x Erros de previsão na demanda – 0% flexibilidade .....	91
Figura 25 – FO ID x Erros de previsão na ofertada – 0% flexibilidade .....	92
Figura 26 – FO ID x Erros de previsão na demanda – 10% flexibilidade .....	93
Figura 27 – Escalonamento recursos ID - caso 06.....	93
Figura 28 - FO ID x Erros de previsão na oferta – 10% flexibilidade .....	94
Figura 29 - FO ID x Erros de previsão na demanda – 25% flexibilidade.....	95
Figura 30 - FO ID x Erros de previsão na oferta – 25% Flexibilidade.....	95
Figura 31 - FO ID x Erros de previsão na demanda – c. máximo – 0% Flexibilidade.....	96
Figura 32 - Escalonamento recursos ID – c. máximo - caso 02 .....	96
Figura 33 – FO ID x Erros de previsão na oferta – c. máximo – 0% flexibilidade .....	97
Figura 34 - FO ID x Erros de previsão na demanda – c. máximo – 10% Flexibilidade .....	97
Figura 35 - FO ID x Erros de previsão na oferta – c. máximo – 10% Flexibilidade .....	98
Figura 36 - FO ID x Erros de previsão na demanda – c. mínimo – 0% Flexibilidade.....	98
Figura 37 - Escalonamento recursos ID – c. mínimo - caso 02.....	99
Figura 38 - FO ID x Erros de previsão na oferta – c. mínimo – 0% Flexibilidade.....	100
Figura 39 - FO ID x Erros de previsão na demanda – c. mínimo – 10% Flexibilidade.....	100
Figura 40 - FO ID x Erros de previsão na oferta – c. mínimo – 10% Flexibilidade.....	101



# Índice de Tabelas

Tabela 1 – Resumo da literatura – GRE.....	29
Tabela 2 – Resumo da literatura - GD .....	36
Tabela 3 – Resumo literatura - VEs .....	38
Tabela 4 – Resumo da literatura - SAE.....	44
Tabela 5 – Resumo de literatura - RD .....	47
Tabela 6 – Resumo da literatura – Métricas de risco.....	50
Tabela 7 – Resultados gerais do modelo ID com base no risco .....	51
Tabela 8 – Resumo das propostas para o problema GRE .....	53
Tabela 9 – Metodologia de criação de cenário extremos.....	65
Tabela 10 – Características dos recursos energéticos – DS .....	76
Tabela 11 – Casos de estudo metodologia 01 .....	76
Tabela 12 – Características dos recursos energéticos – ID .....	77
Tabela 13 – Estudos de casos problema ID.....	78
Tabela 14 – Cenário de exposição ao risco – ID.....	80
Tabela 15 – Tempo de execução e uso de memória.....	81
Tabela 16 – Resultados dos resultados para o problema do DS.....	82
Tabela 17 – Resumo das restrições de geração não despacháveis – cenário 40.....	89



# Acrónimos e Símbolos

## Lista de acrónimos e siglas

<b>CVaR</b>	<i>Conditional value-at-risk</i>
<b>RD</b>	Resposta a demanda
<b>DS</b>	Dia seguinte
<b>FO</b>	Função Objetiva
<b>GD</b>	Geração distribuída
<b>GRE</b>	Gerenciamento de recursos energéticos
<b>ID</b>	Intra Diário
<b>LP</b>	Programação linear
<b>MINLP</b>	Programação não-linear inteira mista
<b>MILP</b>	Programação linear inteira mista
<b>MLE</b>	Mercado local de energia
<b>MSC</b>	Simulação de Monte Carlos
<b>MT</b>	Média tensão
<b>PSO</b>	<i>Particle Swarm Optimization</i>
<b>RED</b>	Recurso distribuído
<b>SAE</b>	Sistema de armazenamento de energia
<b>SG</b>	<i>Smart grid</i>
<b>UC</b>	Unidade consumidora
<b>VaR</b>	<i>Value-at-risk</i>
<b>VE</b>	Veículo elétrico

## Lista de conjuntos

$\Omega_{DG}^d$	Conjunto de geradores despacháveis
$\Omega_{DG}^{nd}$	Conjunto dos geradores renováveis (não despacháveis)

## Lista de parâmetros

$\beta$	Nível de aversão ao risco (nível de exposição ao risco)
$\alpha$	Nível de confiança
$T$	Número total de períodos de otimização
$\Delta t$	Corresponde cada período de tempo (neste caso a 1 hora)
$\eta_{VE/ESS}$	Eficiência de carga e descarga dos VEs e/ou SAEs
$N_{sp}$	Número de fornecedores externos
$N_s$	Número de cenários
$\pi$	Probabilidade de ocorrência de cada cenários
$N_{VE}$	Número de estações de carregamento de VEs
$N_e$	Número de baterias de armazenamento
$N_l$	Número total de cargas
$N_i$	Número total de geradores distribuídos
$P_{LoadDR}^{Max}$	Máxima potência ativo de redução de carga RD (MW)
$VE_{Disch/Charglimit}^{Max}$	Limites máximo de descarga e carga dos VEs (MW)
$ESS_{Disch/Charglimit}^{Max}$	Limites máximo de descarga e carga dos SAEs (MW)
$C_{DG}$	Preço da energia dos geradores distribuídos (u.m/MWh)
$C_{ext}$	Preço da energia do fornecedor externo (u.m/MWh)
$C_{LoadDR}$	Preço pela redução da carga (u.m/MWh)
$C_{ENS}$	Preço pela carga não suprida (u.m/MWh)
$C_{RDG}$	Preço pela restrição de geração (u.m/MWh)
$ESSC_{Disch}$	Preço da energia fornecida pelo SAE (u.m/MWh)
$VEC_{Disch}$	Preço da energia fornecida pelos VE (u.m/MWh)

$MP$	Preço da energia no mercado grossista (u.m/MWh)
$MLE$	Preço da energia no mercado local (u.m/MWh)
<b>Lista de variáveis</b>	
$P_{DG}$	Potência ativa do gerador distribuído (MW)
$P_{ext}$	Potência ativa do fornecedor externo (MW)
$P_{ENS}$	Corte de carga (MW)
$P_{RDG}$	Restrição de geração (MW)
$P_{LoadDR}$	Potência ativa da redução da carga RD (MW)
$P_{buy}$	Potência ativa comprada no mercado grossista (MW)
$P_{sell}$	Potência ativa vendida no mercado grossista (MW)
$VE_{Disch}$	Potência ativa descarregada pelos VEs (MW)
$VE_{Charge}$	Potência ativa carregada pelos VEs (MW)
$E_{VE}$	Energia armazenada nos VEs (MWh)
$ESS_{Disch}$	Potência ativa descarregada pelos SAEs (MW)
$ESS_{charge}$	Potência ativa carregada pelos SAEs (MW)
$E_{ESS}$	Energia armazenada nos SAEs (MWh)
$PE$	Penalização uso sistema VEs e SAEs além dos limites (u.m/MW)
$Z^{Ex}$	Custo total esperado (u.m)
$Z_s^{tot}$	Custo esperado de cada cenários s (u.m)
$x_{VECharge}$	Binário representa a carga do VEs
$y_{VEDisch}$	Binário representa a descarga do VEs
$x_{ESSCharge}$	Binário representa a carga do SAEs
$y_{ESSDisch}$	Binário representa a descarga do SAEs
$x_{sell/buy}$	Binário representado venda/compra em um mercado
$\sigma_{VE/ESS}$	Percentual de restrição de uso dos sistemas VE e SAEs



# 1 Introdução

Este trabalho é realizado em colaboração com o centro de investigação GECAD e tem como objetivo introduzir no problema de gerenciamento de recursos energéticos (GRE) considerações de aversão ao risco operacional, por meios da aplicação de métricas de risco. Adicionalmente, é proposto um modelo de otimização exato para o problema GRE em um horizonte mais próximo a operação.

Neste primeiro capítulo é realizado uma apresentação breve do trabalho, definindo as motivações, objetivos e como o documento está estruturado. Por fim, é citados publicações derivadas deste trabalho.

## 1.1 Motivações

Os recursos energéticos renováveis apresentam alto níveis de variabilidade e incertezas quando comparadas com demais recursos convencionais. Essa imprevisibilidade deverá ser gerenciada com eficiência pelas tecnologias associadas a *Smart grid* (SG), acomodando a alta penetração dessas novas formas fontes de energia, como também a nova realidade do consumo (cargas flexíveis, baterias, veículos elétricos (VEs), microprodução local).

Essa flexibilidade exigida pela SG, pode ser fornecida por meio de agregadores de energia, em um ambiente orientado para o mercado, com uma arquitetura de controle interoperáveis dos recursos pertencentes a esse agente. Contudo, para uma operação eficiente e econômica, exigem ferramentas adequadas de GRE, capazes de lidar com o crescente número de recursos e suas incertezas. Assim, a previsão do agendamento de uso do recurso energético é uma parte indispensável de um eficiente sistema de gerenciamento de recursos, fornecendo as decisões de despacho com um dia de antecedência, e como também o custo, ou lucro esperado da operação.

Nesta problemática, a dissertação é a continuação da pesquisa apresentada em (Soares, et al., 2017), com objetivo de propor um modelo de otimização estocástico com métricas de risco,

para a gestão ótimas de recursos de um agregador, buscando um agendamento ótimo mais robusto a ocorrência de cenários extremos. Ainda nesta temática, o trabalho também irá propor um modelo de otimização exato, para a gestão ótima, considerando as incertezas dos recursos em um horizonte temporal de programação mais curto, próximo da operação, Intra Diário (ID) (para a próxima hora em intervalos de 15 minutos).

## 1.2 Objetivos

Este trabalho tem como propósito contribuir para o desenvolvimento de soluções para o problema GRE em sistemas modernos com elevados níveis de incertezas, introduzindo métricas de avaliação de risco. Deste modo objetivo principal desta dissertação é resolver o problema de GRE para um agregador em uma rede de distribuição com alta penetração geração renovável, em horizontes de tempo diferentes, minimizando os custos associados. Para tal, são definidos os objetivos:

- Caracterização e parametrização de uma rede elétrica de média tensão (MT) com elevado grau de penetração de geração distribuída (GD) eólicas, fotovoltaica e biomassa, sistemas de armazenamento de energia (SAEs), VEs, contratos de resposta a demanda (RD) e mercados locais de energia (MLE)
- Desenvolvimento de um modelo estocástico de otimização do tipo linear inteiro misto para resolução do problema de GRE no horizonte do dia seguinte (DS), baseado no risco, utilizando a métrica *Conditional Value-at-Risk* (CVaR)
- Concepção de uma modelo de otimização do tipo linear inteiro misto para solucionar o problema de GRE em um horizonte ID
- Elaboração de algoritmos em TOMLAB para resolver os problemas de otimização proposto neste trabalho
- Testes e validação dos modelos propostos, por meio de simulações utilizando ezsolver do TOMLAB como solucionador do problema de otimização.

## 1.3 Publicações

Os trabalhos realizados para esta dissertação resultaram no artigo científicos já publicado:

- B. Canizes, J. Soares, J. Almeida, W. Paris e Z. Vale, "Energy Resource Scheduling Optimization for Smart Power Distribution Grids - Hour-Ahead Horizon," 2021 IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe), Espoo, Finland, 2021, pp. 01-06, doi: 10.1109/ISGTEurope52324.2021.9640101.

E serviram os como base para a publicação do artigo:

- Bruno Canizes, João Soares, José Almeida e Zita Vale, “Hour-ahead energy resource scheduling optimization for smart power distribution networks considering local energy market,” Energy Reports, Volume 8, Supplement 3, 2022, Pages 575-582, ISSN 2352-4847, <https://doi.org/10.1016/j.egy.2022.02.253>.

## **1.4 Organização do documento**

Esta dissertação está estruturada em seis capítulos. O primeiro capítulo serve como introdução, fornecendo uma contextualização ampla do tema tratado, delineando as motivações e objetivos da pesquisa, e descrevendo a estrutura do documento.

No segundo capítulo é apresentado o estado da arte. Onde é feita uma análise detalhada do panorama atual, abordando assuntos fundamentais para a compreensão e interpretação da pesquisa em questão. Também são examinadas revisões bibliográficas relevantes sobre os vários temas investigados.

O terceiro capítulo apresenta as duas metodologias utilizadas e sua formulação matemática para resolver o problema de GRE baseado no risco e para diferentes horizontes de tempo.

No quarto capítulo, são discutidos os casos de estudos nos quais as metodologias propostas serão aplicadas. Este capítulo também detalha as simulações e testes realizados.

O quinto capítulo apresenta os resultados das simulações e testes realizados, incluindo algumas conclusões derivadas desses resultados.

Finalmente, o sexto capítulo engloba as principais conclusões do estudo, juntamente com propostas para futuras pesquisas.



## 2 Estado da arte

Este capítulo busca apresentar uma revisão do estado geral da arte em relação a GRE ótima em SG. Preferencialmente serão analisados estudos voltados para a GRE de sistemas com alta penetração de geração renovável, que considerem as incertezas relacionadas a geração renovável energia, consumo de energia, demanda dos VEs e SAEs, os preços do MLE e que contemplem mecanismo de medição dos riscos. No entanto, quando necessário, também serão abordados trabalhos com outros enfoques, a fim de fornecer um embasamento teórico que contribua para a compreensão deste trabalho.

### 2.1 Gestão de recursos energéticos

Embora a redes elétricas tradicionais seja uma solução bastante eficaz, perdurando há mais de 50 anos, o seu futuro é incerto. As redes estão evoluindo para sistema massivamente distribuído com inúmeros pontos de controle ao longo do sistema. Estas mudanças ocorrem a nível de distribuição, devido a crescente integração de novas tecnologias de geração renováveis, SAE, cargas flexíveis e VEs (Shaker Nafi, et al., 2016). A alta penetração destes recursos também traz sérios problemas para eficiência da rede, devido a volatilidade das suas incertezas, principalmente quando a produção fotovoltaica e eólica. Neste sentido, surge o conceito de GRE para monitorar e controlar todos esses recursos, de modo conferir benefícios a rede e uma justa remuneração aos investidores (Almeira, 2021).

Em (Leonori, et al., 2020), os autores destacam a importância do crescimento das microrredes de prosumidores como uma solução viável para a integração das fontes renováveis e a melhoria da eficiência energética. É ressaltado a necessidade de um sistema de gerenciamento de energia eficaz, permitindo a otimização do fluxo de energia nas redes, considerando a variabilidade das fontes de energia e as demandas dos consumidores. Os autores, indicam que modelagem dos sistemas de gerenciamento de energia baseada em técnicas de inteligência computacional e aprendizado de máquina, apresentam desempenho superior em relação à abordagem convencionais de *Rolling Time Horizon*. Porém, é destacado que a escolha da

técnica de modelagem depende do cenário operacional e das necessidades da rede, sendo necessário realizar uma avaliação cuidadosa das abordagens para determinar a melhor solução. Além disso, o estudo conclui que as técnicas de modelagem baseadas em inteligência computacional são eficazes para lidar com as incertezas e variabilidades inerentes à geração de energia a partir de fontes renováveis (Leonori, et al., 2020);

O estudo (Ramu, et al., 2023), traz uma abordagem um pouco diferente. É proposto uma técnica de gerenciamento de consumo de energia inteligente, utilizando um gerador fotovoltaico como fonte renovável. Os autores propuseram um sistema preditivo baseada em um modelo de aprendizado de máquina e de dados meteorológicos para prever um perfil de geração de um sistema fotovoltaico. Esse sistema preditivo é essencial para estimar a disponibilidade de geração fotovoltaica durante os períodos de pico de demanda, permitindo um planejamento mais eficiente em relação ao consumo de energia. Em relação ao consumo, é utilizando um algoritmo de enxame de partículas (*Particle Swarm Optimization (PSO)*) para o gerenciamento da carga elétrica levando em consideração o perfil de consumo. Os resultados, destacam a redução da demanda de pico em cerca de 10% e uma redução com os custos de energia por volta de 15%. Além disso, a técnica permitiu melhorar a utilização da energia produzida pelo sistema fotovoltaico, reduzindo a dependência da rede elétrica e dos geradores a diesel. Outro ponto destacado, é a importância da categorização das cargas elétricas do sistema, permitindo a otimização do uso de energia, a fim de reduzir a demanda de pico e contribuir para a sustentabilidade e eficiência energética da instalação.

No mesmo contexto, o trabalho (Silva, et al., 2015), aborda o desenvolvimento de uma ferramenta para o GRE em uma rede interna de distribuição de baixa tensão de um campo universitário para um futuro em que haverá uma alta penetração de recursos distribuídos (RED), tais como: geradores eólicos, fotovoltaicos e de biomassa, SAEs, parque de estacionamento VEs e sistema de controle da carga. O objetivo da ferramenta é ajudar o operador da microrrede a obter o agendamento ótimo dos recursos energéticos, de modo a minimizar os custos de operação e maximizar o seu lucro. Para tal, os autores (Silva, et al., 2015), dividem o problema em duas fases, onde na primeira fase é realizado um agendamento diário e na segunda fase é realizado um agendamento horário. A primeira fase, onde é realizado o agendamento diário, é realizada apenas uma única vez, no dia anterior a operação, nela é considerado as informações históricas de cada recurso energético para cada período de tempo  $t$ , abrangendo as 24 horas do DS. O resultado é um pré-despacho dos recursos, buscando cumprir a estratégia do operador. No dia da operação, ou seja, segunda fase, o operador deverá ajustar a programação dos recursos levando em consideração o resultado da operação do dia anterior, bem como, novas previsões dos recursos energéticos. Este ajuste na programação é importante para compensar algum desequilíbrio entre a programação real e previsão, de modo a evitar eventuais penalizações no mercado, garantindo o cumprimento de todos os contratos estabelecidos. Sendo assim, o agendamento é realizado para cada horário do período, totalizando 24 horas (Silva, et al., 2015).

O estudo (Adefarati, et al., 2021), aborda um modelo de GRE que engloba um esquema de carga dinâmica, geradores eólicos, fotovoltaicos, a diesel e SAE por baterias. Para tanto, é proposta

uma abordagem multiobjetivo que visa otimizar a eficiência operacional do sistema, reduzindo custos totais e de energia, maximizando a utilização de fontes de energia renovável. As incertezas relacionadas aos recursos são tratadas por meio cenários de demanda de carga, geração renovável e de custos de emissão e combustível, que variam de acordo com estações do ano. Como conclusão, os autores do estudo destacam que o modelo é capaz de reduzir os custos operacionais por meio da integração das fontes de energia renovável, minimizando uso de geradores diesel promovendo uma melhoria na sustentabilidade energética do sistema. Além disso, a análise das variações sazonais de carga e geração permite estratégias mais eficientes de operação da rede. Por fim, os resultados dos estudos fornecem balizadores valiosos para tomadores de decisão, como provedores de energia independente, operadores de microrredes e organizações governamentais.

No contexto do agendamento de geração, o trabalho (Guo, et al., 2022) apresenta uma abordagem focada no desenvolvimento de cronogramas de geração adequados para sistemas hidro-eólico-fotovoltaico, que incluem usinas hidroelétrica em cascata e parques eólicos e fotovoltaicas de grande escala. É proposto um modelo capaz de otimizar simultaneamente a produção hidroelétrica em cascata, o desempenho do sistema em período de pico e os riscos operacionais decorrentes das incertezas das previsões de energia eólica e solar. Para resolver o modelo, foi projetado um framework de otimização em duas camadas. Na camada externa, uma estratégia de codificação bidimensional é aplicada para garantir a constância da entrega de energia, e um algoritmo de evolução diferencial multiobjetivo é utilizado para conduzir a otimização. Na camada interna, as estratégias de distribuição de carga entre as usinas hidroelétricas em cascata são alcançadas por meio de um método que combina o coeficiente discriminante com a taxa de armazenamento relativa de água. O modelo proposto e o método de solução são testados na bacia superior do Rio Amarelo na China.

Com base nos testes realizados, os autores do trabalho (Guo, et al., 2022) concluem que a abordagem proposta pode melhorar as diretrizes para operação de curto prazo dos sistemas hidro-eólico-fotovoltaico. Além disso, são fornecidos conjuntos flexíveis de cronogramas de geração para o dia seguinte, acompanhados de indicadores de risco, sendo conveniente para os operadores de rede tomarem decisões informadas. Em comparação com um método tradicional que não considera os riscos operacionais, a abordagem proposta pode reduzir significativamente a taxa de risco abrangente em média 65%, enquanto a produção hidroelétrica em cascata e o desempenho de pico são satisfatórios.

Em (Amir, et al., 2023), no contexto de microrredes com alta integração de recursos energéticos distribuídos e SAE, os autores, propõem um modelo de gerenciamento de energia baseado em uma abordagem de despacho em duas etapas, utilizando uma variante da técnica de PSO. Na primeira etapa, é realizada a programação ótima de energia no horizonte de 24 horas, o qual, leva em consideração as previsões de geração e de consumo, restrições operacionais dos geradores renováveis e a da rede elétrica. Nesta etapa é levado em consideração as incertezas associadas a disponibilidade de energia renovável ao longo do horizonte planejado. Na segunda etapa, o despacho real é realizado, com base nos resultados obtidos da primeira etapa. Os autores, utilizam uma estratégia de despacho a cada 6 horas com base nas previsões

atualizadas e nas condições operacionais em tempo real. Deste modo, os autores (Amir, et al., 2023), concluem que está abordagem de duas etapas, combinada com a utilização de previsões e atualizações em tempo real, permite que o modelo lide de forma eficaz com as incertezas associadas a geração renovável, contribuindo para um gerenciamento mais eficiente e adaptável.

O estudo (Soares, et al., 2017), traz uma abordagem do problema de GRE em grande escala para agregadores em uma SG. Para tal, é proposto um modelo de otimização estocástica de dois estágios, que leva em consideração as várias fontes de incertezas, tais como erros de previsão das frotas de VEs, demanda de energia e perfil de geração renovável. Essas incertezas são tratadas por meio de conjunto de cenários que retratam as características probabilísticas dos dados. Estes cenários são gerados por meio da técnica de Simulação de Monte Carlos (MCS), a qual utiliza as funções distribuição de probabilidade dos erros de previsão, obtidas a partir de dados históricos. Para lidar com alta carga e complexidade computacional associada a modelagem estocástica do problema, os autores, aplicam a técnica de decomposição de Benders para resolver o modelo de otimização. A técnica, consiste em dividir o problema estocástico de dois estágios em um problema principal (problema mestre) e em vários subproblemas (problemas escravos) de menores complexidade, permitindo uma abordagem mais eficiente para resolver o problema de grande escala. Cada fase da decomposição de Benders representa um processo de otimização. No problema mestre são tomadas as decisões de alto nível, como as compras de energia dos fornecedores externos, lances ótimos no mercado grossista e o despacho dos geradores controláveis. O problema mestre é formulado de forma a otimizar as decisões globais do sistema, levando em consideração as restrições e a função objetiva (FO) do problema. Na etapa do problema escravo, são envolvidos os subproblemas associados a cada cenário estocástico considerado, onde é realizado as validações das restrições de rede para cada cenário específico, garantindo que as soluções sejam viáveis e robustas sob diferentes condições. Portanto, a decomposição de Benders é especialmente adequada para lidar com problemas que envolvem as incertezas e múltiplos cenários, pois permite a resolução iterativa dos subproblemas para cada cenário, enquanto mantém a consistência com o problema principal. Isso facilita a validação das restrições de rede para cada cenário, garantindo que a solução final seja robusta e eficaz diante das incertezas consideradas. Como resultado, os autores afirmam que o modelo proposto é capaz de lidar de forma efetiva com as incertezas e fornecer soluções eficiente para o agendamento dos recursos energético em uma SG (Soares, et al., 2017).

Ainda, sobre aplicação da técnica de decomposição de Benders, no trabalho (Soares, et al., 2016a), é apresentado sua aplicação para resolver um problema de GRE em uma rede de distribuição inteligente. O problema é formulado como programação não linear inteira mista (MINLP) em múltiplo períodos, considerando restrições de rede e a presença de diversos REDs. Neste trabalho, o problema master é formulado como um problema inteiro misto, com um conjunto reduzido de restrições técnicas, sendo responsável por tomar decisões de alto nível, já o problema escravo é formulado como não linear verificando a viabilidade técnica da solução proposta no problema mestre.

Em ambos os trabalhos, (Soares, et al., 2016a) e (Soares, et al., 2017), conclui-se que a abordagem de Benders é um método competitivo para resolver problemas de GRE de grande escalada em redes reais de distribuição de energia. Ele é capaz de reduzir o tempo computacional, obtendo soluções dentro de tempo razoável para tomada de decisão do operador da rede.

No trabalho (Almeida, et al., 2021), os autores utilizam algoritmos evolutivos e metaheurística para resolver o problema de GRE considerando múltiplos agregadores em um sistema com alta penetração de recursos renováveis e distribuídos. O problema de otimização, tem como objetivo encontrar um mínimo global para os custos associados a esses agentes, levando em considerações suas características individuais. Como em (Soares, et al., 2017), as incertezas associadas aos recursos renováveis e aos demais recursos energéticos associado ao agregador é tratado por meio cenário estocásticos gerados através da MCS, utilizando as funções de distribuição de probabilidades dos erros de previsão. Para abordar o problema de otimização, o trabalho (Almeida, et al., 2021), empregaram 3 algoritmos distintos, incluindo um algoritmo evolutivo e duas metaheurística de última geração, com intuito de comparar seu desempenho no processo de busca da solução ótima. Consequentemente, pôde-se concluir que as duas metaheurística utilizadas superaram o desempenho do algoritmo evolutivo, devido à sua maior eficácia na exploração do espaço de busca.

Abordando a mesma problemática de GRE, porém para um horizonte de tempo mais próximo a operação, o estudo (Canizes, et al., 2022) apresenta um modelo de GRE para a próxima hora (ID), levando em consideração as transações de um mercado local entre os agentes da rede. O problema é formulado como um MILP, com o objetivo de otimizar o agendamento de recursos energéticos em intervalos de resolução de 15 minutos. Para lidar com as incertezas associadas aos recursos energéticos, são propostos diversos estudos de caso, considerando diferentes níveis de erro de previsão, nos quais a solução do modelo é observada. Como resultado, os autores destacam a capacidade dos SAEs e VEs de reduzir o impacto sobre os custos do agregador em face de determinados níveis de erro de previsão (estudo de caso), ressaltando, por fim, a importância e a necessidade de ferramentas adequadas para lidar com as incertezas nos desafios de GRE.

Na Tabela 1 é apresentada um resumo da literatura revisada abordada neste tópico, sendo elencado o foco, principais objetivos, abordagem e limitações dos trabalhos.

Tabela 1 – Resumo da literatura – GRE

<b>Referência</b>	<b>Foco</b>	<b>Principais objetivos</b>	<b>Abordagem</b>	<b>Limitações</b>
(Silva, et al., 2015)	GRE	Propor uma plataforma a ser utilizada pelo agregador para realizar a GRE em um campus Universitário	Divisão em duas fases de gerenciamento: agendamento com antecedência de um dia e agendamento com antecedência de uma hora	Simplificações no tratamento das incertezas

Tabela 1 - Continua

Tabela 1 - Continuação

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Soares, et al., 2016a)	GRE	Otimizar a GRE, levando em consideração a presença de recursos energéticos distribuídos e VE	Maximização de lucros e eficiência operacional, utilizando o método decomposição de Benders	Modelo não incorpora as incertezas da produção eólica e fotovoltaica.
(Soares, et al., 2017)	GRE	Propor modelo estocástico de dois estágios para o problema de GRE	Minimização do custo total de operação, por meio decomposição de Benders	Simplificações nas equações de rede, considerado fluxo de potência CC
(Leonori, et al., 2020)	GRE	Comparar diferentes estratégias de modelo de GRE baseadas em técnicas de inteligência computacional e propor modelo de representação gráfica das configurações operacionais de uma microrrede.	Comparação de estratégias de modelagem, resultados e avaliação do desempenho de cada técnica de inteligência computacional para resolver o problema de GRE.	Estudo não prever alguns recursos controláveis, tais como estações de carregamento lento, cargas domésticas controladas e sistema bidirecionais
(Almeida, et al., 2021)	GRE	Propor modelo ótimo para GRE considerando múltiplos agregadores	Minimização os custos operacionais e maximização do lucro dos agregadores, por meio utilização de metaheurística e algoritmos evolutivos	Limitado ao horizonte do DS
(Adefarati, et al., 2021)	GRE	Propor um modelo multiobjetivo de GRE para microrrede com alta penetração de recursos distribuídos	Modelo multiobjetivo não linear capaz de minimizar o custo total, custo de energia, uso do banco de baterias e gerador diesel e maximizar relação benefício-custo e uso de energia renovável	Simplificações no tratamento das incertezas associada aos recursos renováveis
(Canizes, et al., 2022)	GRE	Apresentar um modelo de GRE para horizonte ID (uma hora à frente) considerando as transações do mercado local entre os participantes	Modelo formulado em programação linear inteira mista, resolvido de forma determinística	Não considera cenários estocásticos para incertezas dos recursos energéticos
(Guo, et al., 2022)	GRE	Propor abordagem de agendamento de geração de energia para o DS, considerando aversão ao risco, para sistema hidro-eólico-fotovoltaico	Caracterização das incertezas nas previsões energia eólica e fotovoltaica, proposição de um modelo de agendamento de geração averso ao risco, framework de otimização de duas camadas	Simplificações na distribuição de probabilidade do erro de previsão de energia eólica e fotovoltaica e sua correlação

Tabela 1 - Continua

Tabela 1 - Conclusão

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Ramu, et al., 2023)	GRE	Gerenciamento eficiente de geração fotovoltaica	Gestão pelo lado da demanda, utilizando técnicas de otimização baseada no Enxame de Partículas Binárias Reforçadas	Estudo específico para um sistema de geração e uma carga.
(Amir, et al., 2023)	GRE	Propor modelo de despacho de dois estágios para uma microrrede autônoma	Divisão do problema em duas etapas, onde na primeira é realizada previsão dos recursos energéticos e a segunda despacho real.	Simplificações na previsão dos erros.

## 2.2 Smart grid

As redes elétricas inteligentes, ou SG, representam sistemas avançados de fluxo de energia bidirecionais, capaz de autorrecuperação, adaptável, resiliente e sustentável, com capacidade de absorver as incertezas dos recursos renováveis distribuídos. No estudo (Dileep, 2020), os autores descrevem as SGs como um meio de entrega bidirecional transparente, instantâneo e sem interrupções de energia e informações, permitindo que a indústria elétrica melhore a entrega e a transmissão de energia, ao mesmo tempo em que capacita os consumidores a terem mais controle sobre suas decisões energéticas.

As SGs incorporam os benefícios das tecnologias de informação e comunicação avançadas para fornecer informações em tempo real e permitir o equilíbrio quase instantâneo entre oferta e demanda na rede elétrica. A troca bidirecional de informações entre a rede elétrica e o consumidor é uma diferença significativa entre a SG e as redes tradicionais (Dileep, 2020).

Ainda sobre o trabalho (Dileep, 2020), são elencados uma série de funções e serviços inovadores que as SGs podem fornecer:

- Troca de dados sobre geradores, consumidores e redes, e processamento desses dados por meio de tecnologia da informação. Permitindo um monitoramento e controle da rede melhorado;
- Integração de inúmeras novas instalações de geração menores, incluindo fontes de energia renováveis, como energia solar e eólica;
- Equilibrar as flutuações nos rendimentos de eletricidade que surgem como resultado do uso de energias renováveis, feito por meio do uso de SAE e programas de resposta à demanda;
- Por meio de sensores, comunicações, processamento de informações e atuadores, a concessionária pode usar um grau mais elevado de coordenação de rede para reconfigurar o sistema e evitar que as correntes de falha excedam níveis prejudiciais;

- Usando sensores, comunicações e processamento de informações sincronizados no tempo para melhorar a precisão do monitoramento e controle da rede;
- Determinação em tempo real da capacidade de um elemento para transportar carga com base em condições elétricas e ambientais. Permitindo o uso mais eficiente dos recursos da rede;
- Isolamento automático e reconfiguração de segmentos com falhas de alimentadores de distribuição ou linhas de transmissão por meio de sensores, controles, interruptores e sistemas de comunicação;
- Medição em tempo real do consumo do cliente e gerenciamento da carga por meio de sistemas de infraestrutura de medição avançada e controladores de eletrodomésticos incorporados que ajudam os clientes a tomar decisões informadas sobre o uso de energia por meio de sinais de preço em tempo real;
- Os clientes recebem informações para tomar decisões educadas sobre o uso de eletricidade. Isso ajuda a promover a eficiência energética e reduzir o consumo de energia.

Em (Zame, et al., 2018), os autores realizam uma revisão da literatura para analisar e sintetizar as informações disponíveis sobre SGs e SAE, identificando barreiras regulatórias e econômicas para sua implantação. Dentro as barreiras, vale citar as principais: falta de políticas e regulamentações claras para incentivar a adoção de SAE, falta de modelos de negócios viáveis, falta de padrões e interoperabilidade entre diferentes tecnologias de armazenamento de energia e a falta de incentivos financeiros para financiar a implantação do sistema.

## 2.3 Geração distribuída

A transição energética sustentável no século 21 demanda uma ampla renovação no setor energético. São necessárias melhorias não apenas nas produções de energia elétrica, mas também no sistema de transmissão e distribuição. Neste contexto, a GD oferece eficiência, flexibilidade e economia, sendo considerada como parte crucial de um futuro energético sustentável (Nadeem, et al., 2023).

Em (El-Khattam & M.M.A Salama, 2004), os autores destacam que a GD não é um conceito novo, mas sim uma abordagem emergente para fornecer energia elétrica no coração do sistema de energia. Depende principalmente da instalação e operação de um portfólio de unidades GD de pequeno porte, compactas, limpas e próximo a carga elétrica. Os autores realizam uma divisão entre os tipos de GD, classificando os geradores em tradicionais e não tradicionais, conforme observamos na Figura 1.

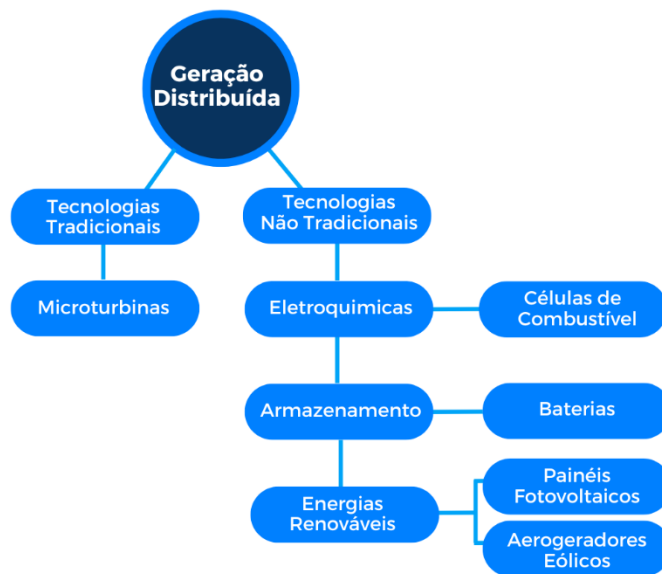


Figura 1 – Tipos de tecnologias de GD, adaptada de (El-Khattam & M.M.A Salama, 2004)

Nas tecnologias tradicionais, é destacado as microturbinas, capazes de operar com gás natural, propano e óleo combustível. Essas microturbinas são mais eficientes e apresentam emissões mais baixas em comparação com as turbinas de grande escala. Outro ponto relevante é a sua tecnologia bem consolidada das microturbinas, que permite sua inicialização fácil e requer um investimento inicial menor em comparação com outras tecnologias GD (El-Khattam & M.M.A Salama, 2004).

Por outro lado, temos as tecnologias não tradicionais, que incluem dispositivos eletroquímicos, sistemas de armazenamento e geradores renováveis. O primeiro tipo de dispositivo refere-se às células combustíveis, que continuamente convertem energia química em energia elétrica. Embora não sejam tão eficientes quanto as microturbinas, não envolvem qualquer tipo de combustão. Quanto aos sistemas de armazenamento de energia, são projetados para acumular energia durante determinados intervalos de tempo e são utilizados apenas quando necessário. Geralmente, são combinados com outras formas GD para fornecer energia em períodos de pico de demanda. Por fim, os autores do trabalho (El-Khattam & M.M.A Salama, 2004) abordam as tecnologias que utilizam fontes renováveis, como energia solar fotovoltaica e eólica. Essas tecnologias realizam a conversão direta da radiação solar e da energia cinética dos ventos, respectivamente, em energia elétrica. Apesar de terem uma eficiência baixa, contribuem para um futuro sustentável, uma vez que os recursos necessários estão sempre disponíveis ao longo do tempo.

Em (Lopes, et al., 2007), os autores elencam vários obstáculos a serem superados para a integração da GD nos sistemas elétricos de energia, tais como: falta de uma definição universalmente aceita de GD, políticas e regulamentações claras e consistentes, falta de coordenação de proteção e operação em relação aos serviços auxiliares, falta de incentivos financeiros adequados, necessidade de investimento em comunicação e ferramentas de

gerenciamento de sistemas. Esses obstáculos destacam a necessidade de uma abordagem abrangente e colaborativa para a integração da GD, envolvendo diversos atores, incluindo planejamento e operadores do sistema de energia, formuladores de política energética, reguladores e o público no geral. Os autores, também enfatizam a necessidade de uma abordagem ativa na gestão das redes de distribuição para acomodar a GD de forma eficaz.

Em (Nadeem, et al., 2023) os autores apresentam uma vasta gama de vantagem de um sistema elétrico com alta penetração da GD em relação aos sistemas centralizado, sendo elas:

- Fornece soluções energéticas econômicas devido à produção local e à redução ou eliminação de custos de transmissão e distribuição;
- Oferecer sistemas de energia mais eficientes;
- Proporcionar acesso à energia limpa para instalações rurais e remotas;
- Prover a redução dos picos de demanda de carga, complementando o fornecimento a rede;
- Melhorar a segurança energética;
- Reduz tempo de implantação e desenvolvimento de novos empreendimentos;
- Ajuda a evitar atualização e substituição dispendiosa de sistemas de transmissão e distribuição;
- Apresenta melhor resiliência contra desastres naturais, incluindo inundações e tempestades.

Em contrapartida, também é elencado em (Nadeem, et al., 2023) as desvantagens:

- Afeta a estabilidade da rede;
- Pode exigir um SAE para backup;
- Colocar questões de qualidade de energia em termos de conectividade à rede, especialmente no caso de sistemas baseados em energias renováveis.

Ainda sobre o trabalho (Nadeem, et al., 2023), é apresentando uma classificação dos sistemas descentralizados por outro ponto de vista, conforme observado na Figura 2. Em termos de conexão à rede, os sistemas podem ser classificados em dois tipos: sistemas conectados à rede (*on-grid*) e sistemas não conectados (*off-grid*). Os sistemas *on-grid* podem ser subdivididos em projetos de grande escala de utilidade, que fornecem energia para a rede local. Por outro lado, os sistemas *off-grid* são mais adequados para áreas com acesso limitado à rede, como comunidades remotas e rurais (Nadeem, et al., 2023).



Figura 2 – Classificação dos sistemas descentralizados, adaptada de (Nadeem, et al., 2023)

Em relação ao nível de aplicação, são divididos em três níveis: o nível de pequenos edifícios, nível distrital e nível urbano. Essa classificação está relacionada à abrangência do sistema, se é aplicada a edifícios individuais, bairros, comunidades ou a níveis municipais (como fazendas solares ou eólicas) (Nadeem, et al., 2023).

Por fim, a classificação por tipo de tecnologia, podendo ser não renovável ou renovável. As tecnologias não renováveis são representadas por microturbinas e geradores a diesel, que fornecem energia de forma confiável para atender totalmente à demanda de energia. Em contrapartida, as tecnologias renováveis são representadas por geradores fotovoltaicos e eólicos, onde não é possível satisfazer todos os requisitos de energia devido à intermitência, necessitando de sistemas de apoio para oferecer uma solução confiável (Nadeem, et al., 2023).

No estudo (Mazur, et al., 2023), os autores destacam que a criação de um sistema de energia localmente equilibrado sem o uso de combustíveis fósseis é uma tarefa multifacetada que requer conhecimentos interdisciplinares. Eles também ressaltam que, embora existam razões técnicas, ambientais e políticas para implementar tais soluções, atualmente não há soluções prontas e amplamente disponíveis que garantem o equilíbrio local sem o uso de combustíveis fósseis, ao mesmo tempo em que asseguram a autossuficiência energética total de uma área. É sugerido que a implantação de sistemas híbridos, que envolvem a cooperação de instalações fotovoltaicas, parque eólicos e plantas de biogás, com SAE, pode ser uma solução mais eficaz. Destaca-se que a tecnologia de armazenamento pode contribuir para o desenvolvimento desses sistemas localmente equilibrados.

Os autores de (Liu, et al., 2012), destacam que a GD renovável é incentivada e promovida em países desenvolvidos e em alguns grandes países em desenvolvimento com altas taxas de emissões de carbono, por meio de várias políticas de energia renovável e de redução de

emissões. O apoio financeiro torna-se um mecanismo comum na maioria dos países, por meio de tarifas subsidiadas e esquemas de comércio de emissão. Além disso, ressaltam que as tecnologias mais comuns de GD incluem microgeração hidroelétrica, eólica e solar, geração biomassa, cogeração de resfriamento e aquecimento combinados e geração geotérmica.

Ainda em (Liu, et al., 2012), também são discutidos os impactos da GD nos modos de despacho de sistema de energia elétrica, especificadamente o sistema de Guangdong na China. Os autores, citam que devido à natureza intermitente e variável das fontes renovável, como eólica e solar, é essencial possuir mecanismo preciso de previsão de geração, a fim de otimizar o despacho e garantir o equilíbrio entre geração e demanda. Outro ponto abordado é a integração das GD, uma vez que sua inserção pode introduzir novos desafios operacionais devido à variabilidade da geração, exigindo ajustes rápidos no despacho para lidar com flutuações na geração. Há também a necessidade de o despacho do sistema ser flexível o suficiente para acomodar as variações na geração, garantindo, no entanto, a estabilidade e confiabilidade do sistema. A incorporação de tecnologias de armazenamento de energia, como baterias e sistema de bombeamento, é discutida como meio de suavizar as flutuações e garantir a disponibilidade de energia quando necessário.

O estudo (Schäfer & Moser, 2012) destaca a importância da participação das unidades distribuídas nos mercados de energia elétrica, impulsionada pela redução dos subsídios governamentais e pela necessidade de eficiência operacional. Os autores sugerem a criação de usinas virtuais como uma possível solução para a participação dessas unidades no mercado. São destacadas três vantagens desse modelo: otimização da cobertura da carga, onde a usina virtual é integrada ao sistema de geração total e operada de forma mais eficiente para atender à carga, resultando em redução dos custos totais; participação no mercado de reserva, contribuindo para a estabilidade e confiabilidade do fornecimento de energia; e capacidade de evitar picos de demanda, reduzindo os custos de operação. O estudo também aborda uma metodologia para otimização baseada em Decomposição e Relaxamento de Lagrange, que visa encontrar a operação mais eficiente da usina virtual, considerando as restrições técnicas e de mercado, como a participação nos mercados de antecipação, do dia seguinte e de reserva. Por fim, a Tabela 2 oferece uma visão geral da literatura sobre a GD abordada neste trabalho.

Tabela 2 – Resumo da literatura - GD

Referência	Foco	Principais objetivos	Abordagem
(El-Khattam & M.M.A Salama, 2004)	GD	Apresentar uma pesquisa abrangente sobre GD e tecnologias não tradicionais como células combustíveis, destacando seus benefícios operacionais e econômicos.	Revisão bibliográfica abrangente sobre temática.

Tabela 2 - Continua

Tabela 2 - Conclusão

Referência	Foco	Principais objetivos	Abordagem
(Lopes, et al., 2007)	GD	Apresentar uma visão geral sobre integração da GD nos sistemas de energia elétrica.	Revisão abrangente das questões relacionadas à integração da GD nos sistemas de energia elétrica, com ênfase nos drivers, desafios e oportunidades.
(Liu, et al., 2012)	GD	Apresentar e discutir os impactos das GD no despacho de sistemas de energia elétrica.	Abordagem analítica e descritiva dos impactos das GD nos modos de despacho do sistema de energia elétrica, com foco na rede elétrica de Guangdong na China.
(Schäfer & Moser, 2012)	GD	Apresentar um método de otimização para simular uma usina virtual em diferentes mercados de energia elétrica.	Apresentação de opção de marketing para usinas virtuais e propor modelo otimização para determinar a operação mais eficientes e econômica de uma usina virtual.
(Mazur, et al., 2023)	Sistema locais de Energia	Objetivo é fornecer uma visão geral das tendências e desafios relacionados a criação de sistema energia localmente equilibrados.	Revisão bibliográfica abrangente sobre temática.
(Nadeem, et al., 2023)	GD	Apresentar uma revisão aprofundada dos sistemas de energia distribuídos sob as perspectivas tecnologias, aplicação e de políticas.	Revisão sistemática da literatura acerca de sistema de energia distribuído.

## 2.4 Veículos elétricos

O aumento das emissões de CO<sub>2</sub>, as mudanças ambientais drásticas e, especialmente, a escassez de combustível fósseis destacam a importância da substituição dos veículos de combustão tradicionais. Além disso, o preço dos combustíveis fósseis, como a gasolina e o petróleo, tem flutuado significativamente nos últimos anos. Diante destes fatos, a frota de VE vem se expandindo rapidamente, sendo considerado uma excelente alternativa aos veículos tradicionais (Amin Gharibi, et al., 2023).

As vendas de VEs em 2022 registraram mais um ano de recorde, mesmo diante de perturbações na cadeia de abastecimento, incertezas macroeconômicas e geopolítica, além do aumento dos preços das matérias-primas e da energia. As vendas registras, tanto do VE a baterias (BEVs) e

VE híbridos *plug-in* (PHEVs), ultrapassou a marca de 10 milhões em 2022. Esse aumento elevou o número total de VEs nas estradas do mundo para 26 milhões, representando um aumento de 60% em relação ao de 2021. Cerca de 70% da frota mundial de carros elétricos são do tipo BEVs, a Figura 3 ilustra o estoque global de VEs em determinadas regiões do mundo (International Energy Agency, 2023).




Figura 3 – Estoque global de VEs em determinadas regiões 2010 a 2022, fonte (International Energy Agency, 2023)

Diante desses números, a penetração descontrolada dos VEs pode se tornar um sério desafio para a rede elétrica, acarretando sérias dificuldades para o planejamento e operação dos sistemas de distribuição (Bañol Arias, et al., 2019). A Tabela 3, apresenta um resumo da literatura abordada sobre VEs.

Tabela 3 – Resumo literatura - VEs

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Liu, et al., 2013)	Classificação dos VEs	Discute as oportunidades e desafios de conexão VEs com a rede.	Análise de bibliografia sobre os conceitos relacionados às tecnologias e <i>frameworks</i> de conexão de VEs a rede.	Não analisa políticas e regulamentações sobre VEs.
(Soares, et al., 2016b)	Comportamento de VEs	Apresentar um <i>framework</i> para estimar os possíveis estados dos VEs, incluindo sua demanda, localização e tempo de carga, ao longo de uma SG	Por meio de simulações de MSC e lógica Fuzzy são caracterizando as incertezas, gerando cenários estocásticos para o planejamento de recursos energéticos.	Consideração de apenas frotas agregadas e não de perfis individuais.

Tabela 3 - Continua

Tabela 3 - Conclusão

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Soares, et al., 2016c)	GRE	Formulação de um modelo para programação dos recursos energéticos para o DS, considerando preço dinâmico da eletricidade para VEs.	Modelo estocástico de dois estágios, considerando as incertezas dos recursos energéticos, buscando integrar a precificação ótima para os VEs.	Alta carga computacional. Modelo tem uma grande dependência da curva oferta demanda dos VEs.
(Canizes, et al., 2019)	Comportamento de VEs	Otimização da operação de redes com alta penetração de recursos energéticos distribuídos e sistemas de carregamento de VEs.	Propor um simulador de comportamento do usuário de VEs e um modelo de precificação dinâmica e de otimização dos recursos energéticos da rede, onde objetivo é minimizar o custo de carregamentos VEs.	Poucos perfis de usuários de VE, não prevê controle sobre carga.
(Amin Gharibi, et al., 2023)	Gestão de VEs	Agendamento ótimo para carga de VEs em estacionamentos, considerando incerteza do mercado e comportamento do usuário.	<i>Framework</i> baseado em <i>deep learning</i> estruturado em três etapas: previsão do comportamento VE, preços do mercado e agendamento.	Limitações referente aos dados VEs, como horário de partida e chegada, capacidade de carregamento das baterias.
(Bañol Arias, et al., 2019)	Revisão literatura VEs	Revisão e classificação dos serviços disponíveis em VEs para o sistema de distribuição.	Levantamento bibliográfico	Não realizar uma análise de aspectos econômicos e regulatórios dos serviços.

O aumento do número de VEs e outras fontes de energia distribuída nos sistemas de energia, tem gerado grandes desafios no planejamento e operação dos sistemas de distribuição. No entanto, os VEs podem oferecer novas oportunidades à rede, fornecendo diversos serviços locais e pontuais. Neste sentido, o trabalho (Bañol Arias, et al., 2019), apresenta uma revisão e classificação dos potenciais serviços para o sistema elétrico que os VEs podem fornecer. Na Figura 4, é mostrado o resumo dos serviços que os VEs podem fornecer para as diferentes partes do sistema. Com o estudo, os autores destacam que os serviços de fornecimento de potência ativa têm alta probabilidade de implementação a curto prazo, enquanto a compensação de potência reativa pode ser implementada a médio e longo prazo. Além disso, visualizam a possibilidade da combinação dos serviços de potência ativa com o de regulação da frequência e serviços de potência reativa em condições específicas da rede.



Figura 4 – Serviço fornecidos pelo VEs, adaptada de (Bañol Arias, et al., 2019)

O artigo (Liu, et al., 2013) discute as tecnologias de conexão dos VEs à rede para carga e/ou descarga, destacando as tecnologias veículo-casa (V2H), veículo-veículo (V2V) e veículo-rede (V2G). A tecnologia V2H refere-se à capacidade de um VE fornecer energia de volta para uma residência, transformando-o não apenas em um meio de transporte, mas também em uma fonte de energia para a casa. Por outro lado, o modelo V2V possibilita a comunicação direta entre veículos e a rede elétrica, permitindo que os VEs compartilhem energia entre si, formando uma espécie de “comunidade de energia” móvel. Por exemplo, em um cenário com vários VEs conectados à mesma rede, o V2V poderia otimizar o uso e a distribuição de energia entre os VEs, reduzindo a carga do sistema e melhorando sua eficiência energética como um todo. Essa tecnologia é especialmente relevante em cenários com alta penetração de VEs.

Por fim, o V2G representa uma evolução do V2H, permitindo que os VEs forneçam energia de volta à rede quando necessário. Em vez de apenas consumir energia da rede para recarregar, os VEs podem atuar como recurso de armazenamento de energia móvel. O V2G possui o potencial de proporcionar diversos benefícios, como a redução da demanda de pico na rede elétrica, o suporte à integração de energias renováveis intermitentes, a melhoria da estabilidade do sistema elétrica e a geração de receita para os proprietários dos VEs. Essa tecnologia está alinhada com a transição para um sistema energético mais sustentável, inteligente e eficiente explorando a potência dos VEs como ativos de rede distribuição (Liu, et al., 2013).

No artigo (Amin Gharibi, et al., 2023), é discutida a temática do estacionamento de VEs, o qual possibilita um carregamento coordenados dos VEs e a participação dos estacionamentos no mercado de energia. O estudo apresenta um *framework* baseado em *deep learning* para o

agendamento ótimo de carga dos VEs em um estacionamento. O *framework* proposto é dividido em três etapas: modelagem dos parâmetros de carga dos VEs utilizando técnicas de modelagem estatísticas e de aprendizado de máquina, como CopulaGAN; previsão dos preços de mercado de energia 24 horas à frente usando uma rede neural autorregressiva; e, posteriormente, utilizando os dados das outras duas etapas, é realizado o agendamento ótimo de carga dos VEs. O CopulaGAN é uma rede neural capaz de gerar dados sintéticos semelhantes aos dados reais. Desta forma, os autores concluem que o *framework* proposto em (Amin Gharibi, et al., 2023) supera as limitações dos métodos estatísticos baseados em modelos para gerenciar as incertezas dos parâmetros dos VEs e dos preços de mercado de energia, e pode ajudar os estacionamentos a reduzirem os seus custos de carregamento de VEs.

O estudo (Soares, et al., 2016b), apresenta um método para estimar os possíveis estados dos VEs, levando em consideração a sua localização, demanda de energia e períodos de conexão à rede. Para isso, propõe-se um método de simulação de MSC e lógica Fuzzy para caracterizar a incerteza inerente dos VEs e gerar cenários estocásticos para o modelo de planejamento de recursos energético. O modelo proposto fornece informações precisas sobre localização, demanda de energia e período de conexão à rede dos VEs para as próximas 24 horas, sendo essas informações imprescindíveis para os operadores. Além disso, os autores (Soares, et al., 2016b) destacam a importância do uso de *Big Data* e sistemas eficientes de comunicação e informação para o sucesso da implementação desse tipo de modelo.

Em (Soares, et al., 2016c), é proposto uma abordagem de programação estocástica para GRE em uma rede distribuição inteligente, com o foco na maximização do lucro esperado pelo agregador de energia e na precificação ótima da energia, que influencia o comportamento dos diferentes clientes de VEs. Para tal, é desenvolvido um modelo estocástico de duas etapas. Na primeira etapa, são previstas as incertezas associadas à geração renováveis, à demanda variável e é determinada a precificação ótima para os diferentes grupos de clientes de VEs. Na segunda etapa, envolve o processo de tomada de decisão com base nas previsões da primeira etapa, com objetivo maximizar o lucro esperado do agregador de energia. Os autores concluem que a precificação ótima é uma ferramenta eficaz para influenciar o momento e a quantidade de recarga dos VEs, sem a necessidade de uma infraestrutura complexa. Além disso, essa abordagem pode ser considerada como uma maneira de lidar com a crescente demanda por mobilidade elétrica, maximizando a utilização de energias renováveis.

O artigo (Canizes, et al., 2019), apresenta uma metodologia que combina um simulador de comportamento dos VEs com um modelo de precificação dinâmica de energia baseado em preços marginais locais para otimizar a operação de um sistema com alta penetração de REDs e infraestrutura de carregamento de VEs. O simulador tem como objetivo gerar uma população realista de usuários de VEs, enquanto o modelo de precificação é empregado para minimizar as perdas de energia ao longo da rede, reduzir os custos de carregamento de VEs e aprimorar a operação do sistema.

## 2.5 Sistema de armazenamento de energia elétrica

O crescente nível de penetração de geradores renováveis, como eólicos e solares, tem dado origem a questões anteriormente menos comuns, como dificuldades no controle de flexibilidade da rede, erros de previsão de geração e eventuais picos de preço. Neste contexto, os SAEs surgem como uma possível solução ótima para mitigar estes problemas. Os SAEs permitem armazenar a energia em momentos de excesso de geração além da necessidade do sistema (consumo) e utilizá-la posteriormente, proporcionando maior flexibilidade à rede (Alhamali, et al., 2016).

Em (Belli, et al., 2016), os autores destacam que a falta de programabilidade dos geradores renováveis, como os fotovoltaicos e eólicos, pode reduzir seus benefícios econômicos e ambientais, tornando-se algo prejudicial para a rede elétrica. Neste contexto, o uso de SAE pode ajudar a aumentar o autoconsumo de energia produzida e reduzir a dependência da rede elétrica. Diante disso, os autores propõem uma metodologia de gerenciamento de armazenamento de energia renovável em múltiplos períodos, com objetivo de minimizar troca de energia com a rede elétrica e otimizar o desempenho do SAE. Para a implementação, utiliza-se um modelo de previsão de geração e carga baseada em redes neurais artificiais. Com esse modelo de previsão, são realizadas diversas simulações com objetivo de minimizar a energia total trocada com a rede, os picos de demanda de energia e a quantidade de energia trocada em um determinado período de tempo. Como resultados, a metodologia foi capaz de reduzir o pico máximo de potência trocada com a rede elétrica de 23 kW para 8 kW, demonstrando sua eficácia. Os autores destacam a importância do modelo de previsão de geração e carga para auxiliar no modelo de gerenciamento.

De acordo com o autor do trabalho (Antweiler, 2021), há três opções para lidar com o desafio da alta penetração de geradores intermitentes: fornecer capacidade de reserva suficiente para o sistema (para atender picos de consumo ou compensar a intermitência da geração), melhorar o equilíbrio da carga ao longo da rede e, por fim, implantar SAE em grande escala. Essas três opções podem ser combinadas de acordo com seus custos. Diante deste fator, o autor realiza uma abordagem teórica e empírica para avaliação da viabilidade econômica do SAE.

Além disso, o autor menciona que historicamente, o único método rentável de SAE em grande escala é o armazenamento por bombeamento hidráulico, a partir de usina hidroelétricas reversíveis (Antweiler, 2021). Além dos SAEs baseados em baterias, amplamente difundidos, o autor destaca outros sistemas como:

- Armazenamento térmico: que utiliza o calor gerado por fonte renováveis, como o sol, para aquecer um material de armazenamento, como sais fundidos, liberando o calor conforme a demanda;
- Armazenamento por compressão de ar: que comprime o ar em reservatórios subterrâneos ou tanques e o libera para acionar turbinas quando necessário;

- Armazenamento por volante de inércia: que armazena energia cinética rotacional em um volante de inércia, que pode ser liberada para fornecer energia mecânica quando necessário;
- Armazenamento por hidrogênio: que converte eletricidade excedente em hidrogênio por meio de eletrólise da água, que pode ser armazenado e posteriormente utilizado para gerar eletricidade por meio de células de combustível.

Em (Liu, et al., 2015), propõe-se o uso de rede neurais artificiais para prever a produção de energia de um gerador eólico e os preços marginais locais, juntamente com um sistema híbrido de armazenamento de energia, com objetivo de otimizar o cronograma de produção do complexo gerador eólico. O sistema híbrido de armazenamento de energia é composto por um sistema de armazenamento primário e secundário. O primário é projetado para otimizar a receita do gerador com base nas previsões de energia eólica e preços marginais locais de um dia para o outro. Por outro lado, o sistema secundário é aplicado para lidar com erros de previsão durante a operação em tempo real, especialmente em dia com picos de preço. Os autores destacam a eficácia da estratégia proposta, pois, a partir dos resultados das simulações, observaram uma melhoria na receita total da fazenda eólica e uma otimização do cronograma de produção.

O artigo (Menniti, et al., 2018), apresenta um método eficiente de gerenciamento de energia para um sistema de energia local, com ênfase na presença de SAEs. Duas abordagens são propostas: uma em tempo real e outra preditiva. A abordagem em tempo real, envolve medidas instantâneas de produção de energia renovável e consumo para gerenciar o armazenamento de energia de acordo com metas predefinidas e restrições do sistema. Por outro lado, a abordagem preditiva, utiliza modelos de previsão de produção de energia e demanda da carga para otimizar os fluxos de energia entre diferentes fontes, cargas e SAEs ao longo de vários períodos de tempo. O método em tempo real, foi implementado e testado em um campus universitário, demonstrando sua capacidade de equilibrar a geração e o consumo de energia, reduzir picos de consumo e minimizar a troca de energia com a rede. Os autores destacam, que a implementação prática do método ressaltou a importância de considerar dinâmicas como a carga da bateria e conversos de energia, bem como a incerteza na demanda de carga. Além disso, o estudo enfatizou a necessidade de ajustes contínuos no sistema de gerenciamento para lidar com variações imprevistas na geração e consumo de energia.

O estudo (Xuewei, et al., 2020) aborda a importância crucial da configuração adequada dos SAEs para mitigar as flutuações na geração de energia eólica e solar. A pesquisa examina a volatilidade inerente à geração de energia renovável, propondo métodos de configuração de SAEs com base em análises de dados históricos e simulações computacionais. Os resultados destacam a necessidade de diferentes capacidades de armazenamento para suavizar as flutuações de saída em diversos níveis de volatilidade. Além disso, o estudo enfatiza a importância crítica de avaliar os custos e os desafios práticos associados à implementação desses sistemas. Conclui-se que a integração bem-sucedida de fontes renováveis no sistema de

energia exige uma abordagem cuidadosa na configuração dos SAEs, a fim de assegurar a estabilidade e a qualidade da energia gerada.

O estudo (Cai, et al., 2022), propõe uma estratégia colaborativa para o planejamento de sistemas de energia eólica-solar-SAE, levando em consideração a evolução morfológica das redes de transmissão e distribuição. A evolução morfológica refere-se às mudanças na forma, estrutura e configuração de um sistema ao longo do tempo. No contexto das redes elétricas, essas mudanças envolvem transformações físicas e estruturais à medida que novas tecnologias, fontes de energia e demandas dos consumidores são introduzidas e integradas. Essas mudanças, podem incluir a expansão da rede, introdução de novas fontes de energia renovável, a implementação de SAEs, a modernização das infraestruturas e a melhoria da eficiência operacional. Como resultado, os autores demonstram a eficácia do modelo proposto em considerar as características estruturais das redes de transmissão e distribuição, garantindo eficiência computacional, convergência e precisão na solução. A estratégia colaborativa apresentada possui potencial para aplicação em futuras formas de rede de energia, com um maior acoplamento de informações entre as redes de transmissão e distribuição e um aumento da participação de energias limpas e SAEs (Cai, et al., 2022).

Por fim, na Tabela 4, é apresentado o resumo do conjunto de literatura que aborda diversos temas relacionados aos SAEs e analisadas neste trabalho

Tabela 4 – Resumo da literatura - SAE

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Liu, et al., 2015)	SAE	Gerenciamento de sistema de produção eólica com armazenamento híbrido, com base nas previsões de produção e custos marginais locais.	Utilização de redes neurais para previsão de produção eólica e preços marginais do mercado. E preposição de SAE com dois estágios.	Simplificações das incertezas de geração durante operação em tempo real.
(Belli, et al., 2016)	Gerenciamento de SAEs	Propor um método de gerenciamento de SAE em múltiplos períodos com o objetivo de minimizar a troca de energia com rede local.	Implementação de modelos de previsão de geração renovável e carga, utilizando Redes neurais artificiais.	Não prevê sistema de carga programável
(Menniti, et al., 2018)	Gerenciamento de energia	Aplicação método de gerenciamento de energia em um sistema local energia, com foco na presença de SAEs.	Utilização de modelos de previsão de produção de energia fotovoltaica, demanda do sistema permitindo o gerenciamento adequado SAE. O modelo é testado na prática em um campus universitário.	Simplificações nos dados de previsão de geração fotovoltaica e demanda de carga.

Tabela 4 - Continua

Tabela 4 - Conclusão

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Xuewei, et al., 2020)	SAE	Desenvolver métodos de controle de SAEs para melhorar a estabilidade e a qualidade da energia gerada a partir de fontes renováveis, contribuindo para a integração eficiente dessas fontes no sistema de energia.	Análises de dados históricos de geração de energia eólicas e solar e compreensão da volatilidade dessas fontes é proposto métodos de configuração de SAEs para suavizar as flutuações e contribuir para integração eficientes dessas fontes.	Não é abordado os desafios práticos para implementação dos sistemas propostos.
(Antweiler, 2021)	SAE	Analisar a viabilidade econômica e os benefícios de SAEs.	Abordagem teórica e analítica para explorar a viabilidade econômica dos SAEs. E modelos microeconômicos para avaliar impacto sobre previsão de preço, limites operativos e redução uso das linhas.	Não há especificações dos tipos de tecnologias de SAEs.
(Cai, et al., 2022)	SAE	Propor uma estratégia de planejamento colaborativo eólico-solar-SAE considerando a evolução da rede de distribuição e transmissão.	Desenvolvimento de um modelo de otimização cooperativa para sistemas eólicos-solar-SAE. Proposição de uma estratégia de planejamento colaborativo considerando a evolução morfológica das redes para sistemas de armazenamento de energia eólica-fotovoltaica.	Necessita de um alto tempo computacional para convergência do modelo, enriquecer cenários de aplicação de modelos.

## 2.6 Resposta à demanda

A resposta à demanda (RD) refere-se à capacidade dos consumidores de energia participarem ativamente das condições de oferta de energia, ajustando seus padrões de consumo de acordo com as necessidades do sistema elétrico. Isso implica na habilidade dos consumidores de reduzir ou deslocar o consumo de eletricidade em momentos específicos em resposta a sinais de preços ou condições de fornecimento de energia. A RD emerge como uma estratégia crucial para equilibrar a oferta e a demanda de energia em redes com alta penetração de geração renovável (Pawar, et al., 2020).

No trabalho (Pawar, et al., 2020), os autores propuseram um modelo de RD baseado em um sistema inteligente de gerenciamento de energia, que utiliza técnicas de aprendizado de máquina para prever a disponibilidade de energia. Isso permite a negociação de energia e ações de controle de carga com base nas prioridades dos consumidores. O sistema foi desenvolvido com o objetivo de otimizar o uso de energia, especialmente proveniente de fontes renováveis. Por meio desse modelo, os consumidores têm a capacidade de ajustar seus padrões de consumo de energia de acordo com as condições de fornecimento de energia, contribuindo

para a estabilidade e eficiência dos sistemas elétricos. Os autores ressaltam a relevância da gestão da demanda de energia, especialmente diante da crescente integração de fontes renováveis. Ao permitir a negociação de energia e ações de controle com base nas prioridades dos consumidores, o sistema inteligente de gerenciamento de energia demonstra o potencial para otimizar o uso de energia e aprimorar a eficiência dos sistemas elétricos.

O estudo (Ali, et al., 2023) apresenta um método que considera a RD como uma estratégia para minimizar os custos operacionais e aumentar a eficiência de microrredes integradas com fontes renováveis e SAEs. De acordo com (Ali, et al., 2023), a RD permite que operadores e consumidores ajustem parte da carga dos períodos de alto preço para os períodos de baixo preço, o que resulta em reduções de custos tanto para os operadores quanto para os consumidores. Os resultados obtidos pelos autores demonstraram uma diminuição nos custos operacionais de 2,60% em um horizonte de 24 horas e de 3,72% em um horizonte de um ano, evidenciando a eficácia do método proposto.

Em (Assad, et al., 2022), os autores destacam que nos atuais sistemas de energia desregulados, para manter o equilíbrio do sistema, existem duas abordagens principais: gestão pelo lado da oferta e gestão pelo lado da demanda. Ambas as abordagens visam otimizar a eficiência do sistema, mitigar contingências e aumentar a capacidade de carga. A gestão pelo lado da oferta busca maximizar a eficiência da rede elétrica controlando a geração e distribuição de energia, com o objetivo de atender à demanda de forma eficaz. Por outro lado, a gestão pelo lado da demanda baseia-se nos padrões de uso de eletricidade e na potência da carga em tempo real dos consumidores para ajustar a demanda de acordo com as condições do mercado e do sistema elétrico. Enquanto a gestão pelo lado da oferta está mais relacionada à infraestrutura e à operação da rede elétrica, a gestão pelo lado da demanda está vinculada ao comportamento e às escolhas dos consumidores em relação ao consumo de energia. Ambos os sistemas visam equilibrar a oferta e a demanda de energia. Em suma, uma abordagem concentra-se na disponibilidade de energia, enquanto a outra se concentra na utilização da energia, com o objetivo final de garantir a estabilidade e eficiência do sistema elétrico.

O gerenciamento do lado da demanda, envolve o planejamento, implementação e monitoramento de utilidades no sistema de distribuição em um ambiente de SG, com o objetivo de influenciar o uso de eletricidade pelos clientes produzindo mudanças desejadas na curva de consumo de energia. A integração e implementação pelo lado da demanda são possíveis várias maneiras, porém podem ser resumidas em duas categorias: programas baseados em incentivos e programas baseados em preços. A principal característica do RD baseado em preço é que os consumidores reagem rapidamente aos sinais tarifários, por outro lado, os programas baseados em incentivos, os consumidores são incentivados independentemente das tarifas de eletricidade (Panda, et al., 2023).

O trabalho (Santo, et al., 2018) descreve uma metodologia de gerenciamento ativo do lado da demanda, utilizando técnicas de otimização e inteligência artificial para diminuir os custos com energia elétrica dos consumidores residências que possuem pequenos sistemas de GD. A abordagem proposta envolve o emprego de redes neurais treinadas com dados otimizados para

administrar um SAEs, levando em conta os padrões de consumo e geração fotovoltaica. O sistema foi projetado para lidar com tarifas de eletricidade onde os preços variam conforme o horário do dia. A validação da metodologia demonstrou eficiência na redução dos custos de eletricidades para os consumidores, contribuindo assim para a gestão eficaz da demanda de energia e para a integração de fontes renováveis na rede elétrica.

O artigo (Christoforos, et al., 2022), realiza uma revisão abrangente sobre a utilização da técnica de otimização de Enxame de Partículas na programação e controle de recursos residenciais para gestão de demanda. É avaliado a eficácia e aplicabilidade da técnica de otimização em modelos envolvendo um grande número de residências e recursos, ressaltando a importância de incorporar outras fontes de energia, principalmente renováveis e SAEs. Além disso, o estudo ressalta a necessidade de desenvolver métricas abrangentes para avaliar não apenas a economia de custos, mas também os benefícios ambientais e a satisfação do usuário, visando assim aumentar o engajamento e a participação em programas de gerenciamento da demanda de energia.

Para encerrar esse tópico, é apresentado na Tabela 5, um resumo do conjunto de estudos sobre a temática de RD abordada.

Tabela 5 – Resumo de literatura - RD

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Santo, et al., 2018)	RD	Desenvolver uma metodologia para realizar a gestão ativa do lado da demanda para residências em redes inteligentes.	Desenvolver um sistema de tomada de decisão baseado em redes neurais treinadas com dados otimizados, para gerenciar os recursos reduzindo os custos do consumidor e adiando investimento na expansão da rede.	Limitações nos casos de estudos.
(Pawar, et al., 2020)	Gestão de Energia	Desenvolver um sistema inteligente de gerenciamento de energia com previsão precisa e estratégia de carga para geração renovável, baseado em IoT.	Através de um sistema de previsão precisa de energia para o próximo dia e para o mês, permitindo ao sistema negociar a energia disponível e despachar a ação de controle com base na prioridade atribuída pelo consumidor a um aparelho.	Complexidade do modelo, erros nos dados meteorológicos e confiabilidade do sistema IoT.
(Assad, et al., 2022)	RD	Fornecer uma análise crítica e abrangente dos métodos computacionais utilizados em SG, RD e otimização de recursos.	Revisão crítica da literatura existente sobre SG, RD e otimização de recursos, com foco nos métodos computacionais utilizados nessas áreas.	Revisão bibliográfica.

Tabela 5 - Continua

Tabela 5 - Conclusão

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Christoforo s, et al., 2022)	RD	O objetivo deste trabalho é avaliar diferentes métodos PSO na programação e controle de diferentes recursos energéticos residenciais.	Revisão abrangente da literatura sobre otimização de demanda residencial, com foco na técnica de otimização PSO.	Não há definição de métricas para desempenho dos métodos de agendamento de RD.
(Ali, et al., 2023)	GRE	Propor um método considerando a resposta da demanda para minimizar os custos operacionais em uma microrrede com alta penetração de geração renováveis.	Modelo de otimização para gerenciar uma microrrede isolada integrada com sistemas híbridos renováveis e de armazenamento, considerando RD para transferir pico de demanda.	Simplificações no método de fluxo de rede.
(Panda, et al., 2023)	Cargas Flexíveis	Propor um modelo de gestão ótima de carga flexíveis residências no horizonte do DS.	Modelo estocástico de comportamento da carga flexível com a integração em um modelo de múltiplos objetivos para realizar o agendamento eficiente das cargas flexíveis, considerando os benefícios de várias partes interessadas.	Trabalho não prevê outros recursos flexíveis como geração, baterias e VEs.

## 2.7 Métrica de risco

### 2.7.1 Definições teóricas

As métricas de riscos abordadas neste trabalho são comumente aplicadas na gestão de riscos financeiros, especialmente por instituições financeiras e outras organizações similares. No entanto, também são amplamente utilizadas no setor elétrico para avaliar os riscos associados as incertezas dos recursos energéticos e para gerenciar projetos complexos que envolvem diversas incertezas (Rocha, 2013).

Na gestão de risco, uma métrica amplamente utilizada é o *Value-at-Risk* (VaR). O VaR representa a perda máximo, ou seja, a pior perda, em um determinado intervalo de confiança, também conhecido como nível de confiança, representado por  $\alpha$ , ao qual um investidor estaria exposto dentro de um horizonte de tempo específico. Assim, o VaR pode ser interpretado como a quantia pela qual a perda não será excedida em  $(1 - \alpha)$  % dos cenários analisados (Rocha, 2013).

Para os autores (Almeida, et al., 2022) e (Mostafa, et al., 2016), o VaR é uma medida de risco que avalia o custo máximo esperado para um determinado nível de confiança e período. Já em (Asensio & Contreras, 2016) e (Dias de Lima, et al., 2023), o VaR é uma medida de risco que representa o limite superior para os custos esperados, conforme o intervalo de confiança. Em suma, o VaR é uma ferramenta crucial para a análise de risco, embora apresente uma limitação significativa: considera apenas os cenários extremos que podem ocorrer dentro do nível de confiança estabelecido. Isso significa que o gestor fica exposto a cenários extremos menos prováveis, que podem ocorrer além do nível de confiança estabelecido.

Assim sendo, o VaR procura resumir em um único número a perda máxima esperada dentro de um horizonte e um grau de confiança estatística. Um VaR de 95% indica que há 5 chances em 100 de que a perda seja maior do que a indicado pelo VaR no período em que foi calculado. Dessa forma, o VaR, torna-se fácil de interpretar, podendo ser entendido como: “Existe uma certeza de  $(1 - \alpha)$  % de que não haverá perdas maior que o valor VaR” (Rocha, 2013).

A determinação do VaR é relativamente simples, contanto que se conheça a distribuição probabilística dos cenários, pois, por definição, o VaR é algum quantil associado a um percentil extremo dos cenários, geralmente 1% ou 5%. Assim, pode-se calcular, o pior resultado entre os 99% dos melhores, ou o melhor entre os 1% dos piores. O valor resultante é o VaR de 1% (Rocha, 2013) e (Asensio & Contreras, 2016).

Embora o VaR seja amplamente aceito e utilizado na gestão de riscos em diversos setores, ele enfrenta várias críticas. Nos estudos (Almeida, et al., 2022) e (Dias de Lima, et al., 2023), os autores, destacam uma limitação significativa do VaR, que é a consideração apenas dos cenários extremos que podem ocorrer dentro do nível de confiança analisado. Em outras palavras, podem ocorrer situações em que as perdas superem significativamente o VaR. Isso acontece porque o VaR não leva em consideração a magnitude das perdas além do nível de confiança, resultando em uma subestimação do risco em situações raras e extremas (Asensio & Contreras, 2016). Em ambos os trabalhos analisados, essa limitação é superada utilizando uma métrica chamada de *Conditional Value at Risk*.

O CVaR, é definido como uma medida de risco que leva em consideração os cenários raros extremos que ocorrem além do nível de confiança estabelecido pelo VaR (Almeida, et al., 2022). Em uma perspectiva diferente, o CVaR representa a expectativa condicional das perdas que excedem o VaR, levando em conta a distribuição das perdas além do ponto de corte do VaR (Asensio & Contreras, 2016). Em resumo, o CVaR é um custo adicional calculado como a média ponderada das perdas dos cenários superiores ao valor de corte de VaR.

No estudo (Rocha, 2013), o autor oferece uma definição interessante de CVaR, descrevendo-o como uma medida de risco que indica a perda média que excede o VaR. Em outras palavras, o CVaR quantifica “quão” grande é, em média, o risco ao qual o gestor está sujeito. Dessa forma, podemos considerar o CVaR uma medida mais conservadora de risco em comparação ao VaR (Rocha, 2013). Enquanto o VaR responde à pergunta “Qual é a perda máxima que o gestor está

sujeito nos  $(1 - \alpha)$  % cenários? o CVaR responde à pergunta “Qual é a perda média incorrida pelo gestor nos  $\alpha$ % piores cenários?”.

Em ambos os trabalhos analisados, a métrica de risco CVaR foi incorporada à função a ser otimizada por meio da atribuição de um parâmetro denominado nível de aversão ao risco, representado por  $\beta$ . Esse parâmetro varia entre 0 e 1, indicando em percentual a posição estratégica do gestor em relação ao risco. Para  $\beta = 0$ , indica que o gestor adota uma posição neutra em relação ao risco, enquanto para  $\beta = 1$ , representa uma estratégia de aversão total ao risco (Almeida, et al., 2022) e (Asensio & Contreras, 2016). Assim, quanto maior o valor  $\beta$ , maior a preferência do gestor por estratégias mais seguras e robusta diante da ocorrência de cenários extremos.

Portanto, este parâmetro desempenha um papel crucial na formulação objetiva do problema a ser otimizado, onde a minimização da FO busca uma estratégia que equilibre o custo esperado com a métrica de risco, apresentada por CVaR (Asensio & Contreras, 2016). Na Tabela 6 é apresentando um resumo da literatura estuda sobre estema, sendo elencado os objetivos, abordagem e limitações de cada trabalho analisado.

Tabela 6 – Resumo da literatura – Métricas de risco

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Rocha, 2013)	Projetos de eficiência energética	Substituir o método mais comum e abrangente de decisão para investimento em projetos de eficiência energética no Brasil	Utilizando técnicas de representação de incertezas e métricas de risco, proem um modelo de decisão ótima para investimento.	Modelo não prevê UCs produtoras de energia e suas incertezas, e também, não é modelado as incertezas técnicas relativas à vida útil dos equipamentos
(Asensio & Contreras, 2016)	Integração de recursos energéticos renováveis em sistemas isolados	Propor um modelo estocástico para o problema <i>unit commitment</i> , levando em consideração um determinado valor mínimo de risco	Formulação de um modelo MILP incluindo CVaR	Falta da incerteza da disponibilidade das unidades geradoras, programas de RD e de SAEs
(Mostafa, et al., 2016)	Planejamento de redes de distribuição	Método baseado em risco para alocação de transformadores, considerando simultaneamente os riscos econômicos e técnicos	Formulação de um modelo MINLP, resolvido por algoritmos genéticos. As incertezas dos recursos são tratadas por meios de cenários probabilísticos.	Número reduzido de cenários. Alguns aspectos práticos de operação da rede foram simplificados, como: dispositivos de rejeição de carga, religadores e restrições de transferência de carga

Tabela 6 - Continua

Tabela 6 - Conclusão

Referência	Foco	Principais objetivos	Abordagem	Limitações
(Almeida, et al., 2022)	Otimização de recursos energéticos baseado no risco	Propor uma da estratégia de análise de risco utilizando as métricas VaR e CVaR na formulação do problema de GRE	Utilização da metaheurística distribuição marginal univariada celular com distribuição normal-cauchy	Trabalho não prevê a gestão dos recursos em horizonte mais curto, ID, onde eventos extremos podem ocorrer
(Dias de Lima, et al., 2023)	Planejamento de sistemas de distribuição de energia renovável	Propor um modelo de planejamento de longo prazo para sistemas de distribuição sustentáveis, considerando estações de carregamento de VEs e impostos sobre carbono.	Avaliação do risco sob duas óticas, custos de planejamento e imposto sobre carbono. CVaR é usado como métrica de gerenciamento de risco.	Modelo proposto é centralizado, não considerando as prioridades dos diferentes agentes do sistema de distribuição.

### 2.7.2 Exemplos de aplicações

Para exemplificar o comportamento da métrica de risco e os demais custos do agregador, vale destacar os resultados obtidos pelos autores no trabalho (Almeida, et al., 2022). O objetivo do trabalho é propor um modelo de GRE para agregadores, considerando estratégias neutras e avessa em relação ao risco. O modelo busca lidar com as incertezas e o comportamento estocástico do consumo de energia, demanda dos VEs, geração de energia renovável e dos preços do mercado energia elétrica. É utilizado a métrica de CVaR para analisar os custos associados aos piores cenários, permitindo que o agregador decida entre aceitar ou mitigar os riscos. Na Tabela 7, são apresentados os resultados gerais do modelo proposto para resolver o problema de GRE com base no risco, considerando um horizonte ID.

Tabela 7 – Resultados gerais do modelo ID com base no risco, adaptada de (Almeida, et al., 2022)

Componentes	Posição em relação ao risco	
	Neutra (u.m)	Avessa (u.m)
Custos operacionais (investimento do modelo DS)	21 485,23	22 272,89
Custo pela carga não atendida	31,02	9,23
Custo de Geração	18 283,07	19 970,01
Custo por compra no mercado	3 171,15	2 293,66
Remuneração por venda no mercado	1 494,86	956,88
Penalizações	16,00	13,00
Custo total	20 006,37	21 329,02
Custo + CVaR	29 701,23	25 576,73
Custo do pior cenário	84 232,70	40 571,52

Na transição do agregador de uma abordagem de risco neutra para uma de aversão ao risco, conforme demonstrado na Tabela 7, observa-se um aumento de 787,66 unidades monetárias (u.m) nos custos operacionais, principalmente devido ao custo de geração. Este aumento decorre da estratégia do agregador, que eleva o investimento na produção de energia para se proteger contra cenários extremos. Adicionalmente, os gastos por não atendimento da carga são reduzidos em 70% na abordagem aversa ao risco, representando uma melhoria significativa para o agregador. No entanto, o custo total sofre um aumento de 6,61% quando o agregador adota uma postura aversa ao risco. Em contrapartida, quando se analisa o custo do pior cenário, este é reduzido em aproximadamente 51% (Almeida, et al., 2022).

De acordo com (Almeida, et al., 2022), essas mudanças se explicam pela priorização da segurança e resiliência do sistema por parte do agregador, que está disposto a aumentar seus investimentos para se proteger contra eventos extremos e reduzir os custos associados a esses eventos. A redução significativa nos gastos com a carga não atendida indica que a estratégia de aversão ao risco adotada pelo agregador está sendo eficaz na mitigação de perdas em situações adversas, resultando em uma solução mais robusta e resiliente para o GRE.

Também vale destacar o trabalho (Asensio & Contreras, 2016), que tem como objetivo desenvolver um modelo estocástico para o problema de *unit commitment* em sistemas isolados com alta penetração de fontes renováveis, considerando estratégias de aversão ao risco. O trabalho aborda as dificuldades relacionadas a intermitência das fontes renováveis e como isso afeta as decisões de despacho dos geradores convencionais em sistemas isolados, os quais não possuem a mesma flexibilidade de sistemas interconectados. A introdução do CVaR no modelo, visa quantificar o risco associados às incertezas de previsão, permitindo que os tomadores de decisão compreendam melhor as implicações financeiras de suas escolhas. Deste modo ao resolver o problema para diferentes níveis de aversão e custos pôr não fornecimento de energia, é possível representar uma fronteira eficiente. Está é uma representação que mostra as combinações ideais de risco e custo esperado, permitindo aos tomadores de decisão visualizarem o *trade-off* entre o risco e custo. Na Figura 5 é apresentada a variação do CVaR em relação aos custos totais.

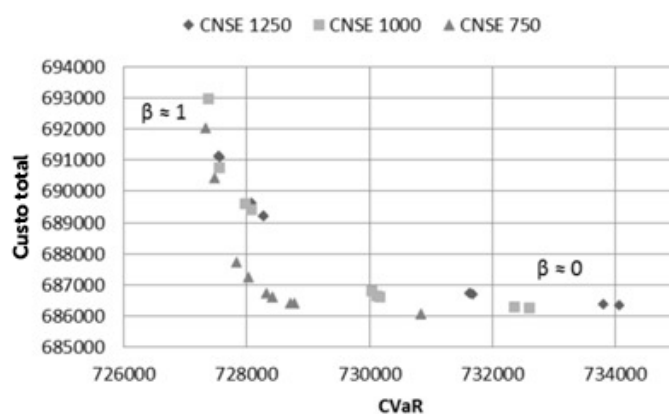


Figura 5 – Custo total VS CVaR ( $\alpha = 0,99$ ), fonte (Asensio & Contreras, 2016)

É observado que, à medida que aversão ao risco aumenta, os custos totais de despacho também. Os autores, destacam que uma exposição a um risco mais elevado ( $\beta > 0.5$ ) não proporciona benefícios adicionais em termos de CVaR ou custos totais de despacho (Asensio & Contreras, 2016).

## 2.8 Aspectos conclusivos

Neste capítulo, foram abordados diversos tópicos que destacam a importância da gestão de recursos energéticos em redes com alta penetração de REDs, especialmente VEs e SAEs.

Inicialmente, foi realizado um contexto sobre a temática de GRE, dado seu papel central neste trabalho. Para isso, foram apresentados alguns trabalhos relevantes desenvolvidos nesse conceito. Em seguida, foi introduzido o conceito de SG, destacando suas características e sua capacidade de lidar com os desafios associados à alta integração de recursos energético na rede. Posteriormente, foram abordados os temas de GDs, VEs e SAEs, discutindo vários trabalhos com o objetivo de estabelecer uma base teórica sólida para a construção do modelo de GRE, foco deste trabalho.

Os conceitos de VaR e CVaR também foram estudados, que são medidas de risco que permitem lidar com as incertezas inerente ao problema e obter uma solução robusta e segura diante dos diferentes cenários que representam as incertezas na programação dos recursos energéticos, com o menor risco possível.

Por fim, a Tabela 8 compara as principais diferenças entre os modelos propostos na literatura abordada neste capítulo com os modelos que serão propostos neste estudo.

Tabela 8 – Resumo das propostas para o problema GRE

Referências	Horizontes de Programação	Cenários estocásticos	Recursos distribuídos					Métricas de risco
			Renováveis	VEs	SAEs	DR	MLE	
(Silva, et al., 2015)	2	-	x	x	x	x	x	-
(Soares, et al., 2016a)	1	-	x	x	x	x	x	-
(Soares, et al., 2017)	1	x	x	x	x	x	x	-
(Almeida, et al., 2021)	1	x	x	x	x	x	x	-
(Adefarati, et al., 2021)	1	-	x	x	x	x	x	-
(Canizes, et al., 2022)	1	-	x	x	x	x	x	-
(Guo, et al., 2022)	1	x	x	-	-	-	x	x
(Amir, et al., 2023)	1	x	x	x	-	-	-	-

Tabela 8 - Continua

Tabela 8 - Conclusão

Referências	Horizontes de Programação	Cenários estocásticos	Recursos distribuídos					Métricas de risco
			Renováveis	VEs	SAEs	DR	MLE	
(Asensio & Contreras, 2016)	1	x	x	-	-	-	-	x
(Almeida, et al., 2022)	1	x	x	x	x	x	x	x
Este trabalho	2	Somente para o problema do DS	x	x	x	x	x	x

## 3 Metodologia

Neste capítulo, serão apresentadas as duas metodologias para resolver o problema GRE em diferentes horizontes temporais. A primeira metodologia propõe um modelo de otimização no horizonte do DS, baseado no risco, utilizando a métrica CVaR. Enquanto a segunda metodologia, propõe um modelo de otimização próximo à operação real, no horizonte ID para o mesmo problema de GRE.

### 3.1 Metodologia 1 – Dia seguinte baseado no risco

Para desenvolver um modelo de otimização baseado no risco para o problema do DS, foram utilizados como referências estudos anteriores que abordaram essa temática, particularmente os trabalhos (Soares, et al., 2017) e (Lezama, et al., 2019). A Figura 6, adaptada do trabalho (Canizes, et al., 2022), apresenta de forma gráfica o modelo que será proposto na primeira metodologia deste trabalho.

Nos estudos (Soares, et al., 2017) e (Lezama, et al., 2019), é apresentado um modelo estocástico de dois estágios para a gestão dos recursos associados a um agregador. Este modelo não apenas considera as restrições técnicas dos recursos energéticos, mas também aborda as diversas incertezas associadas ao perfil de geração renovável, comportamento da frota de VEs, demanda horaria da carga e variações nos preços do mercado de energia. Essas incertezas são tratadas por meio das construções de cenários probabilísticos. O resultado do modelo é o agendamento do uso dos recursos energéticos associado ao agregador, no contexto do dia anterior para as próximas 24 horas de operação da rede.

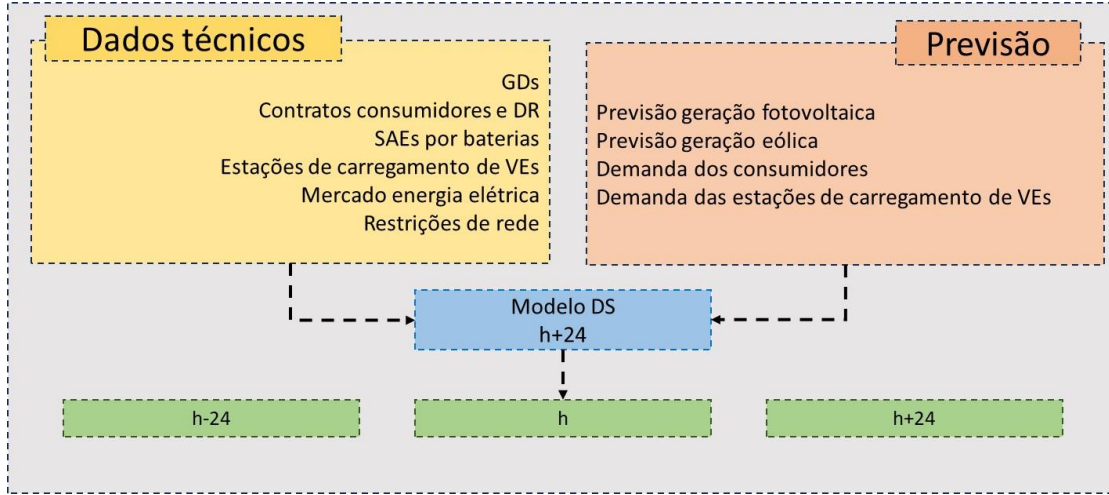


Figura 6 – Diagrama da metodologia proposta DS, adaptada de (Canizes, et al., 2022)

O objetivo do modelo é minimizar o custo total de operação do agregador, conforme representado na equação (1). No primeiro estágio de otimização, busca-se minimizar os custos dos geradores despacháveis e os gastos com fornecedores externos, conforme demonstrado na equação (3). Já o segundo estágio, equação (4), são considerados os custos associados aos geradores renováveis (não despacháveis), contratos de controle da demanda, descarga dos VEs e SAEs, bem como eventuais penalizações por restrições de geração e cargas não atendidas. Além disso, na FO, são contemplados os custos esperados das transações do mercado diário, conforme descrito na equação (5).

Na equação (1), a métrica de risco é representada por CVaR, o qual é dependente do custo esperado de cada cenário ( $Z_s^{tot}$ ), sendo  $Z^{Ex}$  é custo esperado do conjunto de todos os cenários estocástico.

$$\text{Min } OF = Z^{Ex} + \beta \cdot \text{CVaR}_\alpha(Z_s^{tot}) \quad (1)$$

$$Z^{Ex} = OC^1 + OC^2 + MT \quad (2)$$

$$OC^1 = \sum_{t=1}^T \left[ \sum_{i \in \Omega_{DG}^d} P_{DG(i,t)} \cdot C_{DG(i,t)} + \sum_{sp=1}^{N_{sp}} P_{ext(sp,t)} \cdot C_{ext(sp,t)} \right] \cdot \Delta t \quad (3)$$

$$OC^2 = \sum_{s=1}^{N_s} \sum_{t=1}^T \left[ \sum_{VE=1}^{N_{VE}} V E_{Disch(VE,t,s)} \cdot V E C_{Disch(VE,t)} + \sum_{l=1}^{N_l} P_{LoadDR(l,t,s)} \cdot C_{LoadDR(l,t)} + \sum_{i=1}^{N_i} P_{ENS(l,t,s)} \cdot C_{ENS(l,t)} + \sum_{i=1}^{N_i} P_{RDG(i,t,s)} \cdot C_{RDG(i,t)} \right] \cdot \Delta t \cdot \pi(s) \quad (4)$$

$$MT = \sum_{s=1}^{N_s} \sum_{t=1}^T [P_{buy(t)} \cdot MP_{(t,s)} - P_{sell(t)} \cdot MP_{(t,s)}] \cdot \pi(s) \cdot \Delta t \quad (5)$$

Cada estágio do modelo proposto neste trabalho desempenha um papel específico. Na primeira fase do processo de otimização, são tomadas as decisões globais do sistema, como as compras de energia dos fornecedores externos, os lances ótimos para o mercado grossista e o despacho das unidades geradoras controláveis. Já na segunda fase, as decisões são refinadas e ajustadas para cada cenário específicos, levando em consideração as restrições locais e a validação das restrições de rede para cada cenário estocástico (Soares, et al., 2017).

As variáveis de decisões da FO estão sujeitas a uma série de restrições, as quais têm como objetivo representar matematicamente o comportamento operativo do sistema, sendo elas:

**Restrições de rede:** Conforme proposto em (Soares, et al., 2017) e (Lezama, et al., 2019), será utilizado um modelo de fluxo de potência CC, conforme modelado na equação (6). A adoção desse modelo é justificada pela presença de sistemas de controle de tensão adequadamente posicionados e dimensionados ao longo da rede de distribuição analisada neste trabalho, os quais mantêm a tensão e a potência reativa dentro dos limites operacionais. Optar pelo modelo CC em detrimento do modelo de completo de fluxo de rede contribui para evitar a complexidade excessiva do modelo, tornando o computacionalmente mais viável.

Em relação às variáveis,  $P_L$  representa a potência ativa nas linhas do sistema (em MW) e  $N_L$  o número total de linhas. As barras do sistema são indexadas por  $b$  e  $w$ . A equação (7) representa o limite máximo do fluxo de transmissão admissível na linha. Supondo que o restante do sistema está conectada a barra 1 ( $b = 1$ ), é necessário subtrair do lado esquerdo da equação (6) o balanço de potência transacionada no mercado diário ( $P_{sell(t)} - P_{buy(t)}$ ) (MW) para  $b = 1$ .

$$\begin{aligned}
& \sum_{i \in \Omega_{DC}^b} (P_{DG(i,t)} - P_{RDG(i,t)}) + \sum_{ext \in \Omega_{ext}^b} P_{ext(ext,t)} \\
& + \sum_{l \in \Omega_{nl}^b} (P_{NSD(l,t,s)} + P_{LoadDR(l,t,s)} - P_{Load(l,t,s)}) \\
& + \sum_{ESS \in \Omega_{Ne}^b} (ESS_{Disch}(e,t,s) - ESS_{Charge}(e,t,s)) \\
& + \sum_{VE \in \Omega_{Nve}^b} (VE_{Disch}(ev,t,s) - VE_{Charge}(ev,t,s)) \\
& - \sum_{b,w=1}^{N_L} (P_{L(b,w,t,s)} - P_{L(w,b,t,s)}) = 0 \\
& P_{L(b,w,t,s)} \leq P_{L(b,w)}^{MAX} \quad \forall t, s \quad (7)
\end{aligned} \tag{6}$$

**Restrições operativas dos geradores despacháveis e fornecedor externo:** As equações (8) e (9) definem  $x_{DG}$  como uma variável binária que indica o despacho do gerador para cada período  $t$ , garantindo o respeito aos limites máximos e mínimos de operação de cada gerador  $i$ . De forma similar, as restrições (10) e (11), utilizam a varável  $x_{ext}$  para identificar a presença de fornecimento por parte do fornecedor externo.

$$P_{DG(i,t)} \geq x_{DG(i,t)} \cdot P_{DGlimit}^{Min} \quad \forall t, \forall i \in \Omega_{DG}^d \quad (8)$$

$$P_{DG(i,t)} \leq x_{DG(i,t)} \cdot P_{DGlimit}^{Max} \quad \forall t, \forall i \in \Omega_{DG}^d \quad (9)$$

$$P_{ext}(ext,t) \geq x_{ext}(ext,t) \cdot P_{extlimit}^{Min} \quad \forall t, \forall ext \quad (10)$$

$$P_{ext}(ext,t) \leq x_{ext}(ext,t) \cdot P_{extlimit}^{Max} \quad \forall t, \forall ext \quad (11)$$

Considerando  $P_{DG(i,t)}$  e  $P_{ext(i,t)}$ , como as potências ativa (em MW) dos geradores despacháveis  $i$  no período  $t$ , e as potências ativa (em MW) do fornecedor externo  $i$  no mesmo período  $t$ , respectivamente, os limites máximo e mínimos de operação dos geradores despacháveis e dos fornecedores externos são representados por,  $P_{DGlimit}^{Min}$ ,  $P_{DGlimit}^{Max}$ ,  $P_{extlimit}^{Min}$  e  $P_{extlimit}^{Max}$ , respectivamente.

**Restrições do SAEs:** Na equação (12), as variáveis binárias  $x_{ESSCharg}$  e  $y_{ESSDisch}$  identificam o estado de carga ou descarga das baterias dos SAEs, garantindo que não ocorra o carregamento e descarregamento no mesmo período de tempo  $t$  para a mesma bateria  $e$ . A equação (13) representa o equilíbrio de armazenamento de cada unidade de bateria, onde  $E_{ESS}$  é a energia armazenada na unidade e no período  $t$  e cenário  $s$  (em MWh). A eficiência de carga e descarga das unidades é representado por  $\eta_{ESS}$  (em %). As equações (14) e (15) definem os limites máximos de descarga e carga das baterias. Na equação (16),  $E_{ESS}^{maxbatcap}$  representada a máxima capacidade de armazenamento de cada bateria (em MWh).

$$x_{ESSCharg}(e,t,s) + y_{ESSDisch}(e,t,s) \leq 1 \quad \forall t, \forall e, \forall s \quad (12)$$

$$E_{ESS}(e,t,s) = E_{ESS}(e,t-1,s) + \eta_{ESS}(e) \cdot ESS_{Charg}(e,t,s) \cdot \Delta t - \frac{1}{\eta_{ESS}(e)} \cdot ESS_{Disch}(e,t,s) \cdot \Delta t \quad \forall t, \forall e, \forall s \quad (13)$$

$$ESS_{Disch}(e,t,s) \leq ESS_{Dischlimit}^{Max} \quad \forall t, \forall e, \forall s \quad (14)$$

$$ESS_{Disch}(e,t,s) \geq 0$$

$$ESS_{Charg}(e,t,s) \leq ESS_{Charglimit}^{Max} \quad \forall t, \forall e, \forall s \quad (15)$$

$$ESS_{Charg}(e,t,s) \geq 0$$

$$E_{ESS}(e,t,s) \leq E_{ESS(e)}^{maxbatcap} \quad \forall t, \forall e, \forall s \quad (16)$$

$$E_{ESS}(e,t,s) \geq 0$$

**Restrições dos VEs:** Os estudos (Soares, et al., 2017) e (Lezama, et al., 2019) modelam os VEs como um sistema de baterias virtuais, uma analogia ao mundo real seria um estacionamento de recarga ou um ponto na rede onde um grande conjunto de VEs esteja sempre conectado. Assim, as equações que representam as restrições operacionais dos VEs assemelham-se às dos SAEs, porém apresentam mais fontes de incertezas na sua previsão, devido ao comportamento aleatório dos usuários dos VEs. As equações (17)-(21) descrevem esse recurso.

$$x_{VECharg}(VE,t,s) + y_{VEDisch}(VE,t,s) \leq 1 \quad \forall t, \forall ve, \forall s \quad (17)$$

$$E_{VE}(VE,t,s) = E_{VE}(VE,t-1,s) + \eta_{VE(VE)} \cdot VE_{Charg}(VE,t,s) \cdot \Delta t - \frac{1}{\eta_{VE(VE)}} \cdot VE_{Disch}(VE,t,s) \cdot \Delta t \quad \forall t, \forall ve, \forall s \quad (18)$$

$$VE_{Disch}(VE,t,s) \leq VE_{Dischlimit}^{Max} \quad \forall t, \forall ve, \forall s \quad (19)$$

$$VE_{Disch}(VE,t,s) \geq 0$$

$$VE_{Charg}(VE,t,s) \leq VE_{Charglimit}^{Max} \quad \forall t, \forall ve, \forall s \quad (20)$$

$$VE_{Charg}(VE,t,s) \geq 0$$

$$\begin{aligned} E_{VE(VE,t,s)} &\leq E_{EV(e)}^{maxbatcap} \\ E_{VE(VE,t,s)} &\geq 0 \end{aligned} \quad \forall t, \forall ve, \forall s \quad (21)$$

As variáveis binárias  $x_{VECharg}$  e  $y_{VEDisch}$  representam o estado de carga ou descarga dos VEs, não podendo ocorrer simultaneamente, conforme descrito na equação (17). Na equação (18), assim como no caso do SAE, é expresso o equilíbrio da energia armazenada nos VEs, onde  $E_{VE}$  denota a energia armazenada na unidade  $VE$  no período  $t$  para o cenário  $s$  (em MWh) e  $\eta_{EV}$  representa a eficiência de carga e descarga do VE (em %). As equações (19)-(21), definem os limites máximos e mínimos de descarga, carga e armazenamento, respectivamente.

**Restrições da RD:** Na equação (22),  $P_{LoadDR}^{Max}$  representa a máxima potência ativa (em MW) que pode ser reduzida da carga  $l$  no período  $t$  para o cenário  $s$ , refletindo o controle direto sobre a carga  $l$ .

$$\begin{aligned} P_{LoadDR(l,t,s)} &\leq P_{LoadDR(l,t,s)}^{Max} \\ P_{LoadDR(l,t,s)} &\geq 0 \end{aligned} \quad \forall t, \forall l, \forall s \quad (22)$$

**Restrições do mercado grossista:** Será considerado um único mercado diário de energia, no qual tem a capacidade de ofertar energia dentro de certos limites. Além disso, é comum que haja um montante mínimo de compra nesses mercados. Portanto, as equações (23)-(26) estabelecem os limites máximos e mínimos para a venda e compra no mercado.

$$P_{sell} \leq x_{sell} \cdot P_{sell}^{max} \quad \forall t \quad (23)$$

$$P_{sell} \geq x_{sell} \cdot P_{sell}^{min} \quad \forall t \quad (24)$$

$$P_{buy} \leq x_{buy} \cdot P_{buy}^{max} \quad \forall t \quad (25)$$

$$P_{buy} \geq x_{buy} \cdot P_{buy}^{min} \quad \forall t \quad (26)$$

$$x_{sell} + x_{buy} \leq 1 \quad \forall t \quad (27)$$

Onde  $P_{sell}$  e  $P_{buy}$  representam as potências ativas vendida e comprada no mercado diário (em MW), enquanto  $P_{sell}^{max}$ ,  $P_{sell}^{min}$ ,  $P_{buy}^{max}$  e  $P_{buy}^{min}$  são os limites máximos e mínimos de compra e venda no mercado (em MW). Na equação (27), há a restrição que proíbe a ação de compra e venda para o mesmo período de tempo  $t$ .

**A restrições de corte de carga:** É definida na equação (28), onde  $P_{ENS}$  é potência ativa de corte da carga  $l$ , no período  $t$  no cenário  $s$  (em MW).

$$P_{ENS(l,t,s)} \leq P_{Load(l,t,s)} - P_{LoadDR(l,t,s)} \quad \forall t, \forall l, \forall s \quad (28)$$

**Restrição de geração renovável (não despachada):** O poder de restrição da geração renovável, ou seja, não despachável, não pode ser superior a geração renovável prevista para o gerador  $i$ , no período  $t$  no cenário  $s$ .

$$P_{RDG} \leq P_{DG(i,t,s)} \quad \forall t, \forall i \in \Omega_{DG}^{nd}, \forall s \quad (29)$$

Temos que,  $P_{RDG}$  é a potência ativa (em MW) restringida dos geradores  $i$  não despacháveis ( $\Omega_{DG}^{nd}$ ), no período  $t$  para o cenário  $s$ .

**Restrições de métrica de risco:** A introdução de uma métrica de risco (CVaR) para o problema de GRE do DS baseia-se em duas estratégias: uma em que o agregador adota uma postura neutra em relação ao risco e outra em que adota uma postura aversa. Essas posturas determinam o impacto do CVaR na FO. A variável  $\beta$ , inserida na equação (1), representa a posição do agregador em relação ao risco, sendo um percentil que determina o impacto do CVaR no valor da FO.

Quando o agregador adotar uma postura totalmente neutra em relação ao risco, ele opta por não considerar a métrica de risco durante o processo de tomada de decisão, o que significa que  $\beta$  assume o valor 0. Nesse cenário, a FO pode ser resumida ao custo esperado dos cenários, conforme a equação (2).

Por outro lado, quando o agregador adota uma postura aversa ao risco, a métrica de risco é incorporada à FO. Nessa abordagem, utilizamos o CVaR para medir o risco, que indica a perda média excedente ao VaR para um determinado nível de confiança  $\alpha$ . O CVaR é capaz de quantificar, em média, o tamanho da perda (risco) que o agregador está sujeito, considerando a ocorrência de eventos extremos nos cenários avaliados (Almeida, et al., 2022). A Figura 7 ilustra graficamente os conceitos de CVaR e VaR por meio das funções de distribuição normal e cumulativa.

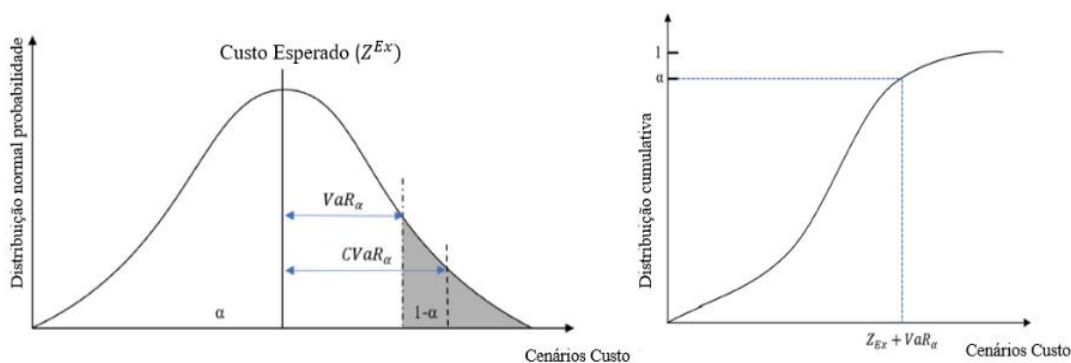


Figura 7 - Representação do VaR, CVaR e Zex, adaptada (Almeida, et al., 2022)

Assim, o CVaR representa um custo adicional incluindo na FO relacionada aos cenários extremos que excedem o limite de confiança de  $(1-\alpha)$  %, podendo ser determinado pela equação (30).

$$CVaR_{\alpha}(Z_s^{tot}) = VaR_{\alpha}(Z_s^{tot}) + \frac{1}{1-\alpha} \cdot \sum_{s=1}^{Ns} \rho_s \cdot \varphi_s \quad (30)$$

Na equação (31),  $\varphi_s$  é uma variável auxiliar associado aos custos dos cenários extremos, que só terá um valor quando o custo do cenário  $s$ ,  $Z_s^{tot}$ , for superior ao custo esperado  $Z^{Ex}$  adicionado o valor de VaR. Caso contrário, seu valor é igual a zero.

$$\varphi_s \begin{cases} Z_s^{tot} - Z^{Ex} - VaR_{\alpha}(Z_s^{tot}), & \text{se } Z_s^{tot} \geq Z^{Ex} + VaR_{\alpha}(Z_s^{tot}) \\ 0, & \text{caso contrário} \end{cases} \quad (31)$$

Portanto, a FO do problema de GRE do DS proposto neste trabalho varia de acordo com o nível de aversão ao risco do agregador ( $\beta$ ). O parâmetro  $\beta$  representa o percentual de aversão ao

risco, podendo variar de 0 a 1. Quando assumido o valor 0, a FO é igual ao custo esperado, o que significa que o agregador possui uma postura neutra em relação ao risco. Já para  $\beta$  igual a 1, o agregador toma uma postura de aversão total ao risco, obtendo soluções para o problema mais robustas.

### 3.1.1 Técnica de Otimização

Problemas do tipo MINLP, como o problema GRE para o DS em redes de tamanho real, requerem um alto esforço computacional para serem resolvidos. Portanto, os autores (Soares, et al., 2017) e (Lezama, et al., 2019) empregam a decomposição de Benders para superar as dificuldades de resolver a otimização não linear.

A metodologia de decomposição de J. F. Benders foi proposta em 1962 para resolver problemas de programação linear inteira ou programação linear inteira mista (MILP) de grande escala. A ideia básica por trás da técnica de Benders é decompor o problema principal (problema mestre) em subproblemas menores (problemas escravos) e mais gerenciáveis, utilizando a teoria da dualidade em programação linear e não linear. A decomposição é feita em termos de variáveis, e o problema principal é resolvido de forma iterativa, ajustando as soluções dos subproblemas até que o problema mestre seja viável ou esteja próximo de ser viável (Conejo, et al., 2006) e (Soares, et al., 2016a).

Neste trabalho, seguindo a abordagem de (Soares, et al., 2017) e (Lezama, et al., 2019), o problema é dividido em duas fases de decomposição de Benders. Na primeira fase, denominada problema mestre, são tomadas as decisões de alto nível, tais como as compras de energia do fornecedor externo, lances ótimos no mercado grossista e o despacho dos geradores controláveis. O problema mestre é formulado como MILP de forma a otimizar as decisões globais do problema, sem levar em consideração restrições técnicas detalhadas, como fluxo de potência das linhas e limites térmicos; em vez disso, apenas uma equação de equilíbrio de potência é considerada. Na segunda fase, denominada problema escravo, são resolvidos os subproblemas associados a cada cenário considerando, por meio problemas de otimização linear (LP). Nessa fase, são realizadas as validações das restrições de rede e limites térmicos para cada cenários específico, garantindo que a solução seja viável e robusta sob diferentes condições.

A FO original (1) é ajustada para incorporar a variável  $\alpha_{Benders}$ , que representa os cortes de Benders. Portanto, a nova FO, referente ao problema mestre, representada em (32), tem como objetivo minimizar o valor de  $\alpha_{Benders}$ , enquanto satisfaz a nova restrição (33).

$$\text{Min } OF = Z^{Ex} + \beta \cdot CVaR_{\alpha}(Z_s^{tot}) + \alpha_{Benders} \quad (32)$$

$$\begin{aligned}
\alpha_{benders} \geq & Z_{up}^{m-1} + \sum_{t=1}^T \sum_{sp=1}^{Nsp} \lambda_{ext(s,t)}^{m-1} \cdot (x_{ext(sp,t)}^m - x_{ext(sp,t)}^{m-1}) \\
& + \sum_{t=1}^T \sum_{i \in \Omega_{DG}^t} \lambda_{DG(i,t)}^{m-1} \cdot (x_{DG(i,t)}^m - x_{DG(i,t)}^{m-1}) \\
& + \sum_{t=1}^T \sum_{e=1}^{Ne} \lambda_{ESS\_disch(e,t,s)}^{m-1} \cdot (x_{ESS\_disch(e,t,s)}^m - x_{ESS\_disch(e,t,s)}^{m-1}) \\
& + \sum_{t=1}^T \sum_{e=1}^{Ne} \lambda_{ESS\_charg(e,t,s)}^{m-1} \cdot (y_{ESS\_charg(e,t,s)}^m - y_{ESS\_charg(e,t,s)}^{m-1}) \\
& + \sum_{t=1}^T \sum_{VE=1}^{Nve} \lambda_{VE\_disch(VE,t,s)}^{m-1} \cdot (x_{VE\_disch(VE,t,s)}^m - x_{VE\_disch(VE,t,s)}^{m-1}) \\
& + \sum_{t=1}^T \sum_{VE=1}^{Nve} \lambda_{VE\_charg(VE,t,s)}^{m-1} \cdot (y_{VE\_charg(VE,t,s)}^m - y_{VE\_charg(VE,t,s)}^{m-1})
\end{aligned} \tag{33}$$

Os cortes lineares de Benders são formulados na equação (33), onde  $Z_{up}^{m-1}$  representa a soma das inviabilidades do problema escravo na iteração anterior, denotada por  $m - 1$ . A variável  $\lambda_{ext(s,t)}^{m-1}$  são os multiplicadores Lagrange associado à restrição do fornecedor externo, enquanto  $\lambda_{DG(i,t)}^{m-1}$  refere-se aos multiplicadores de Lagrange associado às restrições dos geradores despacháveis. Além disso,  $\lambda_{ESS\_disch(e,t,s)}^{m-1}$  e  $\lambda_{ESS\_charg(e,t,s)}^{m-1}$  são os multiplicadores de Lagrange associados às restrições de descarga e carga do SAE, respectivamente, e  $\lambda_{VE\_disch(VE,t,s)}^{m-1}$  e  $\lambda_{VE\_charg(VE,t,s)}^{m-1}$  representam os multiplicadores Lagrange associados às restrições de descarga e carga dos VEs, respectivamente. Esses multiplicadores de Lagrange são obtidos no problema escravo da iteração anterior e incorporados ao problema mestre (Soares, et al., 2017).

Para o problema escravo, a FO original (1) é ajustada para (34), onde  $ZA_{(b,t)}$  representa a variável de relaxação para o fluxo de potência CC, conforme a equação (35), e  $ZF_{(h,t)}$  é a relaxação para os limites térmicos das linhas de transmissão, como definido na equação (36). Esses valores indicam o grau de violação dessas restrições. Embora o subproblema escravo não possa alterar as variáveis binárias, ele é capaz de ajustar as variáveis contínuas do problema para satisfazer várias restrições, enquanto minimiza a FO juntamente com as variáveis de folga (Soares, et al., 2017).

$$\text{Minimize } Z^{Ex} + \sum_{t=1}^T \sum_{b=1}^{N_b} ZA_{(b,t)} + \sum_{t=1}^T \sum_{h=1}^{N_h} ZF_{(h,t)} \tag{34}$$

$$\begin{aligned}
& \sum_{i \in \Omega_{DC}^b} (P_{DG(i,t)} - P_{RDG(i,t)}) + \sum_{ext \in \Omega_{ext}^b} P_{ext(ext,t)} \\
& + \sum_{l \in \Omega_{nl}^b} (P_{NSD(l,t,s)} + P_{LoadDR(l,t,s)} - P_{Load(l,t,s)}) \\
& + \sum_{ESS \in \Omega_{Ne}^b} (ESS_{Disch}(e,t) - ESS_{Charge}(e,t)) \quad \forall b, t \quad (35) \\
& + \sum_{VE \in \Omega_{Nve}^b} (VE_{Disch}(ev,t) - VE_{Charge}(ev,t)) \\
& - \sum_{b,w=1}^{N_L} (P_{L(b,w,t)} - P_{L(w,b,t)}) + ZA_{(b,t)} = 0 \\
& P_{L(b,w,t)} + ZF_{(b,w,t)} \leq P_{L(b,w)}^{MAX} \quad \forall t \quad (36)
\end{aligned}$$

A abordagem adotada em (Soares, et al., 2017) e (Lezama, et al., 2019), é iterativa e, portanto, requer um critério de parada para encerrar sua execução. O algoritmo encerra sua iteração quando a diferença entre  $Z_{up}$  e  $Z_{down}$  é igual a zero ou menor que um valor especificado muito pequeno. A variável  $Z_{down}$  refere-se aos valores dos cortes obtidos no problema mestre, ou seja, o valor de  $\alpha_{Benders}$ . Se a diferença entre esses valores for maior que  $Z_{up}$ , isso indica desempenho insatisfatório na otimização. Normalmente, a convergência do problema ocorre na primeira iteração, quando a solução mestre é viável.

### 3.1.2 Geração de cenários

O agregador neste modelo está sujeito a diversas fontes de incertezas relacionado aos múltiplos recursos energéticos sobre sua gestão. Nomeadamente, essas incertezas são os erros de previsão, devido ao comportamento aleatório dos usuários de VEs e o seus padrões de carregamento, projeções dos preços do mercado de energia e do consumo de energia, além das previsões da produção das fontes renováveis incertas (Dabhi & Pandya, 2020). Dada a aleatoriedade dessas variáveis, a tomada de decisão torna-se desafiadora, dificultando uma abordagem eficaz e precisa. Para lidar com esse desafio, o modelo proposto incorpora essas incertezas por meio de uma técnica de otimização baseada em cenários estocásticos (Almeida, et al., 2022).

Assim, ao abordar a resolução do problema de GRE, surge uma questão crucial: “como gerar um conjunto de cenários que possa representar de forma adequada todas as características probabilísticas dos dados de entrada?” Nesse contexto, recorre-se ao método de MSC para gerar um amplo conjunto inicial de cenários que capturem as incertezas enfrentadas pelo agregador. Os parâmetros de entrada do método MSC incluem a função de probabilidade dos erros de previsão, derivada de um conjunto de dados históricos (Soares, et al., 2017) e (Ghazvini, et al., 2015).

Os cenários, denotados por  $x^s$ , são compostos pela soma dos erros derivados dos dados históricos, conforme descrito pela equação (37). Onde,  $x^{previsão}$  representa o erro associado à

previsão feita, que pode assumir valores positivos ou negativos, enquanto  $x^{erro,s}$  são o ruído adicional associado a cada cenário  $s$ , seguindo uma distribuição normal de média zero e desvio padrão  $\sigma$ .

$$x^s = x^{previsão}(t) + x^{erro,s}(t) \tag{37}$$

Poder meio do conceito de árvore de cenários, podemos visualizar como a incerteza se desenvolve ao longo do tempo, combinando-se para formar um conjunto abrangente de cenários (Gröwe-Kuska, et al., 2003). Na Figura 8, cada nó representa um estado da variável aleatória em um momento específico, enquanto os ramos representam as diferentes realizações da variável aleatória. Cada trajeto completo na árvore constitui um cenário, e sua probabilidade é igual ao produto das probabilidades dos ramos (Soares, et al., 2017).




Figura 8 - Representação de árvore de cenários, fonte (Soares, et al., 2017)

Muitos cenários são inicialmente gerados, resultando em um problema de otimização de grande escala. Quanto maior o número de cenários, mais preciso será a resposta do modelo. No entanto, há um *trade-off* entre o tempo computacional e a precisão da resposta, ou seja, um grande conjunto de cenários requer mais tempo computacional para ser processado. Para enfrentar essa restrição, são empregadas técnicas padrão de redução de cenários. Essas técnicas agrupam cenários semelhantes e excluem cenários com baixa probabilidade de ocorrências, criando assim um subconjunto menor de cenários, próximo à distribuição inicial em termo de métrica probabilística (Gröwe-Kuska, et al., 2003).

O principal objetivo da redução do número de cenários é tornar o problema de otimização substancialmente menor, reduzindo o número de variáveis e restrições. Isso, por sua vez, diminui o tempo computacional necessário para encontrar soluções razoáveis rapidamente, ao mesmo tempo que mantém as características estatísticas principais do conjunto de dados original. No entanto, o custo operacional dessa abordagem é a introdução de imprecisões na solução final do modelo.

Para a metodologia do problema GRE do DS baseado no risco, foi adotado como base os cenários de estudo do trabalho (Soares, et al., 2017), com a substituição de 10% dos cenários por aqueles com maior impacto sobre a FO. No trabalho mencionado, inicialmente são gerados 5.000 cenários, levando em consideração as incertezas associadas aos recursos energéticos da

rede estudada. Em seguida, o número de cenários é reduzido para 150 por meio da técnica GAMS/SCENRED<sup>1</sup>.

Durante o processo de redução, são removidos os cenários com baixa probabilidade de ocorrência. No entanto, muitos desses cenários são responsáveis por impactos significativos no processo de tomada de decisão. Como resultado, um problema de GRE baseado em risco, utilizando o conjunto original de 150 cenários reduzidos, pode ser pouco eficaz, pois não contempla eventos extremos (com altos custos operacionais).

Para superar essa limitação, optou-se por modificar 15 cenários originais transformando em cenários extremos, que têm um grande impacto sobre a FO, apesar de sua baixa probabilidade de ocorrência. Esse processo de modificação não alterou a distribuição de probabilidade do conjunto de 150 cenários, não sendo necessário realizar uma redistribuição da probabilidade do conjunto. Na Tabela 9 é apresentada a metodologia para modificar os cenários originais e criar os cenários extremos.

Tabela 9 – Metodologia de criação de cenário extremos

30	<b>Incremento de 30% do consumo de energia e retirada do mercado grossista.</b>
10	<b>Incremento de 30% do consumo de energia e redução de 50% da energia transacionada no mercado grossista.</b>
79	<b>Incremento de 40% do consumo de energia e redução para 0 MW o RD.</b>
60	<b>Incremento de 40% do consumo de energia e de 20% de geração fotovoltaica.</b>
40	<b>Decremento de 40% do consumo de energia e incremento de 40% de geração fotovoltaica e eólica.</b>
5	Incremento de 50% do consumo de energia.
48	Incremento de 50% do consumo de energia, 80% do preço do mercado grossista. e redução de 30% da capacidade de RD.
28	Incremento de 60% do consumo de energia e de 20% e 30% de geração fotovoltaica e eólica, respectivamente.
95	Incremento de 60% do consumo de energia e 30% da energia transacionada no mercado grossista.
118	Incremento de 60% do consumo de energia e de 25% da capacidade de RD.
106	Redução de 70% da capacidade do fornecedor externo e incremento de 70% do preço do mercado grossista.
02	Incremento de 120% do preço do mercado grossista e redução de 60% da capacidade de RD.
137	Redução de 30% de geração fotovoltaica e eólica, redução 75% da energia transacionada no mercado grossista e incremento de 70% do preço do mercado grossista.
147	Redução de 30% de geração fotovoltaica e eólica e para 0 MW o RD.
92	Redução de 50% da energia transacionada no mercado grossista.

<sup>1</sup> O algoritmo de redução de cenários fornecidos pelo SCENRED determina um subconjunto de cenários reduzido, respeitando a precisão prescrita, atribuindo novas probabilidades aos cenários preservados.  
[https://www.gams.com/39/docs/T\\_SCENRED](https://www.gams.com/39/docs/T_SCENRED)

O método de escolha dos 15 cenários modificados, se deu unicamente pela probabilidade de ocorrência, optando por aqueles com menor probabilidade. A modificação envolve apenas as variáveis de decisão, não alterando a distribuição probabilística do conjunto dos 150 cenários. Deste modo, esses cenários extremos têm um alto impacto sobre FO, porém com uma baixa probabilidade de ocorrência.

### 3.2 Metodologia 2 – Intra diário

Para desenvolver um modelo de otimização para o problema GRE no horizonte ID, utilizamos como base o modelo proposto para o DS, conforme apresentado neste trabalho. Na Figura 9, adaptada de (Canizes, et al., 2021 ), ilustra graficamente o modelo proposto para o horizonte ID.

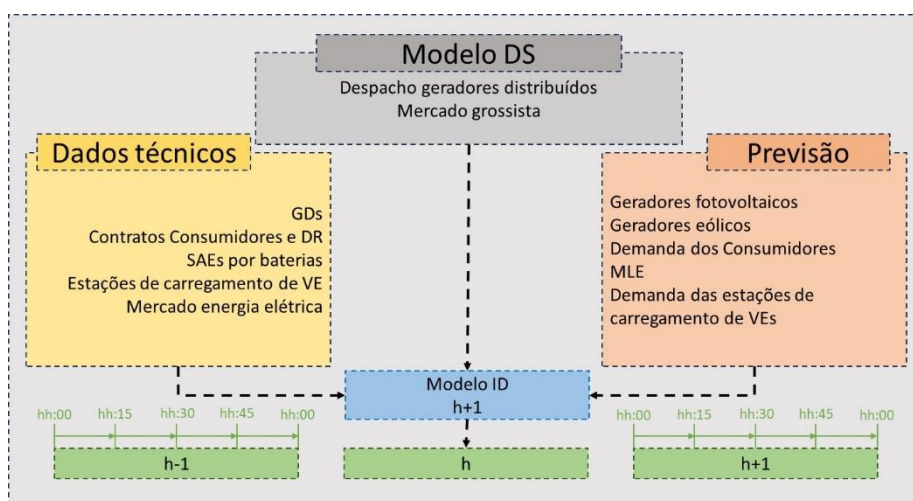


Figura 9 - Diagrama da metodologia proposta ID, adaptada (Canizes, et al., 2021 )

O modelo ID tem como ponto de partida o modelo do DS, pois seus dados e variáveis são entradas do modelo. Além disso, é crucial conhecer todos os dados técnicos e previsões dos recursos energéticos associados ao agregador, incluindo previsão de geração renovável, dados dos geradores distribuídos, previsão da carga, contratos de RD, informações do mercado de energia e previsões dos VEs e SAEs.

O resultado desse modelo é o escalonamento dos recursos energéticos associados ao agregador na hora  $h$  para a próxima hora  $h+1$ , com um intervalo de resolução de 15 minutos. Portanto, todos os dados de entrada do modelo precisam ser transformados para a mesma base de tempo, de 15 minutos. Vale ressaltar que as restrições de rede não serão consideradas no problema de otimização, uma vez que o operador do sistema de distribuição é responsável pela análise de rede, permitindo formular o problema como um MILP.

Assim, a formulação matemática do modelo é semelhante à do DS, mas com um passo de otimização de 15 minutos. Também são inseridos contratos RD que permitem ao agregador

solicitar o aumento do consumo de energia para minimizar as restrições da geração dos recursos renováveis. Outra diferença é a introdução de um MLE e um sistema de restrição para uso dos recursos de SAEs e VEs. Na equação (38), temos a FO para o modelo ID.

$$\begin{aligned}
Min OC = & \sum_{t=1}^T \left( \sum_{i=1}^{N_i} P_{DG(i,t)} \cdot C_{DG(i,t)} + \sum_{sp=1}^{N_{sp}} P_{ext(sp,t)} \cdot C_{ext(sp,t)} \right. \\
& + \sum_{l=1}^{N_l} \left( P_{LoadDR(l,t)}^{Down} + P_{LoadDR(l,t)}^{Up} \right) \cdot C_{loadDR(l,t)} \\
& + \sum_{e=1}^{N_e} ESS_{Disch(e,t)} \cdot ESSC_{Disch(e,t)} \\
& + \sum_{e=1}^{N_e} ESS_{Charg(e,t)} \cdot ESSC_{Charg(e,t)} \\
& + \sum_{VE=1}^{N_{VE}} EV_{Disch(VE,t)} \cdot EVC_{Disch(VE,t)} \\
& + \sum_{VE=1}^{N_{VE}} EV_{Charg(VE,t)} \cdot EVC_{Charg(VE,t)} + \sum_{l=1}^{N_l} P_{ENS(l,t)} \cdot C_{ENS(l,t)} \\
& \left. + \sum_{i=1}^{N_i} P_{RDG(i,t)} \cdot C_{RDG(i,t)} \right) \times \Delta t + ME + PE
\end{aligned} \tag{38}$$

$$\begin{aligned}
ME = & \sum_{t=1}^T \left( \sum_{md=1}^{N_{md}} (P_{buy}^{md}(md,t) \cdot MP_{(md,t)}) - (P_{sell}^{md}(md,t) \cdot MP_{(md,t)}) \right. \\
& \left. + \sum_{ml=1}^{N_{ml}} (P_{buy}^{ml}(ml,t) \cdot MLE_{(ml,t)}) - (P_{sell}^{ml}(ml,t) \cdot MLE_{(ml,t)}) \right) \times \Delta t
\end{aligned} \tag{39}$$

$$\begin{aligned}
PE = & \sum_{t=1}^T \left( \sum_{e=1}^{N_e} (DE_{ESS(e,t)}^{up} + DE_{ESS(e,t)}^{down}) \cdot DEC_{ESS(e,t)} \right. \\
& \left. + \sum_{VE=1}^{N_{VE}} (DE_{VE(VE,t)}^{up} + DE_{VE(VE,t)}^{down}) \cdot DEC_{VE(VE,t)} \right)
\end{aligned} \tag{40}$$

Na equação (39), são representados os custos relacionados aos mercados de energia MP e MLE. No mercado MP, as ofertas permanecem fixas, definidas no modelo do DS e sua inclusão na FO serve apenas para composição do custo total. Já no mercado MLE,  $P_{buy}^{ml}$  e  $P_{sell}^{ml}$ , representam as potências ativa comprada e vendida (em MW), enquanto variável MLE é o preço da energia em (em u.m/MWh).

Na equação (40), é representado o sistema de restrição e penalização (PE) do uso dos SAEs e VEs, que tem como objetivo introduzir um custo na FO caso esses recursos sejam utilizados além de um limite estabelecido. Esse limite é determinado como uma porcentagem de

utilização em relação ao resultado do problema do DS. Por exemplo, ao definir um limite de 10% de utilização, o problema ID poderá utilizar os SAEs e VEs dentro de uma margem de  $\pm 10\%$  sem aplicação de penalizações. Essa abordagem visa evitar o uso descontrolado desses recursos, pois violações de contratos podem ocorrer, ou no caso dos VEs, os usuários podem não possuir bateria suficiente para suas necessidades.

Ainda sobre a equação (40),  $DE_{ESS}^{up}$  representa a diferença positiva na energia armazenada no SAEs ao final de cada hora de otimização (em MWh), enquanto  $DE_{ESS}^{down}$  representa a diferença negativa na energia armazenada nos SAEs ao final de cada hora de otimização (em MWh). Essa mesma lógica é aplicada para os VEs, onde  $DE_{VE}^{up}$  e  $DE_{VE}^{down}$ , representam as diferenças positiva e negativa para os VEs respectivamente. As variáveis  $DEC_{ESS}$  e  $DEC_{VE}$  são os coeficientes das penalizações financeiras em u.m/MWh.

As variáveis de decisões da FO estão sujeitas a uma série de restrições, que possuem como objetivo representar matematicamente seu comportamento operativa, sendo elas:

**Restrições do SAEs:** Observa-se que o conjunto de restrições impostas aos SAEs é semelhante ao do modelo proposto para o DS neste trabalho. No entanto, são acrescentadas duas restrições adicionais, representadas pelas equações (42) e (43), referente ao sistema de PE. Nestas equações,  $\sigma_{ESS}$  representa, em percentual, a restrição de uso das SAEs, enquanto  $E_{ESS}^{DS}$  representa a quantidade de energia armazenada na unidade  $e$  ao final da hora ( $t+4$ ) na solução do problema do DS, medida em MWh.

É importante ressaltar que, devido à diferença no passo de otimização entre o problema ID e o do DS, sendo  $\frac{1}{4}$  de hora e 1 horas, respectivamente, somente é possível considerar os valores de armazenamento de energia resultando de 1 hora inteira de otimização. Em outras palavras, esses valores são referentes ao 4º período de otimização,  $t+4$ .

$$\begin{aligned} & \left( E_{ESS(e,t)} - DE_{ESS(e,t)}^{down} + DE_{ESS(e,t)}^{up} \right) \\ = & \left( E_{ESS(e,t-1)} - DE_{ESS(e,t-1)}^{down} + DE_{ESS(e,t-1)}^{up} \right) + \eta_{ESS(e)} \\ & \cdot ESS_{Charg(e,t)} \cdot \Delta t - \frac{1}{\eta_{ESS(e)}} \cdot ESS_{Disch(e,t)} \cdot \Delta t \end{aligned} \quad \forall t, \forall VE \quad (41)$$

$$E_{ESS(e,t+4)} \leq (1 + \sigma_{ESS}) \cdot E_{ESS(e,t+4)}^{DS} \quad \forall t, \forall VE \quad (42)$$

$$E_{ESS(e,t+4)} \geq (1 - \sigma_{ESS}) \cdot E_{ESS(e,t+4)}^{DS} \quad \forall t, \forall VE \quad (43)$$

$$\begin{aligned} ESS_{Disch(e,t)} & \leq ESS_{Dischlimit}^{Max} \\ ESS_{Disch(e,t)} & \geq 0 \end{aligned} \quad \forall t, \forall VE \quad (44)$$

$$\begin{aligned} ESS_{Charg(e,t)} & \leq ESS_{Charglimit}^{Max} \\ ESS_{Charg(e,t)} & \geq 0 \end{aligned} \quad \forall t, \forall VE \quad (45)$$

$$\begin{aligned} \left( E_{ESS(e,t)} - DE_{ESS(e,t)}^{down} + DE_{ESS(e,t)}^{up} \right) & \leq E_{ESS(e)}^{maxbatcap} \\ E_{ESS(e,t)} & \geq 0 \\ DE_{ESS(e,t)}^{down} & \geq 0 \\ DE_{ESS(e,t)}^{up} & \geq 0 \end{aligned} \quad \forall t, \forall VE \quad (46)$$

$$x_{ESSCharg(e,t)} + y_{ESSDisch(e,t)} \leq 1 \quad \forall t, \forall VE \quad (47)$$

Na restrição (41), de equilíbrio de armazenamento das SAEs, são introduzidas duas variáveis de “relaxação”,  $DE_{ESS}^{down}$  e  $DE_{ESS}^{up}$ , que quantificam a diferença na energia armazenada nas SAEs em relação à resposta do DS. As demais restrições são idênticas às do modelo do DS apresentando anteriormente

**Restrições do VEs:** Como mencionado anteriormente, podemos modelar o sistema de VEs de forma semelhante às SAEs, com a principal diferença o comportamento das incertezas associadas a esse sistema. Portanto, no contexto ID, as restrições aplicadas aos VEs são idênticas às impostas ao sistema de SAEs, conforme descritos nas equações (48)-(54).

$$\begin{aligned} & \left( E_{VE(VE,t)} - DE_{VE(VE,t)}^{down} + DE_{VE(VE,t)}^{up} \right) \\ = & \left( E_{VE(VE,t-1)} - DE_{VE(VE,t)}^{down} + DE_{VE(VE,t)}^{up} \right) + \eta_{VE(e)} \quad \forall t, \forall VE \quad (48) \\ & \cdot VE_{Charg(VE,t)} \cdot \Delta t - \frac{1}{\eta_{VE(VE)}} \cdot VE_{Disch(VE,t)} \cdot \Delta t \end{aligned}$$

$$E_{VE(VE,t+4)} \leq (1 + \sigma_{VE}) \cdot E_{VE(VE,t+4)}^{DS} \quad \forall t, \forall VE \quad (49)$$

$$E_{VE(VE,t+4)} \geq (1 - \sigma_{VE}) \cdot E_{VE(VE,t+4)}^{DS} \quad \forall t, \forall VE \quad (50)$$

$$\begin{aligned} EV_{Disch(VE,t)} & \leq VE_{Dischlimit}^{Max} \\ VE_{Disch(VE,t)} & \geq 0 \end{aligned} \quad \forall t, \forall VE \quad (51)$$

$$\begin{aligned} VE_{Charg(VE,t)} & \leq VE_{Charglimit}^{Max} \\ VE_{Charg(VE,t)} & \geq 0 \end{aligned} \quad \forall t, \forall VE \quad (52)$$

$$\begin{aligned} \left( E_{VE(VE,t)} - DE_{VE(VE,t)}^{down} + DE_{VE(VE,t)}^{up} \right) & \leq E_{VE(VE)}^{maxbatcap} \\ E_{VE(VE,t)} & \geq 0 \\ DE_{VE(VE,t)}^{down} & \geq 0 \\ DE_{VE(VE,t)}^{up} & \geq 0 \end{aligned} \quad \forall t, \forall VE \quad (53)$$

$$x_{VECharg(VE,t)} + y_{VEDisch(VE,t)} \leq 1 \quad \forall t, \forall VE \quad (54)$$

**Restrições dos mercado grossista e local:** Para o MLE, é previsto um único mercado local que deve respeitar às restrições (55)-(58), que definem os limites máximos e mínimos para as negociações. Os limites superiores de potência ativa para compra e venda (em MW) são determinados por  $P_{buy}^{maxml}$  e  $P_{sell}^{maxml}$ , enquanto os limites inferiores, são representados por  $P_{buy}^{minml}$  e  $P_{sell}^{minml}$  em MW. A equação (59), restringe a compra e venda no mesmo período de tempo  $t$ .

$$P_{buy(t)}^{ml} \leq P_{buy(t)}^{maxml} \quad \forall t \quad (55)$$

$$P_{sell(t)}^{ml} \leq P_{sell(t)}^{maxml} \quad \forall t \quad (56)$$

$$P_{buy(t)}^{ml} \geq P_{buy(t)}^{minml} \quad \forall t \quad (57)$$

$$P_{sell(t)}^{ml} \geq P_{sell(t)}^{minml} \quad \forall t \quad (58)$$

$$x_{sell(t)}^{ml} + x_{buy(t)}^{ml} \leq 1 \quad \forall t \quad (59)$$

$$P_{buy(t)}^{md} = P_{buy(t)}^{DS} \quad \forall t \quad (60)$$

$$P_{sell(t)}^{md} = P_{sell(t)}^{DS} \quad \forall t \quad (61)$$

Para o MP, as ofertas feitas no problema do DS permanecem inalteradas para o resultado do problema ID, conforme expressões (60) e (61), onde  $P_{buy}^{DS}$  e  $P_{sell}^{DS}$  representam a potência ativa comprada e vendida (em MW), respectivamente, obtida a partir do modelo do DS.

**Restrições do RD:** A formulação para RD, expressas nas equações (62) e (63), é análoga à do problema do DS. No entanto, no contexto do problema ID, o agregador tem a capacidade não apenas de reduzir a carga,  $P_{LoadDR}^{down}$ , mas também de adicionar carga ao sistema,  $P_{LoadDR}^{up}$ . Contudo, o agregador está sujeito a um limite máximo, definido por  $P_{LoadDR}^{Max}$ .

$$\begin{aligned} P_{LoadDR(l,t)}^{up} &\leq P_{LoadDR(l,t)}^{Max} \\ P_{LoadDR(l,t)}^{up} &\geq 0 \end{aligned} \quad \forall l, \forall t \quad (62)$$

$$\begin{aligned} P_{LoadDR(l,t)}^{down} &\leq P_{LoadDR(l,t)}^{Max} \\ P_{LoadDR(l,t)}^{down} &\geq 0 \end{aligned} \quad \forall l, \forall t \quad (63)$$

**Restrições equilíbrio de potência:** Como mencionado anteriormente, no modelo ID, não são considerados os limites operativos das linhas do sistema de distribuição da rede. Portanto, a FO é sujeito apenas a um balanço de potência, dado pela equação (64).

$$\begin{aligned} &\sum_{i=1}^{N_i} (P_{DG(i,t)} - P_{RDG(i,t)}) + \sum_{e=1}^{N_e} (ESS_{Disch(e,t)} - ESS_{Charge(e,t)}) \\ &+ \sum_{VE=1}^{N_{VE}} (VE_{Disch(VE,t)} - VE_{Charg(VE,t)}) \\ &+ \sum_{md=1}^{N_{md}} (P_{buy}^{md}(md,t) - P_{sell}^{md}(md,t)) + \sum_{ml=1}^{N_{ml}} (P_{buy}^{ml}(ml,t) - P_{sell}^{ml}(ml,t)) \\ &+ \sum_{l=1}^{N_l} (P_{NSD(l,t)} + P_{DR(l,t)}^{down} - P_{DR(l,t)}^{up} - P_{Load(l,t)}) = 0 \quad \forall t \end{aligned} \quad (64)$$

**Restrições de corte de carga:** As equações de corte de carga, ou carga não atendida,  $P_{NSD}$ , são iguais ao do problema do DS apresentado anteriormente neste trabalho. Na equação (65), podemos verificar sua formulação matemática

$$\begin{aligned} P_{ENS(l,t)} &\geq 0 \\ P_{ENS(l,t)} &\leq P_{Load(t,s)} - P_{LoadDR(l,t)}^{down} \end{aligned} \quad \forall t, \forall l \quad (65)$$

**Restrições de corte de geração:** Os cortes ou restrição de geração,  $P_{RDG}$ , está sujeito a equação (66), onde  $P_{DG}$  é a potência ativa do gerador  $i$ , no instante de tempo  $t$ .

$$\begin{aligned} P_{RDG} &\geq 0 \\ P_{RDG} &\leq P_{DG(i,t)} \end{aligned} \quad \forall t, \forall i \quad (66)$$

Por fim, é importante ressaltar que todos os dados de entrada, incluindo a resposta do modelo do DS proposto neste trabalho, devem ser convertidos para a mesma base de tempo. Em outras palavras, é necessário realizar a transformação da base horário para base de 15 minutos.

### 3.3 Aspectos conclusivos

Neste capítulo, foram apresentadas duas metodologias para abordar os problemas de GREs baseado em risco no horizonte do DS e outra para o horizonte ID. Ambas as formulações matemáticas consideram as funções de custos e as restrições técnicas dos recursos energéticos que o agregador precisa respeitar. O modelo para o DS é baseado nos trabalhos (Soares, et al., 2017) e (Lezama, et al., 2019), com a inclusão de uma estratégia de minimização de risco na FO, usando o CVaR como métrica de mensuração do risco o qual o agregador está exposto.

Na primeira metodologia, é empregada uma abordagem baseada em cenários estocásticos para lidar com as incertezas e erros de previsão dos recursos renováveis do sistema. Para tal, é utilizado o método de MSC para gerar 5 000 cenários probabilísticos que representam o comportamento incerto desses recursos. Em seguida, é reduzido o número de cenários para 150, mantendo as características estocásticas dos recursos energéticos com certo grau de precisão.

Além disso, para avaliar o comportamento do CVaR e seu impacto na resposta final da metodologia, modificamos 10% dos cenários originais, inserindo cenários extremos. Esses cenários representam situações de eventos catastróficos com um impacto significativo nos custos do agregador, embora sua probabilidade de ocorrência seja mínima. Na próxima seção, detalharemos a metodologia utilizada para inserir esses cenários extremos.

A segunda metodologia propõe um modelo determinístico do tipo MILP para resolver o problema de GRE no horizonte ID. Este modelo é capaz de determinar o agendamento ótimo dos recursos energéticos próximo da operação, em um horizonte horário, com um passo de otimização de 15 minutos. Os dados de entrada para este modelo são derivados da primeira metodologia, com algumas adaptações, como a conversão dos dados para a mesma base de tempo (15 minutos) e a transformação dos cenários estocástico para único cenário médio. Quanto às incertezas, essa metodologia lida com elas por meio de atualizações ou ajustes das previsões e dados de entrada do modelo.



## 4 Casos de Estudos

Neste capítulo, será descrito os casos de estudos o quais os modelos de GRE propostos no capítulo 03 serão testadas e avaliados.

### 4.1 Rede de Distribuição

Para esse estudo, será utilizada uma rede de distribuição real de Portugal, contendo 180 barramentos de 30 kV e uma subestação. Os dados originais da rede foram modificados para incluir uma alta penetração de RED, correspondendo a cerca de 70% de toda capacidade de produção da rede (Soares, et al., 2017) e (Soares, et al., 2016a).

Os 70% de geradores distribuídos equivalem a 116 unidades, distribuídas da seguinte forma: 44 unidades fotovoltaicas, 55 unidades eólicas e 17 unidades de biomassa. Para fins de análises, os geradores eólicos e fotovoltaicos serão agrupados em um conjunto denominado geradores não despacháveis, enquanto as unidades de biomassa formarão o conjunto de geradores despacháveis. O fornecedor externo estará conectado a barra 1, que também serve como ponto de conexão da subestação, interligando toda a rede ao restante do sistema elétrico.

Além disso, o agregador será responsável pela gestão de 5 estacionamentos de recarga de VEs, 7 unidades de SAEs, 1 fornecedor externo, o mercado grossista, 90 consumidores ligados à MT e contratos de controle direto da carga, RD. A Figura 10 ilustra a distribuição desses recursos energéticos ao longo da rede estudada. Os estacionamentos de VEs estão conectados a barras 3, 69, 96, 107 e 161 da rede, enquanto as SAEs estão distribuídas nas barras 13, 15, 18, 29, 31, 34 e 36 (Soares, et al., 2017).




Figura 10 - Diagrama unifilar da rede de 180 barramentos, adaptada (Soares, et al., 2017)

Os consumidores participam de um programa de flexibilidade de demanda, conhecido como RD. Esse programa permite que o agregador solicite a redução do consumo de energia de certas cargas em determinados períodos do dia, visando aliviar a rede durante picos de demanda ou restrições de geração. Para este estudo, está prevista uma capacidade máxima de redução de carga de 5,64 MW, com um benefício de 20 u.m por MWh reduzido.

Além disso, está prevista a participação em um mercado grossista limitado a 2 MWh, aumentando a exposição do agregador a níveis mais elevados de incertezas nos recursos energéticos. Na Figura 11, são apresentadas as projeções de preço do mercado grossista e do fornecedor externo.




Figura 11 - Previsão de preços do mercado grossista e fornecedor externo, adaptada de (Soares, et al., 2017)

Na Figura 12, é mostrado a previsão da geração das fontes eólicas e fotovoltaicas, juntamente com a previsão da demanda. É observável que, na hora 12, a previsão de geração de energia eólica e fotovoltaica varia entre um máximo de 3 MW e o mínimo de 2,5 MW. Essa previsão é resultado da geração dos 150 cenários estocásticos. Os dados específicos de cada tipo de fonte de geração estão listados na Tabela 10. É assumido que não há escassez de recurso de biomassa para produção de energia, garantindo a capacidade de despacho das unidades de biomassa a qualquer período do dia.

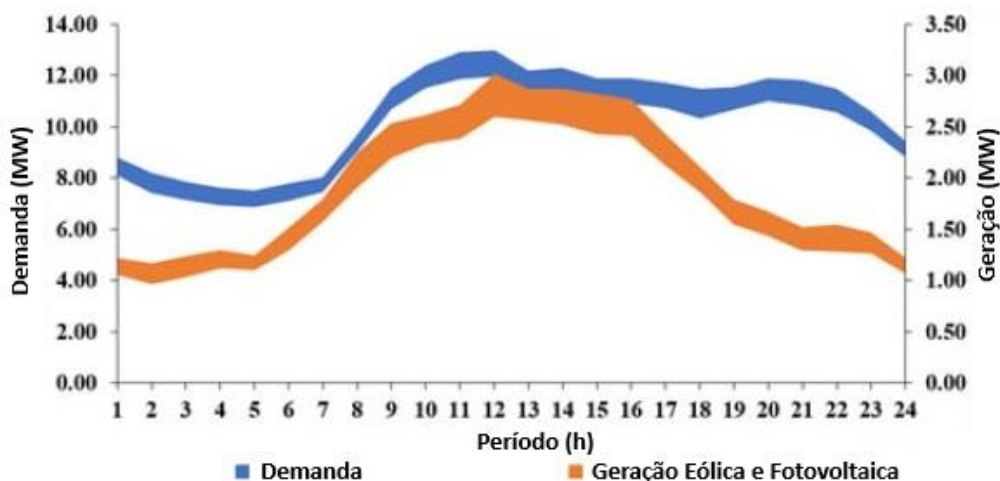


Figura 12 - Previsão da demanda de energia e da geração eólica e fotovoltaica, adaptada de (Soares, et al., 2017)

Para geração dos cenários, são considerados valores máximos de desvios padrão de 15%, 10% e 35% para as variáveis de demanda, preço do mercado grossista e dos VEs respectivamente. Os valores mínimos de desvios padrão considerados para estas variáveis são de 8%, 6% e 20%. Na Tabela 10 é apresentada um resumo das características dos recursos enérgicos da rede.

Tabela 10 – Características dos recursos energéticos – DS

Recurso Energético	Preços (u.m/MWh)		Capacidade (MW)		Previsão (MW)		Quantidades	
	Min	Max	Min	Max	Min	Max		
Biomassa	130	130	0,02	6,23			17	
Fotovoltaica	150	150	-	-	0	0,36	44	
Eólica	90	90	-	-	0	0,69	55	
Fornecedor Externo	100	160	0,05	5,00	-	-	1	
SAEs	Carga	0	0	0,00	1,20	-	-	7
	Descarga	10	10	0,00	1,20	-	-	7
VEs	Carga	130	130	0,31	1,01	-	-	5
	Descarga	180	180	0,31	1,00	-	-	5
RD	Redução	20	20	0,00	5,64	-	-	90
	Acréscimo	20	20	0,00	5,64	-	-	90
Consumidores	160	160			0,56	14,09	90	
MP (compra e venda)	45	84	0,00	2,00			1	

## 4.2 Casos de Estudo – Problema do dia seguinte

Inicialmente são gerados 5 000 cenários que representam a distribuição probabilística das incertezas dos recursos energéticos. Em seguida, por meio da metodologia de GAMS/SCENRED, o número de cenários é reduzido para 150, os quais representam com grau aceitável de precisão as incertezas dos recursos energéticos (Soares, et al., 2017) e (Dabhi & Pandya, 2020).

Para aplicar a metodologia do problema GRE do DS baseado no risco, proposta neste trabalho, foi necessário inserir 15 cenário extremos. A inserção destes cenários extremos tem como objetivo melhorar a observação da influência do CVaR sobre a FO e sobre o agendamento dos recursos energéticos (resposta do modelo).

Deste modo, com objetivo de observar o comportamento dos resultados da primeira metodologia e da métrica de risco CVaR, serão realizados 3 casos de simulação, conforme exposto na Tabela 11. Em cada caso de simulação, para cada nível de confiança ( $\alpha$ ) o nível de aversão ao risco do agregador ( $\beta$ ) será variado, permitindo análise da FO do modelo e do agendamento dos recursos energéticos.

Tabela 11 – Casos de estudo metodologia 01

Casos	Nível de Confiança ( $\alpha$ )	Nível aversão ao risco ( $\beta$ )
01	99%	0 a 1
02	95%	0 a 1
03	90%	0 a 1

Em síntese,  $\alpha$  representa intervalo de confiança dos resultados dos cenários estocástico considerados no processo de otimização do problema. Comumente são utilizados valores de 99% e 95%, que representa que  $(1 - \alpha)$  % dos cenários estão fora dos limites da métrica de risco,

ou seja, CVaR irá representar um custo médio da ocorrência desses  $(1 - \alpha) \%$  (Almeida, et al., 2022).

Já o nível de aversão ao risco ( $\beta$ ), está relacionado a postura do agregador em relação a sua exposição a ocorrência de cenários extremos, podendo este optar por uma postura totalmente neutra,  $\beta = 0$ , ou uma postura totalmente aversa  $\beta = 1$ . Para os casos proposto, serão analisado o comportamento dos resultados e do CVaR variando o nível de aversão ao risco, desde uma posição neutra para totalmente aversa, para cada nível de confiança, conforme mostrado na Tabela 11.

### 4.3 Casos de Estudos – Intra Diário

Para demonstrar a aplicação da metodologia do problema ID, será utilizado a rede de distribuição já apresentada neste trabalho. Além disso, será considerado os resultados do agendamento dos recursos energéticos obtidos com as simulações do problema do DS baseado no risco, deste trabalho, porém será necessário realizar duas adaptações.

A primeira adaptação diz respeito à natureza da formulação do problema de otimização de GRE. Enquanto o problema de GRE do DS é um modelo estocástico baseado em cenários probabilísticos, o modelo do problema de GRE ID é determinístico. Para superar essa diferença, os 150 cenários estocásticos são transformados em único cenário médio, utilizando a média ponderada pela probabilidade associada a cada cenário. Os resultados do problema DS, também passam pela mesma transformação. Como consequência da utilização da média ponderada, algumas diferenças no valor da FO do DS em comparação com ID são observadas.

A segunda adaptação, tem relação ao passo de otimização dos modelos. Como apresentado anteriormente neste trabalho, o problema ID possui um passo de otimização de  $\frac{1}{4}$  de hora, ou seja, todas respostas e decisões são tomadas a cada 15 minuto, enquanto para o problema do DS, as decisões são na base horária (1 h). Diante desse fato, é necessário transformar todas as variáveis associada ao tempo para mesma base tempo, ou seja, para a base de 15 minutos. Na Tabela 12 é apresentado um resumo das características dos recursos energéticos para o problema ID.

Tabela 12 – Características dos recursos energéticos – ID

Recurso Energético	Preços (u.m/MWh)		Capacidade (MW)		Previsão (MW)		Quantidades	
	Min	Max	Min	Max	Min	Max		
Biomassa	32,5	32,5	0,02	6,23			17	
Fotovoltaica	37,5	37,5	-	-	0	0,36	44	
Eólica	22,5	22,5	-	-	0	0,69	55	
Fornecedor externo	25	40	0,05	5,00	-	-	1	
SAEs	Carga	0	0	0,00	1,20	-	-	7
	Descarga	10	10	0,00	1,20	-	-	7

Tabela 12 - Continua

Tabela 12 - Conclusão

Recurso Energético		Preços (u.m/MWh)		Capacidade (MW)		Previsão (MW)		Quantidades
		Min	Max	Min	Max	Min	Max	
VEs	Carga	32,5	32,5	0,31	1,01	-	-	5
	Descarga	45	45	0,31	1,00	-	-	5
RD	Redução	4	4	0,00	5,64	-	-	90
	Acréscimo	4	4	0,00	5,64	-	-	90
Consumidores		40	40			0,56	14,09	90
MP (compra e venda)		11,25	21	0,00	30% da carga			1
MLE (compra e venda)		22,5	42	0,00	30% da carga			1
PE		50	50	-	-	-	-	-

Para simular a ocorrência das incertezas associadas aos recursos energéticos próximos ao horizonte de operação, serão definidos níveis de erros de previsão nos dados de entrada com objetivo de analisar o processo de busca da resposta otimizada para o problema de GRE no horizonte ID proposto. Para tal, são definidos níveis de erro de previsões de demanda (carga) e da geração das unidades não despacháveis (geradores renováveis). As perturbações serão divididas em 3 níveis:  $\pm 2\%$  a  $\pm 5\%$ ,  $\pm 7\%$  a  $\pm 10\%$  e  $\pm 12\%$  a  $\pm 15\%$ . A Tabela 13 apresenta um resumo dos estudos de caso utilizados para testar a metodologia do problema ID.

Tabela 13 – Estudos de casos problema ID

Casos	Níveis de erro de previsão carga (%)	Níveis de erro de previsão geração (%)	Limitação uso SAEs e VEs	MLE?
01	0%, 2% a 5%, 7% a 10% e 12% a 15 %	-	0%	Não
	0%, -2% a -5%, -7% a -10% e -12 a -15%	-	0%	Não
02	0%, 2% a 5%, 7% a 10% e 12% a 15 %	-	0%	Sim
	0%, -2% a -5%, -7% a -10% e -12 a -15%	-	0%	Sim
03	-	0%, 2% a 5%, 7% a 10% e 12% a 15 %	0%	Não
	-	0%, -2% a -5%, -7% a -10% e -12 a -15%	0%	Não
04	-	0%, 2% a 5%, 7% a 10% e 12% a 15 %	0%	Sim
	-	0%, -2% a -5%, -7% a -10% e -12 a -15%	0%	Sim

Tabela 13 - Continua

Tabela 13 - Conclusão

Casos	Níveis de erro de previsão carga (%)	Níveis de erro de previsão geração (%)	Limitação uso SAEs e VEs	MLE?
05	0%, 2% a 5%, 7% a 10% e 12% a 15 %	-	10%	Não
	0%, -2% a -5%, -7% a -10% e -12 a -15%	-	10%	Não
06	0%, 2% a 5%, 7% a 10% e 12% a 15 %	-	10%	Sim
	0%, -2% a -5%, -7% a -10% e -12 a -15%	-	10%	Sim
07	-	0%, 2% a 5%, 7% a 10% e 12% a 15 %	10%	Não
	-	0%, -2% a -5%, -7% a -10% e -12 a -15%	10%	Não
08	-	0%, 2% a 5%, 7% a 10% e 12% a 15 %	10%	Sim
	-	0%, -2% a -5%, -7% a -10% e -12 a -15%	10%	Sim
09	0%, 2% a 5%, 7% a 10% e 12% a 15 %	-	25%	Não
	0%, -2% a -5%, -7% a -10% e -12 a -15%	-	25%	Não
10	0%, 2% a 5%, 7% a 10% e 12% a 15 %	-	25%	Sim
	0%, -2% a -5%, -7% a -10% e -12 a -15%	-	25%	Sim
11	-	0%, 2% a 5%, 7% a 10% e 12% a 15 %	25%	Não
	-	0%, -2% a -5%, -7% a -10% e -12 a -15%	25%	Não
12	-	0%, 2% a 5%, 7% a 10% e 12% a 15 %	25%	Sim
	-	0%, -2% a -5%, -7% a -10% e -12 a -15%	25%	Sim

Outra análise que será realizada, com o objetivo de conectar as duas metodologias proposta, é identificar e analisar a consequência da posição do agregador em relação ao risco, na ocorrência de incertezas próximas ao horizonte de operação. Deste modo será escolhido um único cenário específico para cada posição do agregador em relação ao risco. Para a posição neutra,  $\beta = 0$ , será escolhido o cenário com maior custo esperado ( $Z_s^{tot}$ ), já para a posição totalmente avessa,  $\beta = 1$  o cenário com menor custo esperado. O nível de confiança  $\alpha$  escolhido será o de 99% para ambas as posições. A Tabela 14 mostra os cenários escolhidos para aplicação dos estudos de casos.

Tabela 14 – Cenário de exposição ao risco – ID

$\beta$	$\alpha$	Nº Cenário	Valor $Z_s^{tot}$ no DS
0	99%	79	323,07 u.m
1	99%	136	29,07 u.m

Para os testes utilizando o cenário médio ponderado, será utilizado o resultado do problema do DS para uma posição totalmente aversa ao risco, com  $\beta = 1$ , e um nível de confiança igual 99%. Durante os testes, não foram observadas diferenças significativas na resposta do problema ID para outros valores de  $\beta$  e  $\alpha$ . Isso pode ser justificada pela utilização do cenário médio ponderado, onde as pequenas diferenças são diluídas na média.

## 5 Resultados

Neste capítulo, serão apresentados e discutidos os resultados obtidos com as duas metodologias proposta neste trabalho para resolver o problema de GRE do DS baseado no risco e no problema GRE no horizonte ID.

### 5.1 Problema do dia seguinte baseado no risco

A primeira metodologia desenvolvida neste trabalhado consiste em um modelo estocástico de dois estágios para resolver o problema de GRE para o DS, levando em consideração o risco. O método envolve uma otimização com 150 cenários e um total de 1 459 090 variáveis, incluindo 1 243 600 variáveis de decisão e 215 490 variáveis de restrições. Na Tabela 15 são apresentados os tempos de execução dos casos de estudo e os picos de memória correspondentes.

Tabela 15 – Tempo de execução e uso de memória

Casos	$\beta = 0$		$\beta = 1$	
	Tempo execução (min)	Pico de memória (MB)	Tempo execução (min)	Pico de memória (MB)
01 ( $\alpha = 99\%$ )	29,05	4 328,12	28,32	3 473,35
02 ( $\alpha = 95\%$ )	29,45	4 300,19	28,45	3 684,67
03( $\alpha = 90\%$ )	29,49	4 249,30	30,61	4 327,50

As simulações foram realizadas em um computador de processador único Intel Core i5-930CH @2.40GHz com 12 GB de memória RAM, com Windows 11 Pro, utilizando MATLAB R2018b e TOMLAB v8.1, com solucionador CPLEX. Conforme mostrado na Tabela 15, o tempo de execução é em média de 29,23 min, sendo um tempo compatível com prazo disponível para o processo de decisão. Em relação ao pico de uso memória é no máximo de 4 328,12 MB, sendo adequado aos atuais computadores.

Na Tabela 16, é fornecido um resumo dos valores do custo esperado ( $Z^{Ex}$ ), métrica de risco CVaR e do valor da FO para os casos de estudo proposto neste trabalho. Observa-se que, ao adotar uma posição neutra em relação ao risco,  $\beta = 0$ , os valores da FO permanecem inalterados para diferentes níveis de confiança  $\alpha$ . Isso ocorre porque a métrica de risco, o CVaR, não influencia a FO para essa posição.

Tabela 16 – Resultados dos resultados para o problema do DS

Casos	Neutra $\beta = 0$			Aversa $\beta = 0$		
	$Z^{Ex}$ (u.m)	CVaR (u.m)	FO (u.m)	$Z^{Ex}$ (u.m)	CVaR (u.m)	FO (u.m)
$\alpha = 99\%$	28,687	233,710	28,687	29,615	54,265	83,880
$\alpha = 95\%$	28,687	104,107	28,687	28,759	34,174	62,933
$\alpha = 90\%$	28,687	33,619	28,687	28,720	31,348	60,068

Por outro lado, ao analisar os resultados da Tabela 16 para uma postura totalmente aversa ao risco,  $\beta = 1$ , observa-se um comportamento diferente. Nesta situação, o CVaR é incorporado à FO, sendo minimizado juntamente com o custo global. Nota-se que, para níveis de confiança mais altos,  $\alpha = 99\%$ , o custo esperado e CVaR apresentam um valor maior em comparação com os demais níveis de confiança. Isso ocorre porque, em um  $\alpha = 99\%$ , apenas 1% dos cenários extremos estão fora do intervalo de confiança, enquanto em  $\alpha = 90\%$ , 10% dos cenários extremos ficam fora desse intervalo. Como resultado, nos casos com níveis de confiança mais elevados, o CVaR tende a ter um valor mais alto, refletindo-se em uma FO também mais elevada. A Figura 13 ilustra o comportamento do CVaR para as diferentes posturas de aversão ao risco e níveis de confiança.

Ao analisar a Figura 13, é evidente a variação significativa do CVaR para diferentes níveis de confiança. Para  $\alpha = 99\%$ , o CVaR varia de um mínimo de 54,26 u.m a um máximo de 57,00 u.m. Enquanto para  $\alpha = 95\%$  e  $90\%$ , as faixas de variação são de 34,17 u.m a 34,35 u.m e 31,34 u.m a 31,42 u.m, respectivamente. Assim, observa-se uma diferença na ordem de 20 u.m entre  $\alpha = 99\%$  e os outros níveis de confiança. Esse mesmo padrão pode ser constatado, de forma indiretamente, pelos valores das FOs apresentadas na Tabela 16.

Ainda em relação à Figura 13, sob a perspectiva do nível de exposição ao risco  $\beta$ , observamos um comportamento linear decrescente. Para uma posição neutra,  $\beta = 0$ , o CVaR atinge seu máximo, enquanto para uma posição totalmente aversa ao risco,  $\beta = 1$ , ele é minimizado. Essa tendência é esperada, pois para uma posição neutra, o problema de otimização não busca ativamente minimizar o risco ao qual o agregador está exposto. Em contrapartida, para uma posição totalmente aversa, todas as decisões do processo de otimização são orientadas pela métrica de risco, ponderada pelo fator  $\beta$ . Em suma,  $\beta$  representa um percentil que reflete o impacto do CVaR sobre a FO.




Figura 13 – Comportamento CVaR em relação  $\beta$  e  $\alpha$

Outro aspecto relevante destacado na Figura 13 é a significativa variação observada entre os valores de  $\beta$  iguais a 0 e 0,1. Para  $\beta = 0$ , os CVaRs são de 233,71 u.m, 104,11 u.m e 33,61 u.m para os níveis de confiança de 99%, 95% e 90%, respectivamente. Já para  $\beta = 0,1$ , verificamos os CVaRs de 57,00 u.m, 104,10 u.m e 33,62 u.m para os mesmos níveis de confiança. Esse fenômeno pode ser atribuído ao processo de otimização, no qual, para  $\beta = 0$ , a métrica de risco não influencia a FO, assumindo dentro do processo de otimização, valores apenas para satisfazer as restrições matemáticas do problema. Assim, os valores de CVaR para uma posição neutra são determinados posteriormente, utilizando o custo de cada cenário do problema e o nível de confiança.

Na Figura 14, podemos observar de forma mais evidente a relação entre a FO e o CVaR, onde à medida que o nível de aversão ao risco aumenta, o custo do agregador também aumenta, porém, o risco associado à operação é minimizado. Em outras palavras, o agregador fica exposto a valores de risco menores. Além disso, ao analisar a Figura 14, podemos identificar em quais posições de aversão ao risco ocorrem as maiores reduções do CVaR. Nota-se que, para um nível de confiança de 99%, as maiores reduções de CVaR ocorrem entre os valores de  $\beta = 0$  a  $\beta = 0,6$ , enquanto para um  $\alpha = 95\%$  e  $\alpha = 90\%$ , as maiores reduções ocorrem até uma posição de  $\beta = 0,4$ .

Neste contexto, podemos afirmar que assumir posições de exposição ao risco além de  $\beta = 0,6$  não resultará em reduções significativas no risco de operação (CVaR) para um nível de confiança de 99%. Da mesma forma, que para  $\alpha = 95\%$  e  $90\%$ , assumir posições além de  $\beta = 0,4$  não resultará em reduções relevantes do CVaR.




Figura 14 – Comportamento do CVaR (β) x FO

Outra análise relevante é a relação entre o custo total esperado de todos os cenários estocásticos ( $Z^{Ex}$ ) e o CVaR, conforme é mostrado na Figura 15. Observa-se que, à medida que o agregador assume uma postura mais aversa ao risco, o CVaR diminui, mas isso vem acompanhado de um aumento no custo esperado. Em outras palavras, as decisões tomadas para minimizar o CVaR, resultam em custos mais altos para o agregador. Apesar desse custo mais elevado, em comparação com a outras posições de exposição ao risco, o agregador fica menos exposto a custos extras decorrentes da ocorrência de cenários extremos.

Ainda em relação à Figura 15, é possível observar o impacto da escolha dos níveis de confiança mais elevados. Para um  $\alpha = 99\%$ , os custos esperados são de 29,615 u.m e 28,688 u.m para  $\beta$  iguais a 1 e 0, respectivamente. Já para um nível de confiança de 95%, os custos esperados são de 28.759 u.m e 28.668 u.m para os mesmos valores de  $\beta$ . Para um  $\alpha = 90\%$ , os custos esperados são de 28,720 u.m e 28,688 u.m para  $\beta$  iguais a 1 e 0, respectivamente. Essa observação revela que o custo esperado para  $\beta = 0$  permanece igual para os três níveis de confiança, uma vez que, o CVaR não impacta na FO do problema.

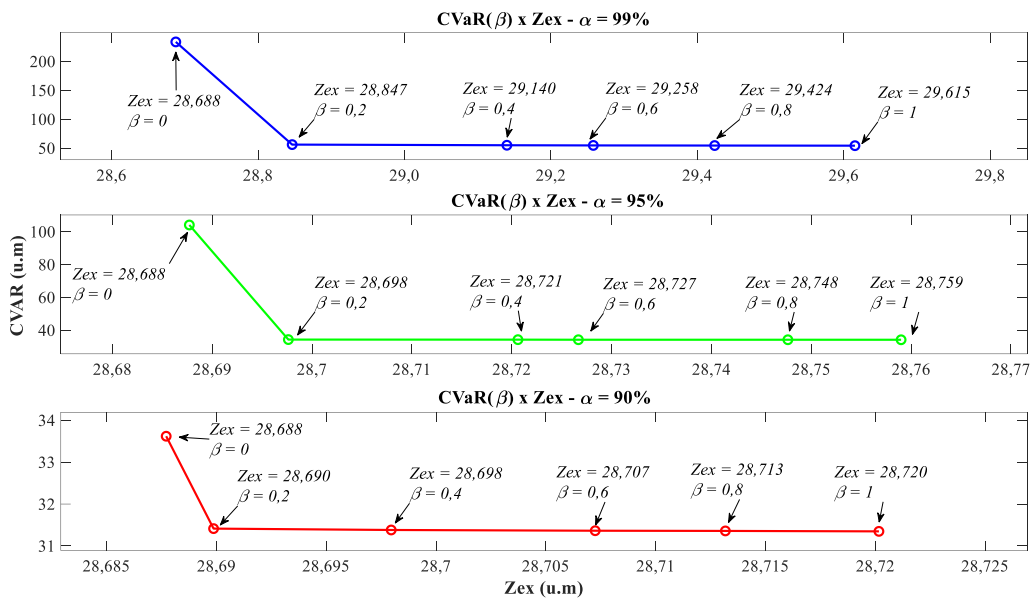


Figura 15 - Comportamento do CVaR (β) x Zex

Em síntese, o custo esperado total representa a média do custo de cada cenário ponderada pela probabilidade de ocorrência de cada cenário previsto para o problema, sem considerar as métricas de risco. Outra análise relevante a ser realizada é observar o comportamento individual do custo esperado de cada cenário. Na Figura 16, são apresentados os custos esperados dos 150 cenários previstos no problema, para os diferentes níveis de confiança e aversão ao risco.

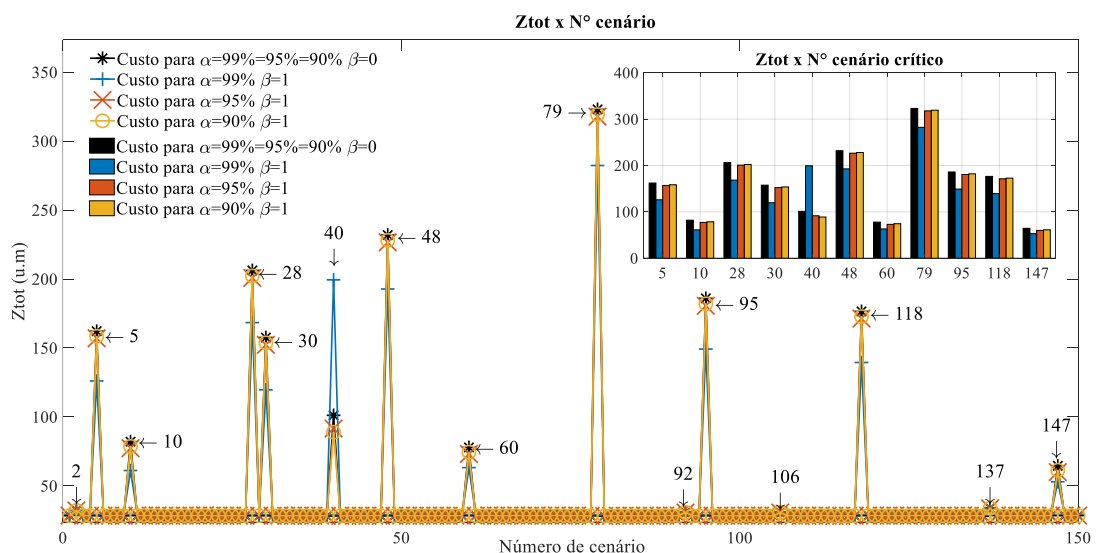


Figura 16 – Custo esperado por cenários

Os picos observados na Figura 16 correspondem aos custos esperados dos cenários extremos inseridos no conjunto dos cenários previstos, conforme descrito na seção anterior. Além disso, podemos compreender claramente a necessidade de modificar os cenários originais, uma vez

que, em média, o conjunto original de cenários, obtidos por meio das simulações de MSC, apresenta uma variação mínima em seu custo esperado individual, e consequentemente na métrica de risco, gerando pouco impacto sobre o processo de otimização.

De modo geral, os custos esperados de cenários crítico para uma posição avessa ao risco são inferiores quando comparado com os custos para uma posição neutra, conforme mostrado na Figura 16. Em relação ao nível de confiança, no subgráfico da Figura 16, nota-se as reduções dos custos esperados dos cenários para os diferentes  $\alpha$ .

Destaca-se que o cenário extremo de maior impacto sobre o agregador é o 79, no qual ocorre um acréscimo de demanda de energia de 40% e não há possibilidade do uso dos contratos de RD, resultando em um substancial aumento de custo devido ao não atendimento total da carga. Na Figura 17, observa-se o escalonamento dos recursos energéticos ligados à geração, evidenciando que em todas as horas há uma potência expressiva de carga não atendida, o que penaliza o agregador, elevando seu custo de operação.




Figura 17 – Escalonamento dos recursos – geração -  $\alpha = 90\%$  e  $\beta = 1$

Outro cenário que vale o destaque, é o cenário 40. Nesse cenário, ocorre uma redução do consumo de energia em 40% e um aumento de 40% na produção dos geradores eólicos e fotovoltaicos. Para  $\beta = 1$  e  $\alpha = 99\%$ , observa-se que o custo esperado é mais elevado em comparação com os demais casos,  $\beta = 0$  e  $\alpha$  iguais 95% e 90%, conforme evidenciado no subgráfico da Figura 16. Este custo mais elevado se dá pela necessidade de restringir a geração dos geradores renováveis ao longo do dia. Para uma análise mais detalhada dos resultados desses cenários, são construídos os gráficos dos escalonamentos dos recursos energéticos, apresentados na Figura 18 e na Figura 19.

Ao comparar as Figura 18 e Figura 19, destacam-se as diferenças no escalonamento dos recursos energéticos entre as posições neutra e avessa ao risco. A diferença mais significativa é o corte de geração dos geradores renováveis (não despacháveis). Nesse cenário específico, há um excedente de geração, que o sistema não consegue absorver completamente, resultando na necessidade de impor restrições à produção. No entanto, para evitar prejuízos financeiros aos produtores, essas restrições são compensadas financeiramente, gerando custos adicionais para o agregador.




Figura 18 – Escalonamento dos recursos – cenário 40 -  $\beta = 0$




Figura 19 – Escalonamentos dos recursos – cenário 40 –  $\alpha = 99\%$  e  $\beta = 1$

Nas Figura 20 e Figura 21, são apresentados os escalonamentos dos recursos energéticos para os níveis de confiança de 95% e 90%, respectivamente. Ao compararmos esses escalonamentos com o da Figura 19, onde  $\alpha = 99\%$  e  $\beta = 1$ , a principal diferença está na quantidade de corte de geração renováveis. Para  $\alpha = 99\%$ , observa-se uma maior potência restringida em comparação com os níveis de 95% e 90%. O mesmo padrão é verificado ao comparar os níveis de corte de geração entre  $\alpha = 95\%$  e  $90\%$ , com níveis mais acentuados para  $\alpha = 95\%$ .




Figura 20 - Escalonamentos dos recursos – cenário 40 –  $\alpha = 95\%$  e  $\beta = 1$

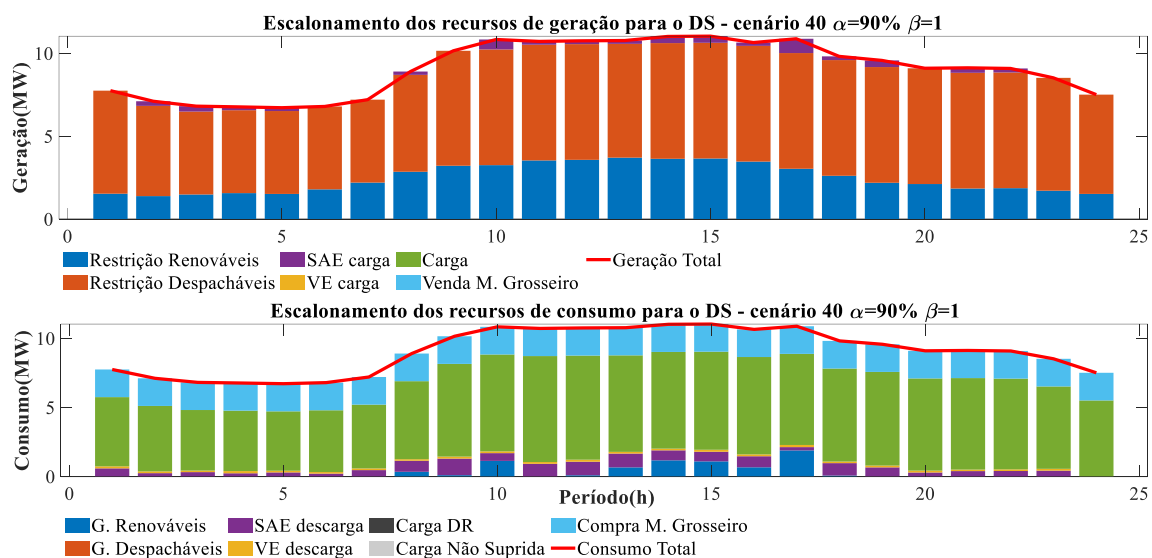


Figura 21 – Escalonamentos dos recursos – cenário 40 –  $\alpha = 90\%$  e  $\beta = 1$

Nesta mesma perspectiva de análise, com base na Tabela 17, percebe-se que no caso de estudo em  $\beta = 1$  e  $\alpha = 99\%$ , como mostrado na Figura 19, as restrições na geração renovável ocorrem ao longo do dia, sendo mais significativas nas primeiras horas (horas 3 a 8). Por outro lado, nos outros casos de estudo, em que  $\beta = 1$  e  $\alpha$  são 95% e 90%, as restrições estão concentradas em horas específicas do dia (horas 8, 9, 13, 14, 15, 16 e 17).

Tabela 17 – Resumo das restrições de geração não despacháveis – cenário 40

Hora	$\alpha=99\%=95\%=90\%$ $\beta = 0$ $P_{RDG}$ (MW)	$\alpha = 99\%$ $\beta = 1$ $P_{RDG}$ (MW)	$\alpha = 95\%$ $\beta = 1$ $P_{RDG}$ (MW)	$\alpha = 90\%$ $\beta = 1$ $P_{RDG}$ (MW)
1	0,0000	0,1581	0,0000	0,0000
2	0,0074	0,6779	0,0000	0,0000
3	0,1291	1,4887	0,0000	0,0000
4	0,0000	1,5704	0,1335	0,0000
5	0,2348	1,4791	0,0000	0,0000
6	0,2370	1,4228	0,0000	0,0000
7	0,1115	1,5153	0,0000	0,0000
8	0,0453	1,7257	1,2894	0,3450
9	0,1537	0,5788	0,7092	0,1006
10	1,3310	1,1958	0,0958	1,1339
11	1,5271	1,3221	0,3221	0,0000
12	0,4784	0,6043	0,2731	0,0941
13	0,4201	0,9804	0,7663	0,6646
14	0,9443	1,0979	0,9399	1,1744
15	0,7627	0,9938	0,9802	1,0995
16	0,5877	1,1292	0,8699	0,6699
17	1,0592	0,9685	0,6636	1,8926
18	0,5081	0,0000	0,0351	0,0723
19	0,0000	0,0000	0,4606	0,0000
20	0,0000	0,2684	0,0000	0,0000
21	0,0000	0,0761	0,0000	0,0000
22	0,0735	0,0834	0,0000	0,0000
23	0,0000	0,0000	0,0000	0,0000
24	0,0000	0,0000	0,0000	0,0000
Total	8,6109	19,3365	7,5387	7,2470

Quando examinamos a potência total restringida dos geradores renováveis ao longo do horizonte de otimização de 24 horas, conforme apresentado na Tabela 17, encontrando os seguintes valores: 19,3365 MWh, 7,5387 MWh e 7,2470 MWh, para  $\beta = 1$  e  $\alpha$  de 99%, 95% e 90%, respectivamente. Para  $\beta = 0$ , a restrição total é de 8,6109 MWh. Assim, podemos concluir que o motivo principal pelo qual o custo esperado do cenário 40, para  $\beta = 1$  e  $\alpha = 99\%$ , é superior aos demais, decorre da maior quantidade de energia restringida dos geradores renováveis, em comparação com os outros casos de estudo.




Figura 22 - Escalonamentos dos recursos – cenário médio –  $\alpha = 99\%$  e  $\beta = 1$

Nas Figura 22 e Figura 23 são apresentados os resultados médios do escalonamento dos recursos energéticos para  $\beta = 1$  e  $\beta = 0$ , respectivamente. Ao analisarmos os dois resultados, observamos apenas pequenas diferenças no escalonamento, sendo uma delas o uso do RD. Para  $\beta = 1$ , o uso do RD é menor quando comprado com caso de estudo  $\beta = 0$ . Essa discrepância sutil também é refletida no custo total esperado,  $Z^{Ex}$ , apresentado na Figura 15, onde a diferença entre os dois casos de estudos é de apenas 0,927 u.m, representando apenas de 3,18%.




Figura 23 - Escalonamentos dos recursos – cenário médio –  $\alpha = 99\%$  e  $\beta = 0$

A pequena discrepância entre os resultados médios do escalonamento entre as posições de aversão ao risco pode ser explicada pelo uso da média ponderada. Essa média é calculada levando em consideração a probabilidade de ocorrência dos 150 cenários previstos para este

estudo. Dessa forma, as principais diferenças nos cenários críticos não são observadas, pois sua probabilidade de ocorrência é mínima. Apesar de não haver grandes variações no escalonamento médio dos recursos energéticos, ele é importante, uma vez que será um dos pontos de partida para a segunda metodologia proposta neste trabalho.

## 5.2 Problema do Intra diário

A segunda metodologia proposta neste trabalho consiste em um modelo determinístico do tipo MILP para resolver o problema de GRE no horizonte ID, utilizando como dados de entrada os resultados da metodologia do problema do DS baseado no risco. Nesta primeira análise, serão utilizados resultados obtidos para uma posição igual  $\beta = 1$  e  $\alpha = 99\%$ . O modelo de otimização prevê um problema com 65 472 variáveis de decisão e 25 728 variáveis de restrição.

Os estudos de caso descrito na seção anterior foram utilizados para testar a metodologia proposta para resolver o problema de GRE no horizonte ID. As simulações foram realizadas em um computador de processador único Intel Core i5-930CH @2,40GHz com 12 GB de memória RAM, com Windows 11 Pro, utilizando MATLAB R2018b e TOMLAB v8,1, com solucionador CPLEX. Em média o tempo de execução é de 0,29 segundos, com pico de uso memoria máxima de 2 559,82 MB, o que se mostra adequado para os computadores modernos.

A análise principal consiste na comparação dos valores da FO do problema ID com os valores da FO do problema do DS baseado no risco proposto neste trabalho, além de observar o impacto do MLE nas respostas do problema. A Figura 24 tem como objetivo apresentar uma comparação entre as FOs para cada nível de erro de previsão de carga em relação à FO do modelo DS. Nesta primeira comparação, nenhum nível de flexibilidade do uso dos SAEs e VEs será considerado.




Figura 24 – FO ID x Erros de previsão na demanda – 0% flexibilidade

Idealmente, quando não há erros de previsão (representados pelas barras 0% na Figura 24), ou seja, quando as previsões realizadas com dia de antecedência se concretizam, os valores das FOs do modelo do ID devem ser iguais aos DS. No entanto, observamos uma diferença de 4,09%

para caso 01 e 3,37% para caso 02. Essa discrepância pode ser atribuída ao uso média ponderada para transformar os dados de entrada do modelo, o que não é ideal e pode resultar em pequenos desvios nas respostas do problema.

Além disso, na Figura 24, é evidente que as maiores diferenças entre as FOs do ID e a FO do DS ocorrem na faixa de erro de previsão de 12% a 15%, especialmente nos erros positivos. Em outras palavras, os erros positivos na previsão de cargas indicam uma demanda de energia maior do que a prevista no modelo do DS, o que pode resultar em cortes de carga ou em um uso mais intenso dos recursos energéticos associados ao agregador. Também é observado que, no caso 02, onde há a presença de um MLE, o modelo realiza vendas de energia quando há erros de previsão negativos, evitando assim penalizações decorrentes de cortes de geração, além de fornecer uma fonte adicional de remuneração ao agregador, o que contribui para a redução do custo de sua operação.

A Figura 25 apresenta um resumo da comparação das FOs quando são simulados erros de previsão sobre a geração renovável do sistema. Observa-se que a diferença percentual em relação ao DS é menor em comparação com as simulações da Figura 24. Essa situação pode ser explicada pelo fato de o erro estar associado apenas às gerações renováveis, que representam 70% de toda geração do sistema. Além disso, nota-se que, para as simulações com 0% de erro de previsão, a diferença percentual é a mesma da Figura 24.




Figura 25 – FO ID x Erros de previsão na ofertada – 0% flexibilidade

Na Figura 26, são apresentadas as FOs das simulações dos casos 03 e 04, nos quais é considerada uma flexibilidade de 10% no uso dos recursos de SAEs e VEs. De imediato, observamos que as diferenças percentuais em relação à FO do DS, quando não são considerados erros de previsão (barras 0% da Figura 26), são inferiores às observadas nos casos 01 e 02 (Figura 24 e Figura 25), sendo de 0,62% e 0,20%, respectivamente. Esse fato pode ser justificado pela possibilidade de uso dos SAEs e VEs em até 10% sem que haja penalizações para o agregador, minimizado assim o efeito do uso da média ponderada.




Figura 26 – FO ID x Erros de previsão na demanda – 10% flexibilidade

Comparando as diferenças percentuais em relação à FO do DS entre as Figura 24 e Figura 26, observamos que quando há uma flexibilidade de uso dos SAEs e VEs, os impactados dos erros de previsão sobre a FO são menores do que nos casos em que não há flexibilidade (casos 01 e 02). Para os casos 05 e 06, a maior diferença percentual é de 18,20%, em comparação com 21,53% nos casos 01 e 02. Essa diferença pode ser explicada pela possibilidade do uso dos SAEs e VEs para minimizar os impactos dos erros de previsão.




Figura 27 – Escalonamento recursos ID - caso 06

Além disso, observamos que a flexibilidade de uso dos SAEs e VEs permite uma leve redução dos custos do agregador (FOs) na presença do MLE. Confrontando os valores da FOs do caso 06 com a caso 02 (Figura 24 e Figura 26), especialmente as variações negativas, percebe-se valores de FOs inferiores para o caso 06. Sua maior diferença ocorre na faixa de erro de previsão de 12 a 15%, onde temos 24,00 u.m para o caso 06, contra 25,15 u.m para o caso 02. Na Figura 27, é mostrado o escalonamento dos recursos energéticos para o caso 06 e nas faixas de erro de

previsão de 12 a 15%. Podemos observar que em todos os períodos de otimização há venda de energia no MLE, justificando a redução dos custos operacionais do agregador, uma vez que há uma fonte de remuneração extra para esse caso em específico.

Para observar o impacto dos erros sobre a previsão de geração renovável com a flexibilidade de uso SAEs e VEs de 10%, são simulados os casos 07 e 08. Os resultados e comparações são ilustradas na Figura 28. Assim, ao analisar as diferenças percentuais em relação a FO do DS, observamos que são mínimas, sendo a maior diferença verificada para o caso 07, igual a 4,51%, para faixa de erro 12 a 15%, nomeadamente para variações positivas.




Figura 28 - FO ID x Erros de previsão na oferta – 10% flexibilidade

Ao compararmos as diferenças percentuais entre a Figura 28 e a Figura 25, podemos observar os benefícios que a flexibilidade de uso dos recursos de armazenamento traz para o agregador. Na Figura 25, a maior diferença é de 8,43% enquanto na Figura 28 é de 4,51%. Isso significa que, mesmo restrita a 10%, a flexibilidade de uso é capaz de minimizar o impacto dos erros de previsão de geração. Os mesmos resultados são observados quando comparamos a Figura 24 e a Figura 26 (casos de estudo onde há erros de previsão da carga).

Os estudos de casos 09, 10, 11 e 12 têm como objetivo identificar as vantagens de fornecer uma maior flexibilidade de uso dos recursos de armazenamento, considerando uma flexibilidade de 25%. Ao comparar os casos 09 e 10 com os casos 05 e 06 (Figura 29 e Figura 26), não observamos impactos significativos, apenas pequenas reduções nas FOs de forma geral. Para as simulações que preveem erros de previsão de geração renovável, Figura 30, quando confrontada com a Figura 28, também não se observam grandes reduções. Deste modo, podemos afirmar que, apesar da flexibilidade de uso dos SAEs e VEs trazer vantagens ao agregador, diminuindo o impacto de erros de previsão próximo ao horizonte de operação, o benefício é limitado.

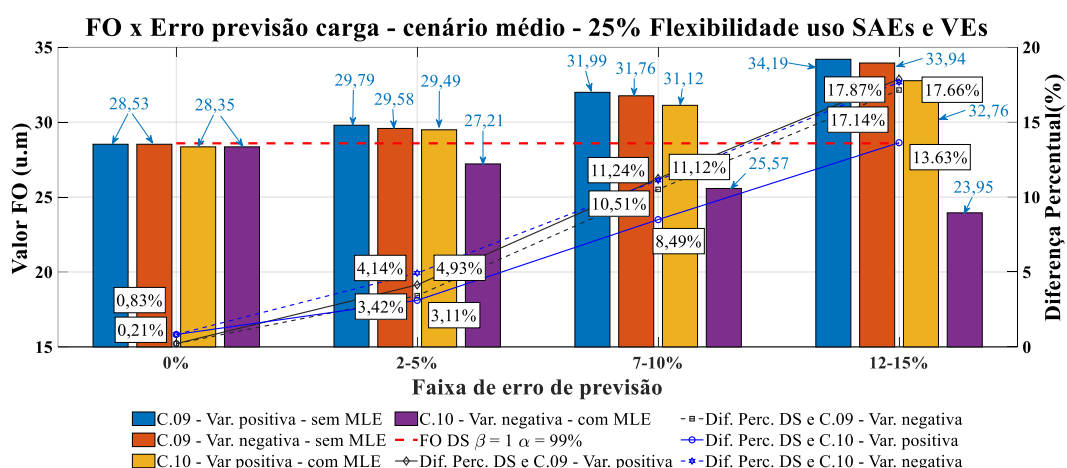


Figura 29 - FO ID x Erros de previsão na demanda – 25% flexibilidade




Figura 30 - FO ID x Erros de previsão na oferta – 25% Flexibilidade

Outra análise importante da metodologia do problema ID é examinar o comportamento das respostas em cenários específicos dos 150 cenários previstos para o modelo do DS baseado no risco. Inicialmente, é fundamental avaliar a exposição ao risco do agregador. Para uma posição neutra ( $\beta = 0$ ), é selecionado o cenário com o maior custo operacional, o de número 79, enquanto para posição aversa ( $\beta = 1$ ), opta-se pelo cenário de menor custo, o de número 139. Os mesmos casos de estudos descritos na Tabela 13 são aplicados nesses dois cenários, porém a análise é limitada a uma flexibilidade 10% no uso dos recursos de armazenamento. Nas Figura 31 e Figura 33, são apresentados os valores para cada caso de estudo e suas diferenças percentuais em relação ao valor do modelo do DS.

Comprando os resultados das Figura 31 e Figura 33 com os resultados anteriores (cenário médio, Figura 24 e Figura 25), observamos que há presença do MLE gera grande impactos positivos para o agregador. O MLE cria um ambiente no qual o agregador tem opção por buscar recursos para atender suas necessidades, evitando deste modo penalizações por cortes de carga ou geração.




Figura 31 - FO ID x Erros de previsão na demanda – c. máximo – 0% Flexibilidade

Nas simulações em que não foram consideradas erros de previsão (barra 0%, Figura 31), notou-se que o MLE proporcionou reduções significativas na FO em comparação com o modelo do DS, chegando a 144%. Essa redução pode ser atribuída à capacidade do agregador recorrer ao MLE para realizar compras e atender à sua demanda mais eficiente, evitando possíveis penalidades pelo não suprimento total da carga. Esse cenário é ilustrado Figura 32, que apresenta o escalonamento dos recursos energéticos para o caso 02, sem considerar erros de previsão. Observa-se que em todos os períodos de otimização, o modelo propôs a aquisição de energia por meio do MLE para atender à demanda do agregador, uma vez que o cenário 79 simula um aumento de 40% na demanda do sistema.

Aprofundando a análise da Figura 32, mesmo com a opção do agregador de realizar compras no MLE para satisfazer suas demandas, observam-se cortes de carga nos intervalos de otimização 43 a 50 e 75 a 93, resultando em penalizações ao agregador.




Figura 32 - Escalonamento recursos ID – c. máximo - caso 02

Nas demais faixas de erros de previsão de carga, o modelo consegue gerenciar os recursos de forma a reduzir os impactos nas FOs. É importante ressaltar, especialmente nas faixas de erros de previsão negativos, com ou sem inclusão do MLE, há consistentemente reduções nas FOs. Essas diminuições não são apenas resultado do processo de otimização, mas também da redução do excesso de demanda prevista no cenário 79.

Ao considerar erros de previsão de geração, especificadamente no caso 04 da Figura 33, observa-se que o MLE é eficaz em proporcionar um ambiente favorável para o agregador. Isso se traduz em reduções nos custos operacionais (FOs) do agregador.




Figura 33 – FO ID x Erros de previsão na oferta – c. máximo – 0% flexibilidade

Ao considerar uma margem de 10% para o uso SAEs e VEs nas Figura 34 e Figura 35, percebemos pequenas reduções nas FOs em comparação com as simulações que não levam em conta essa flexibilidade de usos (Figura 31 e Figura 33). Em relação às diferenças percentuais da FOs em relação à FO do DS, nota-se a mesma tendência das simulações anteriores, onde as diferenças são maiores para níveis mais elevados de erros de previsão. Além disso, constata-se que o MLE cria um ambiente propício para o agregador, possibilidade a redução de seus custos operacionais.




Figura 34 – FO ID x Erros de previsão na demanda – c. máximo – 10% Flexibilidade

Portanto, podemos concluir que o cenário máximo representa uma situação extremamente crítica do ponto de vista da operação do sistema, no qual os SAEs e VEs não conseguem oferecer flexibilidade suficiente para mitigar penalizações e custos do agregador.




Figura 35 - FO ID x Erros de previsão na oferta – c. máximo – 10% Flexibilidade

Considerando outros pontos de vista, voltado para o cenário em que o modelo do DS apresenta o menor valor de FO e o agregador adota uma postura de aversão ao risco, são aplicados os estudos de casos da Tabela 13. As Figura 36 e Figura 38 exibem os valores das FOs para cada nível de erro de previsão, comprando-os com a FO do DS. Como já observado com as simulações do cenário médio, a ausência de erros de previsão resulta em uma diferença entre o valor da FO do modelo ID e o do DS. No entanto, ao contrastarmos as Figura 25 e Figura 36, essa diferença se torna ainda mais evidente, chegando a dobrar. Para cenário médio, as diferenças são de 4,09% e 3,37%, enquanto para o cenário mínimo alcançam 8,83% e 7,75%.




Figura 36 - FO ID x Erros de previsão na demanda – c. mínimo – 0% Flexibilidade

Quanto ao aumento no nível de erro de previsão de carga, as variações percentuais evoluem de forma mais restrita em comparação com o cenário máximo (Figura 31). Em outras palavras, os erros que surgem no período ID têm um impacto menor sobre as FOs em comparação com o cenário máximo. Esta observação pode ser atribuída à postura do agregador em relação ao risco, onde uma postura aversa resulta em uma resposta do modelo do DS mais robusta.

Outra análise relevante a ser realizada é observar o impacto do MLE na resposta do modelo ID. Em um cenário mínimo, a influência sobre o agregador quando confrontado com as FOs do cenário máximo é pequena. O MLE oferece pequenas vantagens para os níveis mais elevados de erro de previsão (7-10% e 12-15%). Na Figura 37, é apresentado o escalonamento dos recursos energéticos para o caso 2, especificamente para variações negativas, onde observamos a presença de vendas no MLE.




Figura 37 - Escalonamento recursos ID – c. mínimo - caso 02

Em relação aos erros na previsão de geração renovável, as diferenças percentuais em comparação com o valor da FO do DS evoluem no mesmo ritmo que os próprios erros, alcançando uma diferença máxima de 13,27% para o caso 03, conforme observado na Figura 38. Esse padrão de comportamento é também evidente nas simulações realizadas com o cenário médio, conforme ilustrado na Figura 25.

De modo geral, o cenário mínimo, por refletir uma resposta mais próxima ao mínimo total, limita a eficácia do modelo ID em otimizá-lo, resultando em poucas diferenças nos estudos de caso. Outra justificativa para os padrões observados é a postura aversa ao risco, onde a resposta do modelo do DS se torna mais robusta diante de desvios ou erros de previsão.

Nas Figura 39 e Figura 40 são apresentados os resultados das simulações considerando uma flexibilidade de 10% para o uso de SAEs e VEs. Conforme esperado e observado previamente, em comparações com as simulações que não levam em conta essa margem de uso (Figura 36 e Figura 38), observamos pequenas reduções nas FOs. Em relação às diferenças percentuais das

FOs em relação à FO do DS, nota-se reduções, especialmente quando não se considera erros de previsão. Observa-se diferenças de 1,61% e 0,81%, enquanto para as simulações anteriores, as diferenças eram de 8,83% e 7,75%. Dessa forma, os SAEs e VEs demonstram fornecer uma flexibilidade capaz de compensar os desvios introduzidos pelas simplificações e modificações dos dados de entrada do modelo ID.




Figura 38 - FO ID x Erros de previsão na oferta – c. mínimo – 0% Flexibilidade




Figura 39 - FO ID x Erros de previsão na demanda – c. mínimo – 10% Flexibilidade

Em relação aos erros na previsão de geração renovável, as diferenças percentuais em comparação com o valor da FO do DS são mínimas, alcançando uma diferença máxima de 6,30% para o caso 07, conforme observado na Figura 40.




Figura 40 - FO ID x Erros de previsão na oferta – c. mínimo – 10% Flexibilidade

Em resumo, os resultados obtidos para todos os conjuntos de dados de entrada (cenário médio, máximo e mínimo) permitem observar a influência dos erros de previsão e das restrições de uso dos SAEs e VEs sobre a resposta do modelo ID. Especificadamente às diferenças percentuais em relação à FO do DS, as simulações considerando o uso do cenário médio e mínimo revelam diferenças menores, enquanto para o cenário máximo, observam-se grandes discrepâncias em relação à FO do DS. A explicação por trás desses fenômenos volta-se para a postura do agregador em relação ao risco, em que os resultados e dados de entrada do modelo ID refletem uma postura aversa ao risco ( $\beta = 1$ ) para os cenários médio e mínimo, enquanto para o cenário máximo, adota-se uma postura neutra ( $\beta = 0$ ).

### 5.3 Aspectos conclusivos

Neste capítulo, são apresentados os resultados obtidos com a aplicação das metodologias para resolver o problema GRE tanto para o DS, com base no risco, quanto para o horizonte ID. Os resultados foram obtidos utilizando o conjunto de casos de estudos definidos no capítulo anterior.

Inicialmente, são discutidos os resultados do modelo do DS baseado no risco. Para isso, é realizado uma análise da FO e do CVaR. Posteriormente, é examinado o custo total ao qual o agregador está sujeito, bem como os custos individuais de cada cenário. Essa abordagem permitiu observar o impacto da métrica de risco no processo de otimização.

Em resumo, o CVaR representa uma perda média financeira possível à qual o agregador estará exposto na ocorrência de eventos extremos. Essa perda média está diretamente relacionada à sua posição em relação risco ( $\beta$ ) e ao nível de confiança ( $\alpha$ ), escolhido.

O nível de confiança reflete a estratégia e a política de gestão de risco do agregador. Assim, agregadores com maior aversão ao risco podem optar por um nível de confiança de 99%, enquanto aqueles dispostos a tolerar mais risco podem preferir 95% ou 90%. Portanto, um CVaR

com um nível de confiança de 95% indica a perda média esperada nos piores 5% dos casos analisados.

Com base nos resultados obtidos, pode-se afirmar que o modelo proposto para resolver o problema GRE para o DS, baseado no risco, é válido. O modelo é capaz de minimizar em simultâneo os custos totais do agregador e o CVaR. Conforme mostrado na Figura 13, constatamos que para uma posição aversa ao risco ( $\beta = 1$ ) para todos os  $\alpha$ , os valores de CVaR são inferiores quando comparados às posições com menores níveis de exposição ao risco ( $\beta < 1$ ). Do ponto de vista do custo esperado, conforme evidenciado na Figura 15, o comportamento é inverso. À medida que o agregador adota uma postura mais aversa ao risco, há uma pequena elevação no valor de Zex, mas o CVaR é reduzido, indicando um agendamento dos recursos mais “custoso” para agregador. Contudo, esse agendamento mais oneroso financeiramente é mais robusto, limitando o impacto dos eventos externos sobre os custos do agregador. Outro aspecto interessante observado é que, para níveis de aversão superiores a 0,6, não há grandes reduções no CVaR.

Na segunda etapa, discutimos os resultados do modelo ID. Este modelo tem como ponto inicial a resposta média do modelo DS proposto neste trabalho e é utilizado como referência para comparações. Os casos de estudo evidenciam que erros de previsão na demanda de consumo afetam mais significativamente o agregador do que erros de previsão na produção dos geradores renováveis. Por exemplo, na Figura 24, observamos uma diferença de até 21,53% no custo total quando comparado com o modelo DS, para os casos com erros na demanda. Em contrapartida, para os casos com erros de previsão de produção, conforme Figura 25, observa-se uma diferença máxima de 8,43%. No que diz respeito aos recursos de armazenamento (VEs e SAEs), é possível observar que esses sistemas fornecem flexibilidade ao sistema, reduzindo o impacto dos erros de previsão sobre o custo do agregador.

Referente à criação de um MLE, observamos que este mecanismo cria um ambiente de mercado onde o agregador pode buscar recursos para atender suas necessidades em caso de erros de previsão ou cenários críticos. Nas Figura 31 e Figura 33, mostramos as FOs dos casos de estudo considerando a ocorrência do cenário mais crítico no problema DS. Nos casos em que é previsto o MLE (casos 02 e 04), há uma redução significativa dos custos do agregador, pois o modelo opta por recorrer ao MLE para realizar compras de energia e atender à demanda, evitando penalizações por não atendimento total da carga, conforme observado na Figura 32. Além disso, em casos de excesso no sistema, o MLE permite uma fonte de remuneração extra, diminuindo o custo total do agregador, conforme observado na Figura 37.

Diante dos resultados obtidos, podemos concluir que o modelo ID proposto é viável, pois consegue lidar eficientemente com erros de previsão e perturbações que ocorrem próximo ao horizonte de operação.

## 6 Conclusões

Para o encerramento deste trabalho, neste capítulo, são apresentadas e discutidas as conclusões obtidas dos estudos realizados. Além disso, são sugeridas direções para trabalhos futuros que possam ser realizados no âmbito e como sequência do desenvolvimento deste trabalho.

### 6.1 Conclusões Finais

A crescente integração de geradores renováveis e REDs nos sistemas elétricos tem introduzido uma maior complexidade na operação das redes, devido aos seus elevados níveis de variabilidade e incerteza em comparação com os recursos convencionais. Nesse contexto, a adoção de ferramentas adequadas de GRE é crucial para garantir uma operação eficiente e econômica. O agendamento do uso desses recursos energéticos representa uma parte indispensável de um sistema de GRE eficaz.

Dado o significativo avanço da penetração desses recursos nos sistemas elétricos modernos, este trabalho apresentou duas metodologias eficientes para a programação de recursos energéticos, para o horizonte do DS e ID. A primeira metodologia propôs um modelo para o DS baseado no risco, sendo a continuação do trabalho (Soares, et al., 2017). Este modelo lida com as variabilidades e incertezas dos recursos energéticos por meio da utilização de cenários estocásticos, que refletem com certa precisão o comportamento real dos recursos. Adicionalmente, é inserida uma métrica de risco, o CVaR, associada diretamente aos cenários extremos, que representam os maiores custos para o agregador.

As métricas de risco são amplamente utilizadas na gestão de riscos financeiros, especialmente por instituições financeiras e outras organizações do setor. No entanto, sua aplicação pode ser extrapolada para outros setores, como o setor elétrico. O CVaR é uma medida de risco amplamente utilizada que pode ser aplicada eficazmente no escalonamento de recursos energéticos. Sua aplicação se destaca na avaliação e gestão dos riscos associados às incertezas

inerentes aos recursos energéticos, especialmente em ambientes onde a variabilidade e a imprevisibilidade são significativas.

No ponto de vista do setor elétrico, o CVaR oferece uma estimativa da perda média esperada em cenários extremos, complementando o VaR ao fornecer uma visão mais abrangente dos possíveis impactos financeiros adversos. Essa métrica é bastante útil para agregadores e operadores do sistema para planejar e otimizar a alocação de seus recursos energéticos ao longo da rede. Para aplicação do CVaR, são utilizados os cenários estocásticos gerados por meio do MSC e posteriormente tratados, gerando o conjunto dos 150 cenários. A sua determinação do está diretamente relacionado ao nível de confiança e a aversão ao risco do agregador.

Para incorporar a métrica de risco no processo de otimização, é inserido na FO do modelo o CVaR juntamente com o custo esperado. Sendo o CVaR, ponderando por um percentil ( $\beta$ ) que representa nível de aversão ao risco do agregador. Deste modo, o modelo permite que as decisões sejam tomadas não apenas com base na minimização do custo esperado, mas também considerando a mitigação dos riscos extremos.

Com os resultados obtidos, podemos observar a minimização do CVaR, à medida que agregador assume uma posição mais aversa ao risco ( $\beta = 1$ ). Para  $\alpha = 99\%$ , à medida que agregador assume postura mais avessa ( $\beta > 0$ ), a uma redução percentual do valor de CVaR de 76,78%. Para os demais níveis de confiança,  $\alpha = 95\%$  e  $90\%$ , são observadas reduções percentuais de 67,18% e 6,75%, respectivamente.

Do ponto de vista do custo esperado, à medida que agregador adota uma posição mais avessa ao risco, há uma pequena elevação no custo de operação, chegando a um aumento percentual máximo de 3,23%. Em termo absolutos, enquanto há uma redução de 179,45 u.m no CVaR, o aumento no custo esperado de apenas 0,927 u.m. Ou seja, na ocorrência de um cenário extremo, a uma economia média de 179,45 u.m. Essas relações entre o CVaR e custo esperados são também observadas nos trabalhos analisados no estado da arte.

Essa economia é observada ao analisar os valores dos custos de cada cenário. No cenário 79 (cenário mais extremo), ao adotar uma postura mais conservadora ( $\beta = 1$  e  $\alpha = 99\%$ ) resulta uma economia de 40,74 u.m, ou cerca de 12,60%, na sua ocorrência. Para uma postura menos conservadora ( $\alpha = 90\%$ ), a redução é de apenas 1,17%. Portanto, os agregadores podem adotar uma postura mais informada e proativa em relação à gestão de riscos, ajustando o nível de confiança conforme sua política de risco. Agregadores com maior aversão ao risco podem optar por um nível de confiança mais alto (por exemplo, 99%), enquanto aqueles dispostos a tolerar mais risco podem escolher níveis mais baixos (95% ou 90%).

Por fim, a aplicação de modelo de GRE do DS baseando no risco, utilizando CVaR, proporciona um agendamento dos recursos energéticos mais robusto para lidar com as incertezas e variabilidades característicos dos modernos sistemas elétricos, assegurando que os riscos financeiros sejam gerenciados de maneira eficaz e que o sistema opere de forma otimizada mesmo diante de eventos extremos.

A segunda metodologia deste trabalho diz respeito ao modelo capaz de resolver o problema GRE no horizonte ID. Esta estrutura é utilizada para otimizar a alocação dos recursos energéticos em um período curto, na próxima hora, com uma resolução temporal de 15 minutos de operação. Desse modo, o modelo consegue garantir a eficiência, confiabilidade e economicidade das operações de um agregador, que enfrenta flutuações frequentes e inesperadas na demanda e oferta de energia próximo ao horizonte de operação.

O modelo ID utilizou como ponto de partida a resposta do escalonamento dos recursos energéticos obtida pela primeira metodologia apresentada neste trabalho. O objetivo deste modelo é ajustar e atualizar o escalonamento dos recursos à medida que ocorrem erros de previsão de demanda e oferta. Esses erros de previsão são incorporados ao modelo por meio de "perturbações" na previsão da demanda e na geração renovável fornecidas pelo modelo do DS baseado no risco.

Os resultados obtidos indicam que níveis mais elevados de erros de previsão (faixa de 12-15%) impactam significativamente o agregador. Nas simulações que consideram erros de previsão na demanda, com 0% de flexibilidade no uso dos SAEs e VEs, e sem o MLE (caso 01), observa-se um aumento de aproximadamente 19% na FO quando ocorrem perturbações na faixa de 12-15%, em comparação com a FO na faixa de erro de 0%. No mesmo cenário, mas do ponto de vista da oferta (caso 03), o aumento é de 4,5% na FO em relação à faixa de erro de 0%. Esta característica pode ser explicada pelo fato de que os erros de previsão afetam apenas os geradores renováveis.

Para avaliar o impacto dos erros de previsão sobre a FO do modelo, os erros foram classificados como "positivos" e "negativos". Nesse contexto, observa-se que erros positivos têm um impacto maior sobre a FO em comparação com erros negativos na mesma faixa de erro. Na Figura 28, para o caso 07, verifica-se que as FOs para erros positivos são, em média, 2,20% superiores às FOs para erros negativos.

Em relação ao MLE previsto no modelo ID, este cria um ambiente de mercado no qual o agregador pode buscar recursos para suprir suas demandas. De modo geral, em todos os casos de estudo que preveem o MLE, as FOs apresentaram menores impactos na ocorrência de erros. Por exemplo, para o caso 06, mostrado na Figura 26, na faixa de erro de 7-10%, observam-se reduções percentuais de 2,86% e 19,35% para erros positivos e negativos, respectivamente. Para erros negativos na demanda, observa-se sempre reduções mais acentuadas nas FOs, uma vez que o modelo recorre ao MLE para vender o excesso de produção.

Também é possível observar os impactos dos constrangimentos contratuais no uso dos recursos de armazenamento, especificamente SAEs e VEs. Em média, na faixa de erro de 12-15%, há uma redução de 3,86% e 3,98% na FO considerando flexibilidade de uso de 10% e 25% desses recursos, respectivamente. Dessa forma, pode-se afirmar que esses recursos fornecem flexibilidade ao sistema, minimizando o impacto dos erros de previsão. No entanto, seus benefícios são limitados e não conseguem atender a todas as necessidades do agregador.

Para conectar as duas metodologias propostas, foi realizada uma análise dos casos de estudo para o modelo ID na efetividade da ocorrência do pior e melhor cenários do ponto de vista do custo. No pior cenário, foi utilizada a resposta do DS considerando uma posição totalmente neutra em relação ao risco. Com a aplicação dos erros, foram observadas grandes variações nas FOs, com aumentos de cerca de 44% na faixa de erro de 12-15% em relação à FO na faixa de erro de 0%. Esse valor é significativamente superior quando comparado à variação no cenário médio (19%).

Outro aspecto relevante é que, nessas simulações, o MLE fornece um ambiente bastante efetivo para o agregador, com reduções médias nas FOs de 250 u.m. Vale destacar que a resposta ao alto impacto dos erros de previsão sobre a FO pode estar na falta de robustez dos dados de entrada.

Do ponto de vista do melhor cenário, foi utilizada a resposta do DS considerando uma posição totalmente aversa ao risco. Com a aplicação dos casos de estudo, foram observadas pequenas elevações nas FOs, chegando a 17%. Diferentemente do pior cenário, o MLE é efetivo para reduzir os custos do agregador, embora com pequenas reduções. De modo geral, na ocorrência de erros de previsão, o melhor cenário tem impactos reduzindo quando comparados ao pior cenário e ao cenário médio.

Resumindo, ambas as metodologias propostas neste trabalho demonstraram desempenhos eficientes, exigindo baixa carga e tempo computacional para resolver o problema de otimização. Os dois modelos foram capazes de lidar com as incertezas associadas ao processo de tomada de decisão, fornecendo soluções de agendamento coesas e eficazes para o agregador, reduzindo seus custos operacionais e oferecendo soluções robustas. Além disso, por meio dos estudos, foi possível verificar os benefícios da criação de ambientes voltados ao mercado, permitindo que os benefícios dos REDs sejam compartilhados com os demais agentes do sistema.

## 6.2 Trabalho Futuros

Para futuras pesquisas, fica sugerido a elaboração de um modelo para o problema de GRE do DS, baseado no risco, que leve em consideração as restrições completas de fluxo de rede, bem como o comportamento individual da frota de VEs. Além disso, seria interessante explorar metaheurística modernas para resolver o problema de otimização, visando melhorar a eficiência computacional. Os usos técnicos mais modernos, permitirá trabalhar em redes de dimensões maiores, bem como, com problemas não lineares mais complexos, onde os modelos matemáticos possuem mais dificuldades ou não conseguem encontrar soluções para o problema GRE.

Em relação à segunda metodologia, recomenda-se a investigação de um modelo estocástico para o problema de GRE no horizonte ID, capaz de lidar com as incertezas dos recursos energéticos por meio de cenários probabilísticos. Além disso, seria vantajoso integrar a métrica

de risco como um dos balizadores da FO do problema, proporcionando uma abordagem mais abrangente e robusta para o agendamento dos recursos.

## 7 Referências

Adefarati, T., Bansal, R., Bettayeb, M. & Naidoo, R., 2021. Optimal energy management of a PV-WTG-BSS-DG microgrid system. *Energy*, 15 Fevereiro.

Alhamali, A., Farrag, M. E., Bevan, G. & Hepburn, D. M., 2016. *Review of Energy Storage Systems in electric grid and their potential in distribution networks*. Cairo, Egito, s.n., pp. 546-551.

Ali, M., Abdulgalil, M. A., Habiballah, I. & Khalid, M., 2023. Optimal Scheduling of Isolated Microgrids With Hybrid Renewables and Energy Storage Systems Considering Demand Response. *IEEE Access*, Volume 11, pp. 80266-80273.

Almeida, J. et al., 2021. *Evolutionary Algorithms for Energy Scheduling under uncertainty considering Multiple Aggregators*. Kraków, Polóand, s.n.

Almeida, J., Soares, J., Lezama, F. & Vale, Z., 2022. Robust Energy Resource Management Incorporating Risk Analysis Using Conditional Value-at-Risk. in *IEEE Access*, pp. 16063-16077.

Almeira, J. R. G. d., 2021. *Optimization of Aggregators Energy*, Porto: Instituto Superior de Engenharia do Porto.

Amin Gharibi, M., Nafisi, H., Askarian-abyaneh, H. & Hajizadeh, A., 2023. Deep learning framework for day-ahead optimal charging scheduling of electric vehicles in parking lot. *Applied Energy*, Volume 349.

Amir, A., Shareef, H. & Awwad , F., 2023. Energy Management in a Standalone Microgrid: A Split-Horizon Dual-Stage Dispatch Strategy. *Energies*, Abril. Volume 16.

Antweiler, W., 2021. Microeconomic models of electricity storage: Price Forecasting, arbitrage limits, curtailment insurance, and transmission line utilization. *Energy Economics*, Setembro, Volume 101.

Asensio, M. & Contreras, J., 2016. Stochastic Unit Commitment in Isolated Systems With Renewable Penetration Under CVaR. *IEEE Transactions on Smart Grid*, 3 Maio, 7(3), pp. 1356-1367.

Assad, U. et al., 2022. Smart Grid, Demand Response and Optimization: A Critical Review of Computational Methods. *Energies*, 09 Março.

Bañol Arias, N. et al., 2019. Distribution System Services Provided by Electric Vehicles: Recent Status, Challenges, and Future Prospects. *IEEE Transactions on Intelligent Transportation Systems*, Dezembro, pp. 4277-4296.

Belli, G. et al., 2016. *A multiperiodal management method at user level for storage systems using artificial neural network forecasts*. Florence, s.n.

Cai, D. et al., 2022. Wind-Photovoltaic-Energy Storage System Collaborative Planning Strategy Considering the Morphological Evolution of the Transmission and Distribution Network. *Energies*, 17 Fevereiro, p. 1481.

Canizes, B. et al., 2021. Energy Resource Scheduling Optimization for Smart Power Distribution Grids – Hour-Ahead Horizon. *IEEE PES Innovative Smart Grid Technologies Europe (ISGT Europe)*.

Canizes, B., Soares, J., Almeida, J. & Zita, V., 2022. Hour-ahead energy resource scheduling optimization for smart power distribution networks considering local energy market. *Energy Reports*, 8(Supplement 3), pp. 575-582.

Canizes, B., Soares, J., Vale, Z. & Corchado, J., 2019. Optimal Distribution Grid Operation Using DLMP-Based Pricing for Electric Vehicle Charging Infrastructure in a Smart City. *Energies*, Volume 12, p. 686.

Christoforos, M.-A., Lamprinos, I. & S. Georgilakis, P., 2022. Particle Swarm Optimization in Residential Demand-Side Management: A Review on Scheduling and Control Algorithms for Demand Response Provision. *Energies*, 13 Fevereiro.

Conejo, A. J., Mínguez, R., Castilho, E. & García-Bertrand, R., 2006. *Decomposition Techniques in Mathematical Programming*. Berlin: Springer.

Dabhi, D. & Pandya, K., 2020. Uncertain Scenario Based MicroGrid Optimization via Hybrid Levy Particle Swarm Variable Neighborhood Search Optimization (HL\_PS\_VNSO). *IEEE Access*, Volume 8, pp. 108782-108797.

Dias de Lima, T. et al., 2023. A Risk-Based Planning Approach for Sustainable Distribution Systems Considering EV Charging Stations and Carbon Taxes. *IEEE Transactions on Sustainable Energy*, 14(4), pp. 2294-2307.

Dileep, G., 2020. A survey on smart grid technologies and applications. *Renewable Energy*, Volume 146, pp. 2589-2625.

El-Khattam, W. & M.M.A Salama, 2004. Distributed generation technologies, definitions and benefits. *Electric Power Systems Research*, Volume 71, pp. 119-128.

Ghazvini, M. A. F. et al., 2015. Incentive-based demand response programs designed by asset-light retail electricity providers for the day-ahead market. *Energy*, 15 Março, pp. 786-799.

Gröwe-Kuska, N., Heitsch, H. & Römisches, W., 2003. *Scenario Reduction and Scenario Tree Construction for Power Management Problems*. Bologna, Italy, s.n.

Guo, Y. et al., 2022. Risk-averse day-ahead generation scheduling of hydro-wind-photovoltaic complementary systems considering the steady requirement of power delivery. *Applied Energy*, 01 Março.

International Energy Agency, 2023. *Global EV Outlook 2023 - Catching up with climate ambitions*, França: IEA.

Leonori, S., Martino, A., Mascioli, F. M. F. & Rizzi, A., 2020. Microgrid Energy Management Systems Design by Computational Intelligence Techniques. *Applied Energy*, Volume 277.

Lezama, F. et al., 2019. 2017 Competition on Modern Heuristic Optimizers for Smart Grid Operation: Testbeds and Results. *Swarm and evolutionary computation*.

Liu, C., Chau, K. T., Wu, D. & Gao, S., 2013. Opportunities and Challenges of Vehicle-to-Home, Vehicle-to-Vehicle, and Vehicle-to-Grid Technologies. *Proceedings of the IEEE*, 101(11), pp. 2409-2427.

Liu, J., Zhang, W., Zhou, R. & Zhon, J., 2012. *Impacts of distributed renewable energy generations on smart grid operation and dispatch*. San Diego, CA, USA, s.n.

Liu, M., Quilumba, F. L. & Lee, W. -J., 2015. Dispatch Scheduling for a Wind Farm With Hybrid Energy Storage Based on Wind and LMP Forecasting. *IEEE Transactions on Industry Applications*, Junho, pp. 1970-1977.

Lopes, J. P. et al., 2007. Integrating distributed generation into electric power systems: A review of drivers, challenges and opportunities. *Electric Power Systems Research*, pp. 1189-1203.

Mazur, Ł., Cieślik, S. & Czapp, S., 2023. Trends in Locally Balanced Energy Systems without the Use of Fossil Fuels: A Review. *Energies*, Julho.

Menniti, D. et al., 2018. *A Real-Life Application of an Efficient Energy Management Method for a Local Energy System in Presence of Energy Storage Systems*. Palermo, Italy, s.n.

Mostafa, E. et al., 2016. Risk-based planning of distribution substation considering technical and economic uncertainties. *Electric Power Systems Research*, Volume 135, pp. 18-26.

Nadeem, T. B., Siddiqui, M., Khalid, M. & Asif, M., 2023. Distributed energy systems: A review of classification, technologies, applications, and policies. *Energy Strategy Reviews*, Volume 48.

Panda, S. et al., 2023. A comprehensive review on demand side management and market design for renewable energy support and integration. *Energy Reports*, Novembro, Volume 10, pp. 2228-2250.

Pawar, P., TarunKumar, M. & K., P. V., 2020. An IoT based Intelligent Smart Energy Management System with accurate forecasting and load strategy for renewable generation. *Measurement*, Fevereiro, Volume 152, p. 107187.

Ramu, P., Gangatharan, S., Rangasamy, S. & Mihet-Popa, L., 2023. Categorization of Loads in Educational Institutions to Effectively Manage Peak Demand and Minimize Energy Cost Using an Intelligent Load Management Technique. *Sustainability*, Agosto.

Rocha, J. E. N. d., 2013. *Sistema Inteligente de Diagnóstico Energéticos e de Análise de Investimento em Projetos de Eficiência Energética Gerenciamento pelo Lado da Demanda*, Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro PUC-RIO.

Santo, K. G. D., Santo, S. G. D., Monaro, R. M. & Saidel, M. A., 2018. Active demand side management for households in smart grids using optimization and artificial intelligence. *Measurement*, Fevereiro, pp. 152-161.

Schäfer, A. & Moser, A., 2012. *Dispatch optimization and economic evaluation of distributed generation in a virtual power plant*. Cleveland, OH, USA, s.n.

Shaker Nafi, N., Ahmed, K., Mark A, G. & Manoj, D., 2016. A survey of smart grid architectures, applications, benefits and standardization. *Journal of Network and Computer Applications*, December, Volume 76, pp. 23-36.

Silva, M. et al., 2015. *Hour-ahead Energy Resource Management in university campus microgrid*. Eindhoven, Netherlands, s.n.

Soares, J. et al., 2016b. Scenario generation for electric vehicles' uncertain behavior in a smart city environment. *Energy*, Volume 111, pp. 664-675.

Soares, J. et al., 2016c. Dynamic electricity pricing for electric vehicles using stochastic. *Energy*, Volume 122, pp. 111-127.

Soares, J. et al., 2017. Two-stage Stochastic Model using Benders' Decomposition for Large-scale Energy Resources Management in Smart grid. *IEEE Transactions on Industry Applications*, 53(6), pp. 5905-5914.

Soares, J., Canizes, B., Vale, Z. & Venayagamoorthy, G. K., 2016a. Benders' decomposition applied to Energy Resource Management in smart distribution networks. *2016 Clemson University Power Systems Conference (PSC)*, pp. 1-8.

Xuewei, S. et al., 2020. *Research on Energy Storage Configuration Method Based on Wind and Solar Volatility*. Chengdu, China, 2020, s.n., pp. 464-468.

Zame, K. K. et al., 2018. Smart grid and energy storage: Policy recommendations. *Renewable and Sustainable Energy Reviews*, pp. 1646-1654.

## DECLARAÇÃO DE INTEGRIDADE


---

### DECLARAÇÃO DE INTEGRIDADE

Declaro ter conduzido este trabalho académico com integridade. Não plagiei ou apliquei qualquer forma de uso indevido de informações ou falsificação de resultados ao longo do processo que levou à sua elaboração.

Declaro que o trabalho apresentado neste documento é original e de minha autoria, não tendo sido utilizado anteriormente para nenhum outro fim.

Declaro ainda que tenho pleno conhecimento do Código de Conduta Ética do P.PORTO.

Documento assinado digitalmente  
 **WANDERLEY PARIS JUNIOR**  
Data: 18/07/2024 20:50:14-0300  
Verifique em <https://validar.iti.gov.br>

Wanderley Paris Junior - 1191141

ISEP, Florianópolis, Santa Catarina, Brasil, 18 de julho de 2024