

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

Vinícius Sebastião Araújo de Castro

**Aproximação Funcional dos Limites de
Estabilidade/Segurança de Tensão por
Redes Neurais Artificiais com Seleção
de Atributos em Problemas de Fluxo de
Potência Ótimo**

Vinícius Sebastião Araújo de Castro

**Aproximação Funcional dos Limites de
Estabilidade/Segurança de Tensão por
Redes Neurais Artificiais com Seleção
de Atributos em Problemas de Fluxo de
Potência Ótimo**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Sistemas Elétricos e Eletrônicos.

Orientador: Prof. Dr. Guilherme Guimarães Lage.

São Carlos – SP

2022



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Engenharia Elétrica

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Vinícius Sebastião Araújo de Castro, realizada em 10/01/2022.

Comissão Julgadora:

Prof. Dr. Guilherme Guimarães Lage (UFSCar)

Prof. Dr. Ricardo Augusto Souza Fernandes (UFSCar)

Prof. Dr. Benvindo Rodrigues Pereira Junior (USP)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Elétrica.

*Aos meus pais, Joel e Maria de Fátima
à minha irmã, Victória
e à minha companheira, Lara.*

Agradecimentos

Agradeço primeiramente a Deus.

Ao Professor Dr. Guilherme Guimarães Lage, pela orientação, pela minha formação como pesquisador e pelos conhecimentos, ensinamento, conselhos e amizade durante o período de desenvolvimento desde trabalho.

À minha família, amigos conterrâneos e de faculdade, que, por vezes distantes, sempre me motivaram, inspiraram e me apoiaram ao decorrer dessa trajetória.

Aos professores e funcionários do Departamento de Engenharia Elétrica (DEE) do Centro de Ciências Exatas e de Tecnologia (CCET) da Universidade Federal de São Carlos (UFSCar).

À UFSCar pela oportunidade da realização do curso de mestrado.

“A simplicidade é o mais alto grau de sofisticação.”
(Leonardo da Vinci)

Resumo

Esta pesquisa tem como objetivo a proposta de um modelo para o problema de Fluxo de Potência Ótimo com Restrição de Estabilidade/Segurança de Tensão (FPO-REST) aplicado a leilões de ajuste em mercados de energia elétrica. Nas abordagens existentes na literatura, muitas das formas de representação da estabilidade/segurança de tensão nos problemas de Fluxo de Potência Ótimo (FPO) são conservadoras, de alto custo computacional e/ou até ineficazes. Nesse contexto, é proposto neste projeto de pesquisa um modelo prático para o problema de FPO-REST cuja representação da estabilidade/segurança de tensão se dá por uma aproximação funcional caracterizada por Rede Neural Artificial (RNA) com seleção de atributos, viabilizando o uso de metodologias de Programação Não Linear (PNL) na sua resolução. Esta pesquisa fundamenta-se metodologicamente na determinação dos limites de estabilidade/segurança de tensão associados à margem de carregamento de Sistemas de Energia Elétrica (SEEs) considerando bifurcações do tipo sela-nó e induzidas por limites e limites técnico-operacionais nas linhas de transmissão; na inclusão de seleção de atributos para aproximação funcional desses limites por Redes Neurais Artificiais (RNAs); na incorporação dessa aproximação funcional ao problema de FPO-REST e na resolução do problema de PNL resultante. Para isso, foram obtidos dados teóricos, a partir de levantamentos bibliográficos, que explicitam os conceitos associados à estabilidade/segurança de tensão dos SEEs, leilões de ajuste em mercados de energia elétrica e resolução de problemas de PNL. O treinamento e validação da aprendizagem das RNAs foram realizados no *software* Jupyter Notebook, e o modelo proposto é implementado no ambiente de modelagem para problemas de programação matemática AMPL e resolvido pelo *solver* LOQO. A validação das aproximações funcionais dos limites de estabilidade/segurança de tensão de SEEs e do modelo proposto é realizada por testes numéricos com sistemas teste comumente empregados na literatura correlata.

Palavras-chave: estabilidade/segurança de tensão, fluxo de potência ótimo, leilões de ajuste, mercados de energia elétrica, redes neurais artificiais, seleção de atributos.

Abstract

The object of this research is the proposal of a model for Voltage-Stability/Security on strained Optimal Power Flow (VSSC-OPF) problems applied to mid-term energy procurement auction systems in electricity markets. In the existing literature, many of the operational security representations in Optimal Power Flow (OPF) problems are too conservative, first or second-order approximations, with high computational costs and/or even ineffective. In this context, a practical VSSC-OPF problem whose voltage stability/security representation is designated by a functional approximation characterized by Artificial Neural Networks (ANNs) with feature selection is proposed in this research project, making it possible the use of Nonlinear Programming (NLP) resolution methodologies. This research project is methodologically founded on determining voltage stability/security limits associated with power system loading margins accounting for saddle-node and limit induced bifurcations and technical-operational limits on transmission lines; in the inclusion of feature selection for the functional approximation of such limits by ANN; the incorporation of this functional approximation into the VSSC-OPF problem and the resolution of the resulting NLP problem. To accomplish this, the main concepts on power system operational voltage stability/security, mid-term energy procurement auction systems in electricity markets and resolution of NLP problems will be outlined by means of a background review on these subjects. The ANN training and validation processes will be realized on Jupyter Notebook, and the proposed model will be implemented in the AMPL modeling language for mathematical programs and solved by LOQO solver. The functional approximation of power system voltage stability/security limits and the proposed VSSC-OPF model will be validated by numerical tests with test-systems commonly deployed for this task in the correlate literature.

Keywords: artificial neural networks, electricity markets, feature selection, optimal power flow, mid-term energy procurement auction systems, voltage stability/security.

Lista de ilustrações

Figura 1 – Neurônio artificial.	40
Figura 2 – Rede neural multi-layer perceptron.	41
Figura 3 – Gráfico das funções de ativação clássicas.	42
Figura 4 – Gráfico da aproximação numérica diferenciável da função de ativação ReLU, onde $\epsilon = 10^{-9}$	43
Figura 5 – Visão geral das técnicas de seleção de atributos.	47
Figura 6 – Fluxograma da metodologia proposta.	57
Figura 7 – Curvas de potência reativa fornecida e potência reativa demandada.	59
Figura 8 – BSN sem limites para Q_G	62
Figura 9 – Ponto de limite instável (BEIL).	62
Figura 10 – BDIL seguida por uma BEIL.	62
Figura 11 – Sistema-teste de 6 barras (MILANO; CANIZARES; INVERNIZZI, 2003).	70
Figura 12 – Todas direções de aumento de geração e carga para Limites Térmicos.	73
Figura 13 – Todas direções de aumento de geração e carga para Bifurcação Induzida por limite (BIL) e Limites Térmicos.	74
Figura 14 – Todas direções de aumento de geração e carga para o Limites de Tensão.	74
Figura 15 – Estimções da Rede Neural Artificial (RNA) para Limites Térmicos (Caso 1).	79
Figura 16 – Estimções da RNA para BIL e Limites Térmicos (Caso 2).	80
Figura 17 – Estimções da RNA para Limites de Tensão (Caso 3).	80

Lista de tabelas

Tabela 1 – Funções de Ativação Clássicas	42
Tabela 2 – Dados das Barras para o Sistema de 6 Barras	71
Tabela 3 – Dados dos Ramos para o Sistema de 6 Barras	71
Tabela 4 – Classificação dos Limites de Estabilidade/Segurança de Tensão	71
Tabela 5 – Ranqueamento dos Atributos para o Sistema-Teste de 6 Barras	75
Tabela 6 – Limites Térmicos com Seleção de Atributos (Caso 1)	76
Tabela 7 – BIL e Limites Térmicos com Seleção de Atributos (Caso 2)	77
Tabela 8 – Limites de Tensão com Seleção de Atributos (Caso 3)	78
Tabela 9 – Síntese dos Treinamentos Realizados para Cada Caso	79
Tabela 10 – Resultados por Limites Térmicos (Caso 1)	84
Tabela 11 – Componentes dos Preços Locais Marginais (PLMs) da Oferta para o Caso 1	85
Tabela 12 – Componentes dos PLMs da Demanda para o Caso 1	85
Tabela 13 – Resultados por BIL e Limites Térmicos (Caso 2)	86
Tabela 14 – Componentes dos PLMs Caso 2 - Oferta	86
Tabela 15 – Componentes dos PLMs Caso 2 - Demanda	86
Tabela 16 – Resultados por Limites de Tensão (Caso 3)	87
Tabela 17 – Componentes dos PLMs Caso 3 - Oferta	87
Tabela 18 – Componentes dos PLMs Caso 3 - Demanda	87

Lista de siglas

BSN Bifurcação de Sela-Nó

BIL Bifurcação Induzida por limite

BDIL Bifurcação Dinâmica Induzida por Limite

BEIL Bifurcação Estática Induzida por Limite

CFS Correlation-based Feature Selection

CFS-UC Correlation-based Feature Selection - Symmetrical Uncertainty

CFS-MDL Correlation-based Feature Selection - Minimum Description Length

CFS-Relief Correlation-based Feature Selection - Relief

EQM Erro Quadrático Médio

FPO Fluxo de Potência Ótimo

FPO-CC Fluxo de Potência Ótimo - Corrente Contínua

FPO-RS Fluxo de Potência Ótimo com Restrição de Segurança

FC Fluxo de Carga

FPO-RET Fluxo de Potência Ótima com Restrição de Estabilidade de Tensão

FPO-REST Fluxo de Potência Ótimo com Restrição de Estabilidade/Segurança de Tensão

IET Índice de Estabilidade de Tensão

KKT Karush-Kuhn-Tucker

PNLIM Programação Não Linear Inteira Mista

PNL Programação Não Linear

p.u. por unidade

PLMs Preços Locais Marginais

RNA Rede Neural Artificial

RFE Recursive Feature Elimination

RFE-SVM Recursive Feature Elimination - Support Vector Machine

SEE Sistema de Energia Elétrica

SEP Sistema Elétrico de Potência

SVM Support Vector Machine

Sumário

1	INTRODUÇÃO	23
1.1	Motivação	25
1.2	Objetivos	25
1.3	Metodologia	26
1.3.1	Forma de Análise dos Resultados	27
1.4	Organização do Trabalho	27
2	ESTADO DA ARTE	29
2.1	FPO-RS	30
2.2	FPO-RET	35
3	FUNDAMENTOS DAS REDES NEURAIS ARTIFICIAIS E SELETORES DE ATRIBUTOS	39
3.1	Redes Neurais Artificiais	39
3.1.1	Arquitetura da Rede Neural Artificial	40
3.1.2	Funções de Ativação	41
3.1.3	Algoritmos de Otimização para o Treinamento das RNAs	44
3.2	Seleção de Atributos	46
3.2.1	Recursive Feature Elimination	48
3.2.2	Correlation-based Feature Selection	48
3.2.3	Spearman’s Rank Correlation Coefficient	49
3.3	Aproximações Funcionais	50
4	MODELAGEM DO PROBLEMA DE FPO-REST	51
4.1	Formulação Genérica de FPO-RS	51
4.2	Formulação Genérica de FPO-RET	52
4.3	Formulação Genérica de FPO-REST	53
4.4	Estimação dos Limites de Estabilidade de Tensão	54
4.5	Formulação Genérica do FPO-REST Proposto	56
5	METODOLOGIA PROPOSTA	57
5.1	Análise de Estabilidade Estática de Tensão	58

5.1.1	Efeitos do Aumento da Demanda	58
5.2	Análise de Bifurcações	59
5.2.1	Bifurcação Sela-Nó	59
5.2.2	Bifurcação Induzida por Limite	60
5.3	Determinação de Pontos de Máximo Carregamento pelo Mé-	
	todo Direto	61
5.4	FPO-REST Aplicado a Sistemas de Leilão de Energia Elétrica	64
5.4.1	Análise das Componentes dos Preços Locais Marginais	66
6	RESULTADOS	69
6.1	Implementação Computacional e Sistema-Teste Considerado . .	70
6.2	Estimação dos Limites de Estabilidade e Segurança de Tensão	
	por Redes Neurais Artificiais com Seleção de Atributos	72
6.3	Análise dos Resultados Obtidos para o FPO-REST Proposto .	84
7	CONSIDERAÇÕES FINAIS	89
7.1	Trabalhos Futuros	89
	REFERÊNCIAS	91

Capítulo 1

Introdução

Apesar de todas as conquistas alcançadas com a reestruturação institucional e regulamentar do setor elétrico no Brasil e em várias partes do mundo, as margens de estabilidade de tensão e segurança operacional dos Sistema de Energia Elétricas (SEEs) têm sido reduzidas, em parte, devido à operação pautada por critérios de eficiência econômica. Em resposta às pressões de mercado, que buscam maximizar o uso dos recursos disponíveis, a operação dos SEEs, mais especificamente do sistema de transmissão de energia elétrica, tem sido feita cada vez mais próxima aos seus limites de controle (ROSEHART, 2002; EL-SAMAHY et al., 2008; CUTSEM et al., 2020). Restrições econômicas e/ou ambientais associadas à falta de investimentos na expansão e manutenção do setor também contribuem de forma decisiva na consolidação deste cenário. Essa é uma característica inerente aos novos modelos do setor elétrico, no qual a tomada de decisões exige a escolha de um objetivo em detrimento de outro.

A meta das empresas vinculadas ao setor de elétrico é tornarem-se cada vez mais eficientes. Essa eficiência, porém, somente será atingida a partir de inovações e aperfeiçoamentos nas metodologias utilizadas como ferramentas de auxílio à tomada de decisões na operação de seus sistemas de forma segura. Nesse contexto, problemas de Fluxo de Potência Ótimo (FPO), Fluxo de Potência Ótimo com Restrição de Segurança (FPO-RS) e Fluxo de Potência Ótima com Restrição de Estabilidade de Tensão (FPO-RET) têm despertado o interesse das empresas do setor elétrico e dos pesquisadores da área (CAPITANESCU et al., 2011; ROALD; ANDERSSON, 2018).

FPO é uma ferramenta computacional que tem por finalidade otimizar um determinado desempenho do sistema, satisfazendo às restrições que são regidas por particularidades operacionais e físicas do SEE (SOUSA; BAPTISTA; COSTA, 2008; CAPITANESCU et al., 2011; STOTT; ALSAÇ, 2012). Assim sendo, o FPO-RS consiste em uma subclasse de problemas de FPO que considera restrições de segurança operacional definidas para o sistema sujeito a problemas de estabilidade transitória (como um curto-circuito em uma linha de transmissão e seu desligamento). Já o FPO-RET consiste em uma subclasse de problemas de FPO que considera restrições de estabilidade de tensão, a exemplo, o

colapso de tensão. A classe de problemas de FPO que engloba as subclasses de problemas de FPO-RS e FPO-RET é denominada Fluxo de Potência Ótimo com Restrição de Estabilidade/Segurança de Tensão (FPO-REST). Essa classe de problemas possui aplicação direta, no contexto do mercado de energia elétrica brasileiro, aos problemas de leilões de ajuste e, de certa forma, aos problemas de determinação dos preços de liquidação das diferenças para contabilização (referenciados na literatura correlata como problemas de compensação). A razão de ser dessa aplicação direta está no fato de que contratos de compra e venda de energia elétrica somente podem ser firmados e celebrados caso não infrinjam limites de estabilidade de tensão e segurança operacional do SEE.

Uma série de fatores fazem com que o FPO-REST seja mais desafiador que problemas “padrão” de FPO e até mesmo os problemas de FPO-RS e FPO-RET separadamente: seu grande porte (consideravelmente maior), a necessidade de se tratar uma maior quantidade de variáveis inteiras e discretas (além dos *taps* dos transformadores e chaveamentos dos bancos de capacitores e reatores *shunt*, consideram-se também mudanças na topologia da rede e acionamentos de unidades de geração), a variedade de estratégias de controle corretivo nos estados de pós-contingência (CAPITANESCU et al., 2011) e, principalmente, a representação (algébrica) eficaz dos limites de estabilidade de tensão.

Outrossim, os sistemas de leilão para aquisição de energia nos mercados de eletricidade têm sido utilizados, em geral, para fomentar a concorrência no setor elétrico entre os intervenientes no mercado (produtores e compradores, respectivamente) para negociar contratos de eletricidade de longo, médio e curto prazo destinados a colmatar a lacuna entre a oferta e a procura (MAURER; BARROSO; CHANG, 2011). Independentemente do prazo para a concepção e implementação do sistema de leilão, os operadores independentes dos mercados de eletricidade híbridos (ou *spot*) procuram alocações transparentes de potência ativa ao mais baixo custo, tanto para a oferta quanto para a demanda na aquisição de energia. Este objetivo pode ser alcançado através de ferramentas baseadas em FPO; o critério a ser usado em tais sistemas de leilão baseados em FPO consiste, em essência, maximizar o bem-estar social sujeito ao balanço de potência, limites de oferta e procura, e restrições técnicas e operacionais e de estabilidade/segurança de tensão (EL-SAMAHY et al., 2008).

No entanto, a representação adequada da estabilidade/segurança da tensão em modelos de FPO ainda é uma questão em aberto. Muitas abordagens encontradas na literatura correlata são, em geral, bastante dependentes de fatores de ponderação (MILANO; CANIZARES; INVERNIZZI, 2003; QIU; ZHAO; WANG, 2017), conservadoras (AVALOS; CANIZARES; ANJOS, 2008; LAGE; COSTA; CANIZARES, 2012) ou aproximadas, demandando alto esforço computacional (CHAVEZ-LUGO et al., 2016; HAMON; PERNINGE; SODER, 2013; PERNINGE; HAMON, 2013; GUTIERREZ-MARTINEZ et al., 2011; LAGE; FERNANDES; COSTA, 2015). Assim, podem não representar limites reais de estabilidade/segurança de tensão ou fornecer sinais de preços inadequados, dificultando

o uso prático desses modelos.

1.1 Motivação

O setor elétrico tem passado por importantes reformas na sua estrutura, e a principal delas foi a mudança do modelo de monopólio para o modelo competitivo, impondo, assim, novas filosofias de planejamento e operação dos SEEs, que envolvem as áreas de geração, transmissão, distribuição e comercialização de energia elétrica.

À medida que as empresas do setor elétrico caminham para um ambiente mais competitivo, o uso de modelos de FPO no auxílio de tomadas de decisões sobre a operação de SEEs adquire maior importância na maximização do uso dos recursos disponíveis. Nesse novo cenário, o FPO tem se tornado uma ferramenta importante e amplamente utilizada para diversos fins na operação de Sistema Elétrico de Potência (SEP) devido ao desenvolvimento de metodologias cada vez mais eficientes.

Nos últimos anos, tem sido dado particular interesse à incorporação de restrições de estabilidade de tensão em problemas de FPO (MILANO; CANIZARES; INVERNIZZI, 2003; AVALOS; CANIZARES; ANJOS, 2008; LAGE; COSTA; CANIZARES, 2012; CHAVEZ-LUGO et al., 2016), uma vez que esse fenômeno está diretamente associado aos principais *blackouts* verificados em todo o mundo durante as últimas décadas (SHAIKH et al., 2018; WANG; YU, 2020). Consequentemente, foram propostos diferentes modelos de FPO com ênfase na estabilidade/segurança do sistema, tais como FPO-RS, FPO-RET e FPO-REST. Contudo, é necessária uma maior investigação, a fim de melhorar tais modelos e respectivas técnicas de resolução, uma vez que sistemas de grande porte demandam uma carga computacional significativa para encontrar soluções ótimas.

1.2 Objetivos

Este projeto de pesquisa tem como objetivo a proposta de um modelo para o problema de FPO-REST aplicado a leilões de ajuste em mercados de energia elétrica. “Os leilões de ajuste visam a adequar a contratação de energia pelas distribuidoras, tratando eventuais desvios oriundos da diferença entre as previsões feitas distribuidoras em leilões anteriores e o comportamento de seu mercado. Como resultado desse leilão, são firmados e celebrados contratos de curta duração (de três meses a dois anos). Os leilões de ajuste estão previstos no artigo 26 do Decreto no 5.163, de 30 de julho de 2004. A Resolução Normativa Aneel no 411/2010 aprova o modelo de edital dos Leilões de Ajuste e delega a sua realização à Câmara de Comercialização de Energia Elétrica (CCEE)” (Câmara de Comercialização de Energia Elétrica, 2020)

Portanto, é proposto neste trabalho um modelo prático baseado em uma formulação de Programação Não Linear (PNL) para o problema de FPO-REST, cuja representação da estabilidade/segurança de tensão se dá por uma aproximação funcional caracterizada por RNAs com seleção de atributos para sua aplicação a sistemas de grande porte.

1.3 Metodologia

A metodologia a ser empregada neste trabalho consiste nos seguintes passos enumerados a seguir:

1. **Determinação de pontos operacionais nos limites de estabilidade e segurança de tensão:** Os limites de estabilidade/segurança de tensão serão associados à margem de carregamento de SEEs considerando bifurcações do tipo sela-nó e induzidas por limite e limites técnico-operacionais (magnitudes de tensão e térmicos) nas linhas de transmissão. Os pontos operacionais serão determinados por um método direto baseado em problemas de otimização com grau de liberdade 1 (AVALOS et al., 2009) equivalente a métodos de continuação parametrizados (AJJARAPU; CHRISTY, 1991).
2. **Seleção de atributos:** A partir da determinação de pontos operacionais nos limites de estabilidade/segurança de tensão será realizada a seleção de atributos, que consiste em um processo no qual um espaço de dados é transformado em um espaço de características de menor dimensão, mas que ainda retenha uma porção significativa da informação intrínseca dos dados (OLDEN; JOY; DEATH, 2004). Essa seleção de atributos permitirá a redução no número de entradas das RNAs que caracterizarão a aproximação funcional dos limites de estabilidade/segurança de tensão e a aplicação dessa abordagem a SEEs de maior porte.
3. **Treinamento das RNAs para a caracterização e validação da aproximação funcional dos limites de estabilidade/segurança de tensão:** Utilizar-se-á o *software* Jupyter Notebook para realização dos treinamentos e validações das RNAs, de forma a gerar a estimativa dos limites de estabilidade/segurança de tensão para o sistema-teste de 6 barras. A forma como ocorre o treinamento e validação dos dados por RNAs nessa ferramenta se dá pelas mesmas metodologias implementadas em diferentes *softwares* existentes no mercado. A vantagem, portanto, do uso do Jupyter Notebook vem da facilidade de tratamento, implementação, interpretação, extração e visualização dos resultados que tal ferramenta oferece.
4. **Incorporação da aproximação funcional dos limites de estabilidade e segurança de tensão ao FPO-REST:** A partir do modelo matemático das RNAs

treinadas e validadas, será definida uma função não linear e diferenciável que aproxima os limites de estabilidade/segurança de tensão do SEE em função das alocações de potência ativa (oferta e a demanda no sistema de leilão).

5. **Resolução do FPO-REST:** O modelo de FPO-REST proposto neste projeto de pesquisa será implementado no ambiente de modelagem de problemas de programação matemática AMPL (AMPL Optimization Inc., 2021) e resolvido pelo *solver* LOQO (VANDERBEI, 2006).
6. **Comparação de resultados para a validação do modelo de FPO-REST proposto:** A praticidade e viabilidade da abordagem proposta será validada por meio de uma comparação de resultados entre o modelo proposto e um modelo de FPO-REST bi-nível equivalente.

1.3.1 Forma de Análise dos Resultados

Para verificar a eficácia do modelo proposto e validar a abordagem para resolução de problemas de FPO-REST desenvolvida, serão realizados testes com um sistema de 6 barras.

Os resultados obtidos serão analisados em duas etapas.

1. **Primeira etapa:** Validação do modelo de FPO-REST proposto considerando um SEE de pequeno porte comumente utilizado na bibliografia correlata (6 barras).
2. **Segunda etapa:** Realização de testes numéricos para diferentes cenários operacionais para verificar a eficácia da abordagem proposta.

1.4 Organização do Trabalho

Este trabalho está organizado da seguinte forma.

No Capítulo 2 é apresentado o estado da arte sobre a modelagem e/ou abordagens de resolução de problemas de FPO-RS e FPO-RET, apontando as proposições exórdias de Alsac e Stott (1974) sobre o FPO-RS e Milano, Canizares e Invernizzi (2003) sobre FPO-RET, e analisando cronologicamente as principais contribuições em publicações correlatas.

No Capítulo 3 é apresentada uma breve revisão sobre as RNAs e seletores de atributos utilizáveis para análise das correlações entrada saída.

No Capítulo 4 apresentam-se as formulações genéricas inerentes aos problemas de FPO-RS, FPO-RET, FPO-REST e o FPO-REST proposto.

No Capítulo 5 apresenta-se a metodologia proposta, bem como as formulações matemáticas empregadas para determinação dos pontos de máximo carregamento pelo método direto e FPO-REST aplicado a sistemas de leilão de energia elétrica.

No Capítulo 6 são apresentados os testes realizados com o modelo de FPO-REST aplicado a sistemas de leilão de energia elétrica e abordagem de resolução propostos neste trabalho.

No Capítulo 7 são apresentadas as considerações finais e o detalhamento das próximas atividades a serem realizadas para a conclusão deste trabalho.

Capítulo 2

Estado da Arte

Um dos focos de estudo deste trabalho consiste na representação da segurança e estabilidade de tensão em problemas de FPO-REST aplicado a leilões de ajuste em mercados de energia elétrica. Portanto, neste capítulo, são apresentados os principais trabalhos acerca dos métodos de Fluxo de Potência Ótimo com Restrições de Segurança de Tensão (FPO-RS) e Fluxo de Potência Ótimo com Restrições de Estabilidade de Tensão (FPO-RET).

Nos trabalhos relacionados ao FPO-RS são factuais duas abordagens. Primeiramente, proposto por Alsac e Stott (1974), o FPO-RS foi modelado com restrições de controle preventivo com o intuito de ser empregado para atuação/correção dos controles no período pré-contingencial.

Com o passar dos anos, viu-se a necessidade da utilização de modelos para problemas de FPO-RS mais precisos e realísticos e que atendessem situações pré, pós e contingencial. Em Monticelli, Pereira e Granville (1987) é proposto um aperfeiçoamento nos modelos de FPO-RS preventivos existentes até então. No estudo em questão, ocorre a adição e implementação de restrições específicas para os períodos contingencial e pós-contingencial. Desta forma, o modelo proposto pelos autores ainda na década de 80 é considerado um marco, aja vista sua contribuição. Em dias atuais, é reconhecido que o trabalho desenvolvido é um divisor de águas e seu conceito de se utilizar restrições que atuem em quaisquer período, reverberam aos estudos atuais demonstrado por diversos autores.

Não obstante, por mais que não muito, existem trabalhos que consideram apenas a utilização do controle preventivo em FPO-RS, para suas finalidades, a exemplo, este trabalho. uma vez que o mesmo é empregado em leilões de ajuste em mercados de energia elétrica, não havendo necessidade das restrições pós-contingenciais.

Nos trabalhos relacionados ao FPO-RET não há abordagens de metodologia pré definida. Na Seção 2.2 deste Capítulo, é apresentado diversas alternativas aplicáveis aos problemas de FPO-RET para distintas situações dos respectivos estudos. É perceptível que determinados trabalhos utilizam de uma mesma técnica, contudo, aplicados em contextos e cenários dessemelhantes. Diante desses fatos, o FPO-RET, bem como o FPO-REST,

são áreas de estudo contemporâneos e em crescente expansão.

2.1 FPO-RS

Nesta seção são apresentados trabalhos acerca de problemas de FPO-RS. Existem diferentes critérios que envolvem a segurança operacional de SEEs, a exemplo, magnitudes de tensão nodais, magnitudes de correntes nas linhas de transmissão (limites térmicos), módulo do fluxo de potência aparente nas linhas de transmissão (limites de congestão) e contingências em barras de geração e linhas de transmissão. A segurança de tensão visa, portanto, assegurar que o SEE siga sendo operado dentro das faixas de tensão permitidas, mesmo após a ocorrência de grandes perturbações. As principais modelagens e/ou metodologias de resolução do problema de FPO-RS são apresentadas em sequência.

Um dos trabalhos precursores do FPO-RS foi proposto por Alsac e Stott (1974), onde se propôs a modelagem de um problema de FPO com a incorporação de um segundo conjunto de restrições para o estado de pré-contingência, denominado FPO-RS. A partir dessa proposta, o FPO-RS passa a constituir uma subclasse de problemas de FPO. Assim sendo, o modelo do problema de FPO-RS é constituído por um conjunto de restrições associado ao estado de pré-contingência, no qual as variáveis de controle devem ser ajustadas de forma a satisfazer este conjunto. Nesse trabalho, as restrições de igualdade do problema são tratadas pelo método Lagrangiano e as restrições de desigualdade são tratadas por penalidades quadráticas. Os autores apresentam resultados numéricos para o sistema teste IEEE de 30 barras de forma a validar a modelagem do problema de FPO-RS. A eficácia da metodologia de resolução desse problema é avaliada pelo método do gradiente reduzido desenvolvido por Dommel e Tinney (1968) considerando contingências em cada uma das linhas de transmissão do sistema-teste. Contudo, a definição dos parâmetros do método do gradiente reduzido e de pesos para as penalidades quadráticas não são triviais e afetam a convergência do método.

Em Barcelo, Lemmon e Koen (1977) é proposta uma modelagem para o problema de FPO-RS impondo restrições de segurança estáticas (como limites de tensão de barramento, capacidade do fluxo de linha e limites de potência reativa do gerador) incluído na formulação pelo uso de funções de penalidade quadráticas. A técnica de minimização não linear usada é o método do gradiente de primeira ordem, formulado de maneira decomposta. Duas funções objetivo são descritas, uma para o custo total de produção por hora, controlando a potência ativa do gerador e as configurações de *tap* em transformadores defasadores, e outra para as perdas ativas em linha de transmissão controlando as tensões dos terminais dos geradores e capacitores/reatores *shunts*. Os testes foram realizados em um sistema de 1200 barras de forma a validar a abordagem proposta.

Os autores Isoda e Sato (1985) apresentam em seu estudo uma modelagem através de um algoritmo de controle de despacho de carga com restrições de segurança empregado

na companhia de energia elétrica Tohoku no Japão em 1984. O algoritmo principal no sistema desenvolvido é baseado no problema de FPO. A formulação ocorre com base no método de Newton desacoplado para Fluxo de Carga (FC) e resolvido por programação quadrática. O sistema pelo qual testou-se o algoritmo proposto possui 180 barras e 200 ramos, composto por 26 geradores e 3 transformadores defasadores controláveis. Segundo o estudo, o algoritmo desenvolvido possui um tempo computacional de 0,2 segundos e consome uma memória inferior comparado ao disponibilizado pelo computador existente da companhia de energia elétrica de Tohoku, que atendera o sistema da mesma. O método de Newton desacoplado possibilita simplificações na matriz Jacobiana de forma a resolver subproblemas da mesma e de forma alternada, possibilitando uma convergência ágil e tão precisa quanto outros métodos existentes na literatura. O conceito de desacoplado vem através das sensibilidades existente entre as potências (ativas e reativas) e as tensões (magnitudes e ângulos de fase), entretanto, geralmente, o fato é verificado para redes de transmissão de extra e ultras tensões (acima de 230 kV).

Em Monticelli, Pereira e Granville (1987), os limites de segurança operacional de um SEE consistem na limitação das magnitudes de tensão nodal dentro de limites operacionais, das magnitudes de corrente em linhas de transmissão (limites térmicos), do módulo do fluxo de potência aparente em linhas ou troncos de transmissão (limites de congestão) nos estados de pré e pós-contingência, com a definição de ajustes preventivos (pré e imediatamente pós-contingência) e corretivos (redespacho ativo/reactivo pós-contingência). Neste trabalho, as restrições de desigualdade são tratadas por penalidades quadráticas e o modelo é constituído por um conjunto de restrições associado ao estado de pré-contingência e outro associado ao estado de pós-contingência, nos quais as variáveis de controle devem ser ajustadas de forma a satisfazer, simultaneamente, ambos conjuntos de restrições. A metodologia de resolução proposta pelos autores constitui em um processo de dois estágios. Em primeiro, encontra-se o ponto operacional para o problema de despacho econômico (caso base). Já no segundo estágio, dado o ponto operacional inicial, novos pontos operacionais são encontrados de forma factível, atendendo as restrições operacionais e de acoplamento para cada configuração de pós-contingência. A metodologia consiste, portanto, nas técnicas de decomposição matemática, em que se permite tratar separadamente o caso base e cada um dos N subproblemas da operação pós-contingencial. Testes foram realizados em um sistema-teste IEEE 118 barras, onde 5 contingências foram selecionadas, quatro interrupções do circuito e um capacitor *shunt*.

Em Stott, Alsac e Monticelli (1987) é realizado uma pesquisa extensa com a finalidade de se definir termos como: monitoramento, análise e particularmente segurança voltados a SEEs. Para os autores, um sistema de energia está em condição de emergência quando os limites operacionais pré-estabelecidos são violados. As violações mais graves e de menor previsibilidade são resultantes de contingências. Para os autores, o conceito de segurança, portanto, gira em torno da capacidade do SEE de suportar os efeitos das perturbações que

ocasionam contingências e, ainda assim, permanecer em operação. Logo, um determinado estado do sistema pode ser declarado seguro apenas quando se obtém uma referência a um ou mais casos de contingência conhecidas e um determinado conjunto de violações monitoradas.

Em Harsan, Hadjsaid e Pruvot (1997) é apresentada uma metodologia cíclica para agilizar a análise de segurança aplicado em FPO-RS. Tal análise se divide em duas partes: a primeira analisa as pequenas alterações das variáveis de controle causadas pelas contingências, de modo que as que não causam impacto significativo no SEE são eliminadas. Já a segunda, analisa as contingências restantes, onde a variação da magnitude das tensões no período de pós-contingência são calculadas por meio do método de Newton desacoplado para FC. Os testes foram realizados no SEE francês de 225-400 kV, contendo 482 barras e 855 ramos. Os resultados mostram que a inclusão do procedimento de segurança cíclico no FPO proposto ocasiona condições mais seguras e acelera consideravelmente o processo de convergência.

Os autores Somasundaram, Kuppusamy e Devi (2004) apresentam em seu artigo um algoritmo baseado em Programação Evolutiva para resolver um problema de FPO-RS. É apresentado uma modelagem de resolução em duas fases. Na primeira, o caso base do problema de FPO é formulado e resolvido. Subsequente, o problema de FPO-RS é resolvido tomando a solução obtida na fase 1 como solução inicial. Para ambas as fases utiliza-se da programação evolutiva. Realizaram-se testes empregando um sistema adaptado IEEE de 30 barras e compararam os resultados obtidos em relação do método de FPO-RS convencional proposto por Alsac e Stott (1974). Segundo os autores, a abordagem proposta é relativamente simples, confiável e eficiente. Apesar dos resultados promissores, o uso de Programação Evolutiva não permite a obtenção de uma solução única. Por se tratar de uma estratégia de otimização estocástica, não há garantias de que duas execuções sob as mesmas condições encontrarão as mesmas soluções, ou que o algoritmo realmente convergiu na melhor solução que poderia encontrar (ALIPOURI; POSHTAN; ALIPOURI, 2012). De fato, não é habitual evidenciar e projetar heurísticas para detectar a aparência do “melhor” ponto (a menos que seu desempenho seja conhecido a priori).

Aos autores Fu, Shahidehpour e Li (2006) propõem em seu artigo um modelo de despacho de contingência preventivo/corretivo com base no modelo de comprometimento de unidade de energia com FPO-RS. O objetivo do modelo proposto é minimizar o custo de operabilidade do sistema, bem como o custo de inicialidade das unidades comprometidas, satisfazendo as restrições de segurança. Na abordagem realizada, o método de relaxamento lagrangiano aumentado é aplicado para resolver o comprometimento de unidade de energia. O objetivo do problema de comprometimento de unidade é otimizar a produção e distribuição de eletricidade, considerando um horizonte de planejamento de curto prazo (a partir de um dia a uma semana). A metodologia apresentada é aplicada aos sistemas de 6 barras e IEEE de 118 e 1168 barras. Para ambos os sistemas são realiza-

dos estudos de casos distintos entre si, donde cada um possui uma de contingência N-1 especificada; após, é calculado pelo modelo, o valor diário baseado em lances, uma vez que a modelagem proposta permite uma distribuição da carga horária sobre o horizonte de 24 horas. O estudo resolve o problema de FPO-RS e elabora um conjunto de ações de controle preventivo/corretivo para operação segura e econômica de um SEE. Contudo, a utilização do método de relaxamento lagrangiano aumentado, trás consigo um otimizador local e não global. Um outro ponto importante, é que o termo quadrático introduzido pelo lagrangiano aumentado não é separável.

Os autores Capitanescu et al. (2007) adotaram um modelo para um algoritmo de FPO-RS de controle preventivo iterativo, propondo duas técnicas de filtragem de contingência baseadas na comparação de violações de pós-contingências. Essa abordagem visa, essencialmente, identificar um subconjunto tão pequeno quanto possível, incluindo todas as contingências de vinculação (ou seja, o menor conjunto de contingências que levem o método a identificar o mesmo valor objetivo ótimo de quando o conjunto completo é avaliado) para o FPO-RS. Nas simulações, usou-se o método de Pontos Interiores em conjunto com uma formulação retangular das variáveis de estado para resolver o problema FPO-RS de controle preventivo. O estudo apresenta resultados obtidos com a abordagem proposta em dois sistemas, um Nórdico de 60 barras modificado e um IEEE de 118 barras. Considerando uma lista de contingências contendo o desligamento de qualquer linha de transmissão. Os experimentos realizados nos sistemas mostraram que o método proposto permite acelerar a solução sequencial do problema de FPO-RS de controle preventivo.

Em Capitanescu et al. (2011) os principais desafios para o cálculo e questões envolvendo FPO-RS são discutidos, a exemplo: o uso de número limitado de ações corretivas nos estados de pós-contingência, técnicas voltadas para reduzir o tamanho do problema de FPO-RS e o tratamento de variáveis discretas, são apresentadas. Para os autores, os principais desafios do problema de FPO-RS encontram-se em: formulações de problemas (visando melhorias na formulação para se obter soluções mais realistas); técnicas de solução de problemas (visando a redução do tamanho do problema); tratamento adequado para as variáveis discretas e, por fim, a utilização de solucionadores de programação não linear robustos e eficientes. Por fim, o artigo revisa o estado da arte das soluções computacionais do problema clássico do FPO-RS e indica possíveis direções futuras de pesquisa que possam ajudar a superar limitações existentes até então.

Em Wen et al. (2015) é proposto o uso do armazenamento de energia distribuída de resposta rápida para implementação de ações de controle corretivo pós-contingência utilizando da formulação do problema de FPO-RS. A metodologia consiste em duas etapas e é resolvido de forma serial. Em princípio, resolve-se o problema da primeira fase (utilizando a decomposição de *Benders*), depois, toma-se a solução do problema do primeiro estágio como parâmetro e resolve-se os problemas da segunda fase. À estratégia de operação das baterias ocorre da seguinte forma: após a ocorrência da contingência

uma ou mais baterias injetam energia imediatamente com o intuito de trazer o sistema para a operação normal; subsequente, as injeções de energia das baterias permanecem constantes até o momento que os geradores do sistema começam o processo de *ramping*; em terceiro momento, durante o período de *ramping* dos geradores, as baterias reduzem continuamente suas injeções até atingirem o seu estado *sleeping*; em paralelo, os geradores aumentam a disponibilidade de energia até chegarem no mesmo patamar de injeção demandada anteposto à contingência. Os autores testaram o modelo e algoritmo proposto em dois sistemas distintos, de 6 barras e RTS 96 de 169 barras modificado. Todas as contingências adotando o critério N-1 foram consideradas em ambos sistemas. Os resultados demonstram em, particular, a potência necessária para suprimento do sistema e quantidade de baterias passíveis de utilização predispostas nas barras do sistema.

Aos autores Teeparthi e Kumar (2017) desenvolveram em seu artigo uma modelagem de resolução de FPO-RS multi-objetivo utilizando um algoritmo híbrido, otimização por enxame de partículas somado a otimização física artificial. Para avaliar a robustez e eficácia do algoritmo proposto para resolução do problema de FPO-RS multi-objetivo, foram considerados um sistema IEEE de 30 barras e um sistema prático de 75 barras. Os resultados dos testes são comparados com os métodos meta-heurísticos de forma individual e em conjunto, em ambos sistemas considerou-se as contingências N-1. Segundo os autores, o algoritmo de otimização desenvolvido integra o melhor das duas técnicas, obtendo assim, um equilíbrio entre exploração (otimização por enxame de partículas) e aproveitamento (otimização física artificial). Entretanto, as características inerentes dessa abordagem limita a aplicação da mesma em algumas situações. No método de otimização por enxame de partículas (abordagem meta-heurística), todas as soluções convergem prematuramente e, conseqüentemente, perdem a diversidade populacional. Além, a otimização física artificial (abordagem estocástica) é um método que usa um mecanismo de atração e repulsão para mover uma “população de indivíduos” para o ponto ótimo e armazena apenas a melhor posição global total obtida por todos os indivíduos, porém, ignora a melhor posição singular de cada indivíduo.

No trabalho desenvolvido por Marcelino et al. (2018) também adotou-se de uma abordagem híbrida, em que utiliza-se otimização por enxame de partículas com evolução diferencial para resolver o problema de FPO-RS. O artigo aborda o problema de FPO-RS considerando duas funções objetivas diferentes, minimização do custo total de operação e a minimização das perdas totais de energia ativa na rede de transmissão. O desempenho do método proposto para resolver o problema de FPO-RS é avaliado utilizando os sistemas IEEE de 57, 118 e 300 barras. Para ambos os sistemas, além do cenário de operação esperado, são considerados cenários de contingência N-1; para o sistema IEEE de 57 barras ocorre o desligamento em dois ramos distintos; já para o IEEE de 118 barras ocorre o desligamento de 4 ramos, e o sistema de 300 barras ocorre o desligamento de 3 ramos.

Em Dini et al. (2021) é apresentado o planejamento de expansão de geração e transmissão com restrição de segurança de acordo com um modelo estratégico de licitação de energia e reserva de mercado. A estratégia é baseada na otimização bi-nível em que minimiza a diferença entre o custo e receita das empresas submetidas ao orçamento de investimentos permitidos para linhas de transmissão e unidades de geração no nível superior, para o nível inferior apresenta o modelo de compensação de mercado baseado na abordagem do problema de FPO-RS. Os autores também utilizaram o método de planejamento de expansão com restrições de segurança baseada na otimização de nível simples, onde se obtém utilizando a abordagem Karush-Kuhn-Tucker (KKT) e o método de decomposição de *benders* para resolução do problema. O método proposto pelos autores é simulado em sistemas de 6 barras e IEEE de 118 barras modificados. São simulados quatro diferentes cenários: análise do fluxo de potência, estratégia proposta considerando apenas com planejamento da linha de transmissão, considerando apenas com planejamento de unidades de geração e o modelo de planejamento de expansão de geração e transmissão com restrição de segurança.

2.2 FPO-RET

Nesta seção são apresentados trabalhos que se relacionam com problemas de FPO-RET. O conceito de estabilidade da tensão refere-se à capacidade de um SEE manter-las entre níveis aceitáveis (limites operacionais) em todas as barras do sistema não apenas em condições normais de operação, mas também após ser submetido a um distúrbio (KUNDUR et al., 2004). É um fato bem estabelecido que o colapso de tensão nos SEE está associado com o aumento da demanda do sistema além de certos limites, bem como o déficit de potência reativa no sistema causado por limitações na geração ou transmissão da mesma. As contingências que por ventura ocorrem no sistema, como interrupções inesperadas do gerador ou da linha de transmissão agravam ou, de fato, desencadeiam problemas de estabilidade de tensão em linhas de transmissão (AVALOS et al., 2009).

Em Milano, Canizares e Invernizzi (2003), o bem estar social e o distanciamento para o máximo carregamento são maximizados em um sistema de leilão de FPO-RET multi-objetivo para aquisição de energia de curto prazo em mercados híbridos de eletricidade. Os limites de estabilidade de tensão são aplicados no sistema de leilões por um conjunto de equações de equilíbrio de potência ativa e reativa associadas ao ponto de operação de máximo carregamento, limites de margem de carregamento para garantir níveis mínimos e máximos de segurança, limites de geração de potência reativa, limites de magnitudes de tensão e limites térmicos (corrente nas linhas de transmissão). O trabalho apresenta resultados numéricos para um sistema de 6 barras e um Italiano de 129 barras de alta tensão. Apesar da segurança do sistema de preços não dependerem do fator de pondera-

ção, as variáveis duais oriundas da modelagem da precificação são, de fato, aferidas pelo fator de ponderação. Esta abordagem atinge soluções ótimas de Pareto, mas não ótimas, condições de mercado por meio de níveis de transação aumentadas, mas não máximos.

Em Milano, Canizares e Conejo (2005), é proposto duas novas técnicas para incluir contingências em cálculos de mercado de eletricidade baseados em FPO-RET. A formulação inclui restrições de estabilidade de tensão como: limites térmicos, conjunto de restrições de igualdade (equações de FC) e desigualdade (limites de geração de potência reativa e limites de tensão), além da inclusão de um parâmetro de carregamento, a fim de garantir uma margem de estabilidade adequada para a solução de mercado. A modelagem é resolvida usando o método de pontos interiores primal-dual baseado na técnica preditor-corretor de Mehrotra. Os autores apresentam resultados numéricos para um sistema de 6 barras e um Italiano de 129 barras. O modelo de FPO-RET baseado no mercado de eletricidade indicaram que uma representação adequada da segurança do sistema e a adequada inclusão de contingências resultam em margens de segurança mais altas e custos mais baixos.

Em Avalos, Canizares e Anjos (2008) e Lage, Costa e Canizares (2012), são propostas restrições de estabilidade de tensão baseadas em Índice de Estabilidade de Tensão (IET) para condições operacionais estáveis de preço em um sistema de leilão FPO-RET para aquisição de energia de curto prazo em mercados híbridos de eletricidade. Em ambas as propostas, os limites de estabilidade de tensão são aplicados no sistema de leilão por limites de geração de potência reativa, limites de magnitude de tensão, limites térmicos e a respectiva restrição de estabilidade de tensão baseada nos IET. No entanto, ambos os IET apresentam perfis não lineares e tal características torna mais difícil relacionar o aumento da carga do sistema de energia com a proximidade dos limites de estabilidade. Outrossim, a atribuição de um valor crítico geral para garantir níveis mínimos de estabilidade tem se mostrado uma abordagem bastante conservadora. Já no trabalho proposto por (CUI; SUN, 2018), um novo IET em uma modelagem de FPO-RET com boas propriedades computacionais sob aproximações suaves é proposto, garantindo a robustez da solução de FPO contra a instabilidade de tensão devido à singularidade de tensão devido à singularidade da matriz Jacobiana de FC, ou seja, bifurcações sela-nó.

Em Gutierrez-Martinez et al. (2011), uma restrição de estabilidade/segurança baseada em uma aproximação por uma RNA é proposto, em que a estabilidade/segurança de tensão e limites de estabilidade de pequenos sinais considerando as contingências N-1 no sistema de energia é aplicada em uma estratégia de leilão de FPO-RET para aquisição de energia de curto prazo em mercados híbridos de eletricidade. Dois sistemas teste foram selecionados para avaliar e demonstrar o modelo proposto: um sistema de duas áreas e um sistema de 118 barras, ambos do IEEE. Nesta abordagem, o limite aproximado de estabilidade consiste numa função diferenciável definida em termos do estado operacional multidimensional.

Em Hamon, Perninge e Soder (2013), propõem uma restrição de estabilidade/segurança baseada em aproximações de segunda ordem de estabilidade/segurança de tensão e limites de estabilidades oriundos de pequenos sinais para impor um certo nível de segurança no custo mínimo de operação esperado, com base no FPO sob variações de parâmetros estocásticos. Enquanto os limites de estabilidades de tensão habituais consistem de interseções associados a bifurcações do tipo sela-nó, induzidas por limites, Hopf e limites térmicos, o limite de estabilidade aproximado, proposto pelos autores, consiste de expansões de Taylor de segunda ordem. Os autores utilizam um sistema-teste IEEE de 9 barras de forma a apontar os resultados obtidos pela metodologia proposta. Todavia, apesar do método de ser bastante preciso devido às expansões de Taylor, tal abordagem tem um custo computacional elevado, uma vez que exige o cálculo de todo o limite de estabilidade/segurança, a busca do ponto de aproximação em torno do qual a aproximação de segunda ordem é mais precisa, a aproximação real de segunda ordem para cada cenário operacional de pré e pós-contingência e, por fim, ações corretivas de pós-contingência.

Em Lage, Fernandes e Costa (2015), é proposta uma aproximação funcional por uma RNA utilizando como algoritmo de treinamento o *levenberg-marquardt*, o trabalho apresenta uma topologia de RNA distinta e motivada através do estudo realizado pelos autores Gutierrez-Martinez et al. (2011). De mesmo modo, tal estratégia possui uma arquitetura em que impõe a estabilidade de tensão em um sistema de leilão utilizando do FPO-RET para aquisição de energia de curto prazo em mercados híbridos de eletricidade. Os testes foram realizados utilizando um sistema-teste de 6 barras com o intuito de indicar o potencial de tal metodologia. Por se tratar da utilização de um algoritmo de treinamento adaptado para funções da soma dos erros ao quadrado, o *levenberg-marquardt* não é recomendado para grandes conjuntos de dados, aja vista o alto consumo de memória. Ademais, o algoritmo encontra apenas um mínimo local, que não é necessariamente o mínimo global. Além de exigir o cálculo de todo o limite de estabilidade/segurança de tensão para o treinamento e validação das RNAs e, portanto, com alto esforço computacional, ambas as abordagens para aproximação dos limites de estabilidade/segurança de tensão dependem da arquitetura da RNA, bem como da definição de funções de ativação e algoritmos de treinamento adequados.

Em Chavez-Lugo et al. (2016), uma restrição de segurança baseada em aproximações de primeira ordem de estabilidade de tensão e limites de estabilidade de pequenos sinais considerando as contingências N-1 no sistema de energia, é aplicada em um sistema de leilão de Fluxo de Potência Ótimo - Corrente Contínua (FPO-CC) (Fluxo de Potência Linearizado) limitada unilateralmente para aquisição de energia de longo prazo em mercados de eletricidade desregulamentados. Enquanto o limite de segurança real consiste de coletores de ligação interna e de interseção associados a bifurcações do tipo sela-nó, bifurcações induzidas por limite e bifurcações Hopf, em cenários de operação N-1, o limite de segurança aproximado consiste de uma série de hiperplanos tangentes de ligação interna

e interseção para cada coletor que resulta em um conjunto de desigualdades lineares em termos do estado de despacho multidimensional. Também é proposta uma heurística para reduzir o número de hiperplanos na restrição de segurança, para que essa aproximação não resulte em um problema de programação linear de dimensões excessivamente grandes. Além de exigir o cálculo de todo o limite de segurança, são reportados erros absolutos máximos de cerca de 0,8 e 10% na aproximação do limite de segurança, contabilizando a heurística proposta, para estudos de caso com os sistemas teste IEEE de 9 e 118 barras, respectivamente. Conseqüentemente, isto pode dificultar a sua aplicação prática e comprometer a precisão da representação de segurança proposta para sistemas maiores.

Capítulo 3

Fundamentos das Redes Neurais Artificiais e Seletores de Atributos

Este Capítulo é dedicado aos preceitos e conceitos das RNAs e seletores de atributos que estão empregados neste trabalho, haja vista a utilidade crucial dos mesmos para obtenção dos resultados esperados.

RNAs e seletores de atributos são ferramentas que possuem inúmeras aplicações em diversas áreas de estudo. Robustez e dinamismo fazem com que a aplicabilidade seja eficiente e confiável, na medida que diversos problemas sejam factíveis, abrindo-se assim, novos horizontes.

3.1 Redes Neurais Artificiais

O trabalho em RNAs, foi motivado, desde o início, pelo reconhecimento de que o cérebro humano calcula de uma maneira totalmente diferente do computador digital convencional. O cérebro humano tem a ímpar capacidade de organizar seus constituintes estruturais, conhecidos como neurônios, de modo a realizar certos cálculos (HAYKIN, 2008). O primeiro modelo artificial para um neurônio biológico foi proposto por Warren McCulloch e Walter Pitts em 1943 (MCCULLOCH; PITTS, 1943). A Figura 1 define um modelo genérico de um neurônio artificial.

O neurônio artificial consiste em um modelo com n terminais de entrada, ou seja, x_1, x_2, \dots, x_n (representando os dendritos) e um terminal de saída único y (representando o axônio). O comportamento sináptico é simulado por meio de pesos sinápticos (w_1, w_2, \dots, w_n) , cujos valores podem ser positivos ou negativos. Matematicamente, o neurônio artificial pode ser representado da seguinte forma:

$$u_k = \sum_{i=1}^m w_{ki} \cdot x_n \quad (1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (2)$$

onde y é a saída, φ é a função de ativação, m é o número de entradas, x_i é a i -ésima entrada, w_i é o peso associado a i -ésima entrada e b refere-se ao *bias* do neurônio.

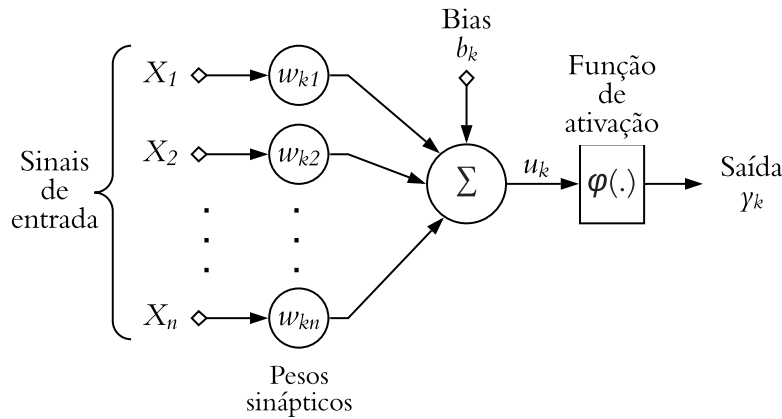


Figura 1 – Neurônio artificial.

Uma RNA obtém seu poder computacional por meio de, primeiramente, sua estrutura distribuída massivamente paralela e, segundo, a sua capacidade de aprender e, portanto, generalizar. Logo, uma RNA consegue obter resultados razoáveis para dados não contidos em sua fase de treinamento, no contexto complexo (HAYKIN, 2008). Não linearidade, mapeamento de entrada e saída, adaptabilidade, implementabilidade integrada em larga escala são fatores que diferenciam RNAs dos demais algoritmos convencionais. Tais características as tornam atraentes para a aplicação em diversas áreas científicas.

3.1.1 Arquitetura da Rede Neural Artificial

Os termos arquitetura, estrutura ou topologia de uma RNA são usados para referenciar sobre a forma como os neurônios artificiais são organizados na rede. Particularmente, esses termos estão focados na descrição de como os nós estão conectados e em como as informações são transmitidas através da rede (Puig Arnavat; Joan Carles, 2015).

As RNAs *multi-layer perceptron*, treinadas com um algoritmo de aprendizagem *back-propagation*, são as redes mais difundidas no contexto de aprendizagem de máquina. Frequentemente, aplicadas a problemas de aprendizagem supervisionados, treinam em um conjunto de pares entrada-saída e modelam a correlação (ou dependências) entre entradas e saídas. O método *back-propagation*, também conhecido como algoritmo *error back-propagation*, é baseado na regra de aprendizagem da correção de erros. O treinamento envolve o ajuste dos parâmetros, também conhecidos como pesos e bias, do modelo buscando a minimização do erro.

O termo *back-propagation* é, por vezes, utilizado para se referir especificamente ao algoritmo de otimização Gradiente Descendente Estocástico, quando aplicado ao treinamento de RNAs. Essa terminologia não é empregada neste trabalho, uma vez que o processo de computação seja por Gradiente ou Jacobiano, realizando cálculos para correção dos erros, é aplicado para a função de treinamento descrita na Sub-subseção 3.1.3, não se restringindo a somente um método específico.

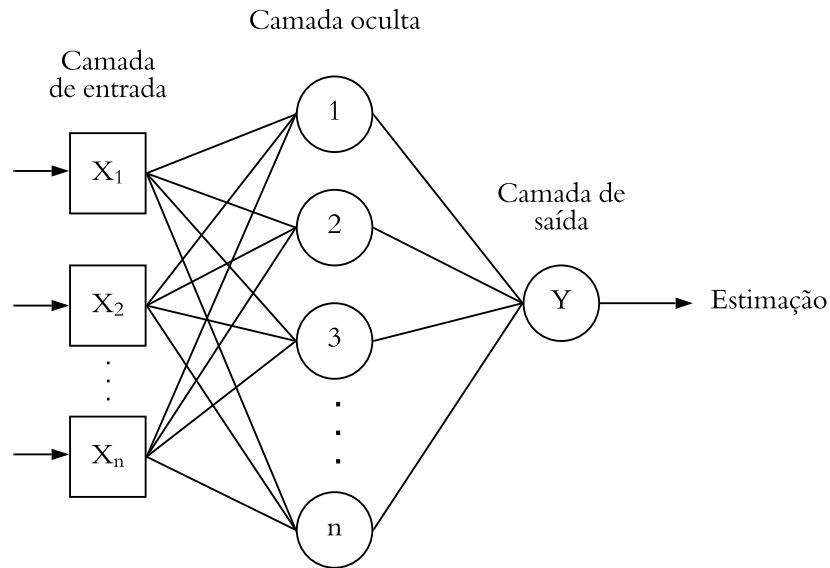


Figura 2 – Rede neural multi-layer perceptron.

Uma RNA *multi-layer perceptron* consiste em neurônios, que são encontrados em camadas, Figura 2. A primeira camada é denominada de camada de entrada, onde valores de interesse são utilizados para alimentar a rede X_1, X_2, \dots, X_n , a última camada é chamada de camada de saída Y , nesta camada é obtido o resultado perante valores inseridos na entrada e, por fim, a camada oculta (ou escondida) se encontra entre as camadas de entrada e saída.

3.1.2 Funções de Ativação

A função de ativação, também chamada de função de transferência, determina a relação entre entradas e saídas de um neurônio e, conseqüentemente, de uma RNA. Em geral, a função de ativação introduz um grau de não linearidade que é valioso para a maioria das aplicações que empregam RNAs (ZHANG; PATUWO; HU, 1998). As funções clássicas comumente utilizadas estão contidas na Tabela 1, de mesmo modo, a Figura 3 esboça as mesmas.

O comportamento de uma RNA é tipicamente caracterizado pelos cálculos elementares de cada neurônio e o processo computacional elementar de cada neurônio é geralmente

um processo de dois passos. No primeiro, um valor real é calculado a partir dos valores de entrada do neurônio e do seu respectivo peso de conexão. Normalmente, este valor é calculado como uma combinação linear ponderada da entrada do neurônio, o produto interno padrão em \mathbb{R}^d entre os vetores X e W . No segundo passo, um valor de saída escalar é computado por uma função de ativação, $f : \mathbb{R} \rightarrow \mathbb{R}$. Desta forma, a saída de um neurônio depende diretamente dos valores de entrada (valores de entrada de toda a rede ou saídas de outros neurônios), dos respectivos pesos de conexão associados as entradas e, por fim, o valor escalar obtido através de uma função de ativação previamente definida (APICELLA et al., 2021).

Tabela 1 – Funções de Ativação Clássicas

Nome	Expressão	Intervalo
Sigmoide (logística)	$f(x) = \frac{1}{1+e^{-x}}$	$(0, 1)$
Tangente hiperbólica	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1, 1)$
Linear	$f(x) = x$	$(-\infty, +\infty)$




Figura 3 – Gráfico das funções de ativação clássicas.

Recentemente, diferentes funções de ativação foram propostas, a maioria das quais inspiradas pelo sucesso obtido pela função *Rectified Linear Unit*, tão somente ReLU e, portanto baseadas numa forma semelhante, com pequenas variações, em relação à função

original. Essas funções de ativação se tornaram de fato, o padrão nas arquiteturas de RNA atuais, superando outras funções clássicas como sigmoide e tangente hiperbólica usadas no passado (APICELLA et al., 2021). A Figura 4 representa graficamente a função de ativação ReLU e, matematicamente, pode ser escrita da seguinte forma:

$$\text{ReLU}(x) = \max(0, x) \approx \frac{x + \sqrt{x^2 + \epsilon}}{2} \quad (3)$$

onde ϵ é um valor positivo não nulo muito pequeno que permite a diferenciabilidade da função ReLU em 0.

Um dos primeiros estudos que demonstrou as melhorias de desempenho de redes equipadas com funções de ativação baseadas em retificadores foi proposto por Glorot, Bordes e Bengio (2011), onde RNAs de aprendizado profundo, equipadas com funções de ativação ReLU, melhoraram o desempenho se comparados a redes que empregaram nos neurônios artificiais, a função de ativação sigmoide. O principal benefício do uso de funções de ativação retificadas é de se evitar o problema do *vanishing gradient* (BENGIO; SIMARD; FRASCONI, 1994), que tem sido um dos principais problemas para RNA por anos.




Figura 4 – Gráfico da aproximação numérica diferenciável da função de ativação ReLU, onde $\epsilon = 10^{-9}$.

Em aprendizagem de máquina, o problema do *vanishing gradient* é encontrado ao treinar RNAs com métodos de aprendizagem baseados em gradientes e *back-propagation*. Nesses métodos, cada um dos pesos associados aos neurônios da RNA recebe uma atualização proporcional à derivada parcial da função de erro em relação ao peso atual em cada iteração durante o treinamento. O problema é que, em alguns casos, o gradiente

será cada vez menor impedindo, efetivamente, que o peso mude seu valor. Na pior das hipóteses, isso pode parar completamente a RNA de continuar o treinamento.

Nos últimos anos, vários esforços continuaram a ser feitos na comunidade científica para encontrar novas funções de ativação com a finalidade de melhorar o desempenho das RNAs (SIBI; JONES; SIDDARTH, 2013; XU et al., 2015; XU; HUANG; LI, 2016; NWANKPA et al., 2018; PEDAMONTI, 2018; APICELLA et al., 2021). No entanto, a pesquisa sobre as funções de ativação clássicas perpetua aos dias atuais (GULCEHRE et al., 2016; XU; HUANG; LI, 2016).

3.1.3 Algoritmos de Otimização para o Treinamento das RNAs

Os algoritmos de otimização utilizados no processo de treinamento de uma RNA buscam, a cada etapa, atualizar pesos e bias de todos os neurônios através dos erros.

3.1.3.1 Gradiente Descendente Estocástico

Dentre as classes de algoritmos de otimização, estão os algoritmos de primeira ordem, os quais requerem o cálculo das derivadas parciais (também chamadas de gradiente) da função objetivo a ser otimizada. Exemplos incluem: Gradiente Descendente, Gradiente Descendente Conjugado e Gradiente Descendente Estocástico. Neste último, é escolhido uma instância aleatória no conjunto de treinamento em cada etapa (época) e calcula os gradientes baseado apenas nesta única instância. Conseqüentemente, isso implica em um algoritmo muito mais rápido, pois tem poucos dados para manipular em cada iteração. Essa característica permite a aplicação, em RNAs, para grandes conjuntos de dados e treinamentos, uma vez que apenas uma instância precisa estar na memória a cada iteração (GERON, 2019). É fato que para chegar mais próximo do mínimo, será necessária uma grande quantidade de iterações, contudo, o tempo da iteração será consideravelmente curto, e o aprendizado mais rápido (BOTTOU, 2010).

A regra de aprendizagem do Gradiente Descendente, precursor do Gradiente Descendente Estocástico, é dada pela Equação (4) (ERNST, 2014). Seja $Q(w)$ denote a função de erro associada a uma RNA com pesos de conexão w . Como dito anteriormente, cada iteração é dado um passo a direção correspondente a $\nabla Q(w)$.

$$w := w - \eta \nabla Q(w) \quad (4)$$

em que, η é um parâmetro constante chamado de taxa de aprendizagem. Considerando a possibilidade de receber um conjunto de n observações x_i, t_i , onde $i = 1, 2, \dots, n$. Cada observação consiste em x entradas na rede e respectivas saídas t . Um caso particular da descida de gradiente pode ser formulado para uma função de erro da seguinte forma:

$$Q(w) = \sum_{i=1}^n Q_i(w) \quad (5)$$

onde $Q_i(w)$ é o erro correspondente à i -ésima observação. Neste caso, a regra de aprendizagem torne-se:

$$w^{(i+1)} := w^{(i)} - \eta \sum_{i=1}^n Q_i(w) \quad (6)$$

A descida de gradiente estocástica, elimina a expectativa da atualização total da rede e calcula o gradiente dos parâmetros usando apenas um exemplo do treinamento a cada etapa, tomando o como base o conjunto de treinamento em pares (x, t) . Dessa forma, a regra de aprendizagem de cada etapa se torna:

$$w^{(i+1)} := w^{(i)} - \eta \nabla Q(w; x, t) \quad (7)$$

O treinamento de uma RNA baseia-se em um conjunto de pares de dados (x, t) , sendo x entradas alimentadas da rede na camada entrada, e t as saídas esperadas.

3.1.3.2 Adam

O algoritmo *Adaptive Moment Estimation*, ou simplesmente Adam, proposto por Kingma e Ba (2017), é um método de otimização de funções objetivo estocásticas a partir de gradientes de primeira ordem. Diferentemente do Gradiente Descendente Estocástico, que mantém uma única taxa de aprendizagem para todas as atualizações dos pesos (parâmetros) durante o treinamento, Adam possui uma taxa de aprendizado específica para cada peso de rede e separadamente adaptada à medida que o aprendizado se desdobra.

Adam concatena as vantagens de duas outras extensões de descida de gradiente estocástico, mais especificamente: *Adaptive Gradient Algorithm* (AdaGrad), e mantém uma taxa de aprendizagem por parâmetro que melhora o desempenho em problemas com gradientes esparsos e, *Root Mean Square Propagation* (RMSProp), que também mantém taxas de aprendizagem por parâmetro que são adaptadas com base na média das magnitudes recentes dos gradientes para o peso (por exemplo, quão rapidamente ele está mudando) (KINGMA; BA, 2017).

O algoritmo utiliza uma atualização de parâmetros semelhante a RMSProp, mas com um termo de *momentum* adicionado. Esse algoritmo mantém uma média móvel de elementos dos gradientes dos parâmetros e seus valores quadrados conforme as Equações (8) e (9).

$$m^{(i)} = \beta_1 \cdot m^{(i-1)} + (1 - \beta_1) \cdot \nabla J(W(i)) \quad (8)$$

$$v^{(i)} = \beta_2 \cdot v^{(i-1)} + (1 - \beta_2) \cdot [\nabla J(W(i))]^2 \quad (9)$$

onde $m^{(i)}$ é o vetor das médias dos gradientes no tempo i , $v^{(i)}$ é o vetor das médias dos quadrados dos gradientes no tempo i , $\nabla J(W(i))$ é o gradiente da função de custo, β_1 é o peso atribuído à média dos gradientes e β_2 é o peso atribuído à média dos quadrados dos gradientes.

No entanto, esses valores de $m^{(i)}$ e $v^{(i)}$ são enviesados e tendem a mover a solução em direção ao zero, principalmente no início e quando os valores de β_1 e β_2 são próximos de 1. A razão para isso é que os passos iniciais tendem a direcionar $m^{(i)}$ e $v^{(i)}$ para $m^{(i-1)}$ e $v^{(i-1)}$ (inicialmente nulos) devido aos altos valores de β_1 e β_2 . Isso torna o crescimento de $m^{(i)}$ e $v^{(i)}$ lento. Para evitar isso, esses valores são corrigidos de acordo com as Equações (10) e (11).

$$\widehat{m}^{(i)} = \frac{m^{(i)}}{1 - \beta_1^i} \quad (10)$$

$$\widehat{v}^{(i)} = \frac{v^{(i)}}{1 - \beta_2^i} \quad (11)$$

onde: $\widehat{m}^{(i)}$ e $\widehat{v}^{(i)}$ são, respectivamente, o vetor corrigido das médias dos gradientes e o vetor corrigido das médias dos quadrados dos gradientes, respectivamente, e β_1^i e β_2^i , significa o peso elevado ao número de épocas. A atualização dos pesos da RNA segue a fórmula:

$$w^{(i+1)} = w^{(i)} - \frac{\eta}{\sqrt{\widehat{v}^{(i)} + \varepsilon}} \cdot \widehat{m} \quad (12)$$

3.2 Seleção de Atributos

Nesta seção aborda-se diferentes técnicas de seleção de atributos, também conhecidas como seleção de variáveis em RNAs. Os métodos de seleção de atributos destinam-se a reduzir o número de variáveis de entrada para aquelas que se acredita serem mais úteis a um modelo, a fim de prever a variável alvo com maior precisão. Muitos modelos de RNAs, especialmente aqueles baseados em regressão, estimarão parâmetros para cada entrada no modelo. Devido a isto, a presença de variáveis que não são relevantes pode acrescentar incertezas às previsões e reduzir a eficácia global do modelo (KUNH, 2013).

Quando se pensa em seletores de atributos são, em termos de métodos supervisionados e não supervisionados. A distinção surge quando os atributos são selecionados com base na variável alvo ou não. Técnicas de seleção de atributos não supervisionadas ignoram a variável alvo, seja por opção ou inexistência, como métodos que removem variáveis redundantes usando correlação. De outro modo, técnicas de seleção de atributos supervisionadas utilizam a variável alvo, como métodos baseados em filtros, *wrappers* ou *intrínsecos* (KUNH, 2013). A Figura 5 exibe uma visão geral dessas técnicas.

Neste trabalho opta-se pela utilização de seletores de atributos que se enquadram nos supervisionados, uma vez que a variável alvo é existente. Outrossim, em aprendizado de máquinas, métodos supervisionados tendem possuir uma performance superior comparado aos não supervisionados, uma vez que esse último busca identificar grupos ou padrões a partir dos conjuntos de dados, sem que haja um objetivo específico a ser alcançado.

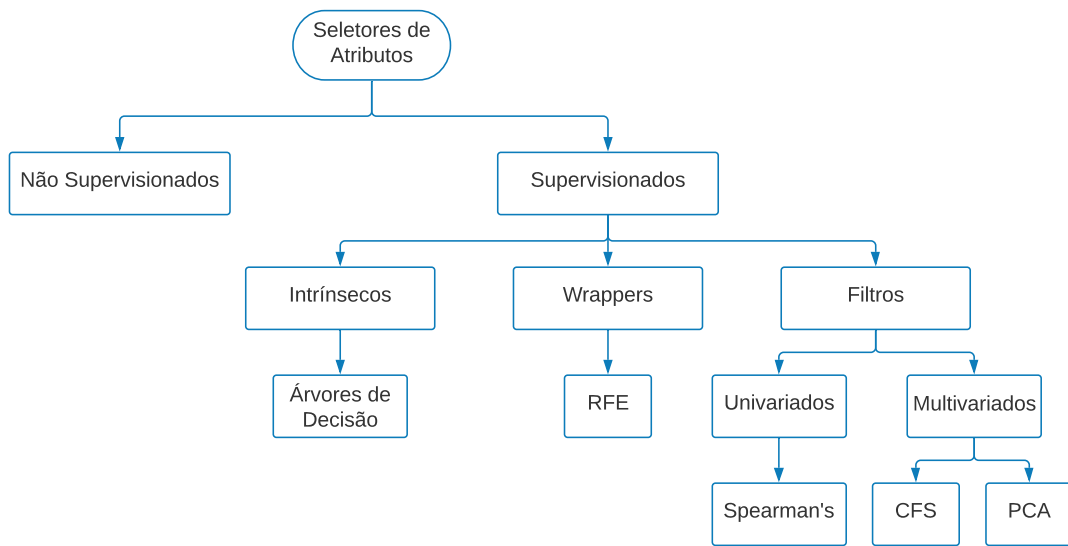


Figura 5 – Visão geral das técnicas de seleção de atributos.

Os algoritmos *wrappers* funcionam avaliando um subconjunto de atributos usando um algoritmo de aprendizado de máquina que emprega uma estratégia de pesquisa para olhar através do espaço de possíveis subconjuntos de atributos, avaliando cada subconjunto com base na qualidade do desempenho de um determinado algoritmo (KUHN, 2013).

Os algoritmos de seleção de atributos baseados em filtros utilizam técnicas estatísticas para avaliar a relação entre cada variável de entrada e variável alvo e, apresentando uma determinada pontuação. Essas pontuações são usadas como base para escolher (filtrar) as variáveis de entrada que serão utilizadas no modelo de RNA (KUHN, 2013). Existem dois tipos de métodos em filtros, univariados, que avaliam e classificam um único atributo de acordo com determinados critérios, e multivariados, que por sua vez avaliam todo o espaço de atributos levando em conta atributos em relação aos outros no conjunto de dado.

Outrossim, existem alguns algoritmos de aprendizado de máquina que realizam a seleção de atributos automaticamente como parte do aprendizado do próprio modelo. O que significa dizer que o modelo incluirá apenas preditores que ajudam a maximizar a precisão. Nesses casos, o modelo pode escolher qual representação dos dados é melhor (KUHN, 2013). Desta forma, podemos nos referir a essas técnicas como métodos intrínsecos de seleção de atributos.

Por fim, existem métodos que selecionam atributos de forma estocástica. Esses métodos utilizam das RNAs já treinadas, extraem os valores contidos em cada peso de conexão de cada neurônio da rede, calculam, baseados em suas respectivas metodologias, e apresentam um ranqueamento de correlação determinando a importância das variáveis de entrada. Esse processo é repetido n vezes com a finalidade de se apurar, estatisticamente, quais entradas são as de maior relevância. Dentre os mais conhecidos algoritmos contidos nesse conjunto, destacam-se dois: o algoritmo de Garson (GARSON, 1991) e o

algoritmo de Olden (OLDEN; JOY; DEATH, 2004). Esses algoritmos se enquadram em estocásticos pelo simples fato da aleatoriedade contida em cada peso de conexão existente para cada nova execução de uma RNA.

3.2.1 Recursive Feature Elimination

O algoritmo *Recursive Feature Elimination (RFE)* pertence ao conjunto de técnicas *wrappers* que utilizam o processo de aprendizagem de máquina para encontrar um subconjunto de atributos ideais r existente no conjunto total de atributos n , onde $r < n$ (BLUM; LANGLEY, 1997; KOHAVI; JOHN, 1997). Existe a impraticabilidade de avaliar todos os subconjuntos de atributos possíveis quando a dimensão dos dados é exacerbadamente grande. Perante a isso, a abordagem *wrapper* consiste em utilizar estratégias gananciosas de busca, como algoritmos *forward* ou *backward* (GREGORUTTI; MICHEL; SAINT-PIERRE, 2016).

Existem distintos algoritmos RFE, dentre eles, proposto primeiramente por Guyon et al. (2002), o *Recursive Feature Elimination - Support Vector Machine (RFE-SVM)* sendo um método eficiente de seleção de atributos em que classifica recursivamente as amostras com a utilização da *Support Vector Machine (SVM)*. Fundamentalmente, o algoritmo inicia com todos os atributos e remove, a cada iteração, um atributo usando os coeficientes do vetor de peso w como critério de classificação (GUO; ZHANG; TANG, 2021). A pontuação dada pelos componentes do vetor de peso w da SVM, pode ser expressa da seguinte forma:

$$w = \sum_k \alpha_k y_k x_k \quad (13)$$

onde $y_k \in \mathcal{L}$ é o rótulo de classe da amostra x_k e o somatório é retirado em todas as iterações e, α_k representa os multiplicadores de Lagrange envolvidos na maximização da margem de separação das classes da SVM.

3.2.2 Correlation-based Feature Selection

Correlation-based Feature Selection (CFS) é um algoritmo de seleção de atributos que classifica subconjuntos de características de acordo com uma função de avaliação heurística baseada em correlação (Mark A. Hall, 1999). A função avalia subconjuntos que contêm vetores de atributos, que estão correlacionados com a variável alvo, mas independentes uns dos outros. O método CFS assume que características irrelevantes mostram uma baixa correlação com a variável alvo e, portanto, devem ser ignoradas pelo algoritmo. Por outro lado, o excesso de atributos deve ser examinado, pois geralmente estão fortemente correlacionados com um ou mais dos outros atributos (WOSIAK; ZAKRZEWSKA, 2018).

O critério utilizado para avaliar um subconjunto de atributos pode ser expresso da seguinte forma:

$$M_s = \frac{k\overline{r_{cf}}}{\sqrt{k + k(k-1)\overline{r_{ff}}}} \quad (14)$$

onde M_s é a importância heurística de um subconjunto de atributos S contendo k variáveis, $\overline{r_{cf}}$ é o valor médio de correlação entre variáveis de entrada e variável alvo, e $\overline{r_{ff}}$ é a correlação média entre duas variáveis. É importante destacar que existem diferentes variações de CFS que empregam diferentes medidas de qualidade ($\overline{r_{cf}}$ e $\overline{r_{ff}}$) entre atributos: *Correlation-based Feature Selection - Symmetrical Uncertainty (CFS-UC)* que utiliza a incerteza simétrica para medir as correlações de atributos (ISERLES, 1989); *Correlation-based Feature Selection - Minimum Description Length (CFS-MDL)* que utiliza comprimento mínimo de descrição simétrico normalizado para medir as correlações de atributos (RISSANEN, 1978) e; *Correlation-based Feature Selection - Relief (CFS-Relief)* que utiliza *relief* simétrico para medir as correlações de atributos (KIRA; RENDELL, 1992).

A implementação do CFS permite ao usuário escolher entre três estratégias de busca heurística: seleção *forward*, eliminação *backward*, e *best first*. A seleção *forward* começa sem atributos e adiciona, gananciosamente, um atributo de cada vez até que não se possa adicionar um único atributo que resulte em uma pontuação superior a já existente. De outro modo, a eliminação *backward* começa com o conjunto completo de atributos e remove avidamente um atributo de cada vez, desde que a pontuação não se degrade. Por fim, a estratégia *best first* pode começar sem qualquer atributo ou com todos os atributos. Em primeiro, a procura avança através do espaço de buscas adicionando atributos; posteriormente, a procura retrocede pelo espaço de buscas, eliminando atributos (Mark A. Hall, 1999).

3.2.3 Spearman's Rank Correlation Coefficient

Spearman's rank correlation coefficient ou simplesmente ρ de Spearman's, em referência a Charles Spearman (SPEARMAN, 1904), é um coeficiente não paramétrico que calcula a relação entre duas variáveis, podendo essas serem lineares ou não lineares, contínuas ou discretas. Tal coeficiente possui um *range* que varia de -1 a 1 , medindo monotonicamente relações crescentes ou decrescentes em que, um valor de 1 em ρ significa uma associação de classificação perfeita positiva, um valor de 0 em ρ significa que não há qualquer associação, e, um valor de -1 em ρ significa uma associação negativa perfeita entre os intervalos (DENIS, 2021). Ou seja, Se o valor de ρ se aproxima de 0 , a associação entre os dois intervalos é mais fraca. Matematicamente ρ de Spearman's pode ser escrito como:

$$\rho = 1 - \frac{6 \cdot D}{N^3 - N} \quad (15)$$

onde ρ indica o coeficiente de correlação de Spearman's; N representa o número das observações e D configura a diferença entre os dois postos de cada observação, expressa da seguinte forma:

$$D = \sum_{i=1}^N (R_i - S_i)^2 \quad (16)$$

em que R_i é o posto de x_i entre os outros x 's e S_i é o posto de y_i entre os outros y 's.

3.3 Aproximações Funcionais

Na teoria matemática de RNA, o teorema da aproximação universal, formulado por Cybenko (1989) apenas para ativações sigmoide e comprovado por Hornik (1991) para todas as funções de ativação, declara que uma RNA *multi-layer perceptron* pré-alimentada com uma única camada oculta que contém um número finito de neurônios pode aproximar funções contínuas em subconjuntos compactos de \mathbb{R}^n , com pressupostos mínimos de função de ativação. O teorema afirma que RNAs simples podem representar uma grande variedade de funções quando há os parâmetros adequados, no entanto, ele não desenvolve a apreensibilidade algorítmica dos mesmos (HAYKIN, 2008).

Uma abordagem alternativa apresentada por (GUTIERREZ-MARTINEZ et al., 2011), em que se utiliza a função diferenciável extraída da RNA e se insere no conjunto de restrições de segurança/estabilidade na modelagem para resolver o problema de FPO-REST demonstra ser possível a utilização de uma função aproximada por RNA em um modelo matemático. Desta forma, um limite de segurança é imposto para o SEE até que os limites de estabilidade sejam atingidos para um ponto de máximo carregamento possível para o SEE, para múltiplos e realistas padrões de despacho de geração. O objetivo principal da utilização de uma RNA é, então, aproximar esse limite para cada padrão de despacho, e uma função diferenciável que fornece um mapeamento entre as variáveis de carregamento e o status de segurança do sistema, criado para cada padrão de geração considerado.

Diante a arquitetura e topologia de RNA proposta neste trabalho, e das Equações (1) e (2) a função matemática da RNA pode ser reescrita da seguinte forma:

$$F(x, w, b) = \varphi \left(\sum_k w_{ok} \cdot \varphi \left(\sum_i w_{ki} \cdot x_i + b_k \right) + b_o \right) - \xi \quad (17)$$

onde $\varphi(\cdot)$ é uma função de ativação diferenciável; w_{ok} é o peso sináptico entre o neurônio k da camada oculta e o neurônio único da camada de saída o ; x_i é o i -ésimo elemento do vetor de entrada x , b representa o *bias* do neurônio artificial e; ξ é o erro máximo absoluto da aproximação funcional.

Capítulo 4

Modelagem do Problema de FPO-REST

4.1 Formulação Genérica de FPO-RS

Um dos objetivos de um FPO-RS é determinar o conjunto dos valores ótimos dos controles de um SEE de forma que as restrições operacionais sejam satisfeitas nos períodos pré e pós-contingência(s). O problema de FPO-RS pode ser formulado como um problema de Programação Não Linear Inteira Mista (PNLIM), não convexo, restrito, de grande porte (CAPITANESCU et al., 2011). Esse problema pode ser representado matematicamente na seguinte forma compacta (MONTICELLI; PEREIRA; GRANVILLE, 1987; CAPITANESCU et al., 2011).

$$\min_{u_0, \dots, u_n} f_0(x_0, u_0) \quad (18a)$$

$$\text{sujeito a: } g_0(x_0, u_0) = 0 \quad (18b)$$

$$h_0(x_0, u_0) \leq L_{\text{pré}} \quad (18c)$$

$$g_k^s(x_k^s, u_0) = 0, \quad k = 1, \dots, n \quad (18d)$$

$$h_k^s(x_k^s, u_0) \leq L_s, \quad k = 1, \dots, n \quad (18e)$$

$$g_k(x_k, u_k) = 0, \quad k = 1, \dots, n \quad (18f)$$

$$h_k(x_k, u_k) \leq L_{\text{pós}}, \quad k = 1, \dots, n \quad (18g)$$

$$\|u_k - u_0\| \leq \overline{\Delta u_k}, \quad k = 1, \dots, n \quad (18h)$$

em que f_0 é a função objetivo que representa um determinado desempenho operacional do SEE; k é o índice que representa diferentes configurações topológicas do sistema ($k = 0$ corresponde ao período pré-contingência, enquanto $k = 1, \dots, n$ corresponde às n configurações contingenciais); x_k é o vetor das variáveis de estado do sistema (i.e., magnitudes e ângulos de fase das tensões nas barras); x_k^s é o vetor das variáveis de estado calculadas

para o curto intervalo de tempo contingencial (antes que o operador ajuste as variáveis de controle do sistema após a eliminação de uma falta, ou seja, antes do redespacho ativo e/ou reativo); u_k é o vetor das variáveis de controle do sistema (i.e., injeções de potência ativa, magnitude de tensão nos terminais dos geradores, *taps* dos transformadores em-fase, susceptância equivalente dos elementos *shunt*, ângulo de defasamento dos transformadores defasadores, estado dos disjuntores e chaves); $\overline{\Delta u_k}$ é o vetor dos máximos ajustes nas variáveis de controle entre o caso base ($k = 0$) e o estado de pós-contingência k . Por fim, $L_{\text{pré}}$, L_s e $L_{\text{pós}}$ representam, respectivamente, os limites técnico-operacionais nos períodos pré, contingencial e pós-contingência(s) – esses limites são definidos de forma que $L_{\text{pré}} \leq L_{\text{pós}} \leq L_s$.

Em (18), as ações de controle u_0 são definidas como preventivas e as ações de controle u_k , com $k = 1, \dots, n$, são definidas como corretivas, as restrições de igualdade representam, de forma geral, as equações de balanço de potência ativa e reativa nas barras do sistema. As restrições de desigualdade representam os limites técnicos (geração de potência ativa e reativa nos geradores, *taps* dos transformadores em-fase, susceptância equivalente dos elementos *shunt*) e os limites operacionais do sistema (magnitudes de tensão, corrente nos ramos etc.).

Um efeito imediato das formulações do FPO-RS é o seu porte, com um grande número de variáveis de decisão e restrições de igualdade e desigualdade. Comumente, k é considerado igual a 1, e o FPO-RS é resolvido em termos da contingência do tipo N-1 mais severa (determinada em estudos prévios ou *offline*) para um desempenho operacional do sistema. Ainda, devido à dificuldade de resolução imposta pelas variáveis de decisão inteiras e discretas, o problema de FPO-RS é, geralmente, modelado como um problema em que a natureza inteira e discreta dessas variáveis de decisão é desprezada e todas as variáveis são consideradas contínuas. Na maioria das publicações da literatura correlata, portanto, o FPO-RS é formulado como um problema de PNL.

4.2 Formulação Genérica de FPO-RET

Devido à dificuldade de representação e/ou estimação dos limites de estabilidade de tensão frente às diferentes propriedades das bifurcações sela-nó e induzidas por limites (SEYDEL, 1994; AVALOS et al., 2009), a maioria dos modelos encontrados na literatura, geralmente, consideram os limites de estabilidade de tensão em função de apenas um tipo de bifurcação (geralmente do tipo sela-nó, pois a matriz Jacobiana, associada às equações de balanço de potência ativa e reativa, é singular nesse ponto de bifurcação) ou usam diferentes aproximações para a representação dos limites de estabilidade de tensão.

Um dos objetivos de um FPO-RET é determinar o conjunto dos valores ótimos dos controles de um SEE de forma que as restrições operacionais sejam satisfeitas ao mesmo tempo que as soluções obtidas estejam dentro das margens de estabilidade desse SEE. O

problema de FPO-RET pode ser formulado como um problema de PNLIM, não convexo, restrito, de grande porte (CAPITANESCU et al., 2011). Esse problema pode ser representado matematicamente na seguinte forma compacta (KODSI; CANIZARES, 2007; AVALOS; CANIZARES; ANJOS, 2008; LAGE; COSTA; CANIZARES, 2012).

$$\begin{aligned} \min_{u_0} \quad & f_0(x_0, u_0) & (19a) \\ \text{sujeito a:} \quad & g_0(x_0, u_0) = 0 & (19b) \\ & h_0(x_0, u_0) \leq L & (19c) \\ & \sigma(x_0, u_0) \leq \sigma_c & (19d) \end{aligned}$$

onde L representa os limites técnico-operacionais do sistema, σ representa uma grandeza associada à estabilidade de tensão do SEE, que pode ser definida, ou não, em relação às variáveis de estado do SEE; e σ_c representa o limite de estabilidade de tensão do SEE. Em (19), as ações de controle u_0 são definidas como preventivas e garantem a estabilidade de tensão do SEE por meio da restrição (19d).

4.3 Formulação Genérica de FPO-REST

Por fim, um problema de FPO-REST procura determinar o conjunto dos valores ótimos dos controle de um SEE, de forma que as restrições operacionais sejam satisfeitas nos períodos pré e pós-contingência(s) ao mesmo tempo que as soluções obtidas estejam dentro das margens de estabilidade de tensão desse SEE, resultando, assim, em uma operação eficiente, segura e estável. O problema de FPO-REST pode ser formulado como um problema de PNLIM, não convexo, restrito, de grande porte (CAPITANESCU et al., 2011). De forma geral, esse problema pode ser representado matematicamente na seguinte forma compacta:

$$\begin{aligned} \min_{u_0, \dots, u_n} \quad & f_0(x_0, u_0) & (20a) \\ \text{sujeito a:} \quad & g_0(x_0, u_0) = 0 & (20b) \\ & h_0(x_0, u_0) \leq L_{\text{pré}} & (20c) \\ & g_k^s(x_k^s, u_0) = 0, & k = 1, \dots, n & (20d) \\ & h_k^s(x_k^s, u_0) \leq L_s, & k = 1, \dots, n & (20e) \\ & g_k(x_k, u_k) = 0, & k = 1, \dots, n & (20f) \\ & h_k(x_k, u_k) \leq L_{\text{pós}}, & k = 1, \dots, n & (20g) \\ & \|u_k - u_0\| \leq \overline{\Delta u_k}, & k = 1, \dots, n & (20h) \\ & \sigma(x_0, u_0) \leq \sigma_c & (20i) \end{aligned}$$

Em (20), as ações de controle u_0 são definidas como preventivas e garantem a estabilidade de tensão do SEE por meio da restrição (20i), e as ações de controle u_k , com $k = 1, \dots, n$, são definidas como corretivas.

Os desafios e as dificuldades específicos inerentes aos problemas de FPO-RS e FPO-RET estão presentes conjuntamente nos problemas de FPO-REST.

4.4 Estimação dos Limites de Estabilidade de Tensão

Devido ao aumento da demanda por energia elétrica e à capacidade limitada do sistema de transmissão de acomodar cargas adicionais mantendo, ao mesmo tempo, um perfil de tensão adequado a diferentes cenários de operação, os SEEs passaram a ser operados em uma região na qual um pequeno acréscimo de carga gera um sensível aumento das perdas reativas nas linhas de transmissão. Nesses sistemas, mesmo aqueles que operam com tensões muito próximas de 1 p.u., pequenas variações nas magnitudes das tensões pouco afetarão os suportes de reativos dos elementos *shunt* do tipo capacitivo, inclusive os de linha. Por outro lado, pequenas variações na diferença de tensão entre os extremos de uma linha de transmissão associadas a grandes diferenças angulares podem causar alterações substanciais nas perdas série de potência reativa. Na tentativa de se manter um perfil adequado de tensão, a progressiva exaustão das reservas de reativos provenientes das barras de geração tem, como consequência, a perda de controle da tensão por parte dos geradores. Isso resulta em uma queda contínua da tensão que, por sua vez, causa um sensível aumento da diferença angular entre os extremos da linha de transmissão, a fim de se manter a transmissão de potência ativa. O aumento dessa diferença angular, somado à queda de tensão e a consequente redução compulsória do suporte de reativos por parte dos elementos *shunt* do tipo capacitivo, causa um novo aumento nas “perdas” reativas das linhas de transmissão que leva o sistema a operar próximo a uma região na qual o controle de tensão não é mais possível (ALVES, 2000). Essa queda gradual e viciosa das magnitudes de tensão é o estágio inicial do colapso de tensão.

A segurança de tensão na operação de um SEE é comumente representada por limites de fluxo de potência ativa em seus ramos. Tais limites são impostos devido aos requisitos operacionais que o sistema deve atender após a ocorrência de uma perturbação, como um curto-circuito em uma linha de transmissão e seu desligamento. Os limites de fluxo de potência ativa são determinados através de estudos *offline* de análise de estabilidade dinâmica e transitória – na prática, esses limites são determinados através de estudos de análise de estabilidade dinâmica (MILANO; CANIZARES; INVERNIZZI, 2003). Devido a uma grande diversidade de cenários de operação possíveis, limites de fluxo de potência ativa podem não representar apropriadamente a segurança de tensão na operação do sistema, pois são fortemente associados aos cenários de operação para os quais foram

determinados (CANIZARES; KODSI, 2006).

IETs têm sido empregados como uma alternativa à representação da segurança de tensão de SEEs por limites de fluxo de potência ativa (CANIZARES et al., 2001). Nessas abordagens, o valor escalar de um IET é determinado por meio de uma função implícita das variáveis de estado do SEE e comparado com o valor crítico do IET associado ao ponto de colapso de tensão (KODSI; CANIZARES, 2007; AVALOS; CANIZARES; ANJOS, 2008). No entanto, a maior limitação dessas abordagens está relacionada à atribuição de valores críticos associados ao colapso de tensão para os IETs (LAGE; COSTA; CANIZARES, 2012). A estimação dos limites de estabilidade de tensão, representados por IETs, é uma tarefa difícil e que, em alguns casos, pode se tornar impraticável. Quando o colapso de tensão é associado a uma barra de geração atingindo um de seus limites de geração de potência reativa (bifurcação induzida por limite), os valores críticos de IETs baseados em propriedades da matriz Jacobiana do modelo do sistema são difíceis de ser estimados sem a resolução do problema de máximo carregamento (AJJARAPU; CHRISTY, 1991; AVALOS et al., 2009).

Para estimar os limites de estabilidade de tensão de um SEE, em (GU; CANIZARES, 2007) propôs-se a estimação das margens de carregamento de SEEs por RNAs. Essa abordagem foi empregada na representação da estabilidade de tensão em problemas de FPO em (GUTIERREZ-MARTINEZ et al., 2011). Esses dois trabalhos, no entanto, consideram que as cargas dentro de uma mesma área possuem padrões de variação iguais, o que limita a aplicação dessa abordagem. Com o objetivo de superar essa limitação, um estudo mais amplo da abordagem de estimação dos limites de estabilidade de tensão por RNAs é apresentado em (LAGE; FERNANDES; COSTA, 2013), e sua aplicação ao problema de FPO-RET é apresentada em (LAGE; FERNANDES; COSTA, 2015). Apesar de ser bastante eficaz, a abordagem de estimação dos limites de tensão de SEEs por RNA limita-se a uma aplicação para SEEs de pequeno porte, visto que o número de entradas da RNA é intimamente relacionado ao porte do SEE.

Uma abordagem alternativa para a estimação dos limites de estabilidade de tensão baseada na topologia do sistema, nos desvios de tensão entre os estados de carga mínima e atual e na demanda de potência reativa nas barras de carga do SEE é apresentada em (SIMPSON-PORCO; DÖRFLER; BULLO, 2016). São apresentados resultados considerando 11 SEEs, dentre os quais destacam-se os sistemas IEEE de 14, 30, 57, 118 e 300 barras, o sistema New England de 39 barras e o sistema polonês de 2383 barras. No entanto, esta abordagem considera apenas pontos de colapso de tensão caracterizados por bifurcações do tipo sela-nó e é baseada em análises matriciais, o que não permite a sua representação algébrica e posterior incorporação aos modelos de FPO-RET.

4.5 Formulação Genérica do FPO-REST Proposto

Após a realização de um levantamento bibliográfico acerca do tema de pesquisa deste trabalho, o modelo de FPO-REST proposto neste projeto de pesquisa consiste na evolução do modelo proposto em (LAGE; FERNANDES; COSTA, 2015) e pode ser representado matematicamente na seguinte forma compacta:

$$\min_{u_0} \quad f_0(x_0, u_0) \quad (21a)$$

$$\text{sujeito a:} \quad g_0(x_0, u_0) = 0 \quad (21b)$$

$$h_0(x_0, u_0) \leq L \quad (21c)$$

$$\sigma(x_0, u_0) \leq \sigma_c(u'_0, k) \quad (21d)$$

onde σ_c , diferentemente de (19d) e (20i), é uma função não linear e diferenciável que representa, simultaneamente, os limites de segurança de tensão do FPO-RS e estabilidade de tensão do FPO-RET do SEE. A função σ_c é caracterizada por RNAs (LAGE; FERNANDES; COSTA, 2013) com seleção de atributos (OLDEN; JOY; DEATH, 2004) para a aplicação deste modelo de FPO-REST a sistemas de maior porte, superando as deficiências desta abordagem apontadas na Subseção 4.4, e definida em termos das variáveis de controle mais significativas u'_0 para a aproximação funcional (determinadas pela seleção de atributos), tal que $u'_0 \subset u_0$, e k é o índice que representa diferentes configurações topológicas do sistema ($k = 0$ corresponde ao período pré-contingência, enquanto $k = 1, \dots, n$ corresponde às n configurações contingenciais).

Os limites de estabilidade/segurança de tensão são associados à margem de carregamento do SEE considerando bifurcações do tipo sela-nó e induzidas por limites e limites técnico-operacionais nas linhas de transmissão e são calculados por meio do modelo de otimização apresentado em (AVALOS et al., 2009). A função σ_c equivale, portanto, ao problema de máximo carregamento (AVALOS et al., 2009) e o FPO-REST (21) equivale, portanto, a um FPO-REST bi-nível.

Capítulo 5

Metodologia Proposta

Neste Capítulo, introduz-se a metodologia a ser empregada neste trabalho de pesquisa enfatizando em passos de determinação de pontos operacionais nos limites de estabilidade/segurança de tensão; e na incorporação da aproximação funcional dos limites de estabilidade/segurança de tensão ao FPO-REST. A Figura 6 esboça o fluxograma que representa a sequência geral da metodologia proposta.

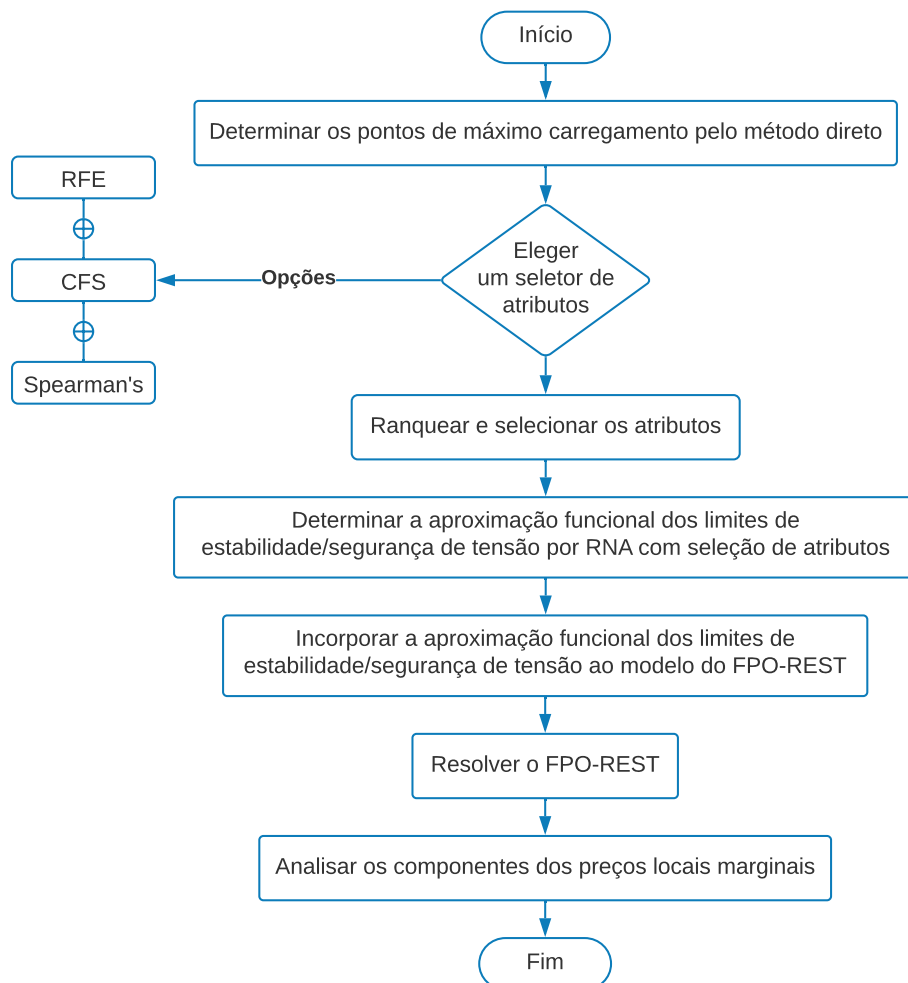


Figura 6 – Fluxograma da metodologia proposta.

5.1 Análise de Estabilidade Estática de Tensão

5.1.1 Efeitos do Aumento da Demanda

O aumento da demanda por energia elétrica, como o devido às variações diárias de carga, pode ter efeitos negativos na estabilidade do sistema. A análise dos efeitos do aumento da demanda se baseia no fato de que o excesso de potência reativa fornecida a uma barra resulta no aumento sua da magnitude de tensão, enquanto o deficit de potência reativa fornecida resulta na diminuição da magnitude de tensão dessa barra. Para isso, considere a barra k de um SEP cujas curvas características de potência reativa fornecida (Q_k^F) e potência reativa demandada (Q_k^D) são dadas na Figura 7. Caso ocorra uma pequena perturbação negativa na magnitude de tensão do ponto s , o fornecimento de potência reativa será maior que a potência reativa demandada. Esse excesso de potência reativa resulta, então, no aumento da magnitude de tensão e o ponto de operação retorna para o ponto de equilíbrio s . Caso a perturbação na magnitude de tensão do ponto s seja positiva, o fornecimento de potência reativa será menor que a demandada e essa falta de potência reativa fornecida faz com que a magnitude de tensão diminua, o que também resulta no retorno do ponto de operação para o ponto de equilíbrio s . Por esse motivo, o ponto de equilíbrio s é definido como ponto de equilíbrio estável.

Caso ocorra a mesma perturbação negativa na magnitude de tensão do ponto u , a redução nessa magnitude de tensão resulta num deficit de potência reativa fornecida, já que a potência reativa fornecida à barra é menor que demandada. Como há um deficit de potência reativa após essa perturbação, não será possível fazer com que sua magnitude de tensão aumente e que o ponto de operação retorne ao ponto de equilíbrio u . Caso a perturbação na magnitude de tensão do ponto u seja positiva, a potência reativa fornecida à barra será maior que demandada. Como há um excesso de potência reativa fornecida após essa perturbação, também não será possível fazer com que a magnitude de tensão da barra diminua e que o ponto de operação retorne ao ponto de equilíbrio u . Assim, o ponto de equilíbrio u é definido como ponto de equilíbrio instável.

À medida que a curva característica de potência reativa demandada desloca-se para cima, e/ou que a curva característica de potência reativa fornecida desloca-se para baixo, os pontos de equilíbrio s e u se aproximam, se fundem, e desaparecem. O ponto de máximo carregamento de um SEP é caracterizado pela fusão entre um ponto de equilíbrio estável e outro ponto de equilíbrio instável, onde esse sistema é operado nos limites de geração e transmissão de potência reativa e ainda existe uma solução para as equações algébricas do modelo da rede. Na ocorrência de um pequeno aumento na carga na barra k quando o sistema está no ponto de máximo carregamento, o sistema elétrico é levado ao colapso de tensão, caracterizado pelo desaparecimento dos pontos de equilíbrio. Esse pequeno aumento da carga faz com que a potência reativa demandada seja maior que a potência reativa fornecida e, em consequência disso, a magnitude de tensão dessa barra diminui.




Figura 7 – Curvas de potência reativa fornecida e potência reativa demandada.

Como há um deficit de potência reativa fornecida, essa magnitude de tensão diminui ainda mais, até o ponto em que ela cai para um valor muito baixo, caracterizando-se assim o de colapso de tensão (Avalos Munoz, Jose Rafael, 2008).

5.2 Análise de Bifurcações

A teoria de bifurcações traz conceitos e ferramentas para a classificação, estudo e fornecimento de informações qualitativas e quantitativas a respeito do comportamento de um sistema não linear próximo ao ponto de bifurcação, ou ponto de equilíbrio crítico, à medida que parâmetros do sistema variam (SEYDEL, 2009). Na análise estática de estabilidade de tensão, assume-se que os parâmetros do sistema variam lentamente de forma a poder-se assumir que o sistema move de um ponto de equilíbrio a outro por essas variações. Tem-se, então, que a análise de bifurcações é usualmente associada ao estudo dos pontos de equilíbrio de modelos de sistemas não lineares.

Nos modelos de SEEs, Bifurcações de Sela-Nó (BSNs) e alguns tipos de BILs são determinadas basicamente pelo desaparecimento das soluções das equações do modelo da rede à medida que a demanda do sistema varia lentamente; essas bifurcações determinam o ponto de máximo carregamento do sistema e são associadas à perda de estabilidade de tensão.

5.2.1 Bifurcação Sela-Nó

Essas bifurcações de codimensão 1 (parâmetro único) ocorrem quando os dois pontos de equilíbrio do modelo do sistema se fundem e “desaparecem” à medida que o parâmetro

λ aumenta, ocasionando o colapso de tensão (ver Figura 8, onde V_{C_k} , V_{G_k} representam, respectivamente, as magnitudes de tensão nas barras de carga e de geração, Q_{G_k} representa a geração de potência reativa da barra k e, λ_c representa o máximo carregamento no ponto de bifurcação). A consequência desta perda de equilíbrio é que o estado do sistema muda dinamicamente. Em particular, a “dinâmica” pode ser tal que as tensões do sistema caiam rapidamente, resultando no colapso de tensão. Como uma BSN indica o momento em que ocorre um colapso de tensão, é útil compreender esta bifurcação dos modelos de SEE a fim compreender e o evitar (CAÑIZARES, 1995).

5.2.2 Bifurcação Induzida por Limite

Essas bifurcações de codimensão 1 foram estudadas em detalhe por Dobson e Lu (1992) e sua ocorrência é muito comum em SEEs devido à exaustão das margens de geração de potência reativa. À medida que a carga de um sistema elétrico aumenta, a demanda por potência reativa, em geral, também aumenta, e os limites de geração de potência reativa por geradores e compensadores síncronos são atingidos. As BILs são ocasionadas por apenas uma variável de controle do sistema atingindo seu limite máximo ou mínimo. Desse fato resulta que as margens de estabilidade de tensão são reduzidas e que, em alguns casos, o ponto de operação deixa de existir, ocasionando o fenômeno do colapso de tensão (DOBSON et al., 2002) (ver Figuras 9 e 10).

As BILs podem ser divididas em dois subtipos de bifurcações: Bifurcação Dinâmica Induzida por Limite (BDIL), e Bifurcação Estática Induzida por Limite (BEIL). No caso de BDILs, pontos de equilíbrio do sistema continuam a existir depois que essa bifurcação acontece à medida que o parâmetro λ aumenta, como mostra a Figura 10. Por outro lado, BEILs são similares a BSNs, pois, para essas bifurcações, os dois pontos de equilíbrio do modelo do sistema se fundem e deixam de existir à medida que o parâmetro λ aumenta, como mostram as Figuras 9 e 10. Os regimes de atuação e saturação indicados nas Figuras 9 e 10 correspondem, respectivamente, aos pontos de carregamento λ do SEP que antecedem e sucedem a um limite atingido.

Em geral, os limites que ativam as BILs podem ser categorizados em três tipos básicos de limites, a saber, limites de atuação, limites de estado e limites de comutação (VENKATASUBRAMANIAN; SCHATTLER; ZABORSKY, 1995). Para o modelo de um SEP baseado nas equações do problema de FC, limites de atuação são diretamente associados à ocorrência de BILs. Esses limites se referem aos limites de certas variáveis do modelo que são definidas em função das variáveis de estado do sistema, como acontece, por exemplo, com as variáveis de geração de potência reativa por geradores e compensadores síncronos. Os limites de estado têm um efeito direto sobre as variáveis de estado e ocorrem quando um estado atinge o seu limite. O resultado na dimensão do sistema é cair por um, uma vez que a variável de estado se torna uma constante no modelo. Estes tipos de limites podem ser modelados definindo a derivada de estado igual a zero quando os limites são

alcançados. Finalmente, os limites de comutação são seguidos por ações pré-estabelecidas (por exemplo, mecanismos de retransmissão ou limitadores de proteção no sistema físico), que podem resultar numa mudança em todo o sistema e, conseqüentemente nos estados. Estes limites podem ser modelados, por exemplo, pela introdução de certas variáveis binárias que representam a lógica interna de um elemento de retransmissão (Avalos Munoz, Jose Rafael, 2008).

5.3 Determinação de Pontos de Máximo Carregamento pelo Método Direto

Para um sistema com n_B barras, com n_G barras de geração, e n_T ramos de transmissão, o modelo para a determinação do ponto de máximo carregamento (σ) associado aos limites de estabilidade e segurança de tensão pelo método direto é apresentado a seguir:

$$\max_{\sigma, K_G, V^c, \theta^c, V_a, V_b} \sigma \quad (22a)$$

$$\text{sujeito a:} \quad \Delta P_i^c(\sigma, P_S, P_D, K_G^c, V^c, \theta^c) = 0, \quad i \in \mathcal{G} \cup \mathcal{C} \quad (22b)$$

$$\Delta Q_i^c(\sigma, P_D, Q_G^c, V^c, \theta^c) = 0, \quad i \in \mathcal{C} \quad (22c)$$

$$V_{G_i}^c = V_{G_i} + V_{a_i} - V_{b_i}, \quad i \in \mathcal{G} \quad (22d)$$

$$\left(Q_{G_i}^c(V^c, \theta^c) - Q_{G_i}^{\min} \right) V_{a_i} = 0, \quad i \in \mathcal{G} \quad (22e)$$

$$\left(Q_{G_i}^{\max} - Q_{G_i}^c(V^c, \theta^c) \right) V_{b_i} = 0, \quad i \in \mathcal{G} \quad (22f)$$

$$Q_{G_i}^{\min} \leq Q_{G_i}^c(V^c, \theta^c) \leq Q_{G_i}^{\max}, \quad i \in \mathcal{G} \quad (22g)$$

$$V_i^{\min} \leq V_i^c \leq V_i^{\max}, \quad i \in \mathcal{B} \quad (22h)$$

$$I_{ij}^c(V^c, \theta^c) \leq I_{ij}^{\max}, \quad \{i, j\} \in \mathcal{L} \quad (22i)$$

$$V_{a_i} \geq 0, \quad i \in \mathcal{G} \quad (22j)$$

$$V_{b_i} \geq 0, \quad i \in \mathcal{G} \quad (22k)$$

onde o sobrescrito c é utilizado para caracterizar funções e variáveis associadas aos limites de estabilidade e segurança de tensão do sistema, isto é, o ponto de operação crítico; $P_S \in \mathbb{R}_+^{n_B}$ é o vetor de parâmetros associados aos blocos de oferta de potência ativa em por unidade (p.u.); $P_D \in \mathbb{R}_+^{n_B}$ é o vetor de parâmetros associados aos blocos de demanda de potência ativa em p.u.; $K_G^c \in \mathbb{R}$ é uma grandeza adimensional usada para modelar uma barra *slack* distribuída; $V^c \in \mathbb{R}_{++}^{n_B}$ é o vetor das magnitudes de tensão em p.u., cujos limites operacionais são dados por $V^{\min} \in \mathbb{R}_{++}^{n_B}$ e $V^{\max} \in \mathbb{R}_{++}^{n_B}$ em p.u., onde $V_G^c \subset V^c$ é o vetor das magnitudes de tensão nas barras de geração; θ^c é o vetor dos ângulos de fase de tensão em radianos (θ^c para a barra de referência angular é definido como 0 rad.); $Q_G^c : \mathbb{R}^{2n_B} \mapsto \mathbb{R}^{n_G}$ é o vetor das funções de geração de potência reativa em p.u., cujos limites são dados por $Q_G^{\min} \in \mathbb{R}^{n_G}$ e $Q_G^{\max} \in \mathbb{R}^{n_G}$ em p.u. (Q_G^c, Q_G^{\min} ,

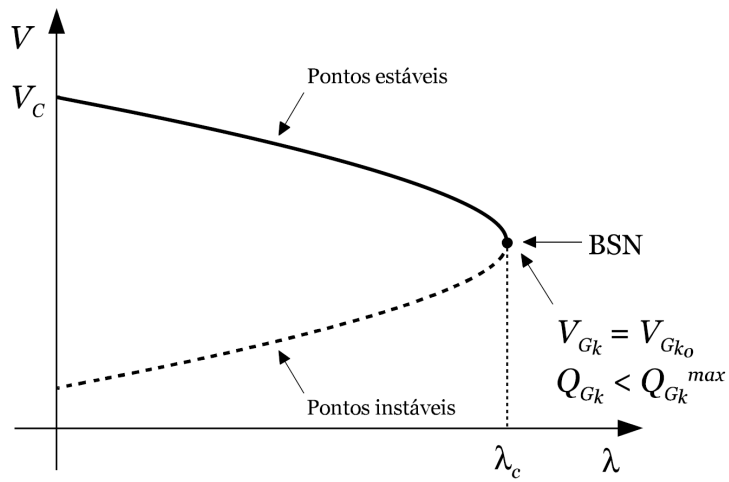


Figura 8 – BSN sem limites para Q_G .

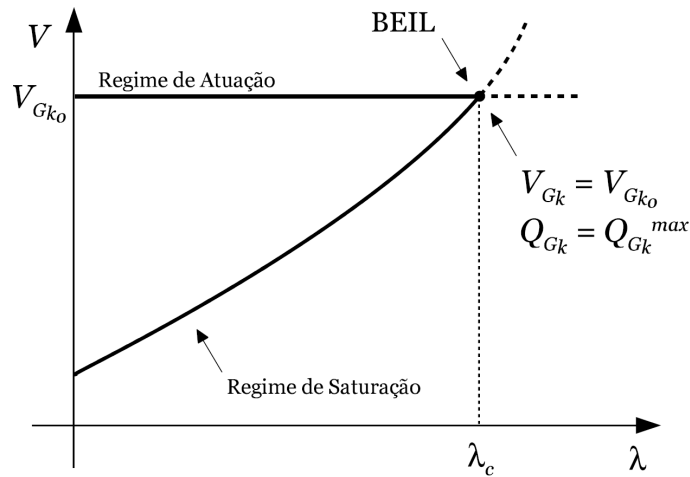


Figura 9 – Ponto de limite instável (BEIL).

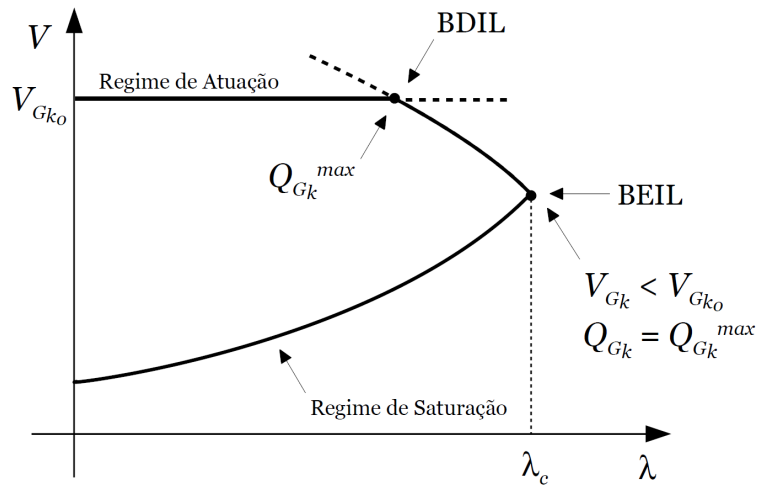


Figura 10 – BDIL seguida por uma BEIL.

e Q_G^{\max} associados a barras de carga são definidos como 0 p.u.); $V_G \in \mathbb{R}_+^{n_G}$ é o vetor de parâmetros associados às magnitudes de tensão das barras de geração definidas pelo operador do sistema; $V_a \in \mathbb{R}_+^{n_G}$ e $V_b \in \mathbb{R}_+^{n_G}$ são vetores de variáveis auxiliares estritamente não negativas utilizadas para representar, respectivamente, acréscimos ou decréscimos nas magnitudes de tensão das barras de geração sempre que os limites máximos ou mínimos de geração de potência reativa forem atingidos, caracterizando a perda do controle da magnitude de tensão nas barras de geração; $I : \mathbb{R}^{2n_B} \mapsto \mathbb{R}_+^{n_T}$ é o vetor dos módulos das correntes nos ramos de transmissão (linhas de transmissão e transformadores em-fase) em p.u., cujos limites superiores são dados por $I^{\max} \in \mathbb{R}_+^{n_T}$ em p.u. (limites térmicos); por fim, \mathcal{G} e \mathcal{C} representam, respectivamente, os conjuntos dos índices das barras de geração e de carga; \mathcal{B} representa o conjunto dos índices de todas as barras do sistema; e \mathcal{L} representa o conjunto de pares ordenados associados aos terminais dos ramos de transmissão do sistema.

Em (22b) e (22c), respectivamente, os balanços de potência ativa e reativa para as barras $i \in \mathcal{B}$, são:

$$\Delta P_i^c(\sigma, P_S, P_D, K_G^c, V^c, \theta^c) = P_{G_i}^c + P_{S_i} - (P_{L_i}^c + P_{D_i}) - \sum_{j \in \mathcal{K}} P_{ij}(V^c, \theta^c) \quad (23a)$$

$$\Delta Q_i^c(\sigma, P_D, K_G^c, V^c, \theta^c) = Q_{G_i}^c(V, \theta) - (Q_{L_i}^c + K_{L_i}^c P_{D_i}) - \sum_{j \in \mathcal{K}} Q_{ij}(V^c, \theta^c) \quad (23b)$$

onde $P_G^c \in \mathbb{R}_+^{n_B}$ representa as saídas de potências ativas de geração de geradores fixos em p.u. e, portanto, não participa da licitação de mercado; $P_L^c \in \mathbb{R}_+^{n_B}$ e $Q_L^c \in \mathbb{R}^{n_B}$ representam as cargas ativas e reativas inelásticas em p.u. que também não participam da licitação de mercado; $K_L^c \in \mathbb{R}^{n_B}$ é um vetor de parâmetros adimensionais utilizado para modelar o aumento de carga reativa em termos de P_D (geralmente mantendo o mesmo fator de potência das respectivas cargas inelásticas); \mathcal{K} é o conjunto de índices de barras conectados ao barramento $i \in \mathcal{B}$ incluindo a própria barra k ; e os fluxos de potência ativa e reativa, P_{ij} e Q_{ij} , através do ramo de transmissão $\{i, j\} \in \mathcal{L}$, são:

$$P_{ij}(V^c, \theta^c) = V_i^c V_j^c (G_{ij} \cos \theta_{ij}^c + B_{ij} \sin \theta_{ij}^c) \quad (24a)$$

$$Q_{ij}(V^c, \theta^c) = V_i^c V_j^c (G_{ij} \sin \theta_{ij}^c - B_{ij} \cos \theta_{ij}^c) \quad (24b)$$

onde G_{ij} e B_{ij} são, respectivamente, as partes real e imaginária do elemento Y_{ij} na matriz admitância da barra; e $\theta_{ij}^c = \theta_i^c - \theta_j^c$.

Por fim, a expressão da corrente I_{ij}^c , 22i, no ramo i - j é dada por:

$$\begin{aligned}
I_{ij}^c(V^c, \theta^c) = & \left\{ \frac{V_i^{c2}}{t_{ij}^2} \left[G_{ij}^2 + (B_{ij} - b_{ij}^{sh})^2 \right] - \right. \\
& 2 \frac{V_i^c V_j^c}{t_{ij}} \left[(G_{ij}^2 + B_{ij}^2 - B_{ij} b_{ij}^{sh}) \cos \theta_{ij}^c + G_{ij} b_{ij}^{sh} \sin \theta_{ij}^c \right] + \\
& \left. V_j^{c2} (G_{ij}^2 + B_{ij}^2) \right\}^{\frac{1}{2}}
\end{aligned} \tag{25}$$

5.4 FPO-REST Aplicado a Sistemas de Leilão de Energia Elétrica

A abordagem baseada em FPO-REST é, basicamente, um problema de otimização não linear e consiste em uma função objetivo que visa maximizar a função de bem-estar social, garantindo que os produtores maximizem sua renda a partir de blocos de oferta de fornecimento de energia ativa aceita, enquanto os compradores minimizam os preços pagos por seus blocos de oferta de demanda de energia ativa aceita sujeitos ao equilíbrio de energia, limites de oferta e demanda e restrições técnicas, operacionais e de estabilidade/segurança de tensão. Um modelo de mercado típico baseado em FPO pode ser representado utilizando o seguinte problema de otimização com restrições de segurança:

$$\max_{\alpha, P_S, P_D, V, \theta} \quad \sum_{i \in \mathcal{D}} C_{D_i} \alpha^{P_D} P_{D_i} - \sum_{j \in \mathcal{S}} C_{S_j} \alpha^{P_S} P_{S_j} \tag{26a}$$

$$\text{sujeito a:} \quad \Delta P_i(\alpha^{P_S}, \alpha^{P_D}, P_S, P_D, V, \theta) = 0, \quad i \in \mathcal{G} \cup \mathcal{C} \tag{26b}$$

$$\Delta Q_i(\alpha^{P_D}, P_D, V, \theta) = 0, \quad i \in \mathcal{C} \tag{26c}$$

$$\sum_{i \in \mathcal{S}} P_{S_i} = 1 \tag{26d}$$

$$\sum_{i \in \mathcal{D}} P_{D_i} = 1 \tag{26e}$$

$$P_{S_i}^{\min} \leq \alpha P_{S_i} \leq P_{S_i}^{\max}, \quad i \in \mathcal{S} \tag{26f}$$

$$P_{D_i}^{\min} \leq \alpha P_{D_i} \leq P_{D_i}^{\max}, \quad i \in \mathcal{D} \tag{26g}$$

$$Q_{G_i}^{\min} \leq Q_{G_i}(V, \theta) \leq Q_{G_i}^{\max}, \quad i \in \mathcal{G} \tag{26h}$$

$$V_i^{\min} \leq V_i \leq V_i^{\max}, \quad i \in \mathcal{B} \tag{26i}$$

$$1 \leq \sigma_c(P'_S, P'_D) \tag{26j}$$

onde $P'_S \subseteq P_S \in \mathbb{R}_+^{n_B}$ é o vetor de parâmetros associados aos blocos de oferta de potência ativa em p.u. com $P_S^{\min} \in \mathbb{R}_+^{n_B}$ e $P_S^{\max} \in \mathbb{R}_+^{n_B}$ representando, respectivamente, blocos mínimos e máximos da oferta de potência ativa em p.u.; $P'_D \subseteq P_D \in \mathbb{R}_+^{n_B}$ é o vetor de parâmetros associados aos blocos de demanda de potência ativa em p.u., com $P_D^{\min} \in \mathbb{R}_+^{n_B}$

e $P_D^{\max} \in \mathbb{R}_+^{n_B}$ representando, respectivamente, blocos mínimos e máximos da demanda de potência ativa em p.u.; $V \in \mathbb{R}_{++}^{n_B}$ é o vetor das magnitudes de tensão em p.u., cujos limites operacionais são dados por $V^{\min} \in \mathbb{R}_{++}^{n_B}$ e $V^{\max} \in \mathbb{R}_{++}^{n_B}$ em p.u.; θ é o vetor dos ângulos de fase de tensão em radianos (θ para a barra de referência angular é definido como 0 rad.); $Q_G : \mathbb{R}^{2n_B} \mapsto \mathbb{R}^{n_G}$ é o vetor das funções de geração de potência reativa em p.u., cujos limites são dados por $Q_G^{\min} \in \mathbb{R}^{n_G}$ e $Q_G^{\max} \in \mathbb{R}^{n_G}$ em p.u. (Q_G^c , Q_G^{\min} , e Q_G^{\max} associados a barras de carga são definidos como 0 p.u.); $C_D \in \mathbb{R}_+^{n_B}$ e $C_S \in \mathbb{R}_+^{n_B}$ são os vetores associados aos blocos de oferta e demanda dos preços de potência ativa em \$/MWh; α representa o vetor dos valores comum que define o padrão de aumento de geração P_S , e carga P_D ; por fim, \mathcal{S} e \mathcal{D} representam, respectivamente, os conjuntos de barras de oferta e demanda de potência ativa.

No modelo de FPO-REST aplicado a sistemas de leilão de energia elétrica, é inserido restrições técnicas e operacionais para atender um melhor desempenho da função bem-estar social. Deste modo, as restrições (26b) e (26c) representam, respectivamente, equações de balanço das potências ativas e reativa para as barras do sistema; em (26d) e (26e) representam, respectivamente, a normalização dos blocos de oferta e demanda de potência ativa; em (26f) e (26g) representam, respectivamente, os limites dos blocos de oferta e demanda de potência ativa, por fim; as restrições (26h), (26i) e (26j), representam as restrições operacionais do sistema.

Em (26b) e (26c), respectivamente, os balanços de potência ativa e reativa para as barras $i \in \mathcal{B}$, são:

$$\Delta P_i(\alpha^{P_S}, \alpha^{P_D}, P_S, P_D, V, \theta) = P_{G_i} + \alpha^{P_S} P_{S_i} - (P_{L_i} + \alpha^{P_D} P_{D_i}) - \sum_{j \in \mathcal{K}} P_{ij}(V, \theta) \quad (27a)$$

$$\Delta Q_i(\alpha^{P_D}, P_D, V, \theta) = Q_{G_i}(V, \theta) - (Q_{L_i} + K_{L_i} \alpha^{P_D} P_{D_i}) - \sum_{j \in \mathcal{K}} Q_{ij}(V, \theta) \quad (27b)$$

onde $P_G \in \mathbb{R}_+^{n_B}$ representa as saídas de potências ativas de geração de geradores fixos em p.u. e, portanto, não participa da licitação de mercado; $P_L \in \mathbb{R}_+^{n_B}$ e $Q_L \in \mathbb{R}^{n_B}$ representam as cargas ativas e reativas inelásticas em p.u. que também não participam da licitação de mercado; $K_L \in \mathbb{R}^{n_B}$ é um vetor de parâmetros adimensionais utilizado para modelar o aumento de carga reativa em termos de P_D (geralmente mantendo o mesmo fator de potência das respectivas cargas inelásticas); e os fluxos de potência ativa e reativa, P_{ij} e Q_{ij} , através do ramo de transmissão $\{i, j\} \in \mathcal{L}$, são definidos pelas Equações (24a) e (24b)

Por último, a restrição (26j) implica que o máximo carregamento do SEE, representado por σ_c , deve ser maior que 1, o que corresponde ao nível carregamento de potência ativa alocada e blocos de oferta e demanda. Em outras palavras, a restrição reforça que os blocos de oferta e demanda aceitos permitem níveis mínimos de segurança; se $\sigma_c = 1$, significa que o nível de máximo carregamento está no limite da estabilidade/segurança de tensão. No problema FPO-REST aplicado ao leilão de energia, σ_c será aproximado funcionalmente pela equação obtida da RNA devidamente treinada.

5.4.1 Análise das Componentes dos Preços Locais Marginais

Os multiplicadores de Lagrange associados às restrições de balanço de potência ativa nos modelos de mercado de energia elétrica baseados em problemas de FPO consistem em benefícios sociais marginais que podem ser interpretados como o resultado da alocação dos blocos de oferta e demanda de energia elétrica em função dos respectivos lances de venda e compra. Além de precificarem a energia elétrica em cada barramento da rede elétrica, eles são resultantes da máxima transação entre os agentes do mercado. Portanto, esses multiplicadores de Lagrange são denominados PLMs (MILANO; CANIZARES; INVERNIZZI, 2003). Assim, a função Lagrangiana associada ao problema (26) é dada por:

$$\begin{aligned}
\mathcal{L} = & \sum_{i \in \mathcal{D}} C_{D_i} \alpha^{P_D} P_{D_i} - \sum_{i \in \mathcal{S}} C_{S_i} \alpha^{P_S} P_{S_i} + \\
& \sum_{i \in \mathcal{G} \cup \mathcal{C}} \lambda_i^{\Delta P} \Delta P_i(\alpha^{P_S}, \alpha^{P_D}, P_S, P_D, V, \theta) + \\
& \sum_{i \in \mathcal{C}} \lambda_i^{\Delta Q} \Delta Q_i(\alpha^{P_D}, P_D, V, \theta) + \\
& \lambda^{\|P_S\|} \left(\sum_{i \in \mathcal{S}} P_{S_i} \right) + \lambda^{\|P_D\|} \left(\sum_{i \in \mathcal{D}} P_{D_i} \right) + \\
& \sum_{i \in \mathcal{S}} \pi_i^{P_S^{\min}} \left(\alpha^{P_S} P_{S_i} - P_{S_i}^{\min} \right) + \sum_{i \in \mathcal{S}} \pi_i^{P_S^{\max}} \left(P_{S_i}^{\max} - \alpha^{P_S} P_{S_i} \right) + \\
& \sum_{i \in \mathcal{D}} \pi_i^{P_D^{\min}} \left(\alpha^{P_D} P_{D_i} - P_{D_i}^{\min} \right) + \sum_{i \in \mathcal{D}} \pi_i^{P_D^{\max}} \left(P_{D_i}^{\max} - \alpha^{P_D} P_{D_i} \right) + \\
& \sum_{i \in \mathcal{G}} \pi_i^{Q_G^{\min}} \left[Q_{G_i}(V, \theta) - Q_{G_i}^{\min} \right] + \sum_{i \in \mathcal{G}} \pi_i^{Q_G^{\max}} \left[Q_{G_i}^{\max} - Q_{G_i}(V, \theta) \right] + \\
& \sum_{i \in \mathcal{B}} \pi_i^{V^{\min}} \left(V_i - V_i^{\min} \right) + \sum_{i \in \mathcal{B}} \pi_i^{V^{\max}} \left(V_i^{\max} - V_i \right) + \\
& \pi^\sigma \left[\sigma_c(P'_S, P'_D) - 1 \right]
\end{aligned} \tag{28}$$

A partir da função Lagrangiana (28) associada ao problema (26), os multiplicadores de Lagrange $\lambda^{\Delta P}$, que correspondem aos PLMs de todas as barras do sistema, podem ser determinados a partir da aplicação da condição necessária de otimalidade de KKT da seguinte forma:

$$\begin{aligned}
\frac{\partial \mathcal{L}}{\partial P_{S_i}} = 0 \quad \longleftrightarrow \quad & -C_{S_i} \alpha^{P_S} + \lambda_i^{\Delta P} \alpha^{P_S} + \lambda^{\|P_S\|} + \pi_i^{P_S^{\min}} \alpha^{P_S} - \\
& \pi_i^{P_S^{\max}} \alpha^{P_S} + \pi^\sigma \frac{\partial \sigma_c}{\partial P_{S_i}}(P'_S, P'_D) = 0
\end{aligned} \tag{29}$$

$$\begin{aligned}
\frac{\partial \mathcal{L}}{\partial P_{D_i}} = 0 \quad \longleftrightarrow \quad & C_{D_i} \alpha^{P_D} - \lambda_i^{\Delta P} \alpha^{P_D} - \lambda_i^{\Delta Q} K_{L_i} \alpha^{P_D} + \lambda^{\|P_D\|} + \\
& \pi_i^{P_D^{\min}} \alpha^{P_D} - \pi_i^{P_D^{\max}} \alpha^{P_D} + \pi^\sigma \frac{\partial \sigma_c}{\partial P_{D_i}}(P'_S, P'_D) = 0
\end{aligned} \tag{30}$$

Assim, os PLMs dados por $\lambda^{\Delta P}$ são, portanto, definidos como:

$$PLM_{S_i} = \lambda_i^{\Delta P} = C_{S_i} - \pi_i^{P_S^{\min}} + \pi_i^{P_S^{\max}} - \frac{1}{\alpha^{P_S}} \left[\lambda^{\|P_S\|} + \pi^\sigma \frac{\partial \sigma_c}{\partial P_{S_i}}(P'_S, P'_D) \right], \quad \forall i \in \mathcal{S} \quad (31)$$

$$PLM_{D_i} = \lambda_i^{\Delta P} = C_{D_i} - \lambda_i^{\Delta Q} K_{L_i} + \pi_i^{P_D^{\min}} - \pi_i^{P_D^{\max}} + \frac{1}{\alpha^{P_D}} \left[\lambda^{\|P_D\|} + \pi^\sigma \frac{\partial \sigma_c}{\partial P_{D_i}}(P'_S, P'_D) \right], \quad \forall i \in \mathcal{D} \quad (32)$$

Para $i \in \mathcal{S}$, o PLM da barra i é composto pelas seguintes componentes:

- C_{S_i} : preço do lance de oferta;
- $\pi_i^{P_S^{\min}}$ e $\pi_i^{P_S^{\max}}$: custos de não participação associados aos limites inferior e superior da energia ofertada, respectivamente;
- $\frac{1}{\alpha^{P_S}} \left[\lambda^{\|P_S\|} + \pi^\sigma \frac{\partial \sigma_c}{\partial P_{S_i}}(P'_S, P'_D) \right]$: custo de estabilidade/segurança de tensão.

Por outro lado, para $i \in \mathcal{D}$, o PLM da barra i é composto pelas seguintes componentes:

- C_{D_i} : preço do lance de demanda;
- $\lambda_i^{\Delta Q} K_{L_i}$: custo do acréscimo da carga reativa;
- $\pi_i^{P_D^{\min}}$ e $\pi_i^{P_D^{\max}}$: custos de não participação associados aos limites inferior e superior da energia demandada, respectivamente;
- $\frac{1}{\alpha^{P_D}} \left[\lambda^{\|P_D\|} + \pi^\sigma \frac{\partial \sigma_c}{\partial P_{D_i}}(P'_S, P'_D) \right]$: custo de estabilidade/segurança de tensão.

Capítulo 6

Resultados

Com a apresentação dos detalhes de funcionamento do método proposto, faz-se necessária a avaliação do mesmo por meio de experimentos. Portanto, neste capítulo são apresentados os resultados numéricos obtidos através da aplicação da metodologia proposta para resolução dos problemas de FPO-REST para o sistema de 6 barras (MILANO; CANIZARES; INVERNIZZI, 2003).

A metodologia proposta foi formulada usando a linguagem para modelagem de problemas matemáticos AMPL (AMPL Optimization Inc., 2021) e o problema de FPO-REST foi resolvido pelo *solver* comercial LOQO (VANDERBEI, 2006). A biblioteca Scikit-learn (PEDREGOSA et al., 2011) e o *framework* Keras (CHOLLET et al., 2015), ambos voltados para estudos e desenvolvimento de aplicações na área de aprendizagem de máquina, além de outras bibliotecas de manipulação de dados, foram selecionados para as devidas implementações das RNAs. Tais implementações foram realizadas utilizando o ambiente computacional *web*, Jupyter Notebook¹ (KLUYVER et al., 2016), através da elaboração em linguagem Python (ROSSUM; DRAKE, 2009).

O ambiente de testes utilizado para obtenção dos resultados possui as seguintes configurações: processador Intel® Core™ i5-9300H com *clock* base de 2,4 GHz e turbo de 4,1 GHz; memória ram de 8 GB DDR4 em *single channel*; SSD NVMe WDC SN520 de 512 GB; e executado no sistema operacional Windows 10 Home. Todos os testes foram efetuados com o mesmo rigor, ou seja, não houve qualquer outra aplicação sendo executada nos momentos de testes, salvo os programas nativos do sistema operacional e Jupyter Notebook.

¹ O Jupyter Notebook é uma aplicação *web*, fundamentada em navegação e de código aberto, para a criação e compartilhamento de projetos que contém linguagens interpretadas, bibliotecas e ferramentas para visualização de resultados.

6.1 Implementação Computacional e Sistema-Teste Considerado

Os resultados mostrados aqui são baseados em um sistema-teste de 6 barras que possui as seguintes características:

- 1 barra *slack*;
- 3 barras de geração (GENCO);
- 3 barras de carga (ESCO);
- 11 linhas de transmissão.

A Figura 11 ilustra a topologia desse sistema-teste de 6 barras, e as Tabelas 2 e 3 apresentam os dados de barras e de ramos do sistema de 6 barras.

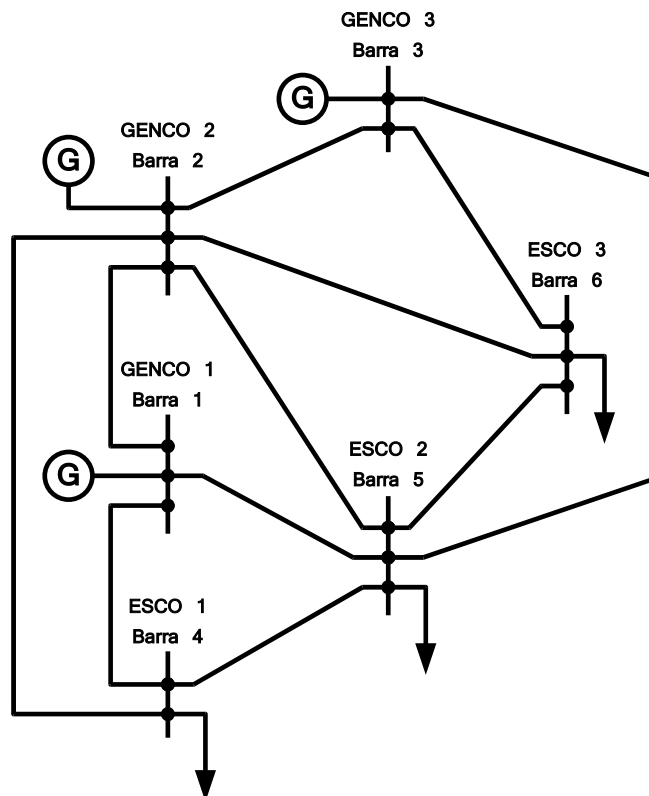


Figura 11 – Sistema-teste de 6 barras (MILANO; CANIZARES; INVERNIZZI, 2003).

Os resultados para o sistema de 6 barras foi empregado em três distintos casos testes cujo objetivo é utilizar a metodologia em possíveis e diferentes situações em que os limites de estabilidade/segurança de tensão abordadas na literatura possam ser averiguados. O ponto de máximo carregamento ou ponto crítico, pode estar associado a um limite térmico; a tensão de uma barra; a um limite de estabilidade de tensão (ponto de colapso)

Tabela 2 – Dados das Barras para o Sistema de 6 Barras

Barra {k}	V_{\min} [p.u.]	V_{\max} [p.u.]	C_S [\$/p.u.]	C_D [\$/p.u.]	P_{G_0} [p.u.]	P_{L_0} [p.u.]	Q_{L_0} [p.u.]	K_L [p.u.]	$Q_{G_{lim}}$ [p.u.]	$P_{S_{\min}}$ [\$/p.u.]	$P_{S_{\max}}$ [\$/p.u.]	$P_{D_{\min}}$ [\$/p.u.]	$P_{D_{\max}}$ [\$/p.u.]
1	0,95	1,05	9,7	-	0,9	-	-	-	$\pm 1,5$	0,00	0,20	0,00	0,00
2	0,95	1,05	8,8	-	1,4	-	-	-	$\pm 1,5$	0,00	0,25	0,00	0,00
3	0,95	1,05	7,0	-	0,6	-	-	-	$\pm 1,5$	0,00	0,20	0,00	0,00
4	0,95	1,05	-	12,0	-	0,9	0,6	0,6667	-	0,00	0,00	0,00	0,25
5	0,95	1,05	-	10,5	-	1,0	0,7	0,7000	-	0,00	0,00	0,00	0,10
6	0,95	1,05	-	9,5	-	0,9	0,6	0,6667	-	0,00	0,00	0,00	0,20

Tabela 3 – Dados dos Ramos para o Sistema de 6 Barras

De i	Para j	r_{ij} [p.u.]	x_{ij} [p.u.]	b_{ij} [p.u.]	$I_{\max_{ij}}$ [A]
1	2	0,100	0,200	0,020	37,0
1	4	0,050	0,200	0,020	113,0
1	5	0,080	0,300	0,030	122,0
2	3	0,050	0,250	0,030	46,0
2	4	0,050	0,100	0,010	200,0
2	5	0,100	0,300	0,020	103,0
2	6	0,070	0,200	0,025	132,0
3	5	0,120	0,260	0,025	95,0
3	6	0,020	0,100	0,010	200,0
4	5	0,200	0,400	0,040	26,0
5	6	0,100	0,300	0,030	29,0

correspondente a uma singularidade do sistema (BSN) ou; a limites do controle do sistema, a exemplo, limites de potência reativa do gerador (BIL). A Tabela 4 traz o resumo das classificações que ocorreram, bem como os parâmetros base empregados.

Tabela 4 – Classificação dos Limites de Estabilidade/Segurança de Tensão

	V mínima [p.u.]	V máxima [p.u.]	V base [KV]	Classificação dos limites
Caso 1	0,90	1,10	230	Limites Térmicos
Caso 2	0,85	1,12	500	BIL e Limites Térmicos
Caso 3	0,90	1,10	500	Limites de Tensão

A escolha das RNAs *multi-layer perceptron*, treinadas com algoritmos de aprendizagem *back-propagation*, dos quais, Gradiente Descendente Estocástico e Adam, foram determinadas para execução dos treinamentos em prol do sistema de 6 barras, onde as entradas utilizadas foram valores de P_S e P_D , em contrapartida, a variável alvo selecionada foram os pontos de máximo carregamento do sistema, σ . Esses dados, por sua vez, foram obtidos através de uma implementação das Equações (22), mencionadas no Capítulo 5, e sua execução se deu pelo *software* de modelagem matemática AMPL e o problema resolvido pelo *solver* LOQO (VANDERBEI, 2006).

Para as execuções das RNAs foram utilizadas algumas configurações visando o melhor desempenho possível, sendo umas delas, o critério de parada. Assumindo que o objetivo de um treinamento com RNA é de minimização da perda, a métrica a ser monitorada denota-

se “*loss*”, em modalidade “*min*”. Durante o *loop* de treinamento, verifica-se ao final de cada época se a perda está ou não diminuindo. Uma vez que o valor de perda não esteja mais decrescendo, o treinamento se encerra preservando, assim, um bom treinamento e evitando problemas de *overfitting*. Outro critério utilizado foi o limite de épocas de treinamento, por sua vez configurado em 1000.

A divisão dos conjuntos de dados para o treinamento e validação foi, respectivamente, 70% e 30%, através da função “*train_test_split*” no qual, os dados foram selecionados de forma randômica e fixa através da função “*random_state*”, ambas utilizadas através da biblioteca Scikit-learn. Essa função define uma “semente” para o gerador aleatório, para que as divisões de treinamento e validação sejam sempre determinísticas. Caso não haja uma “semente”, o resultado das execuções das RNAs será diferente a cada vez. Em outras palavras, o estado aleatório garante que as divisões geradas sejam reproduzíveis, garantindo que os números aleatórios sejam gerados na mesma ordem.

6.2 Estimação dos Limites de Estabilidade e Segurança de Tensão por Redes Neurais Artificiais com Seleção de Atributos

O problema de máximo carregamento do sistema de 6 barras baseado em FPO-REST foi efetivado com a utilização da linguagem de modelagem algébrica AMPL (AMPL Optimization Inc., 2021) e resolvido pelo *solver* LOQO (VANDERBEI, 2006) para 11.881 diferentes padrões de aumento de geração e carga. Esses padrões foram determinados combinando “todas” as possíveis direções de aumento de carga, P_D , com “todas” possíveis direções de aumento de geração, P_S . Para determinar os conjuntos de “todas” direções possíveis de aumento de carga P_{D_k} com $k \in \mathcal{L}$, foi definido como 1, enquanto P_{D_i} , $\forall i \in \mathcal{L} \mid i \neq k$, variando de 0 a 0,9 em etapas de 0,18. Após esse procedimento ter sido realizado para todos os $k \in \mathcal{L}$, todos os parâmetros de P_D foram definidos iguais a 1. Subsequente, o mesmo foi realizado para determinar os conjuntos de “todas” as direções possíveis de aumento de geração. Com os conjuntos de P_D e P_S determinados, os mesmos foram normalizados de modo que um aumento de 1 p.u. de carga seria correspondente a um aumento igual de geração. Por fim, os padrões de carga e aumento de geração foram determinados pela combinação de cada conjunto de P_D com todos os conjuntos de P_S .

Os pontos de máximo carregamento para esses padrões de geração e carga são ilustrados pelas Figuras 12, 13 e 14 e representam, respectivamente, Limites Térmicos, BIL e Limites Térmicos e, Limites de Tensão mencionados na Seção 6.1.




Figura 12 – Todas direções de aumento de geração e carga para Limites Térmicos.

A segunda etapa da metodologia proposta é eleger um dos seletores de atributos apresentados no Capítulo 3 e, logo após, realizar o ranqueamento dos atributos. Para obtenção dos resultados pelos seletores de atributos RFE e CFS, utilizou-se do *software* de código aberto, Weka 3 (WITTEN, 2017), que possui uma coleção de algoritmos de aprendizado de máquina para tarefas de mineração de dados. De outra forma, para a extração dos resultados através do seletor de atributos *Spearman's rank correlation coefficient*, se fez a aplicação pelo *software* Past 4 (HAMMER, 2021), sendo de código aberto para análise de dados científicos, com funções para manipulação de dados, plotagem, estatística univariada e multivariada, entre outras.

A Tabela 5 resume os resultados obtidos em ordem decrescente de importância, os atributos de entrada em relação à variável alvo. Diante desses resultados, são apresentados pelas Tabelas 6, 7 e 8, a resposta obtida por diversas formas. Sendo assim, pôde-se aferir qual configuração e topologia obteve a maior precisão, perante as estimativas dos seletores de atributos: RFE, CFS e *Spearman's rank correlation coefficient*.

A forma de identificar qual seletor de atributos obteve maior êxito perante seu ranqueamento é através de diversos testes, para diferentes topologias e em diferentes configurações. Diante disso, a Equação (33) calcula e determina qual a quantidade de neurônios




Figura 13 – Todas direções de aumento de geração e carga para BIL e Limites Térmicos.




Figura 14 – Todas direções de aumento de geração e carga para o Limites de Tensão.

que estarão contidos na camada escondida, alterando-se assim, as topologias.

$$\lceil N_n \rceil = N_e + (N_e + P) \quad (33)$$

onde $\lceil . \rceil$ é a função *ceil* que, por vez, tem o objetivo de arredondar qualquer número real para o inteiro superior imediato; N_n refere-se ao número de nerônios; N_e retrata o número de entradas, em que será variável de acordo com o tamanho do sistema-teste e, por fim, P indica valores de percentuais a serem incrementados, dos quais são: 0%, $\pm 25\%$, $\pm 50\%$. Ou seja, para o sistema-teste de 6 barras, a quantidade de neurônios na camada escondida irá variar entre 3 e 9. Dessa forma, constitui-se 5 distintas topologias.

Tabela 5 – Ranqueamento dos Atributos para o Sistema-Teste de 6 Barras

Caso	Seletor de atributos	Ranqueamento
1 - Limites Térmicos	RFE	$P_{S_1}, P_{S_2}, P_{D_5}, P_{D_4}, P_{S_3}, P_{D_6}$
	CFS	$P_{S_1}, P_{S_2}, P_{D_4}, P_{S_3}, P_{D_5}, P_{D_6}$
	Spearman's	$P_{S_1}, P_{D_5}, P_{D_4}, P_{S_2}, P_{S_3}, P_{D_6}$
2 - BIL e Limites Térmicos	RFE	$P_{D_6}, P_{D_5}, P_{S_2}, P_{S_3}, P_{D_4}, P_{S_1}$
	CFS	$P_{D_6}, P_{D_5}, P_{S_2}, P_{S_1}, P_{D_4}, P_{S_3}$
	Spearman's	$P_{D_6}, P_{D_5}, P_{D_4}, P_{S_3}, P_{S_2}, P_{S_1}$
3 - Limites de Tensão	RFE	$P_{D_4}, P_{D_5}, P_{S_2}, P_{D_6}, P_{S_3}, P_{S_1}$
	CFS	$P_{D_4}, P_{S_2}, P_{D_6}, P_{S_1}, P_{S_3}, P_{D_5}$
	Spearman's	$P_{D_4}, P_{D_6}, P_{D_5}, P_{S_2}, P_{S_3}, P_{S_1}$

Analisando as Tabelas 6, 7 e 8 podemos verificar qual configuração e topologia, de acordo com cada seletor de atributo, obteve melhores resultados. Para o Caso 1, limites térmicos, os seletores de atributos CFS e RFE, indicaram os atributos P_{S_3} e P_{D_6} como sendo os de menor correção entrada-saída e obtiveram o menor erro EQM de 2.05×10^{-4} . A RNA em questão possui o algoritmo de treinamento Adam e as funções de ativação contidas na camada oculta é a ReLu, e sua topologia é a quinta, logo, possuindo 9 neurônios em sua camada intermediária.

Para o segundo Caso abordado, BIL e limites térmicos, o seletor de atributo CFS foi o que obteve o melhor desempenho em comparação aos demais. O erro EQM de 2.74×10^{-5} foi obtido quando se retirou os atributos P_{S_1} e P_{D_4} , onde a RNA está utilizando o algoritmo de treinamento Adam e as funções de ativação ReLu, a RNA em questão possui 9 neurônios em sua camada intermediária, portanto está localizada na quinta topologia.

Por fim, o Caso 3 que classifica-se como limites de tensão, também ranqueado pelos seletores de atributos vistos anteriormente, obteve um erro EQM de 5.32×10^{-6} quando retirou-se os atributos P_{S_3} e P_{D_5} , por sua vez indicado pelo seletor RFE. O algoritmo de treinamento e as funções de ativação para o Caso em questão foram, respectivamente, Adam e Sigmoid. Essa RNA em questão possui 6 neurônios em sua camada oculta, portanto, pertence a topologia de número 3.

Tabela 6 – Limites Térmicos com Seleção de Atributos (Caso 1)

Topologia	Configuração	Com todos atributos		Sem P_{D_6}		Sem P_{S_3} e P_{D_6}		Sem P_{D_5} e P_{D_6}	
		Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]
1	SGD e Sigmoide	2,40E-03	11,32	2,40E-03	23,47	2,49E-03	25,02	2,57E-03	14,18
	SGD e Tanh	9,04E-04	64,61	9,81E-04	82,61	2,12E-03	16,76	2,34E-03	4,78
	SGD e ReLu	9,44E-04	52,25	2,46E-03	8,48	5,39E-04	102,92	1,80E-03	58,25
	Adam e Sigmoide	4,81E-04	13,98	5,22E-04	19,29	6,35E-04	19,79	2,55E-03	1,77
	Adam e Tanh	4,17E-04	10,97	5,44E-04	9,93	5,88E-04	9,77	2,03E-03	6,57
	Adam e Relu	4,72E-04	4,84	4,52E-04	6,25	1,99E-03	5,55	1,94E-03	3,87
2	SGD e Sigmoide	2,36E-03	8,89	2,45E-03	8,56	2,45E-03	16,11	2,48E-03	11,52
	SGD e Tanh	5,09E-04	91,17	6,52E-04	95,79	7,37E-04	96,75	2,32E-03	4,45
	SGD e ReLu	4,13E-04	93,14	4,90E-04	74,75	5,59E-04	81,06	1,91E-03	23,81
	Adam e Sigmoide	3,77E-04	20,37	3,80E-04	19,76	2,43E-03	2,20	1,82E-03	14,36
	Adam e Tanh	3,50E-04	11,47	4,29E-04	12,48	5,08E-04	15,11	1,86E-03	9,06
	Adam e Relu	9,37E-04	3,68	9,27E-04	3,83	9,28E-04	4,25	1,94E-03	4,55
3	SGD e Sigmoide	2,50E-03	9,39	2,37E-03	12,16	2,43E-03	11,80	2,49E-03	5,63
	SGD e Tanh	5,90E-04	89,55	6,53E-04	92,22	6,35E-04	89,72	2,22E-03	6,70
	SGD e ReLu	2,39E-03	2,70	2,45E-03	10,78	3,57E-04	70,43	1,88E-03	48,00
	Adam e Sigmoide	3,17E-04	13,03	5,04E-04	13,18	5,94E-04	16,44	1,94E-03	9,41
	Adam e Tanh	3,88E-04	7,40	4,26E-04	10,16	4,50E-04	12,93	1,87E-03	7,95
	Adam e Relu	5,15E-04	4,93	3,32E-04	5,86	4,99E-04	5,30	1,97E-03	2,88
4	SGD e Sigmoide	2,37E-03	9,71	2,47E-03	13,96	2,44E-03	13,65	2,50E-03	7,66
	SGD e Tanh	6,69E-04	45,57	6,49E-04	96,12	6,58E-04	71,20	2,06E-03	26,54
	SGD e ReLu	3,62E-04	73,56	4,25E-04	35,94	2,72E-04	93,25	2,05E-03	15,56
	Adam e Sigmoide	3,50E-04	11,40	4,71E-04	14,18	4,34E-04	16,94	2,52E-03	2,08
	Adam e Tanh	2,84E-04	11,78	3,67E-04	11,81	4,19E-04	10,88	1,92E-03	5,90
	Adam e Relu	3,53E-04	4,53	4,67E-04	5,66	3,18E-04	5,90	1,80E-03	4,30
5	SGD e Sigmoide	2,42E-03	9,99	2,42E-03	10,28	2,46E-03	13,01	2,55E-03	10,79
	SGD e Tanh	5,50E-04	62,73	6,78E-04	64,84	6,31E-04	97,17	1,96E-03	22,61
	SGD e ReLu	3,59E-04	56,28	5,20E-04	65,83	3,18E-04	67,21	1,81E-03	26,44
	Adam e Sigmoide	4,17E-04	12,66	3,99E-04	17,56	2,39E-03	2,93	2,43E-03	2,52
	Adam e Tanh	2,72E-04	10,58	3,34E-04	9,95	3,97E-04	10,13	1,85E-03	4,37
	Adam e Relu	4,31E-04	4,63	3,98E-04	4,63	2,05E-04	8,70	1,93E-03	2,93

Tabela 7 – BIL e Limites Térmicos com Seleção de Atributos (Caso 2)

Topologia	Configuração	Com todos atributos		Sem P_{S_1}		Sem P_{S_3}		Sem P_{S_3} e P_{D_4}		Sem P_{S_1} e P_{D_4}		Sem P_{S_1} e P_{S_2}	
		Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]
1	SGD e Sigmoide	4,53E-05	15,72	5,21E-05	24,92	5,06E-05	21,79	4,00E-05	68,88	4,50E-05	17,38	3,69E-05	17,95
	SGD e Tanh	3,06E-05	89,74	4,45E-05	96,02	5,53E-05	87,97	3,83E-05	90,89	4,39E-05	71,56	4,12E-05	100,12
	SGD e ReLu	3,91E-05	34,82	1,71E-04	27,48	1,73E-04	8,75	1,73E-04	16,08	1,72E-04	20,19	1,74E-04	10,59
	Adam e Sigmoide	3,92E-05	4,20	5,02E-05	6,53	3,80E-05	5,96	4,10E-05	8,38	4,37E-05	5,06	4,54E-05	6,87
	Adam e Tanh	3,82E-05	8,24	4,20E-05	6,66	3,43E-05	10,26	4,01E-05	10,36	3,96E-05	9,09	3,58E-05	8,62
	Adam e Relu	3,67E-05	3,22	3,84E-05	3,90	3,74E-05	2,90	1,72E-04	4,49	3,65E-05	3,92	3,86E-05	2,19
2	SGD e Sigmoide	4,93E-05	12,82	3,98E-05	13,06	4,74E-05	23,45	3,85E-05	36,25	4,12E-05	97,20	4,16E-05	10,51
	SGD e Tanh	4,13E-05	97,55	3,64E-05	99,30	5,82E-05	97,48	4,69E-05	96,90	5,80E-05	76,94	3,85E-05	91,21
	SGD e ReLu	5,61E-05	97,22	3,83E-05	62,96	1,08E-04	58,73	3,43E-05	21,69	4,15E-05	45,88	1,75E-04	20,63
	Adam e Sigmoide	3,89E-05	7,03	4,19E-05	7,65	3,73E-05	6,90	4,00E-05	1,47	2,85E-05	7,08	3,77E-05	3,91
	Adam e Tanh	3,91E-05	6,77	3,49E-05	7,63	4,94E-05	8,76	3,93E-05	8,91	3,64E-05	8,76	3,32E-05	5,75
	Adam e Relu	4,86E-05	5,21	4,04E-05	3,60	3,84E-05	3,67	5,45E-05	5,00	3,66E-05	4,45	3,89E-05	2,69
3	SGD e Sigmoide	4,11E-05	12,04	3,81E-05	23,14	4,11E-05	24,22	3,90E-05	20,60	3,78E-05	19,27	4,14E-05	17,84
	SGD e Tanh	4,48E-05	66,53	4,18E-05	59,50	5,31E-05	96,85	5,40E-05	71,86	5,85E-05	97,12	4,43E-05	75,07
	SGD e ReLu	3,42E-05	23,49	3,49E-05	31,09	4,04E-05	55,15	3,39E-05	36,55	4,05E-05	45,87	3,70E-05	33,09
	Adam e Sigmoide	3,84E-05	6,90	3,84E-05	6,56	2,68E-05	11,88	3,04E-05	8,10	3,74E-05	3,76	2,99E-05	9,11
	Adam e Tanh	3,58E-05	7,00	3,76E-05	7,60	3,13E-05	8,63	2,80E-05	8,56	4,96E-05	8,68	3,80E-05	7,49
	Adam e Relu	3,87E-05	4,15	3,86E-05	3,75	2,38E-05	4,80	3,53E-05	5,75	3,91E-05	4,43	5,19E-05	3,95
4	SGD e Sigmoide	3,88E-05	15,19	3,89E-05	16,99	3,92E-05	18,17	4,01E-05	21,95	3,71E-05	34,80	4,51E-05	11,32
	SGD e Tanh	4,27E-05	89,12	4,17E-05	98,15	5,58E-05	97,73	5,78E-05	97,70	5,74E-05	99,42	4,51E-05	54,96
	SGD e ReLu	3,96E-05	33,46	3,16E-05	54,41	4,25E-05	38,15	4,10E-05	33,59	3,15E-05	53,82	3,13E-05	27,81
	Adam e Sigmoide	4,12E-05	6,58	3,61E-05	4,94	4,65E-05	5,28	2,79E-05	7,83	4,09E-05	8,46	4,18E-05	8,13
	Adam e Tanh	3,10E-05	6,73	2,92E-05	6,86	2,69E-05	8,48	3,50E-05	8,85	3,83E-05	7,07	3,34E-05	7,40
	Adam e Relu	4,14E-05	4,70	4,05E-05	4,08	4,19E-05	4,28	3,36E-05	3,87	3,43E-05	5,03	3,84E-05	2,77
5	SGD e Sigmoide	4,12E-05	13,92	4,33E-05	23,33	3,61E-05	8,14	3,90E-05	13,91	3,71E-05	23,14	3,76E-05	14,60
	SGD e Tanh	4,17E-05	100,93	4,84E-05	72,73	4,77E-05	90,34	5,85E-05	98,03	4,41E-05	83,45	3,27E-05	89,30
	SGD e ReLu	3,76E-05	36,60	3,81E-05	42,12	4,01E-05	36,08	4,02E-05	36,46	3,85E-05	45,03	3,41E-05	61,84
	Adam e Sigmoide	2,91E-05	10,91	4,40E-05	5,50	2,65E-05	10,25	3,80E-05	5,26	5,03E-05	3,96	4,44E-05	5,47
	Adam e Tanh	2,72E-05	7,28	3,96E-05	6,91	2,89E-05	8,05	3,79E-05	6,95	3,05E-05	8,54	3,83E-05	7,11
	Adam e Relu	3,77E-05	4,13	3,45E-05	4,81	3,73E-05	4,36	2,80E-05	6,38	2,74E-05	7,95	3,92E-05	3,33

Tabela 8 – Limites de Tensão com Seleção de Atributos (Caso 3)

Topologia	Configuração	Com todos atributos		Sem P_{S_1}		Sem P_{D_5}		Sem P_{S_1} e P_{S_3}		Sem P_{S_3} e P_{D_5}	
		Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]	Erro EQM	Tempo [s]
1	SGD e Sigmoide	1,60E-05	22,44	9,39E-06	43,58	1,16E-05	31,47	1,25E-05	96,54	8,47E-06	48,67
	SGD e Tanh	1,44E-05	47,58	1,64E-05	96,74	1,37E-05	96,35	1,05E-05	94,62	2,60E-05	95,18
	SGD e ReLu	1,02E-05	38,13	9,63E-06	38,32	8,57E-06	44,45	1,02E-05	17,28	4,52E-05	96,54
	Adam e Sigmoide	8,06E-06	3,24	7,93E-06	10,36	1,15E-05	6,51	9,64E-06	7,41	1,00E-05	8,28
	Adam e Tanh	6,69E-06	7,76	1,02E-05	5,78	6,04E-06	8,99	9,93E-06	8,18	1,00E-05	8,81
	Adam e Relu	9,76E-06	3,29	1,11E-05	4,67	1,00E-05	5,67	7,17E-06	3,44	1,25E-05	4,75
2	SGD e Sigmoide	1,17E-05	14,90	9,37E-06	34,17	1,37E-05	18,92	1,09E-05	19,59	9,94E-06	32,94
	SGD e Tanh	1,74E-05	96,62	1,87E-05	97,55	2,00E-05	97,27	1,59E-05	96,52	2,36E-05	95,92
	SGD e ReLu	9,78E-06	74,12	1,07E-05	42,94	1,11E-05	45,25	1,04E-05	58,53	9,97E-06	49,30
	Adam e Sigmoide	7,71E-06	7,11	6,59E-06	10,41	1,22E-05	7,26	9,30E-06	2,88	1,03E-05	5,96
	Adam e Tanh	5,01E-06	6,94	6,52E-06	8,36	4,83E-06	7,80	8,56E-06	8,28	9,20E-06	7,70
	Adam e Relu	9,90E-06	4,42	1,07E-05	6,07	1,04E-05	3,93	1,09E-05	4,95	1,17E-05	4,98
3	SGD e Sigmoide	9,43E-06	18,71	1,05E-05	30,23	9,57E-06	21,99	1,24E-05	12,13	1,21E-05	33,24
	SGD e Tanh	1,12E-05	97,76	3,23E-05	97,97	1,70E-05	95,62	1,08E-05	87,92	2,28E-05	95,62
	SGD e ReLu	1,03E-05	72,67	9,87E-06	33,51	1,05E-05	38,67	8,30E-06	81,29	8,80E-06	50,58
	Adam e Sigmoide	8,55E-06	7,85	9,11E-06	8,56	9,74E-06	7,23	1,01E-05	3,03	5,32E-06	9,63
	Adam e Tanh	9,89E-06	7,23	8,74E-06	7,98	1,39E-05	5,83	8,41E-06	7,40	6,21E-06	8,63
	Adam e Relu	1,11E-05	4,08	1,01E-05	4,73	1,41E-05	4,16	1,17E-05	4,13	9,05E-06	5,35
4	SGD e Sigmoide	9,55E-06	20,34	9,89E-06	25,40	1,14E-05	17,74	9,77E-06	14,67	1,17E-05	27,15
	SGD e Tanh	1,59E-05	96,62	1,77E-05	97,97	1,69E-05	96,50	2,17E-05	96,52	1,27E-05	90,95
	SGD e ReLu	1,07E-05	55,18	1,03E-05	97,32	8,56E-06	69,99	1,24E-05	56,00	1,05E-05	35,85
	Adam e Sigmoide	1,11E-05	6,50	8,04E-06	8,06	1,09E-05	2,35	8,23E-06	8,25	1,02E-05	4,20
	Adam e Tanh	8,98E-06	6,83	7,17E-06	7,91	5,18E-06	7,90	6,73E-06	7,38	1,25E-05	9,63
	Adam e Relu	1,28E-05	4,93	1,03E-05	4,05	1,27E-05	4,95	1,11E-05	3,72	1,47E-05	5,16
5	SGD e Sigmoide	1,02E-05	12,12	1,07E-05	24,31	1,03E-05	13,11	1,03E-05	9,83	1,07E-05	27,67
	SGD e Tanh	1,92E-05	97,68	1,37E-05	97,43	2,61E-05	96,95	1,79E-05	93,24	2,46E-05	98,66
	SGD e ReLu	1,05E-05	71,96	9,77E-06	45,32	1,09E-05	83,21	1,16E-05	57,62	1,02E-05	72,79
	Adam e Sigmoide	8,15E-06	7,54	9,90E-06	9,75	1,08E-05	2,95	9,39E-06	6,00	1,27E-05	3,42
	Adam e Tanh	8,24E-06	7,58	1,37E-05	7,31	8,20E-06	6,85	1,33E-05	7,11	6,79E-06	9,13
	Adam e Relu	1,01E-05	3,82	1,06E-05	4,77	1,00E-05	3,96	9,83E-06	4,71	1,08E-05	4,75

A função de desempenho das RNAs mais difundida na literatura é o Erro Quadrático Médio (EQM) e, por isso, determinou-se-a. O EQM (MSE na sigla em inglês) informa o quão perto uma linha de regressão está de um conjunto de pontos. Ele faz isso tirando as distâncias dos pontos para a linha de regressão (essas distâncias são os “erros”) e elevando ao quadrado. A quadratura é necessária para remover quaisquer sinais negativos e também dá mais peso a diferenças maiores. É chamado de EQM, pois está encontrando a média de um conjunto de erros. Por via de regra, quanto menor o valor de EQM, melhor a previsão. O cálculo para se obter o EQM é definido por:

$$EQM = \frac{1}{n} \cdot \sum_i^n (y_i - \hat{y}_i)^2 \quad (34)$$

onde n representa o número de itens; y_i é o valor alvo original ou observado e, \hat{y}_i é o valor alvo oriundo da previsão realizada pela RNA.

Tabela 9 – Síntese dos Treinamentos Realizados para Cada Caso

Caso	Topologia	Configuração	Erro EQM	Tempo [s]	Atributos ausentes
1 - Limites Térmicos	5	Adam e Relu	2,05E-04	8,70	P_{S_3} e P_{D_6}
2 - BIL e Limites Térmicos	5	Adam e Relu	2,74E-05	7,95	P_{S_1} e P_{D_4}
3 - Limites de Tensão	3	Adam e Sigmoide	5,32E-06	9,63	P_{S_3} e P_{D_5}




Figura 15 – Estimativas da RNA para Limites Térmicos (Caso 1).

As Figuras 15, 16 e 17 demonstram graficamente as estimativas realizadas pelas RNAs com os dados empregados na fase de validação de cada uma das configurações e topologias




Figura 16 – Estimativas da RNA para BIL e Limites Térmicos (Caso 2).




Figura 17 – Estimativas da RNA para Limites de Tensão (Caso 3).

que obtiveram os melhores desempenhos para cada e respectivo Caso. A Tabela 9 resume os valores alcançados e quais atributos foram retirados para obtenção dos menores erros.

Por sua vez, as equações 35, 36, 37 referem-se as equações da aproximação funcional obtida através das RNAs, respectivamente, para limites de tensão (Caso 3), limites térmicos (Caso 1) e BIL e limites térmicos (Caso 2). Tais equações são inseridas, para cada respectivo Caso, na restrição (26j) do modelo (26) dessa forma, resolvendo-o.

$$\begin{aligned}
 \sigma_c = & \left(\frac{1}{1 + e^{(-0.4425P_{S_1})+(-0.3927P_{S_2})+(-0.2070P_{D_4})+(-0.5455P_{D_6})+0.5321}} \cdot 0.7730 \right) + \\
 & \left(\frac{1}{1 + e^{(-0.9590P_{S_1})+(0.1019P_{S_2})+(0.2482P_{D_4})+(-0.8347P_{D_6})-0.2940}} \cdot 0.1282 \right) + \\
 & \left(\frac{1}{1 + e^{(-0.0339P_{S_1})+(-0.0534P_{S_2})+(-0.4966P_{D_4})+(-0.1722P_{D_6})-0.2238}} \cdot 0.1282 \right) + \\
 & \left(\frac{1}{1 + e^{(-0.6489P_{S_1})+(-0.4260P_{S_2})+(-0.2898P_{D_4})+(-0.2530P_{D_6})-0.3944}} \cdot -0.2881 \right) + \\
 & \left(\frac{1}{1 + e^{(-0.4625P_{S_1})+(-0.3667P_{S_2})+(-0.0244P_{D_4})+(-0.1394P_{D_6})-0.3346}} \cdot -0.0753 \right) + \\
 & \left(\frac{1}{1 + e^{(0.3945P_{S_1})+(0.3367P_{S_2})+(0.5323P_{D_4})+(0.6508P_{D_6})+0.7491}} \cdot 1.1039 \right) + 0.4974
 \end{aligned} \tag{35}$$

$$\begin{aligned}
\sigma_c = & \left(\frac{((-0.0911P_{S_1}) + (-0.2019P_{S_2}) + (-0.2041P_{D_4}) + (0.4435P_{D_5}) - 0.2086) + \sqrt{(((0.0654P_{S_1}) + (-0.3526P_{S_2}) + (-0.1190P_{D_4}) + (0.3740P_{D_5}) + 0.4458)^2 + 10^{-9})}}{2} \cdot -1.1313 \right) + \\
& \left(\frac{((0.0654P_{S_1}) + (-0.3526P_{S_2}) + (-0.1190P_{D_4}) + (0.3740P_{D_5}) + 0.4458) + \sqrt{(((0.0654P_{S_1}) + (-0.3526P_{S_2}) + (-0.1190P_{D_4}) + (0.3740P_{D_5}) + 0.4458)^2 + 10^{-9})}}{2} \cdot 0.7581 \right) + \\
& \left(\frac{((0.5938P_{S_1}) + (-0.1181P_{S_2}) + (-0.4279P_{D_4}) + (0.0336P_{D_5}) - 0.1436) + \sqrt{(((0.5938P_{S_1}) + (-0.1181P_{S_2}) + (-0.4279P_{D_4}) + (0.0336P_{D_5}) - 0.1436)^2 + 10^{-9})}}{2} \cdot 0.1877 \right) + \\
& \left(\frac{((-0.2960P_{S_1}) + (0.3215P_{S_2}) + (0.5902P_{D_4}) + (-0.1822P_{D_5}) + 0.2955) + \sqrt{(((0.2960P_{S_1}) + (-0.3215P_{S_2}) + (-0.5902P_{D_4}) + (0.1822P_{D_5}) - 0.2955)^2 + 10^{-9})}}{2} \cdot 0.5291 \right) + \\
& \left(\frac{((-0.4183P_{S_1}) + (0.2954P_{S_2}) + (-0.0754P_{D_4}) + (-0.0360P_{D_5}) + 0.4438) + \sqrt{(((0.4183P_{S_1}) + (-0.2954P_{S_2}) + (0.0754P_{D_4}) + (0.0360P_{D_5}) - 0.4438)^2 + 10^{-9})}}{2} \cdot 0.7252 \right) + \\
& \left(\frac{((-0.2920P_{S_1}) + (-0.0041P_{S_2}) + (0.4569P_{D_4}) + (1.0344P_{D_5}) - 0.5088) + \sqrt{(((0.2920P_{S_1}) + (-0.0041P_{S_2}) + (-0.4569P_{D_4}) + (-1.0344P_{D_5}) + 0.5088)^2 + 10^{-9})}}{2} \cdot -0.4941 \right) + \\
& \left(\frac{((-0.1627P_{S_1}) + (-0.0078P_{S_2}) + (0.4925P_{D_4}) + (0.2403P_{D_5}) - 0.2441) + \sqrt{(((0.1627P_{S_1}) + (-0.0078P_{S_2}) + (-0.4925P_{D_4}) + (-0.2403P_{D_5}) + 0.2441)^2 + 10^{-9})}}{2} \cdot -0.3778 \right) + \\
& \left(\frac{((0.0108P_{S_1}) + (-0.5661P_{S_2}) + (0.1431P_{D_4}) + (-0.5516P_{D_5}) - 0.1514) + \sqrt{(((0.0108P_{S_1}) + (-0.5661P_{S_2}) + (0.1431P_{D_4}) + (-0.5516P_{D_5}) - 0.1514)^2 + 10^{-9})}}{2} \cdot -0.5653 \right) + \\
& \left(\frac{((-0.8692P_{S_1}) + (0.2116P_{S_2}) + (0.1185P_{D_4}) + (0.0805P_{D_5}) + 0.1460) + \sqrt{(((0.8692P_{S_1}) + (-0.2116P_{S_2}) + (-0.1185P_{D_4}) + (-0.0805P_{D_5}) - 0.1460)^2 + 10^{-9})}}{2} \cdot -0.4282 \right) + 0.2636
\end{aligned} \tag{36}$$

$$\begin{aligned}
 \sigma_c = & \left(\frac{((0.6436P_{S_2}) + (0.6294P_{S_3}) + (0.1223P_{D_5}) + (-0.2845P_{D_6}) + 0.2353) + \sqrt{(((0.6436P_{S_2}) + (0.6294P_{S_3}) + (0.1223P_{D_5}) + (-0.2845P_{D_6}) + 0.2353)^2 + 10^{-9})}}{2} \cdot 0.5522 \right) + \\
 & \left(\frac{((0.2891P_{S_2}) + (-0.0459P_{S_3}) + (-0.0050P_{D_5}) + (0.5456P_{D_6}) + 0.2463) + \sqrt{(((0.2891P_{S_2}) + (-0.0459P_{S_3}) + (-0.0050P_{D_5}) + (0.5456P_{D_6}) + 0.2463)^2 + 10^{-9})}}{2} \cdot 0.5283 \right) + \\
 & \left(\frac{((-0.6979P_{S_2}) + (0.3096P_{S_3}) + (-0.6941P_{D_5}) + (-0.4956P_{D_6}) - 0.2169) + \sqrt{(((0.6979P_{S_2}) + (0.3096P_{S_3}) + (-0.6941P_{D_5}) + (-0.4956P_{D_6}) - 0.2169)^2 + 10^{-9})}}{2} \cdot -0.1525 \right) + \\
 & \left(\frac{((0.1655P_{S_2}) + (0.5696P_{S_3}) + (-0.3132P_{D_5}) + (0.1323P_{D_6}) + 0.2698) + \sqrt{(((0.1655P_{S_2}) + (0.5696P_{S_3}) + (-0.3132P_{D_5}) + (0.1323P_{D_6}) + 0.2698)^2 + 10^{-9})}}{2} \cdot 0.4959 \right) + \\
 & \left(\frac{((-0.4551P_{S_2}) + (-0.6522P_{S_3}) + (-0.6646P_{D_5}) + (-0.5485P_{D_6}) + 0.0000) + \sqrt{(((0.4551P_{S_2}) + (0.6522P_{S_3}) + (0.6646P_{D_5}) + (0.5485P_{D_6}) + 0.0000)^2 + 10^{-9})}}{2} \cdot -0.6231 \right) + \\
 & \left(\frac{((-0.2449P_{S_2}) + (-0.1794P_{S_3}) + (0.6152P_{D_5}) + (0.3198P_{D_6}) - 0.1320) + \sqrt{(((0.2449P_{S_2}) + (0.1794P_{S_3}) + (0.6152P_{D_5}) + (0.3198P_{D_6}) - 0.1320)^2 + 10^{-9})}}{2} \cdot 0.0647 \right) + \\
 & \left(\frac{((-0.0442P_{S_2}) + (-0.4739P_{S_3}) + (-0.5610P_{D_5}) + (0.2655P_{D_6}) - 0.2674) + \sqrt{(((0.0442P_{S_2}) + (0.4739P_{S_3}) + (0.5610P_{D_5}) + (0.2655P_{D_6}) - 0.2674)^2 + 10^{-9})}}{2} \cdot -0.1486 \right) + \\
 & \left(\frac{((-0.4671P_{S_2}) + (-0.3422P_{S_3}) + (0.0593P_{D_5}) + (-0.3697P_{D_6}) + 0.8002) + \sqrt{(((0.4671P_{S_2}) + (0.3422P_{S_3}) + (0.0593P_{D_5}) + (0.3697P_{D_6}) + 0.8002)^2 + 10^{-9})}}{2} \cdot 1.3437 \right) + \\
 & \left(\frac{((0.1279P_{S_2}) + (-0.3796P_{S_3}) + (0.0064P_{D_5}) + (0.6366P_{D_6}) + 0.3172) + \sqrt{(((0.1279P_{S_2}) + (-0.3796P_{S_3}) + (0.0064P_{D_5}) + (0.6366P_{D_6}) + 0.3172)^2 + 10^{-9})}}{2} \cdot 0.3907 \right) + 0.2109
 \end{aligned} \tag{37}$$

6.3 Análise dos Resultados Obtidos para o FPO-REST Proposto

Nesta subseção são apresentados os resultados obtidos através da execução do modelo proposto de FPO-REST deste trabalho. Novamente, os resultados foram obtidos pelo *software* de modelagem matemática AMPL (AMPL Optimization Inc., 2021) através do *solver* comercial LOQO (VANDERBEI, 2006). Os erros máximos absolutos ξ nas aproximações funcionais pelas RNAs para cada um dos casos analisados foram feitas conforme (17). Os respectivos erros máximos absolutos ξ foram: 0,12216 para Limites Térmicos (Caso 1); 0,03662 para o BIL e Limites Térmicos (Caso 2); e 0.01260 para o Limites de Tensão (Caso 3).

As equações geradas pelas RNAs juntamente com os erros máximos absolutos considerados foram implementados no problema de FPO-REST em (26).

O estado da rede elétrica e a alocação de oferta e demanda para Limites Térmicos (Caso 1) são apresentados na Tabela 10.

Tabela 10 – Resultados por Limites Térmicos (Caso 1)

Participante {k}	P_S [MW]	P_D [MW]	V [p.u.]	ϕ [graus]	Q_G [Mvar]	PLM [\$/MWh]
1	$2,58e^{-10}$	-	1,1000	0	13,7533	843,08
2	24,4309	-	1,1000	-0,9552	39,6093	842,57
3	5,5667	-	1,1000	-3,0825	28,6721	864,25
4	-	9,8925	1,0316	-3,4868	-	888,51
5	-	10,0000	1,0141	-5,3041	-	906,01
6	-	9,1473	1,0380	-5,2675	-	889,32

Bem-estar Social [\$/h]= 56,65

$\sigma_c = 1,0000$

$\alpha^{P_S} = 0,2999$ e $\alpha^{P_D} = 0,2903$

$\pi_c = 2103,75$; $\lambda^{\|P_S\|} = -49,2734$ e $\lambda^{\|P_D\|} = -13,5640$

Pela Tabela 10 pode ser observado que σ_c é igual a 1,0, indicando que o nível de carregamento do sistema está no seu limite de estabilidade/segurança de tensão. Cabe ressaltar também que a maximização da função bem-estar social é restringida principalmente por esse limite, o que resulta em uma menor alocação de blocos de oferta e demanda de energia elétrica. Em consequência disso, os PLMs também serão menores, dado que esses valores representam a taxa de variação da função bem-estar social em relação à alocação adicional (e infinitesimal) de blocos de oferta e demanda de energia elétrica.

Os componentes dos PLMs de oferta e demanda são apresentados, respectivamente, nas Tabelas 11 e 12.

Como pode ser visto nas Tabelas 11 e 12, os PLMs são diretamente impactados pela restrição de estabilidade/segurança de tensão ativa na solução (o PLM da demanda da

Tabela 11 – Componentes dos PLMs da Oferta para o Caso 1

Limites Térmicos				
Participante {k}	Preço de Venda [\$/MWh]	Custo de Não Participação		Custo de Estabilidade/Segurança de Tensão [\$/MWh]
		Limite Inferior [\$/MWh]	Limite Superior [\$/MWh]	
1	970	208,95	$7,15e^{-8}$	-82,06
2	880	$5,53e^{-8}$	$1,70e^{-6}$	37,44
3	700	$4,57e^{-7}$	$7,46e^{-8}$	-164,26

Tabela 12 – Componentes dos PLMs da Demanda para o Caso 1

Limites Térmicos					
Participante {k}	Preço de Compra [\$/MWh]	Custos do Acréscimo da Carga Reativa [\$/Mvarh]	Custo de Não Participação		Custo de Estabilidade/Segurança de Tensão [\$/MWh]
			Limite Inferior [\$/MWh]	Limite Superior [\$/MWh]	
4	1200	20,79	$1,63e^{-7}$	$8,91e^{-8}$	-291,78
5	1050	26,56	$1,64e^{-7}$	447,71	329,70
6	950	13,96	$1,72e^{-7}$	$1,27e^{-7}$	-46,71

barra 5 também é impactado pelo custo de não participação associado ao limite superior do lance de energia elétrica demandada). Ademais, dado que as componentes dos PLMs são definidas em função das variáveis duais, ressalta-se que erros entre os valores obtidos para os PLMs na Tabela 10 e os valores calculados por meio das suas componentes nas Tabelas 11 e 12 se devem ao *gap* de dualidade entre o resultado dos problemas primal (não linear e não convexo) e dual (convexo); essa explicação também é válida para os estudos de caso apresentados a seguir.

A Tabela 13 contém o estado da rede elétrica e a alocação de oferta e demanda para BIL e Limites Térmicos (Caso 2). Pela tabela, σ_c é igual a 1,7613 indicando que o nível de carregamento do sistema não está no seu limite de estabilidade/segurança de tensão. Diversamente do Caso 1, em que a função bem-estar social é suprimida pelos custos de estabilidade/segurança de tensão e custos de não participação, neste Caso 2, a função bem-estar social é maior devido ao inexistência de tais custos. Outro efeito que se pode notar é de um consumo maior P_D por parte da carga, conseqüentemente a oferta (geração de energia elétrica) aumenta de forma a atender-lá, e os PLMs seguem tendência de crescimento.

Dessa forma, como os limites operacionais não foram atingidos, os custos de estabilidade/segurança de tensão são nulos, o que ocasiona um aumento no valor do bem-estar social. Contudo, existem custos de não participação de algumas barras do sistema-teste, tais barras possuem um acréscimo nos PLMs. As Tabelas 14 e 15, apresentam os resultados referentes aos componentes dos PLMs, respectivamente, oferta e demanda.

Os resultados obtidos para o sistema-teste de 6 barras para Limites de Tensão (Caso 3) estão expressos pela Tabela 16. Já as Tabelas 17 e 18 exibem os resultados obtidos, respectivamente, de oferta e demanda dos PLMs do sistema. De forma análoga, contudo por fatores técnicos operacionais distintos, pode ser observado que σ_c também é igual a 1,0, indicando que o nível de carregamento do sistema está no seu limite da estabi-

Tabela 13 – Resultados por BIL e Limites Térmicos (Caso 2)

Participante {k}	P_S [MW]	P_D [MW]	V [p.u.]	ϕ [graus]	Q_G [Mvar]	PLM [\$/MWh]
1	0	-	1,1200	0	15,5473	896,73
2	25,0000	-	1,1200	-0,7753	41,0531	892,92
3	20,0000	-	1,1200	-2,1425	29,8112	908,80
4	-	25,0000	1,0430	-3,5714	-	948,30
5	-	10,0000	1,0349	-4,8169	-	956,97
6	-	8,6312	1,0600	-4,5074	-	935,93

Bem-estar Social [\$/h] = 126,99						
$\sigma_c = 1,7614$						
$\alpha^{P_S} = 0,4500$ e $\alpha^{P_D} = 0,4363$						
$\pi_c = 1,43e^{-8}$; $\lambda^{\ P_S\ } = 5,06e^{-8}$ e $\lambda^{\ P_D\ } = 5,28e^{-8}$						

Tabela 14 – Componentes dos PLMs Caso 2 - Oferta

BIL e Limites Térmicos				
Participante {k}	Preço de Venda [\$/MWh]	Custo de Não Participação		Custo de Estabilidade/Segurança de Tensão [\$/MWh]
		Limite Inferior [\$/MWh]	Limite Superior [\$/MWh]	
1	970	73,27	$1,86e^{-8}$	0
2	880	$1,33e^{-8}$	12,92	0
3	700	$2,16e^{-8}$	208,80	0

Tabela 15 – Componentes dos PLMs Caso 2 - Demanda

BIL e Limites Térmicos					
Participante {k}	Preço de Venda [\$/MWh]	Custos do Acréscimo da Carga Reativa [\$/Mvarh]	Custo de Não Participação		Custo de Estabilidade/Segurança de Tensão [\$/MWh]
			Limite Inferior [\$/MWh]	Limite Superior [\$/MWh]	
4	1200	24,69	$1,99e^{-8}$	227,00	0
5	1050	26,87	$8,27e^{-8}$	66,15	0
6	950	14,06	$6,24e^{-8}$	$6,95e^{-8}$	0

lidade/segurança de tensão. Esse termo indica que custos de estabilidade/segurança de tensão passam a existir e, a função que visa maximizar o bem-estar social tende a diminuir, e isso se deve principalmente porque o custo para garantir qualidade e confiança do sistema passam a ser contabilizados. Uma característica que o Caso 3 trás é de uma maior utilização das potências ativas (P_D) e por consequência de uma maior geração de energia elétrica (P_S).

Tabela 16 – Resultados por Limites de Tensão (Caso 3)

Participante {k}	P_S [MW]	P_D [MW]	V [p.u.]	ϕ [graus]	Q_G [Mvar]	PLM [\$/MWh]
1	0,8245	-	1,1000	0	13,8829	938,92
2	25,0000	-	1,1000	-0,9532	38,5575	937,75
3	20,0000	-	1,1000	-2,7015	32,0406	958,84
4	-	14,0758	1,0285	-3,5731	-	991,41
5	-	10,0000	1,0121	-5,2409	-	1008,78
6	-	20,0000	1,0320	-5,3071	-	991,02

Bem-estar Social [\$/h] = 95,91

$\sigma_c = 1,0000$

$\alpha^{P_S} = 0,4582$ e $\alpha^{P_D} = 0,4407$

$\pi_c = 1807,83$; $\lambda^{\|P_S\|} = 16,2074$ e $\lambda^{\|P_D\|} = 33,1975$

Tabela 17 – Componentes dos PLMs Caso 3 - Oferta

Limites de Tensão				
Participante {k}	Preço de Venda [\$/MWh]	Custo de Não Participação		Custo de Estabilidade/Segurança de Tensão [\$/MWh]
		Limite Inferior [\$/MWh]	Limite Superior [\$/MWh]	
1	970	$2,80e^{-6}$	$8,10e^{-8}$	31,07
2	880	$6,13e^{-8}$	28,43	-29,31
3	700	$1,04e^{-7}$	294,21	35,36

Tabela 18 – Componentes dos PLMs Caso 3 - Demanda

Limites de Tensão					
Participante {k}	Preço de Venda [\$/MWh]	Custos do Acréscimo da Carga Reativa [\$/Mvarh]	Custo de Não Participação		Custo de Estabilidade/Segurança de Tensão [\$/MWh]
			Limite Inferior [\$/MWh]	Limite Superior [\$/MWh]	
4	1200	24,36	$1,97e^{-7}$	$1,53e^{-7}$	-184,21
5	1050	30,27	$1,93e^{-8}$	86,26	75,31
6	950	17,44	$9,13e^{-8}$	33,52	91,99

Capítulo 7

Considerações Finais

O objetivo principal deste trabalho é propor um modelo para o problema de FPO-REST aplicados a leilões de ajuste em mercados de energia elétrica. Para isso, utiliza-se aproximações funcionais dos limites de estabilidade/segurança de tensão por RNAs, com a utilização de seleção de atributos, com a finalidade de incorporar essa aproximação ao modelo do FPO-REST, conseqüentemente, resolvendo-o.

Com base no que foi apresentado, a principal conclusão que pode ser obtida é que a metodologia proposta se mostra promissora, pois apresenta pontos fortes do modelo implementado no *software* AMPL e aproximações funcionais dos limites de estabilidade/segurança de tensão por RNA com baixíssimos erros.

O método de seleção de atributos utilizados nesse trabalho, ao identificar a importância das variáveis, possibilitam a eliminação da(s) variável(is) menos significativas reduzindo-se o número de entradas da RNA. Isto permite que o treinamento da RNA seja mais rápido e ameniza o problema da “maldição da dimensionalidade” sem que a RNA perca seu desempenho.

O uso das RNAs trazem uma vantagem computacional significativa para a aplicação do modelo matemático de FPO-REST apresentado em leilões de ajuste e mercados de energia elétrica. Em sistemas de grande porte o cálculo realizado, que neste trabalho foi aproximado por uma RNA, pode ser computacionalmente inviável isso se deve, em grande parte, devido a excessiva quantidade de variáveis a serem calculadas. Desta forma, o emprego das RNAs atrelado a seletores de atributos, realizam de modo geral uma estimação precisa, notável e vertiginosa dos valores de máximo carregamento do sistema apresentado.

7.1 Trabalhos Futuros

Como parte dos requisitos do regimento interno para a defesa da dissertação de Mestrado do Programa de Pós-Graduação em Engenharia Elétrica (PPGEE) da Universidade Federal de São Carlos (UFSCar), foi submetido o artigo intitulado *Decentralised Day-*

Ahead Hourly Operation Planning of Microgrids with Distributed Photovoltaic Generation Integrated by Smart Inverters via Mixed-Integer and Mixed-Complementarity Volt/Var Optimization. Em um próximo passo, será submetido um outro artigo analisando as diferenças de modelagem e resultados obtidos para abordagens centralizada e descentralizada desse problema de planejamento de véspera da operação horária de microrredes no contexto das *smart grids*.

Concomitantemente, as perspectivas de continuidade do projeto de pesquisa apresentado nesta dissertação são as seguintes:

- realização de testes da metodologia apresentada utilizando sistemas de maior porte (como, por exemplo, o sistema italiano 300 kV de 129 barras (MILANO; CANIZARES; INVERNIZZI, 2003));
- submissão de um artigo para o periódico *International Journal of Electrical Power & Energy Systems* apresentando a abordagem de representação da estabilidade/segurança de tensão em problemas de FPO aplicados a leilões de ajuste em mercados de energia elétrica desenvolvida neste trabalho;
- submissão de um artigo para o periódico *Electric Power Systems Research* comparando diferentes abordagens de representação da estabilidade/segurança de tensão em problemas de FPO aplicados a leilões de ajuste em mercados de energia elétrica (resultado do projeto desenvolvido pelo grupo de pesquisa);
- aplicação da representação da estabilidade/segurança de tensão em outros problemas de FPO e divulgação dos resultados em periódicos internacionais.

Referências

AJJARAPU, V.; CHRISTY, C. The continuation power flow: a tool for steady state voltage stability analysis. In: [**Proceedings**] **Conference Papers 1991 Power Industry Computer Application Conference**. IEEE, 1991. Disponível em: <<https://doi.org/10.1109/pica.1991.160593>>.

ALIPOURI, Y.; POSHTAN, J.; ALIPOURI, Y. A modification to classical evolutionary programming by shifting strategy parameters. **Applied Intelligence**, Springer Science and Business Media LLC, v. 38, n. 2, p. 175–192, jul. 2012. Disponível em: <<https://doi.org/10.1007/s10489-012-0364-x>>.

ALSAC, O.; STOTT, B. Optimal load flow with steady-state security. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical and Electronics Engineers (IEEE), PAS-93, n. 3, p. 745–751, maio 1974. Disponível em: <<https://doi.org/10.1109/tpas.1974.293972>>.

ALVES, D. A. **Obtenção do ponto de máximo carregamento em sistemas elétricos de potência utilizando novas técnicas de parametrização para o método de continuação**. 2000. Tese (Doutorado em Engenharia Elétrica) — Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2000.

AMPL Optimization Inc. **AMPL**. 2021. [Http://www.ampl.com](http://www.ampl.com).

APICELLA, A. et al. A survey on modern trainable activation functions. **Neural Networks**, Elsevier BV, v. 138, p. 14–32, jun. 2021. Disponível em: <<https://doi.org/10.1016/j.neunet.2021.01.026>>.

Avalos Munoz, Jose Rafael. **Analysis and Application of Optimization Techniques to Power System Security and Electricity Markets**. Tese (Doutorado) — University of Waterloo, 2008. Disponível em: <<http://hdl.handle.net/10012/3692>>.

AVALOS, R. et al. Equivalency of continuation and optimization methods to determine saddle-node and limit-induced bifurcations in power systems. **IEEE Transactions on Circuits and Systems I: Regular Papers**, Institute of Electrical and Electronics Engineers (IEEE), v. 56, n. 1, p. 210–223, jan. 2009. Disponível em: <<https://doi.org/10.1109/tcsi.2008.925941>>.

AVALOS, R. J.; CANIZARES, C. A.; ANJOS, M. F. A practical voltage-stability-constrained optimal power flow. In: **2008 IEEE Power and Energy Society General Meeting - Conversion and Delivery of Electrical Energy in the 21st Century**. IEEE, 2008. Disponível em: <<https://doi.org/10.1109/pes.2008.4596314>>.

- BARCELO, W.; LEMMON, W.; KOEN, H. Optimization of the real-time dispatch with constraints for secure operation of bulk power systems. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 96, n. 3, p. 741–757, maio 1977. Disponível em: <<https://doi.org/10.1109/t-pas.1977.32388>>.
- BENGIO, Y.; SIMARD, P.; FRASCONI, P. Learning long-term dependencies with gradient descent is difficult. **IEEE Transactions on Neural Networks**, Institute of Electrical and Electronics Engineers (IEEE), v. 5, n. 2, p. 157–166, mar. 1994. Disponível em: <<https://doi.org/10.1109/72.279181>>.
- BLUM, A. L.; LANGLEY, P. Selection of relevant features and examples in machine learning. **Artificial Intelligence**, Elsevier BV, v. 97, n. 1-2, p. 245–271, dez. 1997. Disponível em: <[https://doi.org/10.1016/s0004-3702\(97\)00063-5](https://doi.org/10.1016/s0004-3702(97)00063-5)>.
- BOTTOU, L. Large-scale machine learning with stochastic gradient descent. In: **Proceedings of COMPSTAT'2010**. Physica-Verlag HD, 2010. p. 177–186. Disponível em: <https://doi.org/10.1007/978-3-7908-2604-3_16>.
- CANIZARES, C. Conditions for saddle-node bifurcations in AC/DC power systems. **International Journal of Electrical Power & Energy Systems**, Elsevier BV, v. 17, n. 1, p. 61–68, fev. 1995. Disponível em: <[https://doi.org/10.1016/0142-0615\(95\)93278-7](https://doi.org/10.1016/0142-0615(95)93278-7)>.
- CANIZARES, C.; KODSI, S. Power system security in market clearing and dispatch mechanisms. In: **2006 IEEE PES Power Systems Conference and Exposition**. IEEE, 2006. Disponível em: <<https://doi.org/10.1109/psce.2006.296345>>.
- CANIZARES, C. et al. Comparison of voltage security constrained optimal power flow techniques. In: **2001 Power Engineering Society Summer Meeting. Conference Proceedings (Cat. No.01CH37262)**. IEEE, 2001. Disponível em: <<https://doi.org/10.1109/pess.2001.970328>>.
- CAPITANESCU, F. et al. Contingency filtering techniques for preventive security-constrained optimal power flow. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 22, n. 4, p. 1690–1697, nov. 2007. Disponível em: <<https://doi.org/10.1109/tpwrs.2007.907528>>.
- _____. State-of-the-art, challenges, and future trends in security constrained optimal power flow. **Electric Power Systems Research**, Elsevier BV, v. 81, n. 8, p. 1731–1741, ago. 2011. Disponível em: <<https://doi.org/10.1016/j.epsr.2011.04.003>>.
- CHAVEZ-LUGO, M. et al. Practical security boundary-constrained DC optimal power flow for electricity markets. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 31, n. 5, p. 3358–3368, set. 2016. Disponível em: <<https://doi.org/10.1109/tpwrs.2015.2504870>>.
- CHOLLET, F. et al. **Keras**. GitHub, 2015. Disponível em: <<https://github.com/fchollet/keras>>.
- CUI, B.; SUN, X. A. A new voltage stability-constrained optimal power-flow model: Sufficient condition, SOCP representation, and relaxation. **IEEE Transactions on**

Power Systems, Institute of Electrical and Electronics Engineers (IEEE), v. 33, n. 5, p. 5092–5102, set. 2018. Disponível em: <<https://doi.org/10.1109/tpwrs.2018.2801286>>.

CUTSEM, T. V. et al. Test systems for voltage stability studies. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 35, n. 5, p. 4078–4087, set. 2020. Disponível em: <<https://doi.org/10.1109/tpwrs.2020.2976834>>.

CYBENKO, G. Approximation by superpositions of a sigmoidal function. **Mathematics of Control, Signals, and Systems**, Springer Science and Business Media LLC, v. 2, n. 4, p. 303–314, dez. 1989. Disponível em: <<https://doi.org/10.1007/bf02551274>>.

Câmara de Comercialização de Energia Elétrica. **Tipos de leilões**. 2020. <https://www.cee.org.br>. Acesso em: 31 jul. 2020.

DENIS, D. J. **Applied Univariate, Bivariate, and Multivariate Statistics Using Python: A Beginner's Guide to Advanced Data Analysis**. 1. ed. [S.l.]: Wiley, 2021. ISBN 1119578140, 9781119578147, 9781119578178, 9781119578185, 9781119578208.

DINI, A. et al. Security-constrained generation and transmission expansion planning based on optimal bidding in the energy and reserve markets. **Electric Power Systems Research**, Elsevier BV, v. 193, p. 107017, abr. 2021. Disponível em: <<https://doi.org/10.1016/j.epsr.2020.107017>>.

DOBSON, I. et al. Voltage stability assessment: Concepts, practices and tools. **IEEE Power Engineering Society, Power System Stability Subcommittee Special Publication**, v. 11, p. 21–22, 01 2002.

DOBSON, I.; LU, L. Voltage collapse precipitated by the immediate change in stability when generator reactive power limits are encountered. **IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications**, Institute of Electrical and Electronics Engineers (IEEE), v. 39, n. 9, p. 762–766, 1992. Disponível em: <<https://doi.org/10.1109/81.250167>>.

DOMMEL, H.; TINNEY, W. Optimal power flow solutions. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical and Electronics Engineers (IEEE), PAS-87, n. 10, p. 1866–1876, out. 1968. Disponível em: <<https://doi.org/10.1109/tpas.1968.292150>>.

EL-SAMAHY, I. et al. A procurement market model for reactive power services considering system security. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 23, n. 1, p. 137–149, fev. 2008. Disponível em: <<https://doi.org/10.1109/tpwrs.2007.913296>>.

ERNST, O. K. Stochastic gradient descent learning and the backpropagation algorithm. **University of California, San Diego, La Jolla, CA, Tech. Rep**, 2014.

FU, Y.; SHAHIDEHPOUR, M.; LI, Z. AC contingency dispatch based on security-constrained unit commitment. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 21, n. 2, p. 897–908, maio 2006. Disponível em: <<https://doi.org/10.1109/tpwrs.2006.873407>>.

GARSON, G. D. Interpreting neural-network connection weights. **AI Expert**, Miller Freeman, Inc., USA, v. 6, n. 4, p. 46–51, abr. 1991. ISSN 0888-3785.

- GERON, A. **Mãos à Obra Aprendizado de Máquina com Scikit-Learn e TensorFlow**. S.l: Alta Books, 2019. ISBN 978-8550803814.
- GLOROT, X.; BORDES, A.; BENGIO, Y. Deep sparse rectifier neural networks. In: **AISTATS**. JMLR.org, 2011. v. 15, p. 315–323. Disponível em: <<http://www.jmlr.org/proceedings/papers/v15/glorot11a/glorot11a.pdf>>.
- GREGORUTTI, B.; MICHEL, B.; SAINT-PIERRE, P. Correlation and variable importance in random forests. **Statistics and Computing**, Springer Science and Business Media LLC, v. 27, n. 3, p. 659–678, mar. 2016. Disponível em: <<https://doi.org/10.1007/s11222-016-9646-1>>.
- GU, X.; CANIZARES, C. Fast prediction of loadability margins using neural networks to approximate security boundaries of power systems. **IET Generation, Transmission & Distribution**, Institution of Engineering and Technology (IET), v. 1, n. 3, p. 466, 2007. Disponível em: <<https://doi.org/10.1049/iet-gtd:20060265>>.
- GULCEHRE, C. et al. Noisy activation functions. In: PMLR. **International conference on machine learning**. 2016. p. 3059–3068. Disponível em: <<https://arxiv.org/pdf/1603.00391v3.pdf>>.
- GUO, Y.; ZHANG, Z.; TANG, F. Feature selection with kernelized multi-class support vector machine. **Pattern Recognition**, Elsevier BV, v. 117, p. 107988, set. 2021. Disponível em: <<https://doi.org/10.1016/j.patcog.2021.107988>>.
- GUTIERREZ-MARTINEZ, V. J. et al. Neural-network security-boundary constrained optimal power flow. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 26, n. 1, p. 63–72, fev. 2011. Disponível em: <<https://doi.org/10.1109/tpwrs.2010.2050344>>.
- GUYON, I. et al. Gene selection for cancer classification using support vector machines. **Machine Learning**, Springer Science and Business Media LLC, v. 46, n. 1/3, p. 389–422, 2002. Disponível em: <<https://doi.org/10.1023/a:1012487302797>>.
- HAMMER Øyvind. **PAleontological STatistics Version 4.07**. 2021. [Http://www.nhm.uio.no/english/research/infrastructure/past/](http://www.nhm.uio.no/english/research/infrastructure/past/).
- HAMON, C.; PERNINGE, M.; SODER, L. A stochastic optimal power flow problem with stability constraints—part i: Approximating the stability boundary. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 28, n. 2, p. 1839–1848, maio 2013. Disponível em: <<https://doi.org/10.1109/tpwrs.2012.2226760>>.
- HARSAN, H.; HADJSAID, N.; PRUVOT, P. Cyclic security analysis for security constrained optimal power flow. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 12, n. 2, p. 948–953, maio 1997. Disponível em: <<https://doi.org/10.1109/59.589787>>.
- HAYKIN, S. O. **Neural Networks and Learning Machines (3rd Edition)**. Pearson, 2008. ISBN 0131471392. Disponível em: <<https://www.xarg.org/ref/a/0131471392/>>.
- HORNIK, K. Approximation capabilities of multilayer feedforward networks. **Neural Networks**, Elsevier BV, v. 4, n. 2, p. 251–257, 1991. Disponível em: <[https://doi.org/10.1016/0893-6080\(91\)90009-t](https://doi.org/10.1016/0893-6080(91)90009-t)>.

- ISERLES, A. Numerical recipes in c—the art of scientific computing, by w. h. press, b. p. flannery, s. a. teukolsky and w. t. vetterling. pp 735. £27·50. 1988. ISBN 0-521-35465-x (cambridge university press). **The Mathematical Gazette**, Cambridge University Press (CUP), v. 73, n. 464, p. 167–170, jun. 1989. Disponível em: <<https://doi.org/10.2307/3619708>>.
- ISODA, H.; SATO, Y. On-line load dispatching control with security constraints at the tohoku electric power company. **IEEE Transactions on Power Apparatus and Systems**, Institute of Electrical and Electronics Engineers (IEEE), PAS-104, n. 6, p. 1307–1314, jun. 1985. Disponível em: <<https://doi.org/10.1109/tpas.1985.319149>>.
- KINGMA, D. P.; BA, J. **Adam: A Method for Stochastic Optimization**. 2017.
- KIRA, K.; RENDELL, L. A. A practical approach to feature selection. In: **Machine Learning Proceedings 1992**. Elsevier, 1992. p. 249–256. Disponível em: <<https://doi.org/10.1016/b978-1-55860-247-2.50037-1>>.
- KLUYVER, T. et al. Jupyter notebooks – a publishing format for reproducible computational workflows. In: LOIZIDES, F.; SCHMIDT, B. (Ed.). **Positioning and Power in Academic Publishing: Players, Agents and Agendas**. [S.l.], 2016. p. 87 – 90.
- KODSI, S. K. M.; CANIZARES, C. A. Application of a stability-constrained optimal power flow to tuning of oscillation controls in competitive electricity markets. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 22, n. 4, p. 1944–1954, nov. 2007. Disponível em: <<https://doi.org/10.1109/tpwrs.2007.907359>>.
- KOHAVI, R.; JOHN, G. H. Wrappers for feature subset selection. **Artificial Intelligence**, Elsevier BV, v. 97, n. 1-2, p. 273–324, dez. 1997. Disponível em: <[https://doi.org/10.1016/s0004-3702\(97\)00043-x](https://doi.org/10.1016/s0004-3702(97)00043-x)>.
- KUHN, M. **Applied predictive modeling**. New York: Springer, 2013. ISBN 978-1461468486.
- KUNDUR, P. et al. Definition and classification of power system stability IEEE/CIGRE joint task force on stability terms and definitions. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 19, n. 3, p. 1387–1401, ago. 2004. Disponível em: <<https://doi.org/10.1109/tpwrs.2004.825981>>.
- LAGE, G. G.; COSTA, G. R. M. da; CANIZARES, C. A. Limitations of assigning general critical values to voltage stability indices in voltage-stability-constrained optimal power flows. In: **2012 IEEE International Conference on Power System Technology (POWERCON)**. IEEE, 2012. Disponível em: <<https://doi.org/10.1109/powercon.2012.6401277>>.
- LAGE, G. G.; FERNANDES, R. A. S.; COSTA, G. R. M. da. Functional approximation of power system steady-state voltage stability limits by artificial neural networks. **Journal of Control, Automation and Electrical Systems**, Springer Science and Business Media LLC, v. 24, n. 4, p. 544–554, maio 2013. Disponível em: <<https://doi.org/10.1007/s40313-013-0045-y>>.

_____. Optimal power flows with voltage stability constraint based on voltage stability indices and artificial neural networks. In: **2015 IEEE Eindhoven PowerTech**. IEEE, 2015. Disponível em: <<https://doi.org/10.1109/ptc.2015.7232698>>.

MARCELINO, C. G. et al. Solving security constrained optimal power flow problems: a hybrid evolutionary approach. **Applied Intelligence**, Springer Science and Business Media LLC, v. 48, n. 10, p. 3672–3690, abr. 2018. Disponível em: <<https://doi.org/10.1007/s10489-018-1167-5>>.

Mark A. Hall. **Correlation-based Feature Selection for Machine Learning**. Tese (Doutorado) — University of Waterloo, abr. 1999. Disponível em: <<https://www.cs.waikato.ac.nz/~mhall/thesis.pdf>>.

MAURER, L.; BARROSO, L. A.; CHANG, J. M. **Electricity auctions: an overview of efficient practices**. Washington D.C: World Bank, 2011. ISBN 9780821388228 9780821388242.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, Springer Science and Business Media LLC, v. 5, n. 4, p. 115–133, dez. 1943. Disponível em: <<https://doi.org/10.1007/bf02478259>>.

MILANO, F.; CANIZARES, C.; CONEJO, A. Sensitivity-based security-constrained OPF market clearing model. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 20, n. 4, p. 2051–2060, nov. 2005. Disponível em: <<https://doi.org/10.1109/tpwrs.2005.856985>>.

MILANO, F.; CANIZARES, C.; INVERNIZZI, M. Multiobjective optimization for pricing system security in electricity markets. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 18, n. 2, p. 596–604, maio 2003. Disponível em: <<https://doi.org/10.1109/tpwrs.2003.810897>>.

MONTICELLI, A.; PEREIRA, M. V. F.; GRANVILLE, S. Security-constrained optimal power flow with post-contingency corrective rescheduling. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 2, n. 1, p. 175–180, 1987. Disponível em: <<https://doi.org/10.1109/tpwrs.1987.4335095>>.

NWANKPA, C. et al. Activation functions: Comparison of trends in practice and research for deep learning. **arXiv preprint arXiv:1811.03378**, 2018.

OLDEN, J. D.; JOY, M. K.; DEATH, R. G. An accurate comparison of methods for quantifying variable importance in artificial neural networks using simulated data. **Ecological Modelling**, Elsevier BV, v. 178, n. 3-4, p. 389–397, nov. 2004. Disponível em: <<https://doi.org/10.1016/j.ecolmodel.2004.03.013>>.

PEDAMONTI, D. Comparison of non-linear activation functions for deep neural networks on mnist classification task. **arXiv preprint arXiv:1804.02763**, 2018.

PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

- PERNINGE, M.; HAMON, C. A stochastic optimal power flow problem with stability constraints—part II: The optimization problem. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 28, n. 2, p. 1849–1857, maio 2013. Disponível em: <<https://doi.org/10.1109/tpwrs.2012.2226761>>.
- Puig Arnavat, M.; Joan Carles, B. Artificial neural networks for thermochemical conversion of biomass. In: _____. **Recent Advances in Thermo-Chemical Conversion of Biomass**. United Kingdom: Elsevier, 2015. p. 133–156. ISBN 978-0-444-63289-0.
- QIU, J.; ZHAO, J.; WANG, D. Multi-objective generation dispatch considering the trade-off between economy and security. **IET Generation, Transmission & Distribution**, Institution of Engineering and Technology (IET), v. 12, n. 3, p. 633–642, nov. 2017. Disponível em: <<https://doi.org/10.1049/iet-gtd.2017.0337>>.
- RISSANEN, J. Modeling by shortest data description. **Automatica**, Elsevier BV, v. 14, n. 5, p. 465–471, set. 1978. Disponível em: <[https://doi.org/10.1016/0005-1098\(78\)90005-5](https://doi.org/10.1016/0005-1098(78)90005-5)>.
- ROALD, L.; ANDERSSON, G. Chance-constrained ac optimal power flow: Reformulations and efficient algorithms. **IEEE Transactions on Power Systems**, v. 33, n. 3, p. 2906–2918, 2018.
- ROSEHART, W. Optimal power flows incorporating network stability. In: **2002 IEEE Power Engineering Society Winter Meeting. Conference Proceedings (Cat. No.02CH37309)**. IEEE, 2002. Disponível em: <<https://doi.org/10.1109/pesw.2002.985181>>.
- ROSSUM, G. V.; DRAKE, F. L. **Python 3 Reference Manual**. Scotts Valley, CA: CreateSpace, 2009. ISBN 1441412697.
- SEYDEL, R. **Practical bifurcation and stability analysis: from equilibrium to chaos**. 2nd. ed. New York: Springer, 1994. 407 p. ISBN 0387943161.
- SEYDEL, R. U. **Practical Bifurcation and Stability Analysis**. [S.l.: s.n.], 2009. ISBN 9781441917409.
- SHAIKH, F. et al. Blackout mitigation of voltage stability constrained transmission corridors through controlled series resistors. **Recent Advances in Electrical & Electronic Engineering (Formerly Recent Patents on Electrical & Electronic Engineering)**, Bentham Science Publishers Ltd., v. 11, n. 1, jan. 2018. Disponível em: <<https://doi.org/10.2174/2352096510666171108160930>>.
- SIBI, P.; JONES, S. A.; SIDDARTH, P. Analysis of different activation functions using back propagation neural networks. **Journal of theoretical and applied information technology**, v. 47, n. 3, p. 1264–1268, 2013.
- SIMPSON-PORCO, J. W.; DÖRFLER, F.; BULLO, F. Voltage collapse in complex power grids. **Nature Communications**, Springer Science and Business Media LLC, v. 7, n. 1, fev. 2016. Disponível em: <<https://doi.org/10.1038/ncomms10790>>.

- SOMASUNDARAM, P.; KUPPUSAMY, K.; DEVI, R. K. Evolutionary programming based security constrained optimal power flow. **Electric Power Systems Research**, Elsevier BV, v. 72, n. 2, p. 137–145, dez. 2004. Disponível em: <<https://doi.org/10.1016/j.epsr.2004.02.006>>.
- SOUSA, V. A. de; BAPTISTA, E. C.; COSTA, G. R. M. da. Fluxo de potência ótimo reativo via método da função lagrangiana barreira modificada. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, FapUNIFESP (SciELO), v. 19, n. 1, p. 83–92, mar. 2008. Disponível em: <<https://doi.org/10.1590/s0103-17592008000100008>>.
- SPEARMAN, C. The proof and measurement of association between two things. **The American Journal of Psychology**, JSTOR, v. 15, n. 1, p. 72, jan. 1904. Disponível em: <<https://doi.org/10.2307/1412159>>.
- STOTT, B.; ALSAÇ, O. Optimal power flow: Basic requirements for real-life problems and their solutions. In: **SEPOPE XII Symposium, Rio de Janeiro, Brazil**. [S.l.: s.n.], 2012. v. 11.
- STOTT, B.; ALSAC, O.; MONTICELLI, A. Security analysis and optimization. **Proceedings of the IEEE**, Institute of Electrical and Electronics Engineers (IEEE), v. 75, n. 12, p. 1623–1644, 1987. Disponível em: <<https://doi.org/10.1109/proc.1987.13931>>.
- TEEPARTHI, K.; KUMAR, D. V. Multi-objective hybrid PSO-APO algorithm based security constrained optimal power flow with wind and thermal generators. **Engineering Science and Technology, an International Journal**, Elsevier BV, v. 20, n. 2, p. 411–426, abr. 2017. Disponível em: <<https://doi.org/10.1016/j.jestch.2017.03.002>>.
- VANDERBEI, R. J. **LOQO User's Manual – Version 4.05**. Princeton, New Jersey, United State, 2006. Disponível em: <<https://vanderbei.princeton.edu/tex/loqo/loqo405.pdf>>.
- VENKATASUBRAMANIAN, V.; SCHATTLER, H.; ZABORSKY, J. Dynamics of large constrained nonlinear systems—a taxonomy theory [power system stability]. **Proceedings of the IEEE**, Institute of Electrical and Electronics Engineers (IEEE), v. 83, n. 11, p. 1530–1561, 1995. Disponível em: <<https://doi.org/10.1109/5.481633>>.
- WANG, J.; YU, Q. The preventive measure of power system blackout considering the thermal stability and voltage stability. **IOP Conference Series: Earth and Environmental Science**, IOP Publishing, v. 446, p. 042039, mar. 2020. Disponível em: <<https://doi.org/10.1088/1755-1315/446/4/042039>>.
- WEN, Y. et al. Enhanced security-constrained OPF with distributed battery energy storage. **IEEE Transactions on Power Systems**, Institute of Electrical and Electronics Engineers (IEEE), v. 30, n. 1, p. 98–108, jan. 2015. Disponível em: <<https://doi.org/10.1109/tpwrs.2014.2321181>>.
- WITTEN, I. H. **Data mining : practical machine learning tools and techniques**. Cambridge, MA: Morgan Kaufmann Publisher, 2017. ISBN 978-0-12-804291-5.

WOSIAK, A.; ZAKRZEWSKA, D. Integrating correlation-based feature selection and clustering for improved cardiovascular disease diagnosis. **Complexity**, Hindawi Limited, v. 2018, p. 1–11, out. 2018. Disponível em: <<https://doi.org/10.1155/2018/2520706>>.

XU, B.; HUANG, R.; LI, M. Revise saturated activation functions. **arXiv preprint arXiv:1602.05980**, 2016.

XU, B. et al. Empirical evaluation of rectified activations in convolutional network. **arXiv preprint arXiv:1505.00853**, 2015.

ZHANG, G.; PATUWO, B. E.; HU, M. Y. Forecasting with artificial neural networks:. **International Journal of Forecasting**, Elsevier BV, v. 14, n. 1, p. 35–62, mar. 1998. Disponível em: <[https://doi.org/10.1016/s0169-2070\(97\)00044-7](https://doi.org/10.1016/s0169-2070(97)00044-7)>.