

UNIVERSIDADE DE CAXIAS DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

MAIKON DEL RÉ PERIN

***DEEP RESERVOIR COMPUTING* APLICADO NA PREVISÃO DO PREÇO DE
ENERGIA ELÉTRICA NO MERCADO *SPOT***

BENTO GONÇALVES

2019

MAIKON DEL RÉ PERIN

***DEEP RESERVOIR COMPUTING APLICADO NA PREVISÃO DO PREÇO DE
ENERGIA ELÉTRICA NO MERCADO SPOT***

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade de Caxias do Sul, como requisito à obtenção do grau de Mestre em Engenharia de Produção.

Orientador Prof. Dr. Alexandre Mesquita.

BENTO GONÇALVES

2019

Dados Internacionais de Catalogação na Publicação (CIP)
Universidade de Caxias do Sul
Sistema de Bibliotecas UCS - Processamento Técnico

P445d Perin, Maikon Del Ré

Deep Reservoir Computing aplicado na previsão do preço de energia elétrica no mercado *spot* / Maikon Del Ré Perin. – 2019.

80 f. : il. ; 30 cm

Dissertação (Mestrado) - Universidade de Caxias do Sul, Programa de Pós-Graduação em Engenharia de Produção, 2019.

Orientação: Alexandre Mesquita.

1. Inteligência artificial. 2. Redes neurais (Computação). 3. Energia elétrica. 4. Preços. I. Mesquita, Alexandre, orient. II. Título.

CDU 2. ed.: 004.8

Catalogação na fonte elaborada pela(o) bibliotecária(o)
Carolina Machado Quadros - CRB 10/2236

MAIKON DEL RÉ PERIN

***DEEP RESERVOIR COMPUTING APLICADO NA PREVISÃO DO PREÇO DE
ENERGIA ELÉTRICA NO MERCADO SPOT***

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção da Universidade de Caxias do Sul, como requisito parcial à obtenção do grau de Mestre em Engenharia de Produção.

Aprovado em 19/12/2019

Banca Examinadora

Prof. Dr. Alexandre Mesquita
Universidade de Caxias do Sul – UCS

Prof. Dr. Elcio Hideiti Shiguemori
Instituto de Estudos Avançados - IEAv

Prof. Dr. Leonardo Dagnino Chiwiacowsky
Universidade de Caxias do Sul – UCS

Prof. Dr. Odacir Deonísio Gracioli
Universidade de Caxias do Sul – UCS

*Dedico este trabalho à minha
família pelo apoio durante mais
esta etapa da minha vida.*

AGRADECIMENTOS

Primeiramente, agradeço a Deus por tudo.

Agradeço a minha família, por ter sempre me ajudado nas horas que precisei, pelo apoio, pela compreensão e pela força para concluir mais essa etapa da minha vida.

Ao professor Dr. Alexandre Mesquita, pela sua orientação, dedicação, compreensão e paciência. Também, ao Prof. Dr. Elcio Hideiti Shiguemori, ao Prof. Dr. Leonardo Dagnino Chiwiacowsky e ao Prof. Dr. Odacir Deonísio Graciolli pela disponibilidade em avaliar este trabalho.

À Universidade de Caxias do Sul, especialmente ao Reitor Dr. Evaldo Antonio Kuiava, pela oportunidade da bolsa de mestrado disponibilizada que foi muito importante nesta etapa da minha vida.

*O êxito da vida não se mede pelo caminho que
você conquistou, mas sim pelas dificuldades
que superou no caminho.*

Abraham Lincoln

RESUMO

O sistema elétrico brasileiro é referência mundial pelas suas particularidades na forma de geração, transmissão e distribuição de energia. A matriz energética é composta em sua maioria por usinas hidrelétricas e termelétricas, embora tenha-se visto um acentuado aumento de fontes eólicas e solares nos últimos anos. O despacho das usinas hidrelétricas e termelétricas é efetuado de forma centralizada pelo ONS. São utilizados os *softwares* NEWAVE e DECOMP para otimização visando o menor custo total em todo horizonte de estudo. Além do despacho de cada usina hídrica e térmica, esses *softwares* divulgam o preço de liquidação das diferenças, utilizado pela Câmara de Comercialização de Energia Elétrica para valorar o preço de energia no curto prazo. Esse preço também é utilizado para negociações bilaterais entre agentes do mercado, seja para *trading* nas comercializadoras ou compra e venda de energia elétrica para consumidores. Os agentes do mercado utilizam esses *softwares* para projetar o preço de energia elétrica de curto prazo. Todavia, os *softwares* necessitam de alto processamento computacional para efetuar a otimização, além do cálculo do despacho ser bastante moroso. Dessa forma, este trabalho apresenta um modelo computacional utilizando *Deep Reservoir Computing* para projeção do preço de energia elétrica do mercado *spot*. O trabalho demonstra que a *Deep Reservoir Computing* pode ser utilizada como ferramenta de auxílio na projeção do preço de energia elétrica no mercado de curto prazo. O modelo proposto foi desenvolvido no *software* Matlab e, para os experimentos realizados, obteve resultados melhores que redes neurais mais populares, como a Perceptron Multicamadas, onde a correlação foi 3,08% superior na *Deep Reservoir Computing* além do erro percentual médio absoluto ser 8,8% inferior.

Palavras-chave: *Reservoir Computing*. Previsão PLD. Redes Neurais Artificiais. Comercialização de Energia Elétrica. Preço de Energia Elétrica.

ABSTRACT

The Brazilian electric system is a world reference for its particularities in the form of energy generation, transmission and distribution. The energy matrix is mostly composed of hydroelectric and thermoelectric plants, having seen a sharp increase in wind and solar sources in recent years. The dispatch of hydroelectric and thermoelectric power plants is performed centrally by ONS. The softwares NEWAVE and DECOMP is used for optimization aiming the lowest total cost over the entire study horizon. In addition to the dispatch of each hydro and thermal plant, these softwares disclose the liquidation price of the differences, used by the Electric Energy Trading Chamber to value the short-term energy price. This price is also used for bilateral negotiations between market agents, either for trading or buying and selling electricity to consumers. Market players use this software to project short-term electricity prices. However, the software needs high computational processing to perform the optimization, and the dispatch calculation is very time consuming. Thus, this paper presents a computational model using Deep Reservoir Computing to project the spot market electricity price. This work demonstrates that Deep Reservoir Computing can be used as a support tool for projecting electricity prices in the short term market. The proposed model was developed in Matlab software and, for the experiments performed, obtained better results than more popular neural networks, such as Multilayer Perceptron, where the correlation was 3.08% higher in Deep Reservoir Computing in addition to the absolute mean percentage error being 8,8% lower.

Keywords: Reservoir Computing. PLD forecast. Artificial neural networks. Energy Trading. Price of Electricity.

LISTA DE FIGURAS

Figura 1 - CMO semanal.	23
Figura 2 - Organograma do Setor Elétrico.	26
Figura 3 - Capacidade instalada por fonte em dezembro de 2018.	28
Figura 4 - Histórico de geração de energia elétrica por fonte disponibilizados pelo ONS.	29
Figura 5 - Mapa do SIN.	30
Figura 6 - Níveis dos reservatórios em % do SE/CO.	31
Figura 7 - Níveis dos reservatórios em % do S.	32
Figura 8 - Níveis dos reservatórios em % do NE.	32
Figura 9 - Níveis dos reservatórios em % do N.	32
Figura 10 - Processo de decisão de um sistema hidrotérmico.	36
Figura 11 - Curva do custo imediato.	37
Figura 12 - Curva do custo imediato e futuro.	38
Figura 13 - Curva do custo imediato e futuro.	38
Figura 14 - Custo variável unitário das usinas termelétricas despachadas pelo ONS.	39
Figura 15 - Trajetória e estados das afluições.	40
Figura 16 - Neurônio Biológico.	42
Figura 17 - Neurônio artificial.	43
Figura 18 - Principais arquiteturas de redes neurais.	43
Figura 19 - Classificação de Redes Neurais Artificiais.	44
Figura 20 - Estrutura de um <i>Reservoir Computing</i>	45
Figura 21 - Exemplo de configuração de uma <i>deep RC</i>	48
Figura 22 - Variáveis dos modelos do ONS.	49
Figura 23 - Fatores que contribuíram para o CMO da revisão 3 de abril de 2019.	50
Figura 24 - Dados históricos da ENA.	52
Figura 25 - Histograma da ENA.	53
Figura 26 - Dados históricos de Energia Armazenada.	54
Figura 27 - Histograma da Energia Armazenada.	55
Figura 28 - Dados históricos da carga no SE/CO.	55
Figura 29 - Histograma da carga.	56
Figura 30 - Dados históricos do CMO no SE/CO.	57
Figura 31 - Histograma do CMO no SE/CO.	58
Figura 32 - Pseudocódigo do <i>reservoir computing</i> para um reservatório.	60

Figura 33 - Rede Perceptron multicamadas para testes iniciais.	61
Figura 34 - CMO realizado e previsto pela Perceptron Multicamadas no treinamento.	62
Figura 35 - Previsão efetuada com dados não treinados (três maiores correlações).	62
Figura 36 - Previsão efetuada com dados não treinados (três menores EPMA).	63
Figura 37 - CMO realizado e previsto utilizado para treinamento da <i>deep RC</i>	66
Figura 38 - Previsões efetuadas da <i>deep RC</i> com dados não treinados para 7 entradas.	66
Figura 39 - Previsões efetuadas da <i>deep RC</i> com dados não treinados para 10 entradas.	68
Figura 40 - Resultado da correlação variando número de neurônios e reservatórios.	69
Figura 41 - Resultado do EPMA variando número de neurônios e reservatórios.	70
Figura 42 - Resultado da correlação variando a taxa de conectividade e o <i>leaking rate</i>	70
Figura 43 - Resultado do EPMA variando a taxa de conectividade e o <i>leaking rate</i>	71
Figura 44 - Resultado da correlação variando o raio espectral e o número de neurônios.	71
Figura 45 - Resultado do EPMA variando o raio espectral e o número de neurônios.	72
Figura 46 - Histórico dos preços médios de longo prazo de energia elétrica convencional para o SE/CO.	73

LISTA DE QUADROS

Quadro 1 – Intervalos horários de patamares de carga diária de energia.....	36
---	----

LISTA DE TABELAS

Tabela 1 - Geração de energia elétrica por submercado e fonte em 2018.....	29
Tabela 2 - Correlação entre as variáveis do modelo.....	52
Tabela 3 - Dados estatísticos da variável ENA.	53
Tabela 4 - Dados estatísticos da variável Energia Armazenada.....	54
Tabela 5 - Dados estatísticos da variável carga no SE/CO.....	56
Tabela 6 - Dados estatísticos do CMO no SE/CO.....	57
Tabela 7 - Maiores Correlações da Perceptron Multicamadas com dados não treinados.	63
Tabela 8 - Menores EPMA da Perceptron Multicamadas com dados não treinados.	63
Tabela 9 - Configuração da <i>deep RC</i> para teste com 7 variáveis.....	65
Tabela 10 - Resultados da <i>deep RC</i> para 7 variáveis de entrada com dados não treinados.	67
Tabela 11 - Resultados da <i>deep RC</i> para 10 variáveis de entrada com dados não treinados. ..	69
Tabela 12 - Cenários de compra de energia elétrica de curto e longo prazo.....	73
Tabela 13 - Resultado do cenário de compra de energia no CP com o PLD realizado.	74

LISTA DE ABREVIATURAS E SIGLAS

ACL	Ambiente de Contratação Livre
ACR	Ambiente de Contratação Regulado
ANEEL	Agência Nacional de Energia Elétrica
ARIMA	Autoregressive integrated Moving Average
CCEE	Câmara de Comercialização de Energia Elétrica
CEPEL	Centro de Pesquisas de Energia Elétrica
CGH	Central Geradora Hidrelétrica
CMO	Custo Marginal de Operação
CMSE	Comitê de Monitoramento do Sistema Elétrico
CNPE	Conselho Nacional de Política Energética
CP	Curto Prazo
CVU	Custo Variável Unitário
ENA	Energia Natural Afluente
EPE	Empresa de Pesquisa Energética
EPMA	Erro Percentual Médio Absoluto
LP	Longo Prazo
MME	Ministério de Minas e Energia
MW	Megawatt
MWmed	Megawatt Médios
N	Norte
NE	Nordeste
ONS	Operador Nacional do Sistema
PCH	Pequena Central Hidrelétrica
PLD	Preço da Liquidação das Diferenças
PMO	Programa Mensal de Operação
RC	<i>Reservoir Computing</i>
S	Sul
SE/CO	Sudeste/Centro-Oeste
SIN	Sistema Interligado Nacional
UHE	Usina Hidrelétrica
UTE	Usina Termelétrica

SUMÁRIO

1	INTRODUÇÃO	16
1.1	CONTEXTUALIZAÇÃO	17
1.2	JUSTIFICATIVA	19
1.2.1	Justificativa teórica	19
1.2.2	Justificativa prática	22
1.3	QUESTÃO DE PESQUISA	24
1.4	OBJETIVOS	24
1.4.1	Objetivo geral	24
1.4.2	Objetivos específicos.....	25
2	FUNDAMENTAÇÃO TEÓRICA.....	26
2.1	SETOR ELÉTRICO NACIONAL	26
2.1.1	Instituições do Setor Elétrico.....	26
2.1.2	Matriz Energética Brasileira	28
2.1.3	Sistema Interligado Nacional	30
2.1.4	Tipos de Mercado de Eletricidade	32
2.1.5	Ambientes de Contratação	33
2.1.6	Modelos de despacho.....	34
2.1.7	Planejamento de Operação do Sistema Hidrotérmico.....	35
2.2	REDES NEURAIS ARTIFICIAIS	41
2.2.1	Neurônio Biológico	42
2.2.2	Neurônio Artificial	42
2.2.3	<i>Reservoir Computing</i>.....	44
2.2.3.1	<i>Deep Reservoir Computing</i>	47
3	MÉTODO.....	49
3.1	ESCOLHA DAS VARIÁVEIS DE ENTRADA PARA O MODELO.....	49
3.2	ANÁLISE E PROCESSAMENTO DOS DADOS	51
3.3	CONFIGURAÇÃO DA <i>DEEP RESERVOIR COMPUTING</i>	59
3.4	VALIDAÇÃO	60

4	RESULTADOS	61
4.1	RESULTADOS DA REDE NEURAL PERCEPTRON MULTICAMADA.....	61
4.2	RESULTADOS DA REDE NEURAL <i>DEEP RC</i>	64
4.2.1	<i>Deep RC</i> com 7 variáveis de entrada	64
4.2.2	<i>Deep RC</i> com 10 variáveis de entrada	68
4.2.3	Análises com diferentes parâmetros da <i>deep RC</i>	69
4.3	CENÁRIO DE COMPRA OU VENDA DE ENERGIA ELÉTRICA ATRAVÉS DA CURVA PREVISTA PELA <i>DEEP RC</i>	72
5	CONCLUSÃO	75
5.1	TRABALHOS FUTUROS.....	77
	REFERÊNCIAS	78

1 INTRODUÇÃO

O sistema elétrico mundial e, principalmente o brasileiro, passou por diversas modificações referente aos mecanismos regulatórios e operacionais nas últimas décadas. Ao longo da década de 1930, os rios eram propriedade dos municípios em que estavam localizados, bem como grande parte deles pertenciam à união federativa. Nessa época, a intervenção estatal era forte, o que resultou no controle tanto da geração de energia, quanto da transmissão, comercialização e distribuição para o varejo comercial, residencial e industrial (RODRIGUES, 2009).

Na década de 70, o governo aprovou a Lei nº 5.655/71, onde foi definido o custo do serviço, que englobava os custos de geração, transmissão e distribuição em nível nacional. Devido às grandes diferenças de custos existentes nas regiões do país, muitas empresas possuíam resultados negativos, o que forçou o governo a repassar o saldo positivo das empresas superavitárias para as empresas deficitárias, além de estabelecer tarifas para determinadas classes de consumo.

No início da década de 90, esse modelo estatal e verticalizado já apresentava fortes indícios de estagnação e com falta de investimento provenientes de recursos públicos. A dívida externa crescia a cada ano e dessa forma, na ótica do governo, não havia outra maneira a não ser iniciar processos de privatizações para atrair investidores estrangeiros. Com a pressão de grupos de investidores, o governo iniciou processos de melhorias nos mecanismos e operacionalizações no setor elétrico brasileiro, além de privatizações, como forma de impulsionar e revitalizar o crescente mercado elétrico brasileiro (FONSECA, 2013).

Dessa maneira, em 1993, com a Lei nº 8.631/93, o governo extinguiu a equalização tarifária. Posteriormente, em 1995, estimulou a iniciativa privada para participação em empreendimentos geradores de energia elétrica. Com essa lei, o governo deu um grande passo para o mercado livre de energia, que instituiu mecanismos, para determinados consumidores, para comprar energia de forma livre e escolher seu gerador no Sistema Interligado Nacional (SIN). A partir desse momento, a participação estatal se limitava em exercer funções de fiscalização, regulação e mediação entre partes. As funções principais eram exercidas pela iniciativa privada. Na mesma década, foi criada a Agência Nacional de Energia Elétrica (ANEEL), o Operador Nacional do Sistema Elétrico (ONS) e um ambiente para os registros de compra e venda de energia elétrica, antigamente chamado de Mercado Atacadista de Energia (MAE) e hoje conhecido como Câmara de Comercialização de Energia Elétrica (CCEE). Durante os anos de 2003 e 2004, como forma de modernizar os mecanismos e operações do

sistema elétrico, o governo cria a Empresa de Pesquisa Energética (EPE), como forma de planejar o setor elétrico a longo prazo. Também, foi criado um Comitê de Monitoramento do Setor Elétrico (CMSE) com função de avaliar a segurança do suprimento de energia elétrica no SIN (FONSECA, 2013).

Com o sistema elétrico nacional remodelado, novas possibilidades e desafios surgiram para os setores de geração, transmissão, comercialização e distribuição. O objetivo principal da desburocratização do setor elétrico nacional consistiu em melhorar a eficiência do setor de geração e transmissão para reduzir o preço da eletricidade. Uma das principais variáveis do novo modelo do setor elétrico é o preço da energia. O setor de *middle office* de comercializadoras, responsável pelas decisões de contratação de energia no mercado livre de energia, desenvolve e modela ferramentas como forma de prever o preço da energia elétrica. Assim, saber modelar as séries temporais de grandezas relevantes para o setor elétrico, como forma de encontrar uma tendência futura de preços de energia, é necessário para as tomadas de decisão desse setor.

1.1 CONTEXTUALIZAÇÃO

Com o novo modelo do setor elétrico brasileiro, passando de um modelo centralizado e rígido para um modelo liberal e flexível, onde possui consumidores que podem escolher o fornecedor de energia, existem dois ambientes de contratação: o Ambiente de Contratação Regulado (ACR) e o Ambiente de Contratação Livre (ACL). No ACR, as distribuidoras compram energia de longo prazo para os consumidores cativos através de leilões conduzidos pela ANEEL. Já no ACL, as transações são feitas de forma bilateral entre os consumidores livres, geradores e comercializadores.

O ACL possui o preço das liquidações de diferenças (PLD), também conhecido como preço “*spot*”, utilizado para valorar as transações entre montantes registrados e verificados no sistema da CCEE no curto prazo. Além disso, ele é utilizado como referência para compra de energia elétrica no mercado de curto prazo acrescido de um *spread* entre as transações dos agentes do mercado. O PLD é originado a partir do Custo Marginal de Operação (CMO), porém, com valores limitando seu máximo e mínimo, estabelecidos pela ANEEL, além de outras alterações. O CMO semanal é obtido pelo *software* chamado NEWAVE, fornecido pelo Centro de Pesquisas de Energia Elétrica (CEPEL). O NEWAVE utiliza programação estocástica dinâmica como forma de encontrar o valor do CMO, pois as decisões presentes afetam o custo futuro e a otimização geral do sistema elétrico. Esse programa projeta o CMO para as próximas

semanas até o fim do mês. Como variáveis de entrada, o NEWAVE utiliza dados oferecidos pelo ONS para estabelecer o valor do CMO (FONSECA, 2013).

Juntamente com o NEWAVE, diversas comercializadoras utilizam o *software*, também da CEPEL, chamado DECOMP. Este *software* é um modelo de otimização para o horizonte de até 12 meses, com resultados semanais. Ele apresenta as vazões dos rios previstas em um modelo de árvore de possibilidades. A disposição dos geradores é individualizada de forma a obter o melhor despacho das usinas hídricas e térmicas (FONSECA, 2013).

Apesar de existirem *softwares* avançados para previsão do preço de energia elétrica, existem muitos fatores que colaboram para a sua volatilidade, tais como a incerteza da carga de energia no SIN, a forte dependência das chuvas para geração de energia elétrica e a impossibilidade de armazenamento de energia para venda no futuro (QUEIROZ, 2007). Desta maneira, os métodos de previsão do preço de energia elétrica se tornaram muito importantes com o desenvolvimento do setor elétrico brasileiro nos últimos anos. Geradores e comercializadores de energia elétrica necessitam estimar o valor do preço de energia elétrica do mercado *spot* de maneira precisa, como forma de estabelecer os contratos de compra e venda de energia para maximizar os ganhos no mercado.

Os *softwares* NEWAVE e DECOMP estão disponíveis com um determinado custo para usuários e agentes que atuam no setor elétrico. Esses *softwares* precisam ser utilizados por pessoas que analisam o mercado energético diariamente, modelem o sistema elétrico nos *softwares* e interpretem os dados para montar um diagrama decisório de compra e venda de energia elétrica no momento correto.

Nas comercializadoras e geradoras de energia elétrica, os setores podem ser definidos como *front office*, *back office* e *middle office*. O *front office* tem como função a negociação de compra e venda de energia elétrica no mercado. O *back office* executa as funções de registro das compras e vendas, acompanha as garantias dos contratos e faz todo o processo de controladoria dos montantes de energia para registro. Por outro lado, o *middle office*, tem como principal função a avaliação dos riscos do portfólio de contratos de compra e venda. Também, o setor analisa cada tomada de decisão de contratação, com o apoio das tendências de mercado e preços do setor elétrico nacional (MOROZOWSKI, 2009).

Grandes comercializadoras de energia necessitam de um *middle office* para análise da conjuntura do mercado energético, e que mostre para a equipe dos outros setores qual é o caminho com menor risco para maximizar os ganhos. Esse setor faz uso de *softwares* de previsão, tais como o NEWAVE e DECOMP. Porém, se faz necessário o uso de ferramentas para minimizar os erros de projeções fornecidas por ambos *softwares* ou para se obter projeções

satisfatórias com maior rapidez. Uma alternativa é o uso de redes neurais artificiais para projetar o preço de energia elétrica do mercado *spot* como forma de auxiliar, ou até mesmo melhorar as estimativas, nas comercializadoras e geradoras de energia elétrica (RODRIGUES, 2009).

1.2 JUSTIFICATIVA

Nesta seção, são apresentadas as justificativas para este trabalho. Como forma de melhor explicitar o trabalho proposto, foi dividido em duas categorias, a justificativa teórica e a justificativa prática.

1.2.1 Justificativa teórica

Diversas técnicas e pesquisas já foram elaboradas para previsão do preço do custo marginal de operação. Como mostra Fonseca (2013), os modelos NEWAVE e DECOMP utilizam uma grande quantidade de variáveis e que demanda um tempo elevado para processamento, além da necessidade de conhecimento específico sobre os *softwares*. Dessa forma, muitas vezes inviabiliza a utilização dos modelos onde é necessária uma rápida decisão, como no caso de leilões de energia. Fonseca (2013) faz uso de modelos híbridos para prever o valor do CMO, com o uso de NEWAVE e DECOMP para estimar o preço inicial e, posteriormente, o uso de redes neurais artificiais para ajustes da previsão mensal. Foi proposto pelo autor o uso de diversas redes neurais, como por exemplo, *feed-forward* simples e em cascata, redes com atrasos e redes recorrentes. Esses modelos ainda necessitam do auxílio do NEWAVE e DECOMP para efetuar a previsão. Assim, o tempo computacional dos *softwares*, somado ao tempo de execução da rede neural, torna o modelo completo inviável quando se deseja avaliar cenários rapidamente.

Um modelo de previsão proposto por Wan et al. (2014) aborda um sistema híbrido de redes neurais por *Extreme Learning Machines* (ELM), largamente utilizado para métodos de regressão, e métodos probabilísticos, no mercado australiano de eletricidade para previsão do custo horário. Esse método mostrou bons resultados, como por exemplo, valores de erro médio de 3% ou menores para diversos modelos avaliados. Para esse modelo, o autor utilizou somente a demanda e os preços do mercado como variáveis de entrada. Além disso, o mercado australiano de energia possui sua matriz energética baseada em termelétricas de carvão e gás natural. Geração de energia hidrelétrica, juntamente com energias renováveis, são fontes

minoritárias na matriz energética da Austrália, se diferenciando do mercado brasileiro, que possui larga utilização e despacho de fontes hídricas.

Conforme Rodrigues (2009), também foi utilizado redes neurais artificiais para previsão do preço *spot*. O autor destaca a alta volatilidade dos preços de energia elétrica no mercado *spot*, sendo necessário um melhor entendimento do mercado de energia para melhor previsão e consequentes ações a serem tomadas por parte dos agentes do setor. Como variáveis de entrada das redes neurais modeladas, foram utilizados dados de carga, geração (hidrelétrica de Itaipú e restantes, termelétricas, nuclear e eólicas), preços de seis semanas anteriores, nível de armazenamento dos reservatórios, energia natural afluyente, custo dos combustíveis, operação das usinas termelétricas e intercâmbios de energia internos do SIN e internacional. Para treinamento, foi utilizado o algoritmo de Levenberg Marquardt. Como funções de ativação, foi utilizada a Tan-Sigmoid na primeira e segunda camada da rede neural e Purelin (ativação linear) na terceira camada oculta e na camada de saída. Para cada cenário proposto, Rodrigues (2009) utilizou 3 camadas ocultas, porém, variando o número de neurônios. Das 35.548 redes neurais geradas, apenas 83 foram consideradas viáveis pelo autor. Como resultado, para a região Sudeste/Centro-Oeste, o modelo apresentado errou de 20 a 70 preços num total de 435. Nesse modelo, o autor utilizou 16 variáveis de entrada. Apesar do modelo apresentar baixo erro nos resultados da previsão, muitas dessas variáveis são difíceis de prever, pois são resultados de outras variáveis também utilizadas na entrada do modelo. Consequentemente, cenários de médio e longo prazo se tornam difíceis de serem modelados, o que aumenta a incerteza do modelo total.

Queiroz (2007) desenvolveu um modelo com redes neurais para previsão do CMO. O autor utilizou o *software* STATISTICA como auxílio na construção da rede. A melhor rede modelada para obter o CMO foi uma Perceptron Multicamadas com 27 entradas, tendo 27 neurônios nessa camada, 15 neurônios na camada oculta e 3 neurônios na camada de saída. Entre as 27 variáveis de entrada, com o uso de projeto de experimentos, foi identificado que o nível dos reservatórios do submercado Sudeste/Centro-Oeste e a Energia Afluyente também do submercado Sudeste/Centro-Oeste foram as variáveis que mais influenciam a saída da rede neural. Queiroz (2007) destaca a elevada demanda computacional e o tempo na execução de *softwares* como o NEWAVE para previsão do CMO. Afirma também, sobre a necessidade da criação de modelos que consigam reduzir o tempo para previsão dos custos e da demanda computacional com o uso de redes neurais ou modelos similares. Para esse modelo, também existe a dificuldade de modelar as 27 variáveis de entrada para cenários de médio e longo prazo, como no caso de Rodrigues (2009).

Como mostrado por Pereira (2016), foram utilizadas quatro técnicas para previsão do preço do mercado de curto prazo: ARIMA, rede neural recorrente, rede neural direta com 'n' primeiros *lags* e rede neural direta com seleção de *lags*. Cada modelo utilizou como entrada a geração hidráulica média, geração térmica média, carga de energia média, quantidade de água armazenada em reservatório transformada em energia e quantidade de água que entra em reservatório transformada em energia, conhecido como energia natural afluente. Pereira (2016) efetuou a previsão do preço para cada subsistema do SIN e para cada patamar de carga. É explicado também que as redes neurais têm como principal característica a adaptabilidade para aprendizado dos dados para previsão de séries temporais envolvendo sistemas não lineares. Como mostrado no trabalho, as redes neurais foram as principais ferramentas para previsão do PLD. O modelo ARIMA foi utilizado como forma de comparação com os modelos de redes neurais testadas. Foi identificado que o modelo ARIMA apresentou desempenho inferior aos modelos de redes neurais em diversos cenários. Para o submercado Sudeste/Centro-Oeste, o modelo ARIMA apresentou maior erro absoluto enquanto a rede direta com seleção de *lags* apresentou menor erro absoluto. Como relatado no trabalho de Pereira (2016), o mercado de energia brasileiro é singular, não se assemelhando com os mercados norte-americano ou europeu. Dessa forma, novas técnicas e análises tornam os trabalhos de previsão do preço de energia no mercado brasileiro relevantes. Nesse trabalho, as variáveis geração hidráulica e térmica média possuem grande correlação com o valor do preço (se comparado com as outras variáveis), pois, basicamente, é a relação delas que definem o preço de energia elétrica. Todavia, esse modelo se assemelha ao de Rodrigues (2009), onde as variáveis de geração são definidas pelas outras variáveis de entrada do modelo, como é elaborado no programa de despacho do ONS. No NEWAVE/DECOMP, a definição do montante de geração programado é o resultado do modelo. Colocando tais variáveis como entrada, os cenários de médio e longo prazo podem ser influenciados por essas variáveis.

Diversos estudos já foram realizados utilizando a RC como método de previsão. O trabalho de Galle e Valença (2013) utilizou a RC para previsão da potência do vento de dois dias a frente para ser utilizada em parques eólicos. Os autores utilizam o modelo *echo state network* com apenas um reservatório e, para comparação, implementaram a rede neural Perceptron Multicamada. O erro médio absoluto normalizado para a RC foi de 18,02%, enquanto para a Perceptron foi de 24,47%. Isso mostra que a RC obteve um desempenho superior para a previsão da potência do vento. Também, o trabalho de Bezerra (2016) mostra a implementação de RC simples e com hierarquia para a previsão de vazões médias diárias. O autor também utilizou a rede neural Perceptron Multicamada para efetuar comparações. Os

resultados mostraram que a RC simples sem hierarquia obteve resultados melhores. O erro percentual médio absoluto da previsão de vazões médias diárias no aproveitamento hidroelétrico de Tucuruí, utilizando *deep* RC, foi de 8,54%, enquanto a RC obteve 9%, e a Perceptron Multicamada obteve 12,33%. Isso demonstra que a RC obteve uma performance superior se comparado com a rede neural Perceptron Multicamada.

Como mostrado, há diversos trabalhos onde demonstram que a rede neural *deep* RC possui resultados melhores se comparado com modelos de rede neural mais populares, como a Perceptron Multicamadas. Além disso, como mencionado por Bezerra (2016), a rede neural RC possui treinamento apenas na camada de saída, tornando o processo mais ágil se comparado com outros modelos de redes neurais que fazem uso da técnica *Backpropagation*.

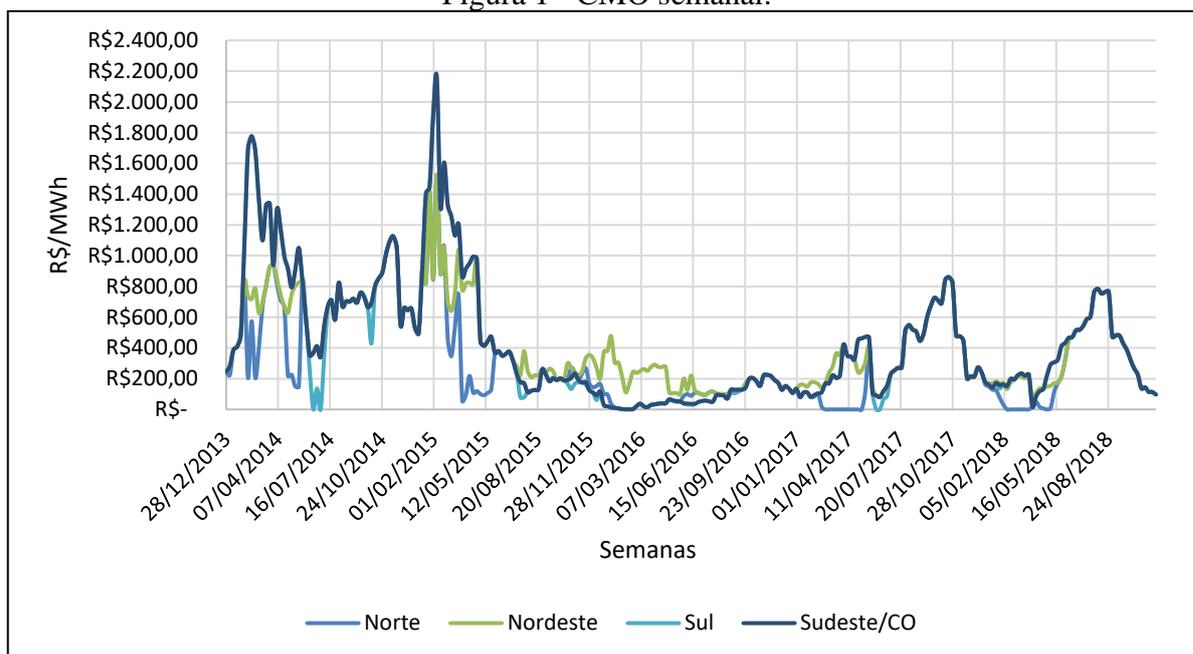
1.2.2 Justificativa prática

O mercado livre de energia está obtendo destaque a cada ano, pelos ganhos financeiros em que os consumidores, autoprodutores, comercializadores e geradores encontram em comprar ou vender energia, dependendo de sua classe, no mercado elétrico brasileiro. Com isso, o setor elétrico se torna cada vez mais competitivo, necessitando de ferramentas como forma de prever tendências de preços do mercado, prevenindo possíveis perdas econômicas por partes das classes que compõem o setor elétrico.

Comercializadoras de energia elétrica são a classe de agentes que mais necessitam conhecer as tendências do preço de energia elétrica, pelo fato de possuírem em seus portfólios de contratos, as compras e vendas de energia entre consumidores, geradores e operações de *trading*. Cada vez mais agentes comercializadores possuem setores de *middle office* com pessoas especializadas em analisar as tendências de mercado utilizando ferramentas computacionais, para avaliar os riscos de operações entre compra e venda de energia. Com *softwares* de previsão, o setor poderá saber com menores incertezas as tendências e poderão tomar decisões com menores riscos.

As maiores incertezas do setor elétrico que possuem influência no preço de energia elétrica são a forte dependência da hidrologia para geração de energia e a demanda ou carga de energia elétrica. Nos últimos anos, como mostra a Figura 1, o CMO semanal da primeira semana de janeiro de 2014 até novembro de 2018, dos quatro submercados do setor elétrico brasileiro, mostrou grande variabilidade nos valores divulgados.

Figura 1 - CMO semanal.



Fonte: Adaptado de ONS (2019c).

O CMO atingiu seu valor mínimo de R\$ 0,00/MWh no Submercado Norte em diversas semanas de 2017 e 2018, bem como o submercado Sul em algumas semanas de 2014 e 2017. O seu valor máximo foi na semana com início em 07/02/15, no valor de R\$ 2.158,57/MWh no submercado Sul e Sudeste/Centro-Oeste (ONS, 2019c).

Para gerar o valor do CMO, o CEPEL, como informado, elaborou o *software* NEWAVE e DECOMP. Todos os setores de previsão de comercializadoras estão submetidos a modelar as variáveis que influenciam o preço da energia com o uso desses programas, e isso caracteriza um gargalo na avaliação de riscos de investimentos e de contratos, como relatado por Almeida (2012). O tempo computacional exigido por esses *softwares* é elevado. Por exemplo, o modelo NEWAVE leva, em média, 3,7 horas para gerar a função de custo futuro utilizando o sistema operacional Centos Linux 7 com 96 núcleos para processamento. Além disso, o NEWAVE e DECOMP não possuem interface gráfica, pois as variáveis de entrada e saída estão descritas em diversos arquivos de texto. Dessa forma, o mercado está exigindo uma ferramenta capaz de elaborar uma tendência com uma eficácia satisfatória de forma mais rápida, onde o responsável pela modelagem do problema saiba executar as ações e efetuar manutenções no modelo, quando necessário. Uma das maneiras de reduzir o tempo das iterações do programa é investindo em sistemas computacionais mais rápidos para executar o NEWAVE/DECOMP ou, como enfatizado por Almeida (2012), criando uma ferramenta similar onde se possa efetuar o mesmo trabalho com algumas restrições.

Diante do exposto, foi elaborada uma ferramenta computacional utilizando rede neural artificial como forma de prever o valor do preço da energia elétrica do mercado de curto prazo, ou mercado *spot*. Esta ferramenta foi elaborada com o intuito de ser utilizada no meio profissional em uma comercializadora de energia elétrica.

Como mostrado na justificativa teórica, já existem diversos trabalhos realizados na área de previsão do preço de energia elétrica utilizando redes neurais. Todavia, elas trazem modelos que são difíceis de serem aplicados no uso profissional diário, pois possuem muitas variáveis com difícil previsão para servir de entrada do modelo, como por exemplo, a geração térmica e hídrica que são consequência das outras variáveis de entrada do modelo. Assim, pesquisas e ferramentas são sempre fundamentais para mostrar novas técnicas e usos das redes neurais, e buscar o aperfeiçoamento das metodologias já relatadas. Este trabalho fez uso da rede neural chamada de *Deep Reservoir Computing*, que mescla as metodologias de *Liquid State Machines* e *Echo State Networks*. Este modelo de rede é caracterizado como uma rede neural artificial recorrente, que possui memórias e *loops* internos, largamente utilizadas para análise de séries temporais.

1.3 QUESTÃO DE PESQUISA

É possível desenvolver um modelo computacional utilizando *deep RC*, capaz de gerar previsões do preço *spot* de energia elétrica satisfatórias, com tempo de execução menor que os modelos desenvolvidos pelo CEPEL e com variáveis de entrada possíveis de serem previstas, para auxílio à tomada de decisão de compra e venda em uma comercializadora de energia elétrica?

1.4 OBJETIVOS

Nessa seção, são apresentados os objetivos geral e específicos do trabalho.

1.4.1 Objetivo geral

O objetivo geral do trabalho é desenvolver um modelo computacional utilizando a rede neural *Deep Reservoir Computing* para previsão do preço de energia elétrica brasileiro no mercado *spot*, como forma de auxiliar as tomadas de decisão de compra e venda de energia elétrica para uma comercializadora do Brasil.

1.4.2 Objetivos específicos

Do objetivo geral, derivam-se os específicos, como sendo:

- a) Estudar os conceitos e o funcionamento do mercado de energia elétrica brasileiro e redes neurais artificiais, especialmente a rede neural *Deep Reservoir Computing*;
- b) Analisar o funcionamento da operação do sistema hidrotérmico brasileiro de geração de energia e os principais modelos utilizados no setor elétrico para planejamento da operação (NEWAVE e DECOMP);
- c) Analisar as variáveis do setor elétrico como forma de escolher as que mais contribuem para previsão do preço de energia elétrica;
- d) Desenvolver um modelo computacional aplicando a rede neural *Deep Reservoir Computing* para a previsão do preço *spot* de energia elétrica semanal do submercado SE/CO;
- e) Analisar os parâmetros de configuração do modelo buscando o melhor *design* para a rede neural;
- f) Avaliar um cenário de compra e venda de energia elétrica, levando em consideração o preço de contratação de longo prazo e a previsão efetuada pelo modelo.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão abordados os tópicos referentes ao setor elétrico nacional, a matriz de energia elétrica brasileira, os modelos de mercado de energia, as divisões dos mercados no Brasil e como ocorre o despacho das usinas por ordem de mérito. Também, serão abordados tópicos referentes às redes neurais artificiais, suas principais arquiteturas bem como o conceito de *Deep Reservoir Computing* (RC) para previsão do preço de energia elétrica.

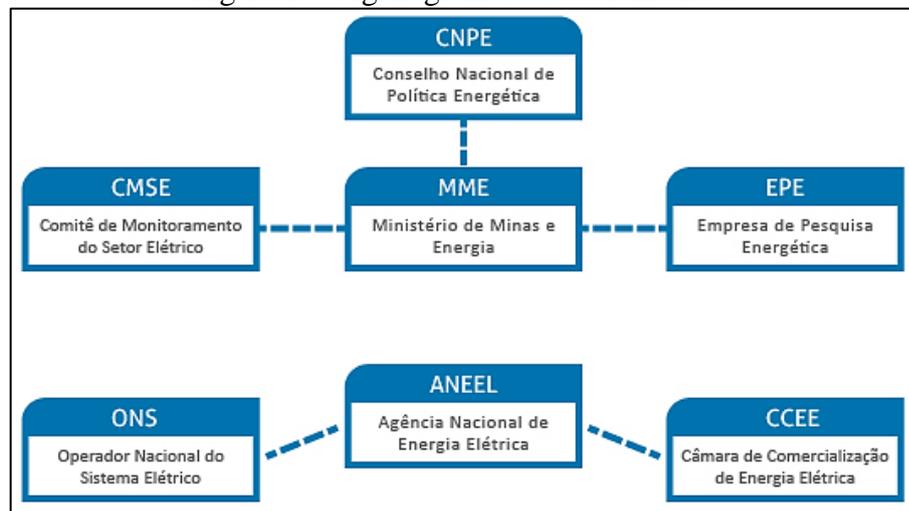
2.1 SETOR ELÉTRICO NACIONAL

O mercado de energia elétrica, como relatado, passou por diversas transformações nas últimas décadas. Na década de 1990, todo o setor era controlado pelo estado e diversos fatores levaram à abertura do mercado energético para se tornar como ele é hoje. Um dos fatores foi a estagnação do investimento estatal devido a vários endividamentos internos que resultou na incapacidade de atender a demanda crescente (PEREIRA, 2016). Após diversas modernizações da legislação e abertura de capital privado, o setor elétrico passou a ter diversos agentes e órgãos responsáveis pelo bom funcionamento dos alicerces que compõem o mercado brasileiro, entre eles a geração, transmissão, distribuição e comercialização.

2.1.1 Instituições do Setor Elétrico

O mercado de energia brasileiro possui diversos órgãos e agentes responsáveis em diversas áreas para manter o suprimento de energia do SIN, como mostrado na Figura 2.

Figura 2 - Organograma do Setor Elétrico.



Fonte: CCEE (2019).

A Agência Nacional de Energia Elétrica (ANEEL) foi criada com a intenção de substituir o Departamento Nacional de Águas e Energia Elétrica (DNAEE), pela Lei nº. 9.427 de 26/12/1996. A ANEEL regula, fiscaliza e define as regras e procedimentos do setor elétrico para o bom funcionamento do mercado de energia, seja para agentes de geração, transmissão, distribuição ou comercialização. Também, a ANEEL realiza os leilões de compra e venda de energia para agentes de distribuição no ambiente de contratação regulado (ACR) e leilões para agentes de transmissão, utilizando uma sistemática entre leilão fechado de primeiro preço e leilão descendente a viva voz (SILVA, 2001).

O ONS, criado em 1998 pela a Lei nº. 9.648, é uma instituição pública de direito privado sem fins lucrativos, responsável pela coordenação e controle das operações de geração e transmissão do setor elétrico nacional. Para exercer a sua função, o ONS efetua diversas pesquisas e estudos do mercado energético de curto até longo prazo para melhor administrar o suprimento de energia elétrica no país, sempre focando no melhor aproveitamento dos reservatórios de água dos submercados e o menor custo para geração de energia elétrica (FONSECA, 2013).

A Câmara de Comercialização de Energia Elétrica (CCEE), criada pelo Decreto nº 5.177/04, é uma instituição privada sem fins lucrativos que absorveu as funções do Mercado Atacadista de Energia (MAE). Sua principal função é a apuração do Preço de Liquidação das Diferenças (PLD), cujo valor é calculado pelo Custo Marginal de Operação emitido pelo ONS como forma de valorar as transações realizadas no mercado de curto prazo. Além disso, a CCEE realiza a contabilização dos montantes de energia comercializados e a liquidação financeira das operações de compra e venda de energia entre os agentes do mercado (RODRIGUES, 2009).

O Comitê de Monitoramento do Setor Elétrico (CMSE) foi criado em 2004 pela Lei 10.848 e é coordenado pelo Ministério de Minas e Energia (MME). O comitê é responsável em acompanhar e avaliar a continuidade e segurança do suprimento de energia elétrica em todo o território brasileiro (QUEIROZ, 2007).

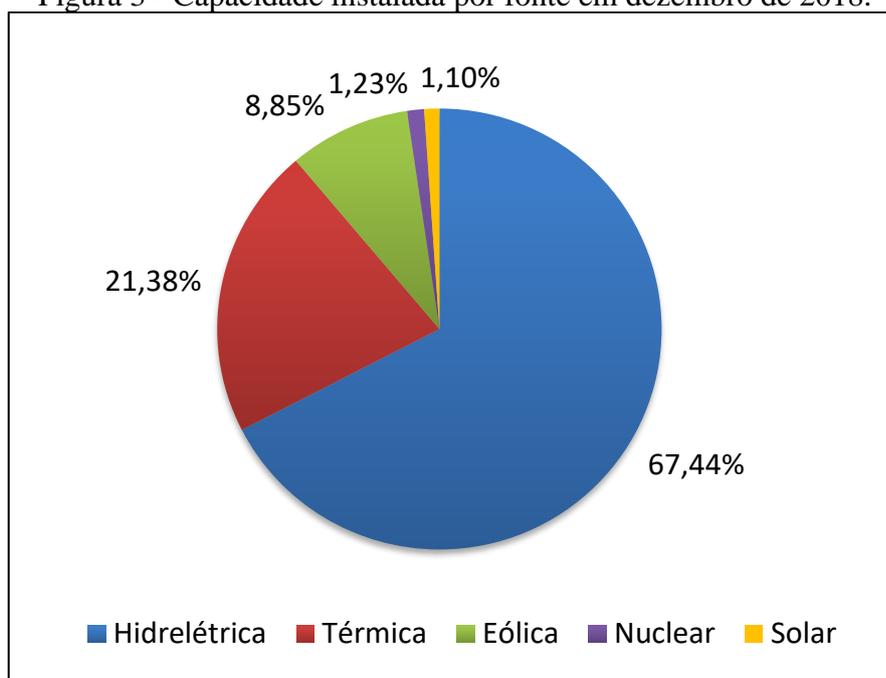
O Ministério de Minas e Energia (MME), juntamente com o Conselho Nacional de Política Energética (CNPE), são responsáveis pela formulação das políticas e diretrizes energéticas, por assegurar o suprimento de energia em áreas remotas do país bem como por rever a matriz energética brasileira nas mais diversas áreas do país (ALMEIDA, 2012).

A Empresa de Pesquisa Energética (EPE) é responsável pelas pesquisas, estudos e projeções referente a matriz energética brasileira, planejamento energético de curto, médio e longo prazo, expansões de agentes de distribuição, transmissão e geração além de toda análise técnica, econômica e ambiental de futuros empreendimentos (ALMEIDA, 2012).

2.1.2 Matriz Energética Brasileira

A maior parte da energia elétrica do Brasil é gerada por fontes hídricas. O Brasil é o país com maior potencial de fontes hídricas do mundo devido a sua grande quantidade de bacias hidrográficas e rios, onde a maior parte da energia hidrelétrica é gerada na região SE/CO (MAIA et al., 2016). A capacidade instalada na malha energética brasileira, no final de 2018, conforme dados divulgados pela ONS, foi de 109.059 MW em usinas hidrelétricas, enquanto as usinas térmicas somaram 34.582 MW. As usinas eólicas obtiveram um crescimento de 16,27% em comparação com 2017, totalizando 14.313 MW de capacidade instalada. As usinas nucleares totalizam 1.990 MW e as solares de 1.780 MW (ONS, 2019a). A Figura 3 mostra a capacidade instalada por fonte de geração com os dados de dezembro de 2018.

Figura 3 - Capacidade instalada por fonte em dezembro de 2018.

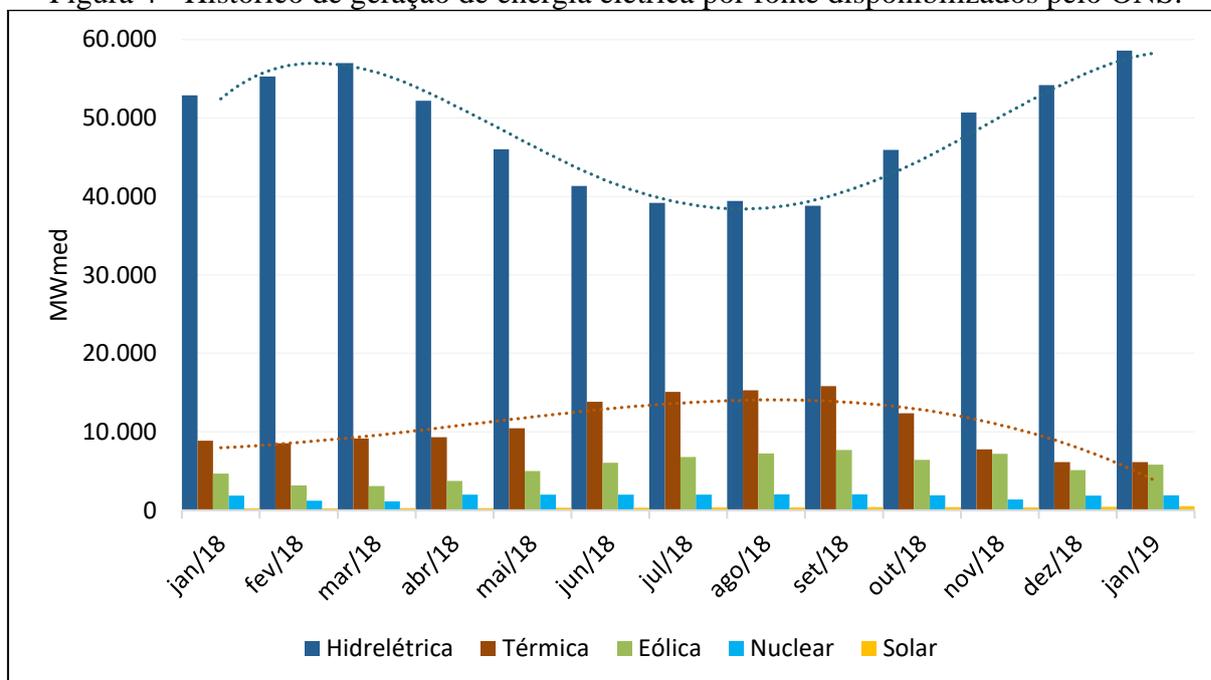


Fonte: Adaptado de ONS (2019a).

Referente à geração de energia, as usinas hidrelétricas produziram 47.707 MWmed (71,24%) em 2018, as usinas térmicas totalizaram 11.608 MWmed (17,33%), usinas eólicas produziram 5.530 MWmed (8,26%), as fontes nucleares somaram 1.789 MWmed (2,67%) e as fontes por energia solar totalizaram 333 MWmed (0,5%). A Figura 4 mostra o histórico de geração de energia por fonte com os dados fornecidos pelo ONS. É possível averiguar que no período que ocorre diminuição da geração de energia das usinas hidrelétricas no período seco

do ano, que corresponde em média de junho até setembro, ocorre um aumento da geração de energia por termelétricas para atendimento da demanda no sistema elétrico (ONS, 2019f).

Figura 4 - Histórico de geração de energia elétrica por fonte disponibilizados pelo ONS.



Fonte: Adaptado de ONS (2019f).

Na Tabela 1 são mostradas as quantidades de energia elétrica gerada por submercado e fonte de geração do ano de 2018. É possível observar as diferenças de geração de energia entre as regiões do Brasil. Por exemplo, na região NE, a fonte que mais gerou energia elétrica foi a eólica. Na região SE/CO, a geração por fonte hídrica foi 3,8 vezes maior se comparado com a geração hídrica da região S, que se encontra em segundo lugar (ONS, 2019f).

Tabela 1 - Geração de energia elétrica por submercado e fonte em 2018.

Fonte	SE/CO	S	N	NE	TOTAL
Hidro	30.804 MWmed	8.095 MWmed	6.919 MWmed	1.889 MWmed	47.707 MWmed
Térmica	5.835 MWmed	1.131 MWmed	1.781 MWmed	2.322 MWmed	11.069 MWmed
Eólica	6 MWmed	670 MWmed	116 MWmed	4.738 MWmed	5.530 MWmed
Solar	105 MWmed	0 MWmed	0 MWmed	228 MWmed	333 MWmed
Nuclear	1.789 MWmed	0 MWmed	0 MWmed	0 MWmed	1.789 MWmed
Produção Total	38.539 MWmed	9.896 MWmed	8.816 MWmed	9.177 MWmed	66.428 MWmed

Fonte: Adaptado de ONS (2019f).

2.1.3 Sistema Interligado Nacional

O Sistema Interligado Nacional (SIN) é uma grande malha elétrica composta por agentes geradores, transmissores e distribuidores, que interliga os sistemas de energia elétrica de diversas regiões do país. Os sistemas isolados e o SIN formam a grande malha elétrica do Sistema Elétrico Brasileiro. O SIN, como mostrado na Figura 5, foi formado ao longo de muitos anos, efetuando interconexões por meio de malhas de transmissão, e assim, sendo possível a transferência de energia entre as mais diversas regiões do país. Portanto, a energia elétrica gerada por fontes hídricas em um submercado pode ser transportada para outro submercado onde possui níveis de reservatórios mais baixos, fazendo que o preço da energia elétrica não aumente se comparado a um modelo sem intercâmbios (ALMEIDA, 2012).

Figura 5 - Mapa do SIN.

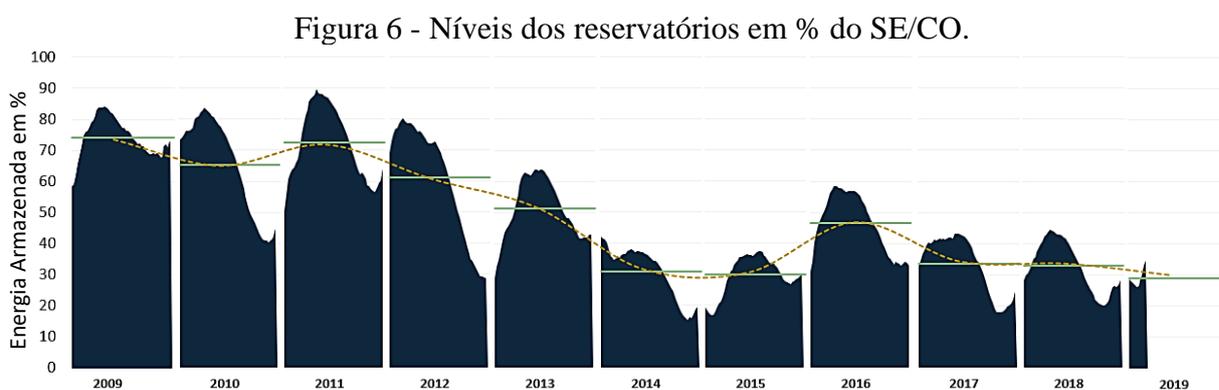


Fonte: ONS (2019g).

Além do SIN, existem os Sistemas Isolados. Esses sistemas são as regiões do Brasil que não estão conectadas na malha elétrica do SIN. Existem 237 localidades no sistema isolado, onde a maioria dessas regiões estão localizadas nos estados de Rondônia, Acre, Amazonas, Roraima, Amapá e Pará. A ilha de Fernando de Noronha e algumas regiões do Mato Grosso também fazem parte do Sistema Isolado (ONS, 2019k). A demanda de energia elétrica nessas regiões é suprida por usinas térmicas movidas a óleo diesel e biomassa, além de utilizarem Pequenas Centrais Hidrelétricas (PCH) e Centrais Geradoras Hidrelétricas (CGH) (ALMEIDA, 2012).

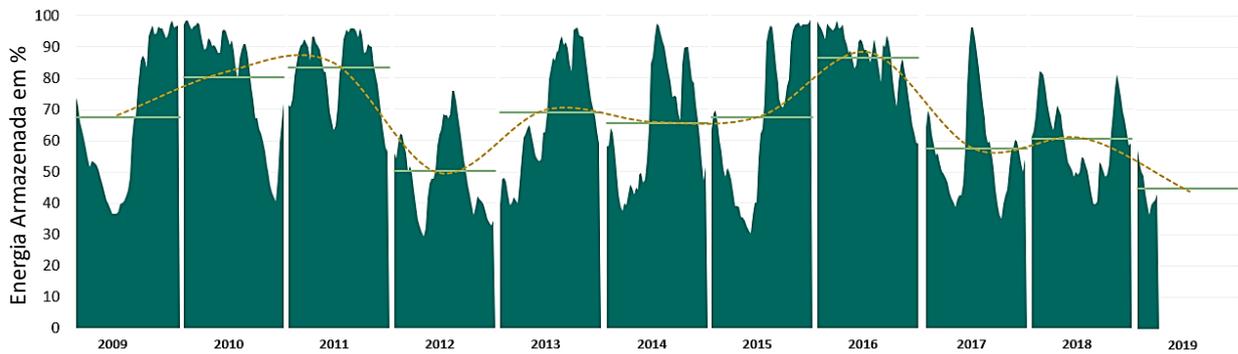
O SIN é formado por quatro submercados: Sudeste/Centro-Oeste, Sul, Nordeste e Norte. Eles foram dispostos dessa maneira devido à diversidade dos regimes hidrológicos e por possuírem algumas características em comum. Por exemplo, o SE/CO que engloba todos os estados do SE, CO, e também Rondônia e Acre, importa energia elétrica durante a maior parte do ano de outras regiões, possui uma grande capacidade de armazenamento de água para geração hídrica e é a região de maior consumo do país. A região Sul possui os reservatórios com maior volatilidade do SIN e a exportação de energia para o submercado SE/CO varia ao longo do ano. O submercado NE, que engloba todos os estados da região Nordeste excluindo-se o Maranhão, importa energia do SE/CO e N na maior parte do ano e possui demanda crescendo ao longo dos últimos anos. O submercado N, que engloba os estados do Norte, excluindo-se a Rondônia e Roraima e adicionando o Maranhão, exporta energia na maior parte do ano devido a sua grande capacidade de geração, e possui baixa demanda se comparado a outros submercados (FONSECA, 2013).

As figuras 6 a 9 mostram os percentuais dos níveis de reservatórios de cada submercado desde 2009 até a semana do dia 11 de março de 2019, destacando as diferentes características de hidrologia entre os submercados (ONS, 2019d).



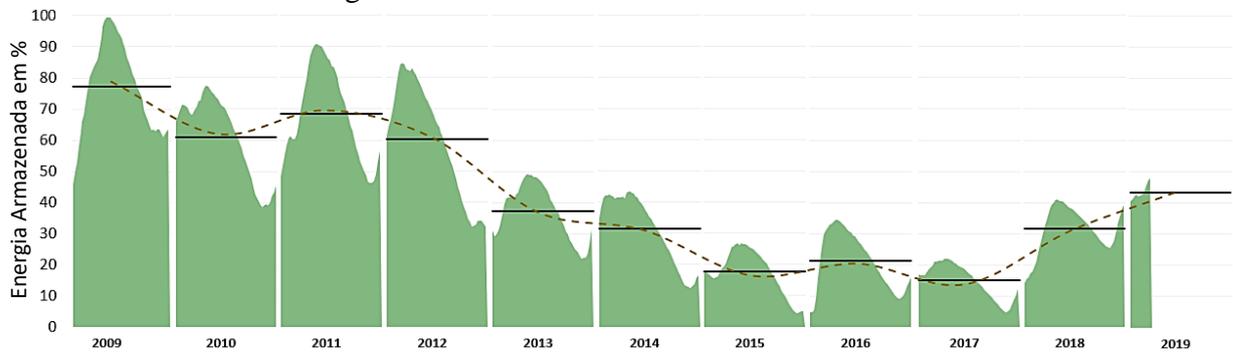
Fonte: Adaptado de ONS (2019d).

Figura 7 - Níveis dos reservatórios em % do S.



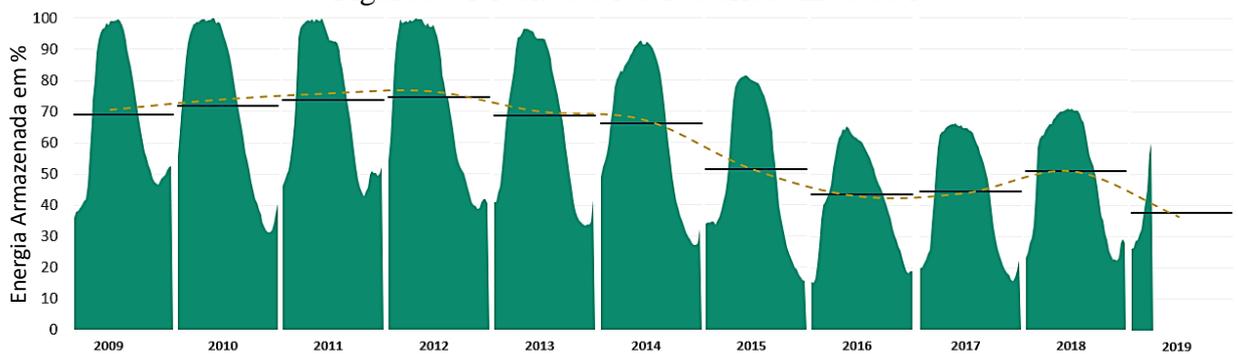
Fonte: Adaptado de ONS (2019d).

Figura 8 - Níveis dos reservatórios em % do NE.



Fonte: Adaptado de ONS (2019d).

Figura 9 - Níveis dos reservatórios em % do N.



Fonte: Adaptado de ONS (2019d).

2.1.4 Tipos de Mercado de Eletricidade

No Brasil, existem quatro tipos de mercados de energia elétrica: *Spot*, Longo Prazo, Serviços Ancilares e outros tipos.

No mercado *Spot*, ou também conhecido como mercado de curto prazo, os agentes participantes realizam negócios e transações de energia referente ao mês atual de operação. Em

um determinado mês de contratação de energia elétrica, podem existir sobras ou faltas do montante de energia elétrica consumido ou produzido. Dessa forma, os agentes do mercado necessitam comprar ou vender energia no mercado de curto prazo (PEREIRA, 2016). As transações efetuadas nesse mercado são valoradas a um preço de referência (PLD). Como o preço do PLD pode variar de forma significativa ao longo dos meses, os agentes participantes estão expostos a grandes riscos financeiros devido à volatilidade do preço da energia elétrica. Esse mercado também é conhecido como mercado atacadista (MEDEIROS, 2003).

No mercado de longo prazo, compradores e vendedores de energia elétrica efetuam seus contratos bilaterais em paralelo ao mercado *Spot*, ou seja, os agentes vendedores, podendo ser geradores ou comercializadores, entregam a energia contratada de longo prazo aos seus compradores, podendo ser consumidores finais, distribuidoras de energia ou até mesmo outros comercializadores (MEDEIROS, 2003). Nesse mercado, o valor do montante de energia contratado é firmado entre as partes e não varia todo mês conforme o PLD. Os contratos de longo prazo podem variar de alguns meses até diversos anos, onde que o montante de energia contratado pode variar por mês (LEME et. al., 2008).

O mercado de Serviços Ancilares é composto por agentes responsáveis pela operação eficiente e segura do sistema elétrico nacional. Também realizam as transações financeiras firmadas em contratos. Os agentes desse mercado são responsáveis, por exemplo, pelo controle da frequência, tensão e supervisionamento da estabilidade das linhas de transmissão (MEDEIROS, 2003).

Além dos três mercados citados, existem outros tipos de mercados que podem englobar os contratos de prestação de serviços de transmissão, distribuição e conexão (MEDEIROS, 2003).

2.1.5 Ambientes de Contratação

Atualmente no Brasil, existem dois modelos de contratação de energia elétrica pelos consumidores: o ambiente de contratação regulada (ACR) e o ambiente de contratação livre (ACL).

O ACR foi efetuado para consumidores no mercado cativo, ou seja, todos os consumidores residenciais, de serviços e indústrias com um nível baixo de contratação de demanda (atualmente abaixo de 500kW de demanda contratada de uma única unidade consumidora, ou com o somatório das demandas das unidades consumidoras com mesma raiz de CNPJ). As grandes indústrias podem optar por permanecerem no mercado cativo, mesmo

estando aptas a migrar ao ACL. Nesse ambiente, a ANEEL define as tarifas e as condições de fornecimento onde que a distribuidora de energia efetua suas revisões tarifárias anualmente. Nesse ambiente, as unidades consumidoras estão condicionadas a pagar uma tarifa excedente, conforme divulgação pela ANEEL referente às bandeias tarifárias, nos meses que ocorrem baixo regime de chuvas e elevação da produção de energia elétrica por termelétricas. A energia fornecida aos consumidores no ACR é efetivada por leilões com as distribuidoras de energia, sem a possibilidade de alterações entre as partes (PEREIRA, 2016).

No ACL, os agentes participantes podem negociar a compra e venda de energia de forma livre, onde que não existem regras quanto à quantidade de compra ou venda, preços a serem celebrados ou prazos de entrega. Todavia, os participantes devem registrar em um ambiente da CCEE a quantidade vendida, enquanto a contraparte deve validar o montante registrado. Essa é a forma de entrega da energia elétrica a um determinado agente participante. Posteriormente, a CCEE fiscaliza os montantes registrados com os montantes consumidos ou vendidos de um determinado agente, e realiza suas liquidações financeiras como forma de deixar o mercado justo entre os participantes (PEREIRA, 2016). A liquidação financeira, basicamente, leva em consideração as diferenças entre os montantes registrados e consumidos ou vendidos, e valora ao preço do PLD as diferenças para os agentes do mercado, podendo se tornar um crédito ou débito. Os agentes participantes do ACL são os geradores, comercializadores, importadores e exportadores de energia e consumidores livres.

2.1.6 Modelos de despacho

No mundo, existem diversas formas de despacho de usinas de geração de energia elétrica. Muitas delas requerem um sistema complexo para entrada de operação no sistema enquanto outras dispõem de sistemas mais simples. Assim, foram classificados dois modelos de despacho: *Tight Pool* e *Loose Pool*.

O Modelo *Loose Pool* é utilizado quando os preços de geração são bastante previsíveis. Por exemplo, a geração por termelétricas pode utilizar gás natural como combustível, para o qual o preço é conhecido e firmado por contratos de longo prazo com um determinado fornecedor. Além de gás natural, as termelétricas podem gerar energia a partir de óleo e carvão, onde que os preços já são conhecidos e firmados por contratos de entrega. Nesse modelo, os agentes vendedores e compradores propõem montantes de compra e venda e o mercado regula o preço da energia pela lei da oferta e procura (PEREIRA, 2016).

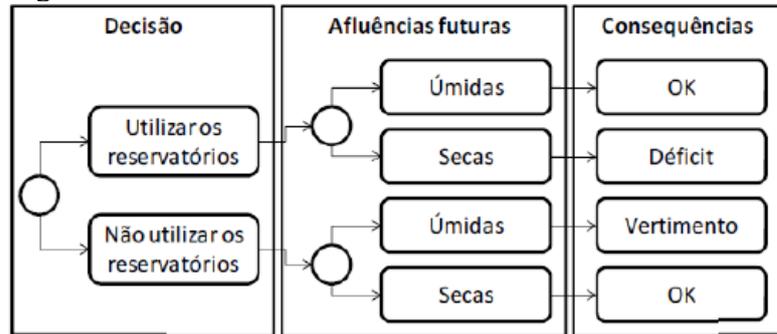
No modelo *Tight Pool*, o custo da energia elétrica é mais complexo de ser previsto. Nesse modelo, o objetivo é evitar ao máximo o uso de geração por termelétricas pois são mais caras se comparadas com os geradores hídricos. No Brasil, é utilizado esse modelo, onde que os recursos hídricos para geração de energia são despachados de maneira otimizada. Esse modelo impõe riscos nas decisões tomadas pelo operador do sistema, pois a capacidade dos reservatórios é limitada e as afluições futuras são incertas (SILVA, 2001). Nesse modelo, os geradores de usinas hidrelétricas não fazem oferta de preços, pois o preço da energia é determinado pelo valor da água, pelo preço das usinas termelétricas despachadas para suprir a demanda dos submercados e, além disso, pode englobar o custo do déficit de energia elétrica (MEDEIROS, 2003).

2.1.7 Planejamento de Operação do Sistema Hidrotérmico

O Brasil, como mencionado, utiliza o modelo de despacho *Tight Pool*. Nesse modelo, o principal objetivo é encontrar o preço mínimo da geração de energia elétrica baseado nas informações técnicas enviadas pelos geradores ao ONS. Os geradores hidráulicos não têm direito de declarar oferta de preços, somente os geradores de termelétricas (SILVA, 2001). Assim, o objetivo é definir o quanto de energia elétrica o gerador hidráulico e térmico irão produzir por um determinado período, visando o menor custo de energia elétrica possível, levando em consideração as afluições atuais e futuras nas bacias hidrográficas brasileiras.

Existe uma séria consequência caso a decisão de gerar energia elétrica pela composição de fontes térmicas ou hídricas, para atendimento da demanda, seja efetuada de maneira incorreta. A figura 10 ilustra as decisões e consequências de um sistema hidrotérmico. Caso a decisão atual seja de utilizar os reservatórios, e o período futuro é de boas afluições para encher os reservatórios de usinas hidrelétricas, não haverá consequências para o setor elétrico. Porém, caso as afluições futuras sejam baixas, a possibilidade de ocorrer déficit de energia elétrica é alta. Assim, será necessário despachar mais usinas termelétricas, elevando o custo da energia elétrica. No outro exemplo, tendo a decisão de não utilizar os reservatórios e as afluições futuras forem altas, ocorrerá vertimento, ou seja, a água que entrou nos reservatórios não estará disponível para gerar energia elétrica no futuro. Por outro lado, caso as afluições futuras forem baixas, não haverá consequências para o setor elétrico, pois a decisão de não utilizar os reservatórios no passado foi correta, havendo água disponível para geração de energia elétrica no período mais seco.

Figura 10 - Processo de decisão de um sistema hidrotérmico.



Fonte: Silva (2001).

O ONS divulga os despachos das usinas para operação energética nacional através do Programa Mensal de Operação (PMO). Eles divulgam os dados de operação mensalmente, porém, os despachos são atualizados semanalmente. As semanas operativas do setor elétrico, que correspondem ao despacho do PMO, sempre são válidas das 0h00min do sábado e termina às 24h00min da sexta-feira subsequente (FONSECA, 2013).

No PMO, é informado o CMO como consequência da relação de despachos das usinas térmicas e hídricas. A definição do CMO é o custo, depois de atendida toda a demanda do sistema elétrico, necessário para atender ao próximo MW de carga em cada região do SIN (FONSECA, 2013). O CMO é definido para cada submercado do SIN. Além disso, ele é atualizado semanalmente nas revisões do PMO e possui um valor para diferentes horários durante o dia, baseado na demanda existente em cada faixa horária estipulada. Como exemplo, o Quadro 1 mostra os patamares de carga, conforme determinado pela Comissão Permanente para Análise de Metodologias e programas Computacionais do Setor Elétrico (CPAMP) em 31/07/2018 e de acordo com a Resolução CNPE nº 7, de 14 de dezembro de 2016, a partir do PMO de janeiro de 2019, sendo estabelecidos os horários dos patamares de carga leve, média e pesada.

Quadro 1 - Intervalos horários de patamares de carga diária de energia.

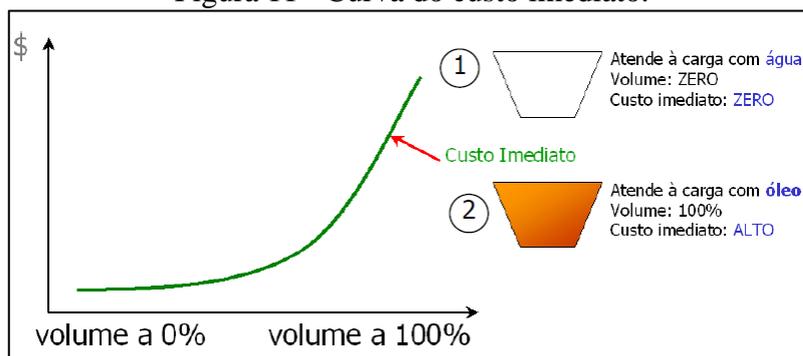
Patamar de Carga	maio a agosto		abril, setembro e outubro		novembro a março	
	2ª a 6ª feira	Sábado, domingo e feriado	2ª a 6ª feira	Sábado, domingo e feriado	2ª a 6ª feira	Sábado, domingo e feriado
Leve	1ª h à 7ª h	1ª h à 18ª h 23ª h à 24ª h	1ª h à 8ª h	1ª h à 18ª h 23ª h à 24ª h	1ª h à 8ª h	1ª h à 20ª h 24ª h
Média	8ª h à 10ª h 23ª h à 24ª h	19ª h à 22ª h	9ª h à 10ª h 21ª h à 24ª h	19ª h à 22ª h	9ª h à 10ª h 19ª h à 24ª h	21ª h à 23ª h
Pesada	11ª h à 22ª h	-	11ª h à 20ª h	-	11ª h à 18ª h	-

Fonte: Adaptado de ONS (2019i).

O planejamento da operação de um sistema hidrotérmico visa a minimizar o custo total em todo horizonte de estudo. O custo de operação total leva em consideração a quantidade de geração térmica e o custo do déficit, caso uma parcela da demanda não seja atendida. O custo total é influenciado pelas decisões da geração térmica, geração hídrica, intercâmbio de regiões do SIN e custo do corte de carga (déficit) (CCEE, 2017).

Para minimizar o custo total, basta estudar o comportamento do custo imediato e do custo futuro. O custo futuro é encontrado pelas decisões tomadas no presente. O custo imediato está relacionado ao custo dos combustíveis em caso de despacho de usinas térmicas. A Figura 11 mostra a curva do custo imediato. Caso o volume de água nos reservatórios no final do período do estudo seja de 0%, significa que não foi utilizada geração térmica e sim, geração hídrica, tornando o custo imediato baixo. Porém, se no presente não forem utilizadas usinas hídricas, mas utilizadas usinas térmicas, o volume dos reservatórios no final do período será de 100% e o custo imediato será elevado (FONSECA, 2013).

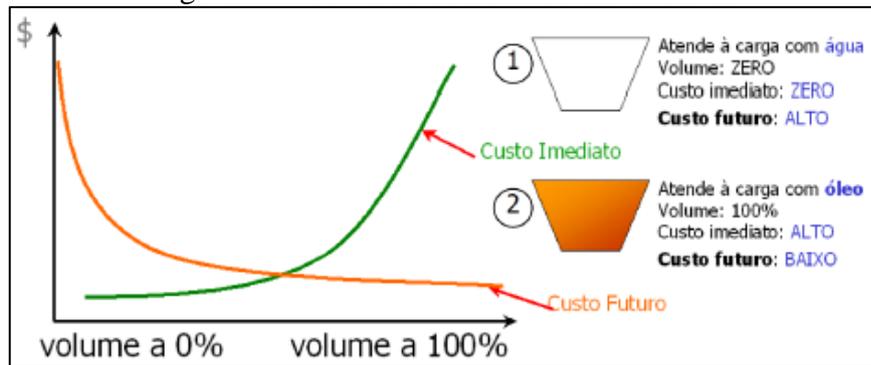
Figura 11 - Curva do custo imediato.



Fonte: CCEE (2017).

Se no presente forem utilizadas usinas hídricas para produção de energia, deixando os volumes dos reservatórios a 0%, o custo futuro será elevado e dependerá das afluições futuras. Todavia, se no presente for utilizada geração térmica, deixando os volumes a 100% e, conseqüentemente, o custo imediato elevado, o custo no futuro será baixo pois haverá recursos hídricos para gerar energia por usinas hidrelétricas (FONSECA, 2013). A Figura 12 mostra o comportamento do custo futuro e do custo imediato.

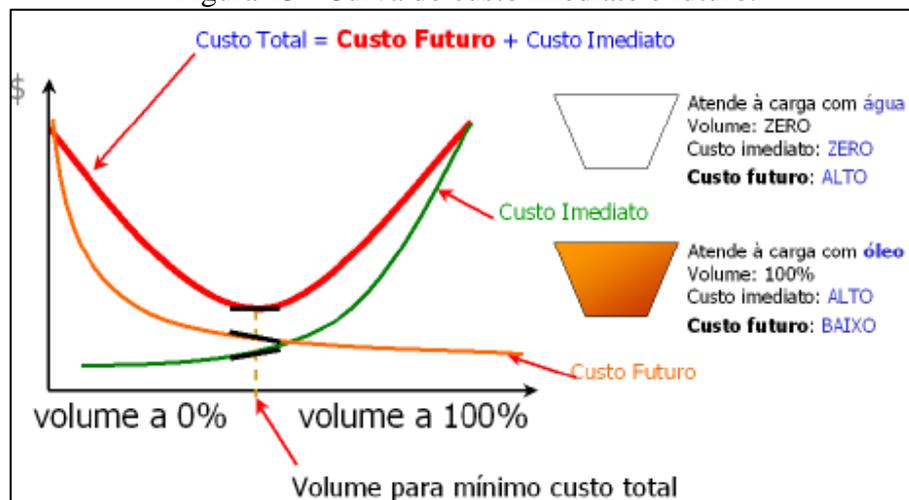
Figura 12 - Curva do custo imediato e futuro.



Fonte: CCEE (2017).

O custo total será a soma das curvas do custo imediato e custo futuro. A Figura 13 mostra a soma das curvas. A derivada nula da função custo total é o ponto ótimo de operação para o sistema hidrotérmico. Assim, a estratégia da ONS é tomar as decisões no presente para que os níveis dos reservatórios, no fim do período em estudo, alcancem o menor custo total (CCEE, 2017).

Figura 13 - Curva do custo imediato e futuro.

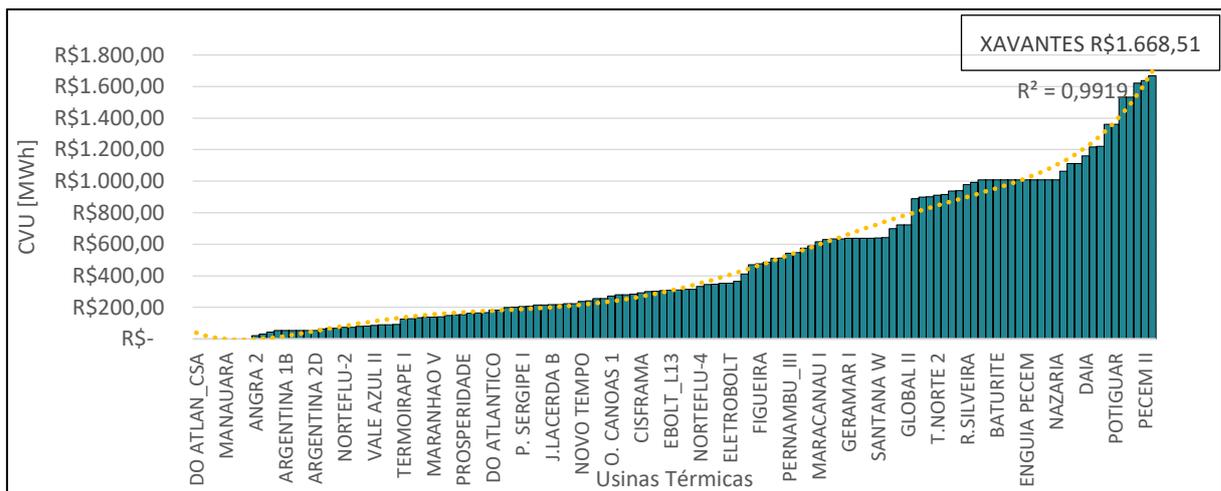


Fonte: CCEE (2017).

A inclinação da função de custo futuro indica o custo em relação ao volume armazenado. A derivada da função custo futuro é conhecido como valor da água. A curva de custo imediato representa o custo da geração térmica e déficit. O despacho das usinas será conduzido de forma a atingir o menor custo equilibrando a geração hídrica e térmica. Em outras palavras, o custo total mínimo é alcançado quando o valor da água será igual ao custo da geração térmica mais cara que estiver sendo acionada (CCEE, 2017).

Nas usinas termelétricas, compostas de usinas a gás, cogeração, nucleares e usinas fósseis, os empreendimentos com menor custo são despachados primeiro. Dessa forma, basta o conhecimento do custo de operação de cada uma e suas respectivas capacidades para encontrar o despacho ótimo, e conseqüentemente, encontrar o custo imediato. Assim, o despacho térmico é efetuado por ordem de mérito do custo crescente (MEDEIROS, 2003). A Figura 14 mostra as usinas possíveis de serem despachadas pelo ONS em ordem de mérito. Os valores são referentes ao PMO de março de 2019. O CVU, mostrado na Figura 14, é o custo variável unitário, ou seja, o custo de geração para cada MWh. A última usina a ser despachada no SIN, e conseqüentemente a mais cara para o PMO de março de 2019, é a UTE Xavantes, cujo custo é de R\$ 1.668,51/MWh que possui geração a diesel. As usinas termelétricas mais baratas são acionadas por resíduos e a gás (ONS, 2019h).

Figura 14 - Custo variável unitário das usinas termelétricas despachadas pelo ONS.



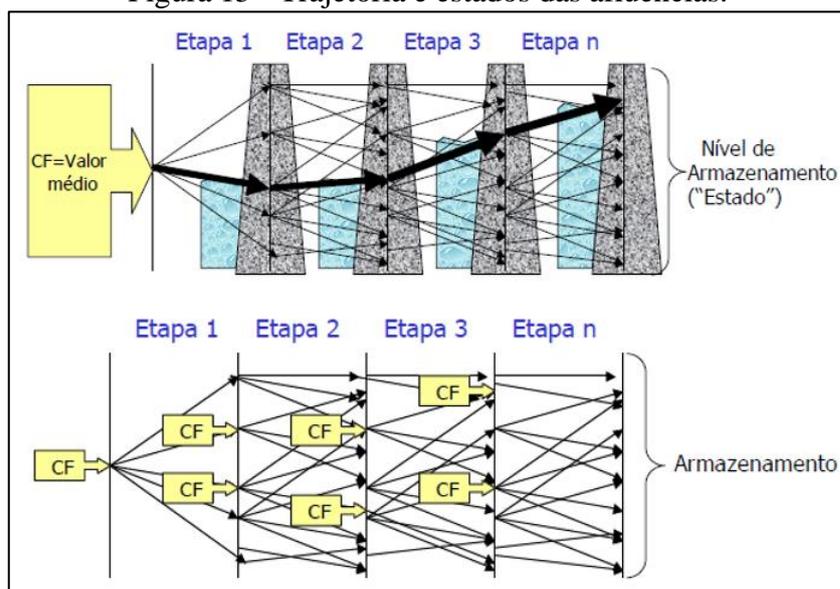
Fonte: Adaptado de ONS (2019h).

A função do custo futuro é mais complexa se comparado com a função do custo imediato. O custo futuro possui uma grande incerteza pois depende das afliências futuras que são difíceis de prever. Uma das opções para realizar a previsão é estudar o comportamento delas no passado com uma série histórica que se iniciou em 1931. As séries temporais possuem um comportamento estatístico periódico de todo o período observado que auxiliam para a previsão das afliências (FONSECA, 2013).

Um modelo estatístico escolhido para modelar o comportamento das afliências foi o modelo PAR(p), que é a sigla para Autorregressivo periódico de ordem p (CCEE, 2017). Isso significa que as afliências dependem delas mesmas em até “p” meses anteriores. Assim, conhecendo o modelo estocástico, é possível sortear um número grande de afliências e

acompanhar a evolução do sistema nos próximos 5 anos para cada uma das trajetórias, encontrando o custo futuro médio. Para trazer a função do custo futuro para o presente, é utilizada a Programação Dinâmica Estocástica, que garante o menor custo futuro para cada estado para as hipóteses consideradas. Com a Programação Dinâmica Estocástica, foi encontrado o problema de dimensionalidade para múltiplos reservatórios, pois se fosse aplicado para todos os níveis dos reservatórios, o número de estados seria elevado e inviabilizaria a técnica. Assim, o custo futuro é calculado apenas para alguns estados (ou níveis) e essa técnica ficou conhecida como Programação Dinâmica Dual Estocástica. Como consequência da redução do número de estados, é necessário calcular a derivada do custo futuro, conhecido como valor da água, para encontrar o custo de qualquer outro estado não utilizado na Programação Dinâmica Dual Estocástica (CCEE, 2017). A Figura 15 mostra o método para encontrar o trajeto do menor custo futuro.

Figura 15 - Trajetória e estados das afluições.



Fonte: Adaptado de CCEE (2017).

Assim, encontrando o custo imediato e o custo futuro, o custo total é a soma dos valores, resultando no custo marginal de operação, que é o custo de equilíbrio entre o valor da água (custo futuro) e o custo das térmicas (custo imediato) (FONSECA, 2013).

Para modelar o sistema hidrotérmico brasileiro, o CEPEL desenvolveu dois *softwares*: o NEWAVE e o DECOMP.

O NEWAVE foi desenvolvido para estudos de médio prazo, para um horizonte de 5 anos, que agrega todos os reservatórios de cada região em um único reservatório equivalente. Os reservatórios de um submercado são unidos como se fosse uma só usina, tendo suas

capacidades somadas. Essa simplificação tem como objetivo obter índices plurianuais de atendimento ao consumo e outras informações que irão subsidiar decisões que envolvem obras e expansões do setor elétrico. Além disso, o NEWAVE agrega as informações de limites de intercâmbio entre os submercados. Um dos resultados do NEWAVE é mostrar o custo futuro, cujo resultado é acoplado ao modelo DECOMP (FONSECA, 2013).

O modelo DECOMP é aplicado para o planejamento do curto prazo e o objetivo é determinar de forma individual as metas de geração de cada usina, atendendo a demanda e minimizando o custo de operação ao longo do período planejado. O DECOMP é baseado como um problema de programação linear, simulando as características físicas e suas restrições das usinas hidrelétricas de forma individual (CCEE, 2017).

Após o cálculo do custo marginal de operação, a CCEE calcula o PLD com as informações repassadas pelo ONS. A diferença entre os dois valores é que o PLD possui um preço máximo e mínimo determinado pela ANEEL. Além disso, o cálculo do PLD não considera as restrições de transmissão interna de cada submercado e as usinas em operação de testes conectadas na rede (MAIA et al., 2016). Todavia, o CMO e o PLD possuem valores próximos. Por exemplo, o CMO para a primeira semana operativa de maio de 2019 foi de R\$ 136,69, enquanto o PLD foi de R\$ 142,65, ou seja, diferença de R\$ 5,96.

Os *softwares* do CEPEL para modelagem do sistema hidrotérmico apresentam baixa assertividade nas previsões de médio prazo (GUARNIER et. al., 2012). Os parâmetros de entrada dos *softwares* são atualizados a cada semana o que muda completamente os cenários de médio prazo utilizando a Programação Dinâmica Dual Estocástica (FONSECA, 2013). Dessa forma, tendo conhecimento de ferramentas que auxiliam na previsão de séries temporais, como por exemplo as redes neurais artificiais, se faz necessário estudo de outras ferramentas que possibilitem uma assertividade maior se comparado com os *softwares* que modelam o sistema hidrotérmico brasileiro (GUARNIER et. al., 2012).

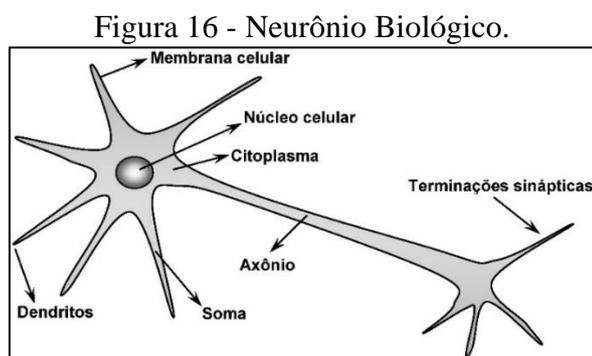
2.2 REDES NEURAS ATIFICIAIS

Redes neurais artificiais são modelos computacionais com capacidade de aprendizado, podendo ser utilizadas como aproximador universal de funções, controle de processos, reconhecimento e classificação de padrões, agrupamento de dados, sistemas de previsão, otimização de sistemas e memórias associativas (SILVA; SPATTI; FLAUZINO, 2010). Uma das propriedades e capacidades mais importantes das redes neurais são a não-linearidade,

mapeamento de entrada-saída, adaptabilidade, resposta a evidências, possuir informações contextuais, tolerante a falhas e analogia neurobiológica (HAYKIN, 2001).

2.2.1 Neurônio Biológico

O neurônio é a célula elementar do sistema nervoso cerebral e sua função é conduzir estímulos elétricos sob determinadas condições. O neurônio é constituído de três partes principais: axônio, dendritos e corpo celular. Os dendritos captam os estímulos vindos de outros neurônios. Posteriormente, o corpo celular tem função de processar tais estímulos, captados pelos dendritos, e disparar um impulso elétrico ao longo do axônio. O axônio é responsável por transmitir o impulso elétrico, com características próprias, para outros neurônios conectores. Estima-se que existem 100 bilhões de neurônios em uma rede neural biológica, diversos deles conduzindo de forma paralela, exercendo a função de pensar e memorizar (SILVA; SPATTI; FLAUZINO, 2010). A figura 16 mostra o modelo de um neurônio biológico.



Fonte: Silva; Spatti; Flauzino (2010).

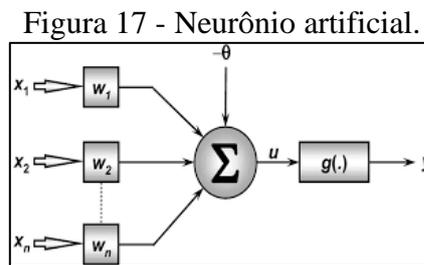
2.2.2 Neurônio Artificial

A estrutura das redes neurais artificiais são modelos simplificados dos neurônios biológicos. A analogia foi efetuada a partir dos estudos da propagação dos impulsos elétricos pelas membranas celulares dos neurônios. O modelo mais simples foi proposto por McCulloch & Pitts em 1943 (SILVA; SPATTI; FLAUZINO, 2010). O neurônio artificial é constituído de sete elementos básicos: os sinais de entrada (x_n), advindos de outros neurônios ou do meio externo; os pesos sinápticos (w_n), que correspondem a valores para ponderar as variáveis de entrada; o combinador linear (Σ), para agregar os sinais de entrada ponderados; o limiar de ativação (θ), cuja função é operar como um *offset* ao combinador linear; o potencial de ativação (u), que é o resultado produzido pelo combinador linear e o limiar de ativação; a função de

ativação (g), cujo objetivo é limitar a saída do neurônio dentro de um intervalo desejável; e o sinal de saída (y), que é o valor final produzido pelo neurônio (SILVA; SPATTI; FLAUZINO, 2010). A Figura 17 mostra o modelo do neurônio artificial e as Equações (1) e (2) mostram o resultado produzido pelo neurônio.

$$u = \sum_{i=1}^n w_i x_i - \theta; \quad (1)$$

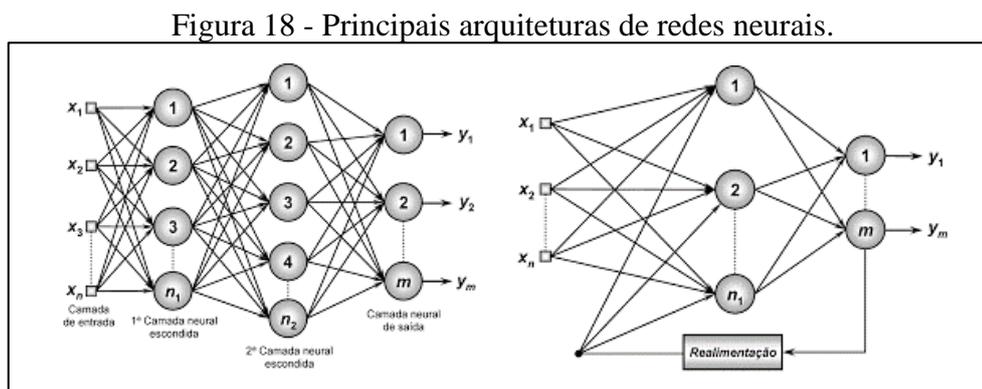
$$y = g(u). \quad (2)$$



Fonte: Silva; Spatti; Flauzino (2010).

As funções de ativação podem ser classificadas entre parcialmente diferenciáveis e totalmente diferenciáveis. As parcialmente diferenciáveis são as funções degrau, degrau bipolar e rampa simétrica. As funções totalmente diferenciáveis são as funções logística, tangente hiperbólica, gaussiana e linear (SILVA; SPATTI; FLAUZINO, 2010).

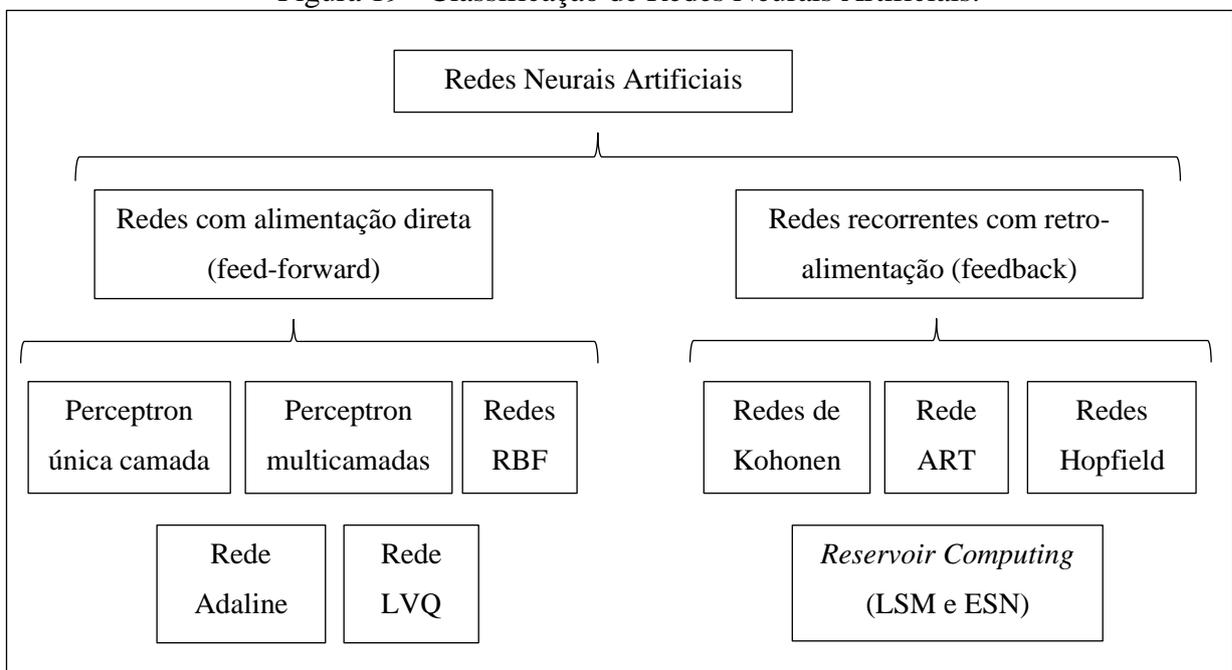
Com a associação de diferentes conexões dos neurônios, é possível formar diversas arquiteturas de redes neurais artificiais. As mais comuns são a *feed-forward* de camada simples e camadas múltiplas e as redes recorrentes. A arquitetura *feed-forward* possui o fluxo de informações sempre em uma única direção, da camada de entrada para a camada de saída. Por outro lado, as redes recorrentes possuem as saídas dos neurônios realimentadas como sinais de entrada para outros neurônios. A Figura 18 mostra a arquitetura *feed-forward* na esquerda e a recorrente na direita.



Fonte: Adaptado de Silva; Spatti; Flauzino (2010).

As redes neurais mais conhecidas são a Perceptron de camada simples, Perceptron multicamadas, rede Adaline, redes RBF (função de base radial), redes recorrentes de Hopfield, redes LVQ (*learning vector quantization*), ART (*adaptive resonance theory*) e redes de Kohonen (SILVA; SPATTI; FLAUZINO, 2010). A Figura 19 mostra a classificação das principais redes. Além disso, existem bibliotecas de redes neurais profundas de código aberto escritas na linguagem de programação *python* ou R como, por exemplo, a Keras e a Scikit-learn. Também, a Tensor Flow, desenvolvida pelo Google, é uma biblioteca de código aberto para desenvolvimento de redes neurais profundas, que pode ser aplicada em diversas plataformas. Neste trabalho será abordada a *Reservoir Computing*, classificada como rede recorrente.

Figura 19 - Classificação de Redes Neurais Artificiais.



Fonte: Adaptado de Rodrigues (2009).

2.2.3 Reservoir Computing

A arquitetura da rede neural artificial conhecida como *Reservoir Computing* (RC) foi desenvolvida primeiramente por Wolfgang Maass, chamada *Liquid State Machines* (LSM) em 2001 (MAASS; NATSCHLÄGER; MARKRAM, 2001). Posteriormente, Hebert Jaeger desenvolveu de forma independente uma rede neural artificial conhecida como *Echo State Network* (ESN), com abordagem similar a de Wolfgang Maass (JAEGER, 2001). Ambas redes neurais possuem um grande reservatório de neurônios com não-linearidade e a propriedade

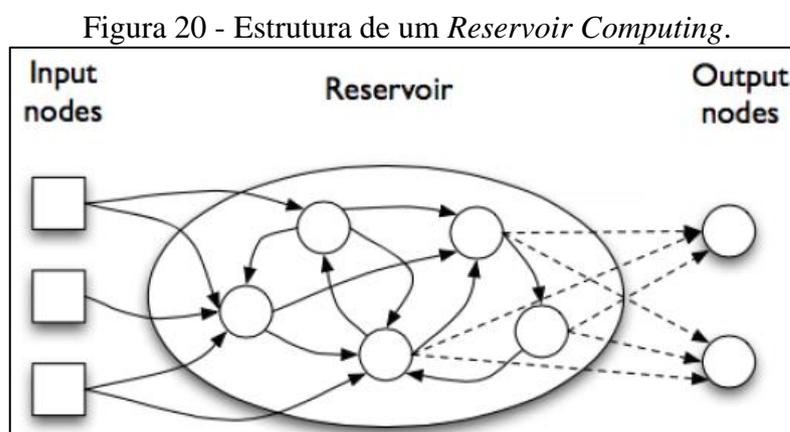
conhecida como *Echo State Property* (ESP) tal que os *inputs* ressonam dentro da rede por um determinado período, e a camada de saída é treinada com uma função linear ou regressiva (BEZERRA, 2016).

A característica da propriedade ESP é armazenar os dados das entradas anteriores por um determinado período, e assim, como o cérebro humano, as informações mais antigas devem ser esquecidas com o tempo. Consequentemente, a rede possui um rico conjunto de informações do presente e do passado, tornando robusta a rede neural aplicada para sistemas dinâmicos (DANTAS; VALENÇA, 2013). Posteriormente, em 2007, Verstraeten criou o termo *Reservoir Computing* unificando os conceitos de LSM e ESN (VERSTRAETEN, 2010). Assim, a literatura passou a usar esse termo para designar redes neurais com reservatórios e que utilizam a ESP.

A ESN é mais utilizada na engenharia se comparado com a LSM. A ESN é mais fácil de ser implementada e requer recursos computacionais com menores capacidades. Todavia, a LSM pode obter melhor resultado em determinadas tarefas devido aos *spiking neurons* que conseguem processar mais informações complexas do que a ESN (BARCELÓ, 2017).

O RC é formado pela camada de entrada, onde constam as variáveis de entrada da rede, um reservatório (*reservoir*) caracterizado por uma grande rede recorrente com pesos fixos e conexões geradas de forma aleatória com característica não linear, e uma camada de saída com função de ativação linear. É importante ressaltar que os neurônios do reservatório possuem pesos fixos, onde não é necessário o treinamento, somente a camada de saída será treinada (BEZERRA, 2016).

A Figura 20 mostra a estrutura de uma rede com reservatório com 3 variáveis de entrada, 5 neurônios no reservatório e 2 neurônios na camada de saída. Somente as conexões pontilhadas usam pesos que exigem treinamento.



Fonte: Bezerra (2016).

Antes de iniciar o processo de treinamento, é necessário definir alguns parâmetros da rede, tais como a quantidade de neurônios no reservatório, a taxa de conectividade (quantos pesos das conexões entre os neurônios do reservatório vão ser diferentes de zero), quantidade de ciclos de *warm-up*, função de ativação no reservatório e a função de ativação na camada de saída (BEZERRA, 2016). Algumas redes implementam o coeficiente *leaking rate*, cujo objetivo é ajustar a velocidade dinâmica de atualização do reservatório (MONTAVON; ORR; MÜLLER, 2012).

Por ser uma metodologia recente, não existem estudos para comprovar a configuração correta para se obter o melhor desempenho em determinada aplicação. Portanto, é necessário avaliar de forma empírica as configurações empregadas para previsão de séries temporais (DANTAS; VALENÇA, 2013). Todavia, existem métodos heurísticos e metaheurísticos que podem auxiliar na melhor configuração da *deep RC*. Além disso, existem alguns procedimentos para produzir uma rede neural com reservatório satisfatória. Uma delas é criar um grande reservatório, com dezenas ou até centenas de neurônios. Também, os pesos devem ser gerados de forma aleatória, preferencialmente com distribuição uniforme (BARCELÓ, 2017).

Supondo que o sistema RC é composto por N nós do reservatório, M entradas e P saídas, para utilizar a técnica, se faz necessário a criação de uma matriz de peso W_{in} de dimensão $M \times N$, da camada de entrada para o reservatório. Posteriormente, é criada a matriz de peso W_{res} de dimensão $N \times N$, identificando as interconexões do reservatório. Essa matriz é gerada a partir de uma distribuição, por exemplo, a gaussiana ou com valores discretos. Após, é necessário ajustar o raio espectral da matriz W_{res} a fim de se obter uma estabilidade numérica. Um raio espectral perto de 1 é considerado um bom ponto inicial para otimização da ESN (GALLE; VALENÇA, 2013). O estado de saída do reservatório é atualizado de acordo com a Equação (3).

$$x(t) = (1 - a)x(t - 1) + af(W_{in}u(t) + W_{res}x(t - 1)), \quad (3)$$

onde $u(t)$ é a entrada do reservatório, $x(t)$ representa o estado do reservatório no instante t , f é a função de ativação do reservatório e a é coeficiente de *leaking rate* (GALLICCHIO; MICHELI; PEDRELLI, 2017).

Para o treinamento dos pesos da camada de saída (*readout*), pode ser utilizada a técnica da Pseudoinversa de Moore-Penrose. Essa técnica, quando aplicada em RC, exige menos recursos computacionais se comparado com uma rede Perceptron de múltiplas camadas

treinadas através de *Back-Propagation*. Dessa forma, um sistema não-linear pode ser convertido em um sistema linear ajustando os pesos das conexões entre o reservatório e a camada de saída (GALLICCHIO; MICHELI; PEDRELLI, 2017). A saída do RC é calculada pela combinação linear do estado do reservatório e a matriz de pesos da camada de saída, de acordo com a Equação (4).

$$y(t) = W_{out}x(t) \quad (4)$$

onde $y(t)$ é o neurônio de saída da RC no instante t e W_{out} são os pesos da matriz que conecta os neurônios do reservatório com os neurônios da camada de saída. A matriz W_{out} é calculada pela Pseudoinversa de Moore Penrose, tendo a matriz de saída $x(t)$ do reservatório de cada período t treinado e a saída desejada (*target*) na matriz $y(t)$.

2.2.3.1 Deep Reservoir Computing

A arquitetura *Deep Reservoir Computing* (*deep RC*) é caracterizada por várias camadas de reservatórios concatenadas uma após a outra. Em uma *deep RC*, a primeira camada é alimentada pela entrada externa de dados e opera como um reservatório único. Cada reservatório posterior a essa primeira camada é alimentado pela saída do reservatório anterior (GALLICCHIO; MICHELI; PEDRELLI, 2017). A Equação (5) descreve a função de saída de cada reservatório em uma *deep RC*.

$$x^{(l)}(t) = (1 - a^{(l)})x^{(l)}(t - 1) + a^{(l)}f\left(W_{in}^{(l)}i^{(l)}(t) + W_{res}^{(l)}x^{(l)}(t - 1)\right) \quad (5)$$

onde o sobrescrito (l) é utilizado para referenciar os parâmetros do reservatório na camada l , e $i^{(l)}$ se refere à entrada do reservatório. Se $l = 1$, então $i^{(l)} = u(t)$, onde $u(t)$ é a entrada externa da *deep RC*, caso contrário, $i^{(l)} = x^{(l-1)}(t)$, ou seja, a entrada do reservatório da camada l será a saída do reservatório da camada anterior.

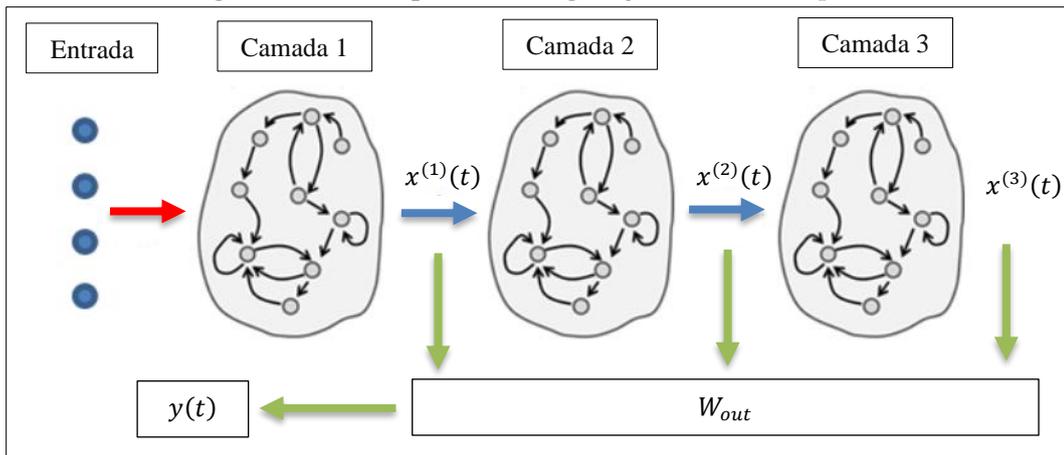
A matriz W_{out} que interliga a saída dos reservatórios concatenados com o neurônio da camada de saída, é calculada a partir da Equação (6).

$$y(t) = W_{out}\left[x^{(1)}(t)x^{(2)}(t) \dots x^{(N_{layers})}(t)\right]^T \quad (6)$$

W_{out} é calculada pela Pseudoinversa de Moore Penrose, tendo o vetor de saída $x^{(layer)}(t)$ de cada reservatório treinado para cada t , e a saída desejada (*target*) na matriz $y(t)$ (GALLICCHIO; MICHELI; PEDRELLI, 2017).

A Figura 21 mostra um exemplo de configuração de uma *deep* RC com 3 camadas (reservatórios) e 9 neurônios em cada reservatório.

Figura 21 - Exemplo de configuração de uma *deep* RC.



Fonte: Adaptado de Gallicchio; Micheli; Pedrelli (2017).

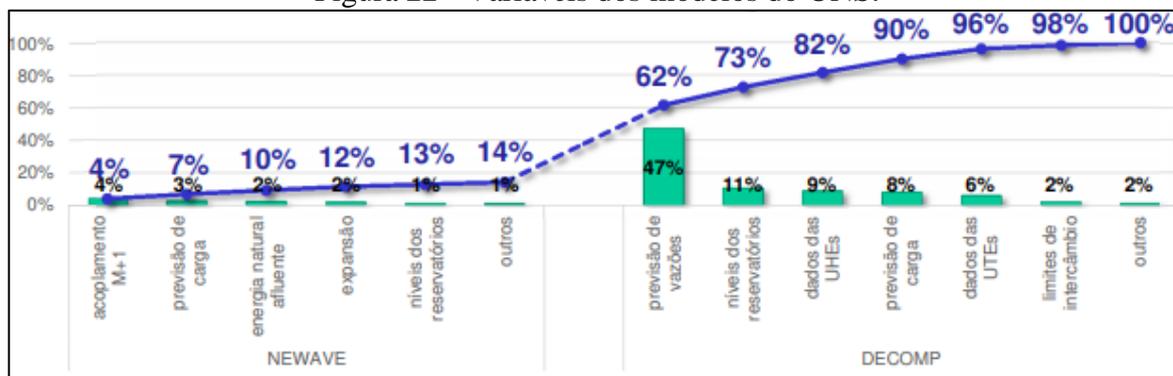
3 MÉTODO

Neste capítulo, serão apresentados os métodos para elaboração de uma ferramenta capaz de prever o CMO médio semanal do mercado *spot* de energia elétrica do submercado SE/CO, utilizando a RNA *Deep Reservoir Computing*. Primeiramente, será abordada a escolha e justificativa das variáveis de entrada do modelo, posteriormente, será efetuada uma análise descritiva das variáveis e mostrado o processamento dos dados. Também, serão apresentadas a configuração da *deep RC* e o método de validação.

3.1 ESCOLHA DAS VARIÁVEIS DE ENTRADA PARA O MODELO

As variáveis para o modelo foram selecionadas através da análise dos fatores que mais contribuem para o valor do CMO. Além disso, as variáveis de entrada devem possuir uma fonte consistente e confiável para projeções futuras, como, por exemplo, uma consultoria de meteorologia para os dados futuros de vazões. Caso contrário, o modelo se torna inviável para aplicações práticas. A Figura 22 mostra as variáveis de entrada e sua relevância nos modelos NEWAVE e DECOMP.

Figura 22 - Variáveis dos modelos do ONS.



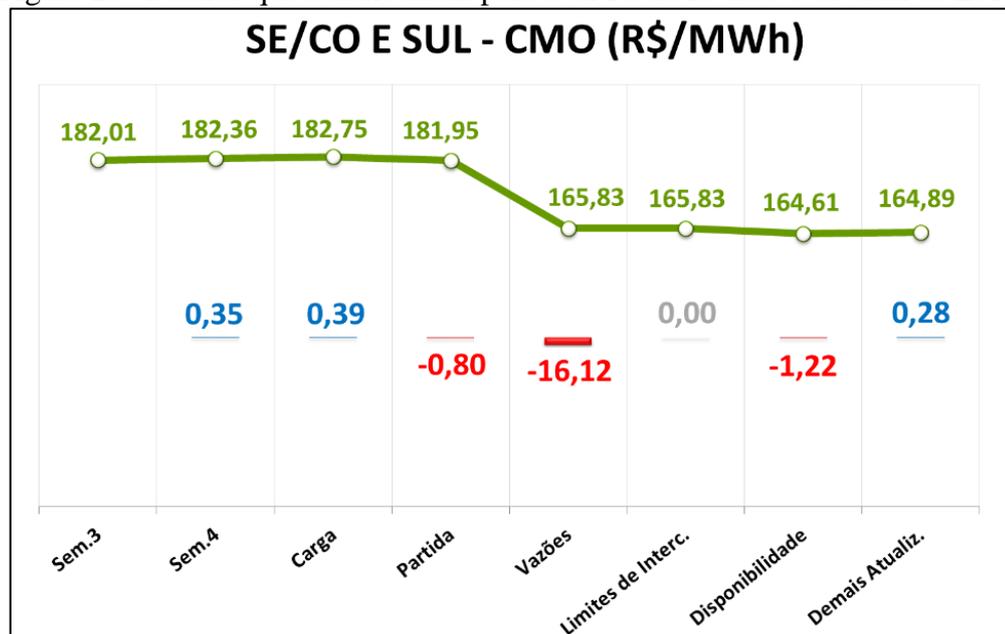
Fonte: ONS (2019I).

O DECOMP possui as variáveis mais significativas para o preço de energia elétrica. As cinco variáveis que mais possuem relevância são a previsão de vazões (47%), níveis dos reservatórios (11%), dados das UHEs (9%), previsão de carga (8%) e dados das UTEs (6%). As variáveis que mais variam ao longo do tempo são os níveis dos reservatórios, carga e previsão de vazões. Os dados das usinas hidrelétricas e termelétricas englobam, por exemplo, as restrições de operação ou o custo de operação para o caso de usinas térmicas. Esses dados não variam significativamente de uma semana para a outra se comparado com as variáveis de

vazões, nível de reservatório e carga. Os limites de intercâmbio, que se refere na capacidade de transmissão de energia elétrica de um submercado para outro, possui impacto de apenas 2% no preço da energia elétrica. O preço pode sofrer impacto devido aos limites de intercâmbio somente se tais limites sofrerem grandes mudanças no curto prazo. O NEWAVE possui algumas variáveis iguais ao do DECOMP, como energia natural afluente, previsão de carga e níveis de reservatórios, e todas elas possuem influência inferior se comparado com as principais variáveis utilizadas no DECOMP.

Como pode ser visto na Figura 23, o fator que mais contribuiu para a redução do valor do CMO da semana do dia 13/04 a 19/04/2019 para a semana do dia 20/04 a 26/04/2019, foram as vazões. O valor do CMO foi de R\$ 182,01 para R\$ 164,89, sendo as vazões responsáveis pela redução de R\$ 16,12.

Figura 23 - Fatores que contribuíram para o CMO da revisão 3 de abril de 2019.



Fonte: ONS (2019j).

Como comparação, Pereira (2016) utilizou como variáveis de entrada para o modelo a geração hídrica, geração térmica, carga, energia armazenada e a ENA. Porém, as variáveis de geração são consequências das outras variáveis, tornando difícil a previsão delas para aplicação como variáveis de entrada do modelo. Assim, as variáveis de geração não serão utilizadas para o modelo proposto. Também, Rodrigues (2009) utilizou 16 variáveis de entrada para o modelo, sendo a energia armazenada, ENA, ENA máxima, geração de Itaipu, gerações hídrica, térmica, nuclear e eólica, carga, intercâmbio de energia entre os submercados, importação ou exportação de energia internacional, e os valores do CMO de semanas anteriores. O modelo apresentou

grande assertividade (erro médio relativo no patamar médio de 3%), porém, o modelo é inviável para aplicações práticas devido à grande quantidade de variáveis de entrada a serem previstas para cenários futuros.

Dessa forma, tendo em vista a aplicação diária e prática do modelo de previsão a ser desenvolvido, as variáveis de entrada escolhidas foram a energia armazenada, energia natural afluyente e a carga do subsistema. Para o valor de saída, foi utilizado o CMO como *target* da *deep RC*. A energia natural afluyente é a energia gerada a partir da vazão de uma determinada bacia ou rio para um reservatório de uma usina hídrica, dado em MWmédios. A energia armazenada é a quantidade de água armazenada nos reservatórios de geração hídrica, dado em MWmédios. A carga é o consumo de energia elétrica em MWmédios. A unidade MWmédios é a razão da energia elétrica em MWh de um determinado período pelo número de horas do mesmo período.

Aplicando o modelo como viés prático, a série temporal futura da carga pode ser adquirida pelo ONS divulgada nas projeções do PMO. A projeção da energia natural afluyente pode ser adquirida por consultorias de meteorologia especializadas no atendimento à comercializadoras de energia. Por fim, a energia armazenada (nível dos reservatórios), é consequência da posição atual dos reservatórios que possui comportamento sazonal, somada das vazões futuras e excluindo a geração hídrica. Para o modelo proposto, será utilizado um percentual da base de dados para treinamento e o restante para testes.

3.2 ANÁLISE E PROCESSAMENTO DOS DADOS

A série temporal de cada variável de entrada e a única saída possuem 538 amostras. Os dados fazem referência a cada semana operativa de 27/12/2008 até 13/04/2019 do submercado SE/CO. Os dados de ENA, energia armazenada, carga e o CMO são disponibilizados na página do histórico de operação do ONS. Com o modelo proposto finalizado, será testada a sua performance utilizando as semanas mais próximas da atualidade e toda a base de dados. Como as versões do NEWAVE e DECOMP, bem como as restrições, linhas de transmissão e entrada de novos projetos em operação, mudaram gradativamente ao longo desse período, é provável que o modelo, com os dados das semanas mais próximas da atualidade, apresente um desempenho melhor se comparado com o modelo utilizando toda a base de dados.

Na Tabela 2, são mostradas as correlações entre as variáveis para o modelo de previsão. A variável que possui maior correlação positiva com o CMO é a carga, enquanto o maior valor de correlação negativa é a energia armazenada.

Tabela 2 - Correlação entre as variáveis do modelo.

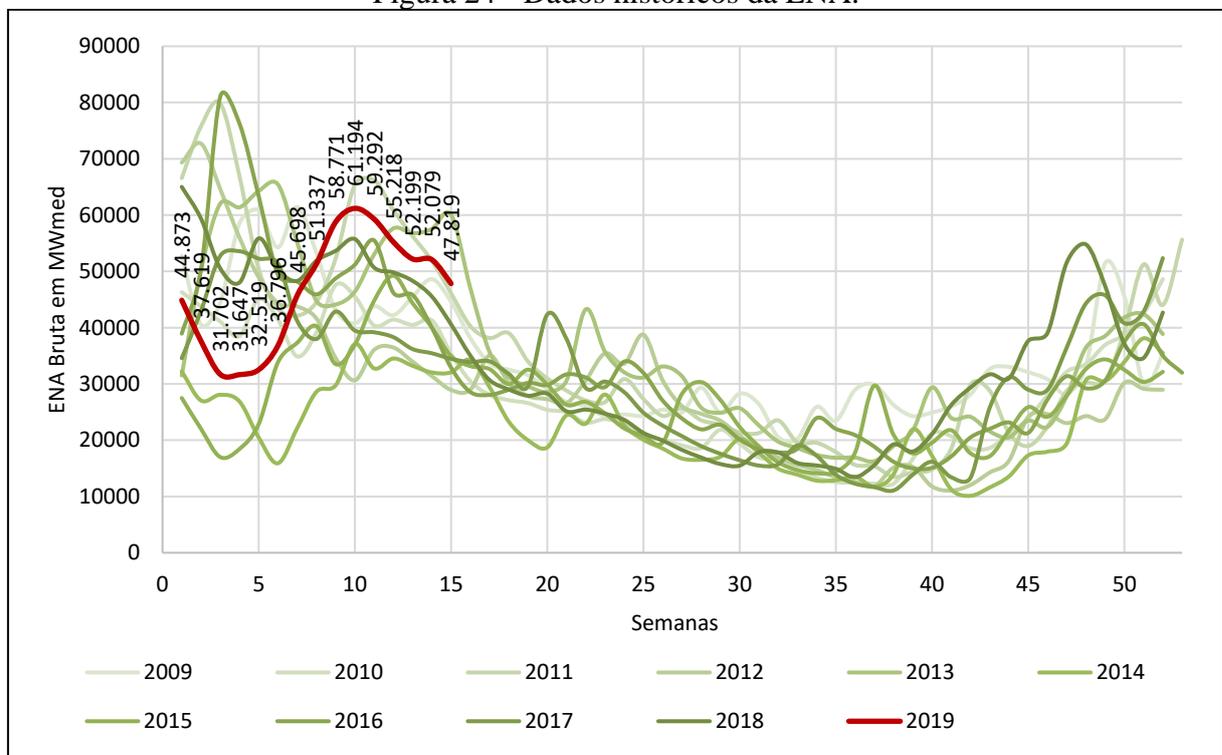
Variáveis	Semana	ENA	Energia Armazenada	Carga	CMO
Semana	1	-0,5106364	-0,22147652	-0,268937	-0,0806078
ENA	-0,5106364	1	0,08650637	0,2216904	-0,2459642
Energia Armazenada	-0,2214765	0,08650637	1	-0,47926	-0,5802704
Carga	-0,268937	0,22169043	-0,47926011	1	0,34619536
CMO	-0,0806078	-0,2459642	-0,58027037	0,3461954	1

Fonte: Elaborada pelo autor (2019).

Como forma de apresentar as variáveis utilizadas no modelo proposto, foi efetuada a estatística descritiva dos dados, gráfico de histograma e as séries históricas plotadas em um gráfico de período anual.

A Figura 24 mostra os dados históricos da ENA, a Tabela 3 mostra os dados estatísticos para a variável ENA e a Figura 25 mostra o gráfico de histograma.

Figura 24 - Dados históricos da ENA.



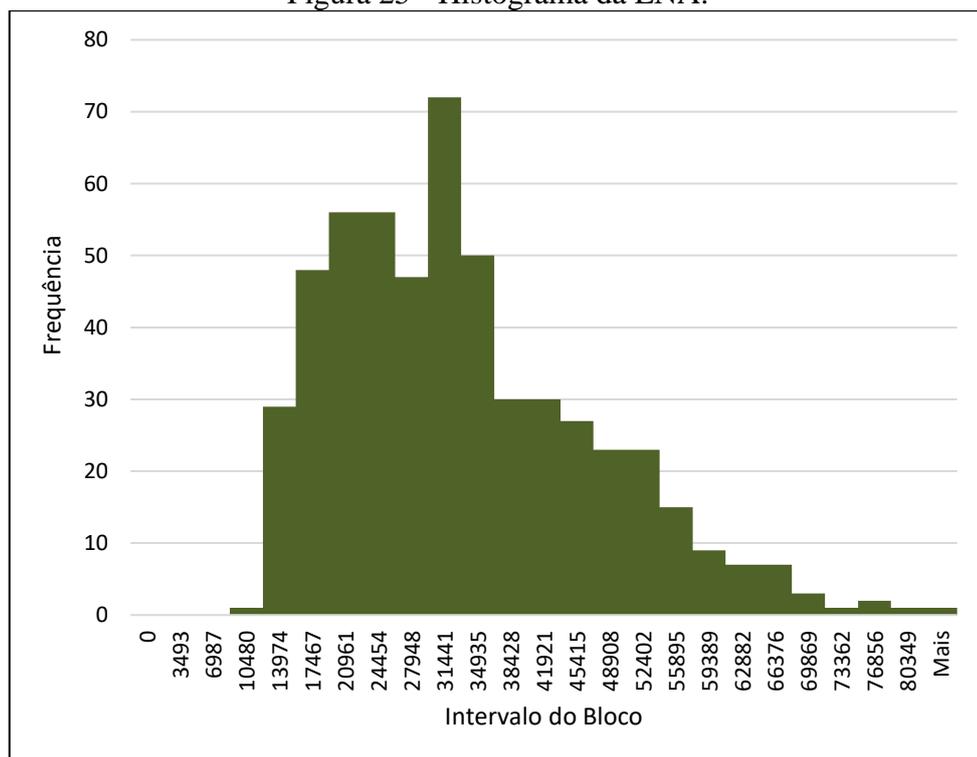
Fonte: Adaptado de ONS (2019e).

Tabela 3 - Dados estatísticos da variável ENA.

ENA	
Média	31690,63
Erro padrão	591,05
Mediana	29404,50
Moda	24279
Desvio padrão	13709,41
Variância da amostra	187948095,3
Curtose	0,353690992
Assimetria	0,830196744
Intervalo	70910
Mínimo	10120
Máximo	81030
Soma	17049559,2
Contagem	538

Fonte: Elaborada pelo autor (2019).

Figura 25 - Histograma da ENA.



Fonte: Elaborada pelo autor (2019).

A Figura 26 mostra os dados históricos da energia armazenada, a Tabela 4 mostra os dados estatísticos da variável energia armazenada e a Figura 27 mostra o gráfico de histograma.

Figura 26 - Dados históricos de Energia Armazenada.

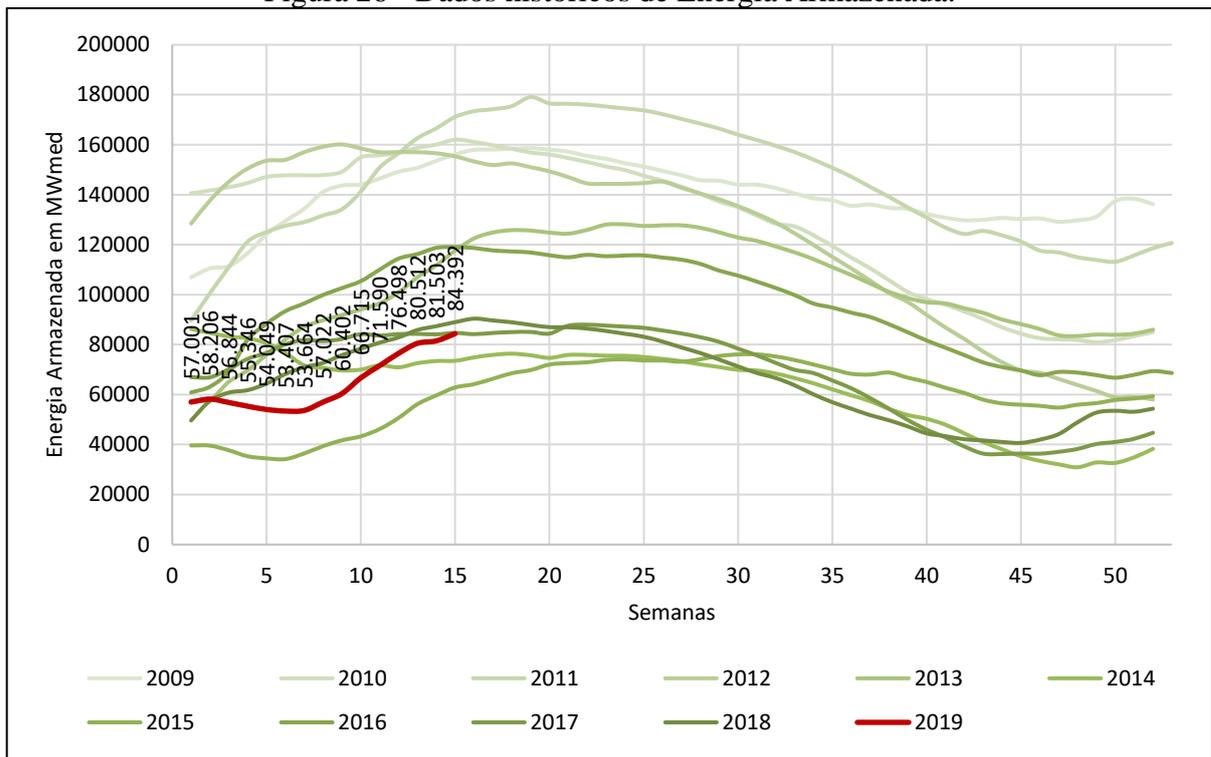
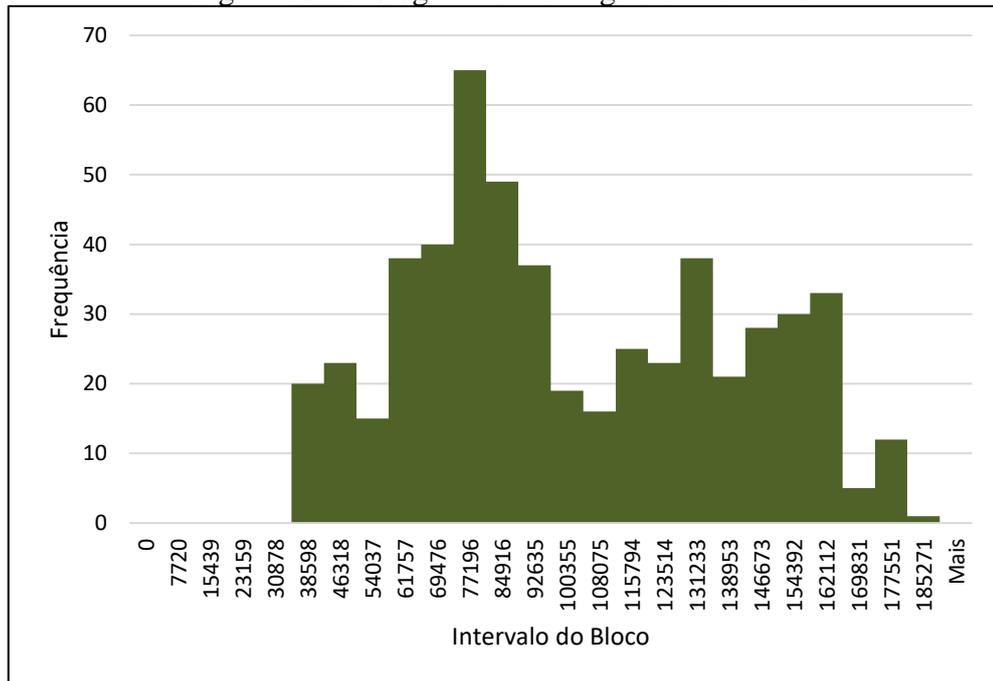


Tabela 4 - Dados estatísticos da variável Energia Armazenada.

Energia Armazenada	
Média	98340,58
Erro padrão	1642,09
Mediana	87466,50
Moda	57980
Desvio padrão	38088,08
Variância da amostra	1450702242
Curtose	-1,070337889
Assimetria	0,253442154
Intervalo	148127
Mínimo	30928
Máximo	179055
Soma	52907233
Contagem	538

Fonte: Elaborada pelo autor (2019).

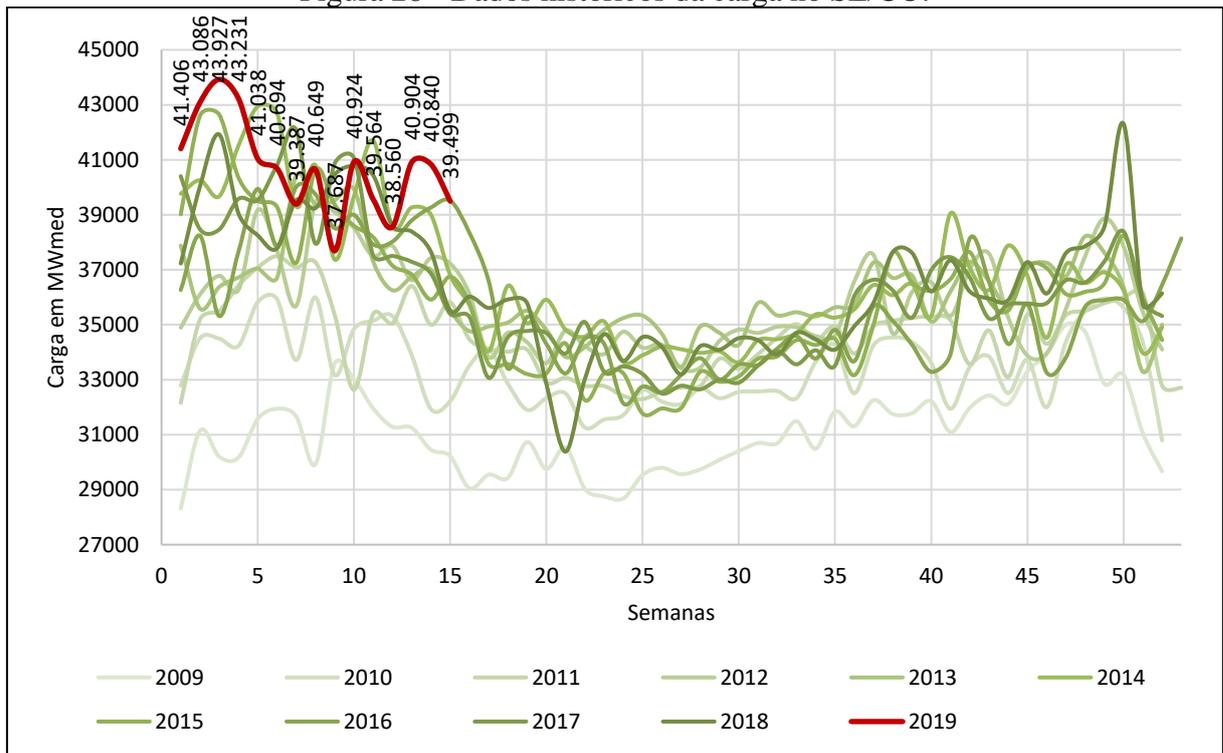
Figura 27 - Histograma da Energia Armazenada.



Fonte: Elaborada pelo autor (2019).

A Figura 28 mostra os dados históricos da carga no SE/CO, a Tabela 5 mostra os dados estatísticos da variável carga e a Figura 29 mostra o gráfico de histograma.

Figura 28 - Dados históricos da carga no SE/CO.



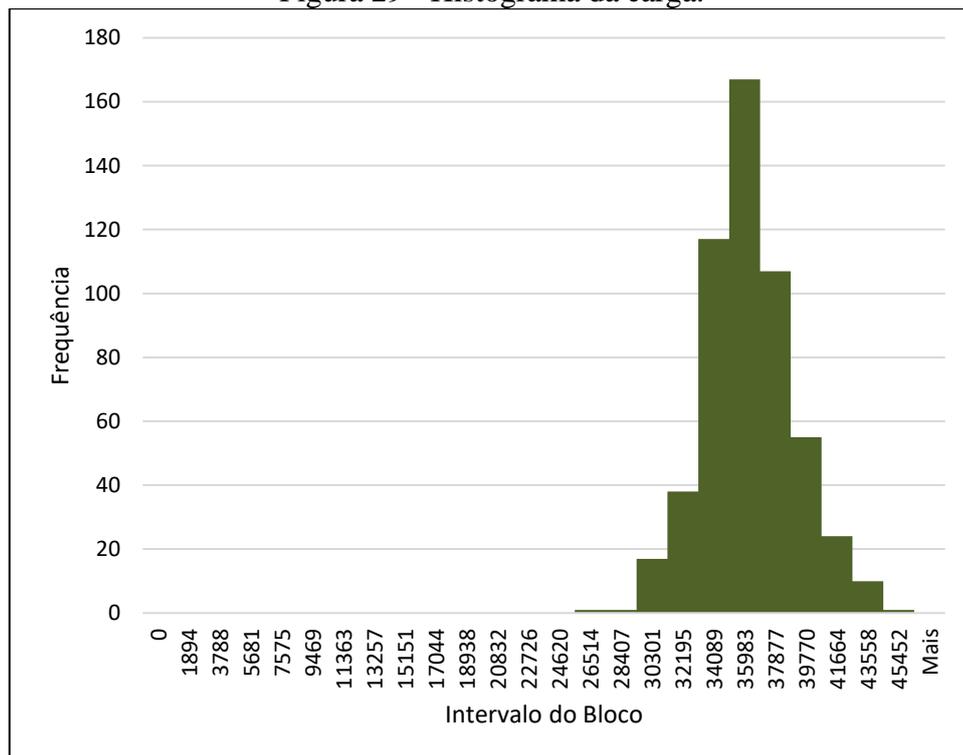
Fonte: Adaptado de ONS (2019b).

Tabela 5 - Dados estatísticos da variável carga no SE/CO.

Carga	
Média	35336,80
Erro padrão	120,09
Mediana	35134,54
Moda	-
Desvio padrão	2785,47
Variância da amostra	7758859,96
Curtose	0,324206999
Assimetria	0,248360278
Intervalo	18241,95
Mínimo	25685,00
Máximo	43926,95
Soma	19011200,45
Contagem	538

Fonte: Elaborada pelo autor (2019).

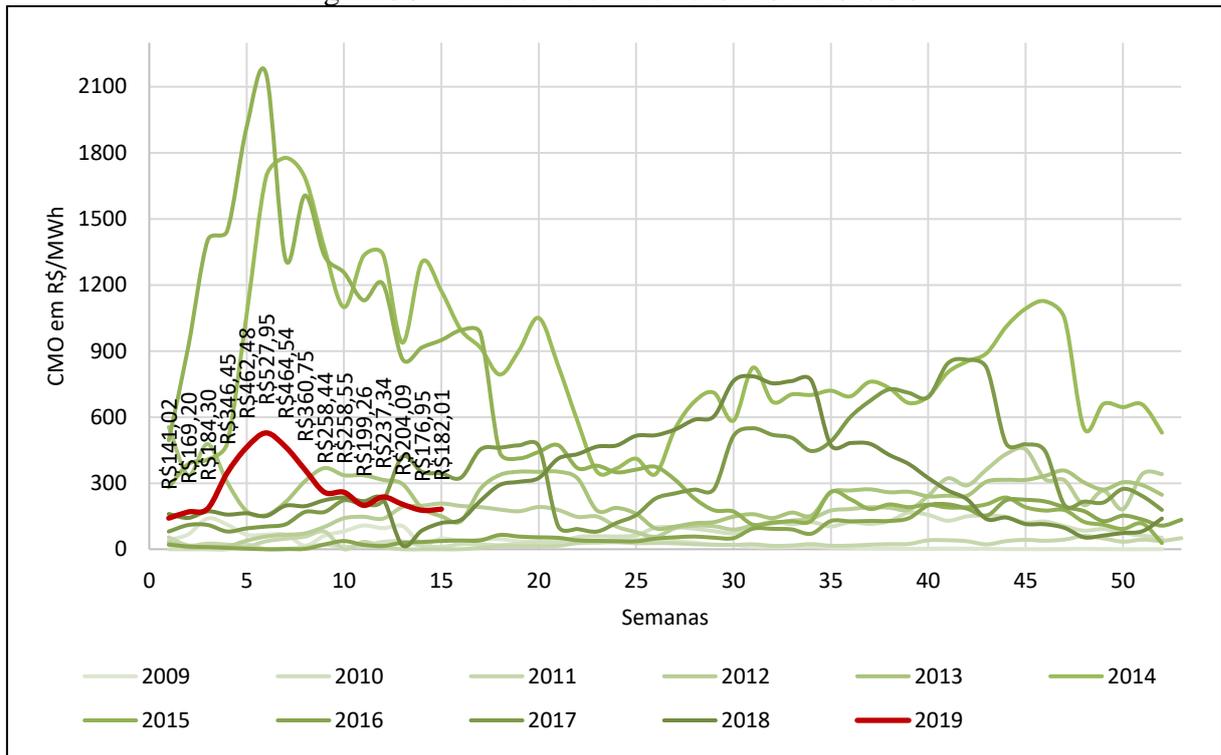
Figura 29 - Histograma da carga.



Fonte: Elaborada pelo autor (2019).

A Figura 30 mostra os dados históricos do CMO no SE/CO, a Tabela 6 mostra os dados estatísticos da variável CMO e a Figura 31 mostra o gráfico de histograma.

Figura 30 - Dados históricos do CMO no SE/CO.



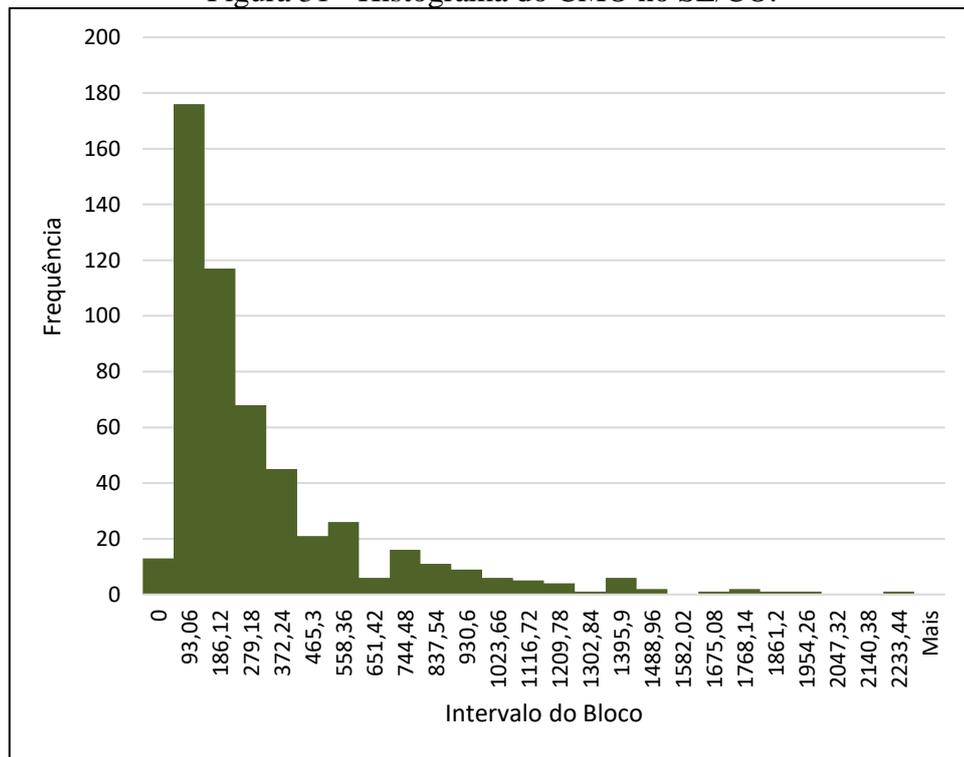
Fonte: Adaptado de ONS (2019c).

Tabela 6 - Dados estatísticos do CMO no SE/CO.

CMO	
Média	268,68
Erro padrão	14,31
Mediana	152,42
Moda	0
Desvio padrão	332,02
Variância da amostra	110238,46
Curtose	6,040077001
Assimetria	2,262712666
Intervalo	2158,57
Mínimo	0
Máximo	2158,57
Soma	144552,74
Contagem	538

Fonte: Elaborada pelo autor (2019).

Figura 31 - Histograma do CMO no SE/CO.



Fonte: Elaborada pelo autor (2019).

Antes de iniciar o processo de treinamento pela rede neural, os dados deverão ser normalizados, visando à melhoria do desempenho de treinamento. A normalização tem por objetivo deixar os dados na faixa de variação dinâmica das funções de ativação, com o intuito de evitar a saturação dos neurônios (SILVA; SPATTI; FLAUZINO, 2010).

Para o modelo proposto, serão testados os modelos de normalização do Teorema de Tales, mostrado na Equação (7), a normalização *z-score*, mostrada na Equação (8), e a *p-norm*, como mostra a Equação (9).

$$z = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (7)$$

onde z é novo valor do dado, x é o dado a ser normalizado, x_{min} é o menor valor da série temporal e x_{max} é o maior valor da série temporal.

$$z = \frac{(x - \mu)}{\sigma} \quad (8)$$

onde z é o novo valor do dado, x é o dado a ser normalizado, μ é a média da série temporal e σ é o desvio padrão da série temporal.

$$x_p = (\sum_{i=1}^n |x_i|^p)^{\frac{1}{p}} \quad (9)$$

onde x_i é o valor da série temporal na posição i , p modela o tipo da normalização, tal que se $p = 1$ é a normalização Manhattan, se $p = 2$ é a normalização Euclidiana. Posteriormente, cada valor da série temporal será dividido por x_p .

3.3 CONFIGURAÇÃO DA *DEEP RESERVOIR COMPUTING*

A quantidade de neurônios na entrada da *deep RC* é definida pelo número de variáveis de entrada do modelo. As variáveis de entrada escolhidas foram a energia armazenada, carga e a energia natural afluyente. Para o modelo proposto, será testado também o uso dos valores de semanas anteriores de energia natural afluyente juntamente com a correspondente semana como forma de avaliar a performance da *deep RC*.

A quantidade de neurônios do reservatório, como sugerido por Barceló (2017), será na ordem de dezenas ou centenas de neurônios. Para isso, será testado empiricamente qual a melhor configuração para o RC. Para Galle e Valença (2013), esse parâmetro foi encontrado de forma aleatória, resultando em 20 neurônios. A quantidade de reservatórios também será definida empiricamente.

Os pesos da camada de entrada para o reservatório são gerados de forma aleatória a partir de uma distribuição uniforme.

O estado inicial dos pesos das conexões do reservatório é iniciado como nulo, assim, são necessários alguns ciclos de *warm up* para eliminar a dependência do estado inicial. A taxa de conectividade do reservatório não será definida antecipadamente, porém, será testada a performance para valores entre 1% até 20%, conforme relatado por Barceló (2017).

A função de ativação para os neurônios do reservatório dependerá do tipo de normalização escolhida para os dados de entrada. Como serão implementadas e analisadas as normalizações citadas na seção 3.2, as funções escolhidas foram a tangente hiperbólica e a logarítmica sigmoideal. Essas funções, além de serem largamente utilizadas entre as funções totalmente diferenciáveis, elas introduzem um comportamento não linear para a rede neural.

Para o neurônio de saída, será utilizado a pseudo-inversa de Moore-Penrose como forma de treinar os dados para previsão do preço de energia elétrica. A Figura 32 mostra um pseudocódigo da *deep RC* para um único reservatório.

Figura 32 - Pseudocódigo do *reservoir computing* para um reservatório.

```

1 Definir a quantidade de neurônios na camada de entrada ( $E$ );
2 Definir a quantidade de neurônios no reservoir ( $N$ );
3 Definir a quantidade de neurônios na camada de saída ( $O$ );
4 Criar a matriz  $W_{in}$  de tamanho  $E \times N$  e gerar aleatoriamente os pesos entre
  -1 e 1;
5 Criar a matriz  $W_{res}$  de tamanho  $N \times N$  e gerar aleatoriamente os pesos entre
  -1 e 1;
6 while até o final da quantidade de ciclos de warm up do
7   | atualizar os estados dos neurônios do RC;
8 end
9 while até que o critério de parada seja atingido do
10  | for cada valor do conjunto de entrada do
11  |   | atualizar os estados dos neurônios do RC;
12  | end
13  | Calcular a pseudo-inversa de Moore-Penrose para encontrar a matriz de
  | pesos que conecta o RC à camada de saída;
14  | for cada valor do conjunto de validação cruzada do
15  |   | atualizar os estados dos neurônios do RC;
16  | end
17  | Calcular os valores de saída do RC;
18  | Calcular o EMQ;
19  | Verificar se o critério de parada já foi atingido;
20 end
21 for cada valor do conjunto de testes do
22  | atualizar os estados dos neurônios do RC;
23 end
24 Calcular os valores de saída do RC;
25 Calcular o Erro Percentual Médio Absoluto;

```

Fonte: Adaptado de Bezerra (2016).

3.4 VALIDAÇÃO

Para a validação do modelo proposto, e como forma de avaliar a performance entre as configurações do modelo, será computado o Erro Percentual Médio Absoluto (EPMA), mostrado na Equação (10) e a correlação entre o preço de energia elétrica realizado e previsto.

$$EPMA = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{A_t - P_t}{A_t} \right|, \quad (10)$$

onde A_t é o valor atual, P_t é o valor previsto pela rede e n é a quantidade de amostras.

Além disso, será exposto um cenário de compra e venda de energia elétrica utilizando a curva da previsão da rede neural, mostrando possíveis resultados de acordo com a estratégia firmada. Assim, é mostrado como um *middle office* pode atuar juntamente com o *front office* e efetuar decisões para maximização dos ganhos.

4 RESULTADOS

Este capítulo apresenta os experimentos e resultados da previsão do preço de energia elétrica no mercado *spot* para o submercado SE/CO utilizando *deep RC*. Inicialmente, será apresentada a previsão do preço de energia elétrica através da rede neural Perceptron multicamadas. Posteriormente, serão apresentados os resultados das variações da configuração do modelo *deep RC* e cenários efetuando estratégia de compra ou venda de energia elétrica através da curva prevista pela rede neural proposta.

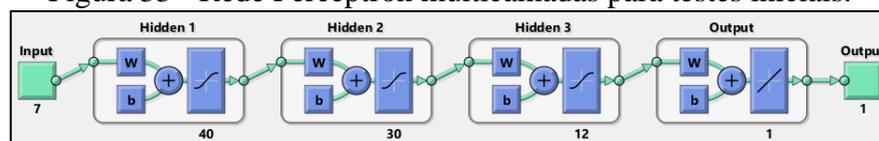
4.1 RESULTADOS DA REDE NEURAL PERCEPTRON MULTICAMADAS

Foi treinada uma rede neural Perceptron Multicamadas com as variáveis de entrada sendo a energia armazenada até o último dia da semana anterior, energia natural afluente da respectiva semana, bem como as três semanas anteriores, a carga da respectiva semana e o número da semana do ano. A variável de saída é o CMO do SE/CO médio semanal. Foram utilizadas três camadas ocultas com 40, 30 e 12 neurônios em cada camada. A quantidade de camadas e a quantidade de neurônios foram encontradas empiricamente. Para isso, foram testadas até 4 camadas, variando-se os neurônios de 1 até 100 com passo igual a 4.

A função de ativação em todos os neurônios das camadas ocultas foi a tangente hiperbólica, podendo os valores de saída variar de -1 até 1. Foi também testada a função sigmoide logística, obtendo resultados inferior se comparado com a tangente hiperbólica.

A função de ativação da camada de saída é linear. O método de treinamento foi o *backpropagation* de gradiente conjugado em escala. A normalização dos dados foi efetuada pela *p-norm* mostrada na Equação (9) sendo $p = 2$, pois foi o método que apresentou os melhores resultados. O critério de parada foi definido como o erro quadrático médio de 100. A rede foi implementada utilizando as bibliotecas de redes neurais no *software* Matlab. A Figura 33 mostra a configuração da rede neural implementada.

Figura 33 - Rede Perceptron multicamadas para testes iniciais.

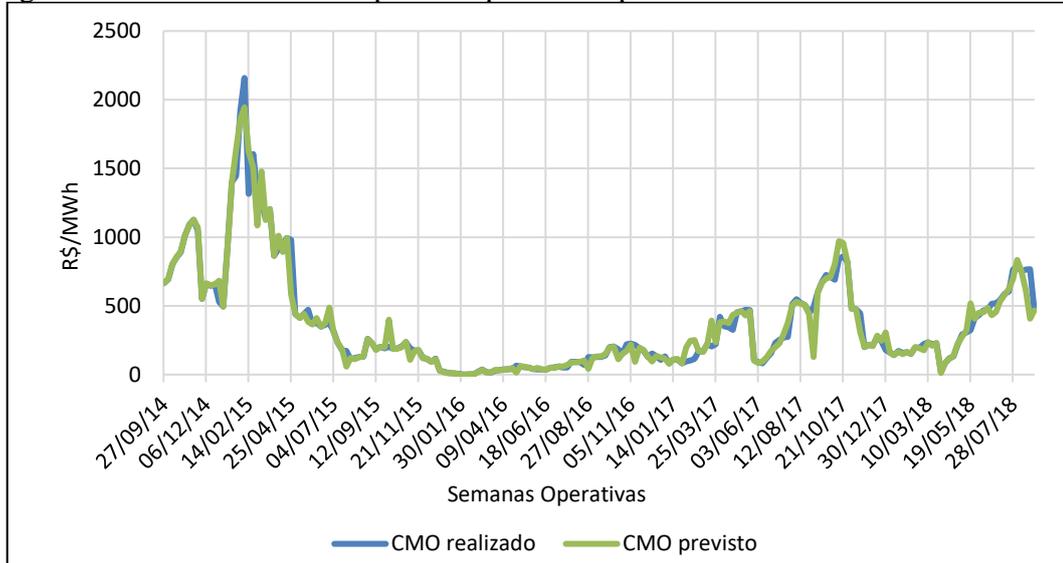


Fonte: Elaborada pelo autor (2019).

Para o treinamento, foram utilizados 206 dados correspondentes da semana operativa do dia 27/09/2014 até 01/09/2018. Foi utilizado esse período pois foi o que apresentou os

melhores resultados. A Figura 34 mostra o gráfico entre o CMO realizado e o CMO previsto pela rede neural. O EPMA para esse período, utilizando os dados treinados, foi de 16,74%. A correlação entre o CMO realizado e o CMO previsto foi de 97,96%.

Figura 34 - CMO realizado e previsto pela Perceptron Multicamadas no treinamento.

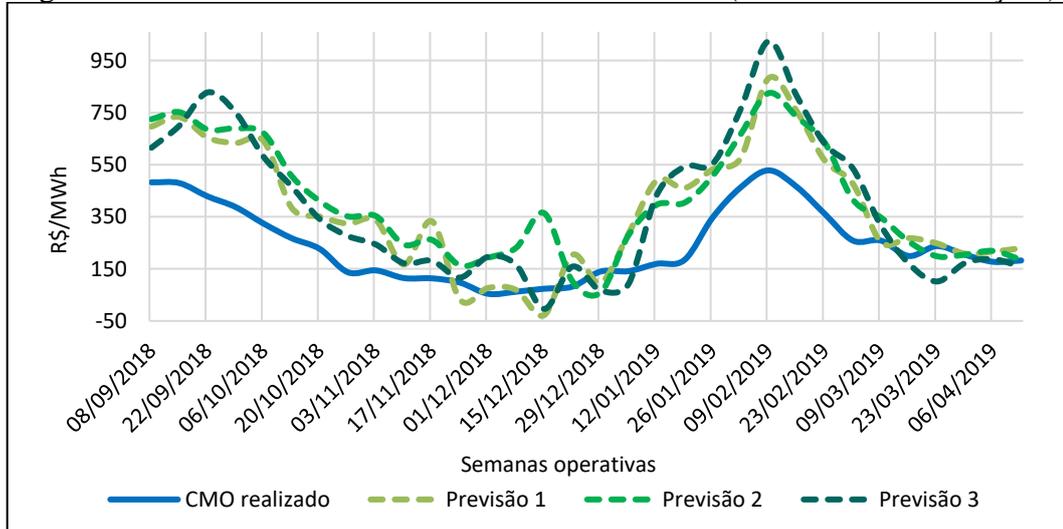


Fonte: Elaborada pelo autor (2019).

Posteriormente, com o restante dos dados que não foram utilizados para treinamento, foram efetuados diversos testes com a rede já treinada para averiguar a performance da previsão, buscando a maior correlação e o menor EPMA.

A Figura 35 mostra o resultado das três melhores correlações do CMO previsto e o CMO realizado para a semana operativa de 08/09/2018 até 14/04/2019 utilizando os mesmos parâmetros citados anteriormente.

Figura 35 - Previsão efetuada com dados não treinados (três maiores correlações).



Fonte: Elaborada pelo autor (2019).

A Tabela 7 mostra a correlação e o EPMA das previsões que obtiveram os maiores valores para correlações do CMO pela Perceptron Multicamadas.

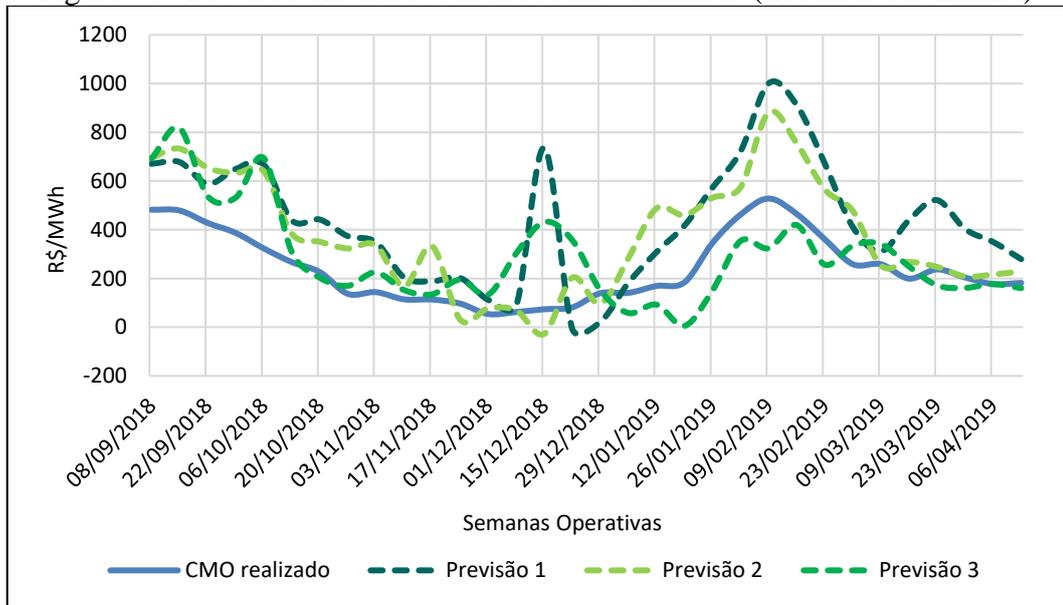
Tabela 7 - Maiores Correlações da Perceptron Multicamadas com dados não treinados.

Métrica	Previsão 1	Previsão 2	Previsão 3
Correlação	90,83%	90,20%	90,09%
EPMA	69,85%	91,69%	76,02%

Fonte: Elaborada pelo autor (2019).

Posteriormente, o modelo buscou os menores EPMA para análise e comparação. A Figura 36 mostra o resultado das iterações que resultaram os três menores EPMA do CMO previsto.

Figura 36 - Previsão efetuada com dados não treinados (três menores EPMA).



Fonte: Elaborada pelo autor (2019).

A Tabela 8 mostra a correlação e o EPMA das previsões que obtiveram os menores valores de EPMA do CMO pela Perceptron Multicamadas.

Tabela 8 - Menores EPMA da Perceptron Multicamadas com dados não treinados.

Métrica	Previsão 1	Previsão 2	Previsão 3
EPMA	42,61%	69,85%	75,73%
Correlação	83,09%	90,83%	62,36%

Fonte: Elaborada pelo autor (2019).

Como mostrado na Tabela 7, a maior correlação foi de 90,83% com EPMA 69,85%, e o menor EPMA, como mostrado na Tabela 8, foi de 42,61% com correlação de 83,09%.

Como pode ser visto na Figura 35 e 36, nas semanas do dia 15/12/2018 e 22/12/2018 houve previsões efetuadas pela rede neural que resultaram em valores negativos. Isso ocorreu, pois, a função de ativação dos neurônios utilizada na rede foi a tangente hiperbólica, que pode assumir valores de saída entre -1 até 1.

4.2 RESULTADOS DA REDE NEURAL *DEEP RC*

Foram realizados dois tipos de testes para averiguar a performance da *deep RC*. O primeiro foi realizado com as mesmas variáveis de entrada utilizadas no experimento da Perceptron Multicamadas e, posteriormente, foram adicionadas novas variáveis.

Todos os experimentos para encontrar a melhor configuração da *deep RC* foram realizados de forma empírica, conforme também elaborado por Galle e Valença (2013).

O período dos dados para treinamento da *deep RC* foi alterado para 02/01/2016 até 01/09/2018 (140 semanas) pois foi o período que apresentou melhores resultados. Também, foram testados outros períodos, por exemplo, as últimas 150, 160, 180 e 206 semanas. Todavia, a correlação alcançava até 30 pontos percentuais inferior se comparado com as últimas 140 semanas.

O período da base de dados para testes da *deep RC*, que não foram utilizados para treinamento, foi o mesmo que os experimentos da Perceptron Multicamadas (08/09/2018 até 14/04/2019) que corresponde a 32 semanas operativas. Foram efetuados diversos experimentos com outros períodos de testes, e se obteve resultados semelhantes quanto à correlação e EPMA.

Ao contrário da Perceptron Multicamadas, a normalização dos dados pelo Teorema de Tales, mostrada na Equação (7), foi a que apresentou os melhores resultados.

A rede *deep RC* foi implementada no *software* Matlab, baseada no trabalho de Gallicchio, Micheli e Pedrelli (2017).

4.2.1 *Deep RC* com 7 variáveis de entrada

Para esse experimento, as variáveis de entrada foram a energia armazenada até o último dia da semana anterior, energia natural afluyente da respectiva semana bem como as três semanas anteriores, a carga da respectiva semana e o número da semana do ano. Essas variáveis

são as mesmas utilizadas na Perceptron Multicamadas e que foram apresentadas na seção anterior.

A Tabela 9 mostra a configuração da *deep RC* para a previsão que obteve uma maior correlação e menor EPMA. A iteração que buscou somente uma maior correlação e a iteração que buscou somente um menor EPMA, foi a mesma que obteve maior correlação e menor EPMA.

Para valores de raio espectral, foram testados os valores de 0 a 1 com passo igual a 0,1. Para as quantidades de neurônios, foram testados os valores de 1, 5, 7 e 10 até 100 com passo igual a 10. Para as quantidades de camadas, foram testados os valores de 1, 3, 5 e 10 até 100 com passo igual a 10. Para valores de *bias*, foram testados apenas os valores 0 e 1. Para os valores de *leaking rate*, foram testados os valores de 0,1 até 1 com passo igual a 0,1. Para os valores de input escala e inter escala, foram testados os valores de 0,01 e 0,1 até 1 com passo igual a 0,1. Para o período de *warmup*, foram testados os valores de 5 até 10 com passo igual a 1. Foram testadas as funções de ativação tangente hiperbólica e logarítmica sigmoidal. Porém, a logarítmica sigmoidal obteve resultados melhores.

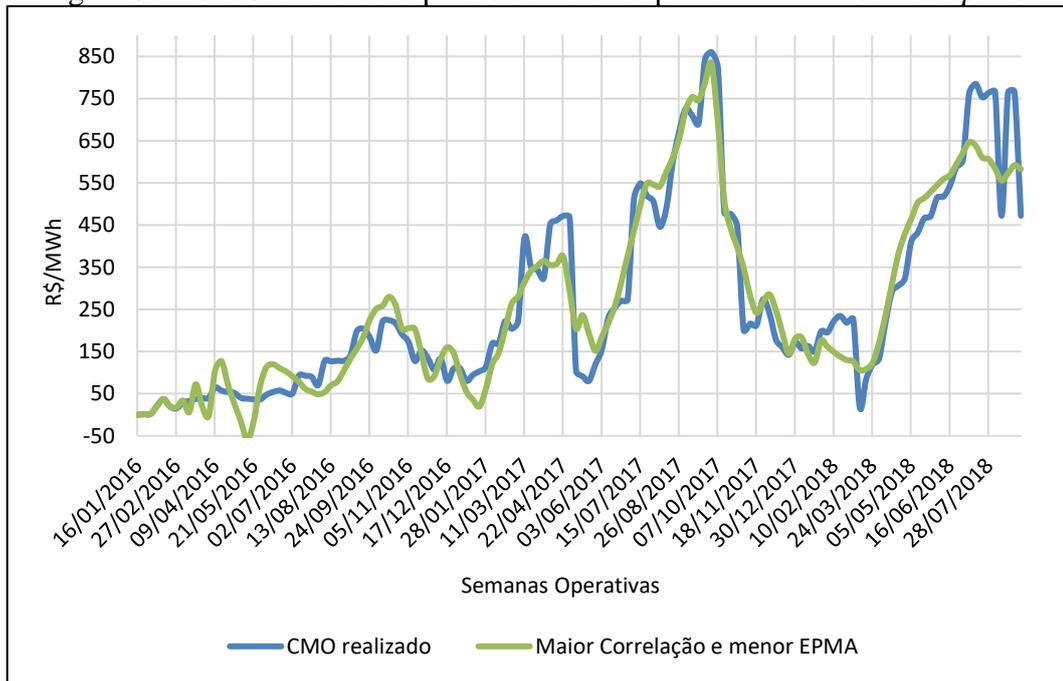
Tabela 9 - Configuração da *deep RC* para teste com 7 variáveis.

Parâmetro	Iteração
	Maior correlação e menor EPMA
Raio Espectral	1
Número de Neurônios	7
Número de Camadas	10
Taxa de Conectividade	0,9
Bias	1
<i>Leaking Rate</i>	0,1
Input Escala	1
Inter Escala	1
Período de <i>Warmup</i>	5
Função de ativação	Logarítmica Sigmoidal

Fonte: Elaborada pelo autor (2019).

A Figura 37 mostra a previsão efetuada pela *deep RC* para dados treinados de 02/01/2016 até 01/09/2018 (140 semanas). A correlação para os dados treinados pela *deep RC* e realizados foi de 95,57% e o EPMA foi de 36,75%.

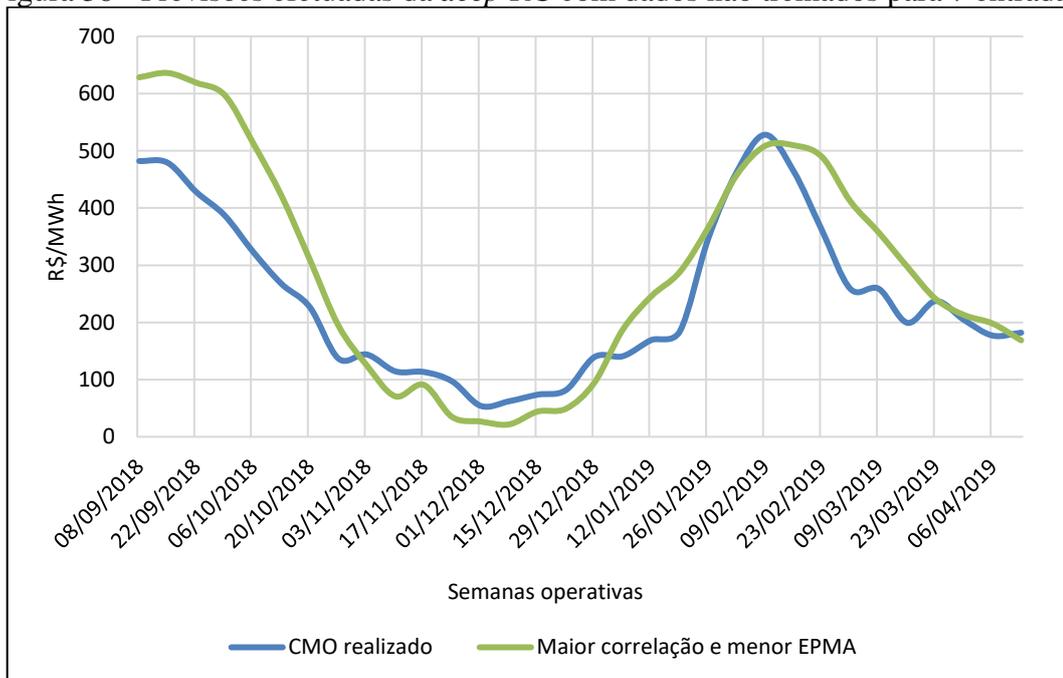
Figura 37 - CMO realizado e previsto utilizado para treinamento da *deep RC*.



Fonte: Elaborada pelo autor (2019).

Posteriormente, foram analisados os resultados para os dados testados. A Figura 38 mostra o resultado da previsão da *deep RC* para dados de teste (não utilizados para treinamento) da iteração que obteve a maior correlação e menor EPMA.

Figura 38 - Previsões efetuadas da *deep RC* com dados não treinados para 7 entradas.



Fonte: Elaborada pelo autor (2019).

A Tabela 10 mostra a correlação e o EPMA da previsão efetuada pela *deep RC* mostrada na Figura 38.

Tabela 10 - Resultados da *deep RC* para 7 variáveis de entrada com dados não treinados.

Métrica	Maior correlação e menor EPMA
EPMA	33,81%
Correlação	93,91%

Fonte: Elaborada pelo autor (2019).

Comparando os resultados entre a Perceptron Multicamadas mostrados na Tabela 7 e 8, com os resultados da *deep RC* mostrado na Tabela 10, para qualquer cenário dos dados testados, a *deep RC* mostrou uma melhor previsão do preço de energia elétrica do SE/CO no mercado *spot*. A melhor correlação encontrada para a Perceptron Multicamadas foi de 90,83%, enquanto para a *deep RC* foi 3,08 pontos percentuais superior. O EPMA encontrado na *deep RC* foi 8,8 pontos percentuais menor se comparado à Perceptron Multicamadas. Todavia, para os dados utilizados no treinamento, a correlação utilizando *deep RC* foi 2,19 pontos percentuais inferior a Perceptron Multicamadas, e o EPMA foi 20,01 pontos percentuais superior. Isso mostra que para os dados treinados, a Perceptron Multicamadas obteve um resultado superior que a *deep RC*, porém, ocorreu o inverso para os dados testados. É possível observar *overfitting* nos dados treinados na Perceptron Multicamadas, o que fez aumentar o erro para os dados testados. Isso ocorreu mesmo flexibilizando os limites e restrições na configuração do modelo.

Ao contrário do que foi descrito por Barceló (2017), a taxa de conectividade dos neurônios internos ao reservatório que apresentou os melhores resultados foi próxima de 90%.

Foi efetuado testes com a rede RC de apenas um reservatório. Os resultados foram expressivamente inferiores se comparados com a *deep RC*. A média da correlação para os testes efetuados foi de 43% e o EPMA médio foi de 97%.

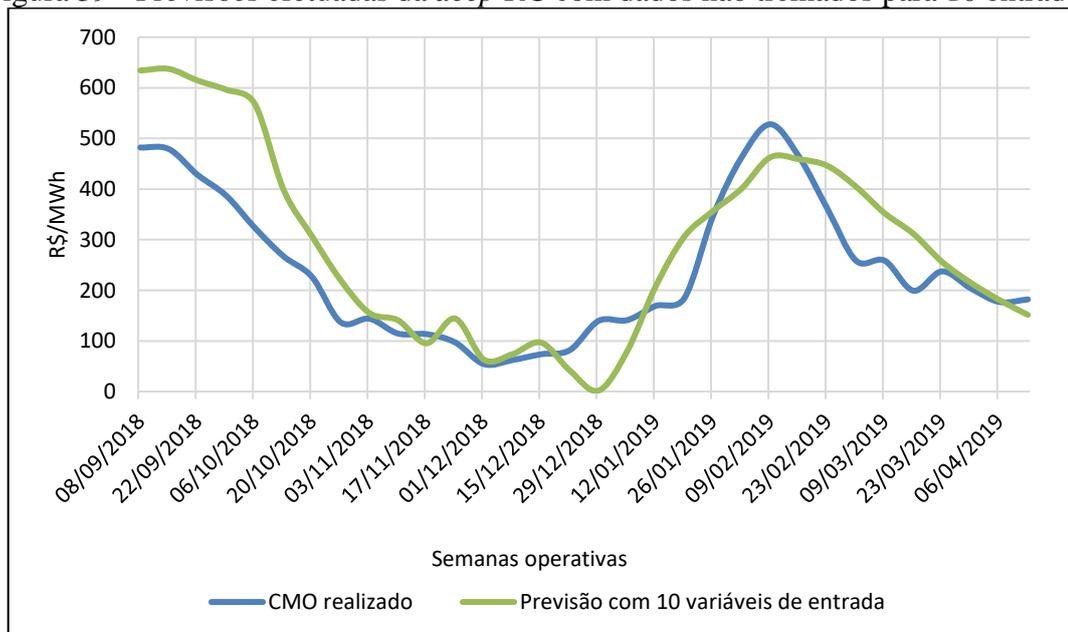
Não é possível efetuar análises do tempo de treinamento entre as redes *deep RC* e a Perceptron Multicamada, pois ambas utilizaram períodos e tamanhos diferentes da base de dados. Todavia, a *deep RC* apresentou tempo inferior de treinamento para qualquer cenário avaliado se comparado com o NEWAVE e DECOMP para projeção de cenários. A versão 27 do NEWAVE leva, em média, 3,7 horas para gerar a função de custo futuro utilizando o sistema operacional Centos Linux 7 com 96 núcleos para processamento. Em seguida, tais funções são utilizadas pelo DECOMP para encontrar o custo imediato e processar o despacho ótimo. O DECOMP, com as mesmas especificações de máquina utilizada pelo NEWAVE, leva em média 2,8 minutos.

A *deep RC*, simulada em sistema operacional Windows com processador I7 de 3ª geração e 8 GB de RAM, implementado no *software* MATLAB e com os parâmetros já definidos, leva em média 1,3 minutos para simular e gerar as previsões de preço de energia elétrica. Isso demonstra que o modelo implementado é significativamente mais rápido se comparado com os modelos do NEWAVE e DECOMP. Porém, cabe destacar que o modelo implementado não serve para efetuar o despacho ótimo da operação hidrotérmica, mas se mostra útil para indicar somente a previsão do preço de energia elétrica.

4.2.2 *Deep RC* com 10 variáveis de entrada

Para este experimento, foi acrescentado como variáveis de entrada a geração solar e eólica, que são as principais gerações de usinas não simuladas e despachadas pelo ONS. Além disso, foi acrescentada a geração térmica nuclear de Angra 1 e Angra 2, que pode apresentar algum impacto no preço de energia elétrica do mercado *spot*, em determinados períodos que as usinas estão em manutenção. A análise é feita somente para dados testados, e não treinados. A configuração da *deep RC* se manteve igual aos testes realizados no item anterior, somente foram adicionadas novas variáveis de entrada. A Figura 39 mostra a previsão que obteve o melhor resultado e a tabela 11 mostra a correlação e o EPMA.

Figura 39 - Previsões efetuadas da *deep RC* com dados não treinados para 10 entradas.



Fonte: Elaborada pelo autor (2019).

Tabela 11 - Resultados da deep RC para 10 variáveis de entrada com dados não treinados.

Métrica	Melhor resultado para 10 variáveis
EPMA	33,15%
Correlação	89,84%

Fonte: Elaborada pelo autor (2019).

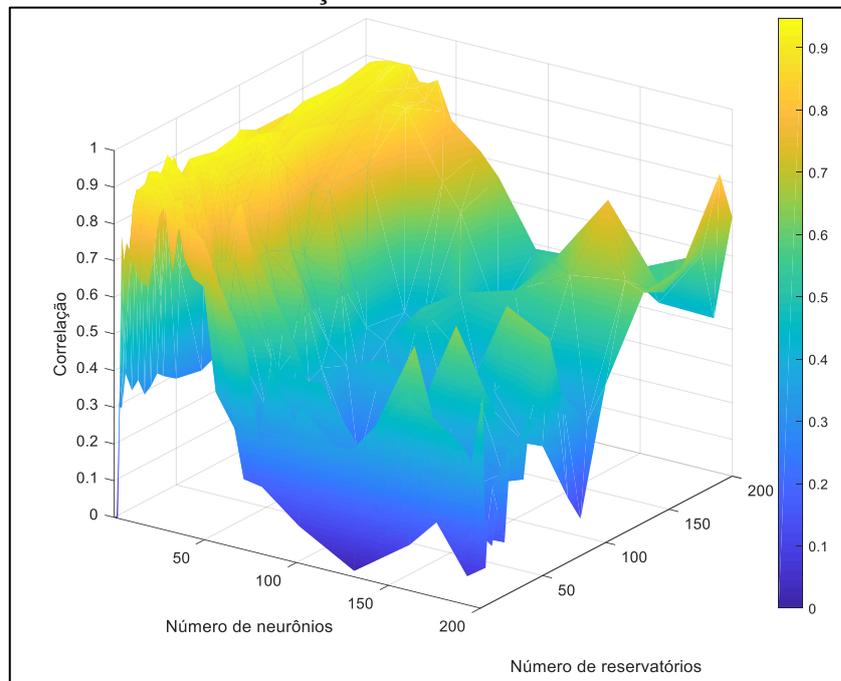
Analisando os resultados com 7 variáveis de entrada mostrado na Tabela 10, e os resultados com 10 variáveis de entrada mostrado na Tabela 11, o EPMA diminuiu 0,66 pontos percentuais, porém, a correlação diminuiu 4,07 pontos percentuais.

4.2.3 Análises com diferentes parâmetros da deep RC

Foi analisada a correlação e o EPMA para diferentes números de neurônios, quantidade de reservatórios, raio espectral, taxa de conectividade e *leaking rate*. Todas as análises foram feitas no modelo mostrado no item 4.2.1 com as configurações da Tabela 9.

A Figura 40 mostra o gráfico da correlação, variando o número de neurônios e de reservatórios, fixando o restante dos parâmetros do modelo conforme a Tabela 9.

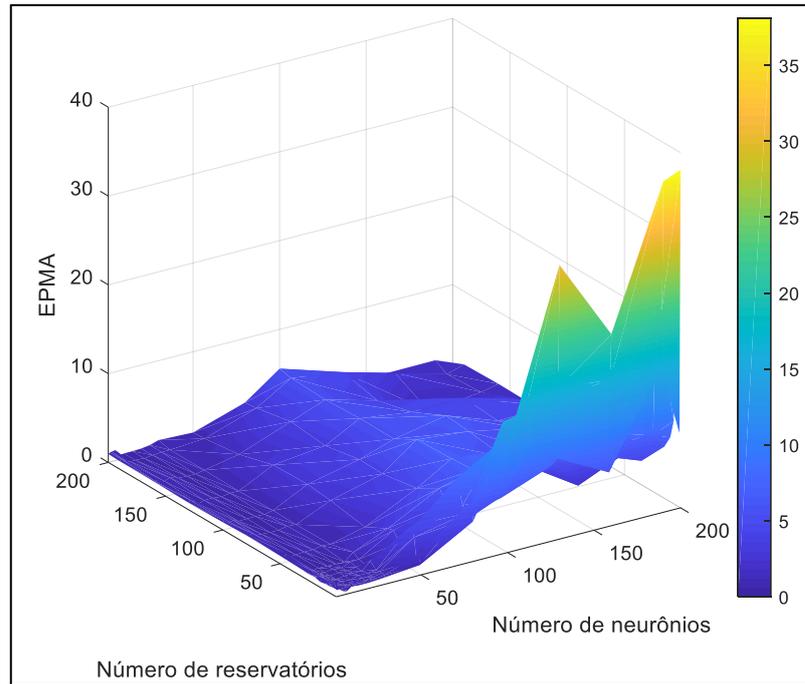
Figura 40 - Resultado da correlação variando número de neurônios e reservatórios.



Fonte: Elaborada pelo autor (2019).

A Figura 41 mostra o gráfico do EPMA, variando o número de neurônios e reservatórios, fixando o restante dos parâmetros do modelo conforme a Tabela 9.

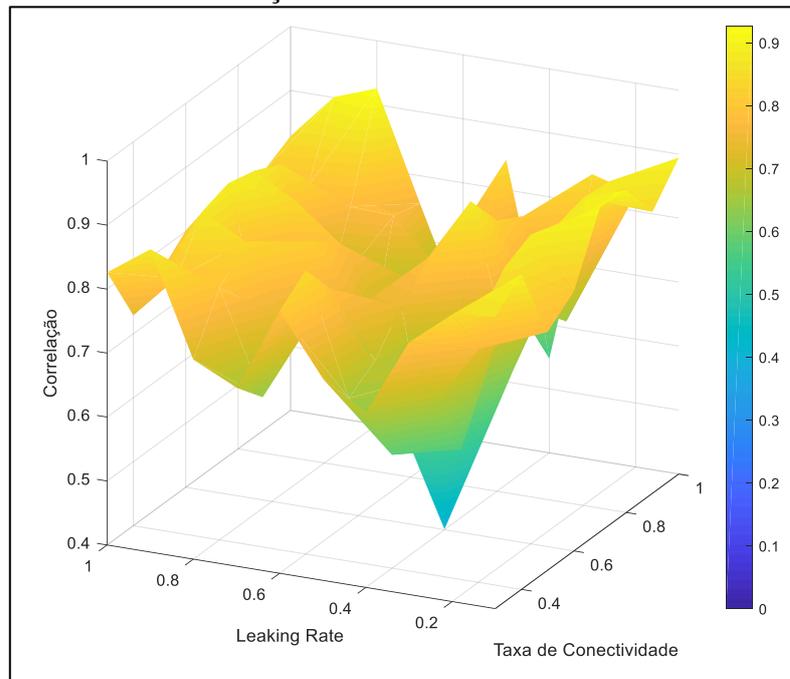
Figura 41 - Resultado do EPMA variando número de neurônios e reservatórios.



Fonte: Elaborada pelo autor (2019).

A Figura 42 mostra o gráfico da correlação, variando a taxa de conectividade e o *leaking rate*, fixando o restante dos parâmetros do modelo conforme a Tabela 9.

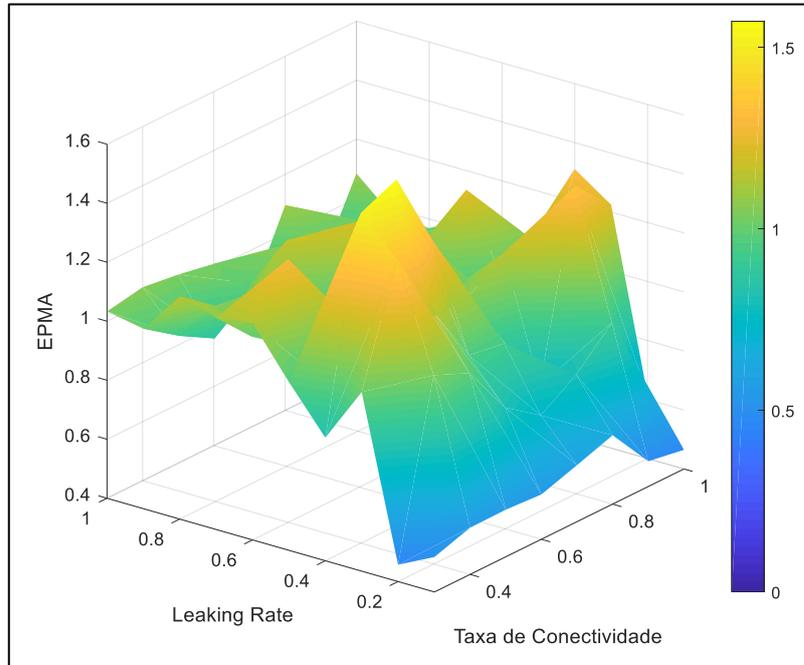
Figura 42 - Resultado da correlação variando a taxa de conectividade e o *leaking rate*.



Fonte: Elaborada pelo autor (2019).

A Figura 43 mostra o gráfico do EPMA, variando a taxa de conectividade e o *leaking rate*, fixando o restante dos parâmetros do modelo conforme a Tabela 9.

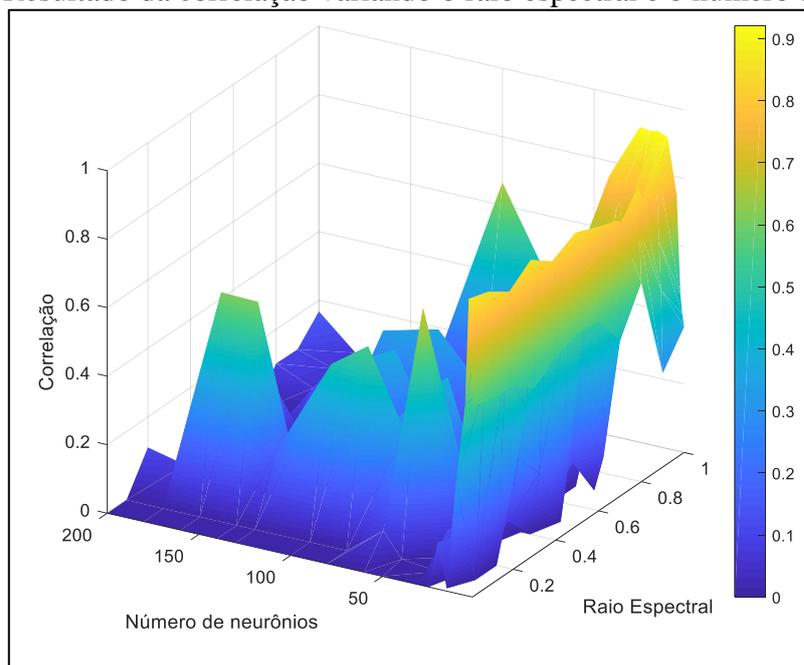
Figura 43 - Resultado do EPMA variando a taxa de conectividade e o *leaking rate*.



Fonte: Elaborada pelo autor (2019).

A Figura 44 mostra o gráfico da correlação, variando o raio espectral e o número de neurônios, fixando o restante dos parâmetros do modelo conforme a Tabela 9.

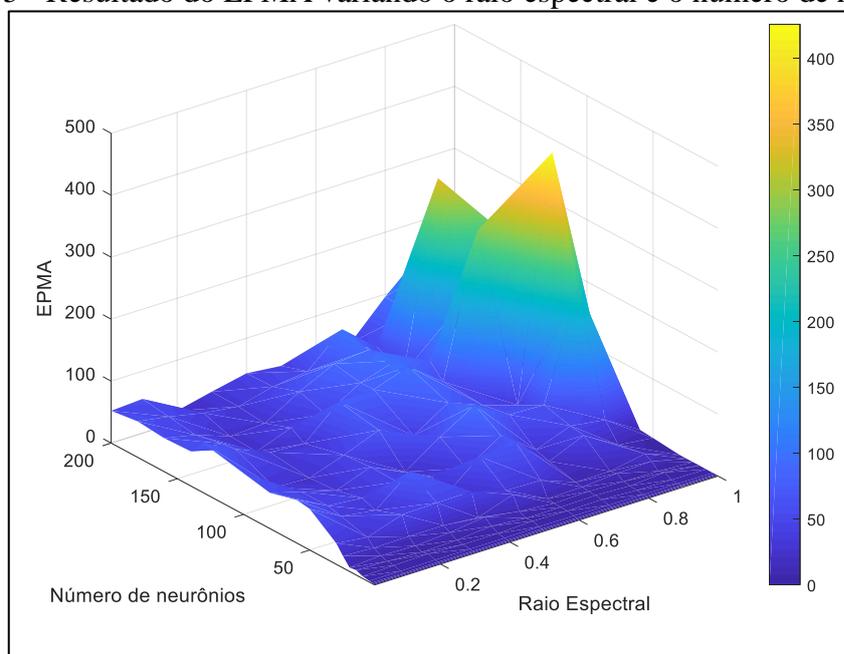
Figura 44 - Resultado da correlação variando o raio espectral e o número de neurônios.



Fonte: Elaborada pelo autor (2019).

A Figura 45 mostra o gráfico do EPMA, variando o raio espectral e o número de neurônios, fixando o restante dos parâmetros do modelo conforme a Tabela 9.

Figura 45 - Resultado do EPMA variando o raio espectral e o número de neurônios.



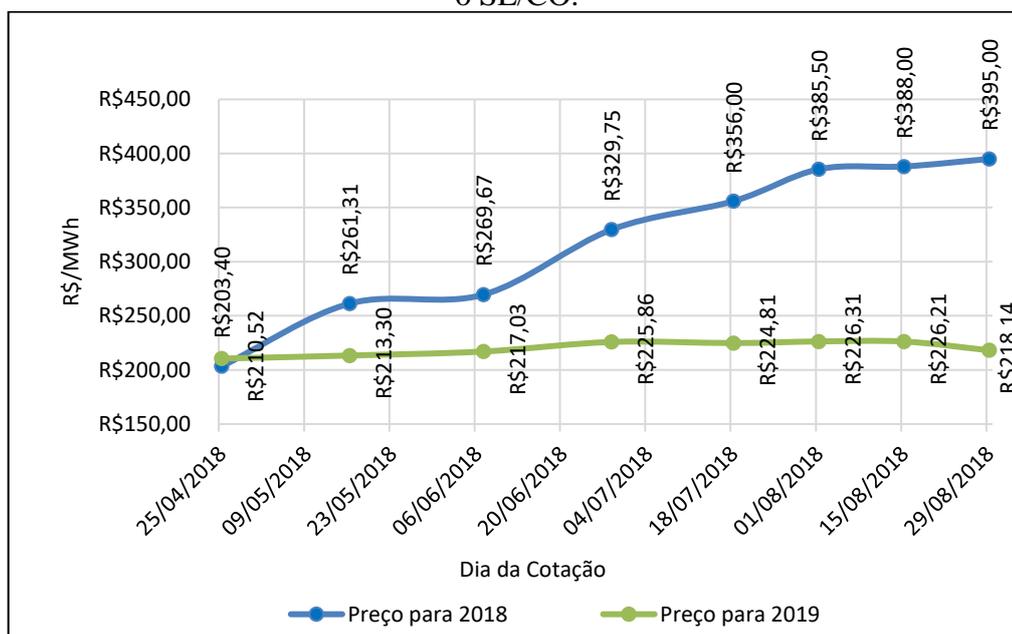
Fonte: Elaborada pelo autor (2019).

4.3 CENÁRIO DE COMPRA OU VENDA DE ENERGIA ELÉTRICA ATRAVÉS DA CURVA PREVISTA PELA *DEEP RC*

O objetivo dessa análise é exemplificar a compra ou venda de energia elétrica para uma determinada carga no ACL, ou *trading* de energia elétrica, utilizando a curva prevista pela *deep RC* mostrada na Figura 38. A Figura 46 mostra o histórico dos preços médios de energia elétrica convencional cotados para a região SE/CO para 2018 e 2019 no período de 25/04/2018 até 29/08/2018. Os preços mostrados são uma média das ofertas das principais comercializadoras e geradoras de energia do país.

A estratégia é negociar energia elétrica para o período de setembro/2018 até dezembro/2018, podendo ser negociada no curto prazo ou em contrato de longo prazo com alguma comercializadora ou geradora de energia elétrica. Como pode ser visto na Figura 46, os preços dos contratos de longo prazo para o primeiro ano são mais voláteis se comparado com os preços do ano seguinte, pois eles são influenciados pelo preço de curto prazo (PLD). O montante de energia negociado nos cenários propostos é de 1 MWmédio.

Figura 46 - Histórico dos preços médios de longo prazo de energia elétrica convencional para o SE/CO.



Fonte: Adaptado de Ludfor Energia (2018)¹.

A Tabela 12 mostra o cenário de compra de energia elétrica através do preço de longo prazo cotado no dia 29/08/2018, e o cenário de compra através dos preços de curto prazo previstos pela *deep RC*. A compra e venda de energia elétrica são negociadas em períodos mensais. Dessa forma, foi necessário calcular o preço ponderado mensal da curva prevista em base semanal, além disso, foi considerado os limites regulatórios de máximo e mínimo do PLD e subtraído o *spread* médio de energia convencional negociado em 2018.

Tabela 12 - Cenários de compra de energia elétrica de curto e longo prazo.

Mês	MWh	Previsão PLD (CP)		Total (CP)	Preços (LP) 29/08/2018		Total (LP)
set/18	720	R\$	513,89	R\$ 413.587,38	R\$	395,00	R\$ 284.400,00
out/18	744	R\$	393,54	R\$ 292.796,63	R\$	395,00	R\$ 293.880,00
nov/18	720	R\$	72,86	R\$ 52.462,13	R\$	395,00	R\$ 284.400,00
dez/18	744	R\$	42,35	R\$ 31.508,40	R\$	395,00	R\$ 293.880,00
			Total	R\$ 790.354,53			R\$ 1.156.560,00

Fonte: Elaborada pelo autor (2019).

Como mostrado na Tabela 12, o valor total pago pelo 1 MW médio é menor no curto prazo. Para uma estratégia de *trading*, a posição a ser tomada seria de venda de um contrato de

¹ Os preços de longo prazo mostrados na Figura 46, foram extraídos dos boletins semanais de preço de longo prazo da Ludfor Energia Ltda. Para obter acesso, é necessário entrar em contato com a empresa.

longo prazo para esses quatro meses do cenário, sendo o preço de venda de R\$ 395,00 (valor médio cotado no mercado) e permanecendo exposto às variações do PLD durante o período de setembro/2018 até dezembro/2018. Assim, seria feita a aquisição da energia elétrica no curto prazo de cada mês para suprir a venda do contrato firmado.

Para uma estratégia de compra de energia para uma carga no ACL, a posição de compra no curto prazo é a mais barata.

A Tabela 13 mostra o valor do PLD realizado para análise do impacto financeiro conforme estratégia firmada.

Tabela 13 - Resultado do cenário de compra de energia no CP com o PLD realizado.

Mês	MWh	PLD realizado	PLD - Spread Convencional	R\$ Total PLD
set/18	720	R\$ 472,75	R\$ 457,75	R\$ 329.580,00
out/18	744	R\$ 271,83	R\$ 256,83	R\$ 191.081,52
nov/18	720	R\$ 123,92	R\$ 108,92	R\$ 78.422,40
dez/18	744	R\$ 78,96	R\$ 63,96	R\$ 47.586,24
Total				R\$ 646.670,16

Fonte: Elaborada pelo autor (2019).

Considerando o resultado de compra no curto prazo com o PLD realizado mostrado na Tabela 13, o lucro gerado no cenário de *trading*, ou a economia gerada para uma carga no ACL, em comparação a um contrato de longo prazo, seria de R\$ 509.889,84. A diferença entre o cenário previsto pela *deep RC* e o PLD realizado para o mercado de curto prazo, para um montante de 1 MW médio, foi de R\$ 143.684,37.

5 CONCLUSÃO

O Brasil possui um dos sistemas de despacho centralizado de usinas hídricas e térmicas mais sofisticados do mundo. A otimização dos níveis dos reservatórios, para usinas hidrelétricas, e os combustíveis, para usinas termelétricas, é necessária onde a predominância na geração do país constitui-se desses dois tipos de usinas. Além disso, o Brasil possui o sistema interligado nacional, que através das linhas de transmissão e de distribuição, pode conectar os geradores e consumidores de norte a sul. Isso cria a necessidade de tornar o despacho de usinas cada vez mais otimizado, levando em consideração o consumo e prioridades de geração nas regiões do país.

Os modelos NEWAVE e DECOMP, responsáveis pela otimização do despacho centralizado, estão em constante modernização para descrever a operação real do sistema elétrico. Esses modelos são empregados oficialmente pelo ONS, e são utilizados para obter previsões e cenários do preço de energia elétrica do curto prazo. Esses *softwares* necessitam de alto processamento computacional para efetuar a otimização, além do cálculo do despacho ser bastante moroso. Por exemplo, conforme testes realizados, a versão 27 do NEWAVE leva, em média, 3,7 horas para gerar a função de custo futuro utilizando o sistema operacional Centos Linux 7 com 96 núcleos para processamento.

Dessa forma, o objetivo deste trabalho foi desenvolver um modelo computacional utilizando *deep RC* para previsão do preço de energia elétrica do mercado *spot* no SE/CO, como forma de auxiliar as tomadas de decisão de compra e venda em uma comercializadora de energia elétrica.

A rede neural *deep RC* é um dos modelos mais recentes de arquiteturas de redes neurais, possui reservatórios de neurônios encadeados utilizando a ESP, fornecendo um rico conjunto de informações do passado e presente, tornando-a robusta para diversos tipos de aplicações e diferenciando-se das demais redes neurais. Para os testes realizados, a *deep RC* mostrou melhores resultados se comparado com a Perceptron Multicamadas, tanto em valores menores de EPMA, quanto em valores maiores de correlação para os dados testados. Por outro lado, utilizando os dados treinados, a Perceptron Multicamadas forneceu melhores resultados, tanto em correlação quanto em EPMA, se comparado com a *deep RC*.

Analisando a diferença dos modelos de redes para dados testados, a *deep RC* apresentou um aumento de 3,08 pontos percentuais na correlação em comparação com a Perceptron Multicamadas, e o EPMA reduziu 8,80 pontos percentuais.

Para a Perceptron Multicamadas, na configuração testada, houve uma redução de 7,13 pontos percentuais para a correlação na projeção entre os dados treinados e testados, e um aumento de 28,87 pontos percentuais para o EPMA. Ou seja, houve uma expressiva redução da correlação e aumento do EPMA entre dados testados e treinados. Isso mostra a ocorrência de *overfitting* no modelo da Perceptron Multicamadas, mesmo sendo testados diversos parâmetros de configuração da rede. Por outro lado, para a *deep RC*, as diferenças foram menos impactantes, onde o EPMA reduziu 2,94% e a correlação diminuiu apenas 1,66% entre dados testados e treinados.

Referente ao incremento de novas variáveis de entrada na *deep RC*, para os testes realizados, os resultados não foram expressivamente melhores. Isso mostra que as variáveis carga, vazões e energia armazenada no submercado são as principais que definem o preço de energia elétrica, como mostrado na Figura 22.

Os resultados mostrados se referem aos diversos experimentos testados e mencionados ao longo dos itens anteriores. Os resultados podem divergir se testados nas diversas outras configurações das redes Perceptron Multicamada e a *deep RC*.

Uma das características mais importantes da *deep RC* é a rapidez de treinamento em comparação com as redes neurais mais conhecidas, por exemplo, a Perceptron Multicamadas. Isso ocorre pois o processo de treinamento dos pesos acontece somente na camada de saída. Também, pelo fato de os pesos dos neurônios dos reservatórios serem fixos, sem alteração em cada iteração, como em outras redes que utilizam o *backpropagation* como treinamento, de modo que o tempo de execução para cada *time step* da base de dados se torna expressivamente baixo. Todavia, a quantidade de parâmetros a serem definidos para a *deep RC* é superior se comparado com outras redes neurais mais conhecidas. Isso torna o processo de parametrização e ajuste da rede trabalhoso.

Comparando o resultado de preços fornecido pelo modelo desenvolvido com os preços definidos pelo NEWAVE e DECOMP, foi possível observar que a *deep RC* pode ser utilizada como método de auxílio na projeção de preço para operação de *trading* ou para auxílio na tendência de preços de LP para consumidores no ACL. Não existem hipóteses de abdicar o uso dos modelos oficiais do ONS para projeção de preço do curto prazo. Porém, o uso da *deep RC* auxilia, de forma significativamente mais rápida, cenários, projeções e tendências dos preços de energia elétrica.

5.1 TRABALHOS FUTUROS

Como trabalhos futuros são propostos:

- a) Aplicação do modelo proposto para projeção do preço de energia elétrica nos quatro submercados, incluindo nas variáveis de entrada os dados de cada submercado.
- b) Implementação da *deep RC* para projeção de vazões e energia armazenada em cada submercado, e posteriormente, servir como dado de entrada no modelo proposto.
- c) Implementação de uma heurística ou meta-heurística para *design* da *deep RC*.

REFERÊNCIAS

ALMEIDA, G. P. S. **Estudo Paramétrico para Estimação no Curto e Médio Prazo do Preço Spot de Energia Elétrica Utilizando Redes Neurais**. 2012. 117 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade de Brasília, Brasília, 2012.

BARCELÓ, M. L. A. **Methodologies for Hardware Implementation of Reservoir Computing Systems**. 2017. 288 f. Tese (Doutorado em Física) - Universidade das Ilhas Baleares, Palma – Espanha, 2017.

BEZZERA, S. G. T. A. **Reservoir Computing com Hierarquia para Previsão de Vazões Médias Diárias**. 2016. 75 f. Dissertação (Mestrado em Engenharia de Computação) – Universidade de Pernambuco, Recife, 2016.

CCEE. **Com quem se relaciona**. Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/ondeatuamos/com_quem_se_relaciona?_afzLoop=953660009977089&_adf.ctrlstate=xp6fyq05y_14#!%40%40%3F_afzLoop%3D953660009977089%26_adf.ctrl.state%3Dxp6fyq05y_18>. Acesso em: 31 mar. 2019.

_____. **Treinamento Newave – Decomp - O SIN e os Modelos para o Planejamento da Operação Energética**. Apostila CCEE de treinamento ao NEWAVE e DECOMP, 2017.

DANTAS, L.; VALENÇA, M. Utilizando Reservoir Computing para realizar diagnóstico precoce de Mal de Alzheimer. **Anais do XI Congresso Brasileiro De Inteligência Computacional – Cbic**, Pernambuco, 2013.

FONSECA, P. C. **Uma alternativa aos Modelos NEWAVE e DECOMP por meio da Aplicação de Técnicas de Inteligência Artificial**. 2013. 89 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Itajubá, Itajubá, 2013.

GALLE, B.; VALENÇA, M. J. S. Utilizado Reservoir Computing para a previsão da potência do vento. **Anais do XI Congresso Brasileiro De Inteligência Computacional – Cbic**, Pernambuco, 2013.

GALLICCHIO, C.; MICHELI, A.; PEDRELLI, L. Deep Reservoir Computing: A Critical Experimental Analysis. **Neurocomputing**. v. 268, p. 87-99. 2017.

GUARNIER, E.; RAMOS, D. S.; BARILLARI, S. N.; PELEGRINI, M. A.; QUEEN, A. S.; CAMARGO, L. A. S. Projeção de Preços no Mercado de Curto Prazo: Análise por Clusterização de Energias Naturais Afluentes e Incorporação de Fenômenos Climatológicos. **Anais do IV Simpósio Brasileiro do Sistema Elétrico**, Goiânia, 2012.

HAYKIN S. **Redes Neurais Artificiais: Princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

JAEGER, H. **The “echo state” approach to analysing and training recurrent neural Networks**. Relatório GMD 148, German National Research Center for Information Technology, 2001.

LEME, R. C.; TURRIONI, J. B.; BALESTRASSI, P. P.; ZAMBRONI, A. C.; SANTOS, P. S. A Study of Electricity Price Volatility for the Brazilian Energy Market. **5th International Conference on the European Electricity Market - IEEE**, 2008.

LUDFOR ENERGIA. **Boletim Semanal - Acompanhamento de Preços**. Bento Gonçalves, 2018. 3 p.

MAIA, V. M.; MEIRELES, B. L.; KLÖTZLE, M. C.; PINTO, A. C. F.; GOMES, L. L. Água: Único Fator a Influenciar o Preço da Energia no Mercado Spot? **Simpósio de Excelência em Gestão e Tecnologia**, Rio de Janeiro, 2016.

MAASS, W.; NATSCHLÄGER, T.; MARKRAM, H. Real-Time Computing Without Stable States: A New Framework for Neural Computation Based on Perturbations. **Neural Computation**. v. 14, p. 2531–2560. 2002.

MEDEIROS, L. **Previsão do Preço Spot no Mercado de Energia Elétrica**. 2003. 144 f. Tese (Doutorado em Engenharia Elétrica) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2003.

MONTAVON G.; ORR, G. B.; MÜLLER, K.; **Neural Networks: Tricks of the Trade**. 2. ed. New York: Springer, 2012.

MOROZOWSKI, M.; GUIMARÃES, F. O. B.; FINARDI, E. C.; TAKIGAWA, F. Y. K.; NOGUEIRA, L. F. A. M. **Dinâmica do Mercado de Energia Elétrica e Formulação de Estratégias Comerciais Sob a Ótica Sistêmica**. V Congresso de Inovação Tecnológica em Energia Elétrica, jun. 2009.

ONS. **Capacidade instalada**. Disponível em: <http://ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/capacidade_instalada.aspx>. Acesso em: 15 mar. 2019a.

_____. **Carga de Energia**. Disponível em: <http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/carga_energia.aspx>. Acesso em: 15 mar. 2019b.

_____. **Custo Marginal de Operação (CMO)**. Disponível em: <<http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/cmo.aspx>>. Acesso em: 15 mar. 2019c.

_____. **Energia Armazenada**. Disponível em: <http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/energia_armazenada.aspx>. Acesso em: 15 mar. 2019d.

_____. **Energia Natural Afluyente por Subsistema**. Disponível em: <http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/energia_afluyente_subsistema.aspx>. Acesso em: 15 mar. 2019e.

_____. **Geração de Energia**. Disponível em: <http://ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/geracao_energia.aspx>. Acesso em: 15 mar. 2019f.

_____. **Mapas**. Disponível em: <<http://ons.org.br/pt/paginas/sobre-o-sin/mapas>>. Acesso em: 14 mar. 2019g.

_____. **Newave**. Disponível em: <<https://agentes.ons.org.br/pmo/newave.aspx>>. Acesso em 20 mar. 2019h.

_____. **Novas durações para os patamares de carga**. Disponível em: <https://agentes.ons.org.br/operacao/processosombra_newave-decomp.aspx>. Acesso em: 13 mar. 2019i.

_____. **Relatório Executivo**. Disponível em: <https://agentes.ons.org.br/operacao/relatorio_executivoPMO.aspx>. Acesso em: 19 abr. 2019j.

_____. **Sistemas Isolados**. Disponível em: <<http://ons.org.br/paginas/sobre-o-sin/sistemas-isolados>>. Acesso em: 15 mar. 2019k.

_____. **Treinamento Metodologias de Projeção do PLD**. Disponível: <<https://agentes.ons.org.br/download/agentes/pmo/treinamentoPMO/10-Metodologia-Projecao-PLD.pdf>>. Acesso em: 19 abr. 2019l.

PEREIRA, F. R. **Redes neurais diretas e recorrentes na previsão do preço de energia elétrica de curto prazo no mercado brasileiro**. 2016. 84 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Pará, Belém, 2016.

QUEIROZ, A. R. **Simulação De Custos Marginais em Mercado de Energia Elétrica Utilizando Redes Neurais**. 2007. 155 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Itajubá, Itajubá, 2007.

RODRIGUES, A. L. **Redes neurais artificiais aplicadas na previsão de preços do mercado *spot* de energia elétrica**. 2009. 179 f. Dissertação (Mestrado em Energia) – Universidade de São Paulo, São Paulo, 2009.

SILVA, E. L. **Formação de Preços em Mercados de Energia Elétrica**. 1. ed. Porto Alegre: Editora Sagra Luzzato, 2001.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo, SP: Artliber, 2010.

VERSTRAETEN, D. **Reservoir Computing: computation with dynamical systems**. 2010. 206 f. Tese (Doutorado em Engenharia da Computação) – Universidade de Ghent, Ghent, 2010.

WAN, C.; XU, Z.; WANG, Y.; DONG, Z. Y.; WONG, K. P. A Hybrid Approach for Probabilistic Forecasting of Electricity Price. **IEEE Transactions on Smart Grid**. v. 5, p. 463-470. 2014.