

UNIVERSIDADE FEDERAL DE OURO PRETO
INSTITUTO DE CIÊNCIAS EXATAS E APLICADAS
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

**PREVISÃO DO PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS POR
MEIO DE REDES NEURAS ARTIFICIAIS**

ALAN PATRIK SOUZA SILVA

TRABALHO DE CONCLUSÃO DE CURSO

JOÃO MONLEVADE, MG

2018

ALAN PATRIK SOUZA SILVA

**PREVISÃO DO PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS POR
MEIO DE REDES NEURAS ARTIFICIAIS**

Monografia apresentada ao Departamento de Engenharia Elétrica da Universidade Federal de Ouro Preto, como parte dos requisitos necessários à obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Víctor Costa da Silva Campos

Coorientador Prof. Dr. Márcio Feliciano Braga

TRABALHO DE CONCLUSÃO DE CURSO

JOÃO MONLEVADE, MG

2018

S586p

Silva, Alan Patrik Souza.

Previsão do preço de liquidação das diferenças por meio de redes neurais artificiais [manuscrito] / Alan Patrik Souza Silva. - 2018.

48f.: il.: color; grafs; mapas.

Orientador: Prof. Dr. Víctor Costa da Silva Campos.

Coorientador: Prof. Dr. Márcio Feliciano Braga.

Monografia (Graduação). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Departamento de Engenharia Elétrica.

1. Engenharia elétrica. 2. Energia elétrica - Produção. 3. Preços - Determinação. I. Campos, Víctor Costa da Silva. II. Braga, Márcio Feliciano. III. Universidade Federal de Ouro Preto. IV. Título.

CDU: 621.3:338.5

Catálogo: ficha@sisbin.ufop.br



ANEXO IV - ATA DE DEFESA

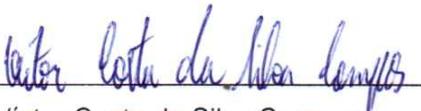
Aos 9 dias do mês de julho de 2018, às 15 horas e 30 minutos, no bloco H deste instituto, foi realizada a defesa de monografia pelo (a) formando (a) Alan Patrik Souza Silva, sendo a comissão examinadora constituída pelos professores e convidados: Francisco Ricardo Abrantes Couy Baracho, Renan Fernandes Bastos, Márcio Feliciano Braga e Vítor Costa da Silva Campos.

O (a) candidato (a) apresentou a monografia intitulada: Previsão do preço de liquidação das diferenças por meio de redes neurais artificiais. A comissão examinadora deliberou, por unanimidade, pela aprovação do(a) candidato(a), com a nota média 9,1, de acordo com a tabela 1. Na forma regulamentar foi lavrada a presente ata que é assinada pelos membros da comissão examinadora e pelo (a) formando(a).

Tabela 1 – Notas de avaliação da banca examinadora

Banca Examinadora	Nota
Francisco Ricardo Abrantes Couy Baracho	9,5
Renan Fernandes Bastos	8,5
Márcio Feliciano Braga	9,0
Vítor Costa da Silva Campos	9,5
Média	9,1

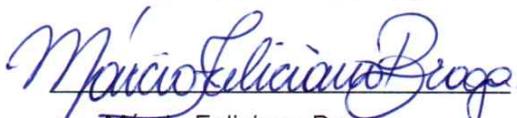
João Monlevade, 09 de julho de 2018.


Vítor Costa da Silva Campos

Professor(a) Orientador(a)


Alan Patrik Souza Silva

Aluno (a)


Márcio Feliciano Braga

Professor(a) Coorientador(a)


Renan Fernandes Bastos

Professor(a) Convidado(a)


Francisco Ricardo Abrantes Couy Baracho

Convidado(a)

AGRADECIMENTOS

A Deus, por ter me dado saúde e força para a superar as dificuldades.

Aos meus pais, Roberval e Maria de Fátima, pelo amor incondicional, carinho e todo suporte dado durante todo o período na universidade.

Aos irmãos da República A Casa Lar, Iuri, Baeta, Godoi e Justin por terem sido minha segunda família e por terem tornado momentos difíceis em momentos de descontração.

Ao meu orientador, Professor Doutor Víctor Costa da Silva Campos, pela incansável supervisão, pelo interesse e confiança, pelos conselhos e, especialmente, pela amizade.

Ao meu coorientador, Professor Doutor Márcio Feliciano Braga, pelo seu incentivo, pela sua disponibilidade e igualmente pelo seu apoio na elaboração deste trabalho.

A todos que, de alguma forma, contribuíram com a realização desse sonho.

Muito obrigado.

"O futuro pertence àqueles que acreditam na beleza de seus sonhos."

Eleanor Roosevelt

RESUMO

Ao longo dos anos, houve um grande aumento de competitividade na indústria de energia elétrica em escala mundial. Para decidir estratégias de licitação e estabelecer contratos bilaterais, a fim de aumentar os lucros e minimizar os riscos, a previsão de preço de energia no mercado desregulado é imprescindível. Fatores como energia armazenada nos reservatórios, quantidade de geração hidrelétrica e termelétrica e a carga do sistema impactam o preço da energia no Brasil. Desse modo, o conhecimento da dinâmica desses fatores pode auxiliar na previsão do preço. Uma das ferramentas utilizadas na análise de séries temporais desses elementos e na análise temporal do preço de liquidação das diferenças são as Redes Neurais Artificiais. Este trabalho utiliza Redes Neurais Artificiais baseadas em modelos Autorregressivos não lineares com o objetivo de prever o preço de energia elétrica três passos (ou semanas) à frente. Duas abordagens são analisadas. A primeira verifica a previsão do preço da energia elétrica realizando, primeiramente, a previsão dos fatores principais que afetam o seu valor, enquanto a segunda verifica a eficiência da previsão da série temporal do preço. Os resultados das duas abordagens foram semelhantes.

Palavras-chave: Preço Spot, PLD, RNA, Previsão de séries temporais, NARNET.

ABSTRACT

Over the years, there has been a large increase in competitiveness in the world-wide electric power industry. In order to decide bidding strategies and establish bilateral contracts, and to increase profits and minimize risks, energy price forecast in the deregulated market is imperative. Factors such as energy stored in the reservoirs, amount of hydroelectric and thermoelectric generation and the system load impact the price of energy in Brazil. Therefore, knowledge of the dynamics of these factors can help predict the price. One of the tools used in the analysis of the time series of these elements and in the temporal analysis of the settlement price of the differences are the Artificial Neural Networks. This work uses Artificial Neural Networks based on nonlinear autoregressive models with the objective of predicting the electric energy price three steps (or weeks) ahead. Two approaches are analyzed. The first one verifies the forecast of the electric energy price by firstly forecasting the main factors that affect its value, while the second one verifies the efficiency of the forecast of the time series of the price. The results of the two approaches were similar.

Keywords: Spot price, PLD, ANN, Time series forecasting, NARNET.

LISTA DE ILUSTRAÇÕES

Figura 1 – Tendência em séries temporais.	5
Figura 2 – Função de autocorrelação com intervalo de confiança.	7
Figura 3 – Constituintes de uma célula neural (USP, 2018).	9
Figura 4 – Modelo de neurônio artificial (MARTINS-FILHO; MOL; ROCHA, 2005).	10
Figura 5 – Função de ativação linear.	11
Figura 6 – Função de ativação com limite.	12
Figura 7 – Função de ativação Sigmoide.	13
Figura 8 – Função de ativação Tangente Hiperbólica.	13
Figura 9 – Rede <i>feedforward</i> com uma única camada de neurônios (SILVA, 2005).	15
Figura 10 – Rede <i>feedforward</i> com uma camada escondida e uma camada de saída (SILVA, 2005).	15
Figura 11 – Rede recorrente sem neurônios escondidos. Adaptado de Silva (2005).	16
Figura 12 – Estrutura de uma NARNET em malha aberta.	20
Figura 13 – Estrutura de uma NARNET em malha fechada.	21
Figura 14 – Sistema de transmissão brasileiro - Horizonte 2017 (ONS, 2017).	23
Figura 15 – Agentes institucionais do setor elétrico (CCEE, 2018a).	24
Figura 16 – Subsistemas do SEB. Adaptado de Ramos et al. (2012).	27
Figura 17 – Evolução do PLD para carga média no sub-mercado Sudeste/Centro-oeste (30 de julho de 2001 à 01 de janeiro de 2018).	28
Figura 18 – Esquema de previsão indireta do PLD.	30
Figura 19 – Esquema de previsão indireta do PLD.	31
Figura 20 – Previsão três passos a frente realizada para a série temporal EA utilizando uma NARNET (11 de fevereiro de 2016 à 1º de janeiro de 2018).	33
Figura 21 – Autocorrelação do resíduo da previsão da série temporal EA (11 de fevereiro de 2016 à 1º de janeiro de 2018).	34
Figura 22 – Previsão três passos a frente realizada para a série temporal GH utilizando uma NARNET(11 de fevereiro de 2016 à 1º de janeiro de 2018).	34
Figura 23 – Autocorrelação do resíduo da previsão da série temporal GH.	35

Figura 24 – Previsão três passos a frente realizada para a série temporal GT utilizando uma NARNET (11 de fevereiro de 2016 à 1º de janeiro de 2018).	35
Figura 25 – Autocorrelação do resíduo da previsão da série temporal GT.	36
Figura 26 – Previsão três passos a frente realizada para a série temporal CA utilizando uma NARNET (11 de fevereiro de 2016 à 1º de janeiro de 2018).	36
Figura 27 – Autocorrelação do resíduo da previsão da série temporal CA.	37
Figura 28 – Previsão três passos a frente realizada para a série temporal PLD utilizando a RNA 1 por meio da abordagem indireta (11 de fevereiro de 2016 à 1º de janeiro de 2018).	39
Figura 29 – Autocorrelação do resíduo da previsão utilizando a RNA 1 da série PLD.	39
Figura 30 – Previsão três passos a frente realizada para a série temporal PLD utilizando a RNA 2 por meio da abordagem indireta (11 de fevereiro de 2016 à 1º de janeiro de 2018).	40
Figura 31 – Autocorrelação do resíduo da previsão utilizando a RNA 2 da série PLD.	40
Figura 32 – Previsão três passos a frente realizada para a série temporal PLD utilizando a rede NARNET 1 (11 de fevereiro de 2016 à 1º de janeiro de 2018).	42
Figura 33 – Autocorrelação do resíduo da previsão da série temporal PLD por meio da previsão direta com a rede NARNET 1.	42
Figura 34 – Previsão três passos a frente realizada para a série temporal PLD utilizando a rede NARNET 2 (11 de fevereiro de 2016 à 1º de janeiro de 2018).	43
Figura 35 – Autocorrelação do resíduo da previsão da série temporal PLD por meio da previsão direta com a rede NARNET 2.	43

LISTA DE TABELAS

Tabela 1 – Parâmetros das RNAs utilizadas na primeira etapa da previsão indireta do PLD .	32
Tabela 2 – Parâmetros das RNAs utilizadas na segunda etapa da previsão indireta do PLD .	38
Tabela 3 – Parâmetros das RNAs para previsão direta do PLD	41

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Motivação	3
1.2	Objetivos	3
1.3	Estrutura do texto	3
2	Fundamentação Teórica	4
2.1	Séries Temporais	4
2.1.1	Definição	4
2.1.2	Componentes de Séries Temporais	4
2.1.3	Métodos de Análise de Séries Temporais	5
2.1.3.1	Função de Autocorrelação	5
2.2	Redes Neurais Artificiais	8
2.2.1	Modelagem do Neurônio	9
2.2.2	Arquiteturas de Redes Neurais	14
2.2.3	Processos de Aprendizagem	17
2.2.4	Treinamento Levenberg-Marquardt	18
2.2.5	Critérios de Análise de Desempenho do Modelo	19
2.2.6	Rede Neural Artificial Autorregressiva Não-linear	19
2.3	A Indústria de Energia Elétrica	21
2.3.1	Segmentação da Indústria de Energia Elétrica	21
2.3.2	O Sistema Interligado Nacional	22
2.3.3	Estrutura Institucional do Setor Elétrico	23
2.3.4	O Mercado de Energia Elétrica	24
2.3.4.1	Ambientes de Contratação	25
2.3.4.2	Ambiente de Contratação Livre	25
2.3.4.3	Formação do Preço de Liquidação das Diferenças	26
3	Abordagem do Problema	29
3.1	Previsão Indireta do PLD	29
3.2	Previsão Direta do PLD	31
4	Resultados e Discussão	32

4.1	Previsão Indireta do PLD	32
4.2	Previsão Direta do PLD	41
5	Conclusão	44
	Referências Bibliográficas	45

1 INTRODUÇÃO

O Setor Elétrico Brasileiro (SEB) teve seu início, em 1879, após o então imperador Dom Pedro II convidar o empresário norte-americano Thomas Alva Edson a introduzir aparelhos e processos para a iluminação pública no intuito de modernizar a cidade do Rio de Janeiro (SILVA, 2015).

Entre os primeiros anos do século XX e meados da década de 1940, o SEB teve seu desenvolvimento impulsionado principalmente por iniciativas de empresas privadas estrangeiras – a empresa canadense Light e a norte-americana Amforp. Nessa época, a participação da União, no que se refere à criação de leis e regulamentação do setor, era pequena. Após a publicação do Código das Águas e da Constituição de 1934, a União, os estados-membros e os municípios passaram a atuar de forma ativa como reguladores do setor nas fases de geração, transmissão e distribuição de energia elétrica (TOLMASQUIM, 2011).

Entre 1930 e 1990, o setor elétrico foi comandado, sobretudo, pelo Estado. A União ficou responsável pela construção de grandes usinas e pelo sistema de transmissão e a maioria dos estados assumiram a distribuição, salvo algumas exceções em que a construção de usinas eram feitas por empresas estaduais (TOLMASQUIM, 2011).

Devido à crise no setor elétrico em 1980 e também à crise econômica da época, o Estado não conseguia manter a expansão do setor elétrico. Paralelamente, diversos países discutiam sobre o papel do Estado nesse setor. A ideia que se tinha era que o Estado passaria a ter puramente a função de regulador da atividade econômica e trabalharia buscando recursos com a iniciativa privada. Isso tudo levou a uma ampla reforma do setor elétrico nos anos que sucederam 1990 (TOLMASQUIM, 2011).

A reforma do setor, que até então estava sob domínio estatal, teve como principal ação a privatização das empresas de energia, com três objetivos principais: equacionar o déficit fiscal, incentivar programas de investimento no setor elétrico e aumentar a eficiência das empresas de energia. Além desses objetivos, existia também a necessidade de desverticalização das empresas que atuavam nos segmentos de geração, transmissão e distribuição, por meio do aumento de competitividade (TOLMASQUIM, 2011).

O modelo, que foi criado com a reforma de 1990, apresentava diversas ineficiências, tais como superestimação do lastro dos contratos iniciais, ausência de coordenação institucional entre

os órgãos setoriais (MAE - Mercado Atacadista de Energia Elétrica¹, ONS - Operador Nacional do Sistema Elétrico e ANEEL - Agência Nacional de Energia Elétrica), falta de um modelo regulatório que estimulasse o investimento privado, falta de planejamento estrutural e restrição ao investimento das empresas estatais. Essas foram as principais causas da crise de fornecimento que resultaram em apagões a nível nacional entre 2000 e 2001. (TOLMASQUIM, 2011).

Com os diversos problemas apresentados, era necessário a criação de um modelo que tivesse confiabilidade de suprimento de energia e também garantisse o crescimento da oferta frente ao aumento da demanda. Deu-se, então, início à criação do Novo Modelo do Setor Elétrico, em 2003. No novo modelo, existem dois ambientes de contratação: o regulado e o livre. No Ambiente de Contratação Regulada (ACR), existem os distribuidores e os consumidores ditos "cativos", e todas as tarifas e condições de fornecimento são reguladas pela ANEEL. No Ambiente de Contratação Livre (ACL), a comercialização é feita entre unidades geradoras e comercializadores, os quais podem comprar energia de qualquer fornecedor e vendê-la a qualquer consumidor livre. Toda a comercialização de energia é feita mediante contratos de compra e venda registrados na Câmara de Comercialização de Energia Elétrica (CCEE).

Com o Ambiente de Contratação Livre administrado pela CCEE, a energia passa a ser negociada livremente entre os agentes. O preço a curto prazo é obtido por um programa que calcula, a cada mês, metas de geração para cada usina, de modo a minimizar o custo de operação. O programa, cujo nome é NEWAVE (Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo), calcula o Custo Marginal de Operação (CMO), que serve como base para a definição do Preço de Liquidação das Diferenças (PLD), também chamado de preço *Spot* (QUEIROZ, 2007).

Ao longo dos anos, houve um grande aumento de competitividade na indústria de energia elétrica em escala mundial (FILHO; AFFONSO; OLIVEIRA, 2009). Para decidir estratégias de licitação e estabelecer contratos bilaterais, a fim de aumentar os lucros e minimizar os riscos, a previsão de preço de energia no mercado desregulado é imprescindível (FILHO; AFFONSO; OLIVEIRA, 2014).

De acordo com Filho, Affonso e Oliveira (2014), elementos como energia armazenada nos reservatórios, quantidade de geração hidrelétrica e termelétrica, e também a carga do sistema impactam o preço da energia. Desse modo, o conhecimento da dinâmica desses fatores pode auxiliar na previsão do preço *Spot*. Uma das ferramentas utilizadas na análise das séries temporais desses

¹ O MAE foi sucedido pela CCEE em 2004.

elementos e na análise temporal do PLD são as Redes Neurais Artificiais (RNA).

Nesse contexto, este trabalho utiliza Redes Neurais Artificiais baseadas em modelos Autorregressivos não lineares (NARNET) com o objetivo de prever o Preço de Liquidação das Diferenças (PLD) três passos (ou semanas) à frente.

1.1 MOTIVAÇÃO

Ao longo dos anos, o número de consumidores livres aumentou consideravelmente no Brasil. Uma das razões do aumento foi o baixo preço a curto prazo, que durou até 2005. Após esse ano, a economia brasileira experimentou um crescimento expressivo e, como consequência, a relação entre demanda e oferta ficou muito próxima. Esse crescimento implicou em uma considerável volatilidade e imprevisibilidade do PLD, que, por sua vez, criou mais incertezas e mais riscos no mercado a curto prazo (LEITE; CASTRO; TIMPONI, 2013). Nesse sentido, é importante desenvolver novas ferramentas para amortizar os riscos no processo de tomada de decisão e elaboração de estratégias de comercialização de energia.

1.2 OBJETIVOS

O objetivo principal deste trabalho é realizar a previsão do Preço de Liquidação das Diferenças (PLD), três passos à frente, para o sub-mercado Sudeste/Centro Oeste. A metodologia adotada baseia-se na utilização de Redes Neurais Artificiais Autorregressivas não lineares (NARNET).

Além disso, duas abordagens são analisadas. A primeira verifica a previsão do PLD realizando, primeiramente, a previsão dos fatores principais que afetam o seu valor, enquanto a segunda verifica a eficiência da previsão da série temporal do PLD.

1.3 ESTRUTURA DO TEXTO

No Capítulo 1, uma breve introdução ao tema do trabalho é dada para contextualização, motivação e justificativas.

No Capítulo 2, são apresentadas a fundamentação teórica necessária para embasar a análise de séries temporais, bem como a utilização de redes neurais.

No Capítulo 3, são apresentadas duas diferentes formas de abordagem do problema.

No Capítulo 4, são apresentados os resultados obtidos para cada modelo utilizado.

O Capítulo 5 apresenta as considerações finais e as propostas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 SÉRIES TEMPORAIS

2.1.1 Definição

Uma série temporal consiste na apresentação de uma coleta de dados observados ao longo do tempo, não necessariamente igualmente espaçados. Nesse caso, a série é discreta. Uma vez que as observações são feitas continuamente, dentro de um intervalo de tempo estabelecido, a série é contínua (GOOIJER et al., 2017). Neste trabalho, as séries temporais analisadas são dados, coletados semanalmente, da energia armazenada nos reservatórios, energia elétrica proveniente de usinas hidrelétricas, energia elétrica proveniente de usinas termelétricas, carga do sistema e PLD, com relação a região sudeste e centro-oeste do Brasil. Portanto, a análise será feita por meio de séries temporais discretas.

A análise de séries temporais tem como objetivo identificar padrões não aleatórios na série temporal de uma variável de interesse. Ao examiná-las, o comportamento passado pode permitir fazer previsões sobre o futuro, ou seja, o entendimento da dinâmica da série no passado, pode ajudar a prever os valores futuros desta (CHATFIELD, 2016).

2.1.2 Componentes de Séries Temporais

Segundo Morettin e Tolo (2006), a maneira mais comum de analisar uma série é por meio da sua decomposição em componentes de tendência, ciclo e sazonalidade.

A tendência indica se uma série tende a crescer, decrescer ou permanecer em um mesmo nível ao longo do tempo. Ao analisar a tendência de uma série, o período de tempo analisado é geralmente grande se comparado ao período total da série. A Figura 1 mostra exemplos de tendência de séries. Na Figura 1a a série tende a crescer, na Figura 1b a série tende a decrescer e na Figura 1c a série tende a permanecer em um nível fixo.

Os ciclos são descritos como oscilações de subida e descida, de forma suave e repetida, ao longo da componente de tendência. Os ciclos estão relacionados a eventos pontuais que afetam a série durante um determinado período.

A sazonalidade de uma série está relacionada a fenômenos que ocorrem durante o período de observação da série e causam oscilações de subida e descida com intervalos de tempo regulares.

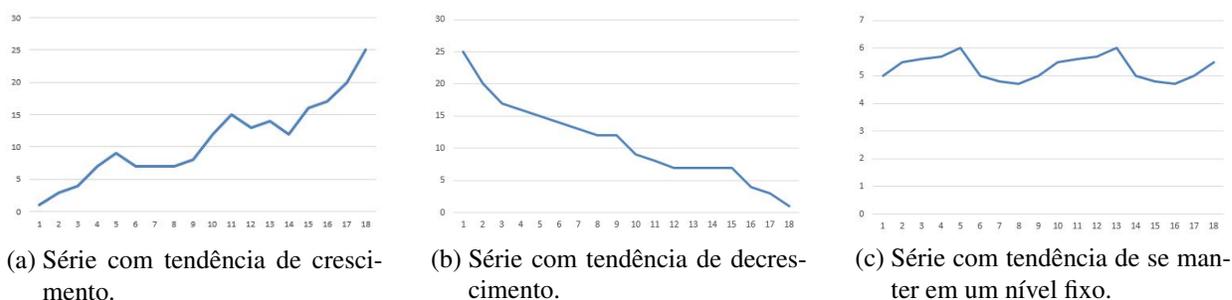


Figura 1 – Tendência em séries temporais.

2.1.3 Métodos de Análise de Séries Temporais

De acordo com Pollock (1987), existem duas grandes classes de métodos de análise de séries temporais: Métodos de Análise no Domínio do Tempo (MADT) e Métodos de Análise no Domínio da Frequência (MADF).

Os MADTs têm sua origem na teoria clássica de correlação. Esses métodos lidam, em sua maioria, com funções de autocorrelação e correlação cruzada de séries que, por sua vez, levam à construção de modelos paramétricos ou estruturais do tipo média móvel auto-regressiva para uma única série ou do tipo função de transferência para duas ou mais séries dependentes (POLLOCK, 1987).

Por outro lado, os MADFs são baseados na extensão dos métodos de análise de Fourier, que se baseiam na ideia de que, em um intervalo finito, qualquer função pode ser aproximada, para qualquer grau de exatidão desejado, fazendo-se a soma ponderada de funções de seno e cosseno das frequências harmônicas (POLLOCK, 1987).

Neste trabalho, a análise das séries temporais é realizada no domínio do tempo, baseando-se na ideia de que existe uma dependência intrínseca entre seus valores presentes e passados. Dessa forma, a função de autocorrelação é utilizada como ferramenta de medição da interdependência dos valores e serve, *a priori*, como um indicador de previsibilidade da série (SCARGLE, 1989).

2.1.3.1 Função de Autocorrelação

A Função de Autocorrelação ou ACF (do inglês, *Autocorrelation Function*) é a medida de quão próxima a quantidade observada em um dado momento é relacionada à mesma quantidade em um outro momento. Isto é, a função de autocorrelação mede a semelhança dos dados da série com eles mesmos ao longo do tempo. Essa função também pode ser vista como uma medida de previsibilidade de uma série temporal, baseada em dados passados. Se os valores da ACF são

grandes para um determinado atraso, isso indica boa previsibilidade da série temporal. Da mesma forma, ao passo que os valores da função diminuem com o atraso, mais difícil se torna a previsão com aqueles valores passados (SCARGLE, 1989).

Segundo (BOX et al., 2015), a estimativa mais satisfatória para a autocorrelação do k-ésimo atraso é dada por

$$r_k = \frac{c_k}{c_0} \quad (2.1)$$

em que

$$c_k = \hat{\gamma} = \frac{1}{N} \sum_{t=1}^{N-k} (z_t - \bar{z})(z_{t+k} - \bar{z}) \quad (2.2)$$

é o valor estimado da autocorrelação γ , N é o número de amostras e \bar{z} é a média das amostras de uma série, definida por

$$\bar{z} = \sum_{t=1}^N \frac{z_t}{N}. \quad (2.3)$$

Em termos práticos, para se obter uma boa estimativa da autocorrelação de uma série, é necessário no mínimo cinquenta observações, para uma análise de atrasos não maior que $N/4$ (BOX et al., 2015).

Uma vez que a dependência dos valores presentes e passados de uma série são quantizados por meio da função de autocorrelação, é necessário definir quais valores correspondem a uma boa correlação e quais não. Para isso é necessário introduzir o conceito de intervalos de confiança.

Dada uma variável aleatória x , com distribuição gaussiana, com média \bar{x} e desvio padrão σ_x , a probabilidade de x_i (uma observação de x) estar compreendida nas faixas de 68%, 95% e 99,7% representadas, respectivamente, por

$$\bar{x} - \sigma_x < x_i < \bar{x} + \sigma_x \quad (2.4)$$

$$\bar{x} - 1,96\sigma_x < x_i < \bar{x} + 1,96\sigma_x \quad (2.5)$$

$$\bar{x} - 3\sigma_x < x_i < \bar{x} + 3\sigma_x \quad (2.6)$$

Seja $\hat{r}_x(k)$ a ACF de x estimada a partir de uma amostra de tamanho N . O desvio padrão de $\hat{r}_x(k)$ é dado por $\sigma_{\hat{r}} = \sigma_x^2 / \sqrt{N}$. Assumindo-se que a distribuição de $\hat{r}_x(k)$ é gaussiana e fazendo uso

dos resultados da Equação (2.5), pode-se dizer que há uma probabilidade de 95% de que os valores da ACF de um sinal do tipo ruído branco¹ $u(k)$ com média zero satisfazem as relações

$$\underline{\hat{r}_u(k)} - 1,96\sigma_{\hat{r}} < \hat{r}_u(k) < \overline{\hat{r}_u(k)} + 1,96\sigma_{\hat{r}}, \quad (2.7)$$

$$\frac{-1,96\sigma_u^2}{\sqrt{N}} < \hat{r}_u(k) < \frac{+1,96\sigma_u^2}{\sqrt{N}}, \quad \forall k \neq 0, \quad (2.8)$$

visto que $\sigma_{\hat{r}} = \sigma_u^2/\sqrt{N}$ e que $\underline{\hat{r}_u(k)} \rightarrow 0$ para um sinal aleatório² (AGUIRRE, 2015).

É importante ressaltar que é comum trabalhar com ACFs normalizadas. Nesse caso, pode-se definir a ACF normalizada de $\hat{r}_z(k)$ e a normalização é tal que $\hat{r}_z(0) = 1$. Reescrevendo a Equação (2.8) para o caso normalizado, tem-se a Equação (2.9).

$$\frac{-1,96}{\sqrt{N}} < \hat{r}_z(k) < \frac{+1,96}{\sqrt{N}}, \quad \forall k \neq 0. \quad (2.9)$$

Nesse intervalo, os valores da série podem ser considerados aleatórios com confiança de 95% (AGUIRRE, 2015).

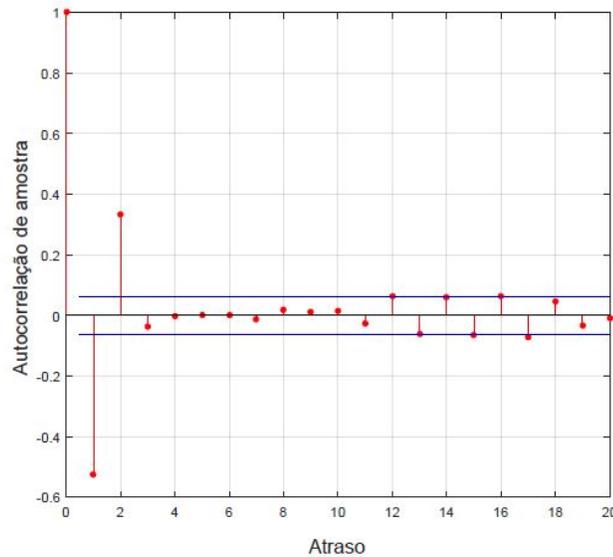


Figura 2 – Função de autocorrelação com intervalo de confiança.

A Figura 2 mostra, como exemplo, o gráfico de uma função de autocorrelação em que foram calculados seus valores de $k = 0$ até $k = 20$. Pode-se notar que, a ACF fica dentro da faixa após

¹ Ruído branco é um processo randômico $z(t)$ com média 0 e variância ∞ (KUO, 1996).

² A barra abaixo de $\hat{r}_u(k)$ indica que a média é tomada não entre os valores de k , mas entre as diversas estimativas de $r_u(k)$, para o mesmo valor de k .

$k = 2$. Isso significa que existe uma dependência desprezível dos valores futuros da série com os valores maiores do que dois passos atrás.

2.2 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) são modelos matemáticos inspirados na estrutura neural de organismos inteligentes que adquirem conhecimento por meio da experiência. Na prática, uma RNA pode ter centenas ou milhares de unidades de processamento, enquanto que no cérebro de um mamífero podem existir bilhões de neurônios (HERCULANO-HOUZEL, 2009).

A primeira publicação sobre RNA foi feita em McCulloch e Pitts (1943), no qual os autores apresentaram o primeiro modelo matemático para um neurônio artificial inspirados em um neurônio biológico.

Posteriormente, em 1949, o psicólogo canadense Donald Olding Hebb, influente na área de neuropsicologia, propôs o primeiro método de treinamento de redes neurais artificiais, cujo estudo levou o nome de Aprendizado Hebb (HEBB, 1949).

A primeira aplicação prática de RNAs surgiu no final dos anos 50, com a invenção da rede Perceptron e a sua regra de aprendizado pelo psicólogo americano Frank Rosenblatt. O psicólogo e seus colegas construíram uma rede Perceptron e demonstraram sua habilidade de resolver problemas de reconhecimento de padrões (ROSENBLATT, 1958).

Quase que paralelamente ao trabalho de Rosenblatt, os engenheiros Bernard Widrow and Ted Hoff apresentaram um novo algoritmo de aprendizado e o usaram para treinar redes neurais lineares adaptativas, muito similares em estrutura e capacidade às redes Perceptron (WIDROW; HOFF, 1960).

Seguindo os trabalhos supracitados, muitos pesquisadores estavam encorajados em conduzir pesquisa nessa área. Entretanto, em 1969, a área de neuro-computação foi dada como um caminho sem saída com a publicação do trabalho de Minsky e Papert (1969). No livro, os autores ressaltavam as limitações das redes neurais desenvolvidas até o momento. Mais especificamente, era enfatizada a impossibilidade das RNAs realizarem a classificação de padrões de classes com separação não-linear.

O trabalho de Minsky e Papert causou grande redução no número de pesquisas na área. Entretanto, alguns estudos importantes foram desenvolvidos. Dentre eles, destacam-se Hopfield (1982), que utiliza mecânica estatística para explicar uma classe específica de redes recorrentes,

e o algoritmo de retropropagação para treinamento de redes Perceptron com múltiplas camadas apresentado em James e Rumelhart (1986).

Após o final dos anos 80, cientistas voltaram a se interessar pela área de RNAs, influenciados principalmente pelos trabalhos realizados entre 1969 e 1980 e pelo aumento da capacidade de processamento dos computadores (SILVA et al., 2017).

A seção seguinte apresenta conceitos importantes sobre RNAs necessários para o desenvolvimento deste trabalho.

2.2.1 Modelagem do Neurônio

O sistema nervoso de um ser humano é formado por uma rede extremamente complexa de células, chamadas neurônios. O papel do neurônio é, basicamente, conduzir impulsos elétricos sob certas condições de operação através de suas ramificações, como mostrado na Figura 3 (QBI, 2018).

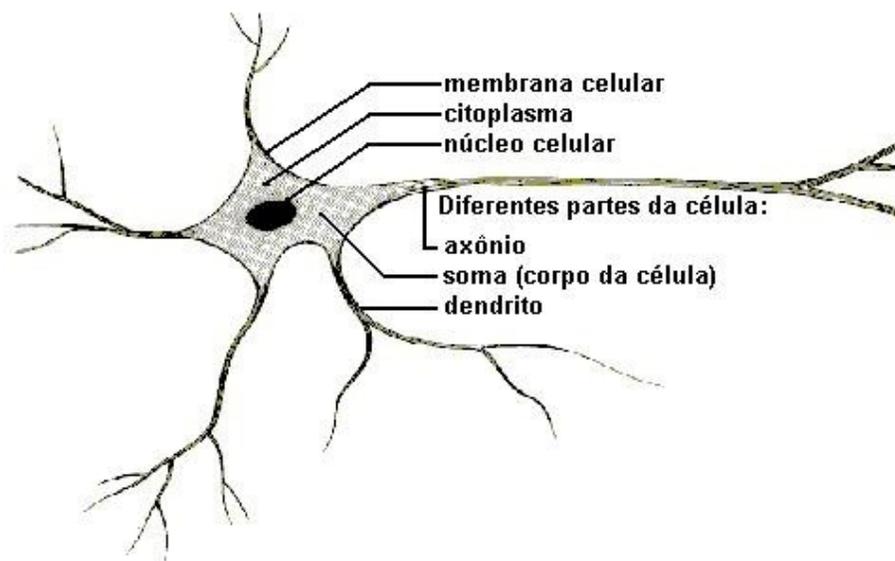


Figura 3 – Constituintes de uma célula neural (USP, 2018).

No contexto de RNAs, o neurônio tem três partes principais: os dendritos, o corpo central e os axônios. Os dendritos são terminais de entrada do neurônio que recebem sinais elétricos e os transmitem para o corpo central. No corpo central da célula nervosa é realizada a soma dos sinais de entrada que, após atingir um dado limiar de ação, transmite um sinal para outros neurônios através dos axônios. Essa comunicação entre um neurônio e outro é feita através da sinapse, região onde dois neurônios entram em contato (DEMUTH et al., 2014).

As estruturas das RNAs foram desenvolvidas baseadas em modelos do sistema nervoso biológico e do próprio cérebro humano. De acordo com Silva et al. (2017), um neurônio artificial utilizado em uma RNA é não-linear, geralmente com saídas contínuas e realiza funções simples como coletar sinais disponíveis em suas entradas, reuni-los por meio de operações matemáticas e produzir uma resposta considerando sua função de ativação.

O modelo de neurônio artificial mais utilizado em RNAs foi proposto em McCulloch e Pitts (1943). Nesse modelo, cada neurônio pode ser implementado como mostrado na Figura 4. O conjunto $\{x_1, x_2, \dots, x_n\}$ representa os múltiplos sinais de entrada da rede.

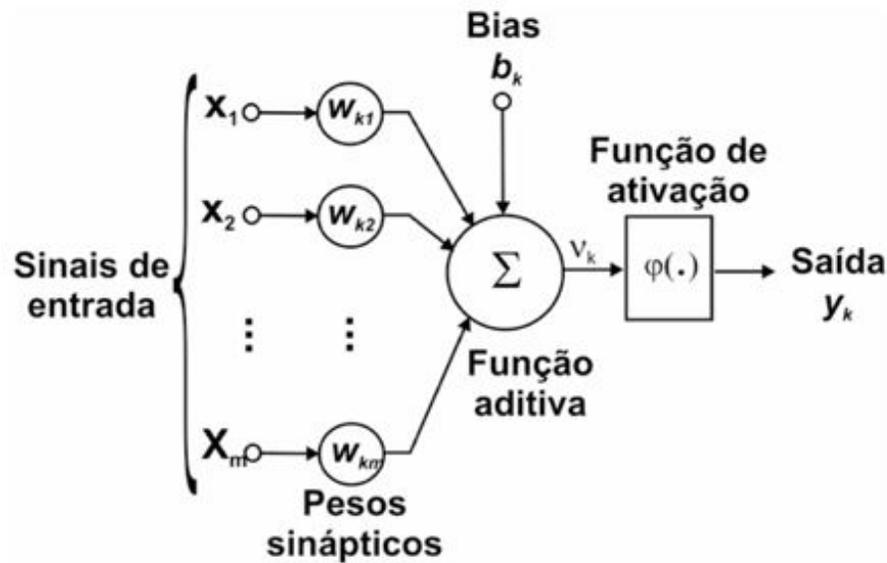


Figura 4 – Modelo de neurônio artificial (MARTINS-FILHO; MOL; ROCHA, 2005).

Os pesos que existem nas junções sinápticas de uma rede são implementadas no neurônio artificial como um conjunto de pesos sinápticos $\{w_{k1}, w_{k2}, \dots, w_{kn}\}$. O pesos refletem a importância de cada entrada $\{x_i\}$. Matematicamente, o peso sináptico de cada dendrito artificial é multiplicado pelo sinal de entrada. Os sinais ponderados da entrada são então somados ao bias ou limiar de ativação³ b_k , variável usada para especificar o limiar específico que a saída v_k ativará a saída através da função de ativação. O modelo mostrado na Figura 4 é definido por

$$v_k = \sum_{i=1}^n w_{kn}x_n - b_k \quad (2.10)$$

³ A variável bias ou limiar de ativação permite que a função de ativação seja inteiramente deslocada para a direita ou para a esquerda.

e

$$y_k = \varphi(v_k). \quad (2.11)$$

As funções de ativação são um elemento extremamente importante das RNAs. Elas basicamente decidem se um neurônio deve ser ativado ou não, ou seja, determinam a relevância da informação que o neurônio está recebendo para então ser transmitida para seus terminais de saída.

Existem diferentes tipos de funções de ativação. De acordo com Reis (2016), as mais utilizadas são:

- **Função de Ativação Linear**

Definida pela Equação (2.12) e mostrada na Figura 5, é a função de ativação mais básica porque não altera a saída de um neurônio. Geralmente é utilizada nas camadas de saída em redes neurais de regressão.

$$\varphi(x) = x \quad (2.12)$$

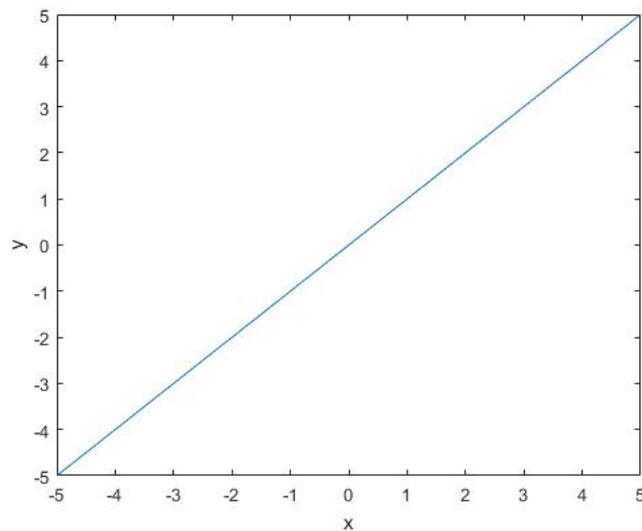


Figura 5 – Função de ativação linear.

- **Função de Ativação com Limite**

Definida pela Equação (2.13) e mostrada na Figura 6, é uma função de ativação que define a saída 1 ou 0 de com um limite estabelecido.

$$\varphi(x) = \begin{cases} 1, & \text{se } x \geq 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2.13)$$

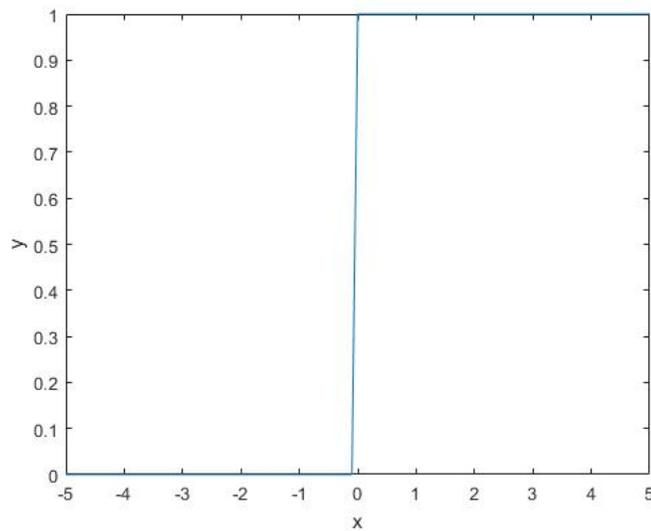


Figura 6 – Função de ativação com limite.

- **Função de Ativação Sigmoide**

Definida pela Equação (2.14) e mostrada na Figura 7, a função de ativação Sigmoide é comumente utilizada por redes neurais com propagação *feedforward* que precisam ter como saída apenas números positivos em redes neurais com múltiplas camadas.

$$\varphi(x) = \frac{1}{1 + e^{-x}} \quad (2.14)$$

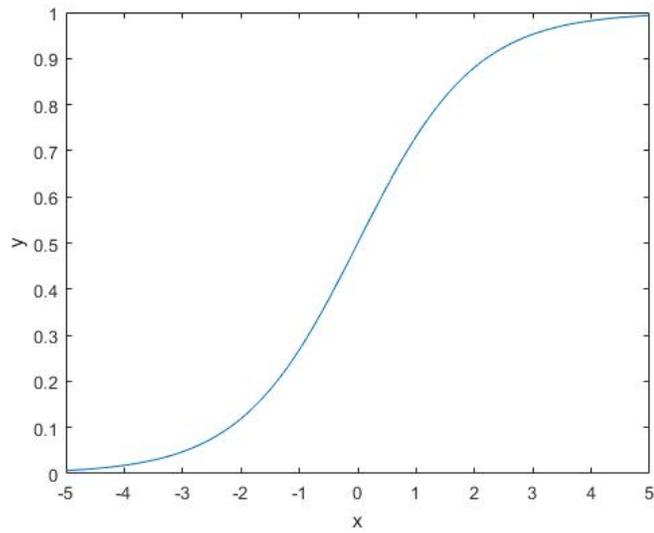


Figura 7 – Função de ativação Sigmoide.

- **Função de Ativação Tangente Hiperbólica**

Definida pela Equação (2.15) e mostrada na Figura 8, a função de ativação Tangente Hiperbólica (TanH) é muito utilizada em redes neurais cujas saídas devem ser entre -1 e 1.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.15)$$

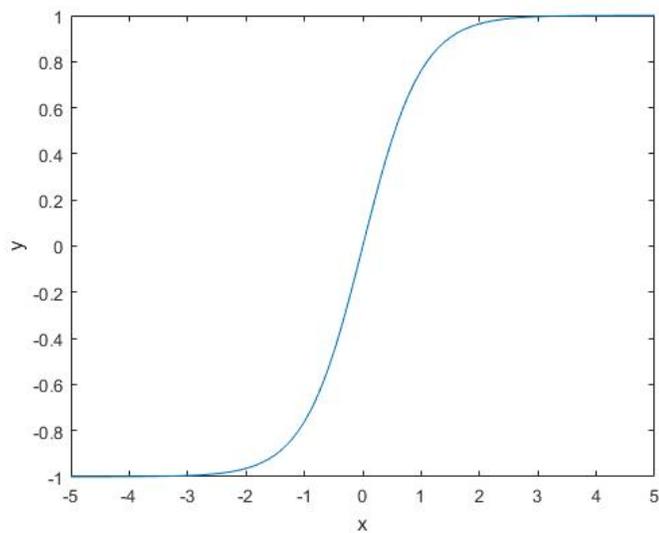


Figura 8 – Função de ativação Tangente Hiperbólica.

2.2.2 Arquiteturas de Redes Neurais

A arquitetura de uma RNA determina como os vários neurônios são organizados ou alocados em relação uns aos outros. Esses arranjos são estruturados de modo a direcionar as conexões sinápticas dos neurônios.

Em geral, uma rede neural artificial pode ser separada em três partes (SILVA et al., 2017):

- Camada de entrada: essa camada é responsável por receber a informação do ambiente externo. As entradas normalmente são normalizadas dentro dos limites estabelecidos pelas funções de ativação. A normalização resulta em uma melhor precisão numérica para as operações matemáticas realizadas pela rede.
- Camada intermediária ou camada escondida: essa camada é responsável por extrair os padrões associados com o processo ou sistema analisado.
- Camada de saída: essa camada é responsável por produzir e apresentar as saídas finais da rede, que é resultado do processamento nas camadas anteriores.

Com base em Haykin et al. (2009), as arquiteturas para RNAs podem ser divididas em três classes diferentes — redes *feedforward* de uma única camada, redes *feedforward* de múltiplas camadas e redes recorrentes.

Para o caso mais simples, nas redes *feedforward* de uma única camada existe apenas a camada de entrada que recebe os dados e os transmite para os neurônios da única camada de processamento que calcula e fornece as saídas, como mostrado na Figura 9.

As redes *feedforward* de múltiplas camadas diferem-se da primeira arquitetura apresentada, intuitivamente, pelo número de camadas de neurônios. Nessa arquitetura, existem uma ou mais camadas intermediárias que transmitem o sinal para a camada de saída, como mostrado na Figura 10.

Nas redes recorrentes, as saídas dos neurônios são utilizadas para realimentar a entrada de outros neurônios. Essa arquitetura é esquematizada na Figura 11.

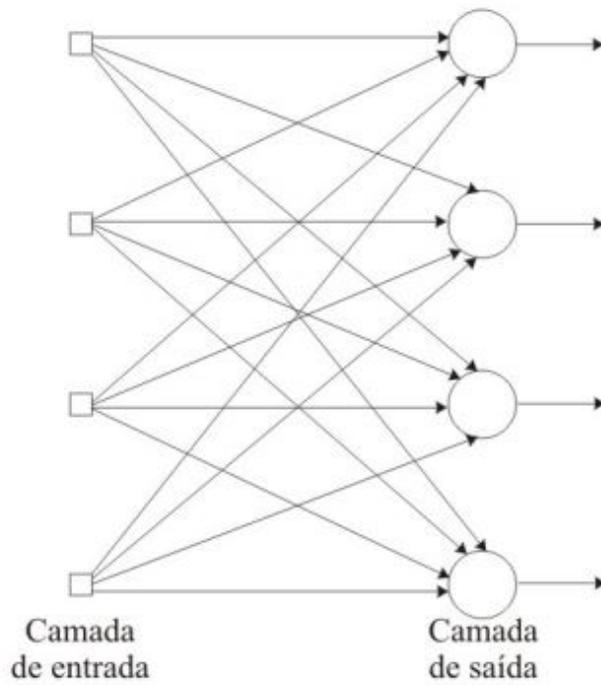


Figura 9 – Rede *feedforward* com uma única camada de neurônios (SILVA, 2005).

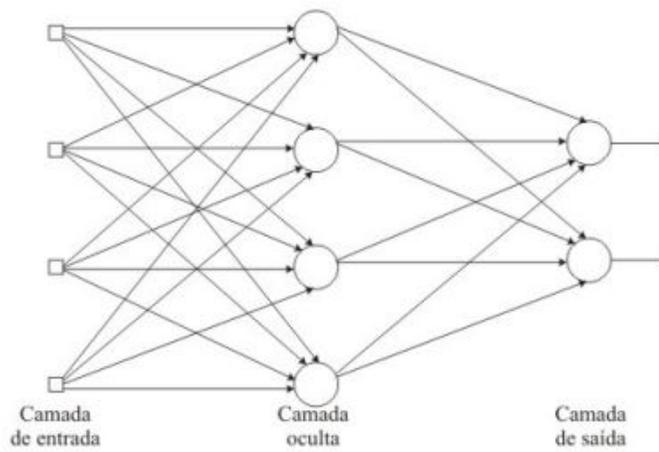


Figura 10 – Rede *feedforward* com uma camada escondida e uma camada de saída (SILVA, 2005).

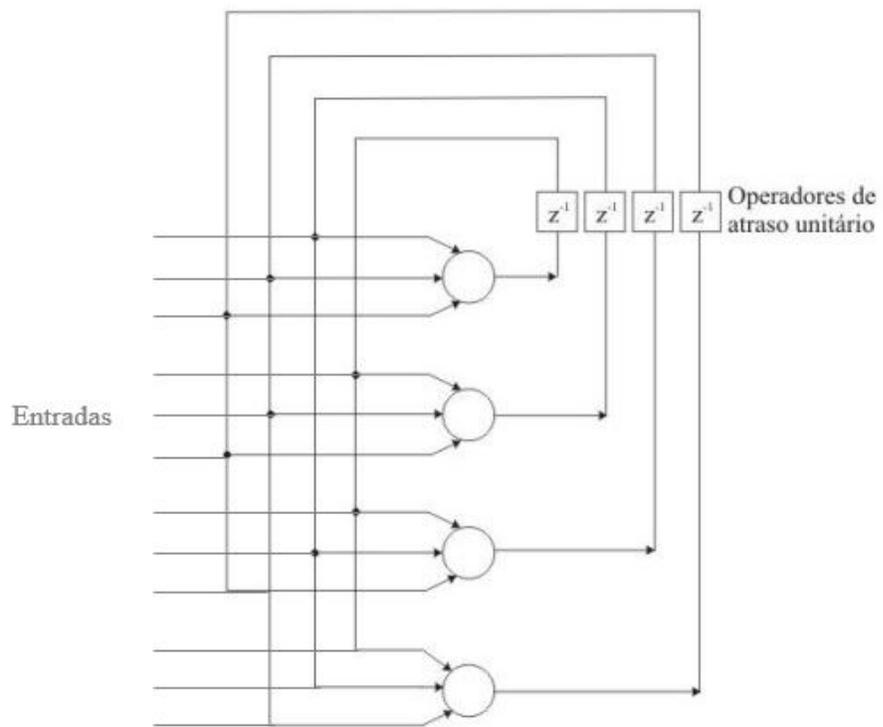


Figura 11 – Rede recorrente sem neurônios escondidos. Adaptado de Silva (2005).

2.2.3 Processos de Aprendizagem

O processo de aprendizagem é uma das características mais importantes de RNAs. A rede neural aprende por meio do ajuste dos pesos sinápticos relacionando a entrada com a saída. Existem duas grandes categorias de treinamento: a supervisionada e a não supervisionada.

No treinamento supervisionado, a aprendizagem ocorre mediante a apresentação de exemplos. São passados à rede os dados de entrada e os dados desejados na saída. Ao passo que as entradas são aplicadas à rede, as saídas resultantes são comparadas com as saídas desejadas. A regra de aprendizagem (ou regra de treinamento) é então utilizada para ajustar os pesos e os bias da rede fazendo com que os dados de saída da rede fiquem o mais próximo possível da saída desejada. Esse processo é iterativo e, a cada vez que novas entradas são apresentadas à rede os pesos sinápticos são atualizados (DEMUTH et al., 2014).

No treinamento não supervisionado, os pesos e o bias são modificados em resposta, apenas, às entradas da rede. Nesse caso, não existem saídas desejadas. Esse tipo de treinamento, a princípio, parece não ter muitas utilidades. Entretanto, de acordo com Demuth et al. (2014), os algoritmos de treinamento não supervisionado realizam algum tipo de operações de agrupamento (do inglês *clustering*). Eles aprendem a categorizar os padrões de entrada em um número finito de classes.

Neste trabalho é utilizado o processo de aprendizagem supervisionado para uma rede multicamadas, uma vez que se busca realizar a comparação de amostras presentes e passadas para previsão de séries temporais.

Uma das formas mais conhecidas de se treinar RNAs é através do algoritmo *backpropagation*, apresentado em James e Rumelhart (1986), o qual realiza a propagação recursiva dos erros.

De acordo com Míguez (2012), durante o treinamento com o algoritmo *backpropagation*, a RNA opera em uma sequência de dois passos. No primeiro, o sinal se propaga da entrada da rede até à saída, através das camadas intermediárias. No segundo passo, a saída da rede é comparada com a saída desejada, obtendo-se, assim, um sinal de erro que é propagado da camada de saída até à camada de entrada. Os pesos das conexões das unidades das camadas internas são modificados à medida que o erro é retropropagado. O ajuste dos pesos é realizado utilizando o método do gradiente, como mostrado na Equação (2.16) (IRWIN; WILAMOWSKI, 2016).

$$w_{k+1} = w_k - \alpha g_k \quad (2.16)$$

em que, w representa o vetor de pesos sinápticos, α representa uma constante de aprendizagem e g

é o gradiente do erro⁴.

2.2.4 Treinamento Levenberg-Marquardt

O algoritmo *backpropagation* foi uma grande revolução no que diz respeito a treinamento de RNAs e ainda é muito utilizado nos dias de hoje. Entretanto, esse algoritmo é visto como ineficiente por causa de sua convergência considerada lenta. Segundo Irwin e Wilamowski (2016), esse algoritmo é lento por dois motivos:

- o tamanho do passo entre uma iteração e outra (representado por α) é constante e muito pequeno, aumentando o número de iterações;
- a curvatura da superfície de erro pode fazer com que o negativo do gradiente não desça diretamente para o ponto mínimo da curva, fazendo curvas até que atinja a solução ótima e consequentemente aumentando o número de iterações.

Com o objetivo de melhorar a performance do treinamento, buscando diminuir o número de iterações para convergência, diversas técnicas de otimização foram incorporadas no algoritmo *backpropagation*. Entre as técnicas mais utilizadas, o algoritmo de Levenberg-Marquardt é o que mais se destaca (SILVA et al., 2017).

O ajuste dos pesos utilizando o algoritmo de Levenberg-Marquardt é dado por

$$w_{k+1} = w_k - (J_k^T J_k + \mu I)^{-1} J_k e_k \quad (2.17)$$

em que, J é a matriz Jacobina

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \cdots & \frac{\partial e_1}{\partial w_N} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \cdots & \frac{\partial e_2}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_M}{\partial w_1} & \frac{\partial e_M}{\partial w_2} & \cdots & \frac{\partial e_M}{\partial w_N} \end{bmatrix}, \quad (2.18)$$

μ é o coeficiente de combinação (sempre positivo), I é a matriz identidade, e representa o erro entre a saída da rede e a saída desejada, M representa o número de saídas e N o número de pesos.

⁴ O cálculo do gradiente pode ser visto com maiores detalhes em Demuth et al. (2014)

2.2.5 Critérios de Análise de Desempenho do Modelo

Para realizar a análise de desempenho da previsão realizada por uma RNA são utilizadas, neste trabalho, as análises gráficas da saída da rede neural e da autocorrelação dos resíduos.

Na regressão linear ou não linear, supõe-se que os resíduos sejam independentes (não correlacionados a) uns dos outros. Se a suposição de independência for violada, alguns resultados de ajuste do modelo podem não ser confiáveis (MINITAB, 2018).

Para realizar a análise do ponto de vista quantitativo, são utilizados os índices RMSE(i), a média e o desvio padrão do erro.

O erro médio quadrático RMSE(i) (do inglês *Root Mean-Square Error*) é um índice utilizado na quantificação de predição e é definido por (AGUIRRE, 2015):

$$RMSE(i) = \frac{\sqrt{\sum_{k=1}^N (y(k) - \hat{y}(k))^2}}{\sqrt{\sum_{k=1}^N (y(k) - y(k-i))^2}} \quad (2.19)$$

em que i representa o número de passos a frente.

O desvio padrão é uma medida que indica a dispersão dos dados dentro de uma amostra com relação à média e é definido como sendo a raiz quadrada da variância. A variância, por sua vez, é definida como sendo a média do quadrado dos erros (MONTGOMERY; RUNGER, 2010).

2.2.6 Rede Neural Artificial Autorregressiva Não-linear

De acordo com Ibrahim et al. (2016), foi provado que séries temporais podem ser modeladas pelo modelo autorregressivo não-linear (modelo NAR) definido pela Equação (2.20). Dessa forma, é esperado que o sinal de erro apresente baixa ou nenhuma autocorrelação.

$$y(t) = h(y(t-1), y(t-2), \dots, y(t-p)) + \varepsilon(t) \quad (2.20)$$

Observa-se na Equação (2.20) que $y(t)$ depende dos valores anteriores de y , em que p representa o número de atrasos e ε representa uma variável aleatória que obedece a distribuição gaussiana.

Séries com características não-lineares, como o PLD, podem utilizar uma Rede Neural Artificial Autorregressiva Não-linear (NARNET) para simular seu comportamento futuro (FAN et

al., 2017). Uma NARNET forma um sistema discreto, não-linear, autorregressivo com entradas endógenas, e pode ser escrito como (IBRAHIM et al., 2016)

$$\hat{y}(t) = h(y(t-1), y(t-2), \dots, y(t-p)) + \varepsilon(t) \quad (2.21)$$

onde \hat{y} representa os valores estimados de y .

Uma rede neural NAR é composta por uma camada de entrada, uma ou mais camadas escondidas, uma camada de saída, atraso de entrada e atraso de saída. Para utilizar a rede neural, é necessário que todos os parâmetros supracitados sejam determinados previamente.

Para uma aproximação não-linear, é comumente utilizada uma função de ativação do tipo S. Neste trabalho, será utilizada a função Tangente Hiperbólica (TanH), definida pela Equação (2.15) e mostrada na Figura 8, nas camadas escondidas.

Como a imagem da função é limitada entre -1 e 1 e os valores da série não necessariamente estão dentro dessa faixa, uma função linear é utilizada na camada de saída da rede. A Figura 12 mostra a estrutura básica da rede neural utilizada neste trabalho.

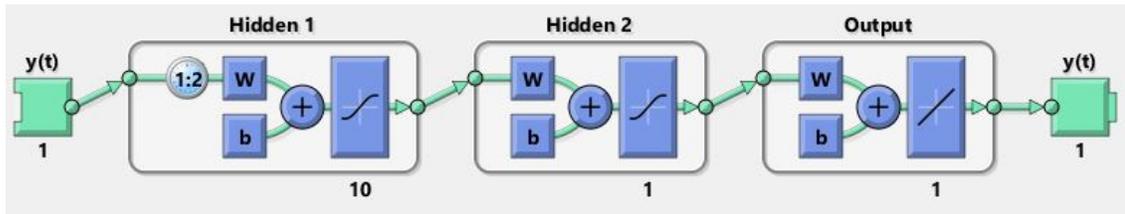


Figura 12 – Estrutura de uma NARNET em malha aberta.

A rede neural NAR é simulada em malha aberta com os valores passados até o valor presente de uma série. Uma vez que a NARNET foi treinada em malha aberta, a saída dessa rede alimenta sua entrada com dados, ou seja, a saída $y(t+1)$ é colocada na entrada da rede e obtêm-se $y(t+2)$, que realimenta novamente a entrada e assim sucessivamente. Em outras palavras, a rede treinada em malha aberta é colocada em malha fechada para que seja realizada a previsão de n passos a frente, como mostrado na Figura 13.

Neste trabalho, a rede neural NAR é implementada utilizando o programa MATLAB, utilizando a função *narnet*. Para preparar os dados de entrada e saída desejada da série nas fases de simulação e treinamento, faz-se uso da função *preparets*. Essa função normaliza ambas entrada e saída desejada com distribuição normal e nível constante de ruído. Além disso, essa função garante a troca correta dos dados de entrada e saída desejada quantas vezes forem necessárias para a alimentação das camadas de entrada e estados de atraso (ŠTENCL et al., 2013).

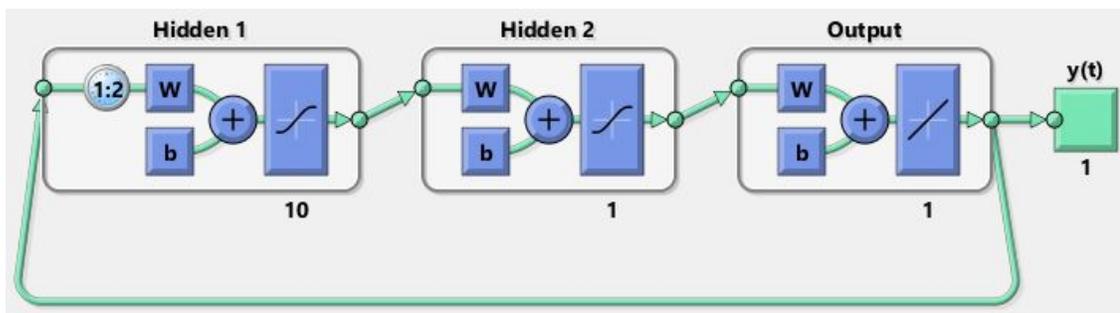


Figura 13 – Estrutura de uma NARNET em malha fechada.

2.3 A INDÚSTRIA DE ENERGIA ELÉTRICA

Para a energia elétrica chegar aos consumidores, ainda é necessário o uso de fios condutores metálicos. As centrais geradoras normalmente ficam a longas distâncias dos centros consumidores, devido principalmente a características naturais de um país como o Brasil. Dessa forma, o transporte de eletricidade é feito através dos fios condutores dos sistemas de transmissão e distribuição que compõem o sistema elétrico brasileiro.

A energia elétrica, vista como produto de compra e venda, é bem peculiar. Sua comercialização deve ser baseada em um equilíbrio rigoroso entre oferta e demanda, uma vez que o “produto” em questão não pode ser armazenado.

A indústria de energia elétrica é composta, basicamente, por geradores espalhados pelo país, e também pelas linhas de transmissão e distribuição que pulverizam o acesso à eletricidade para os diversos cantos do Brasil. O sistema elétrico é todo interconectado - mais um motivo que torna o equilíbrio instantâneo entre geração e consumo de energia um fator extremamente importante.

2.3.1 Segmentação da Indústria de Energia Elétrica

O setor elétrico é dividido em quatro segmentos: geração, transmissão, distribuição e comercialização (ABRADEE, 2018).

A geração é o segmento da indústria de energia elétrica responsável pela produção de eletricidade e por injetá-la nos sistemas de transmissão e distribuição (ABRADEE, 2018).

O segmento de transmissão é responsável pelo transporte de grandes quantidades de energia elétrica para todo o país. No Brasil, o sistema de transmissão é caracterizado por operar linhas com tensões acima de 230 kV (ABRADEE, 2018).

O segmento de distribuição também é responsável pelo transporte de energia. Esse seg-

mento distribui a energia que passa pelas linhas de transmissão para os consumidores finais, de maneira pulverizada (ABRADEE, 2018).

O segmento de comercialização, por sua vez, é o responsável pela compra de energia elétrica das centrais geradoras e pela venda da energia aos agentes do ambiente de contratação livre (ABRADEE, 2018).

2.3.2 O Sistema Interligado Nacional

O Sistema de produção e transmissão de energia elétrica brasileiro é um sistema hidrotermo-eólico extenso e complexo, com predominância de usinas hidrelétricas e com vários proprietários. Esse sistema interconectado entre suas unidades geradoras é também chamado de Sistema Interligado Nacional (SIN). A Figura 14, mostra o sistema de transmissão em 2017 (TOLMASQUIM, 2011).

O Brasil é um país com dimensões continentais em que os recursos mais explorados para produção de energia ficam afastados dos grandes centros de consumo. Isso implica na grande extensão do sistema elétrico, tornando-o um dos maiores do mundo.

A complexidade supracitada do SIN se deve à necessidade de conciliar requisitos conflitantes de economicidade e confiabilidade do sistema, que envolvem, geralmente, a definição de aspectos técnicos do sistema como, por exemplo, corrente alternada ou contínua, e também rotas alternativas para linhas de transmissão, para minimizar riscos de contingências múltiplas. Outro fator que implica na complexidade do SIN são as exigências ambientais que vêm se tornando mais rigorosas e que limitam geograficamente a alocação de elementos do sistema⁵. Além disso, a grande quantidade de agentes de transmissão, provenientes de diferentes lugares e características empresariais distintas, também tornam o sistema mais complexo, exigindo um esforço constante de coordenação por parte do ONS (TOLMASQUIM, 2011).

A interconexão elétrica das usinas torna o fornecimento de energia mais eficiente e menos sujeito as eventuais restrições de oferta. A energia gerada com abundância de água em uma certa região pode fornecer energia para outra localidade que sofre escassez de recursos hídricos, de forma a equilibrar o sistema como um todo.

O SIN é constituído por quatro subsistemas: Sul, Sudeste/Centro-Oeste, Nordeste e a maior parte da região Norte (ONS, 2018). A capacidade instalada de geração do SIN é composta, principalmente, por usinas hidrelétricas, que respondiam, em 2016, por 71,5% da capacidade total.

⁵ Elementos: linhas de transmissão e subestações.

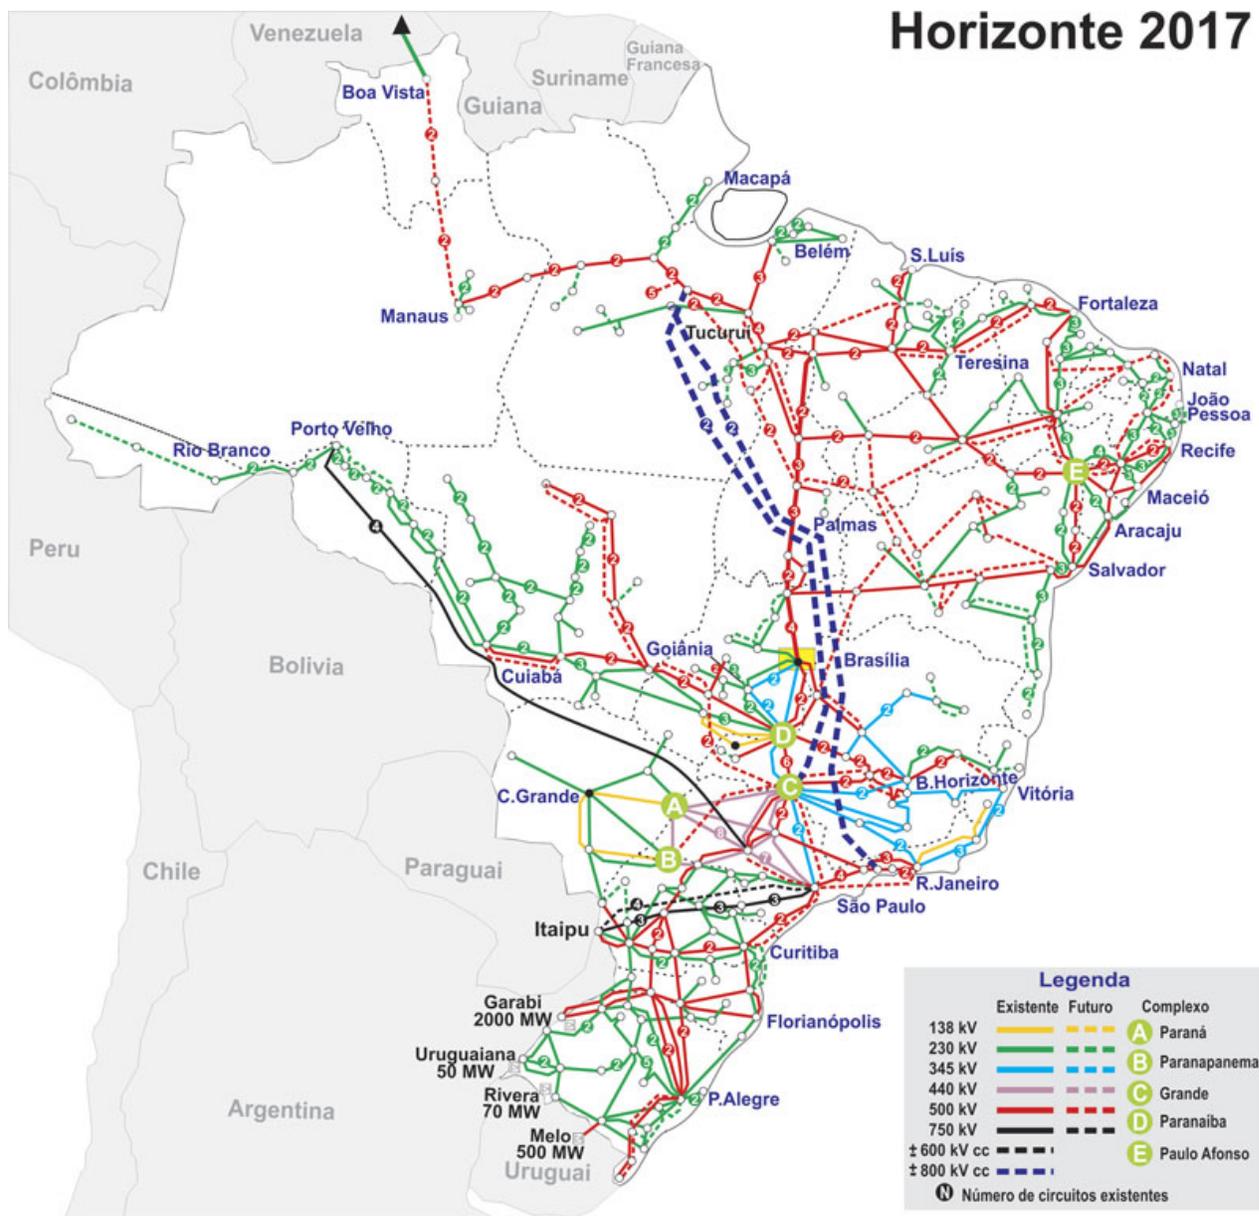


Figura 14 – Sistema de transmissão brasileiro - Horizonte 2017 (ONS, 2017).

Segundo o Plano de Operação Energética (PEN), em 2016 a capacidade total de geração do SIN era de 142042 MW com previsão de crescimento para 166540 MW em 2021 (PEN, 2017).

2.3.3 Estrutura Institucional do Setor Elétrico

O setor elétrico brasileiro passou por reformas institucionais relativamente recentes, ocorridas entre 1995 e 2004. Essas reformas resultaram na atual estrutura de funcionamento do setor, composta por agentes com competências e atribuições bem definidas, de forma que garanta um

bom funcionamento do SEB (TOLMASQUIM, 2011). De modo geral, a Figura 15 mostra o mapeamento organizacional do setor.

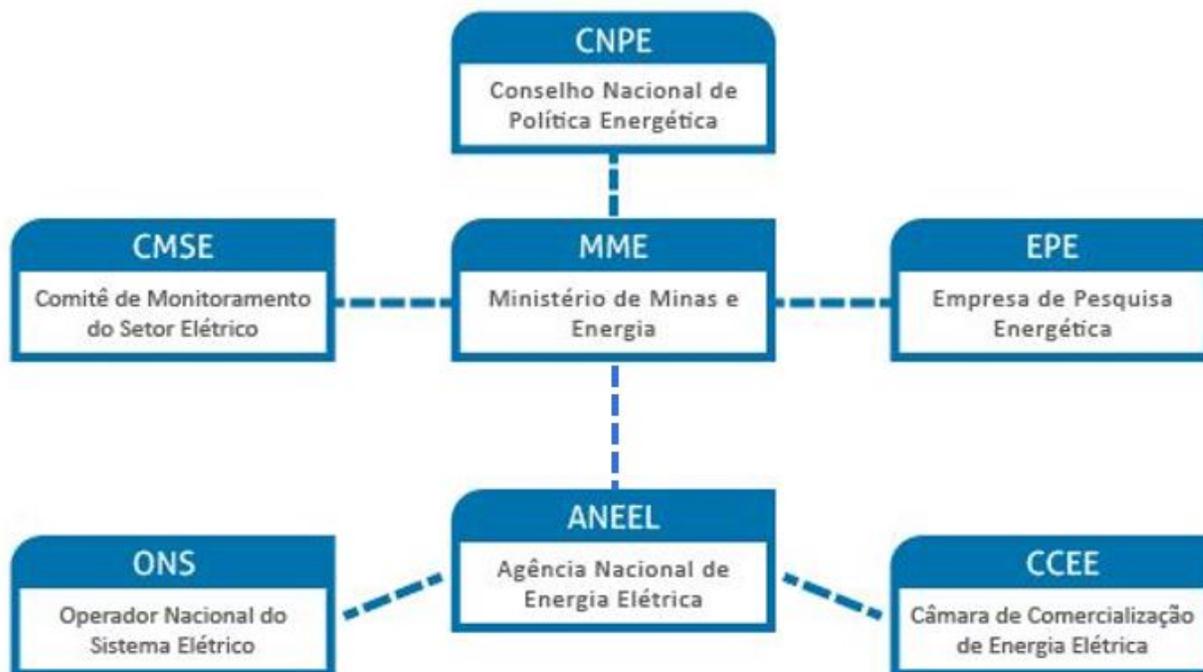


Figura 15 – Agentes institucionais do setor elétrico (CCEE, 2018a).

Todos os elementos mostrados na Figura 15 são tratados com mais detalhes em Tolmasquim (2011).

2.3.4 O Mercado de Energia Elétrica

Os segmentos de geração, transmissão e distribuição estão diretamente relacionados às fases de planejamento de expansão e de operação do sistema elétrico. A fase de planejamento de expansão consiste em estudos baseados em projeções do crescimento de demanda de energia elétrica para curto, médio e longo prazo, com a finalidade de determinar os recursos disponíveis para a operação no futuro, enquanto que a fase de operação tem como objetivo principal utilizar da melhor forma possível a capacidade de recursos existentes. Simultaneamente com as fases supracitadas, ocorre o processo de comercialização da energia elétrica. Todos esses processos estão interligados. Os resultados de planejamento e operação têm grande influência nos prazos de contratos de compra e venda de energia (TOLMASQUIM, 2011).

O chamado Novo Modelo do setor elétrico, que teve início em 2003, tem como objetivos principais a segurança do abastecimento, modicidade tarifária e universalização dos serviços de eletricidade (TOLMASQUIM, 2011).

Segundo Tolmasquim (2011), "no Novo Modelo, os agentes vendedores, titulares de concessão, permissão ou autorização para gerar, importar ou comercializar energia elétrica, estão obrigados a garantir a totalidade de seus contratos, apresentando lastro para a venda de energia e potência suficiente para tanto".

Uma das medidas mais substanciais para alcançar o que o modelo propunha foi a modificação do modo de contratação da energia por parte das distribuidoras por meio da criação de dois ambientes de contratação: o Ambiente de Contratação Livre (ACL) e o Ambiente de Contratação Regulada (ACR) (TOLMASQUIM, 2011).

2.3.4.1 Ambientes de Contratação

A modicidade tarifária e a garantia de suprimento, ambos objetivos do Novo Modelo, são potencialmente contrapostas. O primeiro requer que o preço da energia seja o mais acessível possível, ao passo que o segundo se beneficiaria de preços maiores. Nesse sentido, o governo procura realizá-los por meio da segmentação da demanda (ACL e ACR) e da oferta (energia existente⁶ e energia nova⁷) e também tornando obrigatória a contratação antecipada e integral da demanda projetada dos distribuidores (TOLMASQUIM, 2011).

No ACR, existem os distribuidores e os consumidores cativos, e todas as tarifas e condições de fornecimento são reguladas pela ANEEL. No ACL, a comercialização é feita entre unidades geradoras e comercializadores, que podem comprar energia de qualquer fornecedor e vendê-la a qualquer consumidor livre. Toda a comercialização de energia é feita mediante contratos de compra e venda registrados na Câmara de Comercialização de Energia Elétrica (CCEE).

2.3.4.2 Ambiente de Contratação Livre

O Ambiente de Contratação livre, também chamado de Mercado Livre, é o segmento de mercado onde os consumidores livres⁸ ou desregulados e comercializadores celebram contratos

⁶ Energia proveniente de empreendimentos existentes.

⁷ Energia proveniente de empreendimentos novos.

⁸ Consumidor livre é aquele cuja demanda contratada é igual ou maior que 3 MW, atendidos em tensão de fornecimento acima de 69 kV e, se atendidos em tensão inferior, os ligados após 08/07/1995. Dentro da classe de consumidores livres, existem os consumidores especiais que, por meio da resolução normativa nº 247 de 2006 da ANEEL, podem optar pela compra de energia elétrica no ambiente de contratação livre, com demanda contratada

bilaterais com as unidades geradoras (TOLMASQUIM, 2011).

No ACL, o consumidor livre tem poder de escolha com relação a fonte desejada e seus parceiros comerciais, bem como o estabelecimento de condições de contrato. Além disso, existe a constante concorrência entre geradores e comercializadores tornando o preço da energia, nesse mercado, mais atrativa (ABRACEEL, 2018).

É importante ressaltar que os contratos de compra e venda de energia não incluem os custos atrelados a transmissão e distribuição desta. Existe uma tarifa que os consumidores livres pagam pela utilização da rede para levar a energia elétrica da usina para suas dependências.

Os contratos de compra e venda de energia não estão diretamente atrelados a geração e consumo de energia, ou seja, o despacho físico não tem ligação direta com a relação contratual dos agentes. Dessa forma, não existe uma maneira de garantir que uma usina gerará exatamente o que é previsto em contrato, assim como também não existe garantia de que o consumidor fará o uso da exata quantidade de energia contratada. Ambos os lados podem variar para mais ou para menos na geração e consumo de energia. Essas diferenças são liquidadas no mercado de curto prazo e os valores são devolvidos em forma de crédito ou débito aos agentes envolvidos.

A quantidade de energia gerada e consumida é verificada por meio de medidores de energia. A CCEE então compara esses valores com os montantes contratados. As diferenças são vendidas pelo Preço de Liquidação das Diferenças (PLD).

2.3.4.3 Formação do Preço de Liquidação das Diferenças

O Operador Nacional do Sistema Elétrico (ONS) utiliza uma cadeia de modelos de otimização para determinar o despacho de mínimo custo de operação. Os modelos usam uma programação dinâmica dual estocástica para definir o perfil das unidades de geração, para cada horizonte de planejamento, visando calcular o custo marginal de operação no curto prazo (CMO) para os quatro sub-mercados (CASTRO; LEITE, 2010).

Os sub-mercados são divisões do SIN para as quais são estabelecidos Preços de Liquidação de Diferenças específicos e cujas fronteiras são definidas em razão da presença e duração de restrições relevantes de transmissão aos fluxos de energia elétrica no sistema elétrico brasileiro.

De acordo com Filho, Affonso e Oliveira (2014), diversos fatores como energia armazenada nos reservatórios, quantidade de geração hidrelétrica e termelétrica, e também a carga do sistema

entre 0,5MW e 3MW e tensão mínima de 2,3kV, quando a energia adquirida for proveniente de fonte incentivadas (solar, eólica e biomassa) ou por fontes convencionais que possuem uma potência de 30 a 50MW (CPFL, 2018).

são dados utilizados para a operação ótima do SIN.

Para determinar o PLD, os mesmos modelos de otimização da ONS são utilizados - os modelos NEWAVE e DECOMP (CCEE, 2018b).

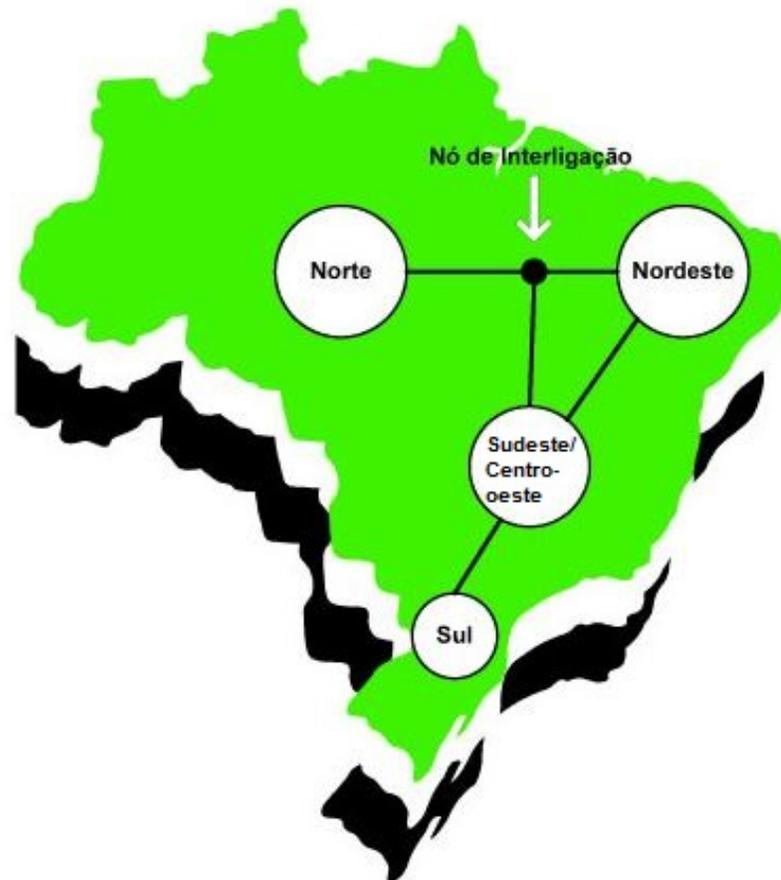


Figura 16 – Subsistemas do SEB. Adaptado de Ramos et al. (2012).

O modelo de otimização NEWAVE é utilizado para o planejamento de médio prazo (até 5 anos), com discretização mensal e representação a sistemas equivalentes, como mostrado na Figura 16. O modelo tem como objetivo determinar a estratégia de geração hidráulica e térmica em cada estágio gerando o CMO para todo o período de planejamento. Um dos resultados mais importantes gerado por esse programas são as funções de custo futuro, que são utilizadas nos modelos de outras etapas para o cálculo do impacto da utilização da água armazenada nos reservatórios.

O modelo de otimização DECOMP, é utilizado para o planejamento de curto prazo (até 12 meses), como discretização semanal para o primeiro mês, e mensal para o restante do período. Esse modelo tem como objetivo determinar o despacho de geração das usinas hidráulicas e térmicas que minimiza o custo de operação ao longo do período de planejamento, dado o conjunto de

informações disponíveis (carga, vazões, disponibilidades, limites de transmissão entre subsistemas e a função de custo futuro proveniente do modelo NEWAVE). Os principais resultados do modelo DECOMP são os despachos individualizados de cada usina e o CMO.

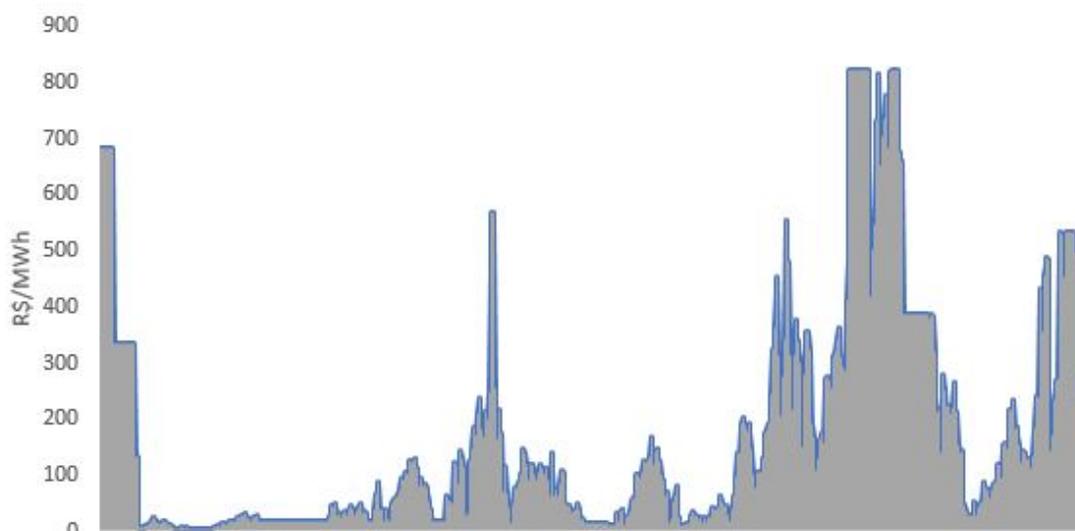


Figura 17 – Evolução do PLD para carga média no sub-mercado Sudeste/Centro-oeste (30 de julho de 2001 à 01 de janeiro de 2018).

Utilizando os valores calculados de CMO, o operador de mercado determina o PLD, em base semanal, para três patamares de carga (carga pesada, média e leve) e para cada sub-mercado — Norte, Nordeste, Sudeste/Centro-Oeste e Sul. O PLD é limitado por valores mínimo e máximo de acordo com a Resolução Normativa ANEEL nº 633/14, com validade entre a primeira e a última semana operativa de preços do ano (CCEE, 2018b).

A Figura 17 mostra o histórico do PLD no sub-mercado Sudeste/Centro-Oeste. É possível observar a volatilidade do preço de energia, que no caso brasileiro é significativamente elevada.

3 ABORDAGEM DO PROBLEMA

Neste trabalho, são verificados modelos de previsão do PLD para o sub-mercado Sudeste/Centro Oeste, capazes de estimar o preço de energia até três passos à frente. A metodologia adotada baseia-se na utilização de Redes Neurais Artificiais.

Duas abordagens são analisadas. A primeira abordagem verifica a previsão do PLD realizando, primeiramente, a previsão dos fatores principais que afetam o seu valor, enquanto que a segunda abordagem verifica a eficiência da previsão da série temporal do PLD. Nas próximas seções, as abordagens realizadas são explicadas com mais detalhes.

3.1 PREVISÃO INDIRETA DO PLD

Esta abordagem busca, primeiramente, realizar a previsão dos fatores principais que influenciam no valor do PLD. Segundo Filho, Affonso e Oliveira (2014), esses fatores para o sub-mercado Sudeste/Centro-Oeste são: Energia Armazena nos reservatórios (EA), energia proveniente de Geração Hidrelétrica (GH), energia proveniente de Geração Termelétrica (GT) e Carga do sub-mercado (CA). Uma vez que é feita a previsão três passos à frente das séries temporais EA, GH, GT e CA utilizando NARNETS, seus valores futuros são utilizados na entrada de uma rede neural tradicional, NNET, que relaciona esses fatores ao valor do PLD. A Figura 18 mostra o esquema da previsão indireta do PLD.

No que se refere ao treinamento de uma NARNET, é necessário entender como é feito a entrada de dados para que a rede trabalhe da maneira desejada. Primeiramente, a rede é treinada em malha aberta, utilizando as ferramentas disponíveis no MATLAB, configurando o número de neurônios e camadas, algoritmo de treinamento e atraso da entrada. Uma vez que a rede neural foi treinada, a previsão três passos à frente é realizada alimentando-se a entrada da rede com a sua saída. Nessa parte, na primeira iteração (ou realimentação), é obtido a previsão um passo à frente. Para obter-se a previsão dois passos à frente, os valores do vetor de entrada são deslocados de modo que o atraso em relação à saída seja sempre o mesmo. O mesmo processo é realizado sucessivamente para previsões com um horizonte maior.

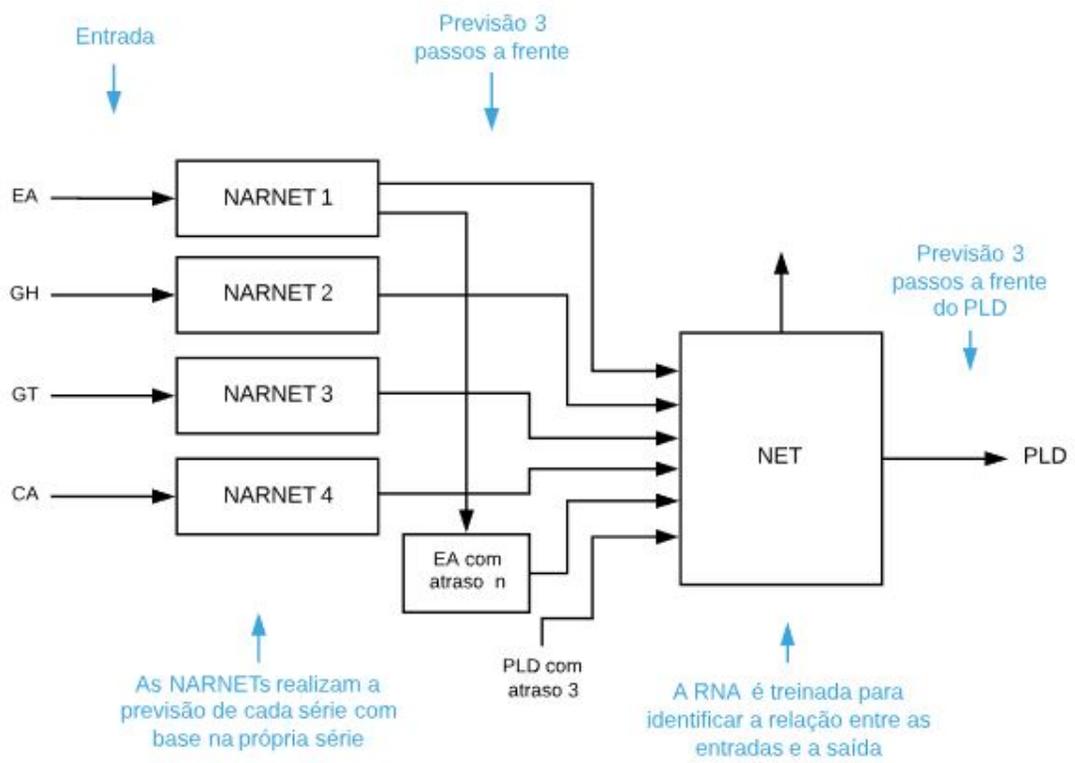


Figura 18 – Esquema de previsão indireta do PLD.

3.2 PREVISÃO DIRETA DO PLD

Esta abordagem busca realizar a previsão do PLD por meio de uma NARNET, assim como é feito com as séries EA, GH, GT e CA. O esquema para a previsão direta do PLD é mostrado na Figura 19.



Figura 19 – Esquema de previsão indireta do PLD.

4 RESULTADOS E DISCUSSÃO

Os resultados são apresentados para o sub-mercado Sudeste/Centro-Oeste e consideram somente o nível de carga média. O horizonte de previsão é de três semanas à frente, ou seja, os dados de entrada da rede possuem um intervalo de tempo de três semanas anteriores aos dados de saída. É importante ressaltar que esse intervalo poderia ser de uma, duas, três ou mais semanas, mas para efeito de cálculo do preço de curto prazo optou-se pelo intervalo de três semanas. São apresentadas as características da RNA (número de neurônios em cada camada e funções de ativação), os atrasos da entrada, o RMSE(3), o desvio padrão do erro, a média do erro, os gráficos comparativos entre o valor esperado e o valor de saída da rede e os gráficos de autocorrelação do resíduo.

4.1 PREVISÃO INDIRETA DO PLD

Na abordagem de previsão indireta do PLD, primeiramente, é realizado a previsão três passos à frente das séries temporais EA, GH, GT e CA, utilizando NARNETS. Nessa primeira etapa, foram simuladas 1764 RNAs para cada série, variando-se o número de neurônios da primeira e segunda camadas de 2 a 15, e alterando-se de 1 a 10 os atrasos da entrada. A Tabela 1 mostra as configurações e características das RNAs NARNETs que tiveram o melhor desempenho.

Tabela 1 – Número de neurônios da primeira camada (N1), número de neurônios da segunda camada (N2), número de neurônios da camada de saída (NS), função de ativação da primeira camada (FA1), função de ativação da segunda camada (FA2), função de ativação da camada de saída (FAS), atraso da entrada, RMSE(3), desvio padrão e média do erro das RNAs utilizadas para previsão três passos à frente das séries de Energia Armazena nos reservatórios (EA), energia proveniente de Geração Hidrelétrica (GH), energia proveniente de Geração Termelétrica (GT) e Carga (CA) do sub-mercado Sudeste/Centro-oeste.

Série Temporal	N1	N2	NS	FA1	FA2	FAS	Atraso da entrada	RMSE(3)	Desvio Padrão	Média do erro
EA	12	6	1	tanH	tanH	linear	3	0,2501	0,7283	-0,1684
GH	11	2	1	tanH	tanH	linear	2	0,9597	$2,07 \times 10^3$	-71,3563
GT	6	11	1	tanH	tanH	linear	3	1,0136	$1,03 \times 10^3$	59,8501
CA	11	8	1	tanH	tanH	linear	3	0,985	$1,73 \times 10^3$	148,5864

As figuras 20, 22, 24 e 26 mostram as previsões realizadas para as séries EA, GH, GT e

CA, respectivamente. Pode-se observar que a previsão mostrada na Figura 20, referente à energia armazenada nos reservatórios, teve o melhor desempenho, tanto em termos qualitativos quanto quantitativos. A série temporal CA não é tão volátil quanto as outras, fazendo com o que o desempenho do preditor seja melhor.

As figuras 21, 23, 25 e 27 mostram os gráficos de resíduo das séries EA, GH, GT e CA, respectivamente. Pode-se ver, nesses gráficos, que o resíduo entre as séries prevista e a real apresentam comportamentos quase que puramente aleatórios, ou seja, o comportamento dinâmico das séries é bem representado pelos preditores.

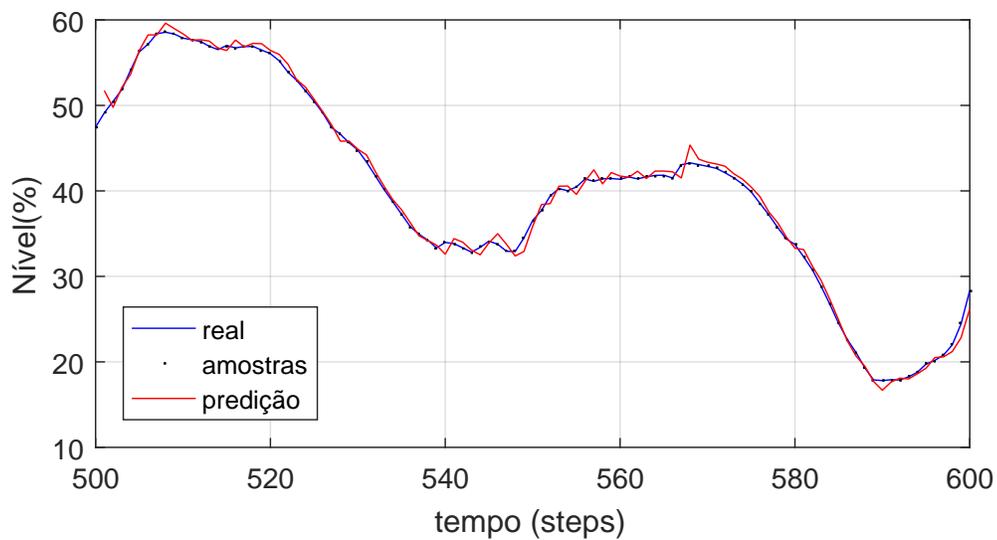


Figura 20 – Previsão três passos a frente realizada para a série temporal EA utilizando uma NAR-NET (11 de fevereiro de 2016 à 1º de janeiro de 2018).

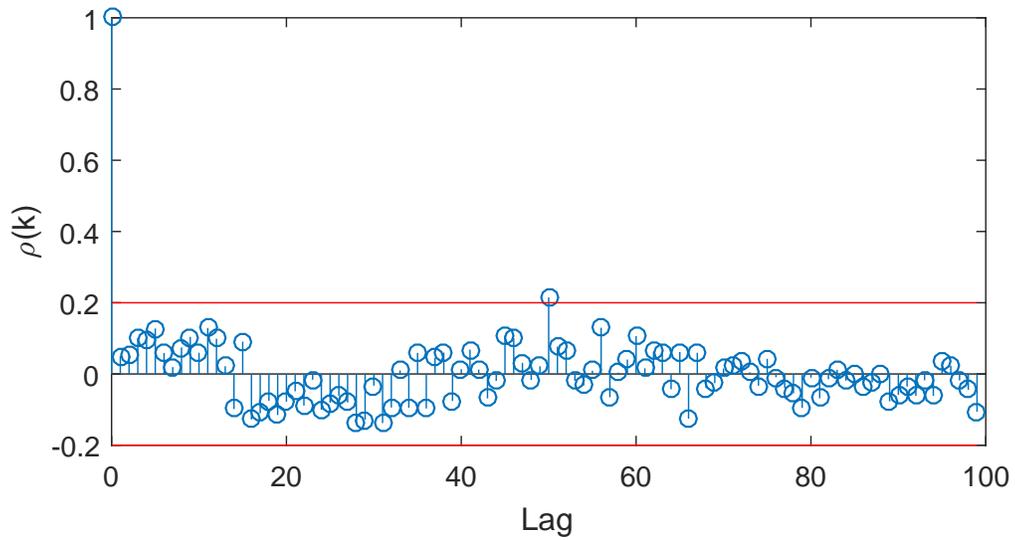


Figura 21 – Autocorrelação do resíduo da previsão da série temporal EA (11 de fevereiro de 2016 à 1º de janeiro de 2018).

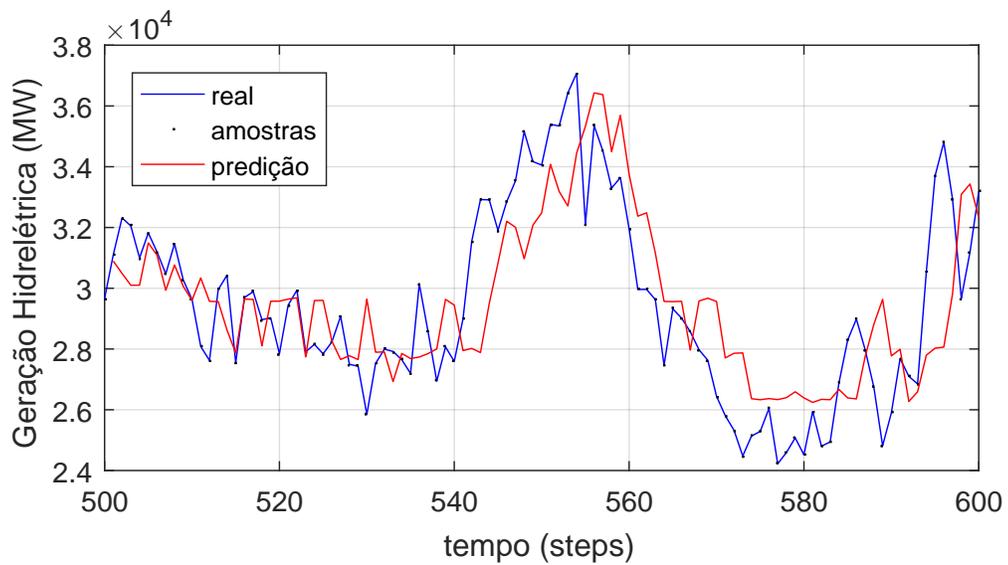


Figura 22 – Previsão três passos a frente realizada para a série temporal GH utilizando uma NAR-NET(11 de fevereiro de 2016 à 1º de janeiro de 2018).

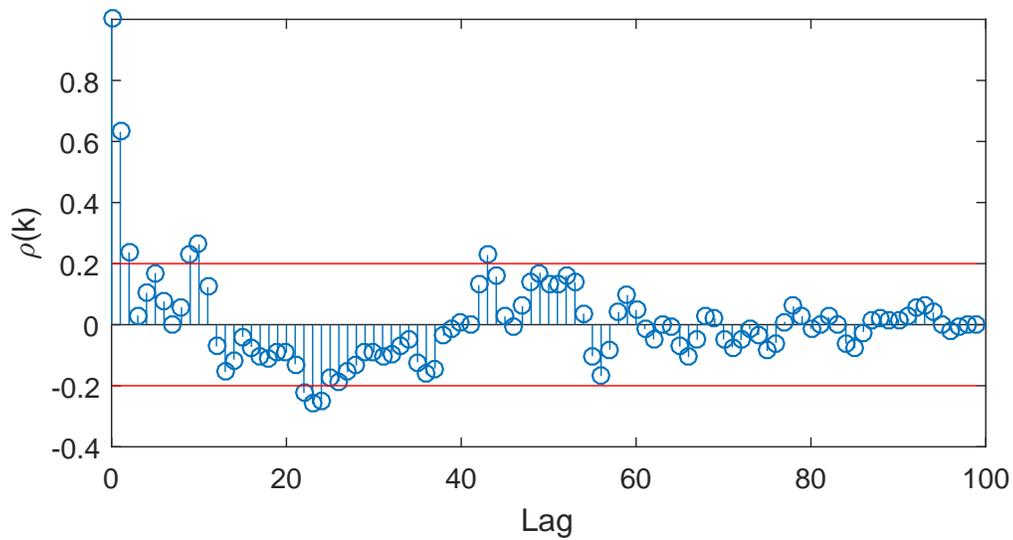


Figura 23 – Autocorrelação do resíduo da previsão da série temporal GH.

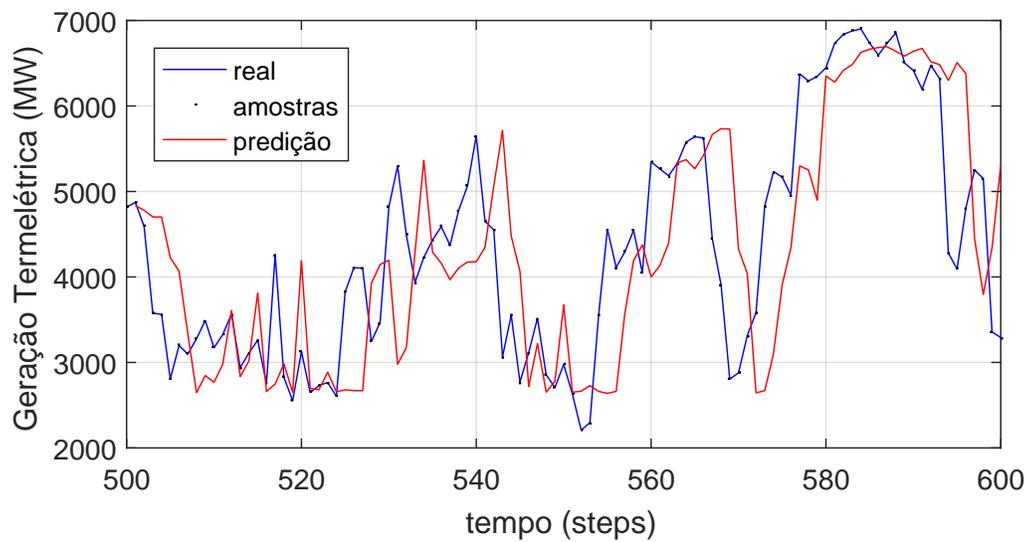


Figura 24 – Previsão três passos a frente realizada para a série temporal GT utilizando uma NAR-NET (11 de fevereiro de 2016 à 1º de janeiro de 2018).

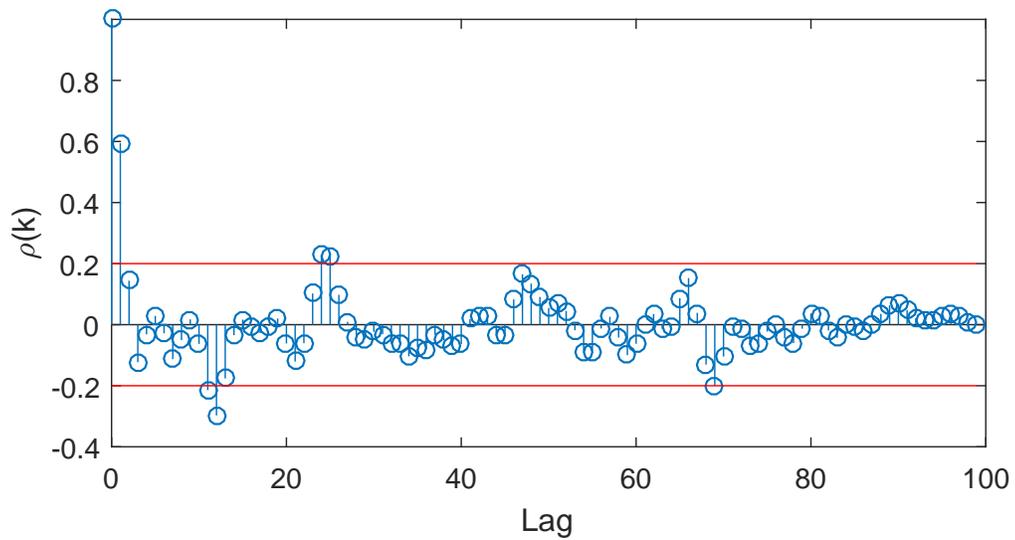


Figura 25 – Autocorrelação do resíduo da previsão da série temporal GT.

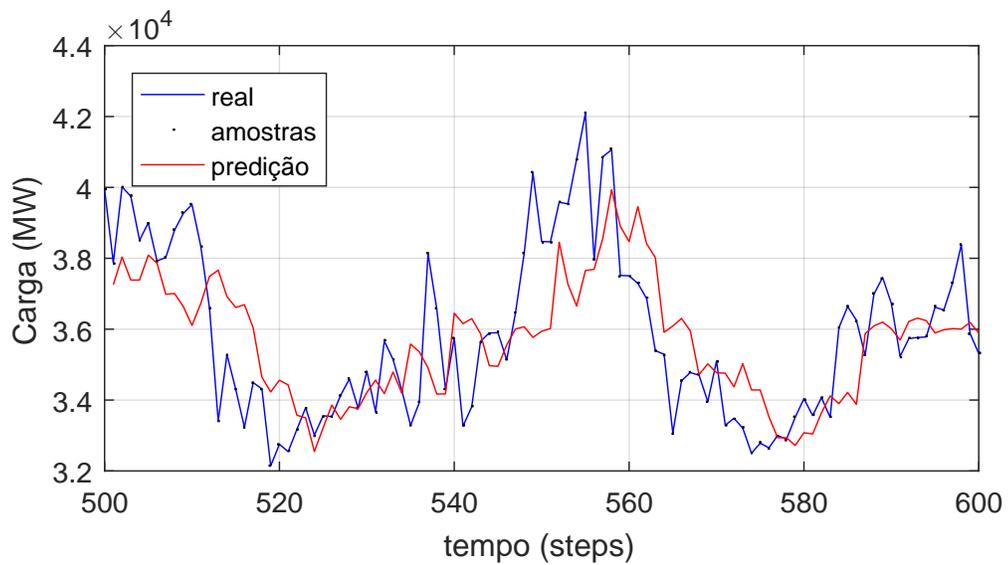


Figura 26 – Previsão três passos a frente realizada para a série temporal CA utilizando uma NAR-NET (11 de fevereiro de 2016 à 1º de janeiro de 2018).

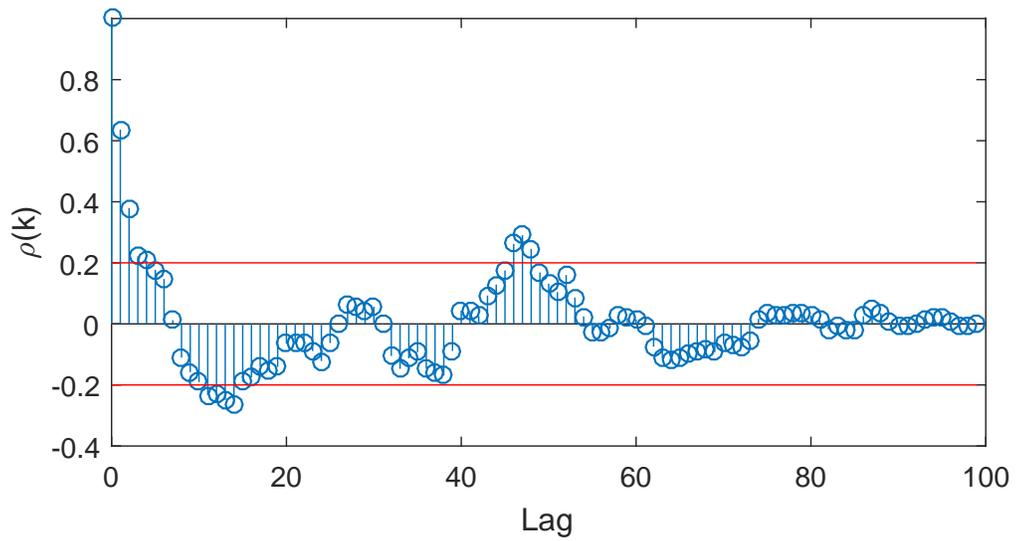


Figura 27 – Autocorrelação do resíduo da previsão da série temporal CA.

Na segunda etapa da primeira abordagem, em que é realizada a previsão indireta do PLD, foram simuladas 8410 RNAs, variando-se o número de neurônios da primeira e segunda camadas de 2 a 30, e alterando-se de 1 a 10 os atrasos da entrada da série EA. A Tabela 2 mostra as configurações e características das duas RNAs com melhor desempenho, utilizando os valores previstos na primeira etapa da abordagem de previsão indireta.

Tabela 2 – Número de neurônios da primeira camada (N1), número de neurônios da segunda camada (N2), número de neurônios da camada de saída (NS), função de ativação da primeira camada (FA1), função de ativação da segunda camada (FA2), função de ativação da camada de saída (FAS), atraso da entrada, RMSE(3), desvio padrão e média do erro das RNAs utilizadas para previsão três passos à frente das séries do PLD no sub-mercado Sudeste/Centro-oeste, por meio da previsão indireta.

Número da rede	N1	N2	NS	FA1	FA2	FAS	Atraso da entrada	RMSE(i)	Desvio Padrão	Média do erro
1	26	16	1	tanH	tanH	linear	10	0,911	89,759	20,4226
2	13	2	1	tanH	tanH	linear	6	1,0477	105,45	-9,5961

As figuras 28 e 30 mostram as previsões realizadas para o PLD utilizando as configurações 1 e 2, mostradas na Tabela 2, respectivamente. Pode-se observar que, em ambos os gráficos, os valores previstos tendem a seguir os valores reais da série temporal.

As figuras 29 e 31 mostram os gráficos de resíduo referentes às configurações 1 e 2, mostradas na Tabela 2, respectivamente. Pode-se ver, nesses gráficos, que os resíduos entre as séries previstas e as séries reais apresentam comportamentos quase aleatórios.

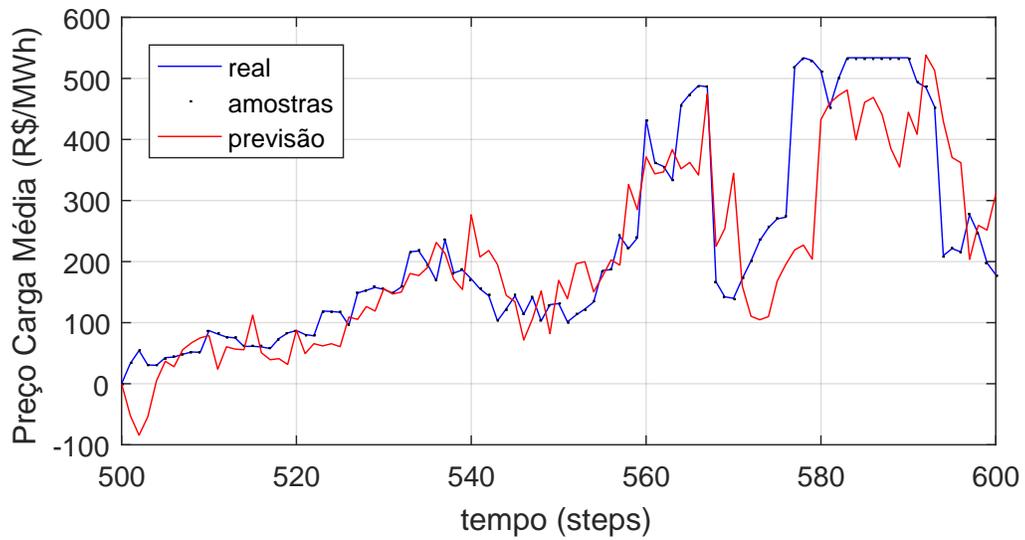


Figura 28 – Previsão três passos a frente realizada para a série temporal PLD utilizando a RNA 1 por meio da abordagem indireta (11 de fevereiro de 2016 à 1º de janeiro de 2018).

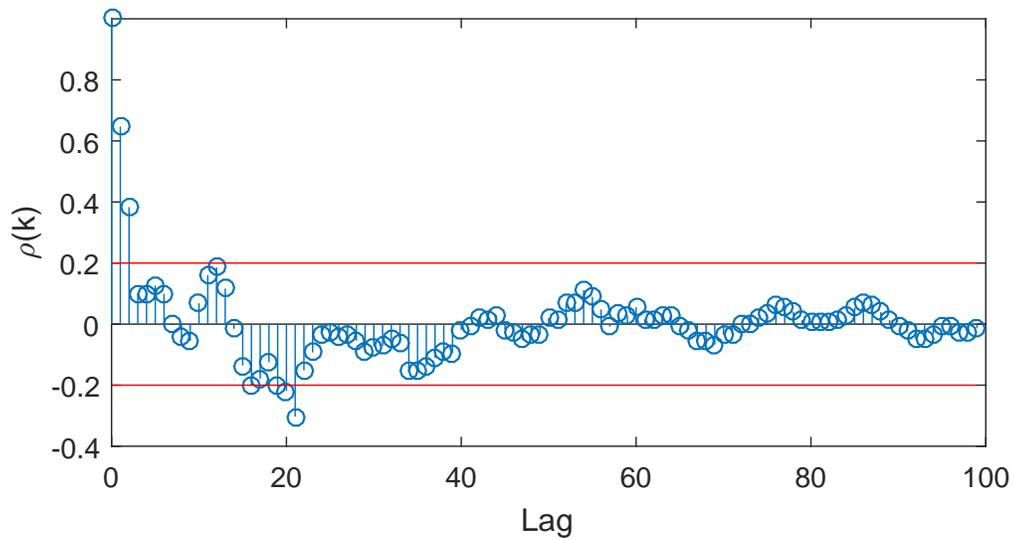


Figura 29 – Autocorrelação do resíduo da previsão utilizando a RNA 1 da série PLD.

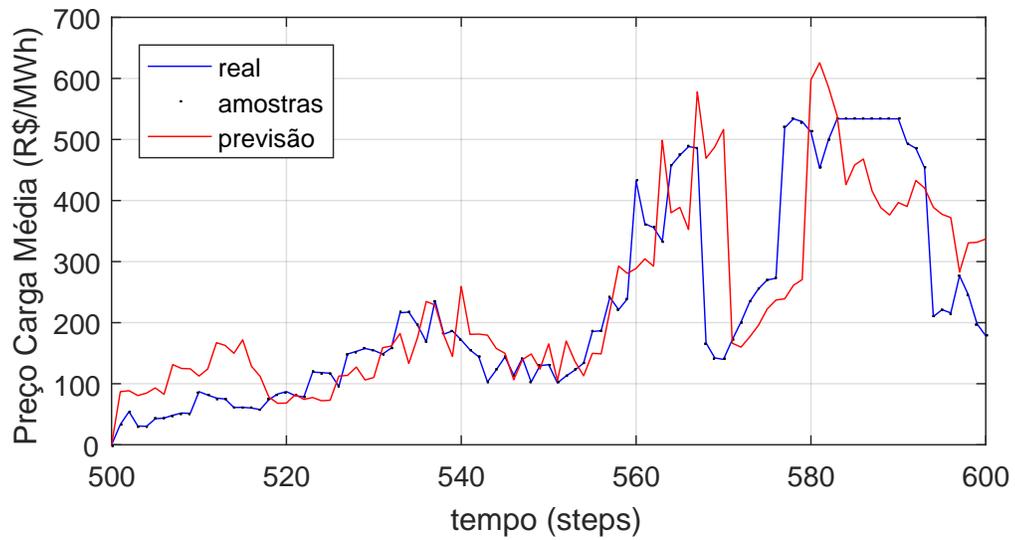


Figura 30 – Previsão três passos a frente realizada para a série temporal PLD utilizando a RNA 2 por meio da abordagem indireta (11 de fevereiro de 2016 à 1º de janeiro de 2018).

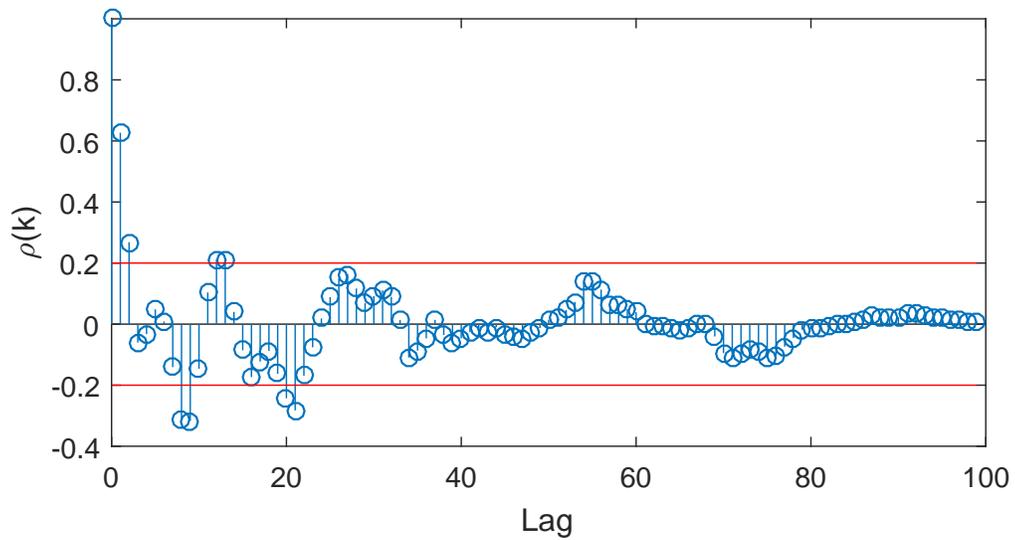


Figura 31 – Autocorrelação do resíduo da previsão utilizando a RNA 2 da série PLD.

4.2 PREVISÃO DIRETA DO PLD

Na abordagem de previsão direta do PLD, primeiramente, é realizada a previsão três passos à frente utilizando NARNETS. Foram simuladas 1764 RNAs para a série temporal do PLD, variando-se o número de neurônios da primeira e segunda camadas de 2 a 15, e alterando-se de 1 a 10 os atrasos da entrada. A Tabela 3 mostra as configurações e características das duas RNAs NARNETs que tiveram o melhor desempenho.

Tabela 3 – Número de neurônios da primeira camada (N1), número de neurônios da segunda camada (N2), número de neurônios da camada de saída (NS), função de ativação da primeira camada (FA1), função de ativação da segunda camada (FA2), função de ativação da camada de saída (FAS), atraso da entrada, RMSE(3), desvio padrão e média do erro das RNAs utilizadas para previsão três passos à frente das séries do PLD no sub-mercado Sudeste/Centro-oeste, por meio da previsão direta.

Série Temporal	N1	N2	NS	FA1	FA2	FAS	Atraso da entrada	RMSE(i)	Desvio Padrão	Média do erro
1	5	2	1	tanH	tanH	linear	3	0,8972	90,3421	7,8684
2	6	2	1	tanH	tanH	linear	2	0,9519	95,9	7,8621

As figuras 32 e 34 mostram as previsões realizadas para a série temporal do PLD utilizando as configurações 1 e 2, mostradas na Tabela 3, respectivamente. Pode-se observar que, em ambos os gráficos, os valores previstos tendem a seguir os valores reais da série temporal.

As figuras 33 e 35 mostram os gráficos de resíduo referentes às configurações 1 e 2, mostradas na Tabela 3, respectivamente. Pode-se ver, nesses gráficos, que os resíduos entre as séries previstas e as séries reais apresentam comportamentos quase aleatórios e parecidos entre si.

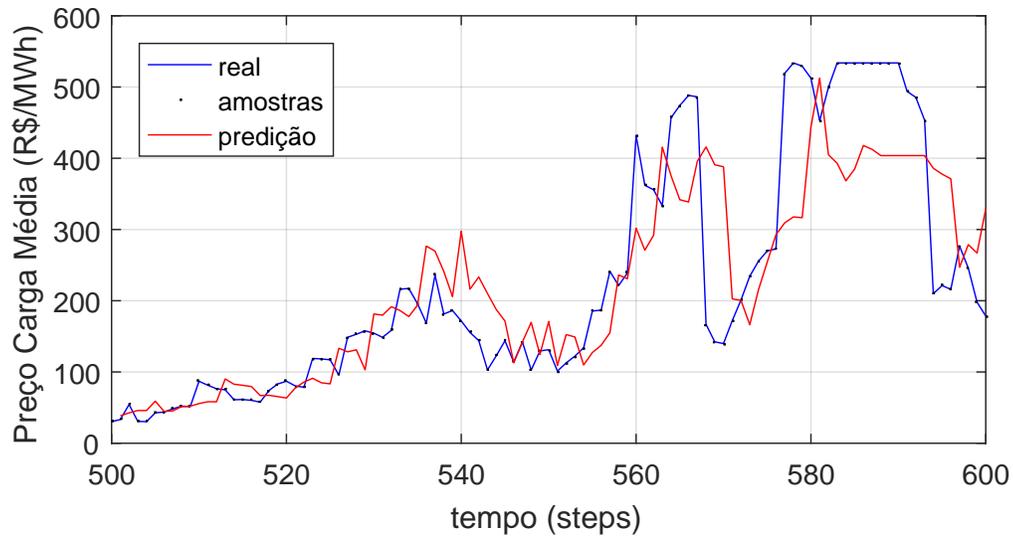


Figura 32 – Previsão três passos a frente realizada para a série temporal PLD utilizando a rede NARNET 1 (11 de fevereiro de 2016 à 1º de janeiro de 2018).

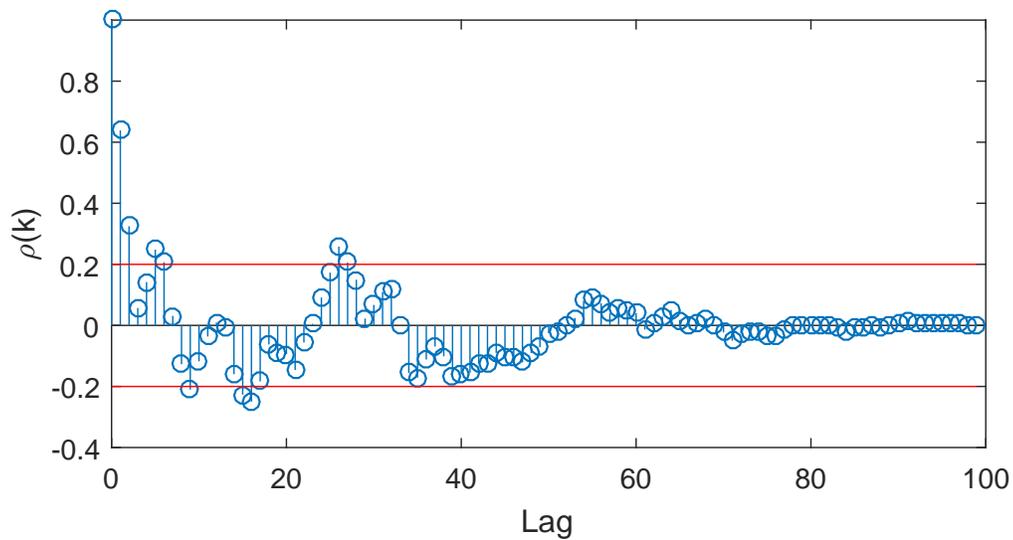


Figura 33 – Autocorrelação do resíduo da previsão da série temporal PLD por meio da previsão direta com a rede NARNET 1.

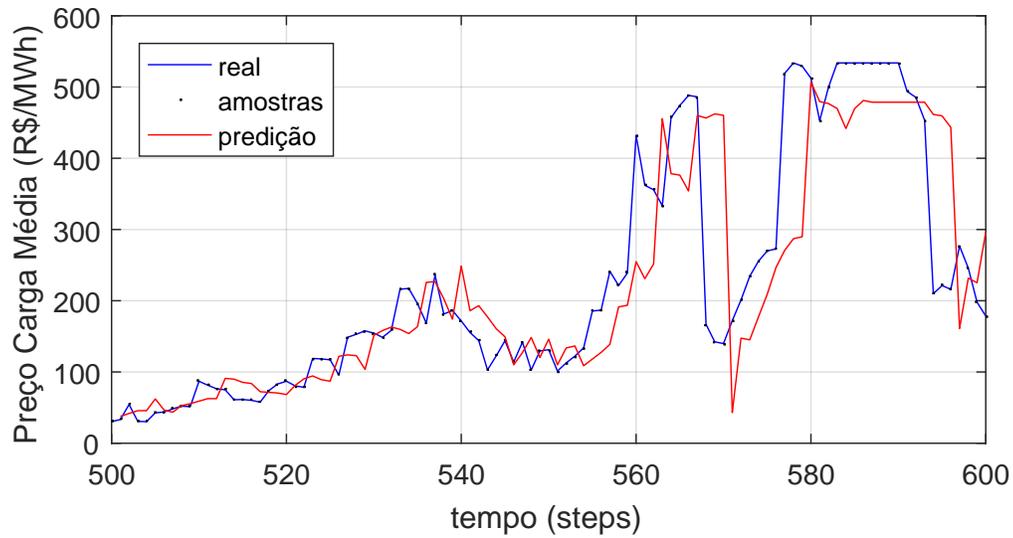


Figura 34 – Previsão três passos a frente realizada para a série temporal PLD utilizando a rede NARNET 2 (11 de fevereiro de 2016 à 1º de janeiro de 2018).

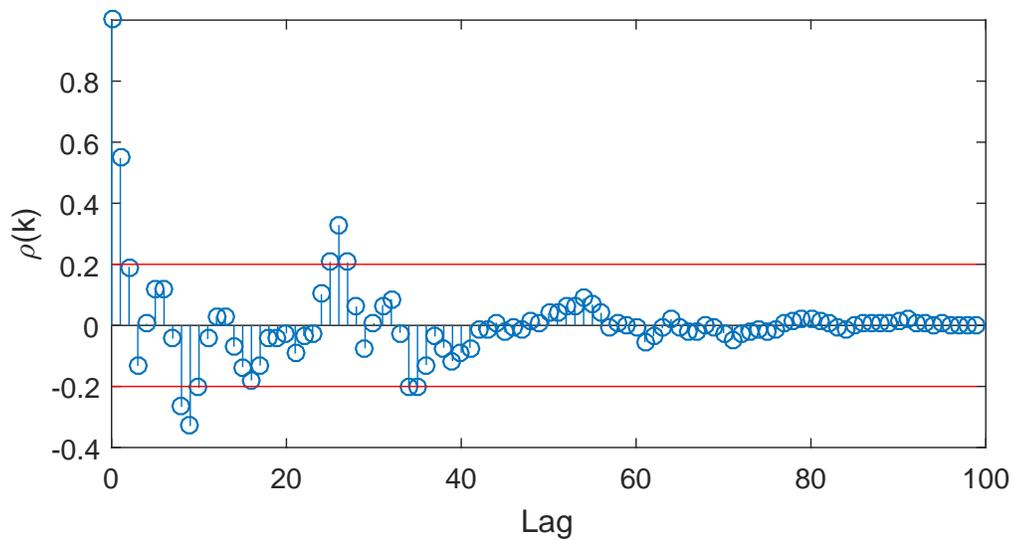


Figura 35 – Autocorrelação do resíduo da previsão da série temporal PLD por meio da previsão direta com a rede NARNET 2.

5 CONCLUSÃO

Ao longo dos anos, o número de consumidores livres aumentou consideravelmente no Brasil, a economia brasileira experimentou um crescimento expressivo e, como consequência, a relação entre demanda e oferta de energia elétrica ficou muito próxima. Esse crescimento implicou em uma considerável volatilidade e imprevisibilidade do preço de liquidação das diferenças, que, por sua vez, criou mais incertezas e mais riscos no mercado a curto prazo.

Fatores como energia armazenada nos reservatórios, quantidade de geração hidrelétrica e termelétrica e a carga do sistema impactam o preço da energia no Brasil. Desse modo, o conhecimento da dinâmica desses fatores pode auxiliar na previsão do preço.

Neste trabalho foi apresentada a aplicação de redes neurais artificiais na previsão do preço de energia elétrica no mercado livre utilizando duas abordagens diferentes. A primeira verifica a previsão do preço da energia elétrica realizando, primeiramente, a previsão dos fatores principais que afetam o seu valor, enquanto a segunda verifica a eficiência da previsão da série temporal do preço. Os resultados obtidos por meio das duas abordagens são semelhantes e incentivam a contínua pesquisa em busca de modelos mais exatos.

Para trabalhos futuros, recomenda-se a continuidade da pesquisa explorando outras variáveis que afetam o preço de energia no mercado livre, sejam fatores naturais como a energia afluyente nos reservatórios ou fatores de conjuntura econômica do país. Recomenda-se também o estudo de outras estruturas de preditores como RNAs NARX ou modelos híbridos de filtro ARIMA e RNA.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABRACEEL. *CARTILHA MERCADO LIVRE DE ENERGIA ELÉTRICA - Um guia básico para consumidores potencialmente livres e especiais*. 2018. Disponível em: <http://www.abraceel.com.br/archives/files/Abraceel_Cartilha_MercadoLivre_V9.pdf>. Acesso em: 22 de maio de 2018.
- ABRADEE. *Visão Geral do Setor*. 2018. Disponível em: <<http://www.abradee.com.br/setor-eletrico/visao-geral-do-setor>>. Acesso em: 16 de maio de 2018.
- AGUIRRE, L. *Introdução à identificação de sistemas: Técnicas lineares e não lineares: Teoria e aplicação*. [S.l.: s.n.], 2015.
- BOX, G. E. et al. *Time series analysis: forecasting and control*. [S.l.]: John Wiley & Sons, 2015.
- CASTRO, N.; LEITE, A. Preço spot de eletricidade: teoria e evidências do caso brasileiro. *IV Encontro de Economia Catarinense*, 2010.
- CCEE. *Com quem se relaciona*. 2018. Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/onde-atuamos/com_quem_se_relaciona?_afzLoop=236477610790616&_adf.ctrl-state=j74vz71p5_1#!%40%40%3F_afzLoop%3D236477610790616%26_adf.ctrl-state%3Dj74vz71p5_5n>. Acesso em: 14 de maio de 2018.
- CCEE. *Metodologia de Preços*. 2018. Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/como_ccee_atua/precos/metodologia_de_precos?_afzLoop=8174115312581&_adf.ctrl-state=ui7qcaz12_1#!%40%40%3F_afzLoop%3D8174115312581%26_adf.ctrl-state%3Dui7qcaz12_5f>. Acesso em: 26 de maio de 2018.
- CHATFIELD, C. *The analysis of time series: an introduction*. [S.l.]: CRC press, 2016.
- CPFL. *Mercado Livre*. 2018. Disponível em: <<https://www.cpfl.com.br/unidades-de-negocios/comercializacao/cpfl-brasil/mercado-livre/Paginas/quem-pode-participar.aspx>>. Acesso em: 20 de junho de 2018.
- DEMUTH, H. B. et al. *Neural Network Design*. [S.l.]: Martin Hagan, 2014.
- FAN, N. et al. Wheel wear prediction of high-speed train using nar and bp neural networks. In: *IEEE. Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData), 2017 IEEE International Conference on*. [S.l.], 2017. p. 126–130.
- FILHO, J. C. R.; AFFONSO, C. d. M.; OLIVEIRA, R. C. de. Energy price prediction multi-step ahead using hybrid model in the brazilian market. *Electric Power Systems Research*, Elsevier, v. 117, p. 115–122, 2014.
- FILHO, J. C. R.; AFFONSO, C. M.; OLIVEIRA, R. C. L. Pricing analysis in the brazilian energy market: A decision tree approach. In: *2009 IEEE Bucharest PowerTech*. [S.l.: s.n.], 2009. p. 1–6.

- GOOIJER, J. G. D. et al. *Elements of Nonlinear Time Series Analysis and Forecasting*. [S.l.]: Springer, 2017.
- HAYKIN, S. S. et al. *Neural networks and learning machines*. [S.l.]: Pearson Upper Saddle River, NJ, USA:, 2009. v. 3.
- HEBB, D. O. *The organization of behavior: A neuropsychological theory*. [S.l.]: New York: Wiley, 1949.
- HERCULANO-HOUZEL, S. *The Human Brain in Numbers: A Linearly Scaled-up Primate Brain*. 2009. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC2776484/>>. Acesso em: 20 de junho de 2018.
- HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, National Acad Sciences, v. 79, n. 8, p. 2554–2558, 1982.
- IBRAHIM, M. et al. Nonlinear autoregressive neural network in an energy management strategy for battery/ultra-capacitor hybrid electrical vehicles. *Electric Power Systems Research*, Elsevier, v. 136, p. 262–269, 2016.
- IRWIN, J. D.; WILAMOWSKI, B. M. *Intelligent systems*. [S.l.]: CRC Press, 2016.
- JAMES, L. M.; RUMELHART, D. E. *Parallel distributed processing: Explorations in the microstructure of cognition: Vol. 1*. [S.l.]: Foundations. Cambridge, MA: MIT Press, 1986.
- KUO, H.-H. *White noise distribution theory*. [S.l.]: CRC press, 1996. v. 5.
- LEITE, A. L. da S.; CASTRO, N. J. de; TIMPONI, R. R. Causas da volatilidade do preço "spot" de eletricidade no brasil. *Ensaio FEE*, v. 34, n. 2, 2013.
- MARTINS-FILHO, L. S.; MOL, A. A.; ROCHA, R. Desenvolvimento de ferramenta computacional para auxílio ao projeto de gemas lapidadas. *Rem: Revista Escola de Minas*, SciELO Brasil, v. 58, n. 4, p. 367–373, 2005.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943.
- MIGUEZ, G. A. *Otimização do Algoritmo de Backpropagation Pelo Uso da Função de Ativação Bi-Hiperbólica*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2012.
- MINITAB. *Detecção de autocorrelação em resíduos*. 2018. Disponível em: <<https://support.minitab.com/pt-br/minitab/18/help-and-how-to/modeling-statistics/regression/supporting-topics/residuals-and-residual-plots/detect-autocorrelation-in-residuals/>>. Acesso em: 31 de maio de 2018.
- MINSKI, M. L.; PAPERT, S. A. *Perceptrons: an introduction to computational geometry*. [S.l.: s.n.], 1969.
- MONTGOMERY, D. C.; RUNGER, G. C. *Applied statistics and probability for engineers*. [S.l.]: John Wiley & Sons, 2010.

- MORETTIN, P. A.; TOLOI, C. *Análise de séries temporais*. [S.l.: s.n.], 2006.
- ONS. *Mapas do SIN*. 2017. Disponível em: <<http://ons.org.br/pt/paginas/sobre-o-sin/mapas>>. Acesso em: 14 de maio de 2018.
- ONS. *O SISTEMA INTERLIGADO NACIONAL*. 2018. Disponível em: <<http://ons.org.br/pt/paginas/sobre-o-sin/o-que-e-o-sin>>. Acesso em: 14 de maio de 2018.
- PEN. *O SISTEMA EM NÚMEROS*. 2017. Disponível em: <<http://ons.org.br/paginas/sobre-o-sin/o-sistema-em-numeros>>. Acesso em: 14 de maio de 2018.
- POLLOCK, D. The methods of time-series analysis. *Interdisciplinary Science Reviews*, Taylor & Francis, v. 12, n. 2, p. 128–135, 1987.
- QBI. *What is a neuron?* 2018. Disponível em: <<https://qbi.uq.edu.au/brain/brain-anatomy/what-neuron>>. Acesso em: 20 de junho de 2018.
- QUEIROZ, A. R. de. *Simulação de custos marginais em mercado de energia elétrica utilizando redes neurais*. Dissertação (Mestrado) — Universidade de São Paulo, 2007.
- RAMOS, T. P. et al. Modelo para o despacho de usinas individualizadas no planejamento hidrotérmico de médio prazo baseado em pnl. *Sba: Controle e Automação Sociedade Brasileira de Automatica*, v. 23, p. 594–607, 2012.
- REIS, B. *Redes Neurais – Funções De Ativação*. 2016. Disponível em: <<http://www.decom.ufop.br/imobilis/redes-neurais-funcoes-de-ativacao/>>. Acesso em: 28 de maio de 2018.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958.
- SCARGLE, J. D. Studies in astronomical time series analysis. iii-fourier transforms, autocorrelation functions, and cross-correlation functions of unevenly spaced data. *The Astrophysical Journal*, v. 343, p. 874–887, 1989.
- SILVA, B. G. d. *Evolução do setor elétrico brasileiro no contexto econômico nacional: uma análise histórica e econométrica de longo prazo*. 2011. 162 f. Dissertação (Mestrado) — Dissertação (Mestrado em Ciências/Energia). Universidade de São Paulo, São Paulo, 2015.
- SILVA, D. R. C. *Redes neurais artificiais no ambiente de redes industriais foundation fieldbus usando blocos funcionais padrões*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2005.
- SILVA, I. N. D. et al. *Artificial Neural Networks*. [S.l.]: Springer, 2017.
- ŠTENCL, M. et al. Forecast of consumer behaviour based on neural networks models comparison. *Acta Universitatis Agriculturae et Silviculturae Mendelianae Brunensis*, Mendel University Press, v. 60, n. 2, p. 437–442, 2013.
- TOLMASQUIM, M. T. *Novo modelo do setor elétrico brasileiro*. [S.l.]: Synergia, 2011.

USP, I. *Redes Neurais Artificiais*. 2018. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/>>. Acesso em: 27 de maio de 2018.

WIDROW, B.; HOFF, M. E. *Adaptive switching circuits*. [S.l.], 1960.



ANEXO X - TERMO DE RESPONSABILIDADE

O texto do trabalho de conclusão de curso intitulado "PREVISÃO DO PREÇO DE LIQUIDAÇÃO DAS DIFERENÇAS POR MEIO DE REDES NEURAIS ARTIFICIAIS" é de minha inteira responsabilidade. Declaro que não há utilização indevida de texto, material fotográfico ou qualquer outro material pertencente a terceiros sem a devida citação ou consentimento dos referidos autores.

João Monlevade, 09 de julho de 2018.

Alon Patric Souza Silva
Nome completo do(a) aluno(a)



ANEXO XI - DECLARAÇÃO DE CONFERÊNCIA DA VERSÃO FINAL

Declaro que conferi a versão final a ser entregue pelo aluno

Alan Patrick Souza Silva, autor do trabalho de conclusão de curso intitulado Processo do peso de liquidação das diferenças por meio de quanto à conformidade nos seguintes itens:

redes neurais artificiais

1. A monografia corresponde a versão final, estando de acordo com as sugestões e correções sugeridas pela banca e seguindo as normas ABNT;
2. A versão final da monografia inclui a ata de defesa (ANEXO IV - apenas verso), a ficha catalográfica e o termo de responsabilidade (ANEXO X -) devidamente assinados.

João Monlevade, 06 de Setembro de 2018.

Victor Costa da Silva Campos

Nome do(a) Professor(a)

VICTOR COSTA DA SILVA CAMPOS