

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ENGENHARIA
ENGENHARIA ELÉTRICA ROBÓTICA E AUTOMAÇÃO INDUSTRIAL

Michele Goliath Martins de Araujo

**REDES NEURAS ARTIFICIAIS APLICADAS À PREDIÇÃO DO PREÇO DE
LIQUIDAÇÃO DAS DIFERENÇAS NO MERCADO DE ENERGIA**

Juiz de Fora
2018

Michele Goliath Martins de Araujo

**REDES NEURAIAS ARTIFICIAIS APLICADAS À PREDIÇÃO DO PREÇO DE
LIQUIDAÇÃO DAS DIFERENÇAS NO MERCADO DE ENERGIA**

Dissertação apresentada ao Programa de
graduação em Engenharia Elétrica, da
Universidade Federal de Juiz de Fora
como requisito parcial a obtenção do grau
de Engenheira Eletricista.

Orientador: Leonardo Rocha Olivi
Coorientador: Luís Henrique Lopes Lima

**Juiz de Fora
2018**

Michele Goliath Martins de Araujo

**REDES NEURAS ARTIFICIAIS APLICADAS À PREDIÇÃO DO PREÇO DE
LIQUIDAÇÃO DAS DIFERENÇAS NO MERCADO DE ENERGIA**

Dissertação apresentada ao Programa de graduação em Engenharia Elétrica, da Universidade Federal de Juiz de Fora como requisito parcial a obtenção do grau de Engenheira Eletricista.

BANCA EXAMINADORA

Professor Dr. Leonardo Rocha Olivi - Orientador
Universidade Federal de Juiz de Fora

Professor Dr. Luís Henrique Lopes Lima – Coorientador
Universidade Federal de Juiz de Fora

Professor Dr. Exuperry Barros Costa
Universidade Federal de Juiz de Fora

Dedico este trabalho às pessoas que amo.

AGRADECIMENTOS

Agradeço primeiramente à Deus, que sem ele nada disso seria possível. Graças à Ele sempre tive a certeza que não estava sozinha nesta jornada. Aos meus pais Margareth e André pela motivação, exemplo, palavras sempre amigas e o apoio incondicional. Amo vocês.

Aos meus familiares que sempre torceram por mim. Ao meu namorado Yago, pelo amor, apoio, paciência e motivação durante esta trajetória.

Agradeço também, ao meu orientador Leonardo Olivi, por me acolher, orientar com excelência e por tornar tudo isso possível. Obrigada pelas palavras amigas, pelos ensinamentos, e por ser exemplo de professor e profissional.

Ao meu coorientador Luís Henrique pelos ensinamentos e grande contribuição, sempre disposto e acessível para sanar as dúvidas.

Aos demais professores da UFJF, pela contribuição para minha formação acadêmica.

Aos meus amigos de sala de aula: vocês foram essenciais. Obrigada por estarem comigo nos momentos de dificuldade, e estenderem a mão nos momentos que mais precisei.

Agradeço a todos os amigos, que nas limitadas oportunidades de reencontros nesses últimos anos, foram essenciais para que eu mantivesse o equilíbrio nos momentos de dificuldades. Em especial, agradeço a minha amiga Haila, minha eterna gratidão por ajudar a tornar este trabalho possível.

Por fim, agradeço, aos amigos da Automateasy e ArcelorMittal Juiz de Fora pelas sugestões, incentivos, experiências e conhecimentos adquiridos.

Ninguém vence sozinho. Muito obrigada a todos!

“A persistência é o caminho do êxito”
Charles Chaplin

RESUMO

A diferença entre contratação e consumo é contabilizada pela CCEE mensalmente e negociada no mercado de curto prazo. Por meio do preço de liquidação das diferenças é promovida a liquidação dessa energia, que pode acarretar lucro ou penalidades. Este trabalho consiste no desenvolvimento de modelo aplicado à predição do Preço das Liquidação das Diferenças (PLD) no Mercado de Curto Prazo (MCP). Foi utilizado para o desenvolvimento deste trabalho Redes Neurais Artificiais (RNA) com método de Levenberg-Marquardt associado ao termo momentum com atraso no tempo. Como variáveis de entrada foi utilizado PLD e seu histórico, Energia Natural Afluenta por Subsistema (ENA), Intercâmbio de Energia (IE) e Energia Armazenada. Como saída, obtêm-se o PLD, sendo uma ferramenta de grande importância na comercialização de energia elétrica.

Palavras-chave: preço liquidação das diferenças, mercado de curto prazo, redes neurais artificiais, Levenberg-Marquardt e comercialização de energia.

ABSTRACT

The difference between contracting and consumption is accounted for by CCEE on a monthly basis and traded on the short-term market. By means of the settlement price of the differences the liquidation of this energy is promoted, which may lead to profit or penalties. This work consists of the development of a model applied to the prediction of the Price of Settlement of Differences (PLD) in the Short-Term Market (MCP). It was used for the development of this work Artificial Neural Networks (RNA) with Levenberg-Marquardt method associated with the term momentum with delay in time. As input variables was used PLD and its history, Subsurface Natural Energy Subsystem (ENA), Energy Exchange (IE) and Stored Energy. As an output, the PLD is obtained, being a tool of great importance in the commercialization of electric energy.

Key words: price settlement of differences, short-term market, artificial neural networks, Levenberg-Marquardt and energy commercialization.

LISTA DE FIGURAS

Figura 1 - Volatilidade Mensal do PLD	14
Figura 2- Esquema de um neurônio biológico.....	19
Figura 3 - Modelo neurônio artificial	20
Figura 4 -Função Logística sigmóide padrão	21
Figura 5- Exemplo de uma rede feedforward de camadas múltiplas.	24
Figura 6- Erro Quadrático Médio (EQM).....	26
Figura 7 - Evolução Sistema Elétrico Brasileiro.	32
Figura 8 - Principais agentes direcionadores do setor elétrico	34
Figura 9 - Representação do montante do mercado spot obtido através da diferença energia contratada e a energia verificada.	40
Figura 10 - Carga, em MW médio, e potência instalada, em MW, dos subsistemas do SIN, em 2008.	43
Figura 11 - Processo de treinamento utilizando o método inserção termo momentum.	47
Figura 12 - Topologia de uma rede TDNN.	48
Figura 13 - Considerando $rgn = 60$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	53
Figura 14 - Considerando $rgn = 100$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	53
Figura 15 - Considerando $rgn = 800$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	53
Figura 16 - Considerando $Alpha = 0.95$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	54
Figura 17 - Considerando $Alpha = 0.98$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	55
Figura 18 - Considerando $Alpha = 0.957$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	55
Figura 19 - Considerando $N1 = 60$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	56
Figura 20 - Considerando $N1 = 100$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	56
Figura 21 - Considerando $N1 = 95$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	56

Figura 22 - Considerando atraso = 20, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	57
Figura 23 - Considerando atraso = 30, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	58
Figura 24 - Considerando atraso = 35, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	58
Figura 25 - Considerando Lambda 1e-2, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	59
Figura 26 - Considerando Lambda 1e-3, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	59
Figura 27 - Considerando Lambda 1e-4, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.	59
Figura 28 - A esquerda encontra-se valores previstos e a direita o EQM.	60
Figura 29- Primeiro gráfico : Resultado esperado vs obtido e o segundo gráfico EQM ao passar do tempo.	61
Figura 30 - Figura à esquerda em preto o que é desejado e em vermelho o que é previsto para o PLD. Já na figura à direita o EQM.	63

LISTA DE ABREVIATURAS E SIGLAS

PLD: Preço Liquidação das diferenças
RNA: Redes Neurais Artificiais
ARIMA: Autoregressive Integrated Moving Average
RNF: Rede Neuro Fuzzy
MPE: Mean Percentual Error
MAPE: Mean Absolute Percentual Error
RMSE: Rooted Mean Squared Error
EQM: Erro Quadrático Médio
MPA: BackPropagation
CCEE: Câmara de Comercialização de Energia Elétrica
ANEEL: Agência Nacional Energia Elétrica
SIN: Sistema Interligado Nacional
UHE: Usina Hidrelétrica
RESEB: Reestruturação do Sistema Elétrico Brasileiro
MP: Medida Provisória
CNPE: Conselho Nacional de Política Energética
MME: Ministério de Minas e Energia
DNAEE: Departamento Nacional de Águas e Energia Elétrica
EPE: Empresa de Pesquisa Energética
CMSE: Comitê de Monitoramento do Setor Elétrico
ONS: Operador Nacional do Sistema Elétrico
SEB: Sistema Elétrico Brasileiro
ACR: Ambiente de Contratação Regulado
ACL: Ambiente de Contratação Livre
UTE: Usina Termelétrica
CMO: Custo Marginal de Operação
MCP: Mercado de Curto Prazo
PCH: Hidrelétricas de Pequeno Porte
ENASub: Energia Natural Afluente por subsistema
IE: Intercâmbio de Energia
EA: Energia Armazenada

SUMÁRIO

1. INTRODUÇÃO	13
2. REVISÃO BIBLIOGRÁFICA	16
2.1 Estudos Relacionados	16
2.2 Redes Neurais Artificiais.....	17
2.3 Neurônio Biológico	18
2.4 Neurônio Artificial	19
2.5 Redes Perceptron Multicamadas	22
2.6 Sistema elétrico brasileiro	28
2.7 Evolução do setor elétrico brasileiro	29
2.8 Mercado em curto prazo	32
2.9 A comercialização de energia elétrica	33
2.10 Agentes direcionantes e suas atribuições.....	34
2.11 Ministério de Minas e Energia (MME)	35
2.12 Agência Nacional de Energia Elétrica (ANEEL)	35
2.13 Conselho Nacional de Política Energética (CNPE).....	36
2.14 Comitê de Monitoramento do Setor Elétrico (CMSE)	37
2.15 Empresa de Pesquisa Energética (EPE).....	38
2.16 Câmara de Comercialização de Energia Elétrica (CCEE).....	39
2.17 Operador Nacional do Sistema Elétrico (ONS).....	39
2.18 Comercialização Energia Elétrica	39
2.19 Leilões de Energia	40
2.20 Ambientes e Contratação	40
2.21 Sistema Elétrico Nacional (SIN)	41
2.22 Preço Liquidação de Diferenças (PLD).....	43
3. METODOLOGIA.....	45
3.1 Método da inserção do termo de momentum	46
3.2 Redes Time Delay Neural Network (TDNN).....	47
3.3 Método Levenberg- Marquardt (LM).....	49

4. RESULTADOS	52
4.1 SIMULAÇÃO COM VALORES DE SEMENTE IGUAIS PARA O GERADOR DE NÚMEROS ALEATÓRIOS (RNG)	52
4.2 SIMULAÇÃO COM VALORES DE ALPHA OU MOMENTUM.....	54
4.3 SIMULAÇÃO COM VALORES DO NÚMERO DE NEURÔNIOS CAMADA ESCONDIDA (N1)	55
4.4 SIMULAÇÃO COM VALORES DO NÚMERO DE ATRASO (ATRASO)	57
4.5 SIMULAÇÃO COM VALORES DO NÚMERO LAMBDA	58
4.6 ABORDAGEM 1.....	60
4.7 ABORDAGEM 2.....	61
4.8 ABORDAGEM 3.....	62
4.9 MELHOR ABORDAGEM.....	62
5. CONCLUSÕES E TRABALHOS FUTUROS	64
REFERÊNCIAS BIBLIOGRÁFICAS	65

1. INTRODUÇÃO

A energia elétrica é a principal fonte de energia do mundo, sendo de extrema importância na indústria mundial, seu valor gera impacto a todos. No Brasil, por se tratar de uma geração predominantemente hidráulica, os preços de energia elétrica sofrem influência de fatores naturais, como estes recursos variam ao longo do ano, é de vital importância à previsão de preços a fim de obter segurança e lucros na comercialização de energia elétrica.

O preço das Liquidações da Diferenças (PLD) é usado para valorar as diferenças de energia apuradas no Mercado de Curto Prazo (MCP). Utiliza-se o PLD para precificar cada montante de energia diferente do que foi estabelecido no contrato. Como o seu preço depende de recursos naturais, o PLD possui grande volatilidade ao longo do ano. Para conseguir prever de maneira eficaz, foi utilizado Redes Neurais Artificiais, um método não linear altamente robusto e preciso.

O Preço de Liquidação das diferenças (PLD) é definido semanalmente para cada um dos subsistemas brasileiros sendo estes Sudeste/ Centro-Oeste (SE-CO), Sul (S), Nordeste (NE) e Norte (N) e para cada patamar de carga que dependem do horário em que a energia é utilizada e demandada, podendo ser, leve, médio e pesado. Sua base é o Custo Marginal de Operação (CMO) do sistema, sendo este referenciado entre um valor máximo e mínimo. Sendo a análise do melhor arranjo das usinas disponíveis para que se tenha menor custo de operação desde que a demanda de energia elétrica seja totalmente suprida. Existindo um CMO para cada submercado (CCEE, 2011).

Com as recentes reformas do Setor Elétrico, o preço da energia elétrica passou a ser calculado por programas computacionais que fornecem o valor do Custo Marginal de Operação (CMO). O CMO é calculado pelo Operador Nacional do Sistema Elétrico (ONS) com base nos modelos computacionais NEWAVE e DECOMP. Estes modelos têm por objetivo definir a geração hidráulica e térmica que se baseiam em parâmetros como condições hidrológicas, demanda de energia, preços de combustível, custo do déficit, entrada de novos projetos e disponibilidade de equipamentos de geração e transmissão para cada um dos submercados e para cada patamar de carga. (ONS, 2016).

O objetivo deste trabalho é a predição do Preço da Liquidação das Diferenças (PLD) uma semana à frente. Para isso, foi utilizado a abordagem de Redes Neurais Artificiais, sendo

a metodologia abordada nesse trabalho Levenberg- Marquardt associado ao termo momentum com atraso na rede.

A predição do PLD é de importante conhecimento para o setor industrial e comercial, pois é uma decisão estratégica o momento de compra de energia, especialmente pela grande variabilidade que está sujeito. Um exemplo de alta volatilidade do PLD é observado na Figura 1 no período de janeiro de 2006 a janeiro de 2011, com a alta do preço do PLD, e grande variação entre os períodos.

Figura 1 - Volatilidade Mensal do PLD



Fonte: (ANEEL, 2011)

Uma distinção inicial pode ser feita em relação ao ambiente de comercialização. No novo modelo, a contratação de energia pode ser feita no Ambiente de Contratação Regulada (ACR) e no Ambiente de Contratação Livre (ACL). No ACR, os consumidores ditos cativos são aqueles atendidos pela distribuidora da área de concessão em que está localizado, exemplo disso são as residências, lojas e pequenas indústrias partilhando contratos de adesão com o distribuidor que opera na região, mas não podem negociar as cláusulas de contrato.

Os consumidores ditos livres, por sua vez, operam no ACL possuem a liberdade de escolher o seu fornecedor de energia. Esta liberdade de fornecedor não tem limitação física, ou seja, podendo escolher qualquer fornecedor de energia presente no Sistema Interligado Nacional (SIN), negociar preços e condições contratuais.

Em sua extensão estão inseridas usinas hidráulicas e térmicas, interligadas por linhas de transmissão. Esta característica da malha brasileira ser interligada permite aos agentes comercializar energia livremente entre si, independente das usinas e das cargas. Embora praticamente todo o território brasileiro esteja conectado pelo SIN é importante ressaltar que existem Estados que ainda estão em processo de interligação. A esta região denominamos de sistema isolado, sendo composto predominantemente, pela região norte do país, onde existe restrições e impactos ambientais sendo o maior desafio para integração do SIN.

Assim o PLD é um importante instrumento de orientação dos agentes do mercado de energia elétrica, pois pode afetá-los financeiramente. Distribuidores e Comercializadores ficam expostos ao PLD por não terem contratado energia suficiente para seu suprimento; por outro lado, geradores que tenham contratado maior suprimento de energia do que conseguem fornecer. Nestas situações ficam expostos ao Mercado de Curto Prazo (MCP) (CCEE, 2017).

A responsabilidade de manter os registros de contratos do ambiente de contratação regulada (ACR) e no ambiente de contratação livre (ACL), como também de realizar a medição dos montantes de energia gerada e consumida e apurar e divulgar o PLD são responsabilidades da Câmara de Comercialização de Energia Elétrica (CCEE) (CCEE, 2017).

Em termos mundiais, os intervalos limitadores dos preços de curto prazo são adotados como contramedida ao poder mercadológico das ofertas, que, em períodos de escassez podem se apropriar de forma agressiva da riqueza produzida pelo mercado. Entretanto, numa precificação como a do mercado brasileiro, que é calculada por modelos computacionais, o limite máximo representa um mitigador aos altos sinais do custo marginal de operação, e a diferença é custeada pelo poder público. Isto pode acontecer, dado que a elasticidade da oferta e da demanda não é considerada como imediata, mas é inegável que ela existe (CCEE, 2017).

Para os dados do PLD extraídos do site da CCEE foi considerado a semana operativa começa no sábado 00:00h e termina na sexta às 24:00h, o PLD vigorará neste intervalo de tempo. O período considerado para este presente trabalho foi de 31/02/2015 à 31/03/2017.

2. REVISÃO BIBLIOGRÁFICA

2.1 Estudos Relacionados

O uso de métodos e modelos matemáticos como forma de antever as possíveis movimentações do mercado financeiro não é uma prática nova. Nas últimas décadas, essa foi uma área de grande interesse para a comunidade de Inteligência Artificial (KIMOTO, 1990; STEINER, 1995; LAWRENCE, 1997; CERETTA et al., 2010).

No trabalho de Campos (2008) foi utilizado a previsão de demanda abordando técnicas de inteligência computacional: ARIMA, NARIMA, Rede Neuro-Fuzzy (RNF) e RNA. Além disso, comparou os resultados por meio dos índices de desempenho Mean Percentual Error (MPE), Mean Absolute Percentual Error (MAPE) e Rooted Mean Squared Error (RMSE).

Mendonça (2008) aborda o problema de contratação de energia elétrica em curto e longo prazo utilizando Redes Neurais Artificiais. Seu estudo está baseado na projeção de 5 anos propondo que a otimização na contratação de energia seja feita como uma estratégia da distribuidora, dentro dos seus limites regulatórios, já que o mercado apresenta desvios.

Pessanha (2007) afirma que para se obter um melhor resultado na contratação de energia deve ser combinado métodos de otimização e simulação. Foi utilizado o método *Sample Path Optimization* ou *Sample Average Approximation* para simular e obter a função objetivo e otimizou os resultados com o algoritmo genético *Riskoptimizer* da *Palisade Corporation*.

Vahidinasab et al. (2008) apresentou técnicas para previsão de preços futuros no mercado de energia elétrica e concluiu que as Redes Neurais Artificiais fornecia um melhor resultado quando comparada por exemplo ao ARIMA pois este não consegue tratar com as não linearidades. Utilizou série histórica de preços com uma camada escondida de dezoito neurônios, função de ativação sigmóide e uma saída com função de ativação linear.

Amjady e Daraeepour (2008) fazem uma combinação de técnicas de RNA para previsão de preços de energia elétrica. Utilizam série histórica de preços apresentando periodicidade horária com previsão para as próximas 24 horas com o método *Relief Function*. E os compara com alguns métodos recentes de previsão de preços.

2.2 Redes Neurais Artificiais

Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no funcionamento do cérebro humano, sendo baseados em seu mecanismo de memorização e aprendizado (AGHBASHLO et al., 2012; MOHANRAJ; JAYARAJ; MURALEEDHARAN, 2012). São abordagens de aprendizado e armazenamento de conhecimentos inspirados nas conexões cerebrais, chamadas sinapses.

Para entender o funcionamento básico de uma rede neural, é necessário compreender, antes, o funcionamento do cérebro humano e seus componentes, pois uma rede neural artificial é um modelo formal para representar o neurônio biológico (JUDD, 1990). Assim, percebendo esse funcionamento e baseado nos principais componentes de um neurônio biológico, Warren McCulloch, neurofisiologista, e Walter Pitts, matemático, de forma simples, desenvolveram o neurônio matemático, representando-o por meio de uma regra de propagação e uma função de ativação (VALENÇA, 2009). Eles combinaram os conceitos trazidos pela Neurofisiologia, como o processo de aprendizagem de um neurônio biológico, e pela Matemática, como pesos e limiares, para desenvolver o neurônio artificial (MACCULLOCH; PITTS, 1943).

A ideia de criação da RNA surgiu antes dos computadores eletrônicos, há quase 60 anos, evoluiu passando por um período de entusiasmo no início dos anos 1960 (ROSENBLATT, 1958). Esta sobrevivência foi em parte devida aos avanços dos computadores eletrônicos, que se tornaram mais baratos e mais rápidos, e às novas soluções propostas por alguns pioneiros (HOPFIELD, 1982 e KOHONEN, 1982).

A motivação original da metodologia foi a tentativa de modelar a rede de neurônios de forma a compreender o funcionamento do cérebro humano de forma a realizar atividades complexas como reconhecimento de padrões, percepção através da simulação do seu funcionamento. As RNAs possuem em comum com o cérebro humano dois aspectos: extrair conhecimento do ambiente através do processo de aprendizagem ou treinamento, e os pesos das conexões entre os neurônios, que são os pesos sinápticos são utilizados para armazenar o conhecimento adquirido.

As Redes Neurais Artificiais têm como potenciais áreas de aplicação aproximação de funções, controle de processos, reconhecimento e classificação de padrões, agrupamento de dados e sistemas de previsão. São baseadas na estrutura individual dos nodos, na topologia de suas conexões e no comportamento conjunto e dinâmico destes nodos naturais a estímulos externos. Elas podem ser operadas como um modelo de caixa preta, o qual não requer

informações detalhadas sobre o sistema ou equipamentos em questão (AGHBASHLO et al., 2012).

Esta ferramenta pode aprender a relação entre entradas e saídas com base nos dados de treinamento, sendo, portanto, amplamente utilizada para modelagem, previsão e classificação, por possibilitar a identificação de relações presentes em fontes de dados limitados, incompletos, com ruídos, dinâmicos e não lineares. Assim, a habilidade da RNA de aprender e generalizar o comportamento de qualquer processo complexo e não linear a torna uma poderosa ferramenta de modelagem (AGHBASHLO et al., 2012; MOHANRAJ; JAYARAJ; MURALEEDHARAN, 2012; YOUSSEFI; EMAMDJOMEH; MOUSAVI, 2009).

2.3 Neurônio Biológico

O cérebro humano é composto de bilhões de neurônios altamente interligados que, juntos, formam um sistema complexo denominada rede neural. Cada neurônio é uma simples unidade de microprocessamento que recebe e combina os sinais de muitos outros neurônios constituintes da rede neural (BAUGHMAN; LIU, 1995; SILVA; SPATTI; FLAUZINO, 2000).

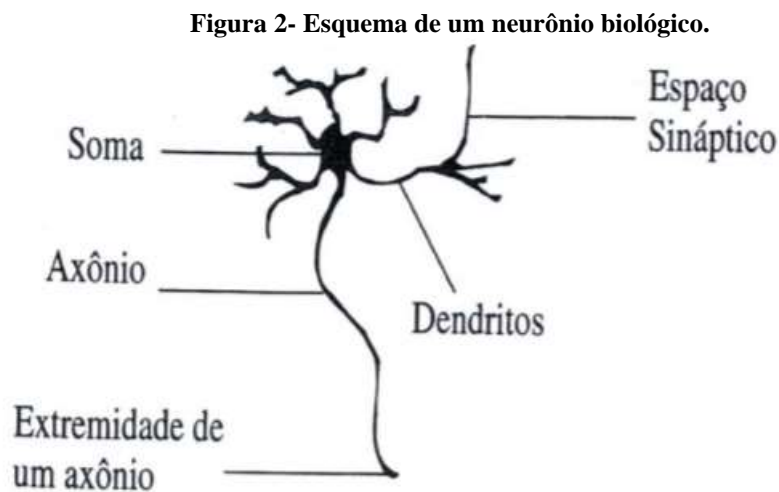
Os neurônios são formados pelo corpo celular ou soma e filamentos que são os dendritos e os axônios, e conectados uns aos outros formando uma grande teia ou rede neural. As sinapses formam as conexões entre os neurônios por meio do axônio (*hillock*) e os dendritos. Elas são formadas por um espaço, entre o terminal de um axônio e o receptor do dendrito, que equivale à cerca de 50 a 200 ângstroms. A resposta de um neurônio ocorre por meio da transferência de impulsos elétricos ou potenciais de ação. A propagação de um neurônio para outro é realizada por meio de substâncias chamadas neurotransmissores (MAREN et al, 1990).

Este contato entre a terminação do axônio de uma célula com o dendrito de outro neurônio é conhecido como sinapse. Tais sinapses funcionam como válvulas capazes de controlar a transmissão dos impulsos entre os nodos da rede neural, pela conversão de sinais elétricos pré-sinápticos em sinal químico e então novamente em sinal elétrico pós-sináptico. A contribuição de todos os nodos pré-sinápticos na polarização do neurônio pós-sináptico irá determinar a geração ou não de um impulso nervoso, possibilitando a maioria das funções realizadas pelo cérebro, como a memorização e o aprendizado (BRAGA; CARVALHO; LUDEMIR, 2000; HAYKIN, 2001).

São células que compõem sistema nervoso tendo a capacidade de estabelecer conexões entre si quando recebem estímulo. Possuem a função básica de receber, processar e enviar

informações. São células onde surgem a concepção, emoções e consciência. O neurônio é composto por corpo celular, axônio e dendritos.

Os dendritos têm como função de receber estímulos vindos de diversos neurônios ou do próprio meio externo. O corpo celular tem papel de processar todas as informações recebidas dos dendritos para saber se ocorrerá o impulso elétrico ao longo do axônio. O axônio é responsável por transferir informações pelo sistema nervoso sendo sua terminação denominada de terminações sinápticas.



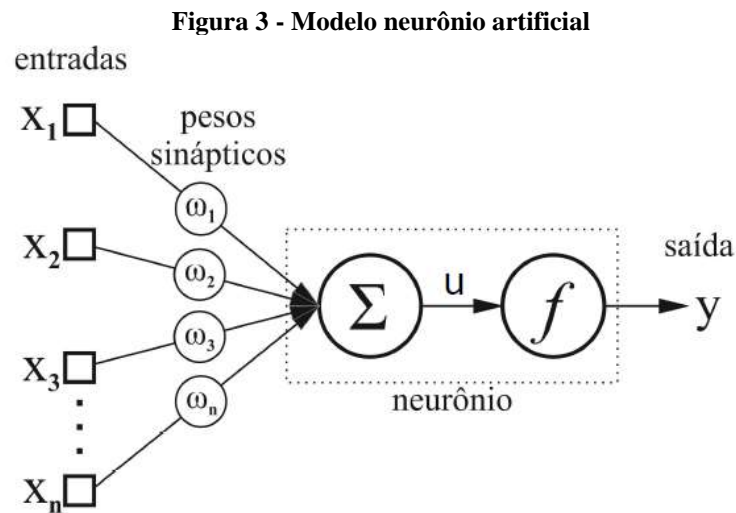
Fonte: Braga, Carvalho e Ludemir (2000).

2.4 Neurônio Artificial

Os neurônios artificiais utilizados nos modelos de redes neurais artificiais são não-lineares, fornecem saídas tipicamente contínuas, e realizam funções simples, como coletar os sinais existentes em suas entradas, agregá-los de acordo com sua função operacional e produzir uma resposta, levando em consideração sua função de ativação existente. (SILVA, SPATTI, FLAUZINO, 2010).

São modelos simplificados dos neurônios biológicos, cada neurônio possui diversos sinais de entrada que são análogos aos impulsos elétricos externos, são normalmente normalizados de acordo com sua função de ativação, que é responsável por limitar a saída do neurônio entre certos valores para que assim possa ativar ou não o neurônio, sendo normalmente não lineares. (SILVA, SPATTI, FLAUZINO, 2010). O modelo do neurônio artificial é mostrado na Figura 3. Os símbolos $\{ x_1, x_2, \dots, x_n \}$ representam os diversos sinais de entrada, e $\{ w_1, w_2, \dots, w_n \}$ são os pesos sinápticos onde mostrarão a relevância de cada entrada possui.

Cada entrada é multiplicada por um peso de conexão (w_n), cujos valores podem ser positivos ou negativos, caso as sinapses sejam excitatórias ou inibitórias respectivamente. Isso permitirá quantificar as suas relevâncias em relação à funcionalidade do respectivo neurônio (BAUGHMAN; LIU, 1995; BRAGA; CARVALHO; LUDEMIR, 2000; SILVA; SPATTI; FLAUZINO, 2000).



Fonte: Autor.

A função soma ou combinador linear (Σ) soma os sinais de entrada, ponderados pelas respectivas sinapses do neurônio, a fim de produzir um valor de potencial ativação, que constitui a diferença do valor produzido entre o combinador linear e o limiar de ativação. O limiar de ativação específica qual será o patamar apropriado para que o potencial de ativação possa gerar um valor de disparo em direção a saída do neurônio (BRAGA; CARVALHO; LUDEMIR, 2000; HAYKIN, 2001; SILVA; SPATTI; FLAUZINO, 2000).

Pesos existentes nas conexões entre neurônios artificiais, análogos às sinapses em neurônios biológicos, são responsáveis por armazenar o conhecimento aprendido. Quanto mais importante é uma entrada, mais significativa será o peso equivalente. Onde u representa o sinal de ativação do neurônio.


A principal função é a realização do somatório ponderado das entradas e aplicar este resultado como entrada de uma função de ativação, para ativar uma saída ou não. Sendo utilizada neste trabalho a função logística, dada por:

$$f(x) = \frac{L}{1 + e^{-k(x-x_0)}} \quad (1)$$

em que x_0 é o valor de x no ponto médio curva sigmóide, L é o valor máximo da amplitude da curva, e k declividade da curva. Para esse trabalho consideraremos $x_0 = 0$, $L = 1$ e $k = 1$. A função logística pode ser observada na Figura 4.

A função sigmóide é uma função estritamente crescente e derivável. Assume um intervalo contínuo de valores entre 0 (para pequenos valores de entrada) e 1 (para grandes valores de entrada), permanecendo finita mesmo com valores de x próximos aos extremos do universo de discurso, $\pm\infty$, o que ocorre em uma maior eficiência no treinamento das redes (BAUGHMAN; LIU, 1995; HAYKIN, 2001).

Figura 4 -Função Logística sigmóide padrão



Fonte: Autor.

Pode-se resumir o funcionamento de um neurônio artificial por meio dos seguintes passos: apresentação de um conjunto de valores que representam as variáveis de entrada do neurônio, realizar a multiplicação de cada entrada pelo seu respectivo peso sináptico, obtendo o potencial de ativação apropriado, tendo como objeto limitar a saída do neurônio e, por fim, compilar a saída a partir da aplicação da função de ativação neural em relação a seu potencial de ativação. (SILVA, SPATTI, FLAUZINO, 2010).

A equação que modela um neurônio pode ser expressa da seguinte forma:

$$u = w_1x_1 + w_2x_2 + \dots + w_nx_n - w_0x_0 = \sum_{i=1}^n w_ix_i - w_0x_0 \quad (2)$$

$$y = f(u) \quad (3)$$

em que u é o somatório exibido na Figura 3, e y é a saída do neurônio, dado pela função de ativação, por exemplo, logística da Equação 1, em que se obtém os resultados esperados para o processo da RNA.

2.5 Redes Perceptron Multicamadas

A topologia de uma rede neural refere-se a como os neurônios desta rede estão interconectados. Enquanto a arquitetura define a forma como os seus diversos neurônios estão arrançados, uns em relação aos outros (BAUGHMAN; LIU, 1995; SILVA; SPATTI; FLAUZINO, 2000), o planejamento da arquitetura e a definição da topologia irão refletir o tipo de problema que se deseja solucionar com a rede (BRAGA; CARVALHO; LUDEMIR, 2000).

Uma rede neural artificial pode ser dividida em três partes, denominadas de camada de entrada, camadas ocultas e camada de saída (KHANLARI et al., 2012).

Segundo Silva, Spatti e Flauzino (2000), a camada de entrada recebe as informações (dados) provenientes do meio externo, especificado anteriormente como valores de entrada. A normalização destas entradas reflete as faixas de variações dinâmicas produzidas pelas funções de ativação. As camadas ocultas ou invisíveis possuem os neurônios que irão extrair as características relacionadas ao processo ou sistema em análise. Já a camada de saída produz e apresenta os resultados finais da rede, os quais são resultantes dos processamentos realizados pelos neurônios das camadas anteriores.

Segundo Yonenaga e Figueiredo (1999), em 1958, Frank Rosenblatt construiu um dos primeiros tipos de redes neurais, a rede neural artificial Perceptron. Essa rede desenvolvida atualiza as sinapses com um método de ajuste supervisionado quando o supervisor ajusta os parâmetros modificáveis da rede neural com base no valor do erro (apud YONENAGA e FIGUEIREDO, 1999).

Entretanto, logo após a publicação do trabalho de Frank Rosenblatt, em 1958, Marvin Minsky e Seymour Papert descobriram e provaram, no trabalho intitulado *Perceptrons*, que as redes neurais de uma única camada não são tão eficientes assim (LUDWIG JR.; MONTGOMERY, 2007). Eles confirmaram que a Perceptron não consegue resolver situações

em que ocorre o problema da resolução da operação da função lógica (OU) exclusivo (XOR) (VALENÇA, 2009), ou seja, problemas que não são linearmente separáveis. Com a publicação do trabalho de Minsky e Papert, muitos pesquisadores na área de redes neurais da época foram desestimulados (NASCIMENTO JR.; YONEYANA. 2004).

Depois disso, as redes neurais foram melhoradas por Rumelhard (1986) com o algoritmo *Backpropagation*. São redes neurais em que os neurônios são organizados em duas ou mais camadas, possuindo pelo menos uma camada intermediária tipicamente denominada de camada escondida de neurônios. Esta camada intermediária se encontra entre a camada de entrada e saída (NASCIMENTO JR.; YONEYANA. 2004).

Dentre suas aplicações podemos destacar a aproximação universal de funções, reconhecimento de padrões e previsões de séries temporais que será parte do desenvolvimento desse projeto.


As redes *feedforward* cujo treinamento é realizado de maneira supervisionada, onde o fluxo da rede inicia a camada de entrada, percorre a camada intermediária finalizando com a camada neural de saída. Entre os principais tipos de redes com arquitetura *feedforward* se encontra o Perceptron multicamadas.

A rede *feedforward* de camada simples é a forma mais básica de uma rede neural, em que temos uma camada de entrada que se projeta sobre uma camada de saída de neurônios. Estas conseguem resolver, apenas, problemas linearmente separáveis (BRAGA; CARVALHO; LUDEMIR, 2000).

A estratégia de treinamento supervisionado consiste em considerar cada amostra dos sinais de entrada, as respectivas saídas desejadas, ou seja, cada amostra de treinamento e composta por sinais de entradas e suas correspondentes saídas. Sendo o ajuste dos pesos de cada neurônio feito pelo treinamento supervisionado.

Na Figura 5, temos um exemplo de uma rede *feedforward* de múltiplas camadas, tipicamente utilizada na resolução de vários problemas complexos, tais como aqueles relacionados à aproximação de funções, classificação de padrões, identificação de sistemas, robótica e controle de processos (RAI; MAJUMDAR; DASGUPTA, 2005).

Figura 5- Exemplo de uma rede feedforward de camadas múltiplas.



Fonte: Silva, Spatti e Flauzino (2000).

Neste caso, ao contrário das redes de camada simples, há uma ou mais camadas ocultas presentes. A determinação do número de camadas escondidas e o número de neurônios que as constituem dependem, sobretudo, do tipo e da complexidade do problema a ser solucionado pela rede, assim como da quantidade e da qualidade dos dados disponíveis a respeito do problema (SILVA; SPATTI; FLAUZINO, 2000).

Essa rede possui duas fases sendo elas a fase *forward* e a *backward*. A fase *forward* como o nome diz, propagação adiante, obtém-se somente as respostas da rede, levando em consideração apenas os valores atuais dos pesos sinápticos que permanecerão inalterados durante à execução desta fase. Já na fase *backward*, que significa propagação reversa, são executados os ajustes dos pesos sinápticos e limiares dos neurônios.

O treinamento *Backpropagation* utilizado seria um gradiente descendente adaptado para Rede Neural Artificial. Funciona por meio de comparação entre as saídas da rede neural e o resultado desejado. Toda vez que se compara gera um erro, este erro possui o nome de Erro Quadrático Médio (EQM).

O algoritmo *Backpropagation* (BPA) é a regra de aprendizado mais utilizada em RNAs, sendo baseada no aprendizado pela correção do erro (BAUGHMAN; LIU, 1995; KHANLARI et al., 2012; RAI; MAJUMDAR; DASGUPTA, 2005). O BPA recalcula os pesos sinápticos pela propagação do erro a partir da camada de saída em direção às camadas anteriores, ou seja, camadas ocultas e camadas de entrada respectivamente. Os valores de saída da rede são comparados aos valores de saída desejados, sendo o erro calculado. Este erro é então propagado

de volta para o ajuste dos pesos sinápticos, de tal maneira, que o erro diminua a cada iteração e o modelo de RNA aproxime-se do valor de saída desejado (KHANLARI et al., 2012; MOHANRAJ; JAYARAJ; MURALEEDHARAN, 2012).

Na fase *forward*, obtém-se a saída da rede por meio da seguinte equação:

$$u_1 = w_1x + w_{01}x_0 \quad (4)$$

$$y_1 = f(u_1) \quad (5)$$

em que w_1 são pesos atuais, x são os valores de entrada, w_{01} é chamado de bias (sendo uma matriz de dimensão $1 \times k$, onde k é o número de entradas da rede) e y_1 é a saída da camada de entrada, sendo esta utilizada como entrada da próxima camada. Por fim, $f(u)$ é a função logística já mencionada acima.

Na última camada tem-se o seguinte equacionamento da rede:

$$u_2 = w_2y_1 + w_{02}x_0 \quad (6)$$

$$y_2 = f(u_2) \quad (7)$$

Vale ressaltar, que neste estudo foi utilizado apenas uma única camada escondida, pois de acordo com o Teorema da Aproximação Universal de Kolmogorov e Cybenko, com apenas uma única camada escondida pode-se obter uma boa generalização e aproximação da rede (KHANLARI et al., 2012). O objetivo do processo de aprendizagem é minimizar o erro global EQM do sistema pela modificação dos pesos. Dado o atual conjunto de pesos w_n , é necessário determinar como alterá-los, a fim de reduzir o erro global. Isto pode ser feito usando a regra do gradiente descendente.

O erro entre a saída da rede y_n e o sinal desejado d (em que é esperado pela rede, neste caso do trabalho é a série temporal do Preço da Liquidação das Diferenças), é obtido pela diferença entre as duas variáveis.

$$EQM = MSE = \sum \frac{1}{2} (d - y_n)^2 \quad (8)$$

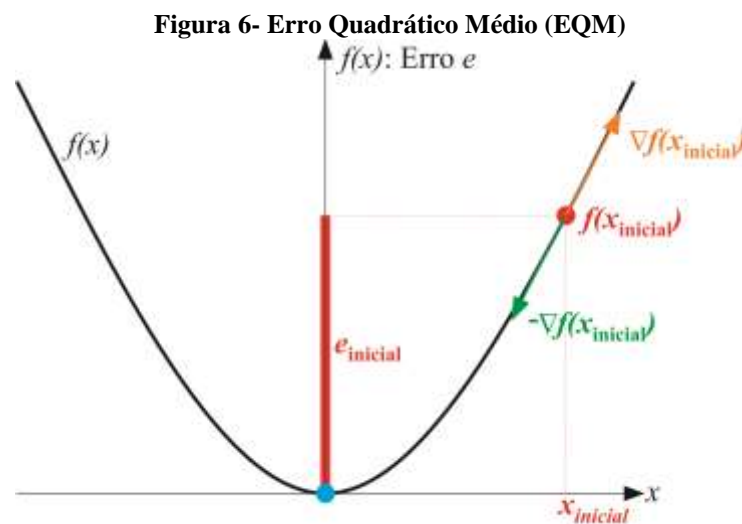
$$RMSE = \sqrt{EQM} \quad (9)$$

É um método baseado em Mínimos Quadrados de otimização de uma função objetivo quadrática. Dada uma função objetivo denominada Erro Quadrático Médio. Deste modo, a

avaliação da performance da rede neural pode ser especificada pelo erro quadrado médio (EQM, do inglês *Mean Squared Error, MSE*) (Equação 8), ou raiz quadrada do erro quadrado médio (*Root Mean Squared Error, RMSE*) (Equação 9).

Minimiza-se o EQM usando a direção contrária do Gradiente. Sendo que o gradiente é um vetor que aponta na direção contrária ao máximo crescimento de uma função. Neste caso, busca-se um vetor na direção contrária ao gradiente pois assim podemos garantir que os pesos obtidos se ajustem para o menor valor de erro. Os conceitos estão expressos na Figura 6.

Já na fase *backward*, como mencionado acima é realizado os ajustes dos pesos. Para isso é necessário calcular o gradiente de EQM com relação a w_2 e w_{02} , referentes à última camada da rede neural.



Fonte: OLIVI, 2017.

O gradiente é calculado a partir da derivada de uma função. A derivada é calculada a partir da regra da cadeia, seus termos são explicitados separadamente e depois ocorre a multiplicação dos termos um a um. Primeiramente calcula-se o termo w_2 como é mostrado abaixo:

$$\frac{\partial EQM}{\partial w_2} = \frac{\partial EQM}{\partial y_2} \frac{\partial y_2}{\partial u_2} \frac{\partial u_2}{\partial w_2} \quad (10)$$

$$\frac{\partial EQM}{\partial y_2} = -(d - y_2) \quad (11)$$

$$\frac{\partial y_2}{\partial u_2} = f'(u_2) \quad (12)$$

$$\frac{\partial u_2}{\partial w_2} = y_1 \quad (13)$$

$$\frac{\partial EQM}{\partial w_2} = -(d - y_2) .* f'(u_2) y_1^T \quad (14)$$

$$\frac{\partial EQM}{\partial w_{02}} = -(d - y_2) .* f'(u_2) x_0^T \quad (15)$$

Em que o símbolo .* da Equação 14 denota uma multiplicação matricial elemento a elemento. Em 14 e 15 tem-se o gradiente do EQM com relação aos pesos sinápticos que se deseja ajustar.

Para realizar o ajuste dos pesos da segunda camada é necessário executar:

$$w_2^{\{t+1\}} = w_2^{\{t\}} - \eta_{w_2} \frac{\partial EQM_t}{\partial w_2} \quad (16)$$

$$w_{02}^{\{t+1\}} = w_{02}^{\{t\}} - \eta_{w_{02}} \frac{\partial EQM_t}{\partial w_{02}} \quad (17)$$

em que η_{w_2} e $\eta_{w_{02}}$ é a taxa de aprendizagem. É uma constante positiva entre 0 e 1, baseada no cálculo do termo de correção por gradiente descendente, que controla a taxa na qual os novos fatores pesos são ajustados. Pequenos valores de η resultam em um lento progresso de treinamento, enquanto altos valores podem produzir oscilações entre soluções relativamente ruins (RAI; MAJUMDAR; DASGUPTA, 2005).

A seleção de uma ótima topologia de RNA envolve quatro passos: (i) preparação e normalização dos dados requeridos para o treinamento, validação e teste, (ii) treinamento das redes pela configuração da topologia da RNA usando diferentes algoritmos de aprendizado, funções de ativação, elementos de processamento (números de neurônios) e iterações de treinamento, (iii) testar a rede obtida com dados de validação, que não foram utilizados no treinamento e, finalmente, (iv) seleção da rede ótima de acordo com os parâmetros estatísticos e a simplicidade da topologia da RNA (ABBASI-TARIGHAT; SHAHBAZI; NIKNAM, 2013; CARVALHO et al., 2013; FARIA et al., 2015; RAI; MAJUMDAR; DASGUPTA, 2005; XI et al., 2013).

A normalização dos dados é imprescindível para um bom desempenho da rede. Não existem restrições em relação à amplitude das variáveis na camada de entrada, contudo, existe uma limitação da amplitude das variáveis de saída previstas, devido ao caráter específico dos neurônios de saída em função dos valores limites das funções de ativação (DIEULOT;

SKURTYYS, 2013; GOÑI et al., 2008). Portanto, para evitar efeitos de tendência das variáveis (devido suas diferentes faixas) e que os componentes dos sinais de saída excedam o intervalo das funções de ativação, cada variável é redimensionada no mesmo intervalo (DIEULOT; SKURTYYS, 2013; RAI; MAJUMDAR; DASGUPTA, 2005).

Como já informado, um dos principais algoritmos de aprendizado utilizados em RNAs MLP é o *backpropagation* com o acréscimo do termo momentum que possibilita a correção dos pesos sinápticos durante o treinamento baseado na diferença (erro) entre o valor desejado e o calculado pela rede (ABBASI-TARIGHAT; SHAHBAZI; NIKNAM, 2013) e permite que a convergência dos pesos resulte em um mínimo global ao invés de um mínimo local do erro (GOKTEPE et al., 2008).

Um dos mais importantes aspectos no desenvolvimento de uma RNA é determinar a qualidade de atuação da rede, uma vez que o treinamento tenha sido finalizado. A análise envolve dois principais critérios: (1) quão bem a rede neural se recorda das respostas preditas a partir dos dados utilizados no treinamento da rede e (2) quão bem a rede prediz respostas a partir de dados que não foram utilizados na fase de treinamento (BAUGHMAN; LIU, 1995).

Durante o ajuste dos pesos sinápticos e limiares dos neurônios de uma RNA, cada apresentação completa dos dados do subconjunto de treinamento é denominada época ou iteração (PHIMOLSIRIPOL; SIRIPATRAWAN; CLELAND, 2011; SILVA; SPATTI; FLAUZINO, 2000). A definição do melhor número de iterações utilizadas durante o treinamento é um critério essencial para se evitar o super-treinamento (*overfitting*). Este problema refere-se à redução da capacidade da rede em generalizar devido a um treinamento excessivo que causa uma memorização dos dados de treinamento e não um aprendizado das relações envolvidas no fenômeno (HAYKIN, 2001; LINDER; PO, 2003).

O melhor número de iterações deve ser obtido por meio da análise da convergência do erro dos dados de validação e teste para um valor de mínimo (LINDER; PO, 2003; PHIMOLSIRIPOL; SIRIPATRAWAN; CLELAND, 2011).

2.6 Sistema elétrico brasileiro

O Sistema Elétrico Brasileiro é caracterizado como um sistema hidrotérmico de grande porte com a predominância de usinas hidrelétricas interligadas por linhas de transmissão. Essa característica faz com que os agentes comercializem energia livremente entre si, independente das usinas e das cargas.

Diante dessa facilidade comercial, criou-se a Câmara de Comercialização de Energia Elétrica (CCEE) para viabilizar a comercialização de energia elétrica no SIN, tanto no ambiente de contratação livre quanto no ambiente de contratação regulada. Contudo, deve-se ressaltar que independentemente se o comércio de energia elétrica for no SIN ou de outras formas a Agência Nacional Energia Elétrica (ANEEL) o regulamenta e fiscaliza, de forma a buscar o equilíbrio do mercado e a maior qualidade dos serviços.

2.7 Evolução do setor elétrico brasileiro

A ideia de progresso e desenvolvimento que marcou o século XIX teve, em grande parte, relação com o avanço técnico que se instalava no Brasil – a energia elétrica. Essa fonte de energia chegou ao país, porque com a implantação da República em 1889 ampliou-se a necessidade das indústrias e empresas públicas aumentarem sua produção, para tanto, a utilização de máquinas e outros instrumentos movidos por esse recurso energético se tornou essencial. Contudo, esse avanço ainda não era palpável, visto que as usinas geradoras de energia eram pequenas e à fio d'água, logo diante dessa realidade houve um esperado interesse por parte de empresas estrangeiras em investir no setor elétrico brasileiro, uma vez que avistavam um grande mercado nas crescentes cidades brasileiras, notadamente São Paulo e Rio de Janeiro (CHUAHY, 1933, p.20).

Nesse sentido, destaca-se a atuação do grupo canadense *Light and Power Company* em São Paulo (1899) e no Rio de Janeiro (1905), e da empresa americana *American & Foreign Power Company – Amforp* (1927), que se instalou em diversos estados da federação, corroborando com o monopólio estrangeiro sobre a produção energética do país, que no final do século XX tornou-se praticamente absoluto (CHUAHY, 1933, p.21).

Diante disso, alguns pesquisadores dividem o desenvolvimento do setor elétrico brasileiro em cinco períodos. O primeiro deles inicia-se com a proclamação da República, em 1889, e termina no início da década de 1930. Nesse período, a economia brasileira caracterizava-se pela produção de produtos primários para a exportação, tendo como principal fonte energética o carvão vegetal. Entretanto, com o desenvolvimento da indústria do café, começou um processo de urbanização que resultou no aumento do consumo de energia elétrica para a iluminação pública, porém esse ainda era incipiente.

O segundo período estendeu-se de 1930 a 1945, e foi caracterizado pelo enfraquecimento do modelo agrário/exportador e pela aceleração do processo de

industrialização. Essa mudança de paradigma, fez com que o Estado promovesse uma maior regulação do setor, como, por exemplo, com a promulgação do Código de Águas (em 1934), que transformou a União em proprietária das quedas d'água, assim ela passou a deliberar exclusivamente sobre a outorga das concessões para aproveitamento hidráulico. Nesse mesmo período, introduziu-se também um sistema tarifário sob o regime de custo do serviço.

O terceiro período iniciou-se no após a Segunda Guerra Mundial e se estendeu até o final da década de 1970, sendo caracterizado pela forte e direta presença do Estado no setor elétrico, principalmente, por meio da criação de empresas estatais em todos os segmentos da indústria. Vislumbra-se o elevado investimento realizado nessa época através do aumento da potência instalada que em pouco mais de vinte anos passou de 1.300 MW para 30.000 MW.

O quarto período iniciou-se na década de 1980 e foi marcado pela crise da dívida externa brasileira, que resultou em altos cortes de gastos e investimentos pelo governo. As tarifas de energia, que eram iguais para todo o país, foram mantidas artificialmente baixas como medida de contenção da inflação, não garantindo às empresas do setor uma remuneração suficiente para o seu equilíbrio econômico. Também vigorava a equalização tarifária entre todos os estados brasileiros, provocando subsídios cruzados entre empresas eficientes e ineficientes. Tal situação adversa criou condições para a proposição de um novo paradigma para o setor elétrico, assim como ocorreu também para outros setores de infraestrutura no país, como o de telecomunicações.

Nesse contexto, iniciou-se o quinto período do desenvolvimento da indústria de eletricidade no Brasil, que perdura até os dias atuais. Em meados da década de 1990, a partir de um projeto de reestruturação do setor elétrico, denominado Reestruturação do Setor Elétrico Brasileiro (RESEB), o Ministério de Minas e Energia preparou as mudanças institucionais e operacionais que culminaram no atual modelo do setor. Esse baseou-se no consenso político-econômico do “estado regulador”, o qual deveria direcionar as políticas de desenvolvimento, bem como regular o setor, sem postar-se como executor em última instância. Assim, muitas empresas foram privatizadas e autarquias de caráter público e independente foram criadas, como é o caso da própria agência reguladora, a ANEEL.

Apesar das reformas, o novo modelo não garantiu a suficiente expansão da oferta de energia, levando o país a um grande racionamento em 2001. Alguns estudiosos do setor atribuem o racionamento, entre outros fatores, à falta de planejamento efetivo e também de monitoramento eficaz centralizado. Foi então, a partir de 2004, que novos ajustes ao modelo foram feitos pelo governo com o intuito de reduzir os riscos de falta de energia e melhorar o

monitoramento e controle do sistema. Os princípios que nortearam o modelo de 2004 foram: a segurança energética, a modicidade tarifária e a universalização do atendimento.

Apesar de alterações significativas em alguns mecanismos inicialmente previstos, como o de compra de energia por parte das distribuidoras, pode-se dizer que a espinha dorsal do modelo dos anos 1990 foi preservada em 2004. Todavia, um novo capítulo na história do setor elétrico iniciou-se com a Medida Provisória 579, de setembro de 2012. Nessa MP, posteriormente convertida na Lei 12.783/2013, empresas geradoras e transmissoras puderam renovar antecipadamente seus contratos de concessão desde que seus preços fossem regulados pela ANEEL. Principalmente devido à regulação dos preços das geradoras que aceitaram os termos da MP, observou-se significativa mudança no contexto institucional do setor elétrico: empresas geradoras que outrora atuavam em ambiente competitivo passaram a ter seus preços regulados, da mesma forma que já ocorria com as distribuidoras e transmissoras, consideradas monopólios naturais.

Com efeito, após as diversas modificações implantadas ao longo do tempo, pode-se dizer que o setor elétrico brasileiro é atualmente caracterizado por:

- Desverticalização da indústria de energia elétrica, com segregação das atividades de geração, transmissão e distribuição.
- Coexistência de empresas públicas e privadas.
- Planejamento e operação centralizados.
- Regulação das atividades de transmissão e distribuição pelo regime de incentivos, ao invés do “custo do serviço”.
- Regulação da atividade de geração para empreendimentos antigos.
- Concorrência na atividade de geração para empreendimentos novos.
- Coexistência de consumidores cativos e livres.
- Livres negociações entre geradores, comercializadores e consumidores livres.
- Leilões regulados para contratação de energia para as distribuidoras, que fornecem energia aos consumidores cativos.
- Preços da energia elétrica (commodity) separados dos preços do seu transporte (uso do fio).
- Preços distintos para cada área de concessão, em substituição à equalização tarifária de outrora.
- Mecanismos de regulação contratuais para compartilhamento de ganhos de produtividade nos setores de transmissão e distribuição.

De forma a sintetizar a evolução histórica trazida à baila nesse capítulo, vê-se na Figura 7:

Figura 7 - Evolução Sistema Elétrico Brasileiro.

Modelo Antigo (até 1995)	Modelo de Livre Mercado (1995 a 2003)	Novo Modelo (2004)
Financiamento através de recursos públicos	Financiamento através de recursos públicos e privados	Financiamento através de recursos públicos e privados
Empresas verticalizadas	Empresas divididas por atividade: geração, transmissão, distribuição e comercialização	Empresas divididas por atividade: geração, transmissão, distribuição, comercialização, importação e exportação.
Empresas predominantemente Estatais	Abertura e ênfase na privatização das Empresas	Convivência entre Empresas Estatais e Privadas
Monopólios - Competição inexistente	Competição na geração e comercialização	Competição na geração e comercialização
Consumidores Cativos	Consumidores Livres e Cativos	Consumidores Livres e Cativos
Tarifas reguladas em todos os segmentos	Preços livremente negociados na geração e comercialização	No ambiente livre: Preços livremente negociados na geração e comercialização. No ambiente regulado: leilão e licitação pela menor tarifa
Mercado Regulado	Mercado Livre	Convivência entre Mercados Livre e Regulado
Planejamento Determinativo - Grupo Coordenador do Planejamento dos Sistemas Elétricos (GCPS)	Planejamento Indicativo pelo Conselho Nacional de Política Energética (CNPE)	Planejamento pela Empresa de Pesquisa Energética (EPE)
Contratação: 100% do Mercado	Contratação : 85% do mercado (até agosto/2003) e 95% mercado (até dez./2004)	Contratação: 100% do mercado + reserva
Sobras/déficits do balanço energético rateados entre compradores	Sobras/déficits do balanço energético liquidados no MAE	Sobras/déficits do balanço energético liquidados na CCEE. Mecanismo de Compensação de Sobras e Déficit (MCSD) para as Distribuidoras.

Fonte: CCEE (WWW.ccee.org.br)

2.8 Mercado em curto prazo

O mercado *spot* é um segmento da CCEE onde são contabilizadas as diferenças entre os montantes de energia elétrica contratados pelos agentes e os montantes de geração e de consumo efetivamente verificados e atribuídos aos respectivos agentes. Todos os contratos de compra e venda de energia celebrados no mercado, tanto no Ambiente de Contratação Regulado como

no Ambiente de Contratação Livre devem ser registrados na CCEE, que realiza a medição dos montantes efetivamente produzidos/consumidos por cada agente. As diferenças apuradas, positivas ou negativas, são contabilizadas para posterior liquidação financeira no Mercado de Curto Prazo e valoradas ao Preço de Liquidação das Diferenças (PLD).

As características mais importantes do mercado spot brasileiro são: existência de um operador único do mercado (CCEE, 2017) que centraliza as transações de compra e venda de energia; custos (e preços) associados diretamente ao despacho econômico; demanda passiva no mercado atacadista; e não há existência de pagamentos por capacidade.

A partir dessas características esse mercado exerce algumas funções importantes em uma indústria desregulamentada: aumenta a flexibilidade das transações; permite ajustes entre a energia contratada e a energia gerada e serve como referência para contratos de longo prazo. Logo, é um importante mecanismo de ajuste entre demanda e oferta (NEWBERY, 1998, p.).

Diante dessas características e funções, é natural que o preço spot de eletricidade seja um ativo volátil, porém, no caso brasileiro a volatilidade é significativamente elevada o que implica um ambiente de expressivas incertezas para os agentes (LEITE; SANTANA, 2006, p.).

2.9 A comercialização de energia elétrica

A partir da década de 1990, buscando eficiência e autonomia econômica, o setor elétrico mundial começa a passar por reformas estruturais em sua forma de operação, sofrendo influência da doutrina do estado mínimo no pensamento econômico. Como resultado destas reformas, que também ocorreram no Brasil, os segmentos de geração, transporte e comercialização de energia passam a ser separados, sendo administrados e operados por agentes distintos.

A ideia predominante foi a de que a livre concorrência deveria prevalecer onde fosse possível, relegando ao estado o papel da regulação onde necessário. Neste contexto, os segmentos de geração e comercialização foram caracterizados como segmentos competitivos, dada a existência de muitos agentes e também pelo fato do produto, a energia elétrica, ser homogêneo, como uma *commodity*.

Por sua vez, os setores de transporte da energia – a transmissão e a distribuição – são considerados monopólios naturais, pois sua estrutura física torna economicamente inviável a competição entre dois agentes em uma mesma área de concessão. Nestes dois segmentos, predomina O segmento de comercialização de energia é relativamente novo, tanto no Brasil

quanto no mundo. Seu surgimento está relacionado com a reestruturação do setor elétrico, ocorrida na década de 1990, e seu papel muito mais relacionado ao contexto econômico e institucional do que propriamente ao processo físico de produção e transporte da energia.

No Brasil, o primeiro contrato de comercialização de energia elétrica, nos moldes do novo modelo, ocorreu em 1999, aproximadamente dois anos após a criação da ANEEL. Atualmente, existem mais de 100 agentes de comercialização de energia elétrica no Brasil, muitos deles atuando como intermediários entre usinas e consumidores livres. o modelo de regulação de preços ou regulação por incentivos.

2.10 Agentes direcionantes e suas atribuições

Atualmente o trabalho de planejar, fiscalizar, regulamentar os recursos dentro do setor de energia elétrica no Brasil é realizado por diversos órgãos e corporações que trabalham de forma independente e conjunta como os agentes governamentais que atuam como direcionadores promovendo medidas integradas no sistema. Estes agentes podem ser vistos na Figura 8.

Figura 8 - Principais agentes direcionadores do setor elétrico



Fonte: Câmara de Comercialização de Energia Elétrica (CCEE, 2017) – Adaptado.

O Setor Elétrico Brasileiro, pelo seu porte e complexidade, constituiu-se em arena econômica propícia a intrincadas discussões do ponto de vista de áreas do conhecimento. Profissionais e estudiosos do setor reconhecem sua dimensão inter e multidisciplinar já que a maioria dos temas relevantes exige a aplicação integrada de várias disciplinas para que se obtenha o mínimo de coerência analítica. Não se pode, por exemplo, discutir “Política

Energética” sem incluir análises das disciplinas macro e microeconômica, financeira, jurídica, tecnológica, ambiental e política (Müller e Santos, 2010).

2.11 Ministério de Minas e Energia (MME)

O Ministério de Minas e Energia é um órgão do governo, criado em 1960, através da Lei nº 3.782, de 22 de julho de 1960, responsável por formular e implementar políticas públicas para o setor energético em geral, levando em consideração as diretrizes definidas pelo Conselho Nacional de Política Energética (CNPE). São competências do MME:

- áreas de geologia;
- recursos minerais e energéticos;
- aproveitamento da energia hidráulica;
- mineração e metalurgia;
- combustível, energia elétrica e energia nuclear.

E em relação ao setor de energia elétrica, cabe ao MME:

- definir diretrizes para os procedimentos licitatórios;
- celebrar contratos de concessão e permissão dos serviços públicos de energia;
- intervir da concessão, caso necessário.

De acordo com Müller e Santos (2010), o ministério, por ser de estrutura governamental, intrinsecamente seria responsável pela manutenção de interesses políticos de curto prazo, ou seja, as demandas mais imediatas da sociedade.

2.12 Agência Nacional de Energia Elétrica (ANEEL)

Criada através da Lei nº 9.427 de 1996, que dispõe sobre a criação das agências reguladoras, tem por atribuição principal regular e fiscalizar a geração, transmissão, distribuição e comercialização de energia elétrica. A necessidade do advento desse tipo de 24 agência de Estado - e não de governo, veio da urgência de se instituir um ambiente regulatório devido ao intenso processo de privatização a partir dos anos 90 (SAMPAIO, 2010).

Há estabilidade funcional dos dirigentes, mandato fixo, autonomia na gestão, ou seja, suas decisões são, pelo menos em tese, independentes. Pode-se perceber a ausência de

submissão a órgãos hierárquicos da administração pública, razão pela qual carrega o título de agência reguladora independente (TOLMASQUIM, 2011).

São atribuições da ANEEL, entre outras:

- executar diretrizes e políticas do governo para a exploração da energia elétrica e o aproveitamento dos potenciais hidráulicos, promovendo os atos regulamentares necessários para o cumprimento da norma;
- promover os procedimentos licitatórios para a contratação de concessionárias e permissionárias de serviço público para a geração, transmissão e distribuição de energia elétrica;
- administrar e fiscalizar os contratos de concessão ou de permissão de serviços públicos de energia elétrica;
- extinguir as divergências entre produtores independentes, autoprodutores, concessionárias, permissionárias e autorizadas, assim como tais agentes e seus consumidores;
- propiciar concorrência entre os agentes e entrar a concentração econômica nos serviços e atividades de energia elétrica;
- monitorar o cumprimento da legislação de defesa da concorrência entre os agentes do SEB;
- estabelecer multas administrativas aos concessionários, permissionários e autorizados de serviços de energia elétrica;
- efetuar regras e procedimentos de comercialização de energia elétrica, tanto na forma regulada quanto na livre

A ANEEL surgiu em 1997, em substituição ao Departamento Nacional de Águas e Energia Elétrica (DNAEE). Sampaio (2010) define a missão da agência:

“a agência tem como missão, além de regular o setor elétrico, estimular a concorrência sadia entre as concessionárias quando possível, comprometer as concessionárias a buscar eficiência não esquecendo a questão ambiental, abrir um canal de diálogo com os consumidores e fomentar a participação desses por meio de associações nos debates pertinentes à regulação.”

2.13 Conselho Nacional de Política Energética (CNPE)

O CNPE é um órgão interministerial, com vinculação à Presidência da República, que possui como presidente e secretário executivo integrantes do Ministério de Minas e Energia. Participam também desse órgão vários ministros, tais como: o da Ciência e Tecnologia; o do

Planejamento, o do Orçamento e Gestão; o da Fazenda; o do Meio Ambiente; o do Desenvolvimento, Indústria e Comércio Exterior; entre outros. Vale ressaltar também, que o Conselho possui representantes dos estados e do Distrito Federal, da sociedade civil (com especialidade nas questões energéticas), das universidades brasileiras (também especialista em energia), além de compô-lo ainda o presidente da Empresa de Pesquisa Energética (TOLMASQUIM, 2011).

O Conselho possui como responsabilidade a elaboração de políticas que garantam o suprimento de insumos energéticos nas mais diversas áreas do país. Além disso, é de sua competência a revisão periódica das matrizes energéticas e o estabelecimento de diretrizes que incluam as mais diversas fontes energéticas como: o gás natural, biocombustíveis, carvão, energia solar e eólica, etc.

Em suma, o CNPE promove o aproveitamento racional dos recursos energéticos com base nos seguintes princípios (MONTEIRO; SANTOS, 2010):

- assegurar o desenvolvimento sustentado bem como a valorização dos recursos energéticos;
- preservação dos interesses do país;
- proteção dos interesses do consumidor de energia;
- proteção do meio ambiente e conservação de energia;
- enumerar soluções adequadas para o suprimento de energia às mais diversas regiões do país;
- utilização racional de fontes renováveis de energia;
- promover a livre concorrência;
- atrair investimentos na geração de energia;
- ampliar a competitividade do país frente ao mercado internacional

2.14 Comitê de Monitoramento do Setor Elétrico (CMSE)

Criado em 2004, o CMSE é um órgão sob coordenação do Ministério de Minas e Energia, no qual, integram permanentemente os membros desse Ministério, bem como os do Operador Nacional do Sistema Elétrico (ONS), os da Câmara de Comercialização de Energia Elétrica (CCEE) e os da Agência Nacional de Energia Elétrica (ANEEL). A principal função desse comitê é acompanhar a segurança do suprimento de energia elétrica em todo o território nacional, além de:

- acompanhar o desenvolvimento das atividades da cadeia produtiva do SEB – geração, distribuição, transmissão, comercialização, importação e exportação de energia elétrica, gás natural, petróleo e seus derivados;
- avaliar as condições de atendimento e abastecimento em relação aos itens acima em horizontes pré-determinados;
- analisar periodicamente a segurança no abastecimento em relação ao mercado de energia elétrica, gás natural e petróleo, em relação à demanda, oferta, qualidade dos insumos energéticos e transporte;
- identificar possíveis entraves técnicos ou administrativos que possam afetar a segurança no abastecimento de energia;
- elaborar propostas para sanar ou prevenir eventuais dificuldades supracitadas.

2.15 Empresa de Pesquisa Energética (EPE)

A EPE foi criada em julho de 2003, em meio à reestruturação institucional do Sistema Elétrico Brasileiro, pela Medida Provisória nº 145. Essa MP foi responsável por autorizar a sua criação na forma de empresa pública, e não mais de fundação, levando-a a obedecer, a partir desse momento, aos ditames da iniciativa privada (TOLMASQUIM, 2011, p.42). Conforme preceitua esse instrumento normativo, a EPE passou a ter competência para:

- realizar estudos e projeções da matriz energética;
- elaborar o balanço energético nacional;
- quantificar os potenciais de recursos energéticos;
- identificar, por meio de estudos, o melhor aproveitamento dos potenciais hidráulicos;
- adquirir licença prévia ambiental e declaração de disponibilidade hídrica necessárias às licitações envolvendo os empreendimentos de produção e transmissão de energia elétrica;
- estudar o desenvolvimento da expansão da geração e transmissão de energia em curto, médio e longo prazo.

2.16 Câmara de Comercialização de Energia Elétrica (CCEE)

A CCEE foi criada em 2004, dentro da proposta do novo modelo do Setor Elétrico Brasileiro, em substituição ao Mercado Atacadista de Energia. Caracteriza-se por ser pessoa jurídica de direito privado, sem fins lucrativos, sob autorização do Poder Concedente e fiscalização da ANEEL. Sua função é operacionalizar a comercialização de energia elétrica (ARAÚJO, 2007) para tanto, opera os leilões de energia, com atuação técnica (MONTEIRO, SANTOS, 2010).

Destaca-se dentre as mudanças ocorridas devido ao surgimento da CCEE a criação de dois ambientes de contratação de energia: o Ambiente de Contratação Regulado (ACR) e o Ambiente de Contratação Livre (ACL). Esses facilitaram o comércio e a negociação de energia no país fazendo com que surgisse a figura do comercializador de energia, que mesmo não envolvido com as atividades de produção de energia diretamente, estuda o mercado com o objetivo de garantir as melhores opções de compra e venda de energia, intermediando as relações entre os geradores e consumidores livres (ACENDE BRASIL, 2010).

2.17 Operador Nacional do Sistema Elétrico (ONS)

O ONS possui caráter estritamente técnico, de natureza privada, sem fins lucrativos, que desempenha funções de coordenação do Sistema Interligado Nacional (SIN). São suas principais competências:

- programar a operação e o despacho centralizado da geração;
- supervisionar e controlar a operação no SIN e nas interligações internacionais;
- contratar e administrar os serviços de transmissão de energia elétrica;
- propor ao Poder Concedente os reforços dos sistemas existentes;
- sugerir regras para a operação da Rede Básica do SIN, a serem aprovadas pela ANEEL.


2.18 Comercialização Energia Elétrica

As relações comerciais entre os Agentes participantes da CCEE são regidas predominantemente por contratos de compra e venda de energia, os quais devem ser registrados. Esse registro inclui apenas as partes envolvidas, os montantes de energia e o período de

vigência, não constando os preços, pois esses são apenas utilizados pelas partes envolvidas em suas liquidações bilaterais.

A CCEE contabiliza as diferenças entre o que foi contratado e o que foi produzido ou consumido. As diferenças negativas ou positivas são liquidadas no Mercado Curto Prazo (Mercado Spot) e valoradas ao Preço de Liquidação das Diferenças (PLD), sendo que este é definido semanalmente para cada patamar de carga e para cada submercado, tendo como base o Custo Marginal de Operação que é limitado por um preço mínimo e por um preço máximo.

Figura 9 - Representação do montante do mercado spot obtido através da diferença energia contratada e a energia verificada.



Fonte: CCEE.

2.19 Leilões de Energia

Com o novo modelo do setor implantado, os leilões de energia foram criados com o objetivo de centralizar a comercialização de energia e de possibilitar maiores investimentos. Nos leilões são realizadas as compras e vendas de energia entre os agentes distribuidores e geradores do setor elétrico (CCEE, 2017).

2.20 Ambientes e Contratação

No novo modelo, a contratação de energia pode ser feita no Ambiente de Contratação Regulada (ACR) ou no Ambiente de Contratação Livre (ACL). Esses dois ambientes possuem diferenciações, quais sejam no primeiro os consumidores ditos “Cativos” partilham contratos

de adesão com o distribuidor que opera na região, exemplo disso são as residências, lojas e pequenas indústrias, não podendo negociar as cláusulas do contrato. Já no segundo, os consumidores são ditos “Livres”, pois podem escolher seu fornecedor de energia (não tendo limitações físicas), bem como qualquer dos vendedores presentes no Sistema Interligado Nacional (SIN), ademais nesse ambiente os preços e condições contratuais são negociáveis.

2.21 Sistema Elétrico Nacional (SIN)

O sistema de produção e transmissão de energia elétrica do Brasil é um sistema hidro-termo-eólico de grande porte, com predominância de usinas hidrelétricas e com múltiplos proprietários. Nesse sentido, foi necessária a criação de um Sistema Interligado Nacional (SIN) constituído por quatro subsistemas: Sul, Sudeste/Centro-Oeste, Nordeste e a maior parte da região Norte. Esses subsistemas, como forma de manter a integridade são conectados por meio da malha de transmissão, que propicia a transferência de energia entre eles, permitindo a obtenção de ganhos sinérgicos e a exploração da diversidade entre os regimes hidrológicos das bacias, atendendo com maior segurança e economicidade o mercado.

A capacidade instalada de geração do SIN é composta, principalmente, por usinas hidrelétricas distribuídas em dezesseis bacias hidrográficas nas diferentes regiões do país. Nos últimos anos, a instalação de usinas eólicas, principalmente nas regiões Nordeste e Sul, apresentou um forte crescimento, aumentando a importância dessa geração para o atendimento do mercado. As usinas térmicas, em geral localizadas nas proximidades dos principais centros de carga, desempenham papel estratégico relevante, pois contribuem para a segurança do SIN. Essas usinas são despachadas em função das condições hidrológicas vigentes, permitindo a gestão dos estoques de água armazenada nos reservatórios das usinas hidrelétricas, para assegurar o atendimento futuro. Os sistemas de transmissão integram as diferentes fontes de produção de energia e possibilitam o suprimento do mercado consumidor.

A operação do SIN é realizada de forma centralizada pelo Operador Nacional do Sistema Elétrico – ONS, que procura garantir a segurança operativa do sistema e a otimização na utilização dos recursos eletroenergéticos. A operação centralizada do sistema busca atender aos requisitos da carga, considerando, entre outras coisas, as condições técnicas e econômicas para o despacho das usinas, as necessidades de energia dos agentes de consumo, os mecanismos de segurança operativa, as restrições de transmissão, o custo do déficit de energia e as interligações internacionais (ONS, 2008).

Conclui-se, portanto, que o Sistema Elétrico Brasileiro é formado por diversas linhas de transmissão, compondo o SIN, que é dividido hoje em quatro submercados: Sul, Nordeste, Norte e Centro Oeste/Sudeste, os quais são distinguidos pelos critérios geoeletricos. Assim, far-se-á uma breve exposição desses subsistemas e submercados a seguir.

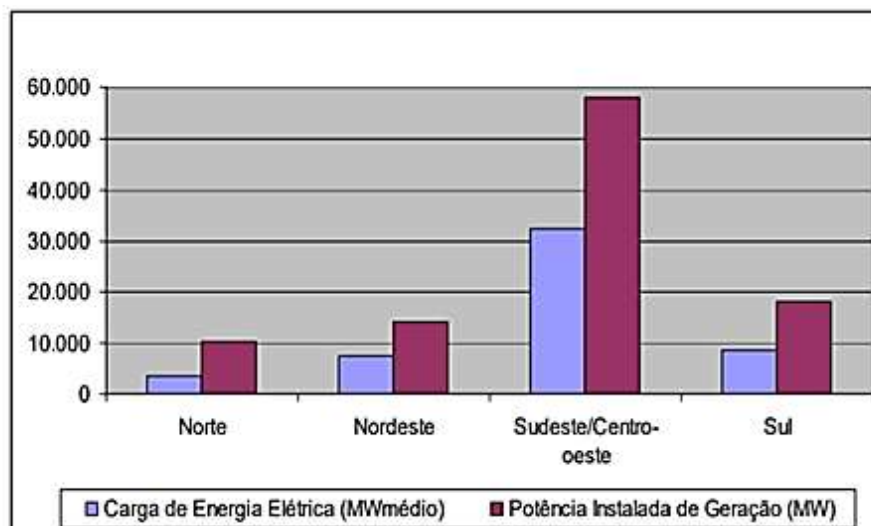
O subsistema Norte é composto pelos estados do Pará, Maranhão e Tocantins e é caracterizado pelo atendimento a cargas industriais eletrointensivas no estado do Pará-Belém e região de Carajás – e no Maranhão, em São Luís (PDE, 2008). Esse subsistema configura-se como exportador de energia tendo em vista o potencial hídrico da região, além de, ser responsável por cerca de 7% do consumo de energia elétrica do SIN, o que representa uma carga média de 3600 MW.

O Subsistema Nordeste é considerado como importador de energia com a presença de várias indústrias nessa região. Compreende os estados do Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe e Bahia. Sua carga elétrica média é em torno de 7500 MW, compreendendo cerca de 14% do consumo do SIN. Tal subsistema é suprido pela energia gerada na própria região, complementada pela energia importada das regiões Sudeste/Centro-oeste e pelos excedentes de energia da região Norte (PDE, 2008).

O Subsistema Sudeste/Centro Oeste é formado pelos estados do Espírito Santo, Rio de Janeiro, Minas Gerais, São Paulo, Goiás, Mato Grosso, Mato Grosso do Sul e pelo Distrito Federal. Representando mais de 60% do consumo do SIN, com carga média em torno de 32300 MW. Apesar de ser o maior polo consumidor do país, apresenta índices de geração de energia mais baixos do que de consumo.

O Subsistema Sul compreende os estados do Rio Grande do Sul, Santa Catarina e Paraná, e representa cerca de 17% do consumo do SIN, apresentando carga em torno de 8600 MW médio. Apresenta índices de produção e consumo de energia muito próximos, conforme Figura 10.

Figura 10 - Carga, em MWmédio, e potência instalada, em MW, dos subsistemas do SIN, em 2008.



Fonte: CCEE.

2.22 Preço Liquidação de Diferenças (PLD)

O Preço de Liquidação de Diferenças (PLD) é o preço de referência para valorar a compra e a venda de energia no Mercado de Curto Prazo (MCP), seu valor é apurado semanalmente, utilizando para tanto o patamar de carga previsto no Custo Marginal de Operação (CMO) e também o submercado analisado.

Conforme consta acima, um dos parâmetros para se auferir o valor do PLD é o patamar de carga. Esse é calculado pelo período de tempo em que as características de consumo de energia elétrica tendem a ser semelhantes como, por exemplo, é considerado patamar leve aquele que ocorre nas primeiras horas do dia, pois não há o consumo, geralmente, de iluminação pública e atividades industriais; como médio o patamar correspondente ao amanhecer e ao início do consumo de atividades de prestação de serviço e incremento da atividade industrial; e o patamar pesado aquele que é verificado com o início do consumo com a iluminação pública e aumento do consumo residencial, sendo considerado o pico de consumo de energia do SIN.

Com relação à influência dos submercados no cálculo do PLD, esses são levados em consideração, tendo em vista que as condições hidrológicas, a demanda de energia, os preços de combustíveis, o custo de déficit, a entrada de novos projetos e a disponibilidade de

equipamentos de geração e transmissão, entre outros fatores, presentes em cada tipo de submercado, alteram seus valores.

O Operador Nacional do Sistema (ONS) utilizando os fatores mencionados, bem como as previsões de disponibilidade de geração vazão de afluentes e carga do sistema, busca minimizar o custo total do PLD por meio de quatro variáveis: geração hidráulica, geração térmica, intercâmbio de energia (entre submercados) e corte de carga. Através dos modelos computacionais utilizados pelo ONS, chega-se ao CMO, que além da função precípua de apurar o valor do PDL, também, precifica cada montante de energia diferente do que foi estabelecido no contrato.

Após auferir o PLD, deve-se ater ao seu limite (teto) mínimo e máximo para evitar que seus valores fiquem próximos a zero ou a valores muito altos, uma vez que em cenários de PLD alto, existe o risco de desaceleração da economia do país. Isso ocorre, pois as empresas produtoras de alumínio, ferros-liga e cloro-soda, para amenizarem as perdas causadas pela diminuição da demanda de seus produtos, começam a vender seu excedente de energia elétrica no mercado de curto prazo e assim lucram mais do que com o valor adquirido pela produção do bem, conforme aduz Ildo Sauer, diretor do Instituto de Energia e Ambiente da USP (BBC Brasil, 2014). A lógica para construção deste limite é definida da seguinte forma se o Custo Marginal de Operação é maior que o Preço da Liquidação de Diferenças máximo então, o PLD possui seu valor máximo caso contrário terá um valor mínimo.

Nesse sentido, percebe-se que o PLD é um importante instrumento de orientação dos agentes do mercado de energia elétrica, pois os afeta financeiramente. Vê-se isso, além da situação descrita no parágrafo anterior, quando os Distribuidores e Comercializadores ficam expostos ao PLD por não terem contratado energia suficiente para seu suprimento; ou por outro lado, geradores que tenham contratado maior suprimento de energia do que conseguem fornecer, logo esses agentes ficam expostos ao Mercado de Curto Prazo (MCP) (CCEE, 2017).

Ressalta-se que o MCP, devido à crise econômica atual pode levar pequenas e médias empresas a ingressarem no mercado livre de energia de olho na redução das contas de luz, pois em empresas com demanda contratada igual ou superior a 500 kW podem adquirir livremente energia gerada por fontes renováveis, como hidrelétricas de pequeno porte (PCH), termelétricas a biomassa e fontes eólicas. O mercado livre difere do mercado cativo (em que 21 residências e empresas são atendidas por distribuidoras), pelo fato de o consumidor poder comprar sua energia livremente de distribuidoras ou comercializadoras. (ABRACEEL, 2016).

Com isso existe a pressão de saída de consumidores hoje no mercado cativo para o mercado livre em busca de preços mais competitivos, por isso a importância de se fazer a

previsão do preço de energia elétrica, tanto do lado da Distribuidora quanto da Comercializadora. Um em busca de novos clientes em sua carteira de ativos com o objetivo de maiores margens de lucros entre a venda e a compra de energia elétrica; e o outro na redução de custos para capital de giro para manter a empresa e/ou expandir os seus negócios através de investimentos (ABRACEEL, 2016).

Somado a isso, a volatilidade e a imprevisibilidade do PLD é gerada pela utilização de recursos hidráulicos existentes no país, as novas hidrelétricas incorporadas serão a fio d'água. Em terceiro lugar, a Constituição Federal de 1988 impôs critérios mais rigorosos na construção de grandes reservatórios. Sendo um fator de risco financeiro e tarifário para os agentes do setor, além de uma das maiores preocupações dos agentes do setor elétrico, em especial os que operam no Ambiente de Contratação Livre (ACL).

Nesse ínterim, para diminuir sua volatilidade tem-se buscado soluções para mitigar o risco hidrológico, como os leilões de energia de reserva e estabelecendo metas para o armazenamento de reservatórios. Vale pontuar que o PLD também é a base de cálculo de itens:

- Tratamentos de exposições financeiras ao mercado de curto prazos;
- Ressarcimentos de energia não gerada no ano por usinas a biomassa;
- Encargos devido a restrições de operação e segurança energética;
- Precificação das penalidades de energia e por falta de combustível;
- Contratação de energia de reserva e abatimento do encargo a pagar pelos consumidores;
- Reajuste da receita de venda em casos de atraso em operação comercial de usinas;
- Contratação no ACR do efeito dos contratos por disponibilidade; e regime de cotas de garantia física e energia nuclear.

3. METODOLOGIA

O objetivo deste trabalho é a previsão do preço do PLD com o tempo de uma semana à frente (no futuro), e, para isso, foram utilizadas as Redes Neurais Artificiais. Dentro das RNAs o método utilizado foi de Levenberg-Marquardt associado ao termo momentum em uma rede Perceptron Multicamadas.

A configuração de dados de entrada e saída da RNA, adquiridos no site do ONS, é formada por dados de armazenamento como a Energia Armazenada (EA), Energia Natural

Afluente por subsistema (ENASub) e o Intercâmbio de Energia (IE). Os valores relacionados ao PLD foram retirados do site do CCEE utilizando seu valor médio de carga, sendo todos esses dados do período de 31/03/2015 à 31/05/2017, totalizando aproximadamente 97 semanas, e considerando a semana operativa e em MW médio da Região Sudeste/Centro-Oeste.

A EA é a soma dos produtos de volume armazenado em cada reservatório de acumulação pela produtividade média acumulada deste e de todas as usinas à jusante, sendo que a EA máxima corresponde à capacidade de cada subsistema considerando todo o volume útil de cada reservatório de acumulação (LOPES, 2007).

A ENA corresponde à soma do produto da vazão natural afluente de cada usina pela produtividade média, logo, uma vez que a água passou pelas turbinas movimentando-as e gerando eletricidade tem-se ENA (LOPES, 2007).

Já o IE é o envio ou recebimento de eletricidade entre os submercados, feito através de linhas de transmissão que os interligam. (LOPES, 2007), utilizando-se para o intercâmbio de energia as regiões Sudeste/Centro-Oeste que interligam para os demais submercados ou subsistemas.

Analisando a Rede Neural Artificial ela possuía apenas uma camada de neurônios escondida e utilizou-se 90 neurônios nessa camada. Além disso, essa rede possui uma única saída que é o PLD. Já a entrada além de possuir as variáveis citadas acima foi utilizado Time Delay Neural Network (TDNN) para o PLD.

Como foi dito anteriormente, a função de ativação da Rede Neural Artificial é a função logística, para isso, foi necessário realizar a normalização dos dados para que assim fosse possível ativar ou não a função. Para se obter resultado real previsto pela rede deve ser realizado a função inversa da normalização.

$$f_{predito} = f_{max} - \frac{(f_{max} - f_{min})(s_{max} - s_{predito})}{s_{max} - s_{min}} \quad (18)$$

Sendo $f_{predito}$ o valor desnormalizado para série temporal a partir do valor obtido normalizado, s_{max} é o intervalo máximo da normalização que nesse trabalho foi adotado como 0.9 e o s_{min} que é o intervalo mínimo da normalização foi considerado 0,1.

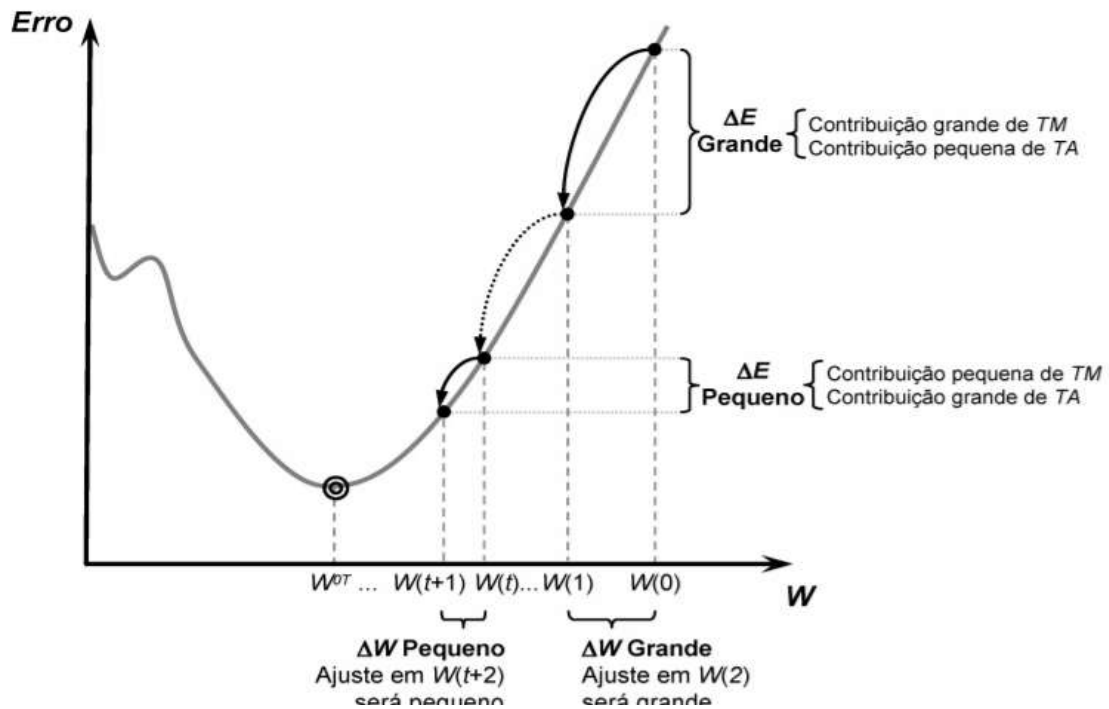
3.1 Método da inserção do termo de momentum

A inserção do termo momentum configura uma das variações mais simples de ser efetuada no algoritmo *backpropagation*, pois é inserindo um único parâmetro onde visa

ponderar o quão as matrizes sinápticas foram alteradas entre duas interações anteriores e sucessivas (SILVA; SPATTI; FLAUZINO, 2000).

Ressalta-se que a taxa de momentum está definida entre 0 e 1. Esse termo acelera as alterações nos fatores peso afetando positivamente o processo de convergência, já que leva em conta o quão a solução atual está afastada da solução ótima, permitindo a convergência para valores de mínimos globais ao invés de mínimos locais (GOKTEPE et al., 2008).

Figura 11 - Processo de treinamento utilizando o método inserção termo momentum.



Fonte: (SILVA, SPATTI,FLAUZINO, 2010).

Assim, o processo de convergência da rede a partir da inserção do termo de momentum se torna mais eficiente, porque é considerado o quão longe está à solução atual da solução final (ótima). Deste modo, o termo de momentum leva em consideração o efeito das mudanças anteriores dos pesos na direção do movimento atual dos pesos.

3.2 Redes Time Delay Neural Network (TDNN)


As redes TDNN nada mais são do que uma maneira específica de organização de dados de entradas e saídas para redes Perceptron Multicamadas, em que se introduz o aspecto dinâmico e temporal por meio da camada de entrada, proporcionando à rede uma memória de curto prazo, aplicando ao vetor de entrada da rede um atraso no tempo. Nesse sentido, é notório

que para cada valor $x(t)$ desejado, a rede treinará com p valores passados, sendo p , portanto, a ordem de predição ou o alcance da memória de curto prazo da rede (HAYKIN, 2009).

Já a técnica TDNN introduz atraso no tempo, uma vez que são redes alimentadas a diante, com múltiplas camadas, cujos nodos das camadas escondidas e da camada de saída são duplicados ao longo do tempo (WAIBEL et al., 1989). Essas entradas atrasadas no tempo permitem que a rede saiba de parte da história da variável no tempo t , possibilitando a solução de problemas de decisão mais complexos, especialmente aqueles dependentes do tempo (KIM e SHIN, 2007).

Percebe-se isso, na rede neural alimentada adiante, a rede é alimentada com as observações das variáveis de interesse de entrada da série temporal a cada passo de tempo e o objetivo é prever um passo à frente, conforme a Figura 12 (ELMAN, 1990 e MOZER, 1988).

Figura 12 - Topologia de uma rede TDNN.



Fonte: Adaptado de HAYKIN (2009).

O processo de aprendizado de uma rede com entradas atrasadas é semelhante à rede convencional. Sendo assim, sua principal diferença está nos conjuntos de dados, onde as amostras são organizadas considerando o atraso entre elas (SILVA et al., 2010).

No decorrer deste trabalho, foi utilizado uma RNA com TDNN com 30 atrasos para variável como PLD para as demais, como EA, ENASub, IE não foram consideradas atraso, ou seja, $x(t), x(t - 1) \dots x(t - 30)$. Logo, considerando os atrasos do PLD e as três variáveis de entrada da rede, ao somarmos totalizou-se um número de 35 entradas para a rede neural.

3.3 Método Levenberg- Marquardt (LM)

Como descrito anteriormente, o algoritmo *Backpropagation* ajusta os valores das matrizes de pesos da rede Perceptron Multicamadas (PMC) em relação à direção oposta do gradiente da função erro quadrático. Entretanto, a utilização desse algoritmo na prática tende a convergir muito lentamente, exigindo-se um elevado esforço computacional. Para contornar este inconveniente, várias técnicas de otimização têm sido incorporadas ao algoritmo a fim de reduzir o seu esforço computacional requerido, para tanto a técnica de otimização mais utilizada é o algoritmo de Levenberg-Marquardt (HAGAN e MENHAJ, 1994). Esse é um método gradiente de segunda ordem, baseado nos Mínimos Quadrados para modelos não lineares, que pode ser incorporado ao algoritmo a fim de potencializar a eficiência do processo de treinamento (SILVA, 2010, p.117).

Devido a sua eficiência o algoritmo de treinamento Levenberg-Marquardt foi utilizado em todas as RNA desenvolvidas, devido às suas vantagens comprovadas frente a outros métodos de treinamentos tradicionais como “aprendizagem rápida” e “convergência confiável” (HAGAN e MENHAJ, 1994).

O algoritmo *backpropagation* é considerado de primeira ordem já que ajusta os parâmetros da rede como por exemplo $w_1, \theta_1, w_2, \theta_2$ com o gradiente. O gradiente descendente é caracterizado como a primeira derivada multidimensional do erro.

Já o método do Levenberg-Marquardt é de segunda ordem, uma vez que utiliza as segundas derivadas dos erros (EQM), acelerando, assim, a convergência do treinamento. Esse método utiliza a segunda derivada multidimensional que é chamada de matriz Hessiana e matriz Jacobiana, a qual é a matriz de derivadas de primeira ordem.

O método original de segunda ordem é o “método de Newton”, que usa a Hessiana literal. Na equação a seguir, será apresentada a matriz Hessiana:

$$H(EQM) = \begin{bmatrix} \frac{\partial^2 EQM}{\partial w_1^2} & \dots & \frac{\partial^2 EQM}{\partial w_1 \partial w_2} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 EQM}{\partial w_N \partial w_1} & \dots & \frac{\partial^2 EQM}{\partial w_N^2} \end{bmatrix} \quad (19)$$

Neste contexto existe o seguinte problema, é necessário calcular a inversa da matriz Hessiana, para que assim possamos ajustar os parâmetros da rede como w_1, w_2 . É possível que aos menos um dos autovalores da Hessiana sejam iguais a zero, o que faz com que o

$\det(H) = 0$, logo, essa matriz não possui inversa, isso torna o seu cálculo muito complicado para ser processado em um computador. Sabendo disso, Levenberg-Marquardt propõe a aproximação da Hessiana de maneira que seja computacionalmente mais rápida, sendo, então:

$$H(EQM) \cong \text{Jacobiano}^T * \text{Jacobiano} \quad (20)$$

Sendo que o *Jacobiano* é o gradiente do algoritmo *backpropagation*. Será mostrada em seguida a matriz Jacobiana:

$$J(EQM) = \begin{bmatrix} \frac{\partial EQM}{\partial w_1} & \dots & \frac{\partial EQM}{\partial w_N} \\ \vdots & \ddots & \vdots \\ \frac{\partial EQM_m}{\partial w_1} & \dots & \frac{\partial EQM_m}{\partial w_n} \end{bmatrix} \quad (21)$$

Nesse presente Trabalho as Hessianas utilizadas serão, conforme Levenberg-Marquardt:

$$H_{w_1} \cong \text{Jacobiano}_{w_1}^T * \text{Jacobiano}_{w_1} \quad (22)$$

$$H_{w_2} \cong \text{Jacobiano}_{w_2}^T * \text{Jacobiano}_{w_2} \quad (23)$$

Ainda assim, pode acontecer do $\det(H) = 0$. Caso isso aconteça, ainda existirá um problema, pois não haverá inversa da Hessiana. Diante desse problema, propôs-se que se $\det(H) = 0$ ou $|\det(H)| \ll \xi$, onde ξ é um valor muito pequeno, então faça:

$$\text{Hessiana} = \text{Hessiana} + \sigma I \quad (24)$$

Deve-se atentar que os termos σ representa um valor muito pequeno, por exemplo, na ordem de 10^{-3} , e I a matriz Identidade. Ao somarmos σ na diagonal principal da Hessiana, na verdade, está somando σ em cada um dos autovalores da Hessiana, logo, aquele que poderia ser zero passará a valer σ . E assim, $\det(H) \neq 0$, havendo a possibilidade de inversa.

Verifica-se, então, que quando estamos utilizando o método de segunda ordem aproxima-se uma quadrática (EQM) por meio de outra quadrática (Hessiana), logo é uma boa aproximação. Já quando utilizamos o método de primeira ordem, aproxima-se uma quadrática (EQM) por meio de uma reta (Jacobiano/ Gradiente).

Como consequência da aplicação do método de segunda ordem, a convergência é mais rápida e requer menos épocas para atingir os níveis de erros determinados pelo projetista. Para este presente trabalho consideraremos uma rede com apenas uma camada escondida, a partir disso iremos calcular $w_1, w_2, \theta_1, \theta_2$, como será mostrado abaixo. Será exemplificado apenas para w_2 e o mesmo servirá para os demais da rede. Para o cálculo de w_2 temos:

Cálculo do Gradiente/Jacobiano:

$$J_{w_2} = \frac{\partial EQM}{\partial w_2} \quad (25)$$

Cálculo da Hessiana:

$$H_{w_2} = Jw_2^T * Jw_2 \quad (26)$$

O ajuste do peso w_2 :

$$w_2 = w_2 - \eta LMw_2^T \quad (27)$$

Onde η , representa a taxa de aprendizado da rede neural, e o LM é o parâmetro de Levenberg-Marquardt que é definido como:

$$LM_{w_2} = (H_{w_2} + \sigma I)^{-1} * Jw_2^T * EQM \quad (28)$$

O Erro Quadrático Médio é um número escalar que no começo do treinamento representa um número grande, pois começamos de maneira aleatória. Então, escalamos a Hessiana por um valor grande, fazendo com que o ajuste de w_i e θ_i sejam grandes, conseqüentemente o método evolui mais rápido, por isso, a importância de se multiplicar pelo EQM. Ao mesmo tempo, deve-se ater que conforme o EQM vai diminuindo, os ajustes ficam menores e faz-se então ajustes finos nos parâmetros.

4. RESULTADOS

A escolha do subsistema SE/CO deve-se ao fato da sua importância geopolítica no Brasil e por estar localizado em minha região. A produção de energia elétrica nesse subsistema é caracterizada por usinas hidrelétricas e térmicas. Para a montagem dos dados escolheu-se um período de 31/05/2015 à 31/03/2017. O período escolhido não interfere nas simulações, existe período diferentes no decorrer do capítulo.

Para se fazer um ajuste e encontrar os melhores parâmetros para o treinamento foram feitas simulações alguns valores de semente, taxa de Levenberg-Marquardt, taxa de aprendizado, número de atrasos, número de neurônios e parâmetros da função de ativação. Para que assim, fosse possível encontrar o melhor resultado. Para tal, foi escolhido um número máximo de épocas igual a 300.

4.1 Simulação com valores de semente iguais para o gerador de números aleatórios (RNG)

Neste contexto, considerou-se:

- ✓ ***Atraso = 10;***
- ✓ ***Número de neurônios = 90;***
- ✓ ***Parâmetros da função de ativação : $\mu = 0.62$ e $b = 0.8$;***
- ✓ ***Alpha = 0.9;***
- ✓ ***Tolerância = $1e^{-1}$;***
- ✓ ***Lambda = $1e^{-3}$;***

Neste sentido, foram feitos com os seguintes valores de semente 60, 100 e 800. Foi escolhido o que apresentou o menor Erro Quadrático Médio (EQM).

$$Rgn = 800 \rightarrow EQM = 0.062694 \quad (29)$$


Para os demais valores testados obteve-se os seguintes resultados:

$$Rgn = 60 \rightarrow EQM = 0.56356 \quad (30)$$

$$Rgn = 100 \rightarrow EQM = 0.74219 \quad (31)$$


Abaixo segue os gráficos referente aos valores considerados acima:

Figura 13 - Considerando $rgn = 60$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



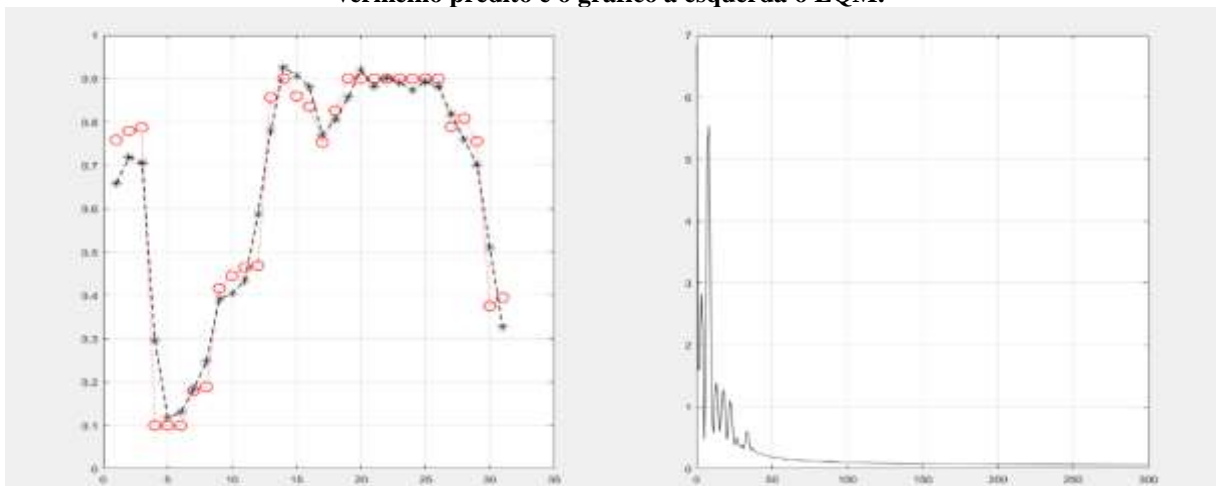
Fonte: Autor.

Figura 14 - Considerando $rgn = 100$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

Figura 15 - Considerando $rgn = 800$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

4.2 Simulação com valores de alpha ou momentum

Neste contexto, considerou-se:

- ✓ **Atraso = 10;**
- ✓ **Número de neurônios = 90;**
- ✓ **Parâmetros da função de ativação : $\mu = 0.62$ e $b = 0.8$;**
- ✓ **$Rgn = 800$;**
- ✓ **Tolerância = $1e^{-1}$;**
- ✓ **$\Lambda = 1e^{-3}$;**

Neste sentido, as simulações foram realizadas com os seguintes valores 0.95, 0.98 e 0.957. Foi escolhido o que apresentou o menor (EQM).

$$\alpha = 0.95 \rightarrow EQM = 0.47605 \quad (32)$$


Para os demais valores testados obteve-se os seguintes resultados:

$$\alpha = 0.957 \rightarrow EQM = 0.084535 \quad (33)$$

$$\alpha = 0.98 \rightarrow EQM = 0.057201 \quad (34)$$


Abaixo segue os gráficos referente aos valores considerados acima:

Figura 16 - Considerando Alpha = 0.95, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.




Fonte: Autor.

Figura 17 - Considerando $\text{Alpha} = 0.98$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

Figura 18 - Considerando $\text{Alpha} = 0.957$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

4.3 Simulação com valores do número de neurônios camada escondida (N_1)

Neste contexto, considerou-se:

- ✓ **Atraso = 10;**
- ✓ **Alpha = 0.95;**
- ✓ **Parâmetros da função de ativação : $\mu = 0.62$ e $b = 0.8$;**
- ✓ **Rgn = 800;**
- ✓ **Tolerância = $1e^{-1}$;**
- ✓ **Lambda = $1e^{-3}$;**

Neste sentido, as simulações foram realizadas com os seguintes valores 60, 100 e 95. Foi escolhido o que apresentou o menor (EQM).

$$N_1 = 95 \rightarrow EQM = 0.046064 \quad (35)$$


Para os demais valores testados obteve-se os seguintes resultados:

$$N_1 = 60 \rightarrow EQM = 0.121862 \quad (36)$$

$$N_1 = 100 \rightarrow EQM = 0.052525 \quad (37)$$


Abaixo seguem os gráficos referente aos valores considerados acima:

Figura 19 - Considerando $N_1 = 60$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.




Fonte: Autor.

Figura 20 - Considerando $N_1 = 100$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

Figura 21 - Considerando $N_1 = 95$, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

4.4 Simulação com valores do número de atraso (atraso)

Neste contexto, considerou-se:

- ✓ *Número de neurônios* = 95;
- ✓ *Alpha* = 0.95;
- ✓ *Parâmetros da função de ativação* : $\mu = 0.62$ e $b = 0.8$;
- ✓ *Rgn* = 800;
- ✓ *Tolerância* = $1e^{-1}$;
- ✓ *Lambda* = $1e^{-3}$;

Neste sentido, as simulações foram realizadas com os seguintes valores 20,30 e 35. Foi escolhido o que apresentou o menor (EQM).

$$\text{atraso} = 30 \rightarrow EQM = 0.005719 \quad (38)$$

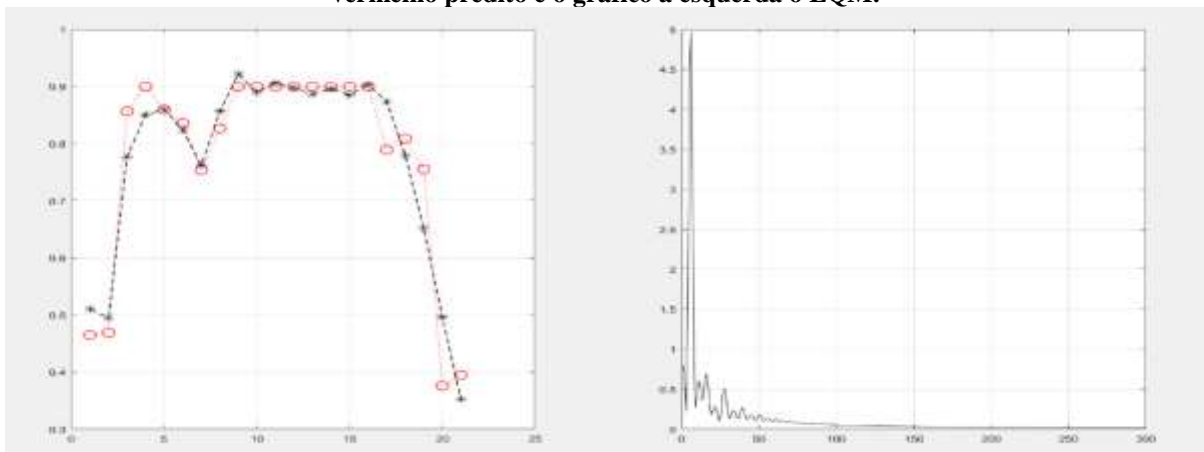
Para os demais valores testados obteve-se os seguintes resultados:

$$\text{atraso} = 20 \rightarrow EQM = 0.024348 \quad (39)$$

$$\text{atraso} = 35 \rightarrow EQM = 0.010201 \quad (40)$$

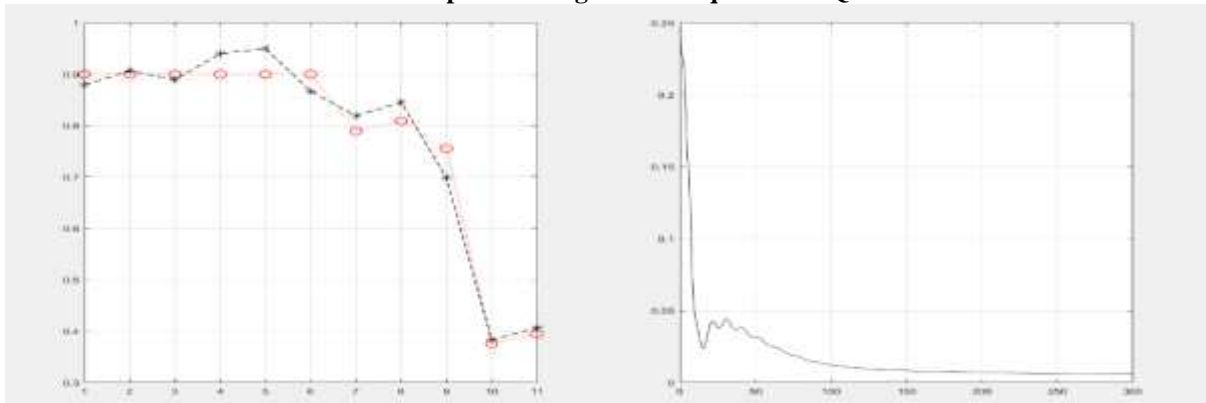
A seguir, tem-se os gráficos referente aos valores considerados acima:

Figura 22 - Considerando atraso = 20, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



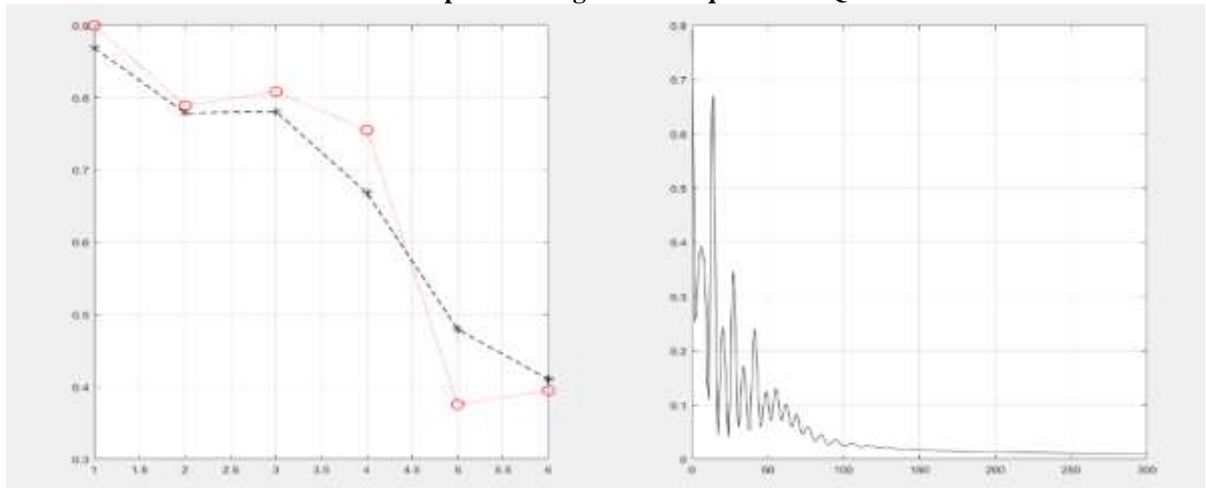
Fonte: Autor.

Figura 23 - Considerando atraso = 30, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

Figura 24 - Considerando atraso = 35, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

4.5 Simulação com valores do número lambda

Neste contexto, considerou-se:

- ✓ *Número de neurônios* = 95;
- ✓ *Alpha* = 0.95;
- ✓ *Parâmetros da função de ativação* : $\mu = 0.62$ e $b = 0.8$;
- ✓ *Rgn* = 800;
- ✓ *Tolerância* = $1e^{-1}$;
- ✓ *Atraso* = 30;

Neste sentido, as simulações foram realizadas com os seguintes valores $1e^{-2}$, $1e^{-3}$ e $1e^{-4}$. Foi escolhido o que apresentou o menor (EQM).

$$\lambda = 1e^{-3} \rightarrow EQM = 0.005719 \quad (41)$$

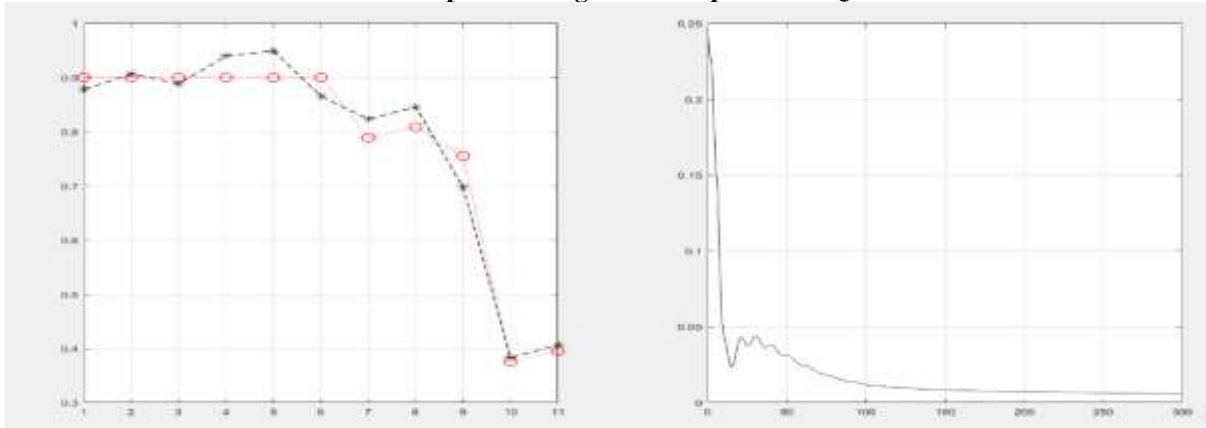
Para os demais valores testados obteve-se os seguintes resultados:

$$\lambda = 1e^{-2} \rightarrow EQM = 0.005827 \quad (42)$$

$$\lambda = 1e^{-4} \rightarrow EQM = 0.005937 \quad (43)$$

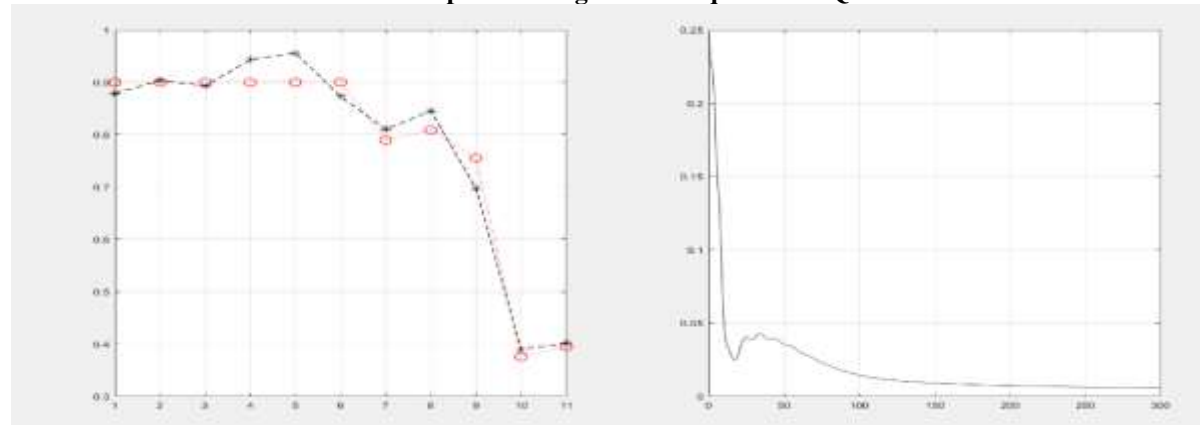
Abaixo segue os gráficos referente aos valores considerados acima:

Figura 25 - Considerando Lambda 1e-2, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.




Fonte: Autor.

Figura 26 - Considerando Lambda 1e-3, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

Figura 27 - Considerando Lambda 1e-4, o Gráfico a esquerda representa em preto o que é esperado e em vermelho predito e o gráfico a esquerda o EQM.



Fonte: Autor.

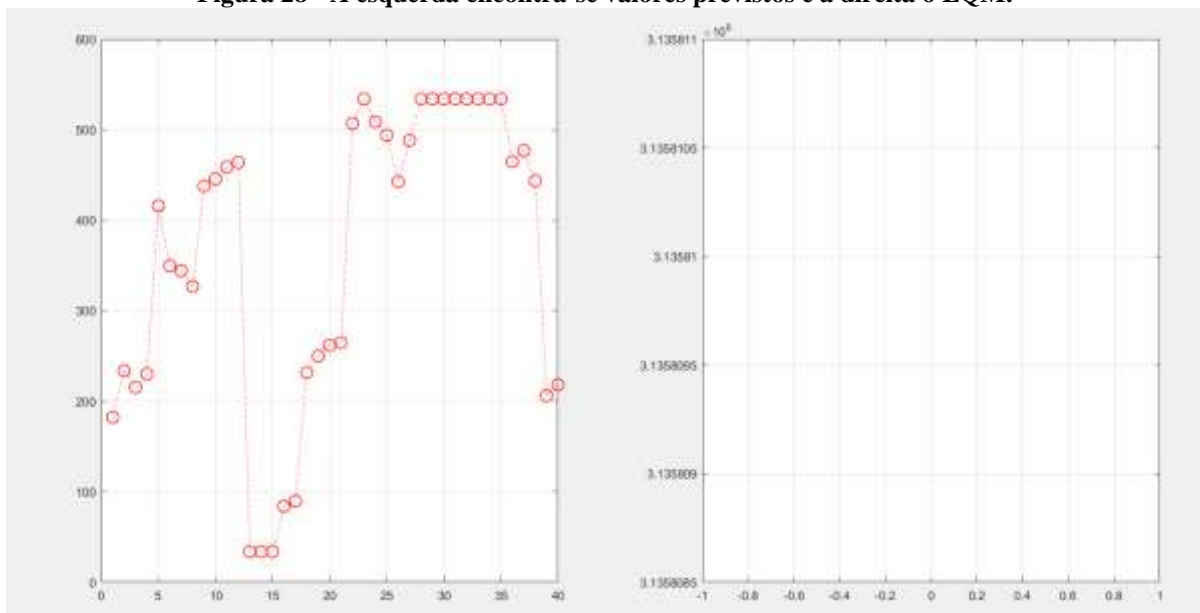
Para o desenvolvimento deste trabalho foram consideradas três abordagens, que serão apresentadas abaixo. Será considerada a melhor abordagem aquela que apresentar o menor erro para um mesmo número de época máxima. Para analisarmos as abordagens e encontrar a melhor resultado foi considerado como parâmetros finais:

- ✓ **Número de neurônios = 95;**
- ✓ **Alpha = 0.95;**
- ✓ **Parâmetros da função de ativação : $\mu = 0.62$ e $b = 0.8$;**
- ✓ **Rgn = 800;**
- ✓ **Tolerância = $1e^{-12}$;**
- ✓ **Lambda = $1e^{-3}$;**
- ✓ **Número de atrasos = 30;**
- ✓ **Épocamax = 300;**

4.6 ABORDAGEM 1

Nesta abordagem considera apenas as entradas como o $PLD(t)$, $EA(t)$, $ENASub(t)$ e $IE(t)$ sem nenhum atraso e prevendo uma semana à frente. Ao realizar o treinamento da rede, o EQM de início com nenhum treinamento foi $EQM = 3135809,611$. Com a passagem de um número de épocas igual a um não foi encontrado o erro pois este extrapolou. Logo, essa abordagem não possui um resultado satisfatório.

Figura 28 - A esquerda encontra-se valores previstos e a direita o EQM.



Fonte: Autor.

4.7 ABORDAGEM 2

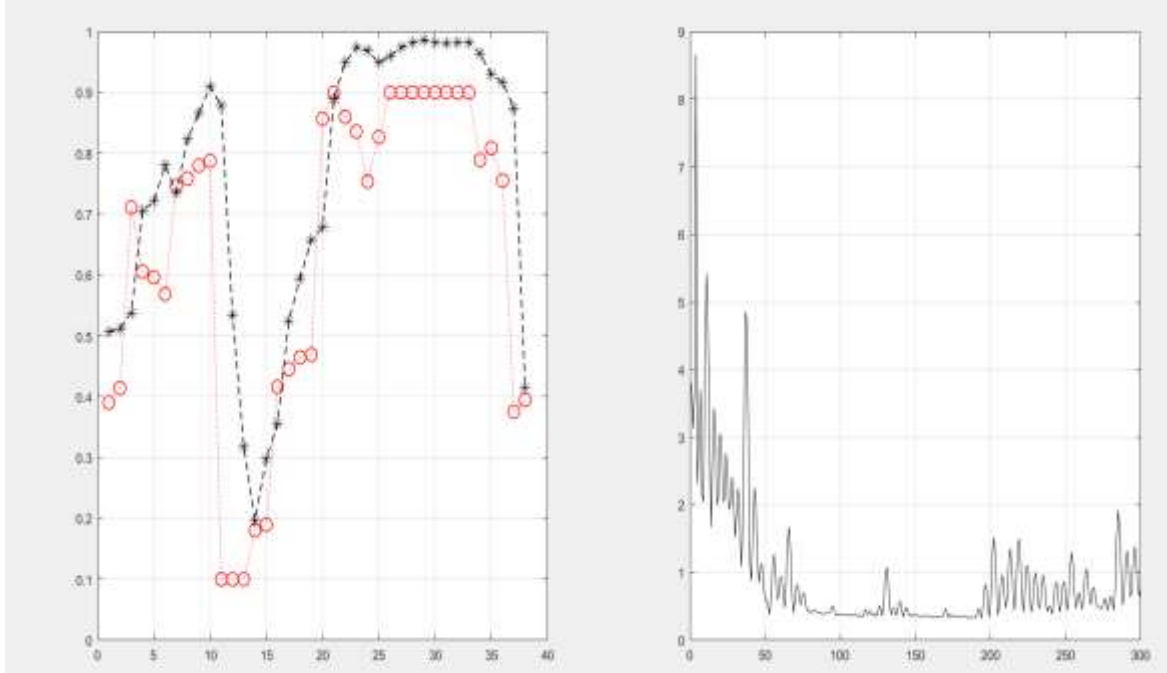
Já nesse estudo foi considerado as variáveis de entrada o $PLD(t)$, e cada uma das entradas atrasadas no tempo. Sendo $N = 30$, onde N é o número de atrasos escolhido.

$$Entrada = \begin{bmatrix} PLD(t) \\ PLD(t - 1) \\ \vdots \\ PLD(t - N) \\ EA(t) \\ EA(t - 1) \\ \vdots \\ EA(t - N) \\ ENASub(t) \\ ENASub(t - 1) \\ \vdots \\ ENASub(t - N) \\ IE(t) \\ IE(t - 1) \\ \vdots \\ IE(t - N) \end{bmatrix}$$

$$Saída = [PLD(t + 1)]$$

A saída $PLD(t + 1)$, significa que o valor do Preço da Liquidação das Diferenças está sendo previsto uma semana à frente.

Figura 29- Primeiro gráfico : Resultado esperado vs obtido e o segundo gráfico EQM ao passar do tempo.



Fonte: Autor.

4.8 ABORDAGEM 3

Adotaremos nessa abordagem como variáveis de entrada:

$$Entrada = \begin{bmatrix} PLD(t) \\ PLD(t-1) \\ \vdots \\ PLD(t-N) \\ EA(t) \\ ENASub(t) \\ IE(T) \end{bmatrix}$$

Sendo $N = 30$, em que N é o número de atrasos, ao realizar um treinamento de 300 épocas obteve-se o seguinte resultado Erro Quadrático Médio obtido $EQM = 0.778190$.

4.9 MELHOR ABORDAGEM


Para o desenvolvimento deste tópico utilizou-se a terceira abordagem, visto que apresentava o menor Erro Quadrático Médio (EQM) após ter sido definido um número máximo de épocas. Apresentando melhor resultado se comparado aos demais.

Como mencionado acima, a partir do momento que foi definido uma melhor abordagem, utilizou-se os dados em um outro período que foi estabelecido acima. Mas, o período não atrapalha no desenvolvimento do estudo.

Pode-se perceber que após um número considerável de épocas obteve um resultado muito satisfatório, obtendo-se um EQM muito pequeno. O que demonstra, que o método abordado prevê o Preço das Liquidações das Diferenças (PLD) com muita exatidão.

$$\triangleright \text{Época} = 185400 \rightarrow EQM = 0.000666 \quad (44)$$

Figura 30 - Figura à esquerda em preto o que é desejado e em vermelho o que é previsto para o PLD. Já na figura à direita o EQM.



Fonte: Autor.

Conforme é possível observar na Figura 30, o EQM foi suficientemente baixo para que os valores desejados pudessem ser atingidos, mostrando um alto grau de acurácia na previsão do valor da próxima semana. Sendo assim, tem-se que a abordagem teve sucesso em seu propósito.

5. CONCLUSÕES E TRABALHOS FUTUROS

Este trabalho mostrou a calibração e utilização de uma rede neural artificial para o propósito de prever o PLD. A técnica de treinamento é a Levenberg-Marquardt com utilização de momentum, que propõe uma aproximação da matriz Hessiana, que é uma técnica de segunda ordem no treinamento de redes neurais artificiais.

Uma série de experimentos de treinamento foram propostos para encontrar uma boa configuração para a rede, uma vez que esta possui diversos parâmetros que, ao serem regulados, podem melhorar o desempenho da mesma. Com a melhor configuração obtida pelos experimentos, foi possível obter um baixo nível de erro entre os dados reais e os dados gerados pela rede neural, mostrando sua eficácia e a sua plausibilidade para a tarefa.

Propõe-se como sugestões para trabalhos futuros:

- Considerar outras variáveis como entrada da rede como Energia Natural Afluente por Bacia, Vazões, Níveis, Capacidade Instalada de Geração entre outras, todas retiradas do site da ONS.
- Comparar o histórico do PLD entre outros subsistemas, para descobrir onde é mais vantajoso comercializar energia e em qual período.
- Como forma de aperfeiçoar o programa e de se obter uma convergência mais rápida, poderia utilizar uma rede recorrente.
- Utilizar outros métodos de Inteligência Artificial associado aos métodos já utilizados, como por exemplo, Enxame de partículas, Fuzzy.

REFERÊNCIAS BIBLIOGRÁFICAS

ABBASI-TARIGHAT, M.; SHAHBAZI, E.; NIKNAM, K. Simultaneous determination of Mn²⁺ and Fe³⁺ as complexes in some foods, vegetable and water samples by artificial neural networks. *Food Chemistry*, London, v. 138, n. 2/3, p. 991-997, June 2013.

ABRACEEL, 2016. Mercado livre é opção para reduzir as contas de luz. Disponível em: <http://www.abraceel.com.br/zpublisher/materias/clipping_txt.asp?id=188185>. Acesso em: 1 set. 2018.

AGHBASHLO, M. et al. The use of artificial neural network to determine the energetic performance of spray drying process: a preliminary study. *Computers and Electronics in Agriculture*, New York, v. 88, p. 32-43, Oct. 2012.

AMJADY, NIMA; DARAEPOUR, ALI. Day-ahead electricity price forecasting using the relief algorithm and neural networks. In: INTERNATIONAL CONFERENCE ON EUROPEAN ELECTRICITY MARKET, 5, 2008. EEM 2008 Proceedings. P.:1 – 7 ... DOI 10.1109/EEM.2008.4579109

ARAÚJO, Luiz E. D., *Concessão de serviço público e ato jurídico perfeito*, 2007.

ASSOCIAÇÃO BRASILEIRA DE DISTRIBUIDORES DE ENERGIA ELÉTRICA, “Visão Geral do Setor”. Disponível em: <<http://www.abradee.com.br/setor-eletrico/visao-geral-do-setor>>. Acesso em: 03 set. 2018.

BAUGHMAN, D. R. ; LIU, Y. A. *Neural networks in bioprocessing and chemical engineering*. San Diego: Academic Press, 1995. 488 p

BBC Brasil, 2014. Custo da energia ameaça frear economia, alertam analistas. Disponível em: <http://www.bbc.com/portuguese/noticias/2014/07/140721_sistema_eletrico_ru>. Acesso em: 05 jul. 2018.

BRAGA, A. de P.; CARVALHO, A. C. P. de L. F.; LUDEMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC, 2000. 262 p.

CAMPOS, R. Júnior. Previsão de séries temporais com aplicações a séries de consumo de energia elétrica. 2008. 110 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Minas Gerais, Minas Gerais, 2008.

CARVALHO, N. B. et al. Artificial neural networks (ANN): prediction of sensory measurements from instrumental data. *Food Science and Technology*, Campinas, v. 33, n. 4, p. 722-729, Nov./Dec. 2013.

CCEE, 2015. Preço Médio da CCEE (R\$/Mwh). Disponível em: <http://www.ccee.org.br/portal/faces/pages_publico/o-que-fazemos/como_ccee_atua/precos/precos_medios?_afLoop=29918275796717#%40%3F_afLoop%3D29918275796717%26_adf.ctrl-state%3D1ctiug20vh_45>. Acesso em: 29 ago. 2018.

CCEE. Câmara Comercializadora de Energia Elétrica. Preço de Liquidação de Diferenças. Brasil 2009. Acesso em 04/09/2018. Disponível em <http://www.ccee.org.br/cceeinterdsm/v/index.jsp?vnextoid=7ccaa5c1de88a010VgnVCM100000aa01a8c0RCRD>.

CCEE. Visão Geral das Operações da CCEE, [S.l.], 2010.

CERETTA, Paulo S; RIGHI, Marcelo B; SCHLENDER, Sergio G. PREVISÃO DO PREÇO DA SOJA: uma comparação entre os modelos ARIMA e redes neurais artificiais. *Revista Informações ECONÔMICAS*, Instituto de Economia Agrícola - Centro de Comunicação e Transferência do Conhecimento. São Paulo. v.40, n.9. 2010 APÊNDICE A – Título.

CHUAHY, Eduardo; VICTER, Wagner Granja. A Construção e a Destruição do Setor Elétrico Brasileiro – Uma análise crítica e histórica de Getúlio Vargas e Fernando Henrique Cardoso. Rio de Janeiro: Relume Dumará, 2002.

COMERCIALIZAÇÃO. Câmara de Comercialização de Energia Elétrica (CCEE). Disponível em: <https://www.ccee.org.br/portal/faces/pages_publico/onde-atuamos/comercializacao?_afLoop=789045258616065#%40%3F_afLoop%3D789045258616065%26_adf.ctrl-state%3D154c19nmpw_34>. Acesso em: 20/08/18.

DIEULOT, J.; SKURTYYS, O. Classification , modeling and prediction of the mechanical behavior of starch-based films. *Journal of Food Engineering*, Essex, v. 119, n. 2, p. 188-195, Nov. 2013.

ELMAN, J. L. Finding structure in time, *Cognitive Science*, vol. 14, p. 179-211, 1990.

EMPRESA DE PESQUISA ENERGÉTICA – EPE – “Plano Decenal de Expansão de Energia – PDE 2008-2017”. In <http://www.epe.gov.br>
http://repositorio.unb.br/bitstream/10482/4034/1/2009_IsabelaSalesVieira.pdf

FARIA, S. et al. Evaluation of extra virgin olive oil stability by artificial neural network. *Food Chemistry*, London, v. 179, p. 35-43, July 2015.

GOKTEPE, A. B. et al. Shear strength estimation of plastic clays with statistical and neural approaches. *Building and Environment*, Oxford, v. 43, n. 5, p. 849- 860, Apr. 2008.

HAGAN, M. T.; MENHAJ, M.; Training feedforward networks with the Marquardt algorithm. *IEEE Transactions Neural Networks*, v.. 5, Nov. 1994.

HAYKIN, S. *Redes neurais: principios e prática*. 2. ed. Porto Alegre: Bookman, 2001. 900 p.

HOPFIELD, J.J.; Neural networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the national Academy of Sciences of the U.S.A.*, n.79, p.2554-8, 1982.

JUDD, J. S, *Neural Network design and Complexity of Learning*. MIT Press, USA, 1990.

KHANLARI, G. R. et al. Prediction of shear strength parameters of soils using artificial neural networks and multivariate regression methods. *Engineering Geology*, Amsterdam, v. 131/132, p. 11-18, Mar. 2012.

KIM, H.; SHIN, K.; A Hybrid Approach Based on Neural Networks and Genetic Algorithms For Detecting Temporal Patterns in Stock Markets. *Applied Soft Computing*, [S.L.], v. 7, n. 2, p.569-576, 2007.

KIMOTO, T, K; ASAKAWA, M; YODA, M. Takeoka. Stock market prediction system with modular neural networks. In *Proceedings of the International Joint Conference on Neural Networks*, volume 1, pages 1–6, 1990.

LAWRENCE, R. Forecasting stock prices using neural networks. Department of Computer Science, University of Manitobo, December 1997.

LEITE, A. L. S.; CASTRO, N. J. ; TIMPONI, R. R. . Preço spot de eletricidade: teoria e evidências do caso brasileiro. In: IV Encontro de Economia Catarinense, 2010, Criciúma. IV Encontro de Economia Catarinense, 2010.

LINDER, R.; PO, S. J. A new neural network approach classifies olfactory signals with high accuracy. *Food Quality and Preference*, Barking, v. 14, n. 5/6, p. 435-440, June 2003.

LOPES, João Eduardo Gonçalves Lopes. Modelo de Planejamento da Operação de Sistemas Hidrotérmicos de Produção de Energia Elétrica. São Paulo, 2007. 141 f Tese (Doutorado). Escola Politécnica da Universidade de São Paulo. Depto de Engenharia Hidráulica e Sanitária. São Paulo, 2007.

LUDWING J.R., OSWALDO; MONTGOMERY, Eduard. Redes Neurais: Fundamentos e Aplicações com Programa em C. Rio de Janeiro: Ciência Moderna, 2007

MAREN, A.; HARSTON, G.; PAP, R.. Handbook of Neural Computing Applications. Califórnia. USA: Academic Press, . 1990.

MCCULLOCH W. & PITTS W.. A Logical Calculus of the Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 5, p. 115-133, 1943.

MENDONÇA, F. J. M. Análise do risco dos contratos de energia elétrica das concessionárias de distribuição. 2008. 110 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal do Maranhão, Maranhão, 2008.

MOHANRAJ, M.; JAYARAJ, S.; MURALEEDHARAN, C. Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems: a review. *Renewable and Sustainable Energy Reviews*, Berlin, v. 16, n. 2, p. 1340-1358, Feb. 2012.

MOHANRAJ, M.; JAYARAJ, S.; MURALEEDHARAN, C. Applications of artificial neural networks for refrigeration, air-conditioning and heat pump systems: a review. *Renewable and Sustainable Energy Reviews*, Berlin, v. 16, n. 2, p. 1340-1358, Feb. 2012.

MOZER, M. C. A focused back-propagation algorithm for temporal pattern recognition University of Toronto, 1988.

MÜLLER, Eduardo; SANTOS, Edmilson dos. Uso Político do Setor Elétrico Brasileiro. Uma Metodologia de Análise Baseada na Teoria de Grupos de Pressão. Rio de Janeiro: Synergia; São Paulo: FAPES, 2010.

NASCIMENTO J.R., L Cairo; YONEYANA, Takashy. Inteligência Artificial em Controle de Automação. São Paulo: FAPESP, 2004.

NEWBERY, D. Competition, Contracts and Entry in the Electricity Spot Market. *Rand Journal of Economics*, vol. 29(4), 1998, pp. 726-749.

NEWBERY, D. Privatization, restructuring and regulation of network utilities. Cambridge, MA, MIT Press, 1999.

OLIVI, Leonardo. Redes Neurais Artificiais. 2017. 23 slides.

ONS, 2018. O Sistema Interligado Nacional. Disponível em: <<http://ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>>. Acesso em: 04 set. 2018.

Operador Nacional do Sistema Elétrico –ONS (2008) “ Desempenho das Interligações Regionais”. In : ONS RE-3/250/2007 – Planejamento da Operação Elétrica de Médio Prazo PEL – Jan/2008 a Abr/2009 – Dados Relevantes 2007”.

PESSANHA, A. J. Estratégia de contratação de energia elétrica em leilões regulados: aplicação de um modelo de simulação e otimização. 2007. 130 f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal Fluminense. Rio de Janeiro, 2007.

PHIMOLSIRIPOL, Y.; SIRIPATRAWAN, U.; CLELAND, D. J. Weight loss of frozen bread dough under isothermal and fluctuating temperature storage conditions. *Journal of Food Engineering*, Essex, v. 106, n. 2, p. 134-143, Sept. 2011.

RAI, P.; MAJUMDAR, G. C.; DASGUPTA, S. Prediction of the viscosity of clarified fruit juice using artificial neural network : a combined effect of concentration and temperature. *Journal of Food Engineering*, Essex, v. 68, n. 4, p. 527-533, June 2005.

RAI, P.; MAJUMDAR, G. C.; DASGUPTA, S. Prediction of the viscosity of clarified fruit juice using artificial neural network : a combined effect of concentration and temperature. *Journal of Food Engineering*, Essex, v. 68, n. 4, p. 527-533, June 2005.

ROSENBLATT, F. The Perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*. v. 65, p. 386-408, 1958.

SAMPAIO, Thiago da Silva. Reguladores, regulados e consumidores: Estudo de caso sobre a Aneel. Brasília, 2010.

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

SILVA, I. N., SPATTI, D. H. e FLAUZINO, R. A. Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas, 1ª ed, São Paulo: Artliber, 2010.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. São Paulo: Artliber, 2000. 399 p.

STEINER, M.; WITTKEMPER, Hans-Georg. Neural networks as an alternative stock market model. In *Neural Networks in the Capital Markets*, chapter 9, pages 137–148. John Wiley and Sons, 1995.

TASHPULATOV, S. N. Estimating the volatility of electricity prices: The case of the England and Wales wholesale electricity market. *Energy Policy*, v. 60, p. 81–90, 2013. Elsevier.

TOSHIOKA, Frank. Previsão de preço semanal de energia elétrica através de Redes Neurais Artificiais com limites de saturação. Curitiba. 2017.

VAHDINASAB, V; JADID, S.; KAZEMI, A.. Day-ahead price forecasting in restructured Power systems using artificial neural networks. *Electric Power Systems Research*. n. 78, p. 1332-1342. 2008.

VALENÇA, M .Fundamento das Redes Neurais: Exemplos em Java. 2ª Edição. Olinda: Livro Rápido – Elógica, 2009.

WAIBEL, A., HANAZAWA, T., HINTON, G., SHIKANO, K. E LANG, K. Phonemic Recognition using Time Delay Neural Networks. *IEEE Trans. Acoust., Speech, Signal Processing*, vol. 37, n. 3, pp. 328-339, 1989.