

ROMERO ÁLAMO OLIVEIRA DE MEDEIROS

**PREVISÃO DE DEMANDA NO MÉDIO PRAZO UTILIZANDO REDES NEURAIS
ARTIFICIAIS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

JOÃO PESSOA

2016

ROMERO ÁLAMO OLIVEIRA DE MEDEIROS

**PREVISÃO DE DEMANDA NO MÉDIO PRAZO UTILIZANDO REDES NEURAIS
ARTIFICIAIS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito para a obtenção do título de Mestre em Engenharia Elétrica.

Orientadores:

Prof. Dr. Juan Moises Maurício Villanueva

Prof. Dr. Yuri Percy Molina Rodriguez

JOÃO PESSOA

2016

ROMERO ÁLAMO OLIVEIRA DE MEDEIROS

**PREVISÃO DE DEMANDA NO MÉDIO PRAZO UTILIZANDO REDES NEURAIS
ARTIFICIAIS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Elétrica - PPGEE, da Universidade Federal da Paraíba - UFPB, como requisito para a obtenção do título de Mestre em Engenharia Elétrica.

Orientadores:

Prof. Dr. Juan Moises Maurício Villanueva

Prof. Dr. Yuri Percy Molina Rodriguez

JOÃO PESSOA

2016

FICHA CATALOGRÁFICA

M488p Medeiros, Romero ÁlamO Oliveira de.
Previsão de demanda no médio prazo utilizando redes neurais artificiais em sistemas de distribuição de energia elétrica / Romero ÁlamO Oliveira de Medeiros.- João Pessoa, 2016.
85f.
Orientadores: Juan Moises Maurício Villanueva, Yuri Percy Molina Rodriguez
Dissertação (Mestrado) - UFPB/CEAR
1. Engenharia elétrica. 2. Previsão de demanda. 3. Energia elétrica - distribuição. 4. Previsão de séries temporais. 5. Redes neurais artificiais. 6. Inteligência artificial.

UFPB/BC

CDU: 621.3(043)

UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB
CENTRO DE ENERGIAS ALTERNATIVAS E RENOVÁVEIS – CEAR
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA - PPGE

A Comissão Examinadora, abaixo assinada, aprova a Dissertação

**PREVISÃO DE DEMANDA NO MÉDIO PRAZO UTILIZANDO REDES NEURAIS
ARTIFICIAIS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

Elaborada por

ROMERO ÁLAMO OLIVEIRA DE MEDEIROS

como requisito para obtenção do grau de
Mestre em Engenharia Elétrica.

COMISSÃO EXAMINADORA

PROF. DR. JUAN MOISES MAURÍCIO VILLANUEVA (Orientador)

PROF. DR. YURI PERCY MOLINA RODRIGUEZ (Orientador)

PROF. DR. HELON DAVID DE MACÊDO BRAZ (Examinador Interno)

PROF. DR. EULER CÁSSIO TAVARES DE MACEDO (Examinador Interno)

PROF. DR. ROGÉRIO GASPAS DE ALMEIDA (Examinador Externo)

João Pessoa/PB, 29 de julho de 2016.

*À minha adorável esposa Valdênia,
compreensiva, amorosa e companheira
em todos os momentos, dedico.*

AGRADECIMENTOS

Meus agradecimentos não seriam verdadeiros se primeiramente eu não ajoelhasse perante Deus. Só Ele sabe o que passei nesses dois anos e sou extremamente grato pelos momentos de superação que me fizeram chegar até aqui.

Agradeço à minha esposa Val que acompanhou de perto e, praticamente, caminhou comigo nessa jornada, pois, nos tornamos uma só carne neste período. Não só tenho tamanha gratidão como também, peço desculpas por diversos momentos de estresse e aborrecimento.

Agradeço aos meus pais por acreditarem nas minhas escolhas desde o dia em que marquei o código de engenharia elétrica para o vestibular. Minha mãe, que sempre me recebeu com uma palavra de conforto e um sorriso revigorante, meus irmãos pelos momentos de descontração, especialmente Raphael, recarregando minhas energias a cada final de semana.

Agradeço aos meus orientadores Dr. Juan Maurício e Dr. Yuri Molina por todo apoio e orientações dadas neste período. Aos professores Dr. Euler Macedo, pela oportunidade no GICA, e Dr. Helon Braz, pelos incentivos à carreira acadêmica.

Agradeço a todos amigos e familiares que puderam estar presentes nos momentos de lazer.

Agradeço aos colegas de laboratório Igor, Ricardos, Felipes, Douglas, Rodolfo, Mateus, Bruno, José, Kleyton, Fernanda, Gabriel, Joel, Diego e Dennyse. Aos colegas de mestrado Jeane, Priscila, Caio, Francisco, Tati, Dayanna, Léo, João, Rafaéis, Carlinhos e Wendell. E, ao técnico Elder. Todos fizeram com que os dias na UFPB tivessem um significado especial.

Agradeço ao apoio da Energisa/PB, pelo incentivo à pesquisa e por disponibilizar os dados utilizados neste trabalho.

“ Nossa maior fraqueza é a desistência.
O caminho mais certo para o sucesso
é sempre tentar apenas mais uma vez. ”

Thomas Alva Edison

LISTA DE ILUSTRAÇÕES

FIGURA 2.1 - O SISTEMA ELÉTRICO DE POTÊNCIA, DA GERAÇÃO AO CONSUMIDOR FINAL.	7
FIGURA 2.2 - USINA HIDRELÉTRICA DE ITAIPU.	8
FIGURA 2.3 - SISTEMA INTERLIGADO NACIONAL (SIN), HORIZONTE 2015	9
FIGURA 2.4 - CENTRAIS ELÉTRICAS QUE COMPÕEM OS SISTEMAS ISOLADOS - SITUAÇÃO EM OUTUBRO DE 2003	10
FIGURA 2.5 - SUBESTAÇÃO DE RIO TINTO II (ENERGISA/PB), DO TIPO ABAIXADORA 69/13,8 KV.	11
FIGURA 2.6 - DIAGRAMA UNIFILAR SIMPLIFICADO DA SUBESTAÇÃO ABAIXADORA.	12
FIGURA 2.7 - SISTEMA DE AQUISIÇÃO DE DADOS.	13
FIGURA 2.8 - EXEMPLOS DE SÉRIES TEMPORAIS: A) LEITURA DE DUAS EM DUAS HORAS DE UMA CONCENTRAÇÃO “X” EM PROCESSO QUÍMICO; B) VARIAÇÃO DIÁRIA DO PREÇO DAS AÇÕES DA IBM; C) LEITURA DE TEMPERATURA EM PROCESSO QUÍMICO A CADA MINUTO; D) LEITURA HORÁRIA DA VISCOSIDADE EM PROCESSO QUÍMICO.	13
FIGURA 2.9 - PERFIL DE CARGA DIÁRIO (DIA TÍPICO) DA SUBESTAÇÃO DE CAJAZEIRAS (CJZ).	15
FIGURA 2.10 - MODELO DO NEURÔNIO ARTIFICIAL.	19
FIGURA 2.11 - REDE NÃO RECORRENTE <i>FEEDFORWARD</i>	22
FIGURA 2.12 - REDE RECORRENTE DO TIPO ELMAN.	23
FIGURA 2.13 – ARQUITETURA DE UMA REDE NEURAL ARTIFICIAL DO TIPO MLP.	23
FIGURA 2.14 - FLUXO DO SINAL EM UM NEURÔNIO J.	24
FIGURA 2.15 - ARQUITETURA DE UMA RNA COM ALGORITMO RPROP.	26
FIGURA 2.16 - PREVISÃO DE SÉRIES TEMPORAIS.	27
FIGURA 2.17 - RNA COM MEMÓRIA DE LINHA DE ATRASO.	28
FIGURA 3.1 - DIAGRAMA UNIFILAR SIMPLIFICADO DE UMA SUBESTAÇÃO.	30
FIGURA 3.2 - EXEMPLO DE CORREÇÃO DE <i>OUTLIERS</i>	31
FIGURA 3.3 - DIAGRAMA UNIFILAR SIMPLIFICADO DA SUBESTAÇÃO 3 (SE3).	34
FIGURA 3.4 - CONJUNTOS (JANELAMENTO) DE ENTRADAS/SAÍDA DA RNA ...	34
FIGURA 3.5 - REALIMENTAÇÃO DA PREVISÃO NOS CONJUNTOS DE VALIDAÇÃO E TESTE.	37
FIGURA 3.6 - CONFIGURAÇÃO TIPO 2 DE ENTRADAS/SAÍDA DA RNA.	38
FIGURA 3.7 - CONFIGURAÇÃO TIPO 3 DE ENTRADAS/SAÍDA DA RNA.	40
FIGURA 3.8 - CONFIGURAÇÃO TIPO 4 DE ENTRADAS/SAÍDA DA RNA.	41
FIGURA 3.9 – GRÁFICO DA TAXA DE CRESCIMENTO DO PONTO 12B1 DA SE1	42
FIGURA 3.10 - CONFIGURAÇÃO TIPO 5 DE ENTRADAS/SAÍDA DA RNA.	43

FIGURA 4.1 - GRÁFICO DA POTÊNCIA MÁXIMA SEMANAL - SE1.....	47
FIGURA 4.2 - GRÁFICO DA POTÊNCIA MÁXIMA SEMANAL - SE2.....	47
FIGURA 4.3 - GRÁFICO DA POTÊNCIA MÁXIMA SEMANAL - SE3.....	48
FIGURA 4.4 - GRÁFICO DA DEMANDA X SEMANAS – JANELA DE 4 SEMANAS – SE1.	49
FIGURA 4.5 - GRÁFICO DA DEMANDA X SEMANAS – JANELA DE 26 SEMANAS – SE1.....	50
FIGURA 4.6 - GRÁFICO DA DEMANDA X SEMANAS – JANELA DE 12 SEMANAS – SE2.....	51
FIGURA 4.7 - GRÁFICO DA DEMANDA X SEMANAS – JANELA DE 4 SEMANAS – SE3.	52
FIGURA 4.8 – GRÁFICOS, COM JP = 4 E 12 SEMANAS, DAS PREVISÕES COM 1 E 2 CAMADAS OCULTAS – SE2.	54
FIGURA 4.9 - GRÁFICOS, COM JP = 26 E 52 SEMANAS, DAS PREVISÕES COM 1 E 2 CAMADAS OCULTAS – SE2.	55
FIGURA 4.10 - GRÁFICOS, COM JP = 4 E 12 SEMANAS, DAS PREVISÕES COM 1 E 2 CAMADAS OCULTAS – SE3.	56
FIGURA 4.11 - GRÁFICOS, COM JP = 26 E 52 SEMANAS, DAS PREVISÕES COM 1 E 2 CAMADAS OCULTAS – SE3.	57
FIGURA 4.12 - GRÁFICOS DA COMPARAÇÃO ENTRE AS RNA'S COM DADOS A PARTIR DE 2008, 2009 E 2010 – SE1.....	59
FIGURA 4.13 - RESULTADOS OBTIDOS DA COMPARAÇÃO ENTRE OS DOIS ALGORITMOS – SE2.	61

LISTA DE TABELAS

TABELA 3.1 - DADOS DE POTÊNCIA ATIVA, INTERVALOS DE 15 EM 15 MINUTOS.	32
TABELA 3.2 - DADOS DE POTÊNCIA MÁXIMA DIÁRIA.	32
TABELA 3.3 - DADOS DE POTÊNCIA MÁXIMA SEMANAL.	33
TABELA 3.4 - CARACTERÍSTICAS DO MODELO DE COMPUTADOR UTILIZADO.	35
TABELA 3.5 – COMBINAÇÕES E OS PARÂMETROS PARA CÁLCULO DO TEMPO MÉDIO DE SIMULAÇÃO.....	36
TABELA 3.6 - EXEMPLO DE DADOS DE ENTRADA E SAÍDA – CONFIGURAÇÃO TIPO 1.	38
TABELA 3.7 - EXEMPLO DE DADOS DE ENTRADA E SAÍDA – CONFIGURAÇÃO TIPO 2.	39
TABELA 3.8 - EXEMPLO DE DADOS DE ENTRADA E SAÍDA – CONFIGURAÇÃO TIPO 3.	40
TABELA 3.9 - EXEMPLO DE DADOS DE ENTRADA E SAÍDA – CONFIGURAÇÃO TIPO 4.	42
TABELA 3.10 - EXEMPLO DE DADOS DE ENTRADA E SAÍDA – CONFIGURAÇÃO TIPO 5.	43
TABELA 3.11 – EVOLUÇÃO DAS TÉCNICAS UTILIZADAS EM CADA UMA DAS CONFIGURAÇÕES.	44
TABELA 4.1 - COMPARATIVO ENTRE OS TIPOS DE CONFIGURAÇÕES PARA UMA JANELA DE 4 SEMANAS – SE1.	48
TABELA 4.2 - COMPARATIVO ENTRE OS TIPOS DE CONFIGURAÇÕES PARA UMA JANELA DE 26 SEMANAS – SE1.	50
TABELA 4.3 - COMPARATIVO ENTRE OS TIPOS DE CONFIGURAÇÕES PARA UMA JANELA DE 12 SEMANAS – SE2.	51
TABELA 4.4 - COMPARATIVO ENTRE OS TIPOS DE CONFIGURAÇÕES PARA UMA JANELA DE 4 SEMANAS – SE3.	52
TABELA 4.5 - RESULTADOS DAS PREVISÕES DAS RNA'S COM 1 E 2 CAMADAS OCULTAS NA SE2.....	53
TABELA 4.6 - RESULTADOS DAS PREVISÕES DAS RNA'S COM 1 E 2 CAMADAS OCULTAS NA SE3.....	56
TABELA 4.7 – RESULTADOS OBTIDOS QUANDO DA VARIAÇÃO DE DADOS APRESENTADOS À RNA – SE2.	58
TABELA 4.8 - RESULTADOS OBTIDOS DA COMPARAÇÃO ENTRE OS DOIS ALGORITMOS – SE2.	60
TABELA 4.9 - DIFERENÇA NO TEMPO DE SIMULAÇÃO ENTRE OS ALGORITMOS.	60

RESUMO

PREVISÃO DE DEMANDA NO MÉDIO PRAZO UTILIZANDO REDES NEURAIS ARTIFICIAIS EM SISTEMAS DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA

Os estudos de previsão de demanda têm grande importância para empresas da área de energia elétrica, pois, existe a necessidade de alocar seus recursos com uma certa antecedência, exigindo um planejamento a médio e longo prazo. Dentre estes recursos, estão a compra de equipamentos, a aquisição e construção de linhas de transmissão, manutenções programadas e a compra e venda de energia. Nesta premissa, foi desenvolvida uma ferramenta de apoio aos especialistas na área de planejamento estratégico em sistemas de distribuição de energia elétrica, utilizando redes neurais artificiais para previsão de demanda. Para o método proposto, foi implementado um procedimento de previsão de demanda no médio prazo da região alimentada por três subestações reais pertencentes ao sistema de distribuição de energia gerido pela concessionária Energisa-PB, utilizando um modelo computacional baseado em redes neurais artificiais (RNA) do tipo *Multilayer Perceptron* (MLP) com o auxílio do ambiente Matlab®. Foram consideradas as informações reais (banco de dados) da potência ativa, para o período de 2008 até 2014, fornecidas pela própria concessionária e a previsão alcançou o horizonte de um ano a frente (52 semanas). A RNA foi treinada com os dados de 2008 a 2013, e o resultado, comparado com dados do ano de 2014. Além disso, foi possível avaliar o desempenho da RNA sob diferentes aspectos (volume de treinamento, parâmetros, configurações, camadas ocultas, etc.) e estimar o crescimento de demanda da região alimentada por cada subestação, o que pode auxiliar o planejamento de expansão do sistema de distribuição.

Palavras chaves: Previsão de Demanda, Distribuição de Energia Elétrica, Previsão de Séries Temporais, Redes Neurais Artificiais, Inteligência Artificial.

ABSTRACT

MIDDLE TERM DEMAND FORECASTING USING ARTIFICIAL NEURAL NETWORKS IN POWER DISTRIBUTION SYSTEM

The demand forecasting studies are of great importance for electricity companies, because there is a need to allocate their resources well in advance, requiring a medium and long-term planning. These resources can be the purchase of new equipment, the transmission line acquisition or construction, scheduled maintenance and the purchase and sale of energy. In this work, a support tool has been developed for experts in strategic planning in power distribution systems using artificial neural networks to demand forecasting. For the proposed method, it implemented a demand forecasting procedure in the medium term of the region fueled by three substations belonging to the power distribution system managed by Energisa-PB, using a computer model based on Multilayer Perceptron (MLP) artificial neural networks with the assistance of Matlab® environment. The database was structured by the measurements of active power from 2008 to 2014, provided by Energisa/PB and the forecast achieved one year ahead (52 weeks) compared with the real data of 2014. In addition, it was possible to evaluate the performance of RNA and estimate the demand growth in the region supplied by each substation, which can assist the distribution system expansion planning.

Keywords: Demand Forecasting, Electric Energy Distribution, Time Series Forecasting, Artificial Neural Networks, Artificial Intelligence.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	MOTIVAÇÃO E RELEVÂNCIA DO TRABALHO	1
1.2	OBJETIVOS	3
1.2.1	Geral	3
1.2.2	Específicos	3
1.3	ORGANIZAÇÃO	5
2	FUNDAMENTAÇÃO TEÓRICA	7
2.1	O SISTEMA ELÉTRICO	7
2.2	SÉRIES TEMPORAIS	13
2.3	MOTIVAÇÃO: TÉCNICA DE PREVISÃO	17
2.4	REDES NEURAIS ARTIFICIAIS	17
2.4.1	Histórico	18
2.4.2	O Neurônio Artificial	19
2.4.3	Arquitetura de uma Rede Neural	21
2.4.4	Perceptrons de Múltiplas Camadas (MLP)	23
2.4.5	Taxas de Aprendizado e Momentum	25
2.4.6	Retropropagação Resiliente (<i>Resilient Backpropagation</i>)	25
2.5	PREVISÕES DE SÉRIES TEMPORAIS UTILIZANDO RNA	26
3	MÉTODO PROPOSTO DE PREVISÃO DE DEMANDA	30
3.1	PREPARAÇÃO DOS DADOS	30
3.2	TREINAMENTO DA RNA	34
3.2.1	Parâmetros de Treinamento	35
3.3	VALIDAÇÃO E TESTE DA RNA	36
3.4	EVOLUÇÃO DO MODELO PROPOSTO	37
3.4.1	Conversão das Semanas em Números Binários	38
3.4.2	Normalização dos Dados	39
3.4.3	Método das Diferenças	41
3.4.4	Taxa de Crescimento de Energia	42
4	RESULTADOS	46
4.1	DADOS DE TREINAMENTO, VALIDAÇÃO E TESTE	46
4.2	VARIAÇÃO DE CONFIGURAÇÕES	48

4.3	UTILIZAÇÃO DE UMA OU DUAS CAMADAS INTERMEDIÁRIAS	53
4.4	VARIAÇÃO DO VOLUME DE DADOS.....	57
4.5	COMPARAÇÃO ENTRE ALGORITMOS.....	60
5	CONCLUSÕES	64
6	REFERÊNCIAS.....	67

1 INTRODUÇÃO

1 INTRODUÇÃO

1.1 MOTIVAÇÃO E RELEVÂNCIA DO TRABALHO

Prever o futuro sempre foi um objetivo a ser alcançado pelo ser humano. Desde antigamente, quando tentava prever a época de uma colheita ou período de chuvas, o homem busca prever o futuro para tomar decisões no presente, e, uma das formas de fazer isso é, normalmente, estudar, avaliar e observar o passado. A capacidade de predição é bastante útil em diversas áreas, como por exemplo, meteorologia, bolsa de valores, comércio, abastecimento de água, etc. Enfim, diversos segmentos necessitam da análise dos dados do passado para predizer ou prever acontecimentos e assim, poder tomar decisões no presente.

As empresas de distribuição de energia elétrica devem elaborar relatórios periódicos de previsões de demanda das cargas localizadas em sua área de concessão, nos horizontes definidos pelo Operador Nacional do Sistema (ONS) e pela Empresa de Pesquisa Energética (EPE) (RIBEIRO *et al.*, 2006). Além destes estudos de previsão, as empresas de distribuição também realizam estudos internos, com o objetivo de planejamento das decisões de operação, controle e manutenção de seus sistemas. Dentre os recursos que exigem uma certa antecedência na alocação, estão: a compra de equipamentos, aquisição e construção de novas linhas de transmissão, manutenções programadas e a compra e venda de energia.

A previsão de demanda pode ser feita para os horizontes de longo, médio, curto e curtíssimo prazo (PAN; LEE, 2012). A diversidade de horizontes de planejamento torna o processo de previsão de demanda uma tarefa extremamente complexa. A previsão de longo prazo tem como horizonte anos ou décadas e tem como objetivo possibilitar o planejamento para aumentar a capacidade das linhas de transmissão ou construção de novas plantas geradoras. A previsão de curto prazo tem como horizonte algumas horas e pode avaliar a segurança do sistema, analisar sua confiabilidade, planejar manutenções, etc. A previsão de curtíssimo prazo prevê minutos à frente e é bastante importante na regulação entre a demanda e a oferta por energia elétrica a fim de evitar flutuações, ajustando a geração de energia à constantes mudanças (CARMONA *et al.*, 2002).

A previsão de demanda de médio prazo, que ocorre desde semanas até meses, permite às concessionárias e empresas de energia elétrica alocar seus recursos como: manutenções nas redes elétricas, a compra de equipamentos, expansão do seu sistema, estratégias no mercado de energia (GHIASSI; ZIMBRA; SAIDANE, 2006) e (PAN; LEE, 2012).

Em Karayiannis *et al.* (2003) destacaram-se os seguintes aspectos quanto à importância da previsão de demanda:

- Distribuição econômica das unidades geradoras;
- Intercâmbio de energia entre empresas;
- Programação da produção, que pode resultar em economia para os consumidores;
- Redução do consumo de energia;
- Diminuição da poluição ambiental.

A Agência Nacional de Energia Elétrica (ANEEL) define os “Procedimentos de Distribuição de Energia Elétrica - PRODIST” em ANEEL (2005), no qual, o objetivo de se regular a atividade de planejamento, no âmbito da distribuição, é permitir uma expansão adequada do sistema elétrico, visando atender os interesses da sociedade (produtores e consumidores), tentando evitar investimentos imprudentes, que acarretariam aumentos desnecessários de tarifas.

Em uma visão de longo prazo, este intervalo deve ser de cinco a dez anos, se aproximando do limite superior (dez) para a rede de transmissão e subestações, e do limite inferior (cinco) para a rede de distribuição. Isso se justifica pelo tempo maior de maturação das obras de transmissão e subestação e, menor, das obras na rede de distribuição. A atualização destes planos deve ser anual, de forma a permitir ao regulador e à sociedade acompanhar as mudanças de tendências nos investimentos, bem como, comparar o que foi planejado e o que foi efetivamente implementado, considerando, naturalmente, as motivações e barreiras de caráter econômico, financeiro, estrutural, organizacional, legal, ambiental, etc. (SANTOS; HADDAD; CRUZ, 2008). Os estudos de previsão de demanda tem o objetivo de auxiliar nesta atualização anual do plano de expansão.

Com a idéia de sempre buscar uma melhor exatidão nos resultados de previsão, uma série de métodos vem sendo desenvolvidos, adaptados e melhorados ao longo do tempo. Antes de surgir a inteligência artificial, somente os métodos estatísticos e probabilísticos, liderados pelos modelos Box e Jenkins (BOX; JENKINS; REINSEL, 2008), eram aplicados em séries temporais para previsão. A partir do desenvolvimento de técnicas computacionais que tinham maior vantagem frente a grandes não linearidades dos dados e não dependiam de complexos modelos matemáticos, métodos baseados em inteligência artificial, liderados pelas redes neurais e lógica fuzzy, começaram a ser utilizados em previsão de demanda. Além desses, foram desenvolvidos métodos híbridos, que combinavam dois ou mais métodos, sendo eles estatísticos ou artificialmente inteligentes.

Apesar de todas as classes de métodos citados conseguirem, ao seu modo, alcançar resultados satisfatórios, estas técnicas continuam sendo aperfeiçoadas e novos métodos têm sido desenvolvidos com a finalidade de melhorar a exatidão e a confiabilidade da previsão, para que, aí sim, estes resultados venham a ser utilizados como ferramentas de auxílio no planejamento a médio e longo prazo, contribuindo para alocação dos recursos no setor elétrico.

1.2 OBJETIVOS

O objetivo geral desta dissertação e seus objetivos específicos são apresentados, respectivamente, nas seções, 1.2.1 e 1.2.2.

1.2.1 Geral

- Desenvolver uma ferramenta computacional de apoio aos especialistas na área de planejamento estratégico em sistemas de distribuição de energia elétrica, utilizando redes neurais artificiais para previsão de demanda.

1.2.2 Específicos

- Realizar uma introdução teórica acerca dos conceitos mais necessários à implementação método proposto: o sistema elétrico, as séries temporais e as técnicas mais utilizadas para previsão, enfatizando as redes neurais artificiais;

- Implementar um procedimento computacional de previsão de demanda baseado em redes neurais do tipo MLP (*multilayer perceptron*);
- Apresentar os resultados obtidos e discutir sua importância em estudos de expansão do sistema de distribuição.

1.3 ORGANIZAÇÃO

Esta dissertação foi estruturada em seis capítulos. No Capítulo 1 é apresentada uma introdução, contendo os propósitos e as motivações do trabalho. Os objetivos são estabelecidos e a organização do texto é citada em tópicos. No capítulo 2 é introduzida a fundamentação teórica composta das considerações a respeito do Sistema Elétrico de Potência (SEP) e as características dos sistemas de geração, transmissão e distribuição de energia elétrica, além dos conceitos relacionados à previsão de séries temporais e apresentação dos métodos estatísticos e baseados em inteligência artificial mais utilizados na área, enfatizando as redes neurais artificiais do tipo MLP (*MultiLayer Perceptron*) com algoritmo de retropropagação resiliente (*resilient backpropagation*).

No Capítulo 3, é apresentada a metodologia de previsão utilizada nesta dissertação, desde a fase de treinamentos, validação, até os testes finais. Os tipos de configurações e parâmetros são exibidos neste capítulo.

No Capítulo 4, os resultados das simulações são apresentados. Para um melhor entendimento, os resultados são divididos em etapas e a visualização consiste na apresentação de tabelas e gráficos com as melhores aproximações. No Capítulo 5, é apresentada a conclusão do trabalho, verificando se os objetivos traçados foram alcançados e analisando os trabalhos futuros que poderiam tomar como base inicial esta dissertação. E, finalmente, no capítulo 6, são apresentadas as referências bibliográficas utilizadas neste trabalho.


2 FUNDAMENTAÇÃO TEÓRICA

2 FUNDAMENTAÇÃO TEÓRICA

2.1 O SISTEMA ELÉTRICO

A principal função do Sistema Elétrico de Potência (SEP) é fornecer energia elétrica aos usuários, com qualidade apropriada, na medida em que essa for solicitada, convertendo energia de naturezas diversas (hidráulica, mecânica, térmica etc.) em energia elétrica e assim, distribuindo aos consumidores (KAGAN; OLIVEIRA; ROBBA, 2005) e (ANDRADE *et al*, 2010). Na Figura 2.1 pode-se visualizar os subsistemas de geração, transmissão e distribuição de energia elétrica, além dos consumidores.

Figura 2.1 - O Sistema Elétrico De Potência, da Geração ao Consumidor Final.



Fonte: adaptado de (ANEEL, 2008).

A geração de energia elétrica ocorre a partir de diferentes tecnologias e as principais fazem uso de máquinas rotativas, geradores síncronos ou alternadores, utilizando turbinas hidráulicas, a vapor ou eólicas. A energia elétrica obtida a partir das usinas hidrelétricas, como por exemplo, a usina de Itaipu na Figura 2.2, está no topo da matriz energética brasileira devido à grande quantidade de cursos d'água espalhados por quase todo território. Outras fontes preenchem essa matriz, como a solar, eólica, termelétrica, etc.


Figura 2.2 - Usina hidrelétrica de Itaipu.



Fonte: ANEEL (2008).

Toda a energia gerada pelo sistema de geração precisa escoar para todo o território nacional, e, para isso a transmissão de energia elétrica no Brasil conta com o Sistema Interligado Nacional (SIN), que abrange a maioria do território brasileiro e é constituído pelas conexões entre as cinco regiões do país, realizadas ao longo do tempo. Na Figura 2.3 pode-se verificar o SIN para o horizonte 2015.

Figura 2.3 - Sistema Interligado Nacional (SIN), Horizonte 2015



Fonte: (ONS, 2013).

Apesar da dimensão continental do SIN, diversos sistemas de menor porte não estão conectados devido às características geográficas da região, que dificultam o acesso e a construção de linhas de transmissão. Eles são chamados de Sistemas Isolados e se concentram principalmente na região amazônica (ANEEL, 2008), como pode ser visto na Figura 2.4.

Figura 2.4 - Centrais elétricas que compõem os Sistemas Isolados - Situação em Outubro de 2003



Fonte: (ANEEL, 2008).

O sistema de transmissão é interligado ao sistema de distribuição por meio dos pontos de fronteira, onde estão as subestações em que a tensão é rebaixada aos níveis de subtransmissão. O sistema de distribuição é bastante importante para o sistema elétrico, não só pelo grande volume de investimentos exigido, como também pela elevada responsabilidade na qualidade, confiabilidade e garantia de serviço prestado ao consumidor (COMITÊ DE DISTRIBUIÇÃO, 1982). O planejamento estratégico, essencial a qualquer sistema, torna-se imprescindível à distribuição, de forma a se atender ao crescimento da carga, procurando-se otimizar a aplicação dos recursos financeiros disponíveis, relativamente mais escassos que nos sistemas de

Geração e Transmissão. Além do mais, os sistemas de geração e transmissão contam com melhores e mais sofisticados sistemas de aquisição de dados e previsão de carga. O controle e monitoramento destes sistemas por parte do Operador Nacional do Sistema (ONS) contribui para esse melhor planejamento.

De acordo com Kagan *et al.* (2005) e Andrade *et al.* (2010), o sistema de distribuição pode ser dividido em três segmentos:

- Subtransmissão: tem a função de receber a energia das linhas de transmissão (tensões iguais ou maiores que 230 kV) e repassar, ou para o sistema de distribuição primária, por meio de subestações abaixadoras, como a que está representada na Figura 2.5, ou, alimentar diretamente consumidores conectados em tensão de subtransmissão, como grandes instalações industriais, etc;
- Distribuição primária: redes de média tensão (34,5 kV e 13,8 kV) que atendem consumidores primários como indústrias de médio porte, conjuntos comerciais, etc. Podem ser aéreas ou subterrâneas;
- Distribuição secundária: redes de baixa tensão (220/127 V) que tem como função suprir consumidores residenciais, a iluminação pública e pequenos comércios e indústrias.


Figura 2.5 - Subestação de Rio Tinto II (Energisa/PB), do tipo abaixadora 69/13,8 kV.



Fonte: (COSTA, 2014)

As subestações que rebaixam a tensão ao nível de 13,8 kV fornecem energia elétrica à rede de distribuição primária e, pode-se dizer que “alimentam” parte da rede juntamente com outras subestações. Por isso, os circuitos de saída destas subestações são chamados de alimentadores. Na Figura 2.6, pode-se visualizar o diagrama unifilar simplificado de uma subestação abaixadora de 69 kV para 13,8 kV com 4 alimentadores. Vale salientar que este diagrama resume a subestação aos barramentos de 69 kV (entrada) e 13,8 kV (saída), disjuntores/religadores e transformador de potência.


Figura 2.6 - Diagrama Unifilar Simplificado da Subestação Abaixadora.



Fonte: elaborado pelo autor, 2015.

As subestações de distribuição de energia são normalmente monitoradas por um Sistema de Aquisição de Dados (SCADA - *Supervisory Control and Data Acquisition*) que coleta dados de natureza elétrica (tensão, corrente, potência, fator de potência, etc.), de diferentes pontos de medição localizados em equipamentos (disjuntores e religadores) e barramentos. Todos os dados obtidos são enviados para um servidor, como ilustrado na Figura 2.7, e terminam por preencher um banco de dados. Estas medições, feitas ao longo do tempo em intervalos definidos (15 em 15 minutos), são ditas séries temporais.

Figura 2.7 - Sistema de Aquisição de Dados.




Fonte: (TEPCO, 2015).

2.2 SÉRIES TEMPORAIS

Uma série temporal é uma sequência de observações feitas ao longo do tempo (BOX; JENKINS; REINSEL, 2008). A quantidade mensal de mercadorias transportadas de uma fábrica, um registro semanal do número de acidentes de avião e observações feitas de hora em hora sobre o rendimento de um processo químico, são exemplos de séries temporais. Áreas como economia, negócios, engenharia, ciências naturais (especialmente geofísica e meteorologia), e as ciências sociais estão trabalhando e analisando séries temporais o tempo todo. Na Figura 2.8, pode-se visualizar exemplos reais de séries temporais.

Figura 2.8 - Exemplos de séries temporais: a) leitura de duas em duas horas de uma concentração "x" em processo químico; b) variação diária do preço das ações da IBM; c) leitura de temperatura em processo químico a cada minuto; d) leitura horária da viscosidade em processo químico.



Fonte: adaptado de (BOX; JENKINS; REINSEL, 2008).

Na análise clássica de séries temporais, é comum a classificação dos movimentos da série em três tipos de variações: a tendência, as variações sazonais (cíclicas) e as variações aleatórias (FISCHER, 1981).

A tendência se apresenta na série como um movimento regular e contínuo de longo prazo, refletindo um movimento ascendente ou descendente em longo período de tempo.

A sazonalidade, ou variações sazonais, é representada pelas variações periódicas que ocorrem com uma certa regularidade num curto espaço de tempo. Estes movimentos cíclicos podem ser diários, semanais, horários, etc.

As variáveis aleatórias referem-se não só aos movimentos esporádicos causados por eventos aleatórios como, por exemplo, fatores climáticos, mas também, a todos os movimentos que não foram identificados, uma vez que não obedecem a nenhuma lei comportamental, capaz de ser descrita de forma determinística, através de relações funcionais exclusivamente aleatórias (FISCHER, 1981).


De acordo com Box *et al.* (2008), além da Previsão de Séries Temporais, que é o foco deste trabalho, pode-se dividir o estudo de séries temporais em mais quatro importantes áreas de aplicação:

- Estimação de Função de Transferência;
- Análise da Interferência de Efeitos Externos à Série;
- Análise de Séries Temporais Multivariadas;
- Controle de Sistemas Discretos.

De forma geral, as previsões fornecem estimativas que são importantes em diversos processos de tomada de decisão (FRANCO JUNIOR, 2013).

No âmbito de problemas voltados para a energia elétrica, podem-se destacar as previsões de carga e/ou demanda que são casos típicos de previsão de séries temporais. Os termos carga e demanda serão considerados equivalentes em toda a dissertação, tendo em vista a definição encontrada em ANEEL (2005) que diz que carga é a caracterização da demanda do sistema. Na Figura 2.9, o perfil de carga diário (dia típico) da subestação de Cajazeiras (CJZ), na Paraíba, pode ser visualizado.

Figura 2.9 - Perfil de carga diário (dia típico) da subestação de Cajazeiras (CJZ).



Fonte: elaborado pelo autor, 2015.

Diversos modelos têm sido propostos para resolver o problema da previsão de séries temporais. Em Mori *et al.* (2007), Pan e Lee (2012) e Alexandrino *et al.* (2008) são apresentados diversos métodos, entre eles:

- Método Adaptativo;
- Filtragem Kalman;
- Modelo Box & Jenkins (AR, MA, ARMA, ARIMA, SARIMA, entre outros);
- Sistema Especialista;
- Modelo de Decisão Fuzzy;
- Rede Neural Artificial (RNA);
- Máquinas Vetor de Suporte (SVM);
- Rede Radial *Basis Function*;
- Modelo Neuro-Fuzzy;
- Teoria do Caos.

Guirelli (2006) e Viglione *et al.* (2006) dividem os métodos em duas classes: os métodos estatísticos e os métodos de inteligência artificial.

Os métodos estatísticos podem ser classificados em métodos regressivos e métodos baseados em séries temporais. Possuem a vantagem de serem técnicas matemáticas já bem desenvolvidas e estudadas, porém, dependem de um modelamento matemático complexo, além da dificuldade de lidar com séries não lineares.

Os modelos regressivos consideram a carga como uma combinação linear de funções tais como senóides, exponenciais, etc. Os modelos baseados em séries temporais levam em consideração para a previsão, dados históricos do comportamento da curva, além da possibilidade de incorporação de fatores externos como temperatura ambiente, umidade e efeitos aleatórios.

O modelo autorregressivo integrado de média móvel (ARIMA) é muito utilizado na modelagem e previsão de séries temporais e é uma generalização do modelo autorregressivo de média móvel (ARMA) (BOX; JENKINS; REINSEL, 2008).

Em Guirelli (2006) são citados como principais métodos estatísticos clássicos:

- Regressão Linear;
- ARIMA (*autoregressive integrated moving average*);
- Alisamento exponencial;
- Análise espectral.

De acordo com Haykin (2001), o objetivo da Inteligência Artificial (IA) é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são atualmente melhores, e, deve ser capaz de fazer três coisas: armazenar conhecimento, aplicar o conhecimento armazenado para resolver problemas e adquirir novo conhecimento através da experiência (SAGE; SINGH, 1990).

Apesar dos métodos baseados em inteligência artificial não dependerem de um modelamento matemático complexo ou conhecimento profundo do sistema, os mesmos apresentam suas dificuldades. A codificação do conhecimento humano não é tão trivial, ainda existe dificuldade na determinação das variáveis de entrada e nos parâmetros e os processos de treinamento são complexos e exigem esforço computacional e tempo. Os principais métodos são:

- Sistemas especialistas;
- Redes neurais artificiais;
- Lógica Fuzzy;
- Algoritmos genéticos.

Pode-se, ainda, considerar outra classe, a dos métodos híbridos, que utilizam duas ou mais técnicas em conjunto, a fim de melhorar a exatidão dos resultados das previsões. Alexandrino *et al.* (2008), De Aquino *et al.* (2006), Fonseca *et al.*, (2005), Gonçalves *et al.* (2006), Jarndal (2013) e Zhang *et al.* (2010) fizeram uso de métodos híbridos em seus trabalhos. Os métodos mais estudados são o Neuro-Fuzzy e Neural-genético.

2.3 MOTIVAÇÃO: TÉCNICA DE PREVISÃO

Apesar da gama de métodos e técnicas possíveis de serem aplicadas na previsão de séries temporais, as Redes Neurais Artificiais (RNA) foram o foco deste trabalho devido a diversos fatores, entre eles:

- Mais de vinte anos de trabalhos acadêmicos publicados;
- Seu poder em trabalhar com variáveis não lineares;
- Maior aceitação de um setor (Elétrico) em que a quebra de paradigmas é um obstáculo. Apresentar uma técnica renomada favorece a aceitação.

2.4 REDES NEURAIS ARTIFICIAIS

O cérebro humano é um computador (sistema de processamento de informação) altamente complexo, não-linear e paralelo (HAYKIN, 2001). Sua alta capacidade de reconhecer, associar e generalizar padrões motivou a criação das Redes Neurais Artificiais (RNA).

As RNA são sistemas paralelos compostos por unidades de processamento simples, os neurônios, que calculam determinadas funções matemáticas e são capazes de resolver uma grande diversidade de problemas. Diversos trabalhos como em Zhang *et al.* (2010), Viglione *et al.* (2006), De Aquino *et al.* (2007), Carmona *et al.*

(2002), Park *et al.*, (1991), Ghiassi *et al.* (2006) e Charytoniuk e Chen (2000a;2000b) utilizaram as redes neurais para previsão de séries temporais.

2.4.1 Histórico

O aparecimento da neurocomputação se deu na década de 40. Em 1943, Warren McCulloch e Walter Pitts descreveram em seu artigo um cálculo lógico das redes neurais que unificava os estudos de neurofisiologia e da lógica matemática (MCCULLOCH; PITTS, 1943). Seu resultado foi tão significativo que é considerado como o nascimento dos estudos de inteligência artificial e redes neurais (HAYKIN, 2001). Eles se basearam em três fontes: o conhecimento da fisiologia básica e da função dos neurônios no cérebro, uma análise formal da lógica proposicional criada por Russel e Whitehead, e a teoria da computação de Turing. McCulloch e Pitts demonstraram que qualquer função computável poderia ser calculada por uma certa rede de neurônios conectados, e que todos os conectivos lógicos poderiam ser implementados por estruturas de redes simples. Também sugeriram que redes definidas adequadamente seriam capazes de aprender (NORVIG; RUSSELL, 2004). Em 1949, Donald Hebb demonstrou uma regra de atualização simples (aprendizagem de Hebb) para modificar as intensidades das conexões entre os neurônios (HEBB, 1949). Até este tempo, surgiram vários exemplos de trabalhos que poderiam ser relacionados à área de inteligência artificial (IA), porém, foi Alan Turing, em (1950), quem primeiro condensou a idéia de IA em seu artigo, apresentando o teste de Turing, a aprendizagem de máquina, algoritmos genéticos e aprendizagem por reforço.

O primeiro neurocomputador, SNARK, foi criado em 1951 por Marvin Minsky. O perceptron, uma das primeiras RNA's com apenas um neurônio e aprendizagem supervisionada, foi apresentado por (ROSENBLATT, 1958). Dois anos depois, Widrow e Hoff desenvolveram o algoritmo dos mínimos quadrados. Os estudos no campo das redes neurais pareciam que iria decolar nos anos 60 até que veio o livro de Minsky e Papert em 1969, que demonstrou que existiam limites fundamentais para aquilo que os perceptrons de camada única podem calcular (MINSKY, 1986). As conclusões de outros pesquisadores também não foram tão animadoras, o que resultou numa queda abrupta dos incentivos à pesquisa na área e colocaram as redes neurais de lado por um bom tempo.


Na década de 80, o reaparecimento das redes neurais baseadas em perceptron foi possível graças à teoria em multicamadas (MLP) treinadas com o algoritmo de retropropagação (*backpropagation*), descoberta por Bryson e Ho em 1969 e desenvolvida, mais de quinze anos depois, por Rumelhart, Hinton e Williams (1986). O desenvolvimento de computadores com uma maior capacidade de processamento e armazenamento contribuiu também para a volta das redes neurais, permitindo que simulações computacionalmente impossíveis 20 anos atrás fossem realizadas. Em 1987 ocorreu a primeira conferência de redes neurais, a IEEE *International Conference on Neural Networks* e dois anos depois foi criada a INNS (*International Neural Networks Society*)(HAYKIN, 1994).

2.4.2 O Neurônio Artificial

A unidade básica de uma RNA é o neurônio artificial, cujo modelo se encontra ilustrado na Figura 2.10. O modelo de um neurônio k qualquer, apresenta três elementos básicos (HAYKIN, 2001):

- Um conjunto de sinapses (conexões), onde, a cada uma delas está associado um peso sináptico w_{kj} , $j = 1, 2, 3, \dots, m$;
- Um somador que na verdade é um combinador linear dos sinais de entrada;
- Uma função de ativação para restringir ou limitar a amplitude de saída.

Figura 2.10 - Modelo do neurônio artificial.



Fonte: adaptado de (HAYKIN, 2001).

Este modelo também inclui um *bias* b_k (polarização) que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, podendo ser positivo ou negativo.

Em termos matemáticos, pode-se descrever o neurônio k escrevendo as equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

e

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

onde: $x_1, x_2, \dots, x_m$ são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o *bias*; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio.

Os três tipos de funções de ativação mais utilizadas em redes neurais, de acordo com Macrini (2000) são:

- Sigmóides e Tangentes hiperbólicas

A função sigmóide ou logística é, juntamente com a hiperbólica, a função de ativação mais utilizada em redes neurais. Tem a propriedade de aliar uma região quase linear à característica de saturação, além de ser diferenciável e não decrescente. É representada pela seguinte equação:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad a > 0 \quad (3)$$

onde a é o *parâmetro de inclinação* da função sigmoide.

A função tangente hiperbólica possui as mesmas características da função sigmóide, mas opera no intervalo $(-a, +a)$ e não no intervalo $(0, a)$. É representada pela equação:

$$\varphi(v) = \tanh(v) \quad (4)$$

- Lineares

A função linear é muito utilizada em neurônio nas camadas de saída da rede, quando não se deseja o efeito de saturação das funções sigmoide e tangente hiperbólica. É representada pela equação:

$$\varphi(v) = av \quad (5)$$

- Radiais

As funções radiais, que na verdade são gaussianas, são fundamentadas nas redes de bases de funções radiais. É representada pela equação:


$$\varphi(v) = e^{-v^2} \quad (6)$$

2.4.3 Arquitetura de uma Rede Neural

O termo “arquitetura” em redes neurais diz respeito à forma que os neurônios e suas conexões são arranjadas e é determinante na sua capacidade de processamento (ZANINI, 2000). As redes neurais podem ser de dois tipos, recorrentes e não recorrentes.

As redes não recorrentes não possuem nenhum laço de realimentação de suas saídas para suas entradas, daí serem consideradas “sem memória”. A estrutura destas redes pode ser formada por uma única camada ou por multicamadas, como pode ser ilustrado pela Figura 2.11. A rede de uma única camada não possui camada com neurônios ocultos.

Figura 2.11 - Rede não recorrente *feedforward*.



Fonte: elaborado pelo autor, 2015.


Um exemplo de redes não recorrentes são as redes “*feedforward*”, em que o sinal é sempre propagado para frente. Não se deve confundir este sinal, conhecido como sinal funcional, com o sinal de erro da retropropagação que ocorre da saída para a entrada (HAYKIN, 2001).

Uma rede neural recorrente se diferencia de uma rede não recorrente por ter pelo menos um laço de realimentação e, por possuírem realimentação, estas redes respondem a estímulos dinamicamente, ou seja, após aplicar uma nova entrada, a saída é calculada e então realimentada para modificar a entrada, daí estas redes serem consideradas “com memória” (VELLASCO, 2007).

A presença de laços de realimentação tem um impacto profundo na capacidade de aprendizagem e no desempenho da rede. Além disso, os laços de realimentação envolvem o uso de ramos particulares compostos de elementos de atraso unitário, Z^{-1} , o que resulta em um comportamento dinâmico não-linear, admitindo-se que a rede neural contenha unidades não lineares (HAYKIN, 2001).

Existem casos de redes totalmente recorrentes, onde cada neurônio é conectado a outro, e casos de redes parcialmente recorrentes, como por exemplo, a rede de Elman, ilustrada na Figura 2.12.

Figura 2.12 - Rede recorrente do tipo Elman.




Fonte: (SZKOŁA; PANCERZ; WARCHOŁ, 2011)

2.4.4 Perceptrons de Múltiplas Camadas (MLP)

As redes perceptrons de múltiplas camadas ou multicamadas (MLP) são consideradas uma importante classe de redes neurais e é bastante mais conhecida e utilizada em diversas aplicações (PAN; LEE, 2012). As redes MLP tem sido aplicadas com sucesso para resolver diversos problemas difíceis, através do seu treinamento de forma supervisionada com um algoritmo muito popular conhecido como algoritmo de retropropagação de erro BP (*backpropagation*) (HAYKIN, 2001). Na Figura 2.13 pode-se visualizar a arquitetura de uma rede MLP com duas camadas ocultas ou intermediárias.


Figura 2.13 – Arquitetura de uma Rede Neural Artificial do tipo MLP.



Fonte: adaptado de (HAYKIN, 1994).

Na Figura 2.14 pode-se visualizar o fluxo do sinal em um neurônio j , onde v_j é a saída do neurônio e y_j é a saída após aplicação da função de ativação φ .

Figura 2.14 - Fluxo do sinal em um neurônio j .



Fonte: adaptado de (HAYKIN, 1994).

O processo de aprendizagem consiste na repetição da regra da cadeia do Cálculo a fim de calcular uma função de erro ε de todos os parâmetros livres da rede (pesos sinápticos e *bias*). Os pesos são ajustados de acordo com o valor da derivada parcial, dada por:

$$\frac{\partial \varepsilon}{\partial w_{ji}} = \frac{\partial \varepsilon}{\partial e_j} \frac{\partial e_j}{\partial y_j} \frac{\partial y_j}{\partial v_j} \frac{\partial v_j}{\partial w_{ji}} \quad (7)$$

Após conhecidas as derivadas parciais de cada peso, o papel do aprendizado é minimizar a função de erro ε por meio da equação 8, onde η representa a taxa de aprendizado.

$$w_{ji}(t+1) = w_{ji}(t) - \eta \frac{\partial \varepsilon(t)}{\partial w_{ji}(t)} \quad (8)$$

A aprendizagem por retropropagação pode ser resumida em dois passos. Durante o passo de propagação (para frente) os pesos sinápticos são todos fixos e durante o passo de retropropagação (para trás), por outro lado, os pesos são ajustados de acordo com uma regra de correção de erro. Enfim, a resposta real da rede é subtraída de uma resposta desejada para produzir um sinal de erro, que é então propagado para trás (retropropagação) através da rede, contra a direção das conexões sinápticas.

2.4.5 Taxas de Aprendizado e Momentum


A taxa de aprendizado η influencia na trajetória percorrida pelo gradiente decrescente. Quanto menor esta taxa, menores serão as atualizações dos pesos de uma iteração para outra, e assim, mais suave será a trajetória percorrida, porém, serão necessárias muitas iterações do algoritmo até encontrar uma solução aceitável. O inverso pode tornar a rede instável, e, para contornar isto é utilizada uma taxa de momentum, que tem o objetivo de estabilizar o sinal em regiões de instabilidade, além de acelerar a convergência (CERRI, 2014).

2.4.6 Retropropagação Resiliente (*Resilient Backpropagation*)

O algoritmo de treinamento padrão *backpropagation* (BP) foi, inquestionavelmente, o mais influente avanço no campo das redes neurais durante a década de 80 (WIDROW; LEHR, 1990). A atualização dos pesos sinápticos não depende somente da escolha das taxas de aprendizado e momentum, mas também, do valor da derivada parcial $\partial \varepsilon / \partial w_{ji}$. Logo, mesmo que a escolha das taxas seja cuidadosamente feita, o comportamento imprevisível da derivada parcial pode afetar os resultados.

Com o intuito de acabar com esse problema, Riedmiller e Braun (1993) propuseram o método de aprendizado *resilient backpropagation* (Rprop), o qual, possui uma estrutura muito semelhante ao próprio *backpropagation*, sendo considerada uma otimização do mesmo. Entretanto, o Rprop é capaz de conduzir uma adaptação local da atualização dos pesos de acordo com o comportamento da função erro, pois não considera o efeito negativo do valor absoluto da parcial derivativa para o cálculo de atualização dos pesos, mas somente o sinal da parcial derivativa que indica a direção de atualização dos pesos (JIN; FENG; JILAI, 2006). Essa mudança acarretou em um processo de adaptação extremamente eficiente em comparação a outras técnicas, sendo considerado um dos mecanismos de atualização de pesos mais rápidos existente. A arquitetura de uma rede neural artificial com algoritmo Rprop é ilustrada na Figura 2.15.

Figura 2.15 - Arquitetura de uma RNA com algoritmo Rprop.



Fonte: adaptado de (JIN; FENG; JILAI, 2006).

Com isso, apesar de eliminar grande parte das limitações do *backpropagation*, um novo problema pode surgir ao utilizar o Rprop: o sobre-ajuste, ou mais conhecido como *overfitting*. Ele ocorre quando o algoritmo se ajusta em demasiado ao conjunto de dados, aprendendo desvios causados por erros de medição ou fatores aleatórios da amostra, e perde sua habilidade de generalização (ANDRADE, 2011). Uma variação das taxas de aprendizado e momentum pode fazer com que as Redes Neurais fiquem menos suscetíveis a *overfitting*.


2.5 PREVISÕES DE SÉRIES TEMPORAIS UTILIZANDO RNA

Seja uma sequência de observações y_k , com $k = 1, 2, 3, \dots$, caracterizando uma série temporal. O objetivo da previsão pode ser resumido da seguinte forma: uma vez conhecidos os valores $y_{k-n+1}, y_{k-n+2}, \dots, y_k$, deseja-se encontrar o valor estimado da variável l períodos a frente da origem k , isto é, determinar $y(k+l)$, onde n e l são, respectivamente, a janela de previsão (JP - passo para trás) e o horizonte de previsão (HP - passo a frente). Assim, deseja-se determinar o seguinte mapeamento:

$$f : (y_{k-n+1}, \dots, y_{k-1}, y_k) \rightarrow y_{k+l} \quad (9)$$

Na Figura 2.16 pode-se visualizar um exemplo de previsão dada uma janela com quatro medidas da variável. A partir de y_{k-3} , y_{k-2} , y_{k-1} e y_k , determina-se o valor para um horizonte, $y(k+1)$.

Figura 2.16 - Previsão de Séries Temporais.



Fonte: elaborado pelo autor, 2015.


Algumas informações provenientes do ambiente externo são de natureza dinâmica e sequencial, de modo que as relações temporais entre padrões consecutivos precisam ser levadas em consideração. O reconhecimento de tais padrões dinâmicos é crucial para a previsão de séries temporais.

Para que a RNA seja usada como procedimento de previsão de séries temporais, torna-se necessário a incorporação do tempo para capacitá-la a modelar as variações estatísticas de uma serie temporal de dados. Segundo (HAYKIN, 1994), esse problema pode ser resolvido por meio da incorporação de um mecanismo chamado memória de curto prazo (MCP). Os componentes individuais da série temporal são armazenados de maneira que o processo de aprendizagem da rede trabalhe em dois eixos: tanto nos próprios dados, quanto na ordem em que eles ocorreram. O principal objetivo da memória é transformar uma rede estática em uma rede dinâmica. Com isso, as RNA's com características puramente estáticas se tornam dinâmicas. Ocorre, portanto, uma separação de responsabilidades, na qual, a rede estática é responsável pela não-linearidade e a memória é responsável pelo tempo. A forma de MCP mais simples utilizada é chamada de memória de linha de atraso. A rede MLP, com uma memória de linha de atraso derivada, aplicada à entrada, é a rede mais simples e uma das mais usadas em previsão de séries temporais.

A Figura 2.17 apresenta uma estrutura com uma rede MLP e a previsão com uma janela de tempo. Nesta figura os blocos constituem um operador de unidade de

atraso Z^{-1} ou memória. Observa-se que a entrada $(k + 1)$ representa o índice do horizonte de previsão. Esta proposta permite implementar a previsão de séries temporais ilustradas na Figura 2.16.

Figura 2.17 - RNA com memória de linha de atraso.



Fonte: elaborado pelo autor, 2015.

3 MÉTODO PROPOSTO DE PREVISÃO DE DEMANDA


3 MÉTODO PROPOSTO DE PREVISÃO DE DEMANDA

Neste capítulo é descrito o método proposto de previsão de demanda, passando pela configuração dos parâmetros da rede e seu treinamento, até os testes preliminares para obtenção dos resultados.

3.1 PREPARAÇÃO DOS DADOS

Os dados de potência ativa utilizados nos experimentos foram disponibilizados pela concessionária Energisa-PB. As três subestações, as quais, os dados foram disponibilizados, são do tipo abaixadora de tensão, de 69 kV para 13,8 kV, e as medições utilizadas neste trabalho são referentes à tensão de 69 kV (Ponto de medição 12B1). Pode-se verificar um exemplo de diagrama unifilar simplificado na Figura 3.1.

Figura 3.1 - Diagrama unifilar simplificado de uma subestação.




Fonte: elaborado pelo autor, 2015.

Os dados de natureza elétrica (potência ativa e reativa, corrente, tensão etc.) foram obtidos a partir de um sistema de aquisição de dados (SCADA), o qual, é responsável por receber os dados obtidos nos PM da subestação (equipamentos e/ou barramentos) e enviá-los para um banco de dados (BD), ficando acessível para a concessionária de energia. Uma análise prévia deste banco verificou a existência de inconsistências, tais como, ausência de dados (zeros ou nulos), picos (*spikes*) e mudanças de nível. Conhecidas na literatura como *outliers*, estas medições podem ser ocasionadas por erros de leitura, falhas do SCADA (*Supervisory Control and Data*

Acquisition) ou até mesmo não serem erros. Porém, independente da natureza, um *outlier* em uma série temporal deve ser corrigido a fim de que não venha a comprometer o algoritmo de previsão, pois, a qualidade e confiabilidade dos dados são essenciais para o processo (GUO et al., 2012); (TAYLOR, 2008).

Este trabalho não foca na identificação e correção de outliers, no entanto, destaca sua importância no tratamento prévio dos dados, através do exemplo da Figura 3.2, onde é ilustrada uma correção de picos e valores ausentes (nulo/zero). Desse modo, foi adotada como premissa do presente trabalho que as séries temporais estão corrigidas.

Figura 3.2 - Exemplo de correção de *outliers*.



Fonte: elaborado pelo autor, 2016.

A Tabela 3.1 contém parte dos dados destas séries e pode-se verificar como foram organizados, em medições de quinze em quinze minutos. Além da potência ativa, informações a respeito do ano, mês, dia, minuto, hora e o dia da semana foram armazenados.

Tabela 3.1 - Dados de potência ativa, intervalos de 15 em 15 minutos.

Dia	Mês	Ano	Id-Dia	Hora	Minuto	Demanda
1	1	2008	3	0	0	5,773
1	1	2008	3	0	15	5,773
1	1	2008	3	0	30	5,513
1	1	2008	3	0	45	5,513
1	1	2008	3	1	0	5,272
1	1	2008	3	1	15	5,272
1	1	2008	3	1	30	5,028
1	1	2008	3	1	45	5,028
1	1	2008	3	2	0	5,028
1	1	2008	3	2	15	5,028
1	1	2008	3	2	30	4,892
1	1	2008	3	2	45	4,892
1	1	2008	3	3	0	4,848
1	1	2008	3	3	15	4,848
1	1	2008	3	3	30	4,962
1	1	2008	3	3	45	4,962

Os dados de potência máxima diária e semanal foram obtidos a partir dos dados de potência de quinze em quinze minutos. Nas Tabela 3.2 e Tabela 3.3 pode-se visualizar como foram preenchidos, respectivamente, os dados de potência máxima diária e semanal.

Tabela 3.2 - Dados de potência máxima diária.

Dia	Mês	Ano	Id-Dia	Hora	Minuto	Demanda
1	1	2008	3	18	45	8,581
2	1	2008	4	18	30	8,871
3	1	2008	5	19	15	8,892
4	1	2008	6	18	45	7,645
5	1	2008	7	18	30	7,962
6	1	2008	1	18	30	7,174
7	1	2008	2	18	45	7,764
8	1	2008	3	18	45	8,077
9	1	2008	4	18	45	7,920
10	1	2008	5	18	30	8,023
11	1	2008	6	18	45	7,894
12	1	2008	7	18	15	7,991
13	1	2008	1	19	0	6,984
14	1	2008	2	18	30	7,667
15	1	2008	3	18	45	7,976
16	1	2008	4	18	45	7,782


Tabela 3.3 - Dados de potência máxima semanal.

Dia	Mês	Ano	Id-Dia	Hora	Minuto	Id-Semana	Demanda
8	1	2008	3	18	45	1	8,077
17	1	2008	5	19	0	2	8,089
25	1	2008	6	19	0	3	7,67
29	1	2008	3	18	30	4	7,888
9	2	2008	7	19	0	5	7,887
14	2	2008	5	19	15	6	7,878
23	2	2008	7	19	0	7	8,067
29	2	2008	6	18	45	8	8,076
6	3	2008	5	18	30	9	8,247
15	3	2008	7	18	30	10	8,254
20	3	2008	5	18	30	11	8,149
26	3	2008	4	18	30	12	7,987
5	4	2008	7	18	15	13	8,012
7	4	2008	2	18	45	14	8,127
16	4	2008	4	19	0	15	8,147
24	4	2008	5	18	15	16	7,994

Desta forma, o banco de dados formado pelas potências máximas semanais alcançou um número máximo de 7 (referente ao período de 2008 a 2014) vezes 52 (referente às semanas) medições, um total de 364.

Com intuito de facilitar a identificação, as três subestações receberam os seguintes codinomes: Subestação 1 (SE1), Subestação 2 (SE2) e Subestação 3 (SE3). As SE1 e SE2 são subestações que tem, no seu diagrama unifilar, 5 (cinco) alimentadores de saída, como ilustrado na Figura 3.1. A SE3, por outro lado, possui 7 (sete) alimentadores de saída. Seu diagrama unifilar simplificado pode ser visualizado na Figura 3.3.

Figura 3.3 - Diagrama Unifilar Simplificado da Subestação 3 (SE3).




Fonte: elaborado pelo autor.

3.2 TREINAMENTO DA RNA

Para o treinamento das Redes Neurais Artificiais foram propostos diferentes conjuntos de janelas, isto é, a quantidade de dados passados que é entregue à entrada da RNA, a cada turno, foi variada. O passo anterior, ou janela de previsão (JP), foi variado entre 4, 12, 26 e 52 semanas, enquanto que, o passo para frente, ou horizonte de previsão (HP), foi fixado em uma semana. Na Figura 3.4 pode-se verificar como os conjuntos de dados foram organizados, onde N corresponde ao índice do conjunto e é igual à janela de previsão mais 1, isto é, caso a janela de previsão (JP) for 4, o primeiro conjunto terá como saída a potência da semana $N = JP + 1 = 4 + 1 = 5$, e, como entrada, os dados das potências correspondentes às semanas 1 a 4, além da entrada referente à semana da potência a prever, ou seja, $N = 5$.

Figura 3.4 - Conjuntos (janelamento) de entradas/saída da RNA



Fonte: elaborado pelo autor, 2016.

Após todo o banco de dados ser convertido nos conjuntos de entradas/saída apresentados na Figura 3.4, os mesmos foram divididos da seguinte forma: conjuntos de 2008 a 2013, 80% para treinamento e 20% para validação, enquanto que os dados de 2014 (52 semanas) formaram os conjuntos de teste.

3.2.1 Parâmetros de Treinamento

O ambiente computacional utilizado para as simulações foi o Matlab® e os parâmetros utilizados foram:

- Número de camadas intermediárias: 1 e 2;
- Taxa de aprendizado: 0.01, 0.3, 0.7 e 1.0;
- Taxa de momentum: 0, 0.3, 0.7 e 1.0;
- Neurônios: 1, 3, 5, 7, 10, 15, 20, 25, 30, 35, 40, 50, 60, 70 e 80;
- Algoritmo de aprendizado: **trainrp** - Rprop (*resilient backpropagation*) do Toolbox de RNA do ambiente Matlab®.

Foram utilizados três computadores, com a mesma configuração de hardware, para as simulações, e, as características do mesmo podem ser verificadas na Tabela 3.4. Vale ressaltar que foi utilizado um mecanismo de seleção e uso de sementes para garantir a aleatoriedade do processo de simulação.

Tabela 3.4 - Características do modelo de Computador Utilizado.

CARACTERÍSTICAS DAS MÁQUINAS UTILIZADAS	
FABRICANTE	Hewlett-Packard Company
MODELO	HP ProDesk 600 G1 SFF
PROCESSADOR	Intel® Core™ i5-4570 CPU @ 3.20GHz
MEMÓRIA RAM	4,00 GB

Na Tabela 3.5 pode-se verificar o total de combinações para RNA com uma e duas camadas intermediárias.

Tabela 3.5 – Combinações e os parâmetros para cálculo do tempo médio de simulação.

Parâmetros de configuração	RNA com UMA camada	RNA com DUAS camadas
Taxa de Aprendizado	4	4
Taxa de Momentum	4	4
Neurônios	15	15 x 15
Iterações	10	10
Combinações	2400	36000
Tempo médio de simulação	1950 segundos = 32 minutos e meio	31000 segundos = 8 horas e 36 minutos
Número de Simulações	53	12
Tempo Total	28 horas	103 horas

3.3 VALIDAÇÃO E TESTE DA RNA

Após cada treinamento da RNA, é realizada uma validação com o objetivo de armazenar a rede, dentre todas as configurações, que alcance o menor erro de acordo com as métricas de validação explicitadas nas equações 10 e 11. Foram utilizados o MAPE (*Mean Absolute Percentage Error*) e o RMSE (*Root Mean Squared Error*), as quais são calculadas pelas expressões:

$$MAPE = \frac{1}{N} \sum_{j=1}^N \left| \frac{P_j - T_j}{P_j} \right| \times 100 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (P_j - T_j)^2} \quad (11)$$

onde, N – Tamanho do conjunto de validação.


P_j – Previsão (dados simulados), com $j = 1, 2, 3 \dots N$.

T_j – Teste (banco de dados), com $j = 1, 2, 3 \dots N$.

A validação consiste em simular a rede treinada para os conjuntos de dados que não foram utilizados no treinamento. A cada passo, o valor que é previsto é

realimentado para os conjuntos de entrada para que os próximos valores a serem previstos sofram influência da previsão anterior, assim como no mundo real. Na Figura 3.5 pode-se visualizar como as entradas e saídas se relacionam nas etapas de validação e teste. Pode-se verificar que os valores previstos (P_5' , P_6' , P_7' ...) são levados para as próximas entradas substituindo os valores reais (P_5 , P_6 , P_7 ...).

Figura 3.5 - Realimentação da previsão nos conjuntos de validação e teste.



Fonte: elaborado pelo autor, 2016.

3.4 EVOLUÇÃO DO MODELO PROPOSTO

O primeiro modelo de configurações entradas/saída foi apresentado na seção 3.2, na Figura 3.4. À medida que este modelo começou a ser utilizado nas simulações, se viu a necessidade de aplicar técnicas aos dados de entrada, visando melhorar a precisão dos resultados das previsões.

Esta configuração padrão foi denominada configuração do tipo 1, pois, não contém nenhuma técnica adicional e sua forma de tratar as entradas/saída é igual ao modelo inicial. Pode-se verificar como os dados de entrada e saída foram organizados, antes da RNA ser treinada, por meio da Tabela 3.6, na qual se mostram os 5 primeiros conjuntos (entradas/saída) para a configuração tipo 1, com janela de previsão (JP) igual a 4 semanas.


Tabela 3.6 - Exemplo de Dados de Entrada e Saída – Configuração Tipo 1.

	ENTRADAS				SAÍDA	
	Potência da Semana N-3 (MW)	Potência da Semana N-2 (MW)	Potência da Semana N-1 (MW)	Potência da Semana N (MW)	Semana N+1	Potência da Semana N+1 (MW)
JP = 4 com N = JP						
Conjunto 1 Para N = 4	13,00	12,40	12,10	11,50	5	11,90
Conjunto 2 Para N = 5	12,40	12,10	11,50	11,90	6	11,70
Conjunto 3 Para N = 6	12,10	11,50	11,90	11,70	7	11,20
Conjunto 4 Para N = 7	11,50	11,90	11,70	11,20	8	11,40
Conjunto 5 Para N = 8	11,90	11,70	11,20	11,40	9	11,40

3.4.1 Conversão das Semanas em Números Binários

A primeira técnica adicionada ao modelo padrão de entradas/saída consistiu em converter os números decimais correspondentes às semanas do ano (1 a 52) em dígitos binários. Como ilustrada na Figura 3.6, a entrada de Semanas a prever passou de uma entrada decimal para seis entradas, correspondente a cada um dos dígitos binários.

Figura 3.6 - Configuração Tipo 2 de Entradas/Saída da RNA.



Fonte: elaborado pelo autor, 2016.

Pode-se visualizar, na Tabela 3.7 - Exemplo de Dados de Entrada e Saída – Configuração Tipo 2., a entrada de semanas a prever, que passou de uma entrada decimal para seis binárias.

Tabela 3.7 - Exemplo de Dados de Entrada e Saída – Configuração Tipo 2.

	ENTRADAS				SAÍDA	
	Potência da Semana N-3 (MW)	Potência da Semana N-2 (MW)	Potência da Semana N-1 (MW)	Potência da Semana N (MW)	Semana N+1 (binário)	Potência da Semana N+1 (MW)
JP = 4 com N = JP						
Conjunto 1 Para N = 4	13,00	12,40	12,10	11,50	000101	11,90
Conjunto 2 Para N = 5	12,40	12,10	11,50	11,90	000110	11,70
Conjunto 3 Para N = 6	12,10	11,50	11,90	11,70	000111	11,20
Conjunto 4 Para N = 7	11,50	11,90	11,70	11,20	001000	11,40
Conjunto 5 Para N = 8	11,90	11,70	11,20	11,40	001001	11,40

3.4.2 Normalização dos Dados

Apesar da função de ativação já garantir a normalização dos dados de entrada da RNA, testes preliminares constataram a necessidade de realizar mais um processo de normalização, logo, foi feita uma normalização dos dados da potência máxima semanal, de acordo com a Equação 12.

$$Smax_n = \frac{Smax}{máx(Smax)} \quad (12)$$

Onde,

$Smax_n$ – Potência máxima semanal normalizada

$Smax$ – Potência máxima semanal

$máx(Smax)$ – Valor máximo entre os valores de potência máxima semanal


Verifica-se, pela Tabela 3.8, que os dados de potência máxima estão normalizados com relação ao maior valor entre as potências máximas semanais. Assim, estes valores se encontram entre 0 e 1.

Tabela 3.8 - Exemplo de Dados de Entrada e Saída – Configuração Tipo 3.

	ENTRADAS				SAÍDA	
	Potência da Semana N-3 (MW)	Potência da Semana N-2 (MW)	Potência da Semana N-1 (MW)	Potência da Semana N (MW)	Semana N+1 (binário)	Potência da Semana N+1 (MW)
JP = 4 com N = JP						
Conjunto 1 Para N = 4	0,69	0,66	0,64	0,61	000101	0,63
Conjunto 2 Para N = 5	0,66	0,64	0,61	0,63	000110	0,62
Conjunto 3 Para N = 6	0,64	0,61	0,63	0,62	000111	0,60
Conjunto 4 Para N = 7	0,61	0,63	0,62	0,60	001000	0,61
Conjunto 5 Para N = 8	0,63	0,62	0,60	0,61	001001	0,61

Acrescentando esta técnica à configuração do tipo 2, tem-se a configuração do tipo 3, visualizada na Figura 3.7. É possível verificar que, uma vez que as entradas de potência máxima semanal são normalizadas, a sua saída deve passar por um processo de desnormalização para que os resultados sejam utilizados na continuação da rotina computacional.

Figura 3.7 - Configuração Tipo 3 de Entradas/Saída da RNA.



Fonte: elaborado pelo autor, 2016.

3.4.3 Método das Diferenças

Resultados preliminares ainda mostraram que a retirada da tendência da série temporal fazia com que a previsão destes dados fosse mais acurada. Assim, os dados de potência máxima semanal passaram por um processo de diferenciação de acordo com a Equação 13. Esta nova configuração recebeu a denominação Tipo 4.

Para $k = 1$ até o número total de dados,

$$Smax_D(k) = Smax_n(k + 1) - Smax_n(k) \quad (13)$$


Sendo,

$Smax_n$ – Potência máxima semanal normalizada.

$Smax_D$ – Diferença da potência máxima semanal normalizada.

A configuração do tipo 4 pode ser visualizada na Figura 3.8, na qual pode-se verificar o acréscimo do método das diferenças aplicado às entradas/saída da RNA.

Figura 3.8 - Configuração Tipo 4 de Entradas/Saída da RNA.



Fonte: elaborado pelo autor, 2016.

Verifica-se, na Tabela 3.9, que os dados de entrada, agora, passam pelos processos de normalização e diferença antes de serem apresentados à RNA, e a saída, obviamente, passa pelo tratamento inverso destes processos para que possa ser utilizada para previsão.


Tabela 3.9 - Exemplo de Dados de Entrada e Saída – Configuração Tipo 4.

JP = 4 com N = JP	ENTRADAS				SAÍDA	
	Potência da Semana N-3 (MW)	Potência da Semana N-2 (MW)	Potência da Semana N-1 (MW)	Potência da Semana N (MW)	Semana N+1 (binário)	Potência da Semana N+1 (MW)
Conjunto 1 Para N = 4	-0,0319	-0,0160	-0,0319	0,0213	000101	-0,0106
Conjunto 2 Para N = 5	-0,0160	-0,0319	0,0213	-0,0106	000110	-0,0266
Conjunto 3 Para N = 6	-0,0319	0,0213	-0,0106	-0,0266	000111	0,0106
Conjunto 4 Para N = 7	0,0213	-0,0106	-0,0266	0,0106	001000	0,0000
Conjunto 5 Para N = 8	-0,0106	-0,0266	0,0106	0,0000	001001	-0,0160

3.4.4 Taxa de Crescimento de Energia

A taxa de crescimento de energia, a exemplo da Figura 3.9, transmite, à rede, informações relevantes com respeito ao crescimento e decréscimo da demanda de energia. Os dados utilizados no cálculo das taxas de crescimento foram os próprios dados de demanda de potência convertidos para demanda de energia, com intuito de simular uma análise prospectiva da evolução socioeconômica e demográfica na região.


Figura 3.9 – Gráfico da Taxa de Crescimento do ponto 12B1 da SE1



Fonte: elaborado pelo autor, 2016.

A taxa de crescimento de energia pode ser visualizada na Figura 3.10 como uma entrada a mais na RNA.

Figura 3.10 - Configuração Tipo 5 de Entradas/Saída da RNA.



Fonte: elaborado pelo autor, 2016.

A única diferença entre os tipos de configuração 4 e 5 é que, na última, a RNA recebe como entrada adicional, a taxa de crescimento de energia, como pode-se verificar, também, na Tabela 3.10.

Tabela 3.10 - Exemplo de Dados de Entrada e Saída – Configuração Tipo 5.

	ENTRADAS						SAÍDA
	Potência da Semana N-3 (MW)	Potência da Semana N-2 (MW)	Potência da Semana N-1 (MW)	Potência da Semana N (MW)	Semana N+1 (binário)	Taxa De Crescim.	Potência da Semana N+1 (MW)
Conjunto 1 Para N = 4	-0,0319	-0,0160	-0,0319	0,0213	000101	0,0260	-0,0106
Conjunto 2 Para N = 5	-0,0160	-0,0319	0,0213	-0,0106	000110	-0,0047	-0,0266
Conjunto 3 Para N = 6	-0,0319	0,0213	-0,0106	-0,0266	000111	-0,0066	0,0106
Conjunto 4 Para N = 7	0,0213	-0,0106	-0,0266	0,0106	001000	-0,0189	0,0000
Conjunto 5 Para N = 8	-0,0106	-0,0266	0,0106	0,0000	001001	-0,0780	-0,0160

Enfim, o método proposto foi sofrendo alterações, no que diz respeito às entradas/saída da RNA, com objetivo de obter melhores resultados. Na Tabela 3.11 pode-se conferir os tipos de configurações e as técnicas utilizadas em cada uma delas.

Tabela 3.11 – Evolução das técnicas utilizadas em cada uma das configurações.

CONFIGURAÇÕES	TÉCNICAS DE PRÉ-TREINAMENTO			
	Conversão das semanas em binário	Normalização dos dados de Demanda	Método das Diferenças	Taxa de crescimento de Energia
TIPO 1	-	-	-	-
TIPO 2	0	-	-	-
TIPO 3	0	0	-	-
TIPO 4	0	0	0	-
TIPO 5	0	0	0	0

4 RESULTADOS

4 RESULTADOS

Os resultados podem ser divididos em etapas. Primeiramente analisou-se a eficácia do algoritmo quando da evolução das técnicas de pré-treinamento. Posteriormente, foram feitas comparações entre os algoritmos de uma e duas camadas ocultas e o comportamento da RNA ao variar a quantidade de dados para treinamento e validação. Por fim, foi feito um levantamento do crescimento de demanda por subestação e como estes resultados influenciariam no planejamento do sistema de distribuição de energia elétrica.


Apesar de ter utilizado as métricas, *MAPE* e *RMSE*, para avaliação do erro, o *MAPE* foi utilizado como referência principal nos resultados, por motivos de simplificação e objetividade. Vale salientar que, quanto mais baixo o *MAPE*, melhores resultados são obtidos. É importante frisar que pode-se ter um baixo *MAPE* e um resultado abaixo do esperado, por isso, a plotagem gráfica e análise de um especialista são importantes para conclusão dos resultados.

4.1 DADOS DE TREINAMENTO, VALIDAÇÃO E TESTE

Nas Figura 4.1, Figura 4.2 e Figura 4.3 pode-se visualizar, respectivamente, os gráficos da Potência Máxima Semanal ao longo dos anos, referentes às medições no ponto de medição (PM) 12B1 das Subestações 1, 2 e 3 (SE1, SE2 e SE3). As subestações foram escolhidas devido suas características particulares de tendência e sazonalidade, explicitadas na seção 2.2.


Os dados referentes aos anos de 2008 a 2013 foram divididos em 80% para o treinamento e 20% para validação. Os dados do ano de 2014 foram utilizados para o teste.

Figura 4.1 - Gráfico da Potência Máxima Semanal - SE1.




Fonte: elaborado pelo autor, 2016.

Figura 4.2 - Gráfico da Potência Máxima Semanal - SE2.



Fonte: elaborado pelo autor, 2016.

Figura 4.3 - Gráfico da Potência Máxima Semanal - SE3.



Fonte: elaborado pelo autor, 2016.

4.2 VARIAÇÃO DE CONFIGURAÇÕES

Principal objetivo desta etapa de resultados foi confrontar os tipos de configuração de pré-treinamento, mencionados nas configurações, do ponto de vista do *MAPE*.


A Tabela 4.1 contém os resultados da previsão para a SE1, fixando a janela de previsão em 4 semanas e utilizando uma RNA com uma camada intermediária.

Tabela 4.1 - Comparativo entre os tipos de configurações para uma janela de 4 semanas – SE1.

Tipo de Configuração	Neurônios Camada Oculta 1	Taxa de Aprendizado	Taxa de Momentum	MAPE(%)
1	7	0.01	0.7	7.3821
2	1	1	1	7.3237
3	1	0.3	1	7.101
4	1	0.3	0	8.9025
5	10	1	0.7	4.395

Na Figura 4.4 pode-se visualizar os resultados das previsões para uma janela de 4 semanas. Foi observado que o resultado mais significativo ocorreu com a configuração tipo 5, isto é, foi obtido o menor *MAPE* e o gráfico seguiu a característica da curva real.

Figura 4.4 - Gráfico da Demanda x Semanas – Janela de 4 Semanas – SE1.




Fonte: elaborado pelo autor, 2016.

Da mesma forma, na Figura 4.5, pode-se visualizar as previsões para SE1 com uma janela de 26 semanas. Os resultados das simulações encontram-se na Tabela 4.2.

Tabela 4.2 - Comparativo entre os tipos de configurações para uma janela de 26 semanas – SE1.

Tipo de Configuração	Neurônios Camada Oculta 1	Taxa de Aprendizado	Taxa de Momentum	MAPE(%)
1	7	0,7	0,7	5,1604
2	3	0,3	1	4,1752
3	15	0,3	0	7,2587
4	1	0,7	0,7	5,0317
5	1	0,3	0	7,6681

Figura 4.5 - Gráfico da Demanda x Semanas – Janela de 26 Semanas – SE1.



Fonte: elaborado pelo autor, 2016.

A SE1 tem uma característica diferente de SE2 e SE3, que é a diminuição da demanda ao longo do ano de 2014, ao invés do crescimento. Apesar disso, a RNA


consegue acompanhar a curva, principalmente, com a configuração tipo 5, que leva em consideração a taxa de crescimento de energia. O menor *MAPE*, obtido com a configuração tipo 2, não reflete o melhor resultado devido não seguir as variações da curva real.

Os resultados das simulações para SE2, janela de 12 semanas, encontram-se na Tabela 4.3 e os gráficos, na Figura 4.6.

Tabela 4.3 - Comparativo entre os tipos de configurações para uma janela de 12 semanas – SE2.

Tipo de Configuração	Neurônios Camada Oculta 1	Taxa de Aprendizado	Taxa de Momentum	MAPE(%)
1	1	1	0,7	2,4471
2	1	0,3	1	2,5993
3	1	0,01	0	2,5381
4	5	1	0,3	3,1103
5	5	0,7	0,3	2,4205

Figura 4.6 - Gráfico da Demanda x Semanas – Janela de 12 Semanas – SE2.



Fonte: elaborado pelo autor, 2016.


Os resultados para SE2 alcançaram um *MAPE* médio de 2,5 %, justificando a tendência bem definida da curva de demanda, diferente da SE1. Apesar disso, vê-se que a melhor rede (menor *MAPE*) para as configurações dos tipos 1, 2 e 3 foi utilizando apenas um neurônio e esse resultado não é tão satisfatório, pois, é um caso onde a rede não treinou o suficiente para representar o conjunto de dados (*underfitting*).

Do mesmo modo, para SE3, os resultados para uma janela de 4 semanas encontram-se na Tabela 4.4 e os gráficos na Figura 4.7. Assim como para SE2, os resultados das previsões foram melhores e a curva do tipo 5 alcançou o menor *MAPE*.

Tabela 4.4 - Comparativo entre os tipos de configurações para uma janela de 4 semanas – SE3.

Tipo de Configuração	Neurônios Camada 1	Taxa de Aprendizado	Taxa de Momentum	MAPE(%)
1	7	0,7	0,7	4,9137
2	5	0,3	0,3	5,1556
3	15	0,3	1	4,4576
4	3	0,7	0,7	3,7997
5	20	0,01	1	2,9466

Figura 4.7 - Gráfico da Demanda x Semanas – Janela de 4 Semanas – SE3.



Fonte: elaborado pelo autor, 2015.

4.3 UTILIZAÇÃO DE UMA OU DUAS CAMADAS INTERMEDIÁRIAS

A configuração tipo 5 foi utilizada para comparar outros aspectos das RNA's como: uso de uma ou duas camadas, variação quanto à quantidade de dados para treinamento e a comparação entre algoritmos de aprendizado.

Como mencionado no capítulo 3, a quantidade de neurônios nas camadas intermediárias foi variada de acordo com valores específicos entre 1 e 80. Esse intervalo foi alcançado depois de testes sucessivos em que não se constatou a diminuição do *MAPE*.


A Tabela 4.5 contém os resultados obtidos para a SE2 e os gráficos podem ser visualizados nas Figura 4.8 e Figura 4.9.

Tabela 4.5 - Resultados das previsões das RNA's com 1 e 2 camadas ocultas na SE2.


Janela	RNA com UMA camada					RNA com DUAS camadas				
	Neurônios		Tx.		MAPE (%)	Neurônios		Tx.		MAPE (%)
	C1	C2	Apr.	Mom.		C1	C2	Apr.	Mom.	
4	10	0	0.7	0.7	4.5724	50	7	1	0	2.8597
12	5	0	1	0.3	3.1103	50	7	1	0	3.2392
26	5	0	0.7	0.7	2.7616	5	1	1	0.7	2.916
52	1	0	0.3	0	3.329	1	1	0.01	0.3	3.9538

Figura 4.8 – Gráficos, com JP = 4 e 12 semanas, das previsões com 1 e 2 camadas ocultas – SE2.

Janela de Previsão: 4 Semanas - MAPE(1 Camada)= 4.5724 - MAPE(2 Camadas)= 2.8597




Janela de Previsão: 12 Semanas - MAPE(1 Camada)= 3.1103 - MAPE(2 Camadas)= 3.2392




Fonte: elaborado pelo autor, 2016.

Figura 4.9 - Gráficos, com JP = 26 e 52 semanas, das previsões com 1 e 2 camadas ocultas – SE2.

Janela de Previsão: 26 Semanas - MAPE(1 Camada)= 2.7616 - MAPE(2 Camadas)= 2.916



Janela de Previsão: 52 Semanas - MAPE(1 Camada)= 3.329 - MAPE(2 Camadas)= 3.9538



Fonte: elaborado pelo autor, 2016.


O mesmo procedimento foi feito para a SE3. A Tabela 4.6 contém os resultados da comparação entre RNA com uma e duas camadas ocultas, para a subestação 3. Os gráficos foram plotados e podem ser visualizados nas Figura 4.10 e Figura 4.11. Pode-se concluir que para o caso estudado, o uso de duas camadas não obteve grande vantagem frente às curvas da SE2 nem para SE3.

Tabela 4.6 - Resultados das previsões das RNA's com 1 e 2 camadas ocultas na SE3.


Janela	RNA com UMA camada					RNA com DUAS camadas				
	Neurônios		Tx.		MAPE	Neurônios		Tx.		MAPE
	C1	C2	Apr.	Mom.		C1	C2	Apr.	Mom.	
4	3	0	0,7	0,7	3,7997	7	7	0,3	0,7	3,3102
12	25	0	0,7	0	3,6217	7	10	0,7	0,3	3,1467
26	10	0	0,3	1	3,3757	15	10	1	0,3	4,4852
52	3	0	0,01	0,3	4,2216	50	15	0,7	0	3,5828

Figura 4.10 - Gráficos, com JP = 4 e 12 semanas, das previsões com 1 e 2 camadas ocultas – SE3.

Janela de Previsão: 4 Semanas - MAPE(1 Camada)= 3.7997 - MAPE(2 Camadas)= 3.3102




Janela de Previsão: 12 Semanas - MAPE(1 Camada)= 3.6217 - MAPE(2 Camadas)= 3.1467



Fonte: elaborado pelo autor, 2016.

Figura 4.11 - Gráficos, com JP = 26 e 52 semanas, das previsões com 1 e 2 camadas ocultas – SE3.



Fonte: elaborado pelo autor, 2016.

4.4 VARIAÇÃO DO VOLUME DE DADOS

Nesta etapa dos resultados, foi variada a quantidade de dados disponíveis, da seguinte forma:


- Desde 2008: Treinamento e Validação (2008 - 2013) / Teste (2014);
- Desde 2009: Treinamento e Validação (2009 - 2013) / Teste (2014);
- Desde 2010: Treinamento e Validação (2010 - 2013) / Teste (2014);

A Tabela 4.7 contém os resultados da comparação e estes resultados podem ser visualizados na Figura 4.12.

Tabela 4.7 – Resultados obtidos quando da variação de dados apresentados à RNA – SE2.

Janela de Previsão	Dados Desde	Neurônios Camada Oculta 1	Taxa de Aprendiz.	Taxa de Momentum	MAPE (%)
4	2008	10	0,7	1	3,0797
4	2009	25	0,3	0	4,9613
4	2010	10	1	0	6,2009
12	2008	3	0,3	1	4,1899
12	2009	7	1	0	4,1819
12	2010	3	0,7	0,3	4,4279
26	2008	1	0,3	0,3	3,0397
26	2009	3	0,01	0,7	2,9709
26	2010	1	1	0,3	2,9840
52	2008	10	0,3	0	4,6662
52	2009	7	0,01	0,7	4,1213
52	2010	3	1	0,3	205,24

Figura 4.12 - Gráficos da comparação entre as RNA's com dados a partir de 2008, 2009 e 2010 – SE1.



Fonte: elaborado pelo autor, 2016.

4.5 COMPARAÇÃO ENTRE ALGORITMOS

O algoritmo de aprendizado Rprop (*trainrp*, no Matlab®) foi utilizado nas simulações devido seu poder de convergência e menor tempo de simulação. É baseado no MLP com retropropagação resiliente, que, tem origem no algoritmo *backpropagation* com gradiente decrescente (BP), o *traingd*, no Matlab®. Uma das formas de verificar a eficiência do algoritmo Rprop é comparando sua performance frente ao *backpropagation* padrão. A Tabela 4.8 foi preenchida com estes dados e os mesmo podem ser visualizados na Figura 4.13.

Tabela 4.8 - Resultados obtidos da comparação entre os dois algoritmos – SE2.


Janela	RNA com Rprop					RNA com BP				
	N	Tx. Apr.	Tx. Mom.	MAPE (%)	TEMPO (s)	N	Tx. Apr.	Tx. Mom.	MAPE (%)	TEMPO (s)
4	10	0,7	1	3,0797	1740,3	1	1	1	7,1915	4236,9
12	3	0,3	1	4,1899	1942,5	7	0,01	1	12,891	4279,8
26	1	0,3	0,3	3,0397	1870,3	1	1	0,3	11,367	4245,1
52	10	0,3	0	4,6662	1800,8	1	0,7	1	7,3887	5202,9

A diferença com relação ao tempo de simulação entre os algoritmos está explicitada na Tabela 4.9.

Tabela 4.9 - Diferença no tempo de simulação entre os algoritmos.

Janela	TEMPO DE SIMULAÇÃO (s)		
	RNA com Rprop	RNA com BP	Diferença
4	1740,3	4236,9	2,43 x menor
12	1942,5	4279,8	2,20 x menor
26	1870,3	4245,1	2,27 x menor
52	1800,8	5202,9	2,89 x menor

Figura 4.13 - Resultados obtidos da comparação entre os dois algoritmos – SE2.



Fonte: elaborado pelo autor, 2016.

Ficou clara a superioridade do algoritmo Rprop frente ao *backpropagation* (BP) padrão, tanto em relação à convergência, quanto ao tempo de simulação que, em média foi 2,5 vezes mais rápido.

5 CONCLUSÕES

5 CONCLUSÕES

Nesta dissertação foi proposta a utilização da inteligência artificial, mais especificamente, redes neurais artificiais do tipo MLP com algoritmo de aprendizado resiliente *backpropagation* (Rprop), para desenvolver uma ferramenta de previsão no médio prazo (até um ano).

Foram utilizadas como estudo de caso, três subestações do sistema de distribuição de energia elétrica gerido pela concessionária Energisa/PB, e, o objetivo foi realizar uma previsão de demanda no médio prazo.

Em relação à metodologia desenvolvida, foram alcançados melhores resultados quando se fez uso de todas as técnicas de pré treinamento, isto é, além do algoritmo Rprop, uso das técnicas de semanas binárias, normalização dos dados, diferenças dos dados e taxa de crescimento de energia. O melhor resultado desta configuração (tipo 5) foi de 2,42 % (MAPE).

No comparativo entre uso de uma ou duas camadas, os resultados das previsões foram similares. O que mais pesou contra a RNA com duas camadas ocultas foi que o tempo de simulação, com os mesmos parâmetros, foi de 15 vezes em relação à RNA com uma camada. Foi possível concluir que o uso de duas camadas ocultas pode ser interessante quando não há preocupação com o tempo de simulação ou dependendo da natureza dos dados.

Em relação à quantidade de dados disponíveis e sua influência na previsão, pode-se concluir que, utilizando uma janela de previsão de 4 ou 12, os resultados são muito parecidos e os dados mais antigos, quando retirados, não influenciam na previsão. Quanto aos resultados com janela de previsão (JP) de 26 e 52, pioraram bastante a medida que a quantidade de dados diminuía. Isso acontece porque, ao formar os conjuntos de 26 e 52 janelas, perde-se uma quantidade considerável de conjuntos e a RNA não treinou o suficiente para representar o conjunto de dados (*underfitting*).

A metodologia que utiliza o algoritmo Rprop (*resilient backpropagation*) precisava ser avaliada e isso foi feito comparando resultados da RNA tipo 5 com Rprop e com o BP (*backpropagation with gradient descent*). Os resultados foram indiscutivelmente, favoráveis ao Rprop, pois, além de previsões com MAPE muito

abaixo, também conseguiu realizar as simulações, em média, 2,5 vezes mais rápido que o algoritmo BP.

Complementarmente, pode-se concluir que a metodologia proposta permite auxiliar a equipe de planejamento do sistema de distribuição da concessionária, visto que, os resultados estão dentro de uma faixa aceitável, com erro abaixo de 5% (MAPE). Por fim conclui-se que o algoritmo é eficaz e pode ser utilizado para previsão de séries temporais.

Como trabalhos futuros, o estudo de técnicas híbridas, como Neuro-Fuzzy ou algoritmos genéticos, pode ser interessante do ponto de vista de diminuição do tempo de simulação, visto que não seria necessário rodar todas as configurações.

Em acréscimo ao trabalho, os resultados destas previsões podem ser utilizados na questão de reconfiguração de redes de distribuição, tanto voltada para o curto prazo (contingência), como para médio e longo prazo, visando o planejamento de uma reconfiguração futura.

6 REFERÊNCIAS

6 REFERÊNCIAS

- ALEXANDRINO, J. L.; ZANCHETTIN, C.; CARVALHO FILHO, E. **A hybrid intelligent system clonart for short and mid-term forecasting for the Brazilian Energy Distribution System**. In: IEEE International Joint Conference on Neural Networks, 2008.
- ANDRADE, L. N. de. **Redes neurais artificiais aplicadas na identificação automática de áreas cafeeiras em imagens de satélite**. 2011. UFMG, Belo Horizonte - MG, 2011.
- ANDRADE, L. C. M. D. **Abordagem neurofuzzy para previsão de demanda de energia elétrica no curtíssimo prazo**. 2010. Biblioteca Digital de Teses e Dissertações da USP, 2010.
- ANEEL. **Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST Módulo 2 – Planejamento da Expansão do Sistema de Distribuição**, 2005. Disponível em: <http://www.aneel.gov.br/arquivos/PDF/Modulo2_V2.pdf>. Acesso em: 26 fev. 2016.
- ANEEL. **Atlas de energia elétrica do Brasil** Agência Nacional de Energia Elétrica, 2008.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 4 edition ed. Hoboken, N.J: Wiley, 2008.
- CARMONA, D.; JARAMILLO, M. A.; GONZALEZ, E.; ALVAREZ, J. A. **Electric energy demand forecasting with neural networks**. In: IECON 2002.
- CERRI, R. **Redes neurais e algoritmos genéticos para problemas de classificação hierárquica multirrótulo**. 2014. USP, São Carlos - SP, 2014.
- CHARYTONIUK, W.; CHEN, M.-S. **Neural network design for short-term load forecasting**. In: International Conference on Electric Utility Deregulation and Restructuring and Power Technologies, 2000.
- CHARYTONIUK, W.; CHEN, M.-S. **Very short-term load forecasting using artificial neural networks**. IEEE Transactions on Power Systems, v. 15, n. 1, p. 263–268, fev. 2000b.
- COMITÊ DE DISTRIBUIÇÃO, E. **Planejamento de sistemas de distribuição (coleção distribuição de energia elétrica volume 1)**. Rio de Janeiro: Campus/Eletróbrás, 1982. v. 1
- COSTA, M. S. da. **ACOMPANHAMENTO DA CONSTRUÇÃO DA SUBESTAÇÃO RIO TINTO II 69kV**. João Pessoa - PB: UFPB - CEAR, 2014.
- DE AQUINO, R. R. B.; FERREIRA, A. A.; LIRA, M. M. S.; SILVA, G. B.; NETO, O. N.; OLIVEIRA, J. B.; DINIZ, C. F.; FIDELES, J. A **Hybrid Intelligent System for Short**

and Mid-term Forecasting for the CELPE Distribution Utility. In: International Joint Conference on Neural Networks, 2006. IJCNN '06.

DE AQUINO, R. R. B.; NETO, O. N.; LIRA, M. M. S.; FERREIRA, A. A.; CARVALHO, M. A.; SILVA, G. B.; DE OLIVEIRA, J. B. **Development of an Artificial Neural Network by Genetic Algorithm to Mid-Term Load Forecasting.** In: International Joint Conference on Neural Networks, 2007. IJCNN 2007,

FISCHER, S. **Series univariantes de tempo — metodologia de box & jenkins.** 1981. Universidade Federal do Rio Grande do Sul, Porto Alegre, 1981.

FONSECA, E. T.; VELLASCO, P. C. G. S.; VELLASCO, M. M. B. R.; DE ANDRADE, S. A. L. **A neuro-fuzzy system for steel beams patch load prediction.** In: Fifth International Conference on Hybrid Intelligent Systems, 2005. HIS '05.

FRANCO JUNIOR, E. F. **Modelo para previsão de demanda ativa usando rna.** 2013. Universidade Estadual de Campinas, 2013.

GHIASSI, M.; ZIMBRA, D.; SAIDANE, H. **Medium Term System Load Forecasting with a Dynamic Artificial Neural Network Model.** Electric Power Systems Research, v. 76, n. 5, p. 302–316, 2006.

GONCALVES, L. B.; VELLASCO, M. M. B. R.; PACHECO, M. A. C.; SOUZA, F. J. de. **Inverted hierarchical neuro-fuzzy BSP system: a novel neuro-fuzzy model for pattern classification and rule extraction in databases.** IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews, v. 36, n. 2, p. 236–248, mar. 2006.

GUIRELLI, C. R. **Previsão da carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial.** 2006. Biblioteca Digital de Teses e Dissertações da USP, 2006.

GUO, Z.; LI, W.; LAU, A.; INGA-ROJAS, T.; WANG, K. **Detecting X-Outliers in Load Curve Data in Power Systems.** IEEE Transactions on Power Systems, v. 27, n. 2, p. 875–884, maio 2012.

HAYKIN, S. **Neural networks: a comprehensive foundation.** [s.l.] MacMillan Publishing Company, 1994.

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

HEBB, D. O. **The organization of behavior.** New York: Wiley, 1949.

JARNDAL, A. **Load forecasting for power system planning using a genetic-fuzzy-neural networks approach.** In: 2013 7th IEEE GCC Conference and Exhibition (GCC),

JIN, L.; FENG, Y.; JILAI, Y. **Peak Load Forecasting Using Hierarchical Clustering and RPROP Neural Network.** In: 2006 IEEE PES.

KAGAN, N.; OLIVEIRA, C. C. B. de; ROBBA, E. J. **Introdução aos sistemas de distribuição de energia**. Edição: 1 ed. São Paulo: Edgard Blucher, 2005.

KARAYIANNIS, N. B.; BALASUBRAMANIAN, M.; MALKI, H.; OTHERS. **Evaluation of cosine radial basis function neural networks on electric power load forecasting**. In: Neural Networks, 2003.

MACRINI, J. L. R. **Modelo de previsão de carga utilizando redes neurais: otimização camada a camada**. 2000. PUC-Rio, 2000.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Math. Biophys, v. 5, p. 115–133, 1943.

MINSKY, M. **The society of mind**. New York: Simon and Schuster, 1986.

MORI, H.; KURATA, E. **Graphical Modeling for Selecting Input Variables of Short-term Load Forecasting**. In: Power Tech, jul. 2007.

NORVIG, P.; RUSSELL, S. **Inteligência artificial**. Edição: 2ª ed. [s.l.] Elsevier Acadêmico, 2004.

ONS. Disponível em: <<http://www.ons.org.br/home>>. Acesso em: 23 jul. 2015.

PAN, X.; LEE, B. **A comparison of support vector machines and artificial neural networks for mid-term load forecasting**. mar. 2012.

PARK, D. C.; EL-SHARKAWI, M. A.; MARKS, R. J.; ATLAS, L. E.; DAMBORG, M. J.; OTHERS. **Electric load forecasting using an artificial neural network**. Power Systems, IEEE Transactions on, v. 6, n. 2, p. 442–449, 1991.

RIBEIRO, P. M.; GARRIDO, D. A.; VELÁSQUEZ, R. M. G.; FALCÃO, D. M.; DA SILVA, A. P. A. **Sistema computacional para previsão de demanda por energia em pontos de suprimento e subestações da COELBA**. XVII Seminário Nacional de Distribuição de Energia Elétrica–SENDI. Belo Horizonte, 2006.

RIEDMILLER, M.; BRAUN, H. **A direct adaptive method for faster backpropagation learning: The RPROP algorithm**. In: Neural Networks, 1993., IEEE International Conference On.

ROSENBLATT, F. **The perceptron: a probabilistic model for information storage and organization in the brain**. Psychological review, v. 65, n. 6, p. 386, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning representations by back-propagating errors**. Nature, v. 323, p. 533–536, 1986.

SAGE, A. P.; SINGH, M. G. **Concise encyclopedia of information processing in systems & organizations**. [s.l.] Pergamon Press, 1990.

SANTOS, A. H. M.; HADDAD, J.; CRUZ, R. A. P. da. **Planejamento da Expansão da Distribuição: Considerações Técnicas e Regulatórias**. 2008.

SZKOŁA, J.; PANCERZ, K.; WARCHOŁ, J. **Recurrent Neural Networks in Computer-Based Clinical Decision Support for Laryngopathies: An Experimental Study**. Computational Intelligence and Neuroscience, 2011. Disponível em: <<http://www.hindawi.com/journals/cin/2011/289398/abs/>>. Acesso em: 9 ago. 2015.

TAYLOR, J. W. **An evaluation of methods for very short-term load forecasting using minute-by-minute British data**. International Journal of Forecasting, v. 24, n. 4, p. 645–658, 2008.

TEPCO. Disponível em: <<http://www.tepco.co.jp/index-j.html>>. Acesso em: 26 fev. 2016.

TURING, A. M. **Computing machinery and intelligence**. Mind, v. 59, n. 236, p. 433–460, 1950.

VELLASCO, M. M. B. R. **Redes Neurais Artificiais**. Rio de Janeiro, Brasil, PUC, notas de Aula, Brasil, 2007. Disponível em: <<http://www.ica.ele.puc-rio.br/Downloads%5C33/ICA-introdu%C3%A7%C3%A3o%20RNs.pdf>>. Acesso em: 9 ago. 2015.

VIGLIONI, G. M. C.; CURY, M. V. Q.; DA SILVA, P. A. L. **Comparação entre Redes Neurais e Técnicas Clássicas para Previsão de Demanda de Transporte Ferroviário**. 2006.

WIDROW, B.; LEHR, M. A. **30 years of adaptive neural networks: perceptron, madaline, and backpropagation**. Proceedings of the IEEE, v. 78, n. 9, p. 1415–1442, 1990.

ZANINI, A. **Redes neurais e regressão dinâmica: um modelo híbrido para previsão de curto prazo da demanda de gasolina automotiva no brasil**. 2000. PUC-Rio, 2000. Disponível em: <<http://www.maxwell.vrac.puc-rio.br/7457/7457.PDF>>. Acesso em: 7 jul. 2015.

ZHANG, L. D.; JIA, L.; ZHU, W. X. **Overview of traffic flow hybrid ANN forecasting algorithm study**. In: Computer Application and System Modeling (ICCSM), IEEE, 2010.