

UNIVERSIDADE FEDERAL DO PAMPA

ROBISON ROBERTO GOMES

**PREVISÃO DE CARGA E DEMANDA DE ENERGIA ELÉTRICA ATRAVÉS DE
SISTEMAS INTELIGENTES**

Alegrete

2015

ROBISON ROBERTO GOMES

**PREVISÃO DE CARGA E DEMANDA DE ENERGIA ELÉTRICA ATRAVÉS DE
SISTEMAS INTELIGENTES**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia Elétrica da Universidade Federal do Pampa, como requisito parcial para obtenção do Título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Giovani Guarienti Pozzebon

Co-Orientador: Prof. Dr. José Wagner Maciel Kaehler

Alegrete

2015

Ficha catalográfica elaborada automaticamente com os dados fornecidos pelo(a) autor(a) através do Módulo de Biblioteca do Sistema GURI (Gestão Unificada de Recursos Institucionais).

G666p Gomes, Robison Roberto

PREVISÃO DE CARGA E DEMANDA DE ENERGIA ELÉTRICA
ATRAVÉS DE SISTEMAS INTELIGENTES / Robison Roberto
Gomes.

75 p.

Trabalho de Conclusão de Curso(Graduação)--
Universidade Federal do Pampa, A ESCOLA E A CIDADE:
POLÍTICAS PÚBLICAS E EDUCACIONAIS, 2015.

"Orientação: Giovani Guarienti Pozzebon".

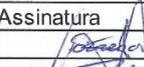
1. Previsão de Demanda de Energia Elétrica. 2.
Sistemas Inteligentes de Previsão. 3. Redes Neurais
Artificiais. 4. Horizontes de Previsão de Demanda.
I. Título.

Autoria: Robison Roberto Gomes

Título: PREVISÃO DE CARGA E DEMANDA DE ENERGIA ELÉTRICA ATRAVÉS DE SISTEMAS INTELIGENTES

Trabalho de Conclusão de Curso apresentado como parte das atividades para a obtenção do título de Bacharel em Engenharia Elétrica do Curso de Engenharia Elétrica da Universidade Federal do Pampa.

Os componentes da banca, abaixo listados, consideram este trabalho aprovado

	Nome	Titulação	Instituição	Assinatura
1	Giovani Guarienti Pozzebon	Prof. Dr.	unipampa	
2	José Wagner Maciel Kaehler	Prof. Dr.	unipampa	
3	Eduardo Machado dos Santos	Prof. Me.	unipampa	Eduardo M. dos Santos

Data da aprovação: 19 de Janeiro de 2015.

*Dedico este trabalho com enorme carinho a minha família, principalmente a minha mãe **Clarice**, que não mediu esforços para que eu pudesse chegar a essa conquista. A minha filha **Ana Laura**, presente de Deus em minha vida. Aos meus **amigos**, que me ensinaram o verdadeiro sentido do amor.*

AGRADECIMENTOS

Obrigado meu Deus, por estar presente em minha vida, me conceder forças para lutar e caminhar e pelas inúmeras vezes que me carregastes em seus braços.

Ao Prof. Dr. Giovani Guarienti Pozzebon, pelos ensinamentos e orientações durante todo desenvolvimento do trabalho de conclusão de curso.

Ao Prof. Dr. José Wagner Maciel Kaehler, pelas orientações preciosas e por compartilhar um pouco de sua enorme experiência.

Aos professores do curso de Engenharia Elétrica, que contribuíram para minha formação e me ensinaram a trabalhar duramente para alcançar êxito em minhas tarefas.

A todos os colegas de curso que compartilharam das mesmas alegrias e das mesmas angústias que eu, passando muitas noites em claro, as vezes em casa, as vezes na universidade, estudando, resolvendo listas de exercícios, fazendo relatórios, artigos, apresentações ou simplesmente tomando um mate e jogando conversa fora (muito raro).

Aos amigos, irmãos e companheiros que fizeram ou fazem parte da minha vida aqui em Alegrete, obrigado por compartilhar os momentos do dia a dia, compartilhar as angústias, as alegrias, pelas palavras de conforto, pelo ombro amigo em inúmeros momentos, pelos bons churrascos acompanhado de muito converseiro.

Aos amigos de Cajobi e São Paulo, obrigado por me incentivarem a estudar, por não medirem esforços para me ajudar, financeiramente, afetivamente e por vocês serem meus ídolos.

“O homem se torna muitas vezes o que ele próprio acredita que é. Se insisto em repetir para mim mesmo que não posso fazer uma determinada coisa, é possível que acabe me tornando realmente incapaz de fazê-la. Ao contrário, se tenho a convicção de que posso fazê-la, certamente adquirirei a capacidade de realizá-la, mesmo que não a tenha no começo”.

Mahatma Gandhi

RESUMO

Sistemas inteligentes de previsões futuras são fundamentais para a operação e o gerenciamento dos sistemas elétricos, onde, o planejamento e a tomada de decisões são realizados para atender as necessidades futuras de energia, em função da disponibilidade atual, que depende de eventos anteriores. Os diferentes tipos de consumidores fazem uso da energia elétrica de formas distintas, o uso final de energia que cada segmento de cliente realiza impacta diretamente em todo o sistema elétrico. O horizonte de previsão de demanda é fundamental para definir estratégias de planejamento e operação, compra de combustíveis, compra e venda de energia, crescimento e expansão e, ainda, negociações de contrato. O presente trabalho trata do desenvolvimento e, implementação de um sistema inteligente de previsão de demanda de energia elétrica através de redes neurais artificiais de previsão. A topologia de rede utilizada nesse processo é a rede *Perceptron de Múltiplas Camadas com Entradas Atrasadas no Tempo* (PMC-TDNN), pois sistemas de energia elétrica possuem características de distribuição que variam em função do tempo e, assim, comportam-se de maneira similar aos sistemas dinâmicos. O sistema é treinado e validado através de um histórico de dados reais, fornecido por um agente distribuidor de energia elétrica. Esses dados foram tratados e manipulados para que o sistema possa ser o mais flexível às variações nas análises. Essa flexibilidade permite com que as análises sejam direcionadas para alimentadores individuais e as previsões sejam realizadas para classes específicas de consumidores. Os resultados iniciais do trabalho desenvolvido não contemplaram os fatores climatológicos e nem a segregação por classes de consumidores, no entanto os resultados indicam que o sistema de previsão poderá possuir um grande potencial de melhoria e aumento na precisão a partir do correlacionamento dessas novas variáveis.

Palavras-Chave: Previsão de demanda, sistemas neurais, horizontes de previsão.

ABSTRACT

Intelligent systems of future forecasts are fundamentals for the operation and management of electrical systems where the planning and decision making are performed to meet future energy needs, according to the current availability which depends on the previous events. The different types of consumers use electrical energy in different ways and each segment of them impacts directly the entire system. The demand forecast horizon is essential to define the strategies of planning and operation, fuel purchasing, sales and purchasing of energy, growth and expansion and further negotiations of contracts. This work deals with the development and implementation of an intelligent systems of demand forecast through forecasts neural systems. The network used for training and validation processes was the Multi-layer Perceptron with Time-Delay Neural Network (PMC-TDNN), because systems of electric energy have distribution features which vary with time and thus behave in a similar way with dynamics systems. The system was trained and validated through the historical real data, supplied by a distributor agent of electricity and the data were treated and manipulated so that the system could be more flexible to changes in the analyzes as possible. This flexibility allows that the analyzes are directed to the individual feeders and the forecasts are made for specific classes of consumers. The initial results of the work did not address nor the weather factors and neither the consumer classes segmentation, however the results were satisfactory and indicate that the forecasting system has a great potential for improvement and increase in accuracy from correlating these new variables.

Keywords: demand forecasting, neural systems, forecast horizons.

LISTA DE FIGURAS

Figura 1 - Representação do neurônio artificial	38
Figura 2 – Funções de ativação, a) linear, b) degrau bipolar, c) tangente hiperbólica, d) logística, e) gaussiana.....	39
Figura 3 – Rede <i>feedforward</i> de camada simples	40
Figura 4 – Rede <i>feedforward</i> de camadas múltiplas.....	41
Figura 5 – Rede recorrente.....	42
Figura 6 – Rede Perceptron.....	43
Figura 7 – Representação da Rede PMC.....	44
Figura 8 – Derivação do algoritmo <i>backpropagation</i>	44
Figura 9 – Neurônio utilizado na diferenciação do algoritmo <i>backpropagation</i>	45
Figura 10– Topologia PMC TDNN.....	48
Figura 11 – Diagrama de blocos das fases de treinamento e operação das Redes PMC.....	49
Figura 12 – Princípio de normalização das amostras.	54
Figura 13 – Processo de treinamento sem a inserção do termo momentum.....	57
Figura 14 – Processo de treinamento com a inserção do termo momentum.....	57
Figura 15 – Erro quadrático médio teste 1 Quinta-Feira.....	59
Figura 16 – Processo de validação teste 1 Quinta-Feira.	59
Figura 17 – Erro quadrático médio teste 2 Quinta-Feira.....	61
Figura 18 – Processo de validação teste 2 Quinta-Feira.	61
Figura 19 – Erro quadrático médio teste 3 Quinta-Feira.....	62
Figura 20 – Processo de validação teste 3 Quinta-Feira.	63
Figura 21 – Erro quadrático médio teste 1 Domingo.	65
Figura 22 – Processo de validação teste 1 Domingo.....	65
Figura 23 – Erro quadrático médio teste 2 Domingo.	67
Figura 24 – Processo de validação teste 2 Domingo.....	67
Figura 25 – Erro quadrático médio teste 3 Domingo.	68
Figura 26 - Processo de validação teste 3 Domingo.	69
Figura 27 – Sistema inteligente de tomada de decisões	73

LISTA DE TABELAS

Tabela 1 – Relação de entradas e saídas da rede.	55
Tabela 2 – Variáveis ajustadas, número de épocas e tempo de simulação obtidos através do teste de convergência da rede com e sem a presença do termo <i>momentum</i>	56
Tabela 3 – Parâmetros iniciais para análises das topologias candidatas para o dia de Quinta-Feira.	58
Tabela 4 – Parâmetros definidos para o teste 1 Quinta-Feira.	59
Tabela 5 – Resultados do teste 1 Quinta-Feira.	60
Tabela 6 – Parâmetros definidos para o teste 2 Quinta-Feira.	60
Tabela 7 – Resultados do teste 2 Quinta-Feira.	61
Tabela 8 – Parâmetros definidos para o teste 3 Quinta-Feira.	62
Tabela 9 – Resultados do teste 3 Quinta-Feira.	63
Tabela 10 – Parâmetros iniciais para análises das topologias candidatas para o dia de Domingo.	64
Tabela 11 – Parâmetros definidos para o teste 1 Domingo.	65
Tabela 12 – Resultados do teste 1 Domingo.	66
Tabela 13 – Parâmetros definidos para o teste 2 Domingo.	66
Tabela 14 – Resultados do teste 2 Domingo.	67
Tabela 15 – Parâmetros definidos para o teste 3 Domingo.	68
Tabela 16 – Resultados do teste 3 Domingo.	69

LISTA DE ABREVIATURAS E SIGLAS

ANEEL – Agência Nacional de Energia elétrica

EPE – Empresa de Pesquisa Energética

GA – Genetic Algorithm

ONS – Operador Nacional do Sistema Elétrico

PCHs – Pequenas Centrais Hidrelétricas

PDE – Plano Decenal de Energia

PIB – Produto Interno Bruto

PMC – Perceptron Multicamadas

PMC-TDNN – Perceptron Multicamadas com Entradas Atrasadas no Tempo

RNAs – Redes Neurais Artificiais

SIN – Sistema Interligado Nacional

SVM – Máquinas de Vetores de Suporte

TDNN – Time Delay Neural Network

SUMÁRIO

1.	INTRODUÇÃO.....	25
2.	FATORES DE INFLUÊNCIA E HORIZONTES DE PREVISÕES DE DEMANDA	29
2.1	FATORES DE INFLUÊNCIA PARA PREVISÕES DE DEMANDA DE ENERGIA ELÉTRICA.....	29
2.1.1	INTRODUÇÃO	29
2.1.2	CONSUMIDORES RESIDENCIAIS	30
2.1.3	CONSUMIDORES COMERCIAIS	30
2.1.4	CONSUMIDORES INDUSTRIAIS	31
2.2	HORIZONTES DE PREVISÃO DE DEMANDA	31
2.2.1	INTRODUÇÃO	31
2.2.2	HORIZONTE DE LONGO PRAZO	32
2.2.3	HORIZONTE DE MÉDIO PRAZO.....	32
2.2.4	HORIZONTE DE CURTO PRAZO.....	33
2.2.5	HORIZONTE DE CURTÍSSIMO PRAZO.....	34
2.2.6	CONCLUSÃO	34
3.	SISTEMAS INTELIGENTES E PRINCIPAIS ARQUITETUTAS DE PREVISÃO DE DEMANDA	35
3.1	SISTEMAS INLEGENTES PARA PREVISÃO DE DEMANDA	35
3.1.1	INTRODUÇÃO	35
3.1.2	ALGORITMOS GENÉTICOS.....	35
3.1.3	REGRESSÃO LINEAR MÚLTIPLA.....	36
3.1.4	REDES NEURAIAS ARTIFICIAIS	37
	ARQUITETURAS DE REDES NEURAIAS	39
	ARQUITETURA FEEDFORWARD DE CAMADA SIMPLES.....	40
	ARQUITETURA FEEDFORWARD DE CAMADAS MÚLTIPLAS	40
	ARQUITETURA RECORRENTE OU REALIMENTADA.....	41
	REDE PERCEPTRON.....	42
	REDE PERCEPTRON MULTICAMADAS (PMC).....	43
3.1.5	LÓGICA FUZZY	46
3.1.6	SISTEMAS HÍBRIDOS	46
3.2	CONTEXTUALIZAÇÃO DO PROJETO.....	47
3.2.1	INTRODUÇÃO	47
3.2.2	REDE PMC-TDNN	48
3.2.3	FLUXOGRAMA DAS REDES PMC.....	48
3.2.4	EQUAÇÕES CARACTERÍSTICAS DAS REDES PMC	49
3.2.5	CONCLUSÃO	52
4.	DESENVOLVIMENTO DO PROJETO E ANÁLISES DOS REDULTADOS.....	53

4.1	DESENVOLVIMENTO DO PROJETO	53
4.1.1	INTRODUÇÃO	53
4.1.2	TRATAMENTO DOS DADOS	53
4.1.3	IMPLEMENTAÇÃO DO ALGORITMO DE TREINAMENTO	54
4.1.4	IMPLEMENTAÇÃO DO ALGORITMO DE FASE DE OPERAÇÃO	55
4.2	ANÁLISE DOS RESULTADOS	56
4.2.1	CONVERGÊNCIA DO TERMO MOMENTUM	56
4.2.2	ANÁLISES DAS TOPOLOGIAS CANDIDATAS 1.	58
	ANÁLISE DO ALIMENTADOR A QUINTA-FEIRA TESTE 1.	58
	ANÁLISE DO ALIMENTADOR A QUINTA-FEIRA TESTE 2.	60
	ANÁLISE DO ALIMENTADOR A QUINTA-FEIRA TESTE 3.	62
4.2.3	ANÁLISES DAS TOPOLOGIAS CANDIDATAS 2.	64
	ANÁLISE DO ALIMENTADOR B DOMINGO TESTE 1.	64
	ANÁLISE DO ALIMENTADOR B DOMINGO TESTE 2.	66
	ANÁLISE DO ALIMENTADOR B DOMINGO TESTE 3.	68
4.3	CONCLUSÃO	70
5.	CONCLUSÃO	71
5.1	CONCLUSÕES GERAIS	71
5.2	SUGESTÃO PARA TRABALHOS FUTUROS	72
	REFERÊNCIAS.....	74

1. INTRODUÇÃO

O sistema elétrico brasileiro é um dos mais extensos do mundo e a maior parte da geração da energia é realizada pelas usinas hidrelétricas. Cicconet (2013) destaca que, na maioria dos casos grande quantidade destas usinas está localizada em locais afastados dos principais centros consumidores de cargas tanto industriais quanto residenciais.

Operador Nacional do Sistema Elétrico (ONS) coordena a operação do sistema interligado nacional (SIN) que abrange todas as regiões do país, realizando e coordenando as possibilidades de troca de energia elétrica entre as regiões, visando suprir as demandas necessárias de energia. De acordo com a Lei de nº 10848 Art. 1º que dispõe sobre o novo modelo de comercialização de energia elétrica, os serviços e instalações de energia elétrica assim como seus consumidores podem optar por um regime de contratação regulada ou livre. Como critério de comercialização, fica definido a oferta de menor tarifa como parâmetro para participação nas licitações de energia elétrica e empreendimento. Em 2005 ANEEL aprovou a Resolução Normativa nº 205, de 22 de dezembro de 2005, onde ficam estabelecidos os procedimentos e as condições do modelo de contrato de permissão para que as cooperativas de eletrificação rural atuem como distribuidores de energia elétrica.

No modelo de mercado livre de comercialização de energia elétrica, a compra e a venda de energia elétrica são realizadas através de leilões, onde, quem compra energia são as distribuidoras e quem vende são as geradoras, podendo entregar a energia em prazos de até 5 anos. Os leilões de energia também possuem a característica de indicar o cenário de oferta e procura a curto, médio e longo prazo, desse modo, previsões futuras de demanda de energia passaram a ter grande relevância para se planejar os investimentos nas áreas de geração, transmissão e

distribuição de energia elétrica. Os cenários refletidos através destes leilões são descritos por Andrade (2010) como horizontes de previsão de demanda, onde tais horizontes podem ser classificados em longo prazo, médio prazo, curto prazo e curtíssimo prazo, onde cada um desses horizontes possui uma especificidade singular.

O setor energético é um dos segmentos socioeconômicos mais importantes de qualquer cidade, estado ou país. Uma das ferramentas que melhor pode direcionar o setor é a previsão de carga e demanda. De acordo com Ferreira (2008) previsão de carga é de fundamental importância para operação do sistema elétrico, garantindo a operação e o planejamento de forma confiável e seguro. Devido à complexidade das atividades do sistema elétrico, as projeções de carga e de demanda de energia elétrica são atividades estratégicas e determinísticas para a operação do sistema. Conforme descrito por (MTEMBO; TAYLOR; EKWUE, 2014) o futuro dos sistemas de geração, transmissão e distribuição depende fundamentalmente de sistemas de previsão de energia com excelente grau de precisão, pois o planejamento da expansão das redes de transmissão, o planejamento da operação e o gerenciamento de despacho estão diretamente relacionados com a precisão da estimativa de cargas e demandas futuras.

Para realizar o planejamento da coordenação de previsão de carga e de demanda de energia elétrica, é necessário considerar uma série de fatores, tais como a demografia, o PIB, a expansão da capacidade instalada e da produção dos grandes consumidores industriais, estão entre alguns dos principais indicadores a serem considerados (EPE, 2013).

De acordo com o ONS, os agentes de distribuição de energia elétrica devem realizar a previsão de demanda de energia elétrica de maneira segmentada, ou seja, a previsão deve ser realizada para cada barramento individual e os agentes devem fornecer previsões de potência ativa e reativa, para um horizonte mínimo de sete meses (FERREIRA, 2008). Em meio à necessidade de se realizarem previsões de demanda de energia elétrica, as pesquisas e estudos relacionados aos sistemas inteligentes de previsão têm avançado consideravelmente nos últimos anos, possibilitando a utilização e adaptação de diversas técnicas que vem sendo utilizadas para prever demandas.

Para Carmona et al. (2002) as empresas que trabalham como geradoras ou distribuidoras de energia elétrica necessitam de sistemas de previsão de energia

elétrica tanto para o curto prazo quanto para o médio e longo prazo, permitindo assim o controle do estoque de combustível, coordenação entre o fornecimento e a demanda, aumento e manutenção dos sistemas de transmissão e construção de novas unidades de geração. Ainda de acordo Carmona et al. (2002) que utiliza técnicas de redes neurais para realizar as previsões no longo prazo, o tratamento dos dados na etapa de pré-processamento elimina a linha de tendência de crescimento, que é um fator muito comum para esse horizonte de previsão.

Conforme descrito em (ALTRAN, 2010) que utiliza técnicas de redes neurais composta por módulos para abordar a previsão de carga multinodal, considerando vários pontos da rede elétrica para a realização da previsão. O sistema proposto por (ALTRAN, 2010) tem como característica a realização de previsão de carga em vários pontos do sistema em um tempo muito menor do que realizar a previsão de carga uma a uma. Para Andrade (2010) que objetiva realizar previsões no curtíssimo prazo, a utilização de sistemas fuzzy se mostrou muito eficaz através de testes realizados para diversas configurações de entrada em diferentes tipos de arquiteturas. Segundo Andrade (2010) a grande vantagem na utilização da lógica fuzzy é a capacidade que a rede possui de filtrar uma grande quantidade de dados em conjuntos menores.

No desenvolvimento desse trabalho foi utilizada uma técnica utilizando redes neurais artificiais com atraso no tempo, com o intuito de tornar possível prever comportamentos futuros de demanda de energia elétrica. As técnicas e os modelos desenvolvidos foram adaptadas à necessidade específica de um agente distribuidor de energia elétrica, cujo perfil de consumo de energia elétrica por parte de seus clientes apresenta características diversificadas e tendências sazonais durante o ano.

O presente trabalho está desenvolvido em 6 capítulos. O capítulo 2 trata sobre os fatores que influenciam os sistemas de previsão de demanda, os perfis de consumidores e os usos finais de energia de cada setor e também dos horizontes de demanda utilizados para as previsões. No capítulo 3 são abordados os principais sistemas inteligentes utilizados para previsões de demanda, assim como, as principais redes e arquiteturas de interesse para o desenvolvimento do projeto. O capítulo 4 aborda o desenvolvimento do projeto, a rede utilizada e a implementação do algoritmo para fase de treinamento e operação e, também, a análise dos resultados. Por último o capítulo 5 aborda as conclusões do trabalho.

2. FATORES DE INFLUÊNCIA E HORIZONTES DE PREVISÕES DE DEMANDA

2.1 FATORES DE INFLUÊNCIA PARA PREVISÕES DE DEMANDA DE ENERGIA ELÉTRICA

2.1.1 INTRODUÇÃO

Diversos fatores influenciam no consumo de energia elétrica. Dentre esses fatores, destacam-se a evolução das tecnologias e a acessibilidade a equipamentos eletroeletrônicos que antes eram de difícil acesso a grande parte da população e que hoje em dia tornaram-se comuns em todas as partes, contribuindo consideravelmente para o aumento do consumo de energia. Fatores econômicos também causam grande influência nos hábitos de consumo de uma população, uma vez que a renda per capita familiar aumenta o consumo de energia utilizado pela população consumidora tende a aumentar.

Para Gellings (1996) uma das grandes dificuldades em realizar previsões de demanda de energia elétrica está relacionada ao comportamento de milhares de consumidores individuais que, conseqüentemente, são impulsionados pelo crescimento ou decréscimo da economia. Fatores culturais e variações demográficas representam grandes contribuições no consumo de energia. Gellings (1996) também destaca os perfis de consumidores e os classifica em três classes principais de consumidores: residenciais, comerciais e industriais, cada uma dessas classes possui características diferentes de consumo.

2.1.2 CONSUMIDORES RESIDENCIAIS

De acordo com EPE (2013) o consumo de energia elétrica no Brasil para o setor residencial está relacionado às variáveis demográficas como população, número de domicílios, número de habitantes por domicílio e o consumo médio por consumidor, o que está diretamente correlacionado com o PIB e a renda per capita.

O uso final que os consumidores residências fazem da energia elétrica impacta diretamente todo o sistema, conforme descrito por Gellings (1996) o setor residencial provoca um aumento rápido na demanda de energia e contribui grandemente com as cargas de pico do sistema, segundo Gellings (1996), entre os anos de 1960 a 1995, as donas de casa causavam grandes impactos no sistema, uma vez que hábitos de usos de equipamentos elétricos domésticos demandavam o fornecimento de energia elétrica para atender as necessidades dos consumidores residenciais. Destaca-se também a influência dos fatores climáticos no consumo de energia dos clientes residenciais, períodos com temperaturas mais elevadas provocam o aumento na carga do sistema, impulsionado pelo crescimento do número de domicílios com ar condicionado.

2.1.3 CONSUMIDORES COMERCIAIS

Para esse perfil de consumidor enquadram-se os edifícios comerciais, estabelecimentos de varejo, escolas e hospitais. Conforme descrito em EPE (2013), no Brasil, a classe de consumidores comerciais é a que irá apresentar o maior crescimento no período de 2013-2023.

Observa-se através de Gellings (1996) que as principais categorias que contribuíram para o crescimento do consumo de energia do setor comercial foram o crescimento da força de trabalho, novos usos e aplicações de eletricidade e a forte competitividade no mercado de trabalho. O setor comercial também sofre a influência dos fatores climáticos, o aumento do consumo de energia elétrica provocado com a refrigeração de ambientes de trabalho tem provocado um aumento na demanda de energia no horário comercial.

2.1.4 CONSUMIDORES INDUSTRIAIS

Os consumidores industriais representam a maior parte do consumo de energia elétrica no país e conseqüentemente possuem um papel determinante para o planejamento e a expansão do sistema. De acordo com Gellings (1996) os consumidores do setor industrial exigem uma abordagem de forma mais complexa em relação aos setores residenciais e comerciais. Para o autor a subdivisão do setor em segmentos particionados de acordo com o ramo e o setor de atuação facilita identificar a aplicação e o uso final que se destina ao consumo de energia.

Pode ser observado através de EPE (2013) que as perspectivas de evolução do setor têm que levar em consideração os investimentos públicos e privados no setor, onde os grandes consumidores industriais atuam também como autoprodutores de energia, sendo alguns autossuficientes para suprirem suas demandas e ainda fornecendo o excedente de energia para a rede. O setor comercial possui tendências de consumo de energia que estão diretamente correlacionadas com o crescimento econômico nacional e internacional, política de exportação, variação cambial, entre outros fatores.

2.2 HORIZONTES DE PREVISÃO DE DEMANDA

2.2.1 INTRODUÇÃO

Os cenários utilizados para previsões de demanda apresentam características distintas que podem variar desde o período clássico de faturamento, qual seja a cada 15 minutos ou por hora ao longo de vários meses, anos ou décadas à frente. De maneira geral, os horizontes temporais das previsões não devem ser caracterizados unicamente em função do tempo ou do período. De acordo com (Ferreira, 2008; Andrade, 2010) horizontes de previsões que para uma determinada empresa são considerados de curto prazo, para outra empresa podem ser considerados de longo prazo, dependendo do estudo e da finalidade da aplicação.

2.2.2 HORIZONTE DE LONGO PRAZO

Previsões de demanda de longo prazo contemplam horizontes temporais que variam de anos a décadas à frente. Segundo Andrade (2010) esse horizonte de previsão possui a finalidade de fornecer a evolução da demanda de energia para distribuidoras e geradoras, colaborando para definições de estratégias e ampliação das linhas de transmissão.

Para a EPE (2013) esse tipo de projeção é de fundamental importância para elaboração do Plano Decenal de Energia (PDE), fornecendo informações importantíssimas para o desenvolvimento dos estudos desenvolvidos para elaboração do plano. Previsões de carga para longo prazo destinam-se principalmente para apontar os requisitos da elevação da capacidade de expansão e estudos econômicos como o tempo de retorno de capital investido (Parlos et al., 1996, pp. 288,292).

De acordo com Altran (2010), esse tipo de horizonte é extremamente importante para fornecer subsídio ao processo de tomada de decisões referentes ao aumento da capacidade de atendimento ao mercado consumidor. De certo modo, para esses horizontes de previsão, é muito difícil obter grandes precisões nas previsões futuras, uma vez que, devido ao longo prazo diversas incertezas com relação aos acontecimentos futuros não podem ser quantificadas com extremo grau de precisão, conforme observado por (Parlos et al., 1996, pp. 288,292).

2.2.3 HORIZONTE DE MÉDIO PRAZO

Horizontes de demanda de médio prazo caracterizam-se por análises de períodos que variam de semanas a meses à frente. Como descrito por Ferreira (2008), esse tipo de horizonte de previsão fornece subsídio para o planejamento da expansão do sistema e principalmente para a operação do sistema elétrico de potência. Além disso possibilita a programação da compra de combustível, planejamento da manutenção de equipamentos, intercâmbios entre áreas, desenvolvimento de políticas tarifárias e serve também como pesquisa de mercado para produtores e revendedores negociarem contratos com outras empresas, possibilitando uma redução nos riscos financeiros envolvidos como relatado por (Ferreira, 2008; Andrade, 2010).

Este horizonte de previsão é de grande utilidade tanto para geradores quanto para agente distribuidores. Segundo (Falvo et al., 2006, pp. 1291,1295) o horizonte de médio prazo é determinante para o planejamento da geração de energia, planejamento das centrais térmicas, gerenciamento dos recursos hídricos e para programação de serviços de manutenção. No que se refere a transmissão e a distribuição, os autores consideram que o horizonte de médio prazo fornece subsídios para o planejamento da expansão da capacidade dos sistemas de transmissão e distribuição, garantindo o fornecimento de energia e o atendimento a demanda dos clientes no médio prazo.

2.2.4 HORIZONTE DE CURTO PRAZO

Para esse tipo de horizonte de previsão de demanda os intervalos variam de dias a semanas à frente. De acordo com Altran (2010) esse horizonte tem por finalidade realizar a alocação econômica dos geradores a fim de que o custo com a produção de energia elétrica seja o menor possível.

Uma abordagem interessante em relação ao horizonte de curto prazo é descrita por Ferreira (2008), o qual destaca a importância para a operação e o controle em tempo real de sistemas de potência, fornecendo subsídios para a análise de segurança, elaboração de estratégias de gerenciamento de carga, programação da geração, estudos de fluxo de potência, estudos de contingência, coordenação hidrotérmica, além do intercâmbio entre as áreas.

Os horizontes de curto prazo são os mais pesquisados no que se refere às previsões de demanda de energia elétrica. O autor relaciona o grande número de estudos realizados para este horizonte com as características de tomadas de decisões que estão diretamente relacionadas aos intervalos de estudo. Análises de confiabilidade, avaliação de segurança do sistema, planejamento de manutenção dos geradores, entre outros estudos, podem ser realizados através deste horizonte conforme descrito por Andrade (2010).

Além de grande importância com relação ao ponto de vista técnico, o horizonte de previsão de demanda no curto prazo possui grande importância em relação a fatores econômicos, Ferreira (2008) relata sobre a competição dos mercados de energia em diversos países, uma vez que, a previsão de carga e demanda no curto prazo está diretamente interligada à redução dos custos

operacionais das empresas de energia e servem para fornecer informações essenciais para a elaboração dos preços da energia e o desenvolvimento de políticas tarifárias.

2.2.5 HORIZONTE DE CURTÍSSIMO PRAZO

Nesse tipo de horizonte de previsão de demanda os intervalos variam de minutos a poucas horas à frente. De acordo com Andrade (2010) esse tipo de previsão requer uma abordagem cujo foco está na análise do comportamento recente das amostras analisadas a fim de se obter previsões para o futuro próximo.

Para Altran (2010), a utilização de intervalos inferiores a uma hora podem exprimir com maior exatidão os perfis instantâneos de carga, fornecendo maiores subsídios para tomadas de decisões sobre os processos com maiores disponibilidades de potência. Através do horizonte de curtíssimo prazo é possível caracterizar com maior exatidão o perfil instantâneo da carga, esse horizonte também serve para fornecer subsídios ao gerenciamento das unidades geradoras Bordignon (2012).

Como descrito por Setiawan et al., (2009), na Austrália esse horizonte de previsão de demanda desempenha um papel importante para o funcionamento do mercado nacional de energia elétrica. Através deste horizonte de previsão, tanto geradores quanto operadores de rede devem informar sua capacidade máxima de abastecimento, permitindo assim que o restante das empresas participantes do setor contribua ativamente para responder à possível deficiência do sistema de abastecimento.

2.2.6 CONCLUSÃO

Neste capítulo apresentou-se estudos referentes aos principais fatores de influência em sistemas de previsão de demanda. Abordou-se os diversos segmentos de clientes consumidores de energia elétrica, destacando alguns dos principais usos finais de energia que cada segmento pratica. Foram abordados também os horizontes de previsão, destacando a finalidade que cada horizonte de previsão representa para o sistema.

3. SISTEMAS INTELIGENTES E PRINCIPAIS ARQUITETUTAS DE PREVISÃO DE DEMANDA

3.1 SISTEMAS INLEGENTES PARA PREVISÃO DE DEMANDA

3.1.1 INTRODUÇÃO

Existem inúmeros métodos e sistemas utilizados para realizar previsões de demanda de energia elétrica. Na maioria dos casos os métodos utilizam informações sobre o passado dos dados para se obterem informações futuras que serão refletidas em função desse histórico de dados.

A definição e escolha de qual método é mais adequado para se utilizar está diretamente relacionado ao horizonte para qual se deseja obter as previsões de demanda. Modelos baseados em estatísticas, regressão linear, algoritmos genéticos, redes neurais artificiais, mapas auto organizáveis, cadeia de Markov, lógica fuzzy e principalmente modelos híbridos, que são uma mistura de algum tipo de algoritmo neural com mais alguma outra técnica, estão entre os mais utilizados e destacados através da literatura.

3.1.2 ALGORITMOS GENÉTICOS

Algoritmos genéticos (GA, do inglês Genetic Algorithm) são técnicas computacionais baseadas na teoria da evolução das espécies estudada pelo naturalista inglês e criador da teoria da evolução natural Charles Darwin.

Esse tipo de algoritmo consiste em técnicas de otimização. Conforme descrito por Jing-Ling et al. (2008) os GA são desenvolvidos através de simulações selecionadas da variação do cruzamento de população, iterativamente auto

adaptativo. O GA é empregado para encontrar soluções aleatoriamente no espaço e descobrir qual a melhor solução para aquele tipo de aplicação.

Para Peixian et al. (2011) os GA codificam as soluções dos problemas com “cromossomo” e os implementa através de sequência de codificação. Inicialmente, antes da implementação do algoritmo, deve-se definir um grupo de “cromossomos” iniciais que serão supostamente considerados como soluções. Primeiramente a solução deve assumir que seja selecionado sempre o “cromossomo” que se mostrar mais forte e adaptável aquela situação. Em seguida o “cromossomo” é replicado para outros grupos através do cruzamento de mutações e finalmente tende a convergir para o “cromossomo” que melhor se adapta ao contexto do problema e assim seja a solução ideal para o problema.

3.1.3 REGRESSÃO LINEAR MÚLTIPLA

O método de regressão linear múltipla consiste em uma técnica estatística utilizada para estimação de parâmetros desconhecidos através de uma relação matemática entre as variáveis de interesse. Esse tipo de técnica consiste na redução no número de variáveis, detectando os padrões de similaridade e fazendo associações entre as variáveis estudadas. De acordo com Gellings (1996) o método de regressão linear múltipla é uma ferramenta de análise linear, desenvolvida através das técnicas dos mínimos quadrados e correlacionada através de análises da variância e do desvio padrão.

Um modelo de análise de regressão linear descrito por Gellings (1996) pode ser observado através da seguinte equação:

$$Y_i = \alpha + \beta_1 X_{1i} + \beta_2 X_{2it} \dots + \beta_k X_{ki} + \varepsilon_i \quad (1)$$

O termo X representa as variáveis observadas, β representa os coeficientes associados às variáveis de entrada e ε representa o erro da distribuição normal. Esse modelo é definido como regressão linear múltipla, por se tratar de um modelo que envolve mais de um coeficiente de regressão linear e as saídas Y desejadas são obtidas a partir de X entradas.

Conforme descrito por Bunnoon et al. (2006) para problemas que possam ser classificados como funções lineares e contenham duas ou mais variáveis, esse método é uma excelente alternativa para realizar o ajuste dos dados.

3.1.4 REDES NEURAIS ARTIFICIAIS

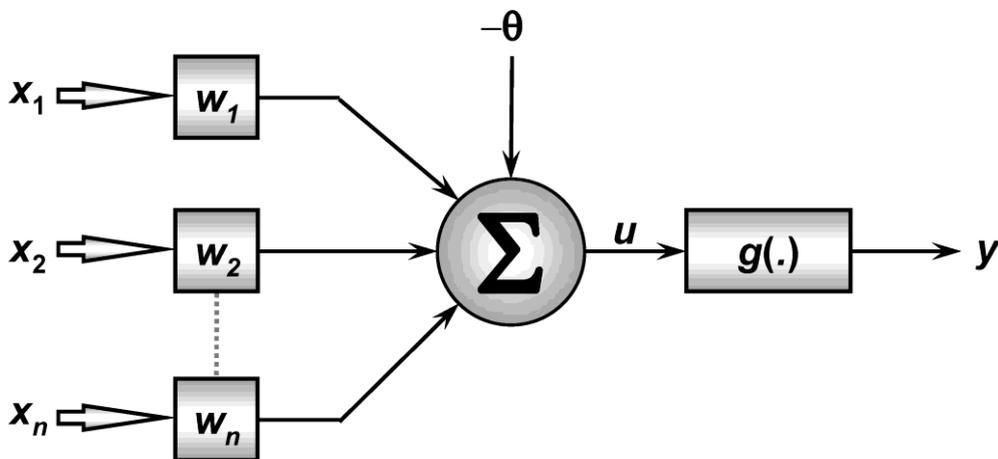
As redes neurais artificiais (RNAs) são poderosas ferramentas que podem ser aplicadas em diversos tipos de problemas. Para Silva et al. (2010) RNAs são tidos como modelos computacionais inspirados de acordo com o sistema nervoso dos seres vivos. Observa-se em (Ferreira, 2008; Bordignon, 2012) que as RNAs também podem ser vistas como um modelo de um processador de sinais que estão paralelamente distribuídos e são constituídos de unidades de processamento simples, conhecidos como neurônios.

Pesquisas referentes a RNAs não são recentes. Estudos históricos relatam que esse tipo de sistema vem sendo utilizado desde meados do século XX, porém, como descrito por Silva et al. (2010), a partir do final dos anos 80, com o desenvolvimento de computadores com maior capacidade de processamento, as pesquisas e estudos relacionados ao tema tiveram realmente interesse e resultados mais significativos. Atualmente, existem inúmeras aplicações práticas que são realizadas em diferentes áreas de conhecimento, aumentando consideravelmente os desenvolvimentos teóricos e as contribuições em pesquisas associadas às redes neurais artificiais.

De maneira análoga aos neurônios biológicos, os neurônios artificiais que compõem a estrutura das RNAs são constituídos de camadas que estão interligadas entre si, definindo a arquitetura do modelo. Conforme Altran (2010), o neurônio artificial é uma unidade de processamento de informação e assim do mesmo modo que o neurônio biológico é fundamental para operação das RNAs. A Figura 1 ilustra a representação do modelo de neurônio artificial, cujo o modelo engloba as principais características de uma rede neural biológica. Deste modo como descrito por Silva et al. (2010) o modelo da Figura 1 pode ser subdividido em sete elementos como descrito a seguir:

- $\{X_1 \dots X_n\}$ Sinais de entrada.
- $\{W_1 \dots W_n\}$ Pesos sinápticos.
- $\{\theta\}$ Limiar de ativação.
- $\{\Sigma\}$ Combinador linear.
- $\{u\}$ Potencial de ativação.
- $\{g\}$ Função de ativação.
- $\{y\}$ Sinal de saída.

Figura 1 - Representação do neurônio artificial



Fonte: Silva et al. (2010, p. 34)

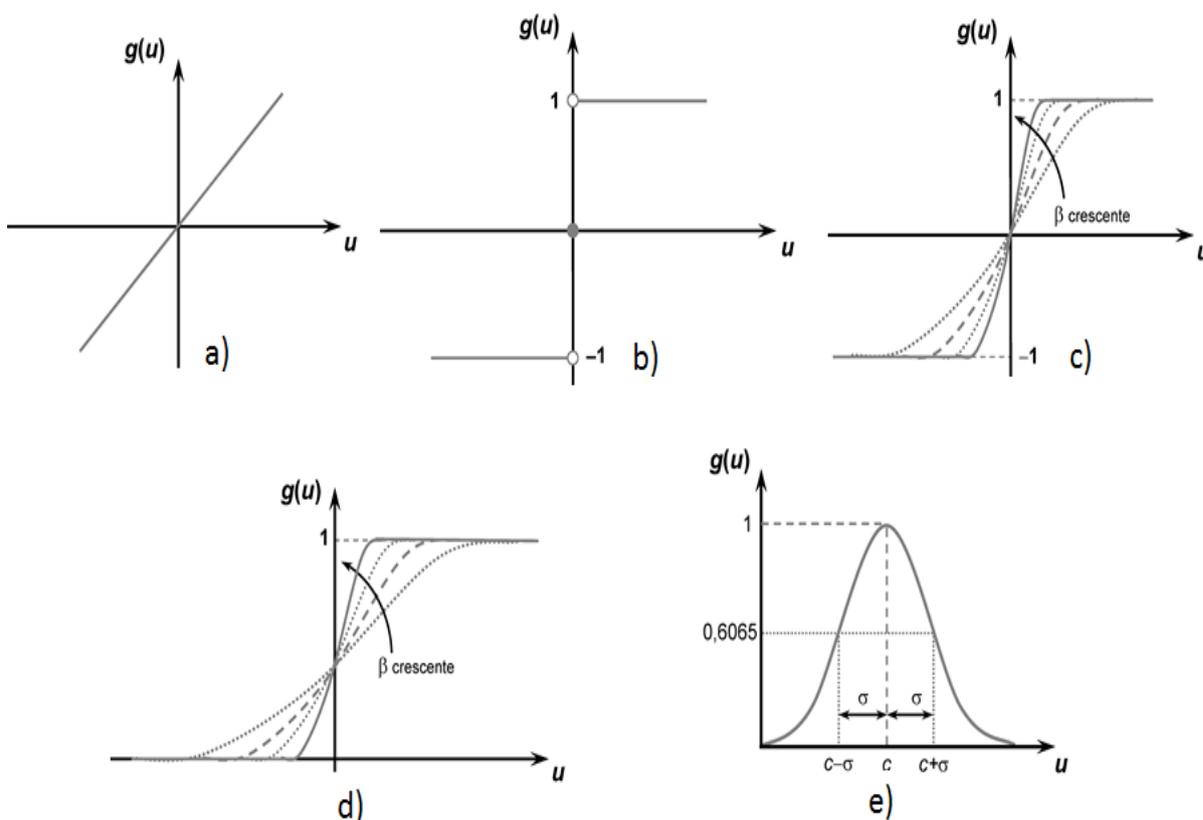
De acordo com Silva et al. (2010) o resultado produzido pelo neurônio artificial pode ser sintetizado através das seguintes expressões:

$$u = \sum_{i=1}^n W_i \cdot X_i - \theta \quad (2)$$

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

Outra observação de fundamental importância é relacionada com a função de ativação. Segundo Silva et al. (2010), tais funções têm como objetivo limitar a saída do neurônio para que fique contida dentro de um intervalo de valores. Na Figura 2, encontram-se representadas algumas das principais funções de ativação.

Figura 2 – Funções de ativação, a) linear, b) degrau bipolar, c) tangente hiperbólica, d) logística, e) gaussiana.



Fonte: Silva et al. (2010, p. 42)

Arquiteturas de Redes Neurais

Existem diferentes arquiteturas de redes ou sistemas neurais que são utilizadas para diversas aplicações em diferentes segmentos de análises e estudos, porém, todas elas possuem uma arquitetura básica em comum que se divide em três partes, denominadas camadas. Conforme descrito por Silva et al. (2010) as camadas subdividem-se em camadas de entrada, camadas escondidas ou intermediárias e camadas de saída.

- Camada de entrada: recebe informações ou dados externos, que são oriundos de sinais amostrados, ensaios realizados, medições realizadas, etc. Os dados geralmente são normalizados afim de que se obtenha uma melhor precisão nos resultados que são obtidos através de expressões matemáticas.
- Camada intermediária: é onde ocorre praticamente todo o processamento da rede. São camadas compostas por neurônios que

possuem a incumbência de extrair informações referentes ao processamento dos dados.

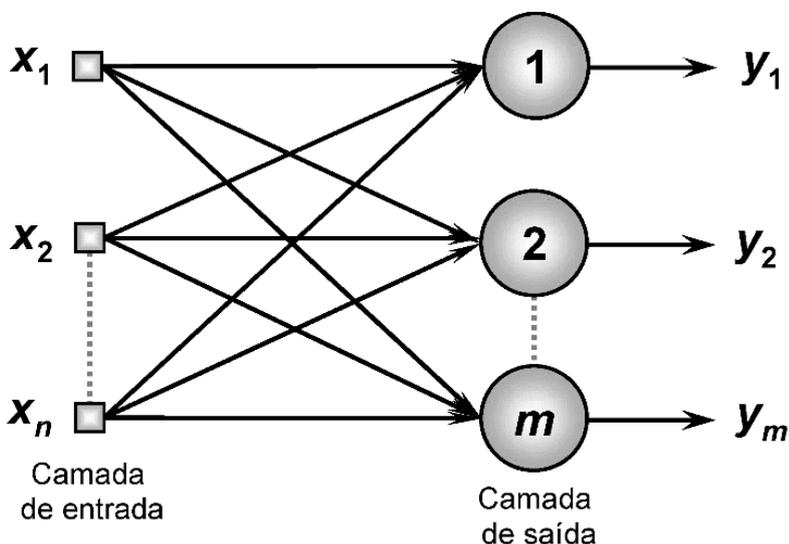
- Camada de saída: é a camada onde são apresentados os resultados finais do processamento dos dados. É formada por neurônios que produzem e apresentam os resultados dos dados que anteriormente são processados pelos neurônios das camadas intermediárias.

Arquitetura *feedforward* de camada simples

É um tipo simples de arquitetura de redes neurais e sua composição é modelada por uma única camada de entrada e uma única saída. O fluxo de informações é unidirecional, fluindo da camada de entrada para camada de saída. Destacam-se como principais redes com esse tipo de arquitetura de camada simples, as redes *Perceptron* e a *Adaline*, conforme Silva et al. (2010).

A Figura 3 ilustra a representação de uma rede *feedforward* de camada simples cuja composição está representada por n entradas e m saídas.

Figura 3 – Rede *feedforward* de camada simples



Fonte: Silva et al. (2010, p. 47)

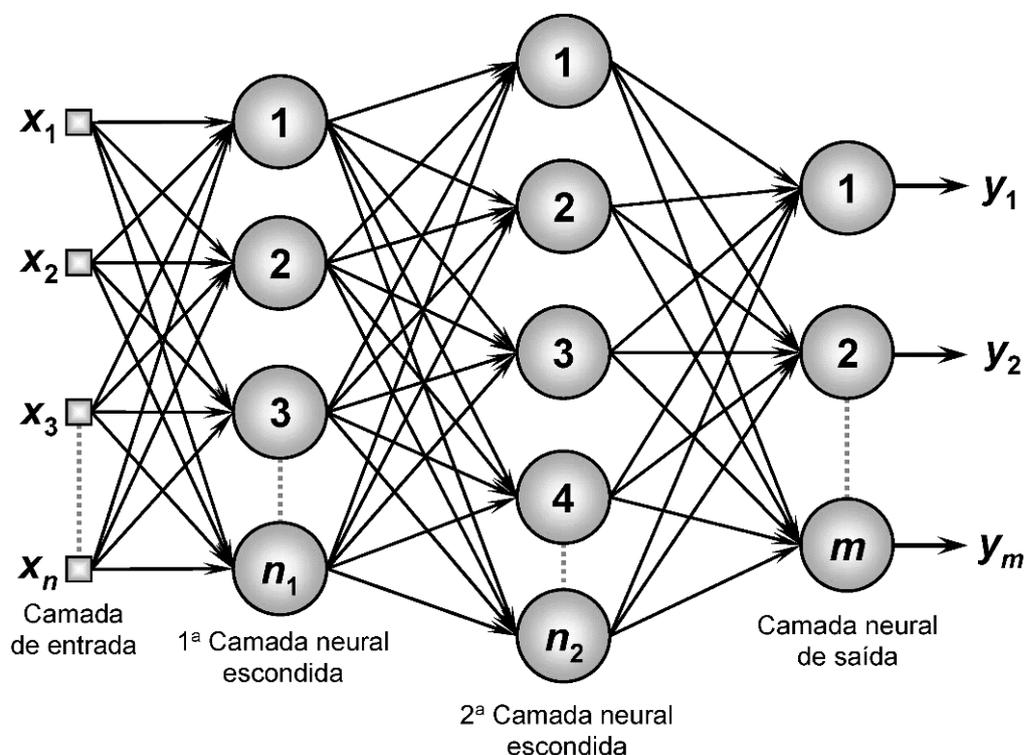
Arquitetura *feedforward* de camadas múltiplas

As redes *feedforward* de camadas múltiplas são constituídas pela presença de uma ou mais camadas intermediárias de neurônios. O número de camadas escondidas e de neurônios que constituem a rede depende da complexidade do

problema que se deseja mapear através da rede. A quantidade de neurônios que constitui a primeira camada escondida geralmente é diferente do número de sinais que compõe a entrada da rede. Podem ser destacados como principais tipos de redes para esse tipo de arquitetura de múltiplas camadas as redes *Perceptron* multicamadas e as redes de base radial Silva et al. (2010).

A Figura 4 ilustra a representação de uma rede *feedforward* de camadas múltiplas cuja composição está representada por n sinais de entradas, duas camadas neurais escondidas, de n_1 e n_2 neurônios e uma camada neural composta m neurônios de saídas.

Figura 4 – Rede *feedforward* de camadas múltiplas



Fonte: Silva et al. (2010, p. 48)

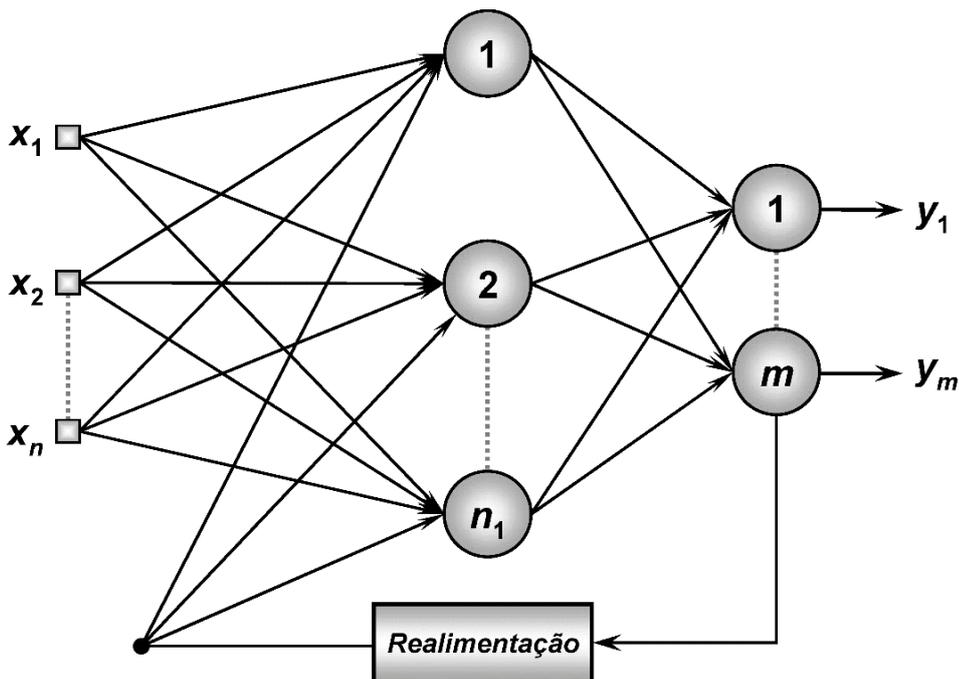
Arquitetura recorrente ou realimentada

Nesse tipo de arquitetura as saídas dos neurônios são realimentadas com sinais de entrada para outros neurônios, realizando processamento dinâmico de informações, onde tais características possibilitam a utilização dessas redes em sistemas variantes em relação ao tempo. Destacam-se como principais redes que utilizam esse tipo de realimentação, as redes de *Hopfield* e a rede *Perceptron*

multicamadas com realimentação entre neurônios situados em camadas distintas, conforme Silva et al. (2010).

A Figura 5 ilustra a representação de uma rede *Perceptron* com realimentação com um dos sinais amostrados na camada de saída realimentando os neurônios da camada intermediária.

Figura 5 – Rede recorrente.

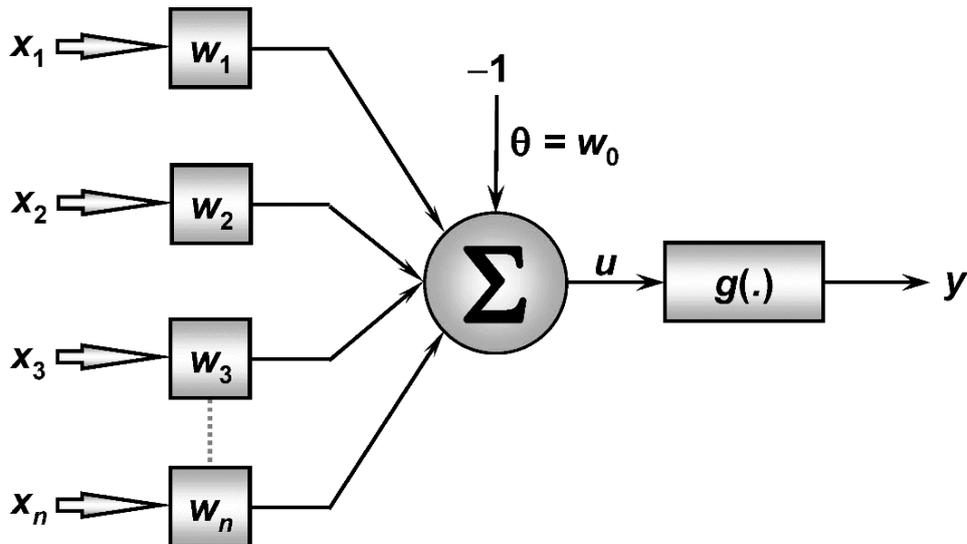


Fonte: Silva et al. (2010, p. 49)

Rede Perceptron

A rede Perceptron pode ser vista como a forma mais simples para a configuração de RNAs. De acordo com Silva et al. (2010) a simplicidade da rede está relacionado à sua condição de possuir apenas uma camada neural, um neurônio artificial e somente uma saída. A Figura 3 ilustra esse tipo de rede que pertence à arquitetura *feedforwad* (alimentação à frente), cujo o fluxo de informações flui no sentido da camada de entrada a camada neural de saída.

Figura 6 – Rede Perceptron.



Fonte: Silva et al. (2010, p. 58)

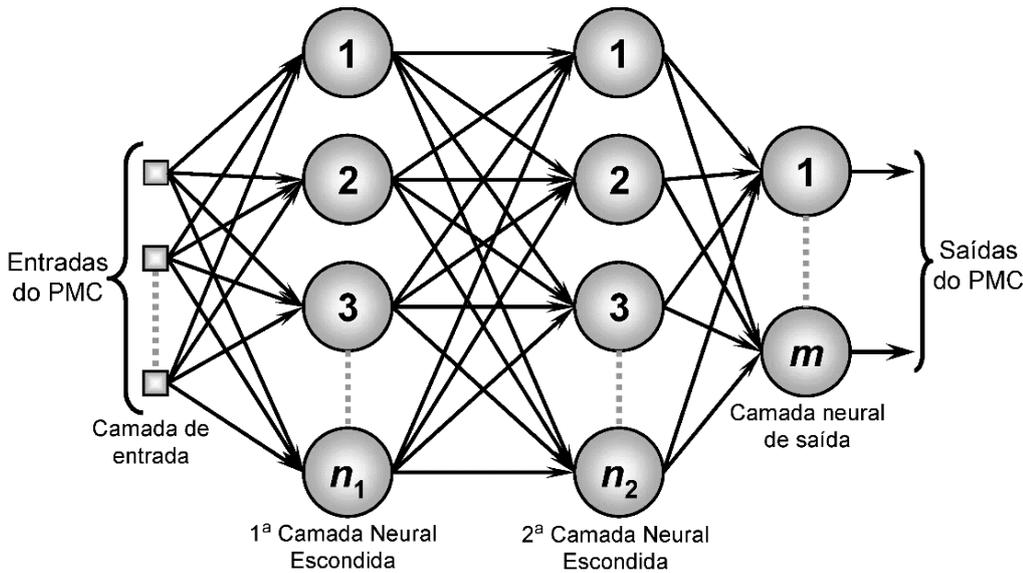
Para fins de representação da análise matemática da rede Perceptron, assumindo a função de ativação como (degrau bipolar), as saídas y receberão os valores 1 ou -1. A expressão 4 ilustra o comportamento matemático para este modelo de rede.

$$y = \begin{cases} 1, \text{ se } \sum_{i=1}^n W_i \cdot X_i - \theta \geq 0 \Leftrightarrow W_1 \cdot X_1 + \dots + W_n \cdot X_n - \theta \geq 0 \\ -1, \text{ se } \sum_{i=1}^n W_i \cdot X_i - \theta < 0 \Leftrightarrow W_1 \cdot X_1 + \dots + W_n \cdot X_n - \theta < 0 \end{cases} \quad (4)$$

Rede Perceptron Multicamadas (PMC)

Este tipo de rede pode ser caracterizado por possuir no mínimo uma camada intermediária de neurônio situada entre a camada de entrada e a camada de saída. De acordo com Silva et al. (2010) nesse tipo de arquitetura de múltiplas camadas, o treinamento é realizado de forma supervisionada, iniciando através da camada de entrada e em seguida percorrendo as camadas intermediárias até fluir para camada neural de saída. Na Figura 7 encontra-se representado o esquemático desse modelo de arquitetura.

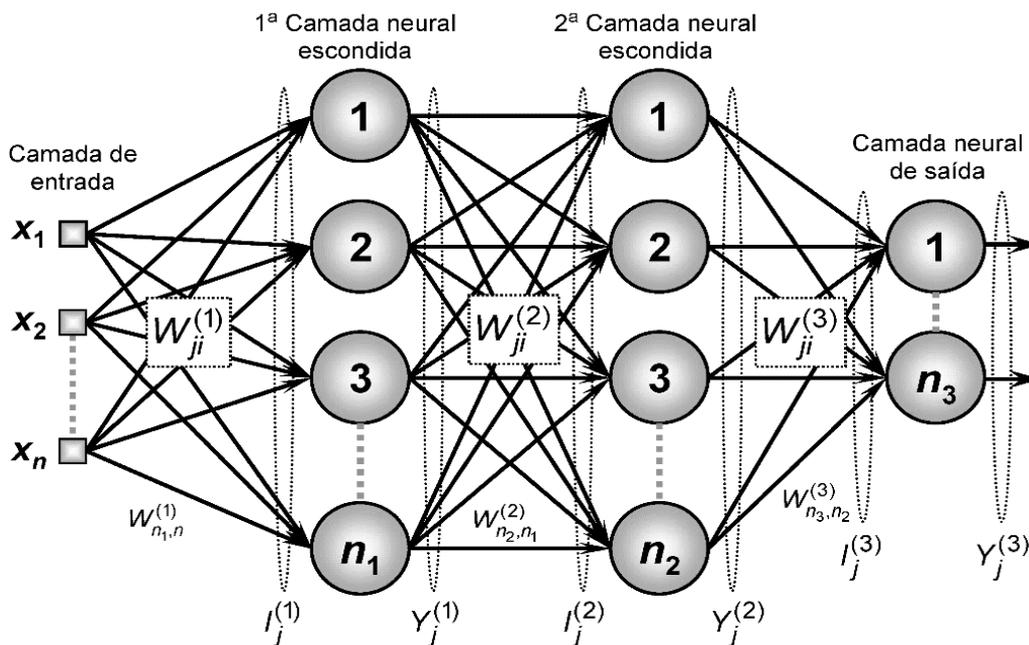
Figura 7 – Representação da Rede PMC.



Fonte: Silva et al. (2010, p. 92)

Pode ser observado que de maneira diferente a rede Perceptron, a rede PMC possui a presença de camadas intermediárias e também pode possuir m saídas. Para realizar o treinamento o algoritmo utilizado no processo é chamado de *backpropagation* ou algoritmo de retro propagação. A Figura 8 ilustra o princípio de funcionamento do treinamento *backpropagation*.

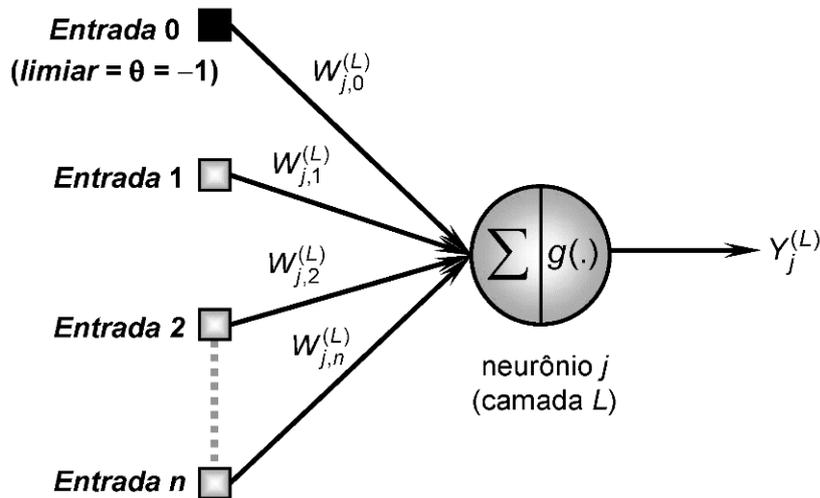
Figura 8 – Derivação do algoritmo *backpropagation*.



Fonte: Silva et al. (2010, p. 95)

Cada neurônio pertencente a alguma das camadas da topologia pode ser configurado através da função de ativação, desde que a função seja contínua e diferenciável em todo o seu domínio Silva et al. (2010). A Figura 9 a seguir ilustra o neurônio utilizado na diferenciação do algoritmo *backpropagation*.

Figura 9 – Neurônio utilizado na diferenciação do algoritmo *backpropagation*.



Fonte: Silva et al. (2010, p. 96)

Com relação as figuras 8 e 9 obtêm-se:

- $W_{ji}^{(L)}$ são matrizes de pesos sinápticos conectados ao j -ésimo neurônio da camada (L) ao i -ésimo neurônio da camada (L-1).
- $W_{ji}^{(n)}$ peso sináptico conectado ao j -ésimo neurônio da camada de saída ao i -ésimo neurônio da camada ($n - 1$).
- $I_{ji}^{(L)}$ são vetores cujos elementos denotam a entrada ponderada em relação ao j -ésimo neurônio da camada (L).
- $Y_{ji}^{(L)}$ são vetores cujos elementos denotam a saída ponderada em relação ao j -ésimo neurônio da camada (L).

$$I_j^{(z)} = \sum_{i=0}^n W_{ji}^{(z)} \cdot X_i \Leftrightarrow I_j^{(z)} = W_{j,0}^{(z)} \cdot X_0 + W_{j,1}^{(z)} \cdot X_1 + \dots + W_{j,n}^{(z)} \cdot X_n \quad (5)$$

$$Y_j^{(z)} = g(I_j^{(z)}) \quad (6)$$

3.1.5 LÓGICA FUZZY

A lógica fuzzy também é conhecida como lógica nebulosa e possui como base a teoria dos conjuntos através dos conceitos de união, intersecção, inclusão, complemento e etc., também conhecida como lógica nebulosa. A lógica fuzzy diferentemente da lógica clássica que propõe valores verdadeiros ou falsos, ela trata isso como questão de grau, sendo que quando um determinado problema apresenta um grau de incerteza. Faz-se necessário a modelagem matemática de um algoritmo que possa contemplar essa peculiaridade. De acordo com Andrade (2010) grande vantagem na utilização da lógica fuzzy para previsões de demanda de energia elétrica está relacionada a sua capacidade de filtrar uma grande quantidade de dados em conjuntos pequenos de regras.

A teoria dos conjuntos fuzzy possibilita a atribuição de valores contidos que estejam contidos dentro dos limites dos intervalos, possibilitando assim a análise de um conjunto de dados ou amostras com maior grau de sensibilidade em relação a teoria clássica dos conjuntos. Para Sousa (2005) um conjunto fuzzy deve ser descrito como conjunto de pares ordenados, sendo que, o primeiro termo é o próprio elemento do conjunto e o segundo é um numeral contido no intervalo de 0 a 1, representando o grau de pertinência deste elemento cuja função de pertinência descreve uma curva e os pontos representam os valores de pertinência contidos no intervalo em função dos respectivos valores pertencentes a este intervalo.

3.1.6 SISTEMAS HÍBRIDOS

Conforme descrito em Andrade (2010) previsão de demanda de energia elétrica através de sistemas híbridos vem sendo empregada frequentemente. Os sistemas híbridos na maioria dos casos são compostos por redes neurais artificiais e mais alguma outra técnica como algoritmo genético ou máquinas de vetores de suporte (SVM).

Observa-se através da literatura recente que há uma tendência em integrar dois ou mais métodos de análises de sistemas inteligentes para aplicações em algoritmos de previsões, constituindo assim em sistemas híbridos. Conforme descrito por Ul Islam et al. (2014) uma variedade de técnicas de programação evolutiva utiliza algoritmos genéticos para otimizar o desempenho das redes neurais. Para os

autores, após a geração inicial das populações de treinamento, o indivíduo que apresenta o melhor desempenho é selecionado para completar o processo de evolução, os genes deste indivíduo são decodificados para otimizar a topologia da rede em seguida a técnica *backpropagation* é empregada no processo de aprendizagem do algoritmo da rede neural artificial.

3.2 CONTEXTUALIZAÇÃO DO PROJETO

3.2.1 INTRODUÇÃO

O objetivo do projeto é desenvolver uma ferramenta inteligente através de sistemas neurais para realizar previsões de demanda de energia elétrica. A ferramenta em desenvolvimento servirá como instrumento de gerenciamento de carga e do despacho da geração de energia elétrica de uma empresa gaúcha que atua com sistemas de pequenas centrais hidrelétricas (PCHs) e também como agente distribuidor de energia elétrica.

Devido ao fato de sistemas de distribuição de energia elétrica variar instantaneamente em função do tempo, tais sistemas podem ser classificados como variantes no tempo ou sistemas dinâmicos. Dessa forma, segundo Silva et al. (2010) podem ser destacadas duas configurações de rede do tipo Perceptron Multicamadas (PMC) candidatas à utilização perante o problema.

- PMC com entradas atrasadas no tempo (*TDNN – time delay neural network*).
- PMC com saídas recorrentes.

Considerando as características das redes neurais mencionadas acima, este trabalho utiliza uma Rede Perceptron Multicamadas com Entradas Atrasadas no Tempo (PMC-TDNN) e adaptada com uma arquitetura recorrente que realiza a realimentação da rede através das saídas obtidas. A rede (PMC-TDNN) foi escolhida para ser utilizada no desenvolvimento do trabalho pelo fato de sistemas de distribuição de energia elétrica apresentar um comportamento que varia em função do tempo, comportando-se como sistemas dinâmicos, onde a rede (PMC-TDNN) é modelada através de características temporais, cuja alimentação da rede é realizada

através de históricos anteriores de dados e assim apresentam um certo atraso no tempo para as saídas futuras obtidas através do processamento do algoritmo.

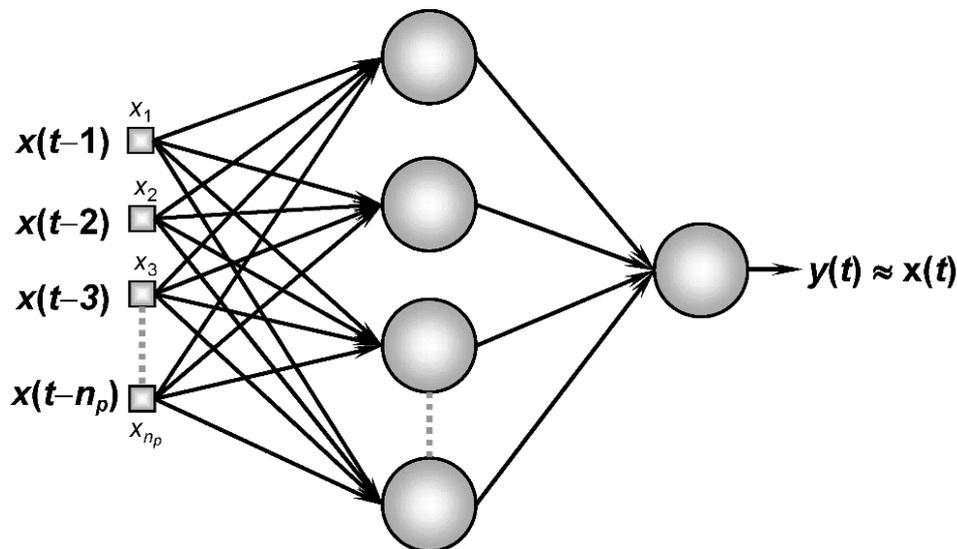
3.2.2 REDE PMC-TDNN

A principal característica nesse tipo de arquitetura está relacionada ao fato da previsão de valores posteriores a um determinado instante de tempo estar relacionado ao conhecimento dos valores anteriores.

$$X(t) = f\{(X(t-1), X(t-2), \dots, X(t-n_p))\} \quad (7)$$

A rede PMC TDNN introduz a linha de atrasos de tempo somente na camada de entrada. Na Figura 10 a seguir pode ser observado como o processo de inserção de amostras anteriores dentro da rede se desenvolve.

Figura 10– Topologia PMC TDNN.

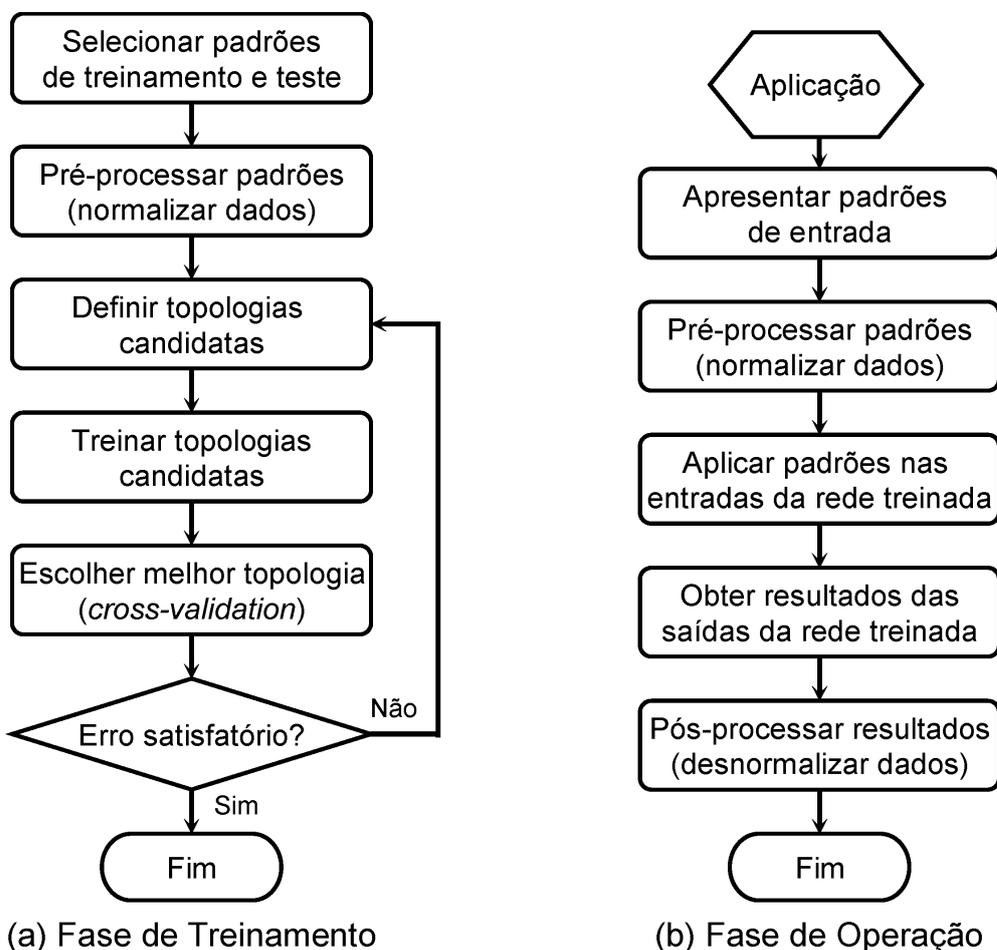


Fonte: Silva et al. (2010, p. 140)

3.2.3 FLUXOGRAMA DAS REDES PMC

A figura 11 representa a ilustração dos fluxogramas do treinamento e da fase de operação do algoritmo implementado através da arquitetura PMC-TDNN, utilizado no projeto em estudo.

Figura 11 – Diagrama de blocos das fases de treinamento e operação das Redes PMC.



Fonte: Silva et al. (2010, p. 159)

3.2.4 EQUAÇÕES CARACTERÍSTICAS DAS REDES PMC

Para o desenvolvimento da rede PMC-TDNN utilizada no trabalho, são necessárias as definições de diversos termos e variáveis fundamentais para o desenvolvimento das análises matemáticas. Através do resultado obtido a partir da equação (7) pode se obter o erro de aproximação como segue representado através da equação (8).

$$E(k) = \frac{1}{2} \sum_{i=1}^n (d_j(k) - Y_j^{(z)}(k))^2 \quad (8)$$

Da equação 8 obtêm-se o erro quadrático, onde:

- $E(k)$ – erro quadrático
- $Y_j^{(z)}(k)$ – valor produzido pelo j -ésimo neurônio de saída da rede, para a k -ésima amostra de treinamento.
- $d_j(k)$ – é o valor que se deseja obter.

Desse modo, assumindo um conjunto de treinamento com p amostras, o desempenho do algoritmo *backpropagation* pode ser avaliado através do erro quadrático médio como observa-se na equação 9.

$$E_M = \frac{1}{p} \sum_{i=1}^p E(k) \quad (9)$$

No processo de treinamento da camada neural de saída, o principal objetivo é realizar o ajuste da matriz de pesos sinápticos de saída, com o objetivo de minimizar o erro entre a saída produzida através do treinamento do algoritmo e a saída que se deseja obter Silva et al. (2010).

O processo de ajuste dos pesos sinápticos pode ser realizado através do treinamento, com a definição de gradiente e fazendo uso da regra da diferenciação em cadeia.

$$\nabla E^{(z)} = \frac{\partial E}{\partial W_{ji}^{(z)}} = \frac{\partial E}{\partial Y_j^{(z)}} \cdot \frac{\partial Y_j^{(z)}}{\partial I_j^{(z)}} \cdot \frac{\partial I_j^{(z)}}{\partial W_{ji}^{(z)}} \quad (10)$$

Através das equações definidas anteriormente, pode se obter as equações (11), (12) e (13) como representadas a seguir:

$$\frac{\partial I_j^{(z)}}{\partial W_{ji}^{(z)}} = Y_i^{(z-1)} \quad (11)$$

$$\frac{\partial Y_j^{(z)}}{\partial I_j^{(z)}} = g'(I_j^{(z)}) \quad (12)$$

$$\frac{\partial E}{\partial Y_j^{(z)}} = -(d_j - Y_j^{(z)}) \quad (13)$$

Da equação (12) $g'(\cdot)$ representa a derivada de primeira ordem da função de ativação. Substituindo as equações (11), (12) e (13) descritas acima, na equação (10) e realizando o ajuste da matriz de pesos de forma oposta ao gradiente para que se minimize o erro, obtêm-se a seguinte equação:

$$\nabla W_{ji}^{(z)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(z)}} \Leftrightarrow \nabla W_{ji}^{(z)} = \eta \cdot \delta_j^{(z)} \cdot Y_i^{(z-1)} \quad (14)$$

A partir da equação (14) onde η é a taxa de aprendizado do algoritmo *backpropagation* e $\delta_j^{(z)}$ é definido como gradiente local em relação ao j -ésimo neurônio da cama de saída. Como forma de processo iterativo, a equação (14) pode ser convertida para a seguinte equação iterativa:

$$W_{ji}^{(z)}(t+1) = W_{ji}^{(z)}(t) + \eta \cdot \delta_j^{(z)} \cdot Y_i^{(z-1)} \quad (15)$$

No processo de ajuste dos pesos sinápticos das camadas intermediárias não se tem acesso aos valores desejados para suas saídas e com isso os ajustes são efetuados por intermédio de estimativas de erros produzidos pelos neurônios da camada imediatamente posterior que conectam-se diretamente aos neurônios ajustados previamente no passo anterior Silva et al. (2010).

$$\nabla E^{(z-1)} = \frac{\partial E}{\partial W_{ji}^{(z-1)}} = \frac{\partial E}{\partial Y_j^{(z-1)}} \cdot \frac{\partial Y_j^{(z-1)}}{\partial I_j^{(z-1)}} \cdot \frac{\partial I_j^{(z-1)}}{\partial W_{ji}^{(z-1)}} \quad (16)$$

Deste modo, analogamente ao processo anterior os termos da equação (16) podem ser obtidos de forma individualizada e o processo de ajuste pode ser estendido desde a última camada escondida até a primeira camada escondida.

O processo iterativo se repete até que a precisão mínima estipulada seja alcançada. O critério que define o processo iterativo é estipulado através do erro quadrático médio, nesse caso, para que o algoritmo convirja o erro quadrático médio entre duas épocas sucessivas deve ser menor ou igual a precisão estipulada inicialmente Silva et al. (2010).

$$\left| E_M^{(atual)} - E_M^{(anterior)} \right| \leq \varepsilon \quad (17)$$

A equação (17) representa o processo de verificação de convergência do algoritmo, enquanto a precisão (ε) mínima não for satisfeita o processo de iteração se repete.

3.2.5 CONCLUSÃO

Neste capítulo foi apresentado os principais sistemas de previsão de demanda utilizados. Metodologias de GA, regressão linear, sistemas neurais, sistemas fuzzy e sistemas híbridos foram abordados através da literatura referenciada. A rede PMC, que foi a utilizada neste trabalho, pode ser melhor estudada e descrita através do presente capítulo.

4. DESENVOLVIMENTO DO PROJETO E ANÁLISES DOS RESULTADOS

4.1 DESENVOLVIMENTO DO PROJETO

4.1.1 INTRODUÇÃO

O modelo desenvolvido para o projeto foi composto pela rede neural (PMC-TDNN) com realimentação, como descrito nos capítulos anteriores. Este capítulo tem como finalidade descrever os procedimentos adotados, assim como os valores das variáveis que foram ajustados durante os processos de treinamento e operação do algoritmo.

4.1.2 TRATAMENTO DOS DADOS

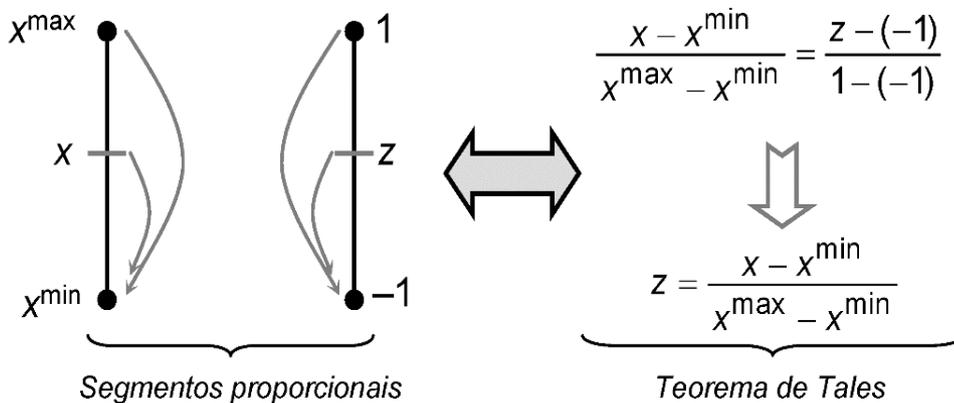
Nessa etapa os dados foram coletados junto a uma empresa gaúcha distribuidora de energia elétrica, dados esses referentes à potência ativa [kWh], obtidos na saída dos alimentadores localizados em suas subestações. Os dados foram organizados e exportados para o ambiente Matlab®.

Em primeira instância optou-se pela classificação dos dados em amostras diárias, onde todo histórico foi dividido por alimentador e cada alimentador foi dividido em sete conjuntos de dados, cada um representando um dia específico da semana. Essa organização de dados teve como objetivo possibilitar um melhor treinamento da rede, de maneira que se pudesse realizar o processo de treinamento para perfis de carga com características similares.

Com os dados organizados por alimentador e dia da semana especificado, a próxima etapa realizada é o processo de normalização de dados. O processo de normalização é realizado mediante a escolha da função de ativação a ser utilizada, no caso deste trabalho foi utilizada a função logística como função de ativação e com isso o conjunto de dados normalizados ficou contido no intervalo de [0 1]. A

figura 12 ilustra o processo de normalização dos dados que pode ser obtido através do Teorema de Tales.

Figura 12 – Princípio de normalização das amostras.



Fonte: Silva et al. (2010, p. 161)

4.1.3 IMPLEMENTAÇÃO DO ALGORITMO DE TREINAMENTO

Nessa etapa, o algoritmo foi implementado através do ambiente Matlab®. Os valores das amostras já se encontram normalizados e são automaticamente carregados para dentro do algoritmo.

Antes da execução do programa pelo usuário, algumas constantes necessitam de ajustes para o processo de treinamento, como a literatura indica alguns valores típicos para essas constantes, adotaram-se os seguintes valores de constantes para o processamento do algoritmo:

- Matrizes de pesos sinápticos são inicializadas de forma randômica em cada processo de treinamento: $w = \text{randômico}$.
- Taxa de aprendizado: $\eta = 0.1$.
- Termo de *momentum*: $\alpha = 0.8$.
- Precisão: $\varepsilon = 1 \times 10^{-6}$

No momento de execução do processo de treinamento o usuário é quem define os parâmetros que serão utilizados pela rede durante o processo de treinamento, como descrito a seguir:

- Número de entradas da rede “X”.
- Número de neurônios na camada intermediária.
- Número de neurônios na camada de saída.
- Número de saídas “futuras” desejadas.

Após definidos os números de entradas, neurônios e saídas da rede o algoritmo inicia o processo de treinamento, para cada iteração realizada é calculado o erro quadrático médio que leva em conta o valor anterior e o atual, enquanto o erro quadrático médio for maior que a precisão especificada o processo de iteração irá se repetir até alcançar a precisão desejada.

4.1.4 IMPLEMENTAÇÃO DO ALGORITMO DE FASE DE OPERAÇÃO

O algoritmo da fase de operação da rede inicia-se automaticamente após a precisão mínima de erro ser alcançada através do processo de treinamento. Após a precisão especificada ser obtida, a matriz de pesos sinápticos é classificada e utilizada para o processo de operação. A partir dessa etapa a matriz de pesos não será mais ajustada.

O algoritmo realiza a primeira iteração e obtém a primeira saída futura desejada, a saída pode ser alocada na posição (1,1). Essa saída passa a realizar o processo de realimentação da rede, nesse momento a saída (1,1) realimenta o algoritmo e a primeira saída da entrada de treinamento é descartada. A Tabela 1 ilustra esse processo de realimentação.

Tabela 1 – Relação de entradas e saídas da rede.

	X1	X2	X3	X4	X5	Saída desejada	Saída da rede
t = 4	X(3)	X(2)	X(1)	0	0	X(4)	Y(4)
t = 5	X(4)	X(3)	X(2)	Y(4)	0	X(5)	Y(5)
t = 6	X(5)	X(4)	X(3)	Y(5)	Y(4)	X(6)	Y(6)
t = 7	X(6)	X(5)	X(4)	Y(6)	Y(5)	X(7)	Y(7)
t = 8	X(7)	X(6)	X(5)	Y(7)	Y(6)	X(8)	Y(8)
t = n	X(n-1)	X(n-2)	X(n-3)	Y(n-1)	Y(n-2)	X(n)	Y(n)

O processo de iteração se repete até que o número de saídas “futuras” desejadas seja alcançado. Calcula-se o erro relativo médio do processo e a variância dos dados.

4.2 ANÁLISE DOS RESULTADOS

4.2.1 CONVERGÊNCIA DO TERMO MOMENTUM

O primeiro treinamento foi realizado com o objetivo de verificar a convergência do algoritmo mediante a presença do termo *momentum* durante o processo de treinamento e ajuste dos pesos sinápticos da rede (PMC-TDNN).

Na Tabela 2 encontram-se os valores das variáveis que foram utilizadas para análise e convergência do algoritmo com e sem a presença do termo *momentum* inserido na rede para uma precisão de $\varepsilon = 1E - 6$ para melhor verificar o desempenho da convergência.

Tabela 2 – Variáveis ajustadas, número de épocas e tempo de simulação obtidos através do teste de convergência da rede com e sem a presença do termo *momentum*.

	Núm. de Entradas da Rede	Núm. de Neurônios Camada Escondida	Núm. de Neurônios Camada Saída	Núm. de Saídas Desejadas	Núm. de Épocas Obtido	Tempo de Simulação Obtido (s)
Sem Momentum	5	15	1	120	424	75.05
Com Momentum $\alpha = 0.8$	5	15	1	120	361	64.8

As figuras 13 e 14 ilustram o comportamento do erro quadrático médio para as análises da rede sem e com o termo *momentum* respectivamente.

Figura 13 – Processo de treinamento sem a inserção do termo momentum.

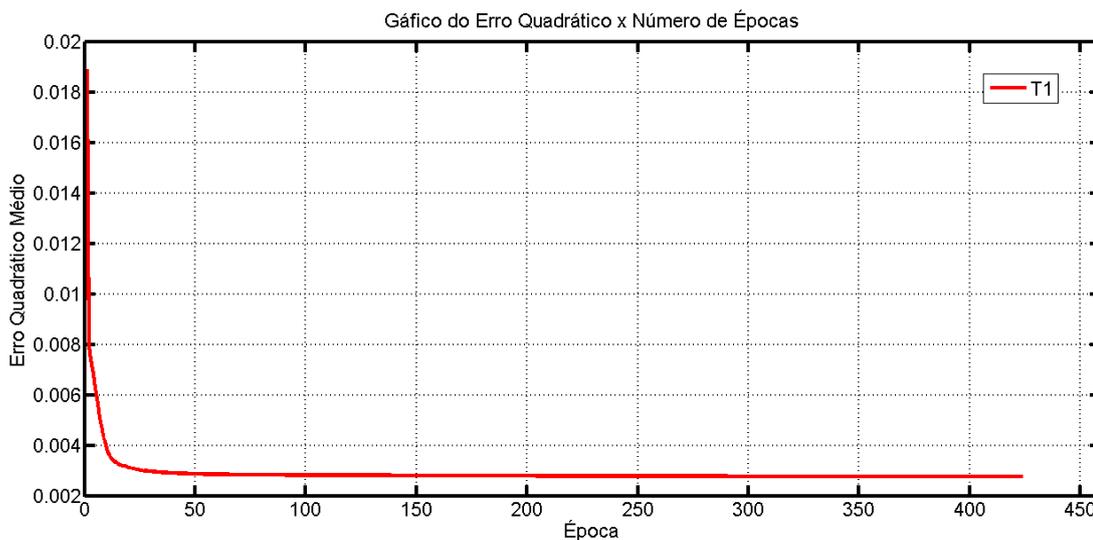
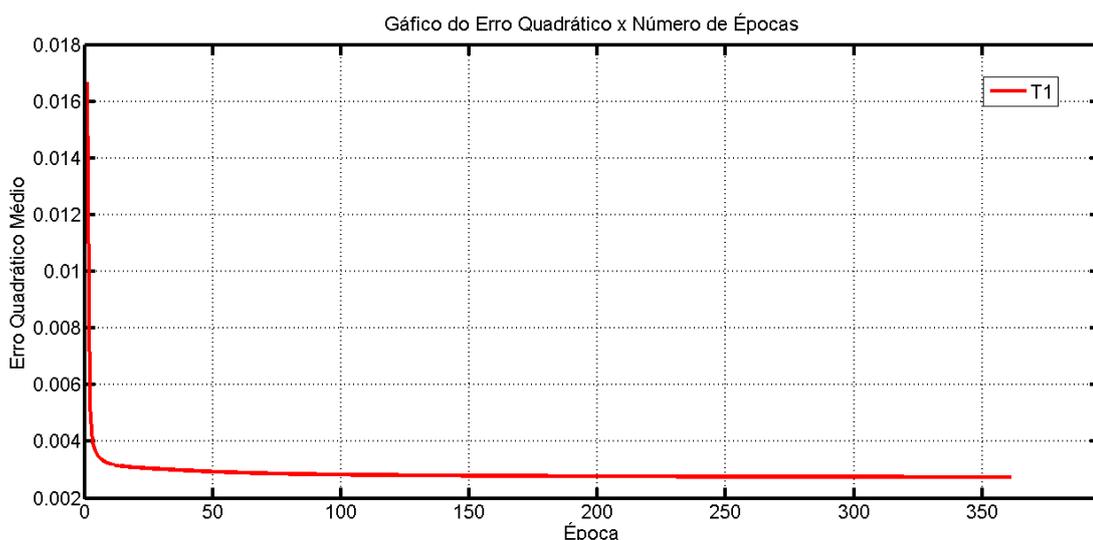


Figura 14 – Processo de treinamento com a inserção do termo momentum.



Pode se observar através da Tabela 2 onde as simulações realizadas com a presença do termo *momentum*, tanto o tempo de simulação quanto o número de épocas apresentaram um melhor desempenho em comparação a simulação da rede sem a presença do termo *momentum*.

Para realizar os testes das topologias candidatas a melhor desempenho da rede, são necessários arbitrar alguns valores iniciais referentes ao número de entradas da rede e ao número de neurônios das camadas escondidas para que se obtenha as melhores combinações em relação as camadas de entrada e camadas intermediárias da rede desenvolvida, com o objetivo de se obter os melhores

desempenhos referente ao tempo de processamento e ao menor erro quadrático médio entre iterações sucessivas.

4.2.2 ANÁLISES DAS TOPOLOGIAS CANDIDATAS 1.

Para realizar as análises com as topologias candidatas 1 diversos parâmetros iniciais como precisão, termo momentum, número de amostras da rede foram mantidos fixos e outros parâmetros como número de entradas, número de neurônios das camadas intermediárias foram ajustados afim de verificar a topologia que apresenta o melhor desempenho.

A Tabela 3 representa os parâmetros fixos, definidos inicialmente para os testes realizados com as diferentes topologias como descritos a seguir:

Tabela 3 – Parâmetros iniciais para análises das topologias candidatas para o dia de Quinta-Feira.

Alimentador A	
Quinta Feira	
Matriz de Pesos sinápticos	w = randômico
Número total de entradas	np = 3600
Número de padrões de treinamento	nt = 3000
Taxa de aprendizagem	n = 0.1
Termo <i>momentum</i>	$\alpha = 0.8$
Precisão	$\epsilon = 1E-6$

ANÁLISE DO ALIMENTADOR A QUINTA-FEIRA TESTE 1.

A Tabela 4 contém as especificações dos parâmetros definidos pelo usuário para o primeiro teste referente ao Alimentador A para o dia de quinta-feira.

Tabela 4 – Parâmetros definidos para o teste 1 Quinta-Feira.

Núm. de Entradas da Rede	3
Núm. de Neurônios Camada Escondida	5
Núm. de Neurônios Camada Saída	1
Núm. de Saídas Desejadas	120

As figuras 15 e 16 representam respectivamente o erro quadrático médio e o processo de validação do teste 1, respectivamente.

Figura 15 – Erro quadrático médio teste 1 Quinta-Feira.

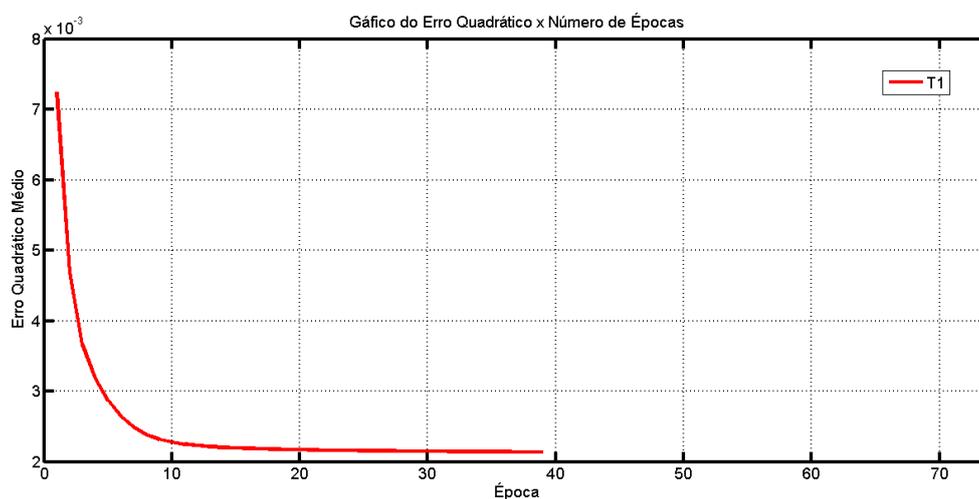
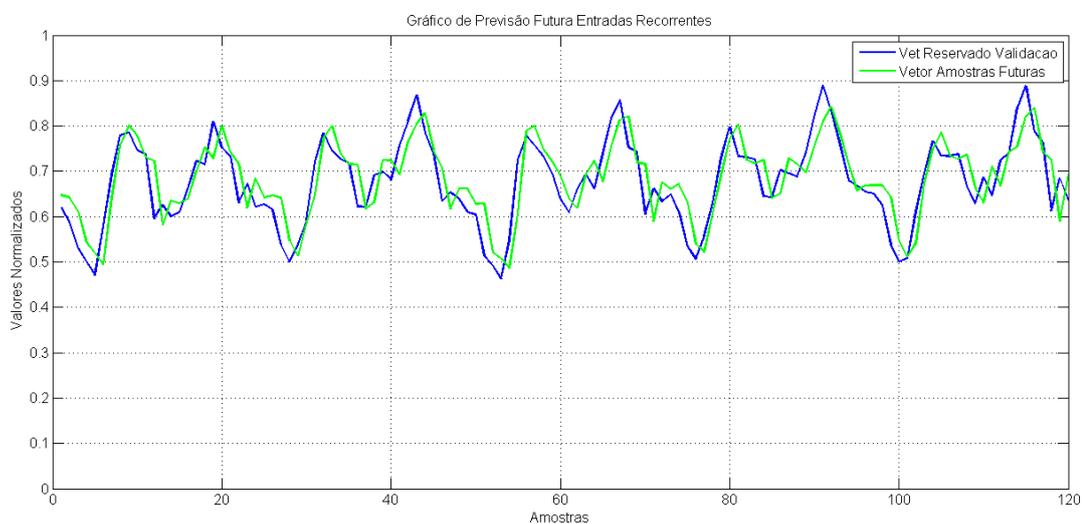


Figura 16 – Processo de validação teste 1 Quinta-Feira.



A Tabela 5 contém os principais resultados obtidos através do teste 1.

Tabela 5 – Resultados do teste 1 Quinta-Feira.

Tempo (s)	7.213
Erro quadrático médio (%)	0.214
Número de épocas	39.000
Erro relativo médio (%)	0.829
Variância	0.701

Os principais parâmetros analisados são o tempo de simulação, erro quadrático médio, número de épocas, erro relativo médio e variância. Os resultados obtidos no teste 1 para as quintas-feiras, a partir dos parâmetros ajustados foram considerados satisfatórios, apresentando um baixo tempo de simulação, erros baixos e poucos números de épocas.

ANÁLISE DO ALIMENTADOR A QUINTA-FEIRA TESTE 2.

A Tabela 6 contém as especificações dos parâmetros definidos pelo usuário para o segundo teste referente ao Alimentador A para o dia de quinta-feira.

Tabela 6 – Parâmetros definidos para o teste 2 Quinta-Feira.

Núm. de Entradas da Rede	5
Núm. de Neurônios Camada Escondida	10
Núm. de Neurônios Camada Saída	1
Núm. de Saídas Desejadas	120

As figuras 17 e 18 representam respectivamente o erro quadrático médio e o processo de validação do teste 2, respectivamente.

Figura 17 – Erro quadrático médio teste 2 Quinta-Feira.

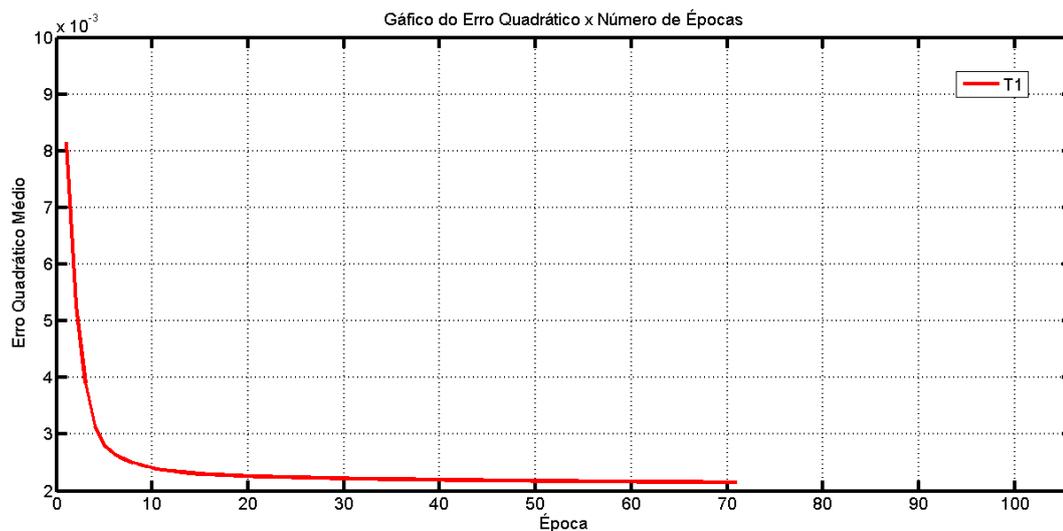
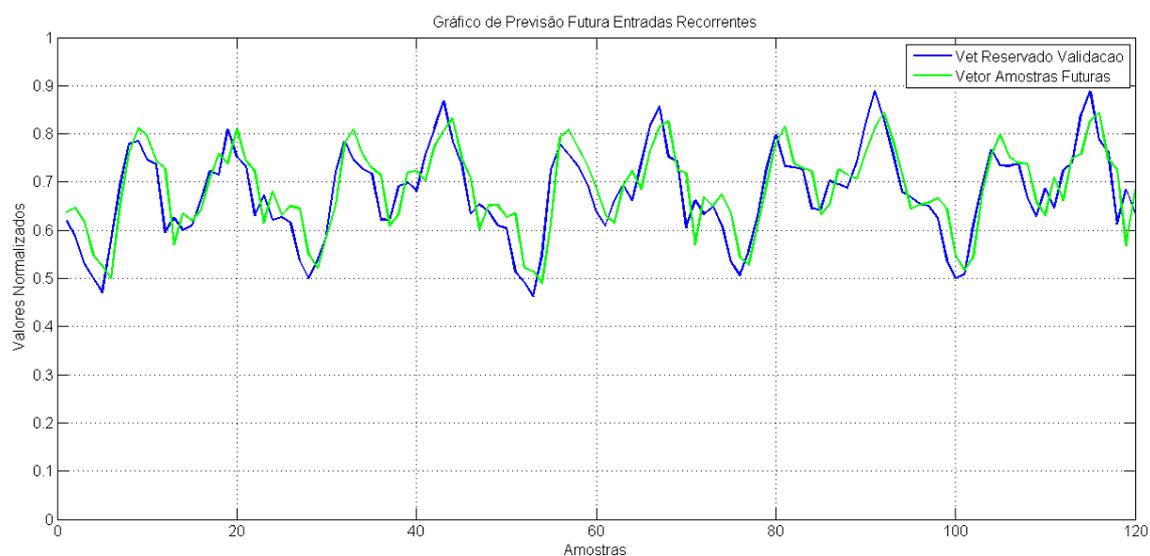


Figura 18 – Processo de validação teste 2 Quinta-Feira.



A Tabela 7 contém os principais resultados obtidos através do teste 2.

Tabela 7 – Resultados do teste 2 Quinta-Feira.

Tempo (s)	14.147
Erro quadrático médio (%)	0.215
Número de épocas	71.000
Erro relativo médio (%)	1.077
Variância	0.747

De acordo com resultados obtidos no teste 2 para as quintas-feiras, para ajustes de parâmetros diferentes aos do teste 1, os resultados também foram considerados satisfatórios com um baixo tempo de simulação e erros baixos.

ANÁLISE DO ALIMENTADOR A QUINTA-FEIRA TESTE 3.

A Tabela 8 contém as especificações dos parâmetros definidos pelo usuário para o terceiro teste referente ao Alimentador A para o dia de quinta-feira.

Tabela 8 – Parâmetros definidos para o teste 3 Quinta-Feira.

Núm. de Entradas da Rede	10
Núm. de Neurônios Camada Escondida	15
Núm. de Neurônios Camada Saída	1
Núm. de Saídas Desejadas	120

As figuras 19 e 20 representam respectivamente o erro quadrático médio e o processo de validação do teste 3.

Figura 19 – Erro quadrático médio teste 3 Quinta-Feira.

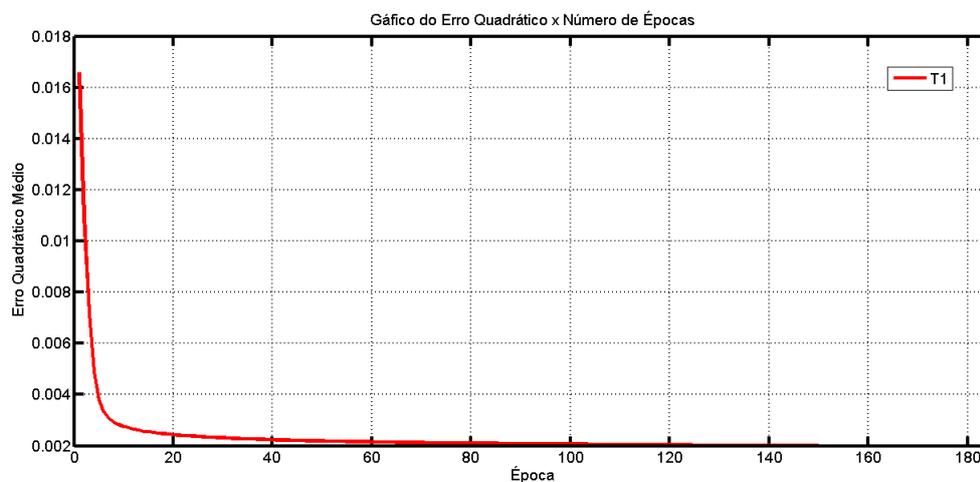
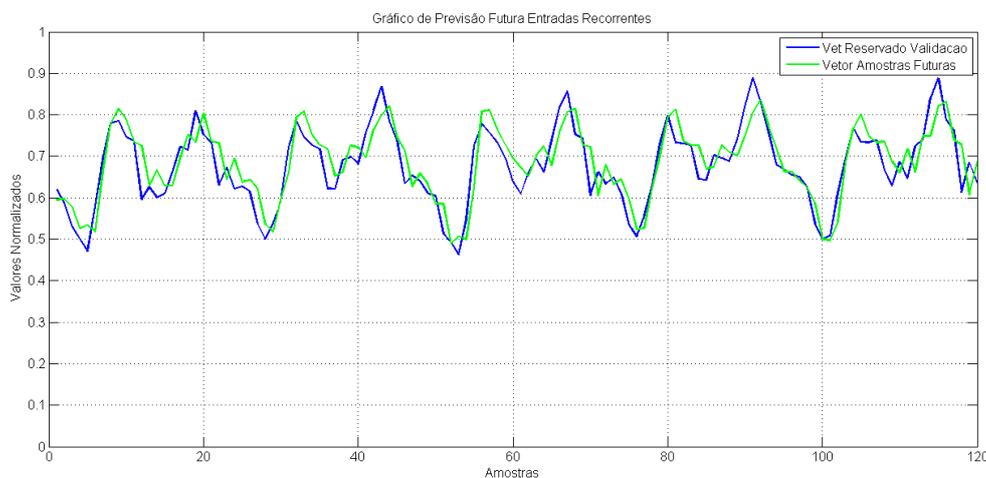


Figura 20 – Processo de validação teste 3 Quinta-Feira.



A Tabela 9 contém os principais resultados obtidos através do teste 3.

Tabela 9 – Resultados do teste 3 Quinta-Feira.

Tempo (s)	28.952
Erro quadrático médio (%)	0.200
Número de épocas	150.000
Erro relativo médio (%)	0.988
Variância	0.762

Os resultados obtidos no teste 3 para as quintas-feiras, para ajustes de parâmetros diferentes aos dos testes 1 e 2, os resultados também foram considerados satisfatórios pois os erros também foram baixos, embora, o tempo de simulação e o número de épocas tenham sido maiores que o apresentado nos testes 1 e 2.

Em relação as análises realizadas para nos testes 1, 2 e 3 referentes à quinta-feira, todos os resultados obtidos apresentaram uma boa estimativa de previsão futura com relação aos valores desejados. Pode ser visto que os resultados obtidos a partir do teste 1 apresentaram melhores desempenhos com relação aos testes 2 e 3, o tempo de simulação, número de épocas, erro relativo médio e a variância foram menores que as dos testes 2 e 3.

4.2.3 ANÁLISES DAS TOPOLOGIAS CANDIDATAS 2.

Para realizar as análises com as topologias candidatas 2 diversos parâmetros iniciais como precisão, termo momentum, número de amostras da rede foram mantidos fixos e outros parâmetros como número de entradas, número de neurônios das camadas intermediárias foram ajustados afim de verificar a topologia que apresenta o melhor desempenho.

A tabela 10 representa os parâmetros fixos, definidos inicialmente para os testes realizados com as diferentes topologias como descritos a seguir:

Tabela 10 – Parâmetros iniciais para análises das topologias candidatas para o dia de Domingo.

Alimentador B	
Domingo	
Matriz de Pesos sinápticos	w = randômico
Número total de entradas	np = 3600
Número de padrões de treinamento	nt = 3240
Taxa de aprendizagem	n = 0.1
Termo <i>momentum</i>	$\alpha = 0.8$
Precisão	$\epsilon = 1E-6$

ANÁLISE DO ALIMENTADOR B DOMINGO TESTE 1.

A Tabela 11 contém as especificações dos parâmetros definidos pelo usuário para o primeiro teste referente ao Alimentador B para o dia de domingo.

Tabela 11 – Parâmetros definidos para o teste 1 Domingo.

Núm. de Entradas da Rede	3
Núm. de Neurônios Camada Escondida	5
Núm. de Neurônios Camada Saída	1
Núm. de Saídas Desejadas	120

As figuras 21 e 22 representam respectivamente o erro quadrático médio e o processo de validação do teste 1.

Figura 21 – Erro quadrático médio teste 1 Domingo.

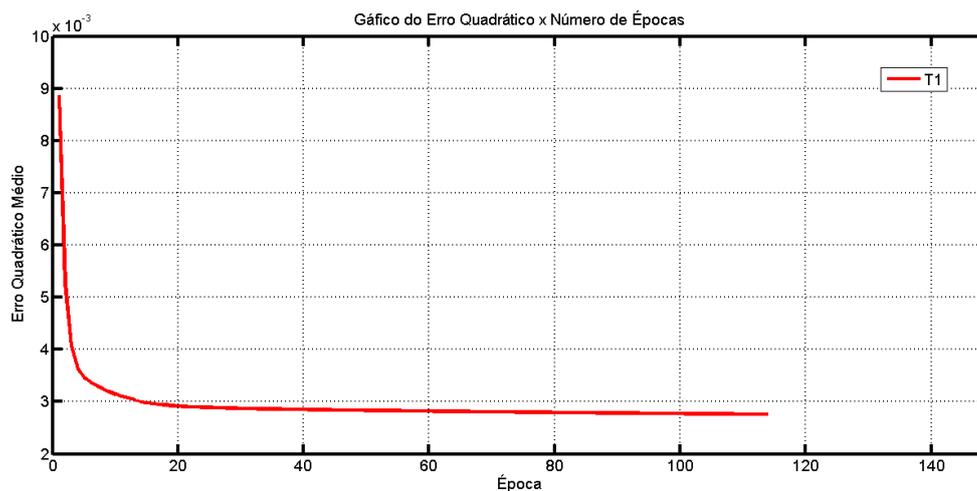
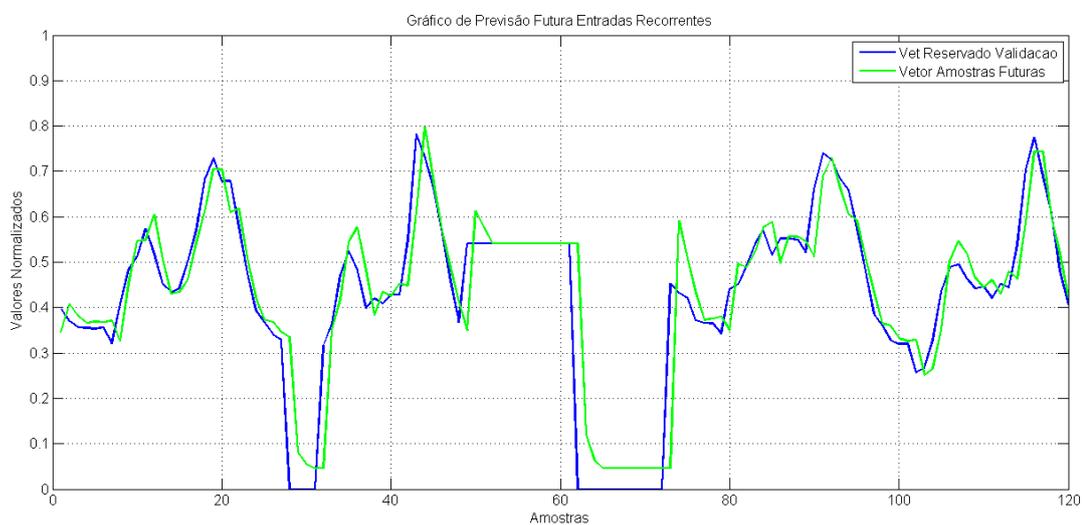


Figura 22 – Processo de validação teste 1 Domingo.



A Tabela 12 contém os principais resultados obtidos através do teste 1.

Tabela 12 – Resultados do teste 1 Domingo.

Tempo (s)	22.035
Erro quadrático médio (%)	0.276
Número de épocas	114.000
Erro relativo médio (%)	0.964
Variância	3.233

Os resultados obtidos no teste 1 para os domingos, a partir dos parâmetros ajustados foram considerados satisfatórios, apresentando um baixo tempo de simulação e erros baixos, embora a variância tenha sido maior do que os valores apresentados nos testes para as quintas-feiras.

ANÁLISE DO ALIMENTADOR B DOMINGO TESTE 2.

A tabela 13 contém as especificações dos parâmetros definidos pelo usuário para o segundo teste referente ao Alimentador B para o dia de domingo.

Tabela 13 – Parâmetros definidos para o teste 2 Domingo.

Núm. de Entradas da Rede	5
Núm. de Neurônios Camada Escondida	10
Núm. de Neurônios Camada Saída	1
Núm. de Saídas Desejadas	120

As figuras 23 e 24 representam respectivamente o erro quadrático médio e o processo de validação do teste 2.

Figura 23 – Erro quadrático médio teste 2 Domingo.

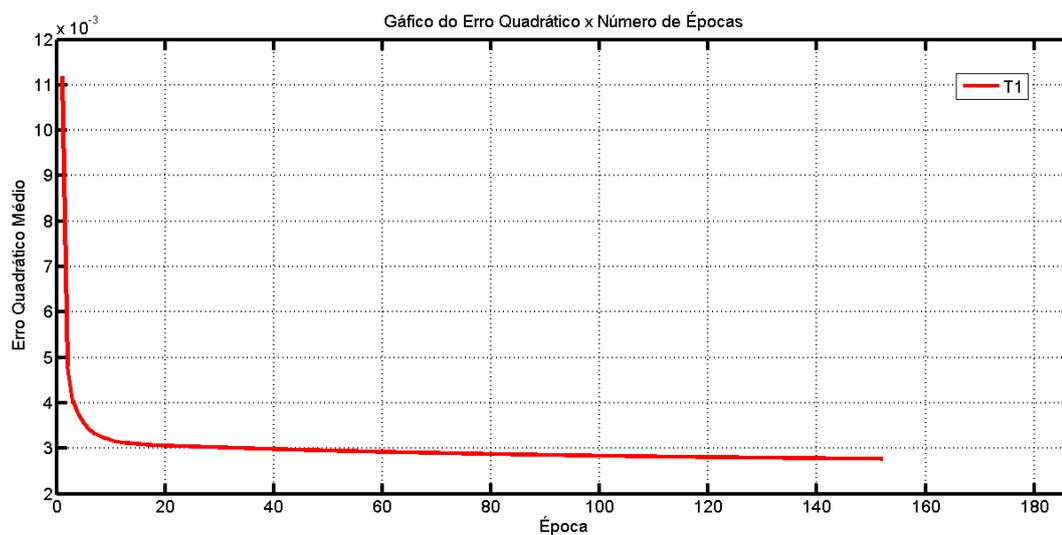
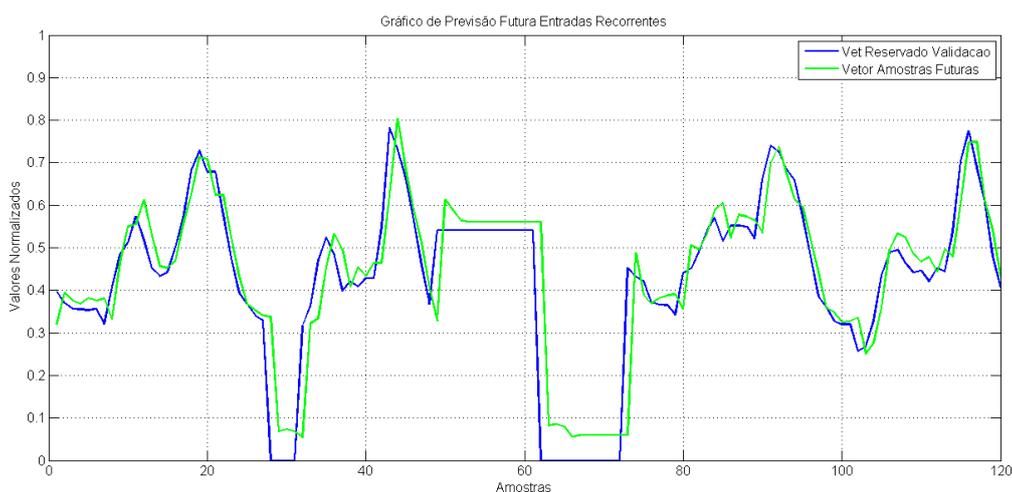


Figura 24 – Processo de validação teste 2 Domingo.



A Tabela 14 contém os principais resultados obtidos através do teste 2.

Tabela 14 – Resultados do teste 2 Domingo.

Tempo (s)	31.419
Erro quadrático médio (%)	0.276
Número de épocas	152.000
Erro relativo médio (%)	1.464
Variância	3.258

De acordo com resultados obtidos no teste 2 para os domingos, para ajustes de parâmetros diferentes aos do teste 1, os resultados também foram considerados satisfatórios com erros baixos.

ANÁLISE DO ALIMENTADOR B DOMINGO TESTE 3.

A tabela 15 contém as especificações dos parâmetros definidos pelo usuário para o terceiro teste referente ao Alimentador B para o dia de domingo.

Tabela 15 – Parâmetros definidos para o teste 3 Domingo.

Núm. de Entradas da Rede	10
Núm. de Neurônios Camada Escondida	15
Núm. de Neurônios Camada Saída	1
Núm. de Saídas Desejadas	120

As figuras 25 e 26 representam respectivamente o erro quadrático médio e o processo de validação do teste 3.

Figura 25 – Erro quadrático médio teste 3 Domingo.

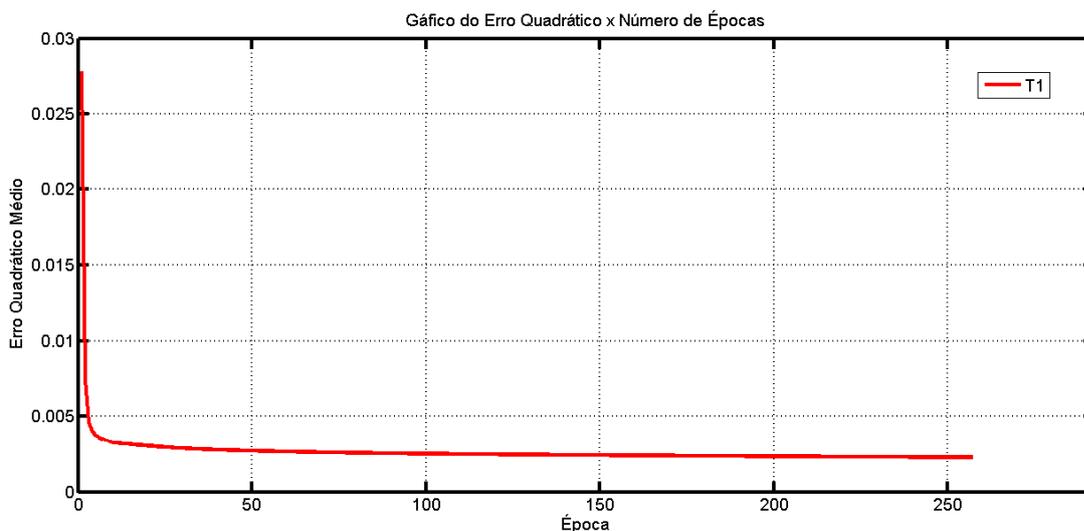
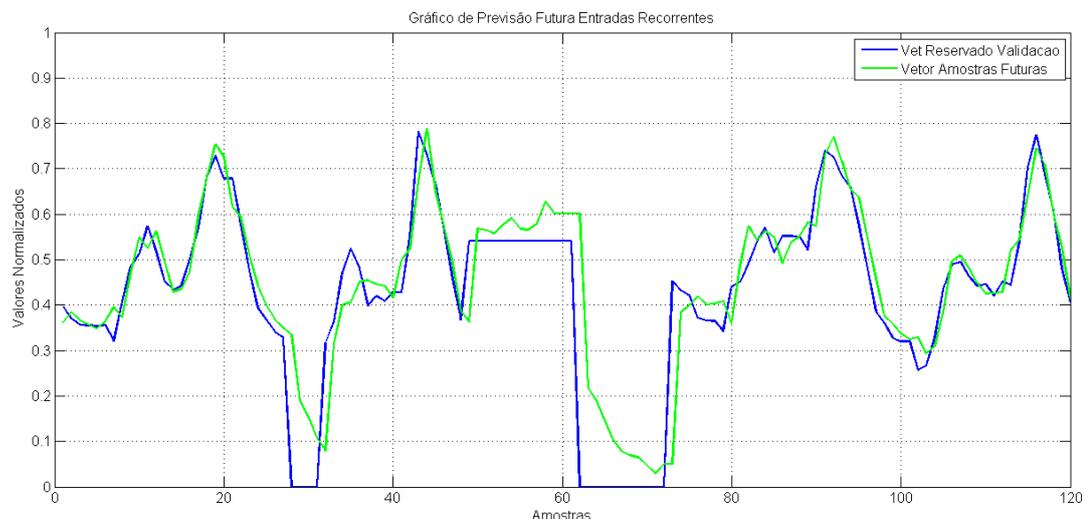


Figura 26 - Processo de validação teste 3 Domingo.



A Tabela 16 contém os principais resultados obtidos através do teste 3.

Tabela 16 – Resultados do teste 3 Domingo.

Tempo (s)	54.255
Erro quadrático médio (%)	0.229
Número de épocas	257.000
Erro relativo médio (%)	2.274
Variância	3.000

Os resultados obtidos no teste 3 para os domingos, para ajustes de parâmetros diferentes aos dos testes 1 e 2, os resultados também foram considerados satisfatórios pois o erro quadrático médio foi baixo, embora, o tempo de simulação, erro relativo médio, a variância e o número de épocas tenham sido maiores que o apresentado nos testes 1 e 2.

As análises realizadas para os testes 1, 2 e 3 referente aos domingos, demonstram que todos os resultados obtidos também apresentaram uma boa estimativa de previsão futura com relação aos valores desejados. Pode ser visto que os resultados obtidos a partir do teste 1 apresentam desempenhos um pouco melhor

em relação aos testes 2 e 3, o tempo de simulação, número de épocas e o erro relativo médio foram menores que os obtidos através dos testes 2 e 3.

Ainda com relação aos testes referentes aos domingos, pode-se observar em alguns pontos a ocorrência da falta de energia, acontecimento que não se constitui num fator de previsibilidade. Para tanto a amostra tratada tanto no aprendizado como na projeção necessita ser ajustada para que não ocorra tal interrupção. O ideal é substituir o período sem energia da sequência por uma série de dados fundamentados no histórico da medição

Para ambos os testes realizados para os Alimentadores A e B, referentes à quinta-feira e ao domingo respectivamente, os resultados que foram obtidos através da rede PMC-TDNN com a saída realimentada apresentaram uma boa previsão futura de demanda para os Alimentadores analisados. As análises podem ser estendidas para os demais Alimentadores e para todos os dias da semana, permitindo assim a previsão de demanda para cada alimentador referente a cada dia da semana com flexibilidade de análise individualizada para cada Alimentador específico.

Vale a pena ressaltar que outro fator que influencia diretamente nos resultados das previsões está relacionado ao número de amostras ou histórico de dados anteriores disponíveis para utilização. Neste caso, quanto maior for esse histórico de dados melhor treinada será a rede, pois, a mesma possui a capacidade de identificar padrões de comportamento e conseqüentemente realiza ajustes mais precisos às matrizes de pesos sinápticos que serão utilizadas nos processos de validação dos resultados.

4.3 CONCLUSÃO

Neste capítulo foi descrito o modelo desenvolvido para o estudo de caso. Puderam ser abordados os algoritmos de fase de treinamento e operação implementados no projeto. Também foi apresentado as análises e simulações realizadas, os gráficos das simulações e tabelas com os principais resultados obtidos puderam ser observados através deste capítulo.

5. CONCLUSÃO

5.1 CONCLUSÕES GERAIS

O estudo realizado através deste trabalho teve como finalidade principal o desenvolvimento e a implementação de um modelo inteligente de previsão de demanda de energia elétrica. A partir das análises bibliográficas realizadas pode-se verificar as principais técnicas de previsões de demanda que eram utilizadas e as técnicas que atualmente estão sendo empregadas para realizar essas análises. Assim como as ferramentas de previsão, pode se observar que os horizontes para os quais se deseja realizar as previsões são de grande importância para elaboração de sistemas inteligentes com um grau maior de precisão.

De acordo com informações descritas na bibliografia consultada, os fatores climatológicos constituem num dos elementos que influenciam diretamente no consumo de energia elétrica. Tal constatação também foi observada pelo agente distribuidor de energia elétrica parceiro deste projeto. Em virtude dessa influência climatológica, deve-se considerar para o desenvolvimento dos sistemas de previsão uma arquitetura de rede que permita correlacionar os históricos anteriores dos dados e as variáveis climáticas.

Outra observação importante que deve ser analisada é com relação ao tratamento dos dados. Neste trabalho a classificação dos dados históricos da distribuidora é realizada de maneira individualizada por alimentador. Para análises futuras os dados podem ser classificados por períodos maiores, ou seja, antes foram classificados semanalmente. Para outras análises podem ser classificados em todo o horizonte de amostras, sendo dividido apenas por alimentador. Neste caso o histórico do alimentador passaria a possuir pouco mais de 26000 amostras frente as 3600 amostras anteriores que estavam subdivididas para cada dia da semana.

Para uma análise mais precisa e específica seria interessante individualizar as análises para classes diferentes de consumo, clientes residenciais, comerciais, rurais e industriais possuem curvas típicas de carga bem diferentes e o comportamento de cada segmento de cliente pode variar muito durante o ano. Com todas essas possibilidades de tratamento de dados e configurações de redes e arquiteturas, os sistemas híbridos são os que mais se adaptam aos tipos de análises sugeridas. Um modelo que possa contemplar um sistema neural com mais alguma outra técnica de redução de variáveis ou mesmo lógica *fuzzy* pode ser implementado para melhorar ainda mais a precisão dos resultados das previsões de demanda de energia elétrica.

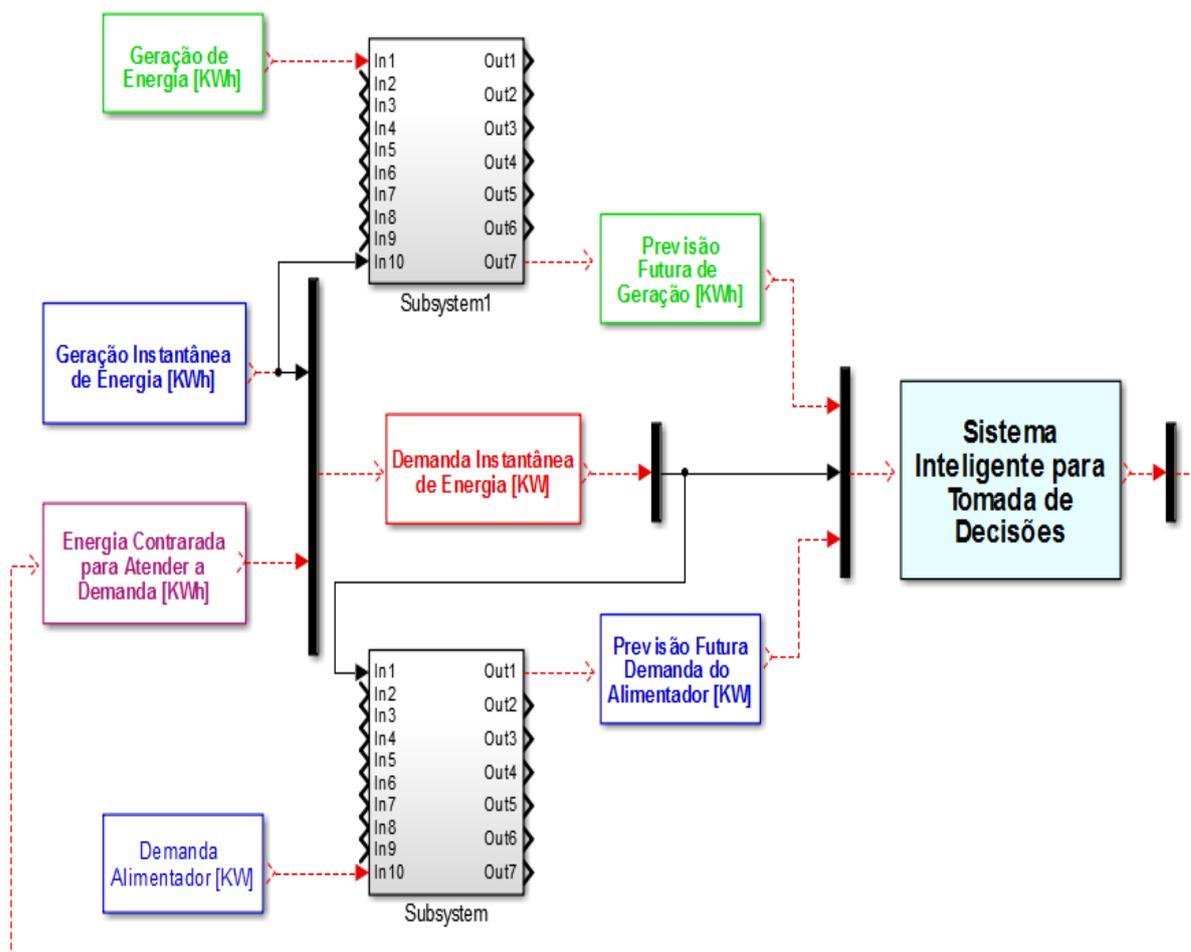
Neste trabalho optou-se por realizar um estudo para se obter somente previsões relacionadas a demanda de carga, e não abranger a previsão de geração de energia elétrica, a continuidade deste trabalho irá dar maiores abrangências a parte de geração de energia e ao gerenciamento do sistema de otimização da relação geração e demanda.

5.2 SUGESTÃO PARA TRABALHOS FUTUROS

Como sugestão para trabalhos futuros, pode ser implementado um sistema inteligente de tomada de decisão, visando o planejamento otimizado entre demanda, geração e contratação de energia, para atender às necessidades de carga dos clientes consumidores.

A ideia é que se possa realizar o controle interligado de todo o sistema, uma vez que conhecendo as necessidades futuras de demandas de energia e também tendo o conhecimento do potencial de geração futura, se possa aperfeiçoar o despacho de energia, evitando a compra emergencial de energia a preços elevados para atender as necessidades de demanda e, com isso, aperfeiçoar o gerenciamento dos fluxos de carga e geração. A figura 27 ilustra através de diagrama de blocos, um modelo inteligente de auxílio à tomada de decisão.

Figura 27 – Sistema inteligente de tomada de decisões



REFERÊNCIAS

ALTRAN, A. B. **Sistema Inteligente para Previsão de Carga Multinodal em Sistemas Elétricos de Potência**. Tese (Doutorado em Engenharia) – Universidade Estadual Paulista – Faculdade de Engenharia, Ilha Solteira, 2010.

ANDRADE, Luciano Carli Moreira. **Abordagem Neurofuzzy Para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo**. Dissertação de Mestrado, Escola de Engenharia de São Carlos. Universidade de São Paulo. São Carlos, 2010, 91p.

ANEEL, Agência Nacional de Energia Elétrica. **Informações Técnicas**. Legislação Básica.

BORDIGNON, Sérgio. **Metodologia para Previsão de Carga de Curtíssimo Prazo Considerando Variáveis Climáticas e Auxiliando na Programação de Despacho de Pequenas Centrais Hidrelétricas**. Dissertação de Mestrado, Universidade Federal do Pampa. Programa de Pós Graduação em Engenharia Elétrica. Alegrete, 2012, 115p.

BUNNOON, P.; CHALERMYANONT, K.; LIMSAKUL, C.. **Mid Term Load Forecasting of the Country Using Statistical Methodology: Case Study in Thailand**. 2009 International Conference on Signal Processing Systems , vol., no., pp.924,928, 15-17 May 2009.

CARMONA, D., JARAMILO, M. A., GONZÁLEZ, E., ALVAREZ, J. D.. **Electric Energy Demand Forecasting with Neural Networks**, Proceedings of IEE IECOM, pp. 1860-1865. 2002.

CICCONET, Franciele. **Estudo Sobre a Operação Descentralizada de Sistemas com Predomínio de Geração Hidrelétrica**. Dissertação de Mestrado, Universidade federal de Santa Catarina. Programa de Pós Graduação em Engenharia Elétrica. Florianópolis, 2013, 157p.

EPE, Empresa de pesquisa Energética. **Projeção de Demanda de Energia Elétrica**. PDE(2014-2023). Rio de Janeiro, 2013, 79p.

FALVO, M.C.; LAMEDICA, R.; PIERAZZO, S.; PRUDENZI, A.. **A Knowledge Based System for Medium Term Load Forecasting**. Transmission and Distribution Conference and Exhibition, 2005/2006 IEEE PES , vol., no., pp.1291,1295, 21-24 May 2006.

FERREIRA, Vitor Hugo. **Desenvolvimento de Modelos Neurais Autônomos para Previsão de Carga Elétrica**. Tese de Doutorado: COPPE/UFRJ, D.Sc., Engenharia Elétrica, Rio de Janeiro, 2008. IX, 302 p. 29,7 cm.

GELLINGS, C. W. **Demand Forecasting in the Electric Utility Industry**. Pennwell Publ. 2. ed.. Tulsa, OK. 1996.

JING-LING, Yuan; XIAO-YAN, Li; LUO, Zhong. **Optimized Grey RBF Prediction Model Based on Genetic Algorithm**. Computer Science and Software Engineering, 2008. International Conference on, vol.1, no., pp.74,77, 12-14 Dec. 2008.

MTEMBO, Victor; TAYLOR, Gareth A.; EKWUE, Arthur. **A novel econometric model for peak demand forecasting**. In: Power Engineering Conference (UPEC), 2014 49th International Universities, vol.1, no., pp.1,6, 2-5 Sept. 2014.

PARLOS, A.G.; Oufi, E.; MUTHUSAMI, J.; PATTON, A.D.; ATIYA, A.F.. **Development of an intelligent long-term electric load forecasting system**. Intelligent Systems Applications to Power Systems, 1996. Proceedings, ISAP 96., International Conference on , vol., no., pp.288,292, 28 Jan-2 Feb 1996.

PEIXIAN, Li; ZHIXIANG, Tan; LILI, Yan; KAZHONG, Deng. **Time Series Prediction of Mining Subsidence Based on Genetic Algorithm Neural Network**. Computer Science and Society (ISCCS), 2011 International Symposium on , vol., no., pp.83,86, 16-17 July 2011.

SETIAWAN, A.; KOPRINSKA, I.; AGELIDIS, V.G.. **Very short-term electricity load demand forecasting using support vector regression**. Neural Networks, 2009. IJCNN 2009. International Joint Conference on , vol., no., pp.2888,2894, 14-19 June 2009.

SILVA, Ivan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**. Artliber. São Paulo, 2010.

SOUSA, Juliano Neves De Paula e. **Aplicação De Lógica Fuzzy Em Sistemas De Controle de Tráfego Metropolitano Em Rodovias Dotadas De Faixas Exclusivas Para Ônibus [Rio de Janeiro]**. Dissertação de Mestrado: COPPE/UFRJ, M.Sc., Engenharia de Transportes, Rio de Janeiro, 2005. IX, 97p. 29,7cm.

UL ISLAM, B.; BAHARUDIN, Z.; NALLAGOWNDEN, P.; RAZA, M.Q.. **A hybrid neuro-genetic approach for STLF: A comparative analysis of model parameter variations**. Power Engineering and Optimization Conference (PEOCO), 2014 IEEE 8th International , vol., no., pp.526,531, 24-25 March 2014.