

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA
FILHO”**

**FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

TÂNIA TENÓRIO GOMES

**REDE ARTMAP EUCLIDIANA UTILIZADA NA SOLUÇÃO DO
PROBLEMA DE PREVISÃO DE CARGAS ELÉTRICAS**

Ilha Solteira

2017

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

TÂNIA TENÓRIO GOMES

**REDE ARTMAP EUCLIDIANA UTILIZADA NA SOLUÇÃO DO
PROBLEMA DE PREVISÃO DE CARGAS ELÉTRICAS**

Dissertação apresentada à Faculdade de
Engenharia de Ilha Solteira – UNESP como parte
dos requisitos para obtenção do título de Mestre.
Especialidade: Automação.

Anna Diva Plasencia Lotufo

Orientadora

Ilha Solteira

2017

FICHA CATALOGRÁFICA


Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

G633r Gomes, Tânia Tenório.
Rede ARTMAP Euclidiana utilizada na solução do problema de previsão de cargas elétricas / Tânia Tenório Gomes. -- Ilha Solteira: [s.n.], 2017
73 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de conhecimento: Automação, 2017

Orientador: Anna Diva Plasencia Lotufo
Inclui bibliografia

1. Previsão de carga a curto prazo. 2. Distância Euclidiana. 3. Teoria da ressonância adaptativa. 4. Rede Artmap Euclidiana.


Raiane da Silva Santos

Serviço Técnico de Biblioteca e Documentação
Seção Técnica de Referência, Atendimento ao Usuário e Documentação
Supervisão Técnica de Seção
CRB CRB-6/9999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Rede ARTMAP Euclidiana utilizada na solução do problema de previsão de cargas elétricas

AUTORA: TANIA TENÓRIO GOMES

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovada como parte das exigências para obtenção do Título de Mestra em ENGENHARIA ELÉTRICA, área: AUTOMAÇÃO pela Comissão Examinadora:

Profa. Dra. ANNA DIVA PLASENCIA LOTUFO
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira

Profa. Dra. MARA LUCIA MARTINS LOPES
Departamento de Matemática / UNESP/ Câmpus de Ilha Solteira

Profa. Dra. ELIZETE DE ANDRADE AMORIM
Centro de Engenharia e Ciências Exatas CECE / Universidade Estadual do Oeste do Paraná

Ilha Solteira, 22 de dezembro de 2017

DEDICATÓRIA

A Deus, criador de todas as coisas.

Aos meus amados filhos:

Lorena, Nicole e David.

AGRADECIMENTOS

Agradeço a Jesus Cristo, nosso Senhor e Salvador que permitiu que este trabalho fosse realizado, sem Ele eu nada poderia.

Agradeço a Prof^a Mara pelos ensinamentos, amizade, confiança e por ser a porta de entrada do laboratório Sintel e desta dissertação.

À minha orientadora Prof^a Anna Diva que me aceitou no programa de pós-graduação, pela orientação e momentos de dificuldades (não foram poucos).

Ao Prof. Minussi pela experiência, responsabilidade e a idealização do laboratório Sintel.

Aos meus amigos de laboratório: Monara “filha adotiva” pela amizade e ajuda em geral, Marcos, que saudade..., Marleide “Rainha do Matlab” pela ajuda com a ferramenta Matlab, Júnior “Rei da Programação” pelas dicas e estratégias de linguagem computacional, a Thays obrigada pelas correções no artigo, a Tatiana “*My sister*” pela amizade, ajuda com *Office* e as caronas, Douglas, Haislan, Aline e Nayara, e quem está chegando sejam bem-vindos: Selene e Ronald, a todos meus amados amigos ao qual não me esquecerei.

A todos os professores e pesquisadores que não medem esforços para que este departamento de engenharia elétrica de Ilha Solteira alcance seus objetivos e alvos.

Aos professores de banca e visitantes pela colaboração e a evolução do crescimento científico.

Aos técnicos do laboratório de informática: Deoclécio e Rafael.

A secretaria: Mariana e Éder.

A equipe da seção técnica de Pós-graduação: Márcia, Graciele e Thaís.

A toda minha família, meus filhos: Lorena, Nicole e David, minha mãe, Leonice, meu padrasto, José Nilton, meus irmãos, Odenir e Otacílio, muito obrigado pelo incentivo.

A Coordenação Aperfeiçoamento Pessoal de Nível Superior (CAPES) pelo apoio financeiro.

“As leis da natureza são apenas os pensamentos matemáticos de Deus”.

Euclides de Alexandria

RESUMO

A geração e distribuição de energia elétrica fazem parte de um vasto esquema no setor elétrico de cada país, tornando-se cada vez mais necessário criar alternativas para minimizar seu custo. Realizar a previsão de cargas elétricas de forma precisa garante uma infraestrutura mais eficiente e confiável para planejamento e operação do sistema elétrico. A proposta deste trabalho é realizar a previsão de carga elétrica global a curto prazo, utilizando uma técnica que forneça uma boa precisão, seja confiável e de baixo custo computacional. Portanto, foi utilizada a rede neural artificial ARTMAP Euclidiana, que é baseada na Teoria da Ressonância Adaptativa. Com objetivo de analisar a eficiência da metodologia proposta foram realizados 3 casos com diferentes horizontes de treinamento, sendo calculado o erro percentual médio. Os dados utilizados para as simulações são de uma companhia elétrica espanhola. O principal objetivo deste trabalho é aplicar a rede neural ARTMAP Euclidiana na previsão de cargas elétricas 24 horas à frente e para validar e verificar se esta rede é uma boa ferramenta para este tipo de estudo foi utilizada a rede neural ARTMAP *Fuzzy* com os mesmos dados empregados na rede ARTMAP Euclidiana como critério de comparação para comprovar a eficiência da rede neural ARTMAP Euclidiana.

Palavras-chave: Previsão de carga a curto prazo. Distância Euclidiana. Teoria da ressonância adaptativa. Rede ARTMAP Euclidiana.

.

ABSTRACT

Generation and distribution of electrical energy are very important for the development of the countries and it is necessary to create alternatives to minimize the costs. Electrical load forecasting must be realized precisely to assure a reliable and secure operation of the electrical system. The proposal of this work is to realize the short term global electrical load forecasting using a technique with good precision and reliable and with low computational cost. Thus, the Euclidian ARTMAP neural network was used which is also based on the adaptive resonance theory. Three different cases with different horizons were used for training and the percentual error is calculated. The data are from a Spanish company. The main objective is to apply the Euclidian ARTMAP neural network to forecast the loads 24 hours ahead. The results are compared with the traditional Fuzzy ARTMAP neural network using the same data and the comparison is effectuated evaluating the MAPE (mean absolute percentual error).

Keywords: Short-terms load forecasting. Euclidean Distance. Adaptive resonance theory. Euclidean ARTMAP network.

LISTA DE FIGURAS

FIGURA 1 - CRESCIMENTO DA PRODUÇÃO DAS INDÚSTRIAS ELETROINTENSIVAS.....	18
FIGURA 2- INVESTIMENTO EM ENERGIA ELÉTRICA E INVESTIMENTO EM GERAÇÃO.....	20
FIGURA 3- REPRESENTAÇÃO DO SISTEMA DE REDE ELÉTRICO INTELIGENTE.....	21
FIGURA 4- ASPECTOS DA REDE INTELIGENTE DE ENERGIA	23
FIGURA 5- CLASSIFICAÇÃO DOS PERÍODOS DA PREVISÃO.....	25
FIGURA 6- ALGUMAS DAS PRINCIPAIS REDES DA FAMÍLIA ART.....	27
FIGURA 7- MODELO DA ART1.....	31
FIGURA 8- SUBSISTEMA DE ATENÇÃO E ORIENTAÇÃO	32
FIGURA 9- REPRESENTAÇÃO GEOMÉTRICA DA REDE ART	33
FIGURA 10- REDE NEURAL ART <i>Fuzzy</i>	35
FIGURA 11- FLUXOGRAMA DA REDE NEURAL ART <i>Fuzzy</i>	38
FIGURA 12- REDE NEURAL ARTMAP <i>Fuzzy</i>	40
FIGURA 13- FLUXOGRAMA DA REDE NEURAL ARTMAP <i>Fuzzy</i>	42
FIGURA 14- REPRESENTAÇÃO GEOMÉTRICA DA CATEGORIA ELIPSOIDAL COMPARADA COM A CATEGORIA DO HIPER-RETÂNGULO.	44
FIGURA 15- COMPARAÇÃO ENTRE AS GEOMETRIAS DAS CATEGORIAS EM HIPER-RETÂNGULOS E HIPER-ESFERAS.	45
FIGURA 16- FLUXOGRAMA DA REDE ARTMAP EUCLIDIANA	51
FIGURA 17- PROCESSO ESQUEMÁTICO PARA PREVISÃO DE DEMANDA ATRAVÉS DA REDE NEURAL ARTMAP EUCLIDIANA.....	54
FIGURA 18- RESULTADO DA PREVISÃO DE CARGA PARA O CASO 1- ARTMAP <i>Fuzzy</i>	57
FIGURA 19- RESULTADO DA PREVISÃO DE CARGA PARA O CASO 2 - ARTMAP <i>Fuzzy</i>	57
FIGURA 20- RESULTADO DA PREVISÃO DE CARGA PARA O CASO 3 - ARTMAP <i>Fuzzy</i>	58
FIGURA 21- RESULTADO DA PREVISÃO DE CARGA PARA O CASO 1 - ARTMAP EUCLIDIANA. ..	58
FIGURA 22- RESULTADO DA PREVISÃO DE CARGA PARA O CASO 2 - ARTMAP EUCLIDIANA.	58
FIGURA 23- RESULTADO DA PREVISÃO DE CARGA PARA O CASO 3 - ARTMAP EUCLIDIANA. ..	59
FIGURA 24- MODELO SIMPLIFICADO DE UM NEURÔNIO BIOLÓGICO E SUAS PARTES.	68
FIGURA 25- NEURÔNIO ARTIFICIAL PROPOSTO POR MCCULLOCH E PITTS.....	69
FIGURA 26- MODELO DE UM NEURÔNIO ARTIFICIAL.	69
FIGURA 27- EXEMPLOS DE FUNÇÕES DE ATIVAÇÃO: LINEAR, RELÉ E SIGMOIDAL.	70
FIGURA 28- MODELO EM CAMADAS DA REDE NEURAL ARTIFICIAL.	71

LISTA DE TABELAS

TABELA 1- BRASIL E REGIÕES. PROJEÇÃO DA POPULAÇÃO TOTAL RESIDENTE , 2017-2026.....	17
TABELA 2- GRANDES CONSUMIDORES INDUSTRIAIS: CONSUMO TOTAL DE ELETRICIDADE (1), POR SEGMENTO (GWh).....	19
TABELA 3- EVOLUÇÃO DAS ARQUITETURAS DA FAMÍLIA ART.	28
TABELA 4- COMPARAÇÃO ENTRE AS FUNÇÕES DA REDE NEURAL ARTMAP FUZZY E ARTMAP EUCLIDIANA.	46
TABELA 5- TAXA DE PARÂMETROS PARA TREINAMENTO DA ARTMAP FUZZY.....	55
TABELA 6- TAXA DE PARÂMETROS PARA TREINAMENTO DA ARTMAP EUCLIDIANA	56
TABELA 7- MAPE, ERRO MÁXIMO E TEMPO DE PROCESSAMENTO DA PREVISÃO – ARTMAP <i>FUZZY</i>	60
TABELA 8- MAPE, ERRO MÁXIMO E TEMPO DE PROCESSAMENTO DA PREVISÃO – ARTMAP EUCLIDIANA	60

LISTA DE SIGLAS E ABREVIATURAS

ANFIS	<i>Adaptive Network Based Fuzzy Inference System.</i>
ARMA	<i>Auto Regressive Moving Average.</i>
ARIMA	<i>Auto Regressive Integrated Moving Average.</i>
ART	<i>Adaptive Resonance Theory.</i>
ARTMAP	<i>Adaptive Resonance Theory – Supervised Predictive Mapping.</i>
AR(p)	<i>Auto Regressive.</i>
CPNN	<i>Counter Propagation Neural Network.</i>
EPE	<i>Empresa de Pesquisa Energética.</i>
EQTAM	<i>Euclidean Quality Threshold Adaptive Resonance Theory-Supervised Predictive Mapping.</i>
FACP	<i>Função de Autocorrelação Parcial.</i>
GN	<i>Grossberg Network.</i>
GRNN	<i>Generalized Regression Neural Network.</i>
MA(q)	<i>Moving Average.</i>
MAPE	<i>Mean Absolute Percentage Error.</i>
MLP	<i>Multilayer Perceptron.</i>
ONS	<i>Operador Nacional de Sistema Elétrico.</i>
PIEE	<i>Programa de Investimento em Energia Elétrica.</i>
RBFNN	<i>Radial Basis Function Neural Network.</i>
RNA	<i>Rede Neural Artificial.</i>
SARIMA	<i>Seasonal Auto Regressive Integrated Moving Average.</i>
SIN	<i>Sistema de Integração Nacional.</i>
SOM	<i>Self Organizing Map.</i>
VLPGO	<i>Large Power Grid Operators.</i>

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	Objetivo do Trabalho	15
1.2	Organização do Texto	15
2	CARGA ELÉTRICA.....	17
2.1	Smart Grid.....	20
2.2	Previsão de Carga Elétrica	23
3	TEORIA DA RESSONÂNCIA ADAPTATIVA.....	26
3.1	Rede Neural ART.....	30
3.1.1	<i>A geometria da Rede Neural ART</i>	32
3.2	Rede Neural ART <i>Fuzzy</i> (Nebulosa).....	34
3.3	Rede Neural ARTMAP	39
3.4	Rede Neural ARTMAP <i>Fuzzy</i>	40
3.5	Rede Neural ARTMAP Euclidiana	43
3.5.1	<i>Algoritmo ARTMAP com o Uso da Distância Euclidiana</i>	46
4	REDE NEURAL ARTMAP EUCLIDIANA APLICADA NA PREVISÃO DE CARGAS ELÉTRICAS	52
5	RESULTADOS DAS SIMULAÇÕES	55
6	CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS	61
6.1	Sugestões para Trabalhos Futuros.....	61
	REFERÊNCIAS	63
	ANEXO A – REDES NEURAIS ARTIFICIAIS	68
A.1	Modelo de Neurônio Biológico	68

A.2	Modelo de Neurônio Artificial	68
A.3	Características Gerais da Rede Neural	70
A.4	Estrutura da Rede Neural.....	71
A.5	Treinamento da Rede Neural	72

1 INTRODUÇÃO

Cada vez mais, as grandes e pequenas companhias do setor de energia elétrica necessitam de tomadas de decisões precisas em relação ao planejamento e organização de sua produção, para fornecer energia de qualidade para as indústrias, empresas e residências.

Sabe-se que existem fatores que influenciam no comportamento das cargas elétricas, e que podem influenciar no aumento do consumo de energia de forma relevante, como as mudanças climáticas, os finais de semana, feriados e/ou dias atípicos.

No Brasil a grande fonte de energia provém de usinas hidrelétricas, no qual necessitam de um bom nível de água no reservatório, caso a pluviosidade seja de volume baixo, necessita-se de acionamento de outras fontes de energia, tais como usina nuclear, eólicas, solar entre outras. Conforme o aumento da população, também há um acréscimo no consumo de energia em nosso país de 2,2% ao ano por habitante (EPE-2017).

Diante deste cenário surge um novo “conceito”, o sistema de energia elétrica inteligente (*Smart Grid*), capaz de monitorar a geração, distribuição e o consumo da energia atribuída. Com a chegada da rede inteligente, os consumidores poderão adquirir informações sobre o consumo de energia por horário, com o banco de dados do último período de faturamento e também a demonstração da qualidade de energia ofertada pelas concessionárias (TEIXEIRA; ESPOSITO; RIVIERA; 2013).

Inúmeras pesquisas tem se desenvolvido para prever o futuro do sistema elétrico para geração, transmissão e distribuição de energia com uma demanda suficiente capaz de suprir as necessidades dos consumidores e empresas em geral. Diante deste paradigma o aprimoramento e surgimento das novas técnicas de previsão de carga elétrica tem sido uma ferramenta eficaz para tratar e prever futuras expansões de rede, coletando dados e proporcionando um acervo de informações para um prévio diagnóstico no desenvolvimento deste sistema.

As técnicas de previsão de cargas elétricas que já tiveram grande destaque na literatura são: técnica de regressão linear simples ou múltipla, alisamento exponencial, estimação de estado, filtro de *Kalman*, ARIMA (*Auto Regressive Integrated Moving Average*) de *Box* e *Jenkins* (1976), todas estas necessitam da modelagem da carga elétrica. Atualmente são utilizadas técnicas inteligentes por fornecerem um processamento mais rápido e robusto.

Há um número considerável de pesquisas disponíveis na literatura fornecendo resultados mais eficientes e rápidos na aquisição de alternativas para previsão de cargas elétricas, entre elas as combinações das redes neurais e com outros modelos de inteligência artificial como, por exemplo, Yang et al. (2016) utilizou a união de três técnicas: as redes neurais com o algoritmo *Backpropagation*, *Adaptive Network Based Fuzzy Inference System* (ANFIS) e o modelo *Seasonal Auto Regressive Integrated Moving Average* (SARIMA), no qual os resultados de previsão do método combinado mostraram-se melhores do que todos os três métodos individuais e o método combinado (híbrido) foi capaz de reduzir os erros e melhorar a precisão entre os valores reais e os valores previstos de forma eficaz.

O trabalho de Ding et al. (2016) usou a rede neural artificial *Multi Layer Perceptron* (MLP) com o algoritmo *Backpropagation* e um algoritmo de minimização conhecido como *Levenberg-Marquardt* para prever cargas elétricas de distribuição de média e baixa tensão e Dudek (2016) propôs um estudo amplo e comparativo entre as redes neurais com base nas MLP, RBFNN (*Radial Basis Function Neural Network*), GRNN (*Generalized Regression Neural Network*), CPNN (*Counter Propagation Neural Network*) e SOM (*Self Organizing Map*) para previsão de carga a curto prazo.

Foi desenvolvido por Oliveira (2013) uma rede neural híbrida composta por duas redes de arquiteturas diferentes como a ART *Fuzzy* e a MLP para previsão de cargas elétricas a curto prazo; Alves, Lotufo e Lopes (2013) obtiveram resultados de previsão utilizando uma rede híbrida com o método de Regressão Linear com Seleção de Variáveis *Stepwise* juntamente com a rede neural artificial MLP com o algoritmo *Backpropagation*; Abreu et. al. (2012) desenvolveram um modelo híbrido utilizando os modelos ARIMA de *Box & Jenkins* e redes neurais artificiais com treinamento realizado pelo algoritmo de *Levenberg-Marquardt* para previsão de cargas elétricas a curto prazo.

A rede ARTMAP Euclidiana foi utilizada por Marchiori (2006) para um Desenvolvimento de um Sistema de Análise da Estabilidade Transitória de Sistemas de Energia Elétrica, nesta pesquisa a rede teve um papel de grande importância satisfazendo um resultado de boa qualidade superando as expectativas. Moreno (2010), apresentou a ART-ARTMAP *Fuzzy* Euclidiana Modificada com o mesmo propósito Analisar a Estabilidade Transitória da Energia Elétrica com Treinamento Contínuo. Com esta mesma nova técnica Barros (2013), trabalhou com Detecção e Classificação de Distúrbios de Tensão.

Foi apresentada em por Yaakob, Lim, e Jain (2009) um novo modelo de rede neural, a EQTAM (*Euclidean Quality Threshold Adaptive Resonance Theory-Supervised*), baseada na ARTMAP

Euclidiana e comparada com outros tipos de redes para classificação de um conjunto de dados clínicos para avaliar problemas médicos do tipo: diabetes, câncer de mama, doenças cardíacas e dermatológicas de um hospital da Malásia.

Este trabalho apresenta uma proposta para obter a previsão de carga elétrica global a curto prazo fundamentada num sistema inteligente. Assim é utilizada uma rede neural artificial baseada na Teoria da Ressonância Adaptativa, mais precisamente a Rede Neural Artificial (RNA) ARTMAP Euclidiana. Uma das principais vantagens de utilizar uma rede baseada na Teoria da Ressonância Adaptativa é sua capacidade aprender novos padrões, sem perder o conhecimento adquirido anteriormente, o que confere a este tipo de rede as características de plasticidade e estabilidade (GROSSBERG, 1976).

1.1 Objetivo do Trabalho

Uma das motivações de utilizar uma rede neural artificial ARTMAP Euclidiana é a não necessidade de realizar a normalização e complementação nos dados de entrada, reduzindo-a pela metade a dimensão do vetor de entrada, isto representa um processamento mais rápido, ou seja, um baixo custo computacional, em relação à rede ARTMAP Fuzzy (VUSKOVIC; DU, 2002). Logo, o objetivo principal deste trabalho, favorece a análise do modelo da rede neural ARTMAP Euclidiana utilizada para obter informações prognósticas para a previsão de cargas elétricas a curto prazo. Ressalta-se que não se encontra na literatura trabalhos que abordem a aplicação desta arquitetura no problema de previsão de cargas elétricas, o que torna o trabalho inovador.

1.2 Organização do Texto

Este trabalho está composto de seis capítulos, sendo atribuído da seguinte forma: carga elétrica, teoria da ressonância adaptativa, rede neural ARTMAP Euclidiana aplicada na previsão de cargas elétricas, resultados das simulações e considerações finais.

O Capítulo 2 trata a importância do consumo, demanda da carga elétrica e as projeções de investimentos para o setor de energia elétrica brasileira, também neste capítulo abordam uma nova estrutura de informação e tecnologia, as *smart grid*. E as características, períodos, técnicas já utilizadas para previsão e citações de trabalhos existentes nos dias atuais.

O capítulo 3 descreve a origem, as propriedades, a natureza da Teoria da Ressonância Adaptativa, as principais redes da família ART, arquitetura, geometria, rede neural ART *Fuzzy*, ARTMAP, ARTMAP *Fuzzy*, ARTMAP Euclidiana, características, algoritmo da rede ARTMAP com o uso da distância euclidiana e o fluxograma.

No capítulo 4 apresenta a metodologia aplicada no trabalho, a coleta dos dados, os períodos utilizados para o resultado da previsão de carga elétrica, o critério de avaliação (MAPE e o Erro Máximo), processo esquemático para previsão de cargas elétricas.

Capítulo 5 indica os valores dos parâmetros utilizados nas redes neurais ARTMAP *Fuzzy* e ARTMAP Euclidiana, resultados analisados de forma gráfica, MAPE e Erro Máximo.

Capítulo 6 é apresentado conclusão, as contribuições deste trabalho e as sugestões para trabalhos futuros.

Nesta dissertação, contém um apêndice, no qual foi abordado um resumo do surgimento, características, estrutura, tipo de treinamento e citações de pesquisas com utilização de métodos híbridos das redes neurais artificiais.

2 CARGA ELÉTRICA

Uma das fontes básicas, essencial e necessária para a sobrevivência da população atual é a energia elétrica. Esta energia é fornecida em diversos sistemas pelas usinas hidrelétricas, solares fotovoltaicas, termelétricas de biomassa e fósseis, entre outras, em prol do consumo de residências, indústrias, comércios, serviços públicos, etc., e é viabilizada por uma estrutura de rede elétrica que tem o desenvolvimento e a organização da geração, transmissão e distribuição da energia elétrica. Além disso, o sistema deve dispor de um controle na produção de forma que a cada instante seja produzida a energia para atender a demanda e as perdas na produção do transporte (KAGAN; BARIONI; JOÃO ROBBA, 2009).

Pesquisas desenvolvidas pelo Instituto Brasileiro de Geografia e Estatística – IBGE tem apresentado uma preocupação relevante com o comportamento da população pelo motivo do país estar passando por um processo de transição demográfica revelando uma redução na taxa de natalidade e mortalidade ao longo dos anos, e que o número de habitantes numa residência tem diminuído enquanto que o número moradias está em crescimento baseado no perfil sociodemográfico das famílias brasileiras quanto ao perfil da renda familiar. Vale ressaltar que a população brasileira aumentará em torno de 13,0 milhões de habitantes entre a próxima década, número próximo a população do estado da Bahia (15 milhões) (EPE, 2017). A Tabela 1 mostra o crescimento populacional de cada região brasileira ao longo de dez anos.

Tabela 1- Brasil e Regiões. Projeção da População Total Residente , 2017-2026.

ANO	NORTE	NORDESTE	SUDESTE	SUL	CENTRO-OESTE	BRASIL
2016	17.822	57.085	86.653	29.542	15.768	206.871
2021	18.885	58.585	89.348	30.483	16.792	214.094
2026	19.799	59.728	91.457	31.232	17.703	219.918

Nota: Os dados populacionais do IBGE, originalmente divulgados com a data de referência de 1º julho de cada ano, são ajustados para a data de 31 de dezembro, tornando-se assim compatíveis com os dados anuais relativos às variáveis energéticas.


Fonte: (EPE, 2017)

Conforme a sociedade aumenta, assim também se faz necessário que este sistema de energia elétrica seja capaz de suprir as necessidades do dia-a-dia para qualquer tipo de trabalho e que seja ofertado em locais e regiões distantes.

A energia elétrica deve ser suficiente e disponibilizada para os consumidores, entretanto, é indispensável um estudo de planejamento para uma previsão a longo, médio e curto prazo com a finalidade de suprir as exigências de demanda de energia presente e futuras. A análise e os resultados da previsão disponibilizará o surgimento de programas de organização e gerenciamento desta energia proporcionando a segurança, qualidade e a confiabilidade no sistema de energia a ser ofertado (TEIXEIRA; ESPOSITO; RIVIERA, 2013).

Os consumidores domiciliares necessitam de uma alta produção de energia elétrica devido ao perfil da taxa de crescimento da população, além desses consumidores, existem aqueles grandes consumidores de energia elétrica no qual consomem em torno de 35% do total da energia produzida no Brasil, são as grandes indústrias da cadeia do alumínio, incluindo a produção de alumina e a extração de bauxita, siderurgia (produção de aço bruto), ferro ligas, pelletização, cobre, petroquímica (produção de eteno), soda-cloro, papel e celulose, e cimento. A Figura 1 apresenta as taxas de crescimento da produção das indústrias eletrointensivas (grandes consumidoras), uma projeção para um período de 10 anos.

Figura 1 - Crescimento da produção das Indústrias Eletrointensivas.



Fonte: (EPE, 2017)

O consumo de eletricidade (por tonelada de produto) das indústrias é muito versátil de segmento para segmento, em função do local (rota tecnológica), do tipo, entre outros. Com base na taxa de crescimento da produção física dos segmentos calculou-se e projetou-se o

consumo total de energia elétrica dos grandes consumidores industriais, indicado na Tabela 2 para cada segmento.

Tabela 2- Grandes consumidores industriais: consumo total de eletricidade (1), por segmento (GWh).


Segmento	2016	2021	2016-2026	
			2026	(% ao ano)
Alumínio	11.982	15.671	20.043	5,3
Alumina	2.953	3.665	3.858	2,7
Bauxita	473	556	545	1,4
Siderurgia (aço bruto)	15.400	16.305	18.589	1,9
Pelotização	3.856	4.431	4.921	2,5
Ferroligas	5.651	6.709	8.609	4,3
Cobre	640	621	898	3,4
Soda-Cloro	3.527	4.051	4.659	2,8
Petroquímica (eteno)	5.135	5.883	6.183	1,9
Celulose	18.284	22.626	26.592	3,8
Pasta Mecânica	1.124	1.108	1.077	-0,4
Papel	8.127	9.065	10.766	2,9
Cimento	6.213	6.440	7.307	1,6
Total	83.366	97.131	114.046	3,2

Fonte: (EPE, 2017)

É de grande importância para o setor elétrico um planejamento que tenha a capacidade de prover energia suficiente e de qualidade para toda a necessidade de demanda populacional crescente e na expansão das indústrias.

Em nosso país há uma enorme existência de bacias hidrográficas favorecendo o predomínio da energia hidráulica em energia elétrica, estas por fim são afastadas dos grandes centros de consumo. O Ministério de Minas e Energia tem uma projeção na demanda de energia elétrica que contempla as usinas hidrelétricas, pequenas centrais elétricas, eólicas, solar, térmicas a biomassa e fósseis para os próximos 10 anos (2017-2026) (BRASIL, 2015). A Figura 2 ilustra as projeções de investimentos em geração e transmissão de energia elétrica e em quais tipos de usinas a serem aplicados em empreendimentos divulgados pelo governo.

Figura 2- Investimento em Energia Elétrica e Investimento em geração



Fonte: (EPE, 2017)

Observa-se que a tendência difundida para finalidade do uso da eletricidade segue para um incremento de novos sistemas na produção, transmissão e distribuição da energia elétrica tanto para consumidores pequenos (residências, comércios, setores públicos, etc.) quanto aos grandes consumidores (indústrias eletrointensivas).

Diante deste cenário surge uma proposta inovadora de uma estrutura recente que fornece uma nova visão na demanda, denominado *Smart Grid* em que contempla um esquema de automação de técnicas de informação e comunicação fornecendo um conjunto de dados e ampliando funções na área do setor elétrico.

Este sistema permitirá um melhor controle no gerenciamento entre as empresas produtoras de energia elétricas e a diversidade na categoria dos consumidores, permitirá uma supervisão na qualidade da energia, uma análise de perdas em áreas técnicas e comerciais e avaliará regiões apropriadas para acomodação da instalação geradoras de energia elétrica e suas transmissões.


2.1 Smart Grid

As redes elétricas inteligentes ou “*Smart Grid*” foi evidenciada por Amin e Wollenberg (2005), nela expõe uma transformação no paradigma no setor elétrico, considerando a necessidade de alterar a estrutura da concessão de energia para um modo mais interativo por razões que divergem cada região ou país. O desprovimento da inserção de diversas fontes de energia elétrica, especificamente as geradoras descentralizadas, renováveis e intermitentes, e admissão de novos consumidores, tal como o carro elétrico, além de

melhorar a eficiência e a extensão da rede elétrica são fatores que justificam a implantação do sistema de rede elétrica inteligente, que está contemplada em três estágios.

O primeiro estágio, as intervenções feitas com objetivo de agregar inteligência a estrutura do ofertamento da energia elétrica (geração, transmissão e distribuição). O segundo estágio, a substituição de medidores eletromecânicos por eletrônicos inteligentes, podendo os consumidores ter acesso a informação sobre o consumo da energia por hora, dados do último período do faturamento da conta (memória em massa) e sugestões de qualidade da energia atribuída pela concessionária, e o terceiro estágio, a dimensão do uso da inteligência nos centros consumidores, permitindo mais favorável e equilibrado o controle do rendimento energético, por meio da geração disponibilizada por fonte solar, eólica ou biomassa (TEIXEIRA; ESPOSITO; RIVIERA, 2013). A Figura 3 ilustra como o sistema da *Smart Grid* está ligado a vários setores de energia elétrica, tanto na produção, transmissão, quanto ao consumo desta energia.

Figura 3- Representação do Sistema de Rede Elétrica Inteligente.



Fonte: Odoroaga (2017)

Com este novo panorama do setor elétrico pode-se também ampliar para outros setores ou serviços como da água, gás, segurança, trânsito entre outros, proporcionando qualidade e confiabilidade.

A nova infraestrutura de informação e tecnologias eletrônicas deve abranger de forma a evoluir para um novo conceito de cidades inteligentes (*smart cities*), e também para ambientes nos quais todos os objetos podem ser identificados, reconhecidos e localizados, este sistema chama-se Internet das Coisas (*Internet of Things - IoT*). Este sistema se encontra em uma fase embrionária mundial, grandes países como a China, Estados Unidos, Japão e alguns países da Europa tem planejado e traçado seus objetivos na implementação da rede elétrica inteligente através de programas de instalação, contudo países como a Espanha, Reino Unido e outros países europeus não atingiram 10% das instalações (TEIXEIRA; ESPOSITO; RIVIERA, 2013).

Cerca de 90% da energia brasileira está em fontes renováveis pertencente a um Sistema de Integração Nacional (SIN), que adota os parâmetros para Redes Elétricas Inteligentes definidas pelo *Very Large Power Grid Operators (VLPGO)*, corporação constituída pelos maiores operadores de energia mundial, e o órgão responsável pela a coordenação e controle da produção e transmissão da energia elétrica é Operador Nacional de Sistema Elétrico – ONS, entende-se que, no Brasil, existem duas sistemáticas de interesse na operação do SIN e que envolvem o uso da rede inteligente.

A primeira sistemática tem o propósito na implementação das redes inteligentes para o aumento na qualidade do funcionamento, controle e maior segurança do sistema de transmissão. O ONS vem supervisionando esse progresso através da contingência da segurança da operação do SIN. A segunda está pertinente as alterações no sistema de distribuição, que o ONS não tem envolvimento direto, mas que afeta a rede de alta tensão. O ONS tem acompanhado essa evolução na rede de distribuição, que vem acontecendo através da implantação dessas novas tecnologias, como o uso de geração, a colocação de medidores inteligentes e a mudança do perfil da carga dos consumidores (CGEE, 2012).

O Brasil ainda está atrasado em relação a outros países no que diz respeito ao uso do sistema elétrico inteligente (HORA DA COSTA, 2014).

É de fundamental importância que o governo crie condições de mercado para as fontes de energias renováveis para um crescimento econômico sustentável, desenvolvimento de tecnologia e competitividade global.

O desequilíbrio financeiro geral demonstra uma vulnerabilidade no sistema econômico, especialmente para os países emergentes, neste novo paradigma, redes inteligentes de energia definitivamente tem se destacado principalmente para grandes

produtores de energia a base de petróleo. Uma das fundamentais características do sistema da rede elétrica inteligente ou “*smart grid*” está ilustrado na Figura 4:

Figura 4- Aspectos da rede inteligente de energia.



Fonte: (CEMIG, 2009b)

2.2 Previsão de Carga Elétrica

A carga elétrica pode sofrer interferências por diversos princípios fundamentais no ambiente determinístico interferindo na eficácia da previsão (O’ DONAVAN, 1983).

Essas características são determinadas por fatores de suma importância sendo eles (AMORIM, 2015):

- Climáticos, é uma das principais características que podem interferir no resultado da previsão, tal como uma vinda de frente fria, o aumento ou a redução da temperatura pelo motivo do uso dos ares-condicionados, velocidade do vento e a umidade do ar.

- Tempo, fator importante dividido em três partes fundamentais, o primeiro, dias de feriados religiosos ou nacionais ou oficiais, o segundo, efeitos sazonais que ocorre de forma cíclica ao longo do ano, em diferentes estações do ano oscilando conforme a demanda, por fim ciclo de diário-semanal em dias de descanso (sábado e domingo) da comunidade.

- Econômicos, podem provocar influência no consumo de energia em determinada região (distrito industrial, zona rural ou urbana).

- Aleatórios ou esporádicos que refletem na previsão conforme a entrada ou saída do consumo de energia de grandes empreendedores, outra situação é uma manifestação popular ou greve dos trabalhadores.

Existem dois tipos de sistemas previsores de cargas elétricas: **espacial**, no qual prevê as cargas futuras de um determinado local, região ou país, e a **temporal**, prevendo cargas em minutos, horas, dias, meses, anos e décadas para pequenos e grandes consumidores (BAO, 2002).

As previsões de cargas elétricas contempla sua realização de diversos perfis em determinados períodos (LOPES, 2005):

- **Previsão a longo prazo:** por constituir de períodos de longa duração como anos e décadas, esta previsão tem o foco na organização técnica e econômica das usinas elétricas, servindo como referência para os setores de energia.


- **Previsão a médio prazo:** por permitir um período entre um ano a mais, é favorável no planejamento da manutenção, planejamento de intercâmbio, considerando um fator de suma importância - o suprimento das fontes de energia.

- **Previsão a curto prazo:** esta previsão é essencial para análise de maior qualidade, segurança, aprimorando os recursos da geração e reduzindo os custos para produção de energia.

- **Previsão a curtíssimo prazo:** utilizada para equilíbrio da geração, reduzindo flutuações e evitando distúrbios nos centros de distribuição (problemas de aumento ou diminuição na queda de tensão).

A figura 5 apresenta os diversos períodos da previsão de cargas elétricas referentes a minutos, horas, dias, anos e décadas (LEONE, 2006; TRUJILLO, 2010; GARCIA, 2013).

Figura 5- Classificação dos Períodos da Previsão.



Fonte: (GARCIA, 2013)

As técnicas de previsão com métodos estatísticos de cargas elétricas que já tiveram grande destaque na literatura são: Técnica de Regressão Linear Simples ou Múltipla, Alisamento Exponencial, Espaço de Estado e Filtro de *Kalman*, Série Temporal de *Box & Jenkins* (1976) (conhecida comumente como previsão dinâmica), essa técnica possui subdivisões (O' Donavan, 1983):

- Modelo Ruído Branco;
- Modelo *Auto Regressive* (AR(p));
- Modelo *Moving Average* (MA(q));
- Modelo *Auto Regressive Moving Average* (ARMA (p,q));
- Modelo de *Walk Aleatório*;
- Modelo *Auto Regressive Integrated Moving Average* (ARIMA);
- Modelo Função de Autocorrelação Parcial (FACP);
- Modelo *Seasonal Auto Regressive Integrated Moving Average* (SARIMA).

Há um número considerável de pesquisas disponíveis na literatura fornecendo resultados mais eficientes e rápidos na aquisição de alternativas para previsão de cargas elétricas.

O presente trabalho realiza uma previsão de cargas elétricas a curto prazo.

3 TEORIA DA RESSONÂNCIA ADAPTATIVA

Algumas das propriedades fundamentais das redes neurais artificiais está associada a capacidade de generalização, obter resultados para padrões de entrada equivalentes aos padrões fornecidos à rede através do treinamento. Os conceitos sobre redes neurais artificiais se encontram no Apêndice A deste trabalho.

Quando se treina uma rede espera-se que ela proporcione forneça respostas adequadas para um padrão de dados de entrada, conforme seu conhecimento, adquirido posteriormente. Se seu conhecimento sofrer variações com o passar do tempo, para ajustar novos padrões de entrada indeterminados necessita-se que o algoritmo da rede seja plástico. Uma solução para este problema seria retreinar a rede, entretanto, as informações adquiridas poderão se perder. E, para que se conserve este novo conhecimento, a rede também necessita ser estável. Este problema é conhecido como o dilema da estabilidade e plasticidade (CARPENTER; GROSSBERG, 1992).

Então, é preciso uma rede incremental que não necessite de um novo começo para cada vez que se apresentem novos padrões de entrada e que conserve suas informações. Em 1976, Grossberg questiona:


- Como pode uma rede conservar seu conhecimento adquirido e ao mesmo tempo ser flexível para armazenar seu novo conhecimento?
- Como pode um sistema ser treinado adaptado (plástico) e permanecer estável a informações imprecisas?
- Como pode um sistema ser plástico e estável ou vice-versa?

Ele próprio responde estas questões com a Teoria da Ressonância Adaptativa (ART). Christoph Von der Malsburg (1973), foi um dos pioneiros a apresentar uma rede neural artificial com propriedades de auto-organização para modelagem de córtex visual das vertebras superiores e influenciou os trabalhos de Teuvo Kohonen e Steven Grossberg. Kohonen desenvolveu a rede SOM (*Self-Organizing Maps*) que faz o mapeamento com características auto-organizável. Grossberg desenvolveu GN (*Grossberg Network*) a primeira rede com arquitetura baseada na teoria da ressonância adaptativa, esta rede apresenta duas camadas, a primeira faz a implementação dos dados de entrada e a segunda camada, no qual é competitiva com conectividade de realimentação não-linear, executa a seleção dos padrões de saída e os armazena na memória (AMORIM, 2006).

A importância desta rede está baseada na resolução do dilema da plasticidade e estabilidade, realizado pelo teste de vigilância para a administração de inclusão de novas entradas em cada grupo. A plasticidade é a capacidade que a rede tem de aprender um novo padrão, em qualquer tempo de sua operação, sem perder o aprendizado adquirido anteriormente. A estabilidade está vinculada com a garantia de agrupamento de todos os elementos nas categorias criadas pelo sistema, tendo em vista que os pesos da rede possuem características somente de decrescimento, ou seja, conforme os ajustes (as adaptações) dos pesos são realizados, os novos valores tendem sempre a diminuir até a estabilização (AMORIM, 2006).

Na atividade de reconhecimento de padrões de entrada, quando algum dado não assemelha a nenhum dos grupos já existentes, um novo grupo é escolhido para a referida entrada. Esta habilidade em algumas redes neurais podem afetar a estabilidade do sistema, ou seja, se houver uma nova aprendizagem, podem os padrões anteriormente já treinados serem prejudicados, podendo sofrer com a perda da capacidade de reconhecer os padrões antigos, nas redes ART este problema como escrito no começo do parágrafo, é resolvido com o mecanismo de vigilância que administra as novas entradas em cada grupo (AMORIM, 2006).

São citados diversos modelos de rede oriundos da família ART, na Figura 6:



Fonte: (SANTOS JÚNIOR, 2013)

- **Rede Neural ART1:** possui treinamento não-supervisionado e tem a capacidade de reconhecer padrões de entrada binários aleatoriamente (CARPENTER; GROSSBERG, 1987);
- **Rede Neural ART2:** treinamento não-supervisionado e possui a capacidade de reconhecer padrões de entrada binários e de entrada analógicos (CARPENTER; GROSSBERG, 1987);
- **Rede Neural ART Fuzzy:** treinamento não-supervisionado possuindo uma arquitetura de cálculos baseado na lógica nebulosa ou *fuzzy* (CARPENTER et al.,1991b);
- **Rede Neural ARTMAP:** treinamento supervisionado, composta por dois módulos ART, interconectados através do módulo inter-ART (CARPENTER et al.,1991a);
- **Rede Neural ARTMAP Fuzzy:** treinamento supervisionado, semelhantemente a ARTMAP diferendo somente nos cálculos, em que são baseados na lógica nebulosa ou *fuzzy* (CARPENTER et al.,1992).

Inúmeras variedades da arquitetura ART vem sendo desenvolvidas, com o intuito de melhorar a generalização do sistema, tornando-as mais eficientes na solução de problemas na vida real. Na Tabela 3 é observada a evolução desta arquitetura.

Tabela 3- Evolução das arquiteturas da família ART.

Ano	Arquitetura	Autor
1976	GN	Grossberg
1987	ART1	Carpenter
	ART2	Carpenter
1990	ART3	Carpenter
1991	ART 2-A	Carpenter
	ARTMAP	Carpenter
	Fuzzy-ART	Carpenter
1992	Fuzzy-ARTMAP	Carpenter
	AFCL Newton	Newton

	Fuzzy Min-Max Neural Network(FMMNN)	Simpson
1993	LAPART Simplified Fuzzy-ARTMAP Fusion ARTMAP	Healy Kasuba Asfour
1994	IAFC	Kim
1995	ART-EMAP Adaptive Hamming Net (AHN) ARAM PROBART	Carpenter Hung Tan Marriot
1996	Gaussian-ARTMAP FasArt hART-J	Williamson Cano-Izquierdo Barfai
1997	Supervised AHN (SAHN) hART-S Barfai Mart ART-LD FasBack dART, dARTMAP Cascade-ARTMAP PNN-ART Lim	Hung Barfai Kim Zhou-J. Cano-Izquierdo Carpenter Tan Lim
1998	ARTMAP-IC LAPART2 Multi-channel ART (MART) Boosted ARTMAP	Carpenter Healy Fernández-Delgado Verzi
1999	Fuzzy (Supervised) AHN ARTEX	Hung Grossberg


	FA Variant Ofam DfasArt	Georgiopoulos Dagher Parrado-Hernández
2000	MicroARTMAP (μ ARTMAP) HART & HARTMAP FANNC Zhou-Z.	Gómez-Sánchez Anagnostopoulos Zhou-Z.
2001	Ellipsoid ART (EA) & Ellipsoid ARTMAP (EAM) Safe μ ARTMAP	Anagnostopoulos Gómez-Sánchez
2002	semi-supervised Ellipsoid ARTMAP (ssEAM) ART-C	Anagnostopoulos He
2003	AFC Default ARTMAP	Sapozhnikova Carpenter
2004	Simplex ARTMAP (SAM) Analog-ART1 ARTSTREAM	Gomes Rajasekaran Grossberg
2005	GreyART Yeh PolyTope ARTMAP (PTAM) Gomes Overlapping PolyTope ARTMAP (OPTAM)	Yeh Gomes Gomes

Fonte: (AMORIM, 2006)

3.1 Rede Neural ART

Os modelos de redes neurais ART são desenvolvidos para codificar reconhecimento estáveis, em tempo real, através da auto-organização, em resposta a sequências arbitrárias de padrões de entrada (CARPENTER; GROSSBERG, 1992; GOPAL et al. 1999; KIM et al. 2001). O primeiro modelo de família ART, esta ilustrado na Figura 7:

Figura 7- Modelo da ART



Fonte: (SANTOS, 2008)

A arquitetura de modelo ART é formada por dois principais subsistemas: o **subsistema de atenção** e o **subsistema de orientação** (CARPENTER; GROSSBERG, 1991).

O **subsistema de atenção** consiste de três campos de neurônios: o campo F_0 , representa o vetor de entrada atual; o campo F_1 processa os dados de entrada; e F_2 , que agrupa os padrões de treinamento em categorias de reconhecimento, em que cada campo pode consistir de várias camadas de neurônios. Estes campos são conectados com pesos de conexão, que são responsáveis pelo armazenamento das informações através de um processo que envolve a escolha da categoria, critério de equalização e treinamento (CARPENTER; GROSSBERG, 1991).

O **subsistema de orientação** é controlado por um parâmetro de vigilância (ρ), que determina se um padrão de entrada pode ser incluído em uma das categorias existentes. CARPENTER; GROSSBERG, 1991).


Os padrões de atividade desenvolvidos sobre os nós nas duas camadas, F_1 e F_2 , no estado de ressonância são chamados de memória a curto prazo (Short Term Memory – STM). A aprendizagem ocorre durante o período de ressonância (DJUKANOVIC et al., 1995;

GEORGIOPOULOS et al., 1996; GOPAL; WOODCOCK; STRAHLER, 1999; SIMPSON, 1989).

As camadas F_1 e F_2 são conectadas através de conexões não-recorrentes ou diretas (*feedforward*) (F_1 a F_2) e recorrentes (*feedback*) (F_2 a F_1). Os pesos associados com as conexões de baixo para cima (*bottom-up*) (conexões de pesos de F_1 para F_2) e de cima para baixo (*top-down*) (conexões de pesos de F_2 para F_1) entre as camadas F_1 e F_2 são chamados de memória a longo prazo (Long Term Memory – LTM) (GOPAL; WOODCOCK; STRAHLER, 1999; KEYVAN, SONG, KELLY, 1999).

A Figura 8 mostra os subsistemas da arquitetura de uma rede ART.

Figura 8- Subsistema de Atenção e Orientação.



Fonte: (LOPES, 2005)

Resumidamente, o subsistema de atenção indica a categoria escolhida e o subsistema de orientação tem a função de aceitar a categoria ou reorientar a busca por outra categoria.

3.1.1 A geometria da Rede Neural ART

As categorias desenvolvidas pela rede neural ART são representadas em hiper-retângulos, em que são definidos os valores entre Min. (Mínimo) e Max. (Máximo). Na


Figura 9, os vetores $u = [u_1 \ u_2]$ e $v = [v_1 \ v_2]$ são associados aos operadores lógicos AND e OR da Lógica *Fuzzy* (CARPENTER; GROSSBERG, 1992).

$$(u \wedge v)_1 = \min(u_1, v_1) \quad (u \wedge v)_2 = \min(u_2, v_2) \quad (1)$$

$$(u \vee v)_1 = \max(u_1, v_1) \quad (u \vee v)_2 = \max(u_2, v_2) \quad (2)$$

As posições u e v são originadas do vetor peso, $w_j = [u_j \ v_j]$, na forma de codificação de complemento, sendo $v_j = u_j^c$ (CARPENTER; GROSSBERG, 1992).

Figura 9- Representação Geométrica da Rede ART



Fonte: (LOPES, 2005)

Existem parâmetros que controlam a rede neural ART, portanto, são de grande importância para o desenvolvimento da aprendizagem. Os parâmetros em destaque são:

- Parâmetro de escolha (aprendizagem) ($\alpha > 0$): controla a sequência de busca entre os neurônios da camada F_2 . Supondo que um ponto (entrada de dados) pertença a mais de um hiper-retângulo, o parâmetro de escolha irá conferir que o

menor dos hiper-retângulos seja o escolhido entre os demais (GOPAL et al, 1999; WEENINK, 1997).

- Parâmetro de treinamento ($\beta \in [0 \ 1]$): se β tem um valor próximo de zero, demonstra um treinamento lento, caso contrário, ou seja, β com valor próximo de um, seu treinamento será rápido.
- Parâmetro de vigilância ($\rho \in [0 \ 1]$): verifica se os padrões de entrada e os pesos tenham combinação para obter a ressonância. Se ρ possui um valor inferior, próximo de zero, a rede permite que os padrões poucos idênticos sejam agrupados na mesma categoria, gerando pequenos números de classes. Caso ρ for atribuído um valor grande, próximo de um, pequenas variações nos padrões de entrada levarão à criação de novas classes (MARCHIORI, 2006).


3.2 Rede Neural ART *Fuzzy* (Nebulosa)

Esta rede possui uma arquitetura de cálculos de operadores que provêm da teoria dos conjuntos *fuzzy* (ZADEH, 1965), em sistemas ART. O diferencial entre as redes ART E ART *Fuzzy* está no operador de interseção ($\cap$), utilizado na rede ART, enquanto que na rede ART *Fuzzy* é empregado o operador *AND* ($\wedge$), isto facilita no processo dos dados analógicos e binários (LOPES, 2005).

Consiste de um campo de pré-processamento de neurônios, F_0 , que transforma o vetor de entrada atual $\mathbf{a}$, e um campo F_1 , que recebe ambas entradas de F_0 , e as entradas de F_2 . A camada F_1 possui $2N$ nós (neurônios), enquanto a camada F_2 possui um número suficiente de nós para acomodar os padrões de entrada em categorias de reconhecimento e realizar o treinamento (LOPES, 2005; MARCHIORI, 2006).

Através da Figura 10, pode-se ter uma melhor percepção do funcionamento da rede neural ART *Fuzzy*.

Figura 10- Rede Neural ART Fuzzy



Fonte: (AMORIM, 2006)

O algoritmo da rede neural ART Fuzzy pode ser resumido nos seguintes passos (CARPENTER; GROSSBERG; REYNOLDS, 1991; CARPENTER; GROSSBERG; ROSEN, 1991; CARPENTER; GROSSBERG, 1992):

- **Passo 1:** Inicialização de pesos e parâmetros da rede.

Ao iniciar, os pesos são todos adotados com um mesmo valor igual a 1, indicando que a categoria não está ativa, $w_{ij} = 1$, o parâmetro de vigilância será escolhido entre 0 e 1, $\rho \in [0, 1]$, o parâmetro de escolha será maior que zero, $\alpha > 0$, e a taxa de treinamento entre 0 e 1, $\beta \in [0, 1]$.

- **Passo 2:** Codificação Complementar do vetor de entrada

Um novo padrão de entrada $a = [a_1 \ a_2 \ \dots \ a_M]$ de M elementos (em que cada elemento a_i é um número real no intervalo $[0, 1]$) passa por uma codificação complementar preliminar. Produzirá um vetor de entrada I de $2N$ elementos, tal como:

$$I = [a \ a^c] = [a_1 \ a_2 \ \dots \ a_N \ a_1^c \ a_2^c \ \dots \ a_M^c] \quad (3)$$

Sendo: $a_i^c = 1 - a_i$.

Esta codificação complementar é uma regra de normalização que preserva a amplitude da informação.

Note que:

$|I| = |[a \ a^c]| = \sum_{i=1}^M a_i + (M - \sum_{i=1}^M a_i) = M$, todos os vetores terão o mesmo comprimento de M .

- **Passo 3:** Escolha da Categoria

A ativação T_j é calculada para cada neurônio j de F_2 , conforme a função escolha dada pela equação (4):

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \quad (4)$$

Sendo:

$\wedge$ = operador *fuzzy* AND, definido por:

$$(I \wedge w)_i = \min(I_i, w_i) \quad (5)$$

Quando no máximo um neurônio se torna ativo, então dizemos que ele teve “a escolha da categoria”, e passa a ser indexada por J (J , maiúsculo ou Jotão), em que:

$$T_J = \max\{T_j : j = 1, \dots, N\} \quad (6)$$

Caso exista mais de um T_j máximo, a categoria j com menor índice é escolhida (SANTOS JÚNIOR, 2013).

- **Passo 4:** Ressonância - Teste de Vigilância

A ressonância ocorre se a função da escolha da categoria ganhadora J satisfaz o teste de vigilância:

$$\frac{|I \wedge w_J|}{I} \geq \rho \quad (7)$$

Se equação (7), não for satisfeita, então o valor da função de escolha T_j é fixo em 0 (zero)(*reset*), para evitar que uma seleção persista na mesma categoria durante o processo de

busca. Então a busca se encerra quando a categoria J escolhida atenda a equação (7) (LOPES, 2005).

- **Passo 5:** Aprendizagem – Atualização de vetor protótipo

O vetor peso w_J é atualizado através da equação (8) (CARPENTER; GROSSBERG, 1992); (LOPES, 2005):


$$w_J^{(novo)} = \beta \left(I \wedge w_J^{(velho)} \right) + (1 - \beta) w_J^{(velho)} \quad (8)$$

Quando $\beta = 1$, tem-se o treinamento rápido. Se o treinamento for rápido, isto permitirá uma atualização com maior rapidez, conforme a equação (9):

$$w_J^{(novo)} = I \wedge w_J^{(velho)} \quad (9)$$

Todos os procedimentos da rede ART *Fuzzy* estão no fluxograma dado pela Figura 11:

Figura 11- Fluxograma da Rede Neural ART Fuzzy.



Fonte: Adaptado (LOPES, 2005)

3.3 Rede Neural ARTMAP

A rede neural ARTMAP (CARPENTER, et. al., 1991a), foi programada a fim de se obter o treinamento supervisionado e auto-organizável sem perder a estabilidade do processo da aprendizagem, diferentemente da rede ART, proposta para classificação não-supervisionada de padrões.

A estrutura básica da rede neural ARTMAP é composta de dois módulos ART, designados ART_a e ART_b , além do módulo Inter-ART.

O primeiro módulo ART_a representa um padrão a entrada e o segundo módulo ART_b , a saída desejada correspondente ao vetor de entrada ART_a .

O terceiro módulo, Inter-ART ou *Match Tracking*, que fará o mapeamento para associar (combinação) os neurônios tanto do módulo ART_a , quanto ao módulo ART_b .

Toda vez que a rede faz um prognóstico errado por meio da conexão associativa instruída, o parâmetro de vigilância (ρ_a), pertencente ao módulo ART_a , é elevado a uma quantidade mínima para corrigir o erro no módulo ART_b (LOPES, 2005)


O módulo ART_a buscará, então, uma nova categoria para a entrada atual até que se ache um prognóstico correto, e a sua correspondente conexão associativa à categoria no módulo ART_b . O módulo ART_a classifica os padrões de entrada apresentados na primeira camada, F_0^a , e o módulo ART_b , com os parâmetros de vigilância (ρ_b), desenvolve categoria referente aos padrões de saída desejado apresentado na primeira camada F_0^b (LIM; HARRISON, 1997).

O “módulo” ou “campo” *Inter-ART*, F^{ab} , recebe entradas de ambos os módulos ART_a e ART_b , se as entradas combinam, então é confirmado o prognóstico selecionado pela categoria, conforme o treinamento, a rede modificará os protótipos das categorias escolhidas em ART_a e ART_b . (LIM; HARRISON, 1997).

Caso as duas entradas não combinam, um sinal de *reset* será feito e o processo de *match tracking* inicializará de maneira que o grau do parâmetro de vigilância no ART_a terá um incremento mínimo para que não ocorra a combinação para aquela entrada atual de ART_a na camada F_1^a . Ativará uma nova busca, escolhendo uma nova categoria no ART_a , cujo prognóstico será combinado novamente com a categoria atual do ART_b (LIM; HARRISON, 1997).

A adaptação/ajuste dos pesos, realizada no módulo *Inter-ART* entre uma categoria ativa J do ART_a e uma categoria ativa K do ART_b é feita de maneira que, a conexão correspondente as categorias ativas dos módulos ART_a e ART_b , ou seja, a conexão entre $F_2^a \rightarrow F^{ab}$, terá valor 1(um) e as demais conexões referentes ao mesmo nó do ART_a terá valor igual a 0(zero) (LOPES, 2005; KARTALOPOULOS,1996; LIM; HARRISON, 1997). A Figura 12 ilustra estrutura de uma rede ARTMAP.

Figura 12- Rede Neural ARTMAP



Fonte: (AMORIM, 2006)

3.4 Rede Neural ARTMAP Fuzzy

Basicamente, o modelo da rede neural ARTMAP *Fuzzy* (CARPENTER, 1992), tem a mesma estrutura da rede ARTMAP (CARPENTER, 1991), apresentada com entrada e saída desejada nos módulos ART_a *Fuzzy* e ART_b *Fuzzy*, sendo a saída desses módulos associados ao módulo de mapeamento, *Inter-ART*, o detalhe está na utilização dos operadores, com o uso da teoria do conjunto *fuzzy* ou nebuloso.

Os vetores para os módulos ART_a *Fuzzy* e ART_b *Fuzzy* estão na forma de codificação complementar. Para o módulo ART_a , temos $I = A = [a \ a^c]$ e para o ART_b , $I = B = [b \ b^c]$,

descrevem-se os vetores de atividade dos módulos envolvidos na rede neural ARTMAP *Fuzzy* (LOPES,20005):

$$ART_a \rightarrow x^a = [x_1^a \dots x_{2M_a}^a], y^a = [y_1^a \dots y_{2N_a}^a] \text{ e } w_j^a [w_{j1}^a \dots w_{j,2M_a}^a];$$


$$ART_b \rightarrow x^b = [x_1^b \dots x_{2M_b}^b], y^b = [y_1^b \dots y_{2N_b}^b] \text{ e } w_j^b [w_{k1}^b \dots w_{k,2M_b}^b];$$

$$Inter-ART \rightarrow x^{ab} = [x_1^{ab} \dots x_{N_b}^{ab}] \text{ e } w_j^{ab} = [w_{j1}^{ab} \dots w_{jN_b}^{ab}].$$

Sendo M_a e M_b , números de vetores de entrada na camada F_1^a e F_1^b , e N_a e N_b □ as dimensões dos vetores de entrada que formam as categorias nas camadas F_2^a e F_2^b dos módulos ART_a *Fuzzy* e ART_b *Fuzzy*, respectivamente (LOPES,2005).

Na Figura 13, o fluxograma mostra como é o funcionamento da rede ARTMAP *Fuzzy*, com todas suas funções e operações.

Figura 13- Fluxograma da Rede Neural ARTMAP Fuzzy.



Fonte: Adaptado (LOPES, 2005)

3.5 Rede Neural ARTMAP Euclidiana

O modelo da rede neural ARTMAP é adequado para a resolução de problemas de classificações, análises e previsões, nela se mantêm a característica da estabilidade e plasticidade, as quais oferecem à rede neural uma aprendizagem estável, múltipla generalização e convergência rápida (Marchiori, 2006).

As redes neurais da família ART apresentam algumas dificuldades operacionais: razoável na sensibilidade dos parâmetros da rede (parâmetro de vigilância, etc.) e a precisão das análises. Através do emprego de novas concepções de treinamento e na arquitetura das redes neurais ART's, isso tem sido solucionado ou amenizado (MARCHIORI, 2006; WILLIAMSON, 1996).

A rede neural ARTMAP Euclidiana contém uma concepção que visa melhorar a precisão nos resultados sem afetar o tempo de cálculo, suas funções e seu treinamento, se comparada com a rede neural ARTMAP clássica.

A rede ARTMAP Euclidiana, apresenta algumas diferenças se relacionarmos com a rede ARTMAP *Fuzzy*. A primeira oposição está na entrada de dados dos vetores, em que não é necessário a normalização e a codificação complementar dos vetores, reduzindo o custo computacional (VUSKOVIC, 2002a), em contraste com outras arquiteturas da família ART. Não contém o parâmetro de escolha (α) contido na camada F_2 para escolha dos neurônios, neste caso, a rede ARTMAP Euclidiana utiliza uma norma baseada na distância euclidiana para a realização da função escolha da categoria.

A função da categoria apresentada na rede neural ARTMAP Euclidiana sobrevém da equação da distância Euclidiana entre dois pontos $x = [x_1 \ x_2 \ \dots \ x_p]$ e $y = [y_1 \ y_2 \ \dots \ y_p]$ em um espaço p -dimensional, e definida como (URL, 2005):

$$\begin{aligned} d_E(x, y) &= \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2} \\ &= \sqrt{(x - y)(x - y)^T} \end{aligned} \quad (10)$$

$$d_E(x, 0) = \|x\|_2 = \sqrt{x_1^2 + x_2^2 + \dots + x_p^2} = \sqrt{x x^T} \quad (11)$$

é a norma Euclidiana de x .


O operador AND ($\wedge$), definido pela teoria dos conjuntos *Fuzzy*, utilizados nas equações da função da categoria e no teste de vigilância utilizado nas redes neurais ART *Fuzzy* e ARTMAP *Fuzzy* não são mais utilizados, logo, os cálculos são baseados somente na distância euclidiana.

Na fase do treinamento é acrescentado (incorporado) na rede um neurônio “vazio”, representando uma categoria de reconhecimento sem a presença de nenhum padrão de entrada (MARCHIORI, 2006), podendo diminuir o número de candidato a vencedor, portanto, diminuindo o número de neurônios por competição.

Ao invés de usarmos a maximização para determinarmos a função da escolha da categoria, empregado nas redes ART e ARTMAP, passa-se a utilizar a minimização para a escolha das categorias.

Geometricamente, utilizam os hiper-retângulos na representação do cálculo da função da categoria nas redes neurais ART e ARTMAP, mas nem sempre esta geometria é necessariamente a melhor representante para agrupar os dados de entrada. Considerando, um sistema de dados bi-dimensional que implicando uma representação de categoria elipsoidal, o uso dos retângulos seria ineficiente para descrever os padrões, então, neste caso os cantos do retângulo obtêm a presença de padrões a mais mostrado na Figura 14.


Figura 14- Representação geométrica da categoria elipsoidal comparada com a categoria do hiper-retângulo.



Fonte: (MARCHIORI, 2006)

A geometria dos hiper-retângulos criada pela lógica *Fuzzy* agora passa a ser das hiper-esferas centradas no centro das classes. Na Figura 15 a linha tracejada é a categoria nova depois da aprendizagem (treinamento).

Figura 15- Comparação entre as geometrias das categorias em hiper-retângulos e hiper-esferas.



Fonte: (AMORIM, 2006)

A Tabela 4 mostra as diferenças entre as funções da rede neural ARTMAP *Fuzzy* e ARTMAP Euclidiana.

Tabela 4- Comparação entre as funções da rede neural ARTMAP *Fuzzy* e ARTMAP Euclidiana.

Módulo	ARTMAP <i>Fuzzy</i>	ARTMAP Euclidiana
Função da Categoria	$T_j^a = \frac{ I_a \wedge w_j^a }{\alpha + w_j^a }$	$T_j^a = (I_j^a - w_j^a)(I_j^a - w_j^a)^T$
Teste de Vigilância	$\frac{ I_a \wedge w_j^a }{ I_a } \geq \rho_a$	$\frac{T_j^a}{\max(I_j^a I_j^{aT}, w_j^a w_j^{aT})} < \rho_a$
Atualização dos Pesos	$w_j^a = \beta(I_a \wedge w_j^a) + (1 - \beta)w_j^a$	$w_j^a = \beta(I_j^a) + (1 - \beta)w_j^a$
Escolha das Categorias	$T_j^a = \max\{T_j: j = 1, \dots, N\}$	$T_j^a = \min\{T_j: j = 1, \dots, N\}$
Inter-ART/Match-Tracking	$\frac{ y^b \wedge w_j^{ab} }{ y^b } \geq \rho_{ab}$	$ y^b \wedge w_j^{ab} < \rho_{ab}$
Incremento no Parâmetro	$\rho_a = \frac{ I_a \wedge w_j^a }{ I_a } + \varepsilon$	$\rho_a = \frac{T_j^a}{\max(I_j^a I_j^{aT}, w_j^a w_j^{aT})} - \varepsilon$

Fonte: Próprio autor.

3.5.1 Algoritmo ARTMAP com o Uso da Distância Euclidiana

O modelo apresentado pelo algoritmo da rede neural ARTMAP Euclidiana a ser executado para a realização do processamento da rede neural está dividido em três etapas, em seus respectivos passos:

1ª Etapa - Início: Definição do vetor padrão de entrada, pesos e parâmetros

Passo 1: Leitura dos Padrões de Entrada e Saída:

O vetor ART_a representa um padrão de entrada e o vetor ART_b a saída desejada correspondente ao vetor de entrada ART_a . A normalização e a complementação dos vetores de entrada é indispensável, por esse motivo, o tamanho dos vetores ficam pela metade se comparada com a tradicional ARTMAP *Fuzzy*.

$$ART_a \rightarrow x^a = [x_1^a \dots x_{M_a}^a], y^a = [y_1^a \dots y_{N_a}^a] \text{ e } w_j^a [w_{j1}^a \dots w_{j,M_a}^a];$$

$$ART_b \rightarrow x^b = [x_1^b \dots x_{M_b}^b], y^b = [y_1^b \dots y_{N_b}^b] \text{ e } w_j^b [w_{k1}^b \dots w_{k,M_b}^b];$$

$$Inter-ART \rightarrow x^{ab} = [x_1^{ab} \dots x_{N_b}^{ab}] \text{ e } w_j^{ab} = [w_{j1}^{ab} \dots w_{jN_b}^{ab}].$$

- M = número de vetores de entrada na camada F_1 ;
- N = dimensão dos vetores de entrada que na camada F_2 formam as categorias.

Passo 2: Construção das matrizes pesos:

Os Pesos w_j^a e w_k^b são iniciados com valor igual a 0, indicando a presença de um único *cluster* (categoria) ativa. O peso w_{jk}^{ab} inicia com o valor igual a 1, indicando que não existe nenhuma categoria ativa.

Passo 3: Leitura dos Parâmetros:

Os parâmetros essenciais para o desenvolvimento da rede neural ARTMAP Euclidiana são:

- β : taxa de treinamento $[0, 1]$;
- ρ_a : parâmetro de vigilância do módulo ART_a $[0, 1]$;
- ρ_b : parâmetro de vigilância do módulo ART_b $[0, 1]$;
- ρ_{ab} : parâmetro de vigilância do módulo ART_{ab} $[0, 1]$;
- ε : incremento do parâmetro ρ_a ;

2ª Etapa - Processo de Treinamento dos dados do vetor padrão de entrada nos módulos: ART_b Euclidiana e ART_a Euclidiana.

Passo 4:

Cálculo das funções T_k^b e T_j^a com o uso da distância Euclidiana.

$$T_k^b = (I_k^b - w_k^b)(I_k^b - w_k^b)^T \text{ e} \quad (12)$$

$$T_j^a = (I_j^a - w_j^a)(I_j^a - w_j^a)^T \quad (13)$$

Passo 5:

O índice K indica a categoria escolhida.

$$T_K^b = \min\{T_k: k = 1, \dots, N\} \quad (14)$$

Passo 6:

O critério de vigilância do módulo ART_b é determinado através da função.

$$\frac{T_K^b}{\max(I_K^b I_K^{b^T}, w_K^b w_K^{b^T})} < \rho_b \quad (15)$$

Passo 7:

Se o critério de vigilância for satisfeito, houve ressonância e passa-se para próximo passo no qual se atualiza o vetor peso w_K^b .

$$w_K^b = \beta(I_K^b) + (1 - \beta)w_K^b \quad (16)$$

Passo 8:

Cálculo do vetor atividade para o número de categorias criadas

$$y_K^b = [y_1^b \ y_2^b \ \dots \ y_N^b]$$

Para:

$$y = \begin{cases} y_k^b = 0, & \text{se } k \neq K \\ y_k^b = 1, & \text{se } k = K \end{cases} \quad (17)$$

Passo 9:

Se o critério de vigilância não for satisfeito, então não houve ressonância e faz-se $T_K^b = 0$ e ocorre o *reset*.

O módulo ART_a possui a mesma estrutura e característica do módulo ART_b Euclidiana usada anteriormente, no qual terá como resposta categoria ativa J . A atualização de w_j^a e vetor atividade y_j^a , será realizado somente depois do módulo Inter-ART, logo após o teste de vigilância. Na ultima etapa deste módulo verifica-se se há o “casamento” da entrada de ART_a com a saída de ART_b .

3ª Etapa - É na finalização deste módulo que se verifica se houve “casamento” entres os Módulo ART_a Euclidiana e Módulo ART_b Euclidiana.

Passo 10:

O critério de vigilância no módulo Inter-ART é verificado por meio da equação (18):

$$|y^b \wedge w_j^{ab}| > \rho_{ab} \quad (18)$$

Passo 10:

Vetor atividade do Módulo ART_a Euclidiana

$$y_j^a = [y_1^a \ y_2^a \ \dots \ y_N^a] \quad (19)$$

para

$$y = \begin{cases} y_j^a = 0, & \text{se } j \neq J \\ y_j^a = 1, & \text{se } j = J \end{cases} \quad (20)$$

Passo 11:

Atualização do vetor de pesos w_j^a

$$w_j^a = \beta(I_j^a) + (1 - \beta)w_j^a \quad (21)$$

Passo 12:

Atualização do vetor de pesos W_{JK}^{ab}

$$W_{JK}^{ab} = [y_1^{ab} \ y_2^{ab} \ \dots \ y_N^{ab}] \quad (22)$$

para

$$y_{jk}^{ab} = \begin{cases} 0, & \text{se } j \neq J; k \neq K \\ 1, & \text{se } j = J; k = K \end{cases} \quad (23)$$

Passo 13:

Se não ocorre ressonância no módulo Inter-ART é acrescentado um decremento no parâmetro de vigilância.

$$\rho_a = \frac{T_J^a}{\max(I_J^a I_J^{aT}, w_J^a w_J^{aT})} - \varepsilon \quad (24)$$


Passo 14:

E volta para a escolha do índice J indicando a categoria escolhida.

$$T_J^a = \min\{T_j: j = 1, \dots, N\} \quad (25)$$

Este procedimento termina quando a categoria escolhida (vencedora) selecionada atenda (satisfaça) o teste de vigilância. Todo o processo da rede neural ARTMAP Euclidiana está descrito no fluxograma da Figura 16.

Figura 16- Fluxograma da Rede ARTMAP Euclidiana.



4 REDE NEURAL ARTMAP EUCLIDIANA APLICADA NA PREVISÃO DE CARGAS ELÉTRICAS

O objetivo desta pesquisa é apresentar uma proposta para obter a previsão de carga elétrica global a curto prazo fundamentada num sistema inteligente. Assim é utilizada uma rede neural artificial baseada na Teoria da Ressonância Adaptativa, mais precisamente a Rede Neural Artificial (RNA) ARTMAP Euclidiana e foi comparada com os resultados obtidos com a rede neural ARTMAP *Fuzzy*, com os mesmos dados de entrada das cargas elétricas utilizado na rede neural ARTMAP Euclidiana. Uma das principais vantagens de utilizar uma rede baseada na Teoria da Ressonância Adaptativa é sua capacidade aprender novos padrões, sem perder o conhecimento adquirido anteriormente, o que confere a este tipo de rede as características de plasticidade e estabilidade.

Uma das motivações de utilizar RNA ARTMAP Euclidiana é de não necessitar de realizar a normalização e complementação nos dados de entrada, reduzindo-a pela metade a dimensão do vetor de entrada, isto representa um processamento mais rápido, ou seja, um baixo custo computacional, em relação à rede ARTMAP *Fuzzy*. Logo, o objetivo principal deste trabalho, favorece a análise do modelo da RNA ARTMAP Euclidiana utilizada para obter informações prognósticas para a previsão de cargas elétricas a curto prazo.

A metodologia proposta, então, consiste em fazer um sistema composto por duas fases. Na primeira fase realiza-se o treinamento, apresentando a rede os dados de entrada referente a cargas e os dados referentes ao período (horas). Após a conclusão desta fase, adquire-se os resultados e os gráficos das previsões na segunda fase, no qual utiliza-se dados de saída no intervalo de 24h.

Todos os dados de cargas de energia coletados serviram como conjunto de padrões de entrada apresentados à rede neural ARTMAP Euclidiana.

O conjunto de entrada para o treinamento da rede contém a hora (h), como dados exógenos, transformados em código binário, sendo representado por um total de 5 bits, carga ($h - 1$) e carga (h) e os dados de saída da rede foi carga ($h + 1$). Logo a representação de vetor de entrada e saída da rede pode ser representado pelas equações (26) E (27), respectivamente (LOPES, 2000):

$$X(h) = [t \ L(h-1) \ L(h)]^T, X \in \mathcal{R}^m \quad (26)$$

$$Y(h) = [L(h+1)]^T, Y \in \mathcal{R}^1 \quad (27)$$

Sendo:

m : dimensão do vetor X ;

$L(h+q)$ = valor da carga q horas anterior à hora corrente h ;

$L(h+1)$ = valor da carga elétrica correspondente à hora subsequente a hora corrente h ;

t = vetor de tempo referente aos dados (mês, dia da semana, feriado, hora, etc), Em nosso trabalho foi utilizado hora (h).

As medições e as coletas de dados das cargas elétricas foram cedidas por uma das Companhias de Energia Elétrica da Espanha, no período de Junho e Julho do ano de 1990, as medidas das cargas utilizadas para previsão a curto prazo foram realizadas no período de um intervalo de 1 hora, sendo 744 dados para o mês de Julho, 1464 dados para os meses de Junho e Julho e 2208 para os meses de Maio, Junho e Julho, sendo previsto o dia 02/08/1990.

Foi utilizado um sistema de janelamento referente ao vetor padrão entrada e padrão de saída desejada para treinamento e diagnóstico da rede. Logo após o treinamento, determina-se a previsão com os dados já treinados anteriormente e com seus pesos atualizados. Para obter os resultados e os gráficos foram utilizados como critério de avaliação o MAPE e Erro Máximo, que permite concluir que a metodologia aplicada garante um bom desempenho na tomada de decisões. A resposta do MAPE deve ser de valor pequeno, isso demonstra que há uma maior precisão na previsão, e é representado pela equação (28):

$$MAPE = \frac{1}{n_e} \sum_{h=1}^{n_e} \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100 \quad (28)$$

no qual:

$L(h)$: valor da carga elétrica real na hora h ;

$\underline{L}(h)$: valor da carga elétrica prevista na hora h ;

n_e : número total de horas para entradas apresentadas na fase de diagnóstico.


O erro máximo é dado pela equação (29):

$$\text{Erro Máximo} = \max \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100 \quad (29)$$

A linguagem de programação utilizada em toda a execução deste trabalho foi o MATLAB (acrônimo de MATrix LABoratory), por oferecer características favoráveis para cálculo de matrizes com grandezas em dimensões, permite a resolução de muitos problemas numéricos em apenas uma fração do tempo, processamento de sinais e construção de gráficos em ambiente fácil de usar.

A Figura 17 mostra resumidamente os processos efetuados pelo *software*, com o uso da rede neural ARTMAP Euclidiana, em que, a primeira fase se faz o treinamento dos dados de entrada e, na segunda fase a realização da previsão de cargas elétricas a curto prazo.

Figura 167- Processo Esquemático para previsão de demanda através da rede neural ARTMAP Euclidiana.



Fonte: Próprio autor.

5 RESULTADOS DAS SIMULAÇÕES

Todas as simulações realizadas pelas redes ARTMAP *Fuzzy* e ARTMAP Euclidiana visam a resolução do problema de previsão de carga a curto prazo (24 à frente).

Os resultados obtidos pela metodologia proposta foram avaliados através do Erro Percentual Médio Absoluto (MAPE) e erro máximo, o que permite analisar e deduzir que a utilização da rede neural ARTMAP Euclidiana garante um bom desempenho e uma boa precisão.

Para prevenir o problema de proliferação de categorias na rede ARTMAP *Fuzzy*, nos módulos ART_a e ART_b, foram normalizados os valores das cargas, conforme a equação (30):

$$carga\ normalizada = \frac{carga}{max(carga)} \quad (30)$$

A Tabela 5 exibe os valores dos parâmetros da rede neural ARTMAP *Fuzzy* utilizados no processamento da fase de treinamento da rede para o mês de Julho (Caso1), para os meses de Junho e Julho (Caso 2) e para os meses de Maio, Junho e Julho (Caso 3).

Tabela 5- Taxa de Parâmetros para Treinamento da ARTMAP *Fuzzy*.

Parâmetros	Caso 1	Caso 2	Caso 3
Vetores Padrão de Entrada	744	1464	2208
Parâmetro de Escolha (α)	0,1	0,1	0,1
Taxa de Treinamento(β)	1	1	1
Parâmetro de Vigilância (ρ_a)	0,95	0,95	0,95
Parâmetro de Vigilância (ρ_b)	1	1	1
Parâmetro de Vigilância – Inter-ART (ρ_{ab})	0,95	0,95	0,95
Incremento (ε)	0,00001	0,00001	0,00001

Fonte: Próprio autor.

O Parâmetro de Vigilância ($\rho = 0,01$) da ARTMAP *Fuzzy* para previsão de carga global tem o mesmo valor para todos os casos, assim também acontece com o Parâmetro de Escolha ($\rho_a = 0,95$).

A Tabela 6 mostra os parâmetros aplicados na rede neural ARTMAP Euclidiana para os Casos 1, 2 e 3, com o mesmo conjunto de dados.

Tabela 6- Taxa de Parâmetros para Treinamento da ARTMAP Euclidiana


Parâmetros	Caso 1	Caso 2	Caso 3
Vetores Padrão de Entrada	744	1464	2208
Taxa de Treinamento(β)	0,999412	0,999412	0,999412
Parâmetro de Vigilância (ρ_a)	0,15	0,15	0,15
Parâmetro de Vigilância (ρ_b)	0,0000001	0,0000001	0,0000001
Parâmetro de Vigilância – Inter-ART (ρ_{ab})	0,15	0,15	0,15
Incremento (ε)	0,0001	0,0001	0,0001

Fonte: Próprio autor.

O Parâmetro de Vigilância ($\rho = 0,1$) da ARTMAP Euclidiana para previsão de carga global tem o mesmo valor para todos os casos.


As Figuras 18, 19 e 20 são resultados obtidos através da rede neural ARTMAP *Fuzzy*, para os Casos 1, 2 e 3, para previsão do dia 02/08/1990.

Figura 178- Resultado da Previsão de carga para o Caso 1- ARTMAP Fuzzy.




Fonte: Próprio autor.

Figura 189- Resultado da Previsão de carga para o Caso 2- ARTMAP Fuzzy.



Fonte: Próprio autor.


Figura 20- Resultado da Previsão de carga para o Caso 3- ARTMAP Fuzzy.



Fonte: Próprio autor.


As Figuras 21, 22 e 23 são resultados obtidos através da rede neural ARTMAP Euclidiana, para os Casos 1, 2 e 3, para previsão do dia 02/08/1990.

Figura 191- Resultado da Previsão de carga para o Caso 1- ARTMAP Euclidiana.




Fonte: Próprio autor.

Figura 202- Resultado da Previsão de carga para o Caso 2 - ARTMAP Euclidiana.



Fonte: Próprio autor.

Figura 213- Resultado da Previsão de carga para o Caso 3 - ARTMAP Euclidiana.



Fonte: Próprio autor.

Através das Figuras 21, 22 e 23, é possível notar que as curvas das cargas elétricas previstas, obtidas pela rede neural ARTMAP Euclidiana se encontram bem próximas da curva real, o que fornece uma confiabilidade na metodologia utilizada.

A Tabela 7 apresenta os resultados dos MAPEs, Erros Máximos e Tempo de processamento da previsão realizados através do treinamento feito nas simulações dos Casos 1, 2 e 3, prevendo o dia 02/08/1990, com o uso da rede neural ARTMAP *Fuzzy*.

Tabela 7- MAPE, Erro Máximo e Tempo de Processamento da Previsão - ARTMAP *Fuzzy*.

Testes	MAPE (%)	Erro Máximo (%)	Tempo (s)
Caso 1	2,12	13,62	0,193
Caso 2	2,91	13,62	0,005
Caso 3	3,27	13,62	0,006

Fonte: Próprio autor.

A Tabela 8 mostra os resultados dos MAPEs, Erros Máximos e Tempo de processamento da previsão realizados através do treinamento feito nas simulações dos Casos 1, 2 e 3, prevendo o dia 02/08/1990, com o uso da rede neural ARTMAP Euclidiana.

Tabela 8- MAPE, Erro Máximo e Tempo de Processamento da Previsão - ARTMAP Euclidiana

Testes	MAPE (%)	Erro Máximo (%)	Tempo (s)
Caso 1	1,33	4,09	0,005
Caso 2	1,32	4,09	0,005
Caso 3	1,57	9,79	0,005

Fonte: Próprio autor.

6 CONSIDERAÇÕES FINAIS E SUGESTÕES PARA TRABALHOS FUTUROS

Este trabalho trata de uma metodologia alternativa para resolver o problema de previsão de carga global a curto prazo realizada através de redes neurais artificiais, mais precisamente, a rede neural ARTMAP Euclidiana.

Foram realizados vários testes visando prever a carga global a curto prazo utilizando dados históricos de uma companhia de energia elétrica espanhola.

Observa-se através dos resultados obtidos que os erros percentuais médios (MAPE) são satisfatórios se comparado com outros trabalhos relacionados a diversas arquiteturas neurais e híbridas. E quando comparado com a utilização de mesmos dados de carga com o uso da rede neural ARTMAP *Fuzzy*, pode-se notar que obteve resultados com maior precisão.

É importante enfatizar que não há trabalhos relacionados a previsão de cargas elétricas baseado na ARTMAP Euclidiana e que a arquitetura mantém as características das redes neurais baseadas na teoria da ressonância adaptativa (plasticidade e estabilidade – capacidade de aprender com a atualização dos pesos, sem perder o conhecimento anteriormente adquirido), portanto, o treinamento é praticamente feito de forma online. Isto, é uma vantagem desta arquitetura e favorece a aplicação desta metodologia visando para fins futuros sua implantação nos sistemas *smart-grids*, visto que esta arquitetura é rápida, precisa e robusta.

6.1 Sugestões para Trabalhos Futuros

A rede neural artificial é uma poderosa ferramenta na aplicação de classificação, análise e previsão para se obter resultados em um ampla área de pesquisa, seja nas engenharias, nas áreas agrárias, saúde ou educação. A essência deste trabalho foi o uso da técnica do método da rede neural ARTMAP Euclidiana para a previsão de cargas elétricas a curto prazo, para trabalhos futuros sugere-se que:

- substituições dos cálculos nas técnicas dos sistemas inteligentes (Sistemas Imunológicos, Lógica Nebulosa, Rede de Kohonen, Perceptron Multicamadas, etc.) pela equação da Distância Euclidiana.
- observa-se que os modelos híbridos obtiveram resultados precisos e eficientes no processo entres as diversas técnicas da família neural artificial, ainda é pouco explorado

essa metodologia com a distância euclidiana, portanto torna-se uma investigação necessária para este tipo estudo.

REFERÊNCIAS

- ABREU, T.; M. PAREDES, M.; ARAÚJO, K. A. M.; LOPES, M. L. M.; LOTUFO, A. D. P. Previsão de cargas elétricas através de um modelo híbrido de regressão com redes neurais artificiais. In: CONGRESSO NACIONAL DE MATEMÁTICA APLICADA E COMPUTACIONAL - CNMAC, 34., 2012. Águas de Lindóia. **Anais...** Uberlândia: SWGE, 2012. p. 1-6.
- ABREU, T. **Previsão de cargas elétricas através de um modelo híbrido de regressão com redes neurais**. 2012. 62 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2012.
- AGGARWAL, R.; SONG, Y. Artificial neural network in power systems. **Power Engineering Journal**, Stevenage, v. 11, n. 3, p. 129-134, 1997.
- ALVES, M. F.; LOTUFO, A. D. P.; LOPES, M. L. M. Seleção de variáveis stepwise aplicadas em redes neurais artificiais para previsão de demanda de cargas elétricas. In: SIMPÓSIO BRASILEIRA DE AUTOMAÇÃO INTELIGENTE - SBAI, 11., 2013, Fortaleza. **Anais...** Fortaleza: UFC, 2013. p. 1-6.
- AMIN, S. M.; WOLLENBERG, B. F. Toward a smart grid: power delivery for the 21st century. **IEEE Power and Energy Magazine**, Piscataway, v. 3, n. 5, p. 1-8, 2005.
- AMORIM, A. J. **Desenvolvimento de uma rede neuro-fuzzy para a previsão da carga**. 98 f. 2015. (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2015.
- AMORIM, D. G. **Redes ART com categorias internas de geometria irregular**. 2006. Tese (Doutorado em Física) - Universidade de Santiago de Compostela, Santiago de Compostela, 2006.
- BAO, J. **Short-term load forecasting based on neural network and moving average**. Iowa: Technical report, Iowa State University, 2002. Disponível em: <<http://citeseerx.ist.psu.edu>>. Acesso em: 17 ago. 2017.
- BARROS A. C. **Deteção e classificação de distúrbios de tensão usando redes neurais artmap euclidiana modificada com treinamento continuado**. 2013. 109 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2013.
- BRASIL. Ministério do Planejamento, Desenvolvimento e Gestão. **Programa de Investimento em Energia Elétrica – PíEE**. Brasília, DF, 2015.
- BOX, G.E.; JENKINS, G.M. **Times series analysis: forecasting and control**. San Francisco: Holden- Day, 1976. 575 p.
- CARPENTER, G. A.; GROSSBERG, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. **Computer Vision, Graphics, and Image Processing**, Maryland Heights, v. 37, p. 54-115, 1987.

CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: supervised real-learning and classification of non-stationary data by a self organizing neural network. **Neural Network**, Kidlington, v. 4, n. 5, p. 565-588, 1991.

CARPENTER, G. A.; GROSSBERG, S.; ROSEN D. B. *Fuzzy ART: fast stable learning and categorization of analog patterns by an adaptive resonance system*. **Neural Network**, Kidlington, v. 4, n. 1, p. 759-771, 1991.

CARPENTER, G. A.; GROSSBERG, S. A self-organizing neural network for supervised learning, recognition and prediction. **IEEE Communications Magazine**, Piscataway, v. 30, n. 9, p. 38-49, 1992.

CENTRO DE GESTÃO E ESTUDOS ESTRATÉGICOS - CGEE. Ministério da Ciência, Tecnologia e Inovação. **Redes elétricas inteligentes: contexto nacional**. Brasília, DF, 2012. (Série de Documentos Técnicos, n. 16).

DING, N.; BENOIT, C.; FOGGIA, G.; BÉSANGER, Y. Neural network-based model design for short-term load forecast in distribution systems. **IEEE Transactions on Power Systems**, Piscataway, v. 31, n. 1, p. 72-81, 2016.

DJUKANOVIC, M.; RUZIC, S.; BABIC, B.; SOBAJIC, D. J.; PAO, Y-H. A neural-net based short term load forecasting using moving window procedure. **Electrical Power & Energy Systems**, London, v. 17, n. 6, p. 391-397, 1995.

DUDEK, G. Neural networks for pattern-based short-term load forecasting: a comparative study. **Neurocomputing**, Libertyville, v. 205, p. 64-74, 2016.

EMPRESA DE PESQUISA ENERGÉTICA – EPE. **Estudos de demanda**. Rio de Janeiro, 2017. (Nota Técnica DEA 001/17).

GARCIA, L. M. D. **Avaliação de Métodos de Previsão de cargas elétricas em curto prazo para aplicação de sistemas de distribuição inteligentes**. 2013. 84 f. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal Santa Maria, Santa Maria, 2013.

GEORGIOPOULOS, M.; FERNLUND, H.; BEBIS, G. and HEILEMAN, G. L. Order of search in fuzzy ART and fuzzy ARTMAP: effect of the choice parameter. **Neural Networks**, Kidlington, v. 9, n. 9, p. 1541-1559, 1996.

GOPAL, S.; WOODCOCK, C. E; STRAHLER, A. H. Fuzzy neural network classification of global land cover from a 1- Degree AVHRR Data Set. **Remote Sensing of Environment**, New York, v. 67, n. 2, p. 230-243, 1999.

GROSSBERG, S. Adaptive pattern recognition and universal encoding ii: feedback, expectation, olfaction, and illusions. **Biological Cybernetics**, Heidelberg, v. 23, p. 187-202, 1976.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Upper Saddle River: Prentice-Hall, 1994.

HORA DA COSTA, S. A. **Os Desafios da implantação da smart grid no modelo de negócios do setor elétrico:** proposta de configuração de uma rede inteligente. 2014, 107 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal da Bahia, Salvador, 2014.

KAGAN, N.; BARIONI, C. C.; JOÃO ROBBA, E. **Introdução aos sistemas de distribuição de energia elétrica.** 2. ed. São Paulo: Edgard Blucher, 2009.

KARTALOPOULOS, S. V. **Understanding neural networks and fuzzy logic:** basic concepts and applications. Piscataway: IEEE Press, 1996.

KEYVAN, S.; SONG, X.; KELLY, M. Nuclear fuel pellet inspection using artificial neural networks. **Journal of Nuclear Materials**, Amsterdam, v. 264, n. 1-2, p. 141-154, 1999.

KROSE, B.; SMAGT, P.V. Na Introduction to Neural Networks. Online Book, University of Amsterdam, Eighth Edition, 1996.

LEONE, M. A. **Previsão de carga de curto prazo usando ensembles de previsores selecionados e evoluídos por algoritmos genéticos.** 2006. 143 f. Dissertação (Mestrado em Engenharia Elétrica)- Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual de Campinas, Campinas, 2006.

LIM, C. P.; HARRISON, R. F. Modified fuzzy ARTMAP approaches bayes optimal classification rates: an empirical demonstration. **Neural Networks**, Kidlington, v. 10, n. 4, p. 755-774, 1997.

LOPES, M. L. M. **Desenvolvimento de um sistema predictor de cargas elétricas via redes neurais.** 2000. 82 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual de São Paulo – UNESP, Ilha Solteira, 2000.

LOPES, M. L. M. **Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica.** 2005. 149 f. Tese (Doutorado em Engenharia Elétrica) Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2005.

MARCHIORI, S. C. **Desenvolvimento de um sistema para análise da estabilidade transitória de sistema de energia elétrica via redes neurais.** 2006. 110 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2006.

MORENO, A. L. **Análise da estabilidade transitória via rede neural ART-ARTMAP Fuzzy euclidiana modificada com treinamento continuado.** 2010. 143 f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista - UNESP Ilha Solteira, 2010.

O'DONOVAN, T. M. **Short term forecasting:** an introduction to the box-jenkins approach. New York: John Wiley & Sons, 1983.

OLIVEIRA, C. M.; LOTUFO A. D. P., LOPES, M. L. M.; SILVEIRA M. C. G. Previsão de cargas elétricas através de uma rede neural híbrida back-ART Fuzzy. In: BRAZILIAN CONGRESS ON COMPUTACIONAL INTELLIGENCE - CBIC, 11., 2013, Porto de Galinhas. **Anas...** [S. l.]: ABRINCOM, 2013. p. 1-6.

SANTOS, A. M. **Uma Análise da aplicação do modelo de rede neural RePART em comitês de classificadores**. 2008. 169 f. Dissertação (Mestrado em Sistemas e Computação) - Universidade Federal do Rio Grande do Norte – UFRN, Natal, 2008.

SANTOS JÚNIOR, C. R. **Teoria da ressonância adaptativa através da linguagem Java para detecção e classificação de e-mails indesejados**. 2013. 77 f. Dissertação (Mestrado em Engenharia Elétrica) Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2013.

SIMPSON, P. K. **Artificial neural systems: foundations, paradigms, applications, and implementations**. New York: Pergamon, 1989.

STORB, B. H.; WAZLAWICK, R. S. **Algumas pinceladas sobre redes neurais artificiais**. Florianópolis: Departamento de Informática e Estatística, Universidade Federal de Santa Catarina - UFSC, 1999.

TEIXEIRA, I.; A ESPOSITO; A. S.; RIVIERA, R. **Redes elétricas inteligentes (Smart Grid): oportunidade para adensamento produtivo e tecnológico local**. Brasília, DF, 2013.

TRUJILLO, J. D. M., **Aplicação de sistemas multiagentes na previsão espacial de demanda elétrica em sistema de distribuição**. 2010. 152 f. Dissertação (Mestrado em Engenharia Elétrica) - Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.

WASSERMAN, P. D. **Neural computing: theory and practice**. New York: Van Nostrand Reinhold, 1989.

WEENINK, D. **Category ART: a variation on adaptive resonance theory neural networks**, Amsterdam: Institute of Phonetic Sciences, University of Amsterdam, 1997.

WIDROW, B.; LEHR, M. A. 30Years of Adaptive Neural Networks: Perceptron, Madaline and Backpropagation, **Proceedings of the IEEE**, New York, v. 78, n. 9, p. 1415-1442, 1990.

WILLIAMSON, J. R. Gaussian ARTMAP: a neural network for fast incremental learning of noisy multidimensional maps. **Neural Networks**, v. 9, n. 5, p. 881-897, 1996.

VUSKOVIC, M.; DU, S. Classification of EMG Patterns with Simplified Fuzzy ARTMAP Networks. In: INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2002, Honolulu. **Proceeding...** New York: IEEE, 2002a. p. 2539-2544.

VUSKOVIC, M.; DU, S. Simplified ARTMAP network based on mahalanobis distance. In: INTERNATIONAL CONFERENCE ON MATHEMATICS AND ENGINEERING TECHNIQUES IN MEDICINE AND BIOLOGICAL SCIENCE, 2002, Las Vegas. **Proceedings...** 2002b. Disponível em: <<http://allserv.ugent.be/~svaelst/courses/distance.pdf>> Acesso em: 15 ago. 2005.

YAAKOB, S. N.; LIM, C. P.; JAIN, L. **Neural comput and applic.** London: Springer – Verlag, 2010.

YANG, Y. et al. Modelling a combined method based on ANFIS and neural network improved by DE algorithm: a case study for short-term electricity demand forecasting. **Applied Soft Computing**, v. 49, p. 663-675, 2016.


ZADEH, L. A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, n. 3, p. 338-353, 1965.

ANEXO A – REDES NEURAIS ARTIFICIAIS

A.1 Modelo de Neurônio Biológico

As principais funções de controle, ordem e equilíbrio de um organismo é realizado através do sistema nervoso, e a célula nervosa que possui a funcionalidade essencial para que este sistema nervoso funcionar de maneira eficiente é chamado de neurônio. Os neurônios biológicos são formados por: dendritos, corpo celular e axônio e se interligam através de sinapses; por eles propagam-se impulsos nervosos e a transmissão dos impulsos elétricos ocorre apenas no sentido do dendrito ao axônio, pode-se entender, que por meio desta conexão, é concedido a inteligência. Na Figura 24 apresenta-se um modelo simplificado de um neurônio biológico e suas partes.

Figura 224- Modelo simplificado de um neurônio biológico e suas partes.




Fonte: (WASSERMAN, 1989)

A.2 Modelo de Neurônio Artificial

Neurologistas e pesquisadores, por volta da década de 40, propuseram o desenvolvimento de uma rede neural artificial que imitasse o comportamento potencial do sistema nervoso com o intuito de solucionar, assimilar novos dilemas (problemas) e de ajustar novas situações. O modelo formulado mais conhecido de um neurônio artificial foi proposto em 1943, pelos cientistas McCulloch (neurofisiologista) e Pitts (matemático), o trabalho contextualizava uma similaridade entre as células vivas e o processo eletrônico que

representava o desempenho de um neurônio natural. A Figura 25 mostra as componentes de um neurônio artificial.


Figura 235- Neurônio Artificial proposto por McCulloch e Pitts.



Fonte: (LOPES, 2005)

O modelo clássico de um neurônio com n entradas e com uma função não-linear denominada função de ativação se apresenta na Figura 26.

Figura 246- Modelo de um neurônio artificial.



Fonte: (LOPES, 2005)


A rede neural artificial equipara-se com o cérebro em duas concepções: o conhecimento é assimilado pela rede, por meio de um procedimento de treinamento ou aprendizado; e a conectividade entres os neurônios relacionados como pesos sinápticos, são adequados (adaptados) para armazenar conhecimento (HAYKIN, 1994).

Um neurônio artificial tem um processamento de treinamento fácil, descreve-se a seguir (Wasserman, 1989):

- Um conjunto de entradas $(x_1, x_2, \dots, x_n)$ é dado ao neurônio artificial que correspondem aos sinais dentro das sinapses de um neurônio natural.
- Cada sinal é multiplicado por um peso $(w_1, w_2, \dots, w_n)$ que está relacionado com a “resistência” de uma única ligação sináptica biológica.
- Logo após são aplicados a um bloco somatório, Σ , em que corresponde ao corpo celular biológico.
- O peso *bias* pondera uma entrada (arbitrária) $x_0 = +1$, no qual controla-se o nível de saída do neurônio. Se a soma ponderada das entradas obtiver um valor maior do que w_0 (*bias*), o neurônio é ativado provocando um pulso na saída. Caso contrário, o neurônio não é ativado. (STORB; WAZLAWICH, 1999; WIDROW; LEHR, 1990).

A ativação de um neurônio artificial é originada através de uma função denominada função de ativação. A Figura 27 apresenta alguns modelos de funções de ativação.

Figura 257- Exemplos de funções de ativação: Linear, Relé e Sigmoidal.



FONTE: (MARCHIORI, 2006)


Sendo: k = constante qualquer; e λ inclinação da função sigmoidal.

A.3 Características Gerais da Rede Neural

As arquiteturas neurais são compostas por camadas com unidades que podem estar conectadas a unidades de camadas posteriores. As camadas estão classificadas em três classes: a camada de entrada (entrada dos padrões), a camada intermediária (processamento da rede) e

a camada de saída (resultado final), (HAYKIN, 1994). A Figura 28, demonstra as camadas de forma geral.

Figura 268- Modelo em camadas da rede neural artificial.



Fonte: (LOPES, 2005)

A.4 Estrutura da Rede Neural

A rede neural pode ser estruturada em duas classificações, conforme a propagação das informações (dados) (Krose; Smagt,1996):

- **Redes Neurais Recorrentes ou *feedback*:** A rede possui laços de realimentação, ou seja, contém conexões de saída de uma determinada camada para a entrada da mesma ou para a entrada de uma camada anterior. Por elas são desenvolvidas uma memória nos neurônios internos.
- **Redes Neurais Não Recorrentes ou *feedforward*:** por estar estruturalmente em camadas, essa rede recebe somente sinais de camadas anteriores, ou seja, elas não contém os laços de realimentação. Não possuem memória sua saída é determinada somente pela função de entrada e dos valores dos pesos.

A.5 Treinamento da Rede Neural

A característica mais importante de uma rede neural é a capacidade de aprender e com isso adquirir habilidade na execução de sua tarefa. Em geral, a maioria das técnicas das redes neurais artificiais possuem algum tipo de regra de treinamento.

É no processo de treinamento da rede que será realizado a adaptação ou ajuste de seus pesos, de acordo com o conjunto dos vetores padrões de entrada apresentado à rede. A diversidade de modelos de algoritmos para treinamento da rede é ampla, variando entre si para cada tipo de rede neural. Basicamente, pode-se classificar o treinamento em:

- **Treinamento Supervisionado:** neste treinamento é feito a combinação do conjunto de entrada e saída desejada. A rede necessita do auxílio de um “professor” na fase do aprendizado que avaliará e informará, na forma de mapeamento à rede seu desempenho, o algoritmo de aprendizagem *backpropagation*, a rede ARTMAP e a ARTMAP *Fuzzy* são exemplos de rede que possuem o treinamento supervisionado. (Krose & Smagt, 1996; Wasserman, 1989).
- **Treinamento Não-Supervisionado:** este modelo é autônomo, ou seja, não necessita do auxílio do “professor”, utilizando o treinamento somente com o conjunto de vetor de entrada. São exemplos: as redes Hopfield, Kohonen e ART (clássica e *Fuzzy*). (KROSE; SMAGT, 1996; WASSERMAN, 1989).
- **Treinamento Híbrido:** o treinamento é determinado através de uma combinação feita pelo treinamento supervisionado e o não-supervisionado.

Uma das principais características das redes neurais é ela obter a importância dos resultados de maneira adequada a diversas situações baseadas em um aprendizado através de experiências passadas (treinamento). Algumas habilidades singulares das redes são apresentadas em apenas em suas estruturas, como:

- **Aprendizado e generalização:** possui a potencialidade para garantir resultados significativos através da aprendizagem e do armazenamento de conhecimento.

- **Processamento paralelo:** possibilita que as funções mais complexas sejam resolvidas com maior rapidez.
- **Não Linearidade:** elas compõem uma alternativa analítica das técnicas padronizadas que as limitam, muitas vezes por suposições restritas de normalidade, linearidade, independência de variável, etc.
- **Robustez:** é capaz de obter seu processamento com dados com ruídos ou dados incompletos de maneira eficiente.
- **Flexibilidade:** as redes neurais artificiais permite uma vasta aplicação em qualquer que seja a área de conhecimentos.

Atualmente, há uma variedade de pesquisadores em busca de inovação nas diversas arquiteturas das redes neurais e técnicas de aprendizado ajustando em aplicações específicas, como por exemplo as previsões de cargas, planejamento, controle, intensificação de sistemas, proteção de sistema de potência, avaliação de segurança, diagnóstico de falhas, etc., (AGGARWAL; SONG, 1997).

É crescente a utilização das redes neurais também em outras áreas de estudos tais como, medicina, engenharia, biologia, entre outras áreas. A potencialidade da rede neural artificial em sua aprendizagem e generalização propicia nas aplicações do tipo: reconhecimento de padrões, processamento de imagens, regressão e previsão, diagnóstico, controle, otimização e filtragem de dados.