

**UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA
CAMPUS DE ILHA SOLTEIRA**

VICTOR SUZUKI SOUTO

**PREVISÃO DE CURVA DE CARGA ELÉTRICA USANDO A REDE
NEURAL ARTMAP FUZZY**

Ilha Solteira
2024

VICTOR SUZUKI SOUTO

**PREVISÃO DE CURVA DE CARGA ELÉTRICA USANDO A REDE
NEURAL ARTMAP FUZZY**

Trabalho de conclusão de curso apresentado
como requisito parcial para obtenção do título
de Bacharel em Engenharia Elétrica
Universidade Estadual Paulista "Júlio de
Mesquita Filho".

Orientadora:

Prof^a. Dr^a. Mara Lúcia Martins Lopes

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

S728p Souto, Victor Suzuki.
Previsão de curva de carga elétrica usando a rede neural Artmap Fuzzy /
Victor Suzuki Souto. -- Ilha Solteira: [s.n.], 2024
46 f. : il.

Trabalho de conclusão de curso (Graduação em Engenharia Elétrica) -
Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira, 2024

Orientador: Mara Lúcia Martins Lopes

Inclui bibliografia

1. Previsão de carga. 2. Redes neurais artificiais. 3. Teoria da ressonância adaptativa. 4. Sistemas elétricos de potência.


ATA DE DEFESA DE TRABALHO DE GRADUAÇÃO

Aos quatro do mês de janeiro do ano de dois mil e vinte e quatro, o discente *Victor Suzuki Souto*, matriculado sob o nº 152053204, tendo como banca examinadora a sua orientadora, a Prof^a. Dr^a. *Mara Lúcia Martins Lopes*, a Pós-doutorando *Carlos Roberto dos Santos Júnior* e o Doutorando *Reginaldo José da Silva*, apresentou o Trabalho de Graduação do Curso de Engenharia Elétrica (FEIS-UNESP) intitulado "**Previsão de Curva de Carga Elétrica Usando a Rede Neural ARTMAP Fuzzy**" obtendo a nota 7,0 (sete) e conceito APROVADO.




Victor Suzuki Souto

- discente -



Prof^a. Dr^a. Mara Lúcia Martins Lopes

- orientadora -



Pós-doutorando Carlos Roberto dos Santos Júnior

- Membro da Banca -



Documento assinado digitalmente

REGINALDO JOSE DA SILVA

Data: 04/01/2024 10:40:23-0300

Verifique em <https://validar.iti.gov.br>

Doutorando Reginaldo José da Silva

- Membro da Banca -

RESUMO

A projeção da demanda de energia elétrica representa uma tarefa de extrema relevância, desempenhando um papel crucial na gestão dos sistemas elétricos de potência. Diversas técnicas podem ser aplicadas para previsão de carga, dentre elas, as redes neurais artificiais, que são sistemas de inteligência computacional não lineares inspirados nas redes neurais do cérebro humano. Elas são capazes de reproduzir diversas características humanas, como por exemplo: fazer associações, abstrair informações e aprender com informações que lhes são “ensinadas”. Dessa forma, este trabalho se propõe a explorar e analisar a aplicação da Rede Neural ARTMAP *Fuzzy* na previsão de curvas de carga elétrica em um cenário real. Para este estudo não foram fornecidos os dados de temperatura, umidade ou quaisquer outros fenômenos que pudessem impactar na previsão da carga. Diferentes intervalos de treinamento e períodos de previsão de curto prazo foram analisados a fim de avaliar o desempenho da metodologia proposta.

Palavras-chave: Previsão de Carga, Redes Neurais Artificiais, Teoria da Ressonância Adaptativa, Sistemas Elétricos de Potência.

ABSTRACT

Projecting electricity demand is an extremely important task and plays a crucial role in the management of power systems. Various techniques can be applied to load forecasting, including artificial neural networks, which are non-linear computer intelligence systems inspired by the neural networks of the human brain. They are capable of reproducing various human characteristics, such as making associations, abstracting information and learning from information that is "taught" to them. In this way, this work aims to explore and analyze the application of the ARTMAP Fuzzy Neural Network in predicting electrical load curves in a real scenario. For this study, no data was provided on temperature, humidity or any other phenomena that could have an impact on load forecasting. Different training intervals and short-term forecast periods were analyzed in order to assess the performance of the proposed methodology.

Keywords: Load Forecast, Artificial Neural Networks, Adaptive Resonance Theory, Electrical Power Systems.

LISTA DE FIGURAS

Figura 1	- Carga total do sistema elétrico brasileiro, distribuição por fonte...	13
Figura 2	- Representação do SIN -2017.....	14
Figura 3	- Geração e carga por região.....	15
Figura 4	- Geração, transmissão e distribuição da energia.....	16
Figura 5	- Matriz elétrica nacional, 2022.....	17
Figura 6	- Estruturas de um neurônio biológico.....	19
Figura 7	- Modelo de neurônio – <i>McCulloch-Pitts</i>	20
Figura 8	- Modelo de rede neural artificial.....	21
Figura 9	- Tela inicial <i>MatLab</i>	25
Figura 10	- Previsão de carga para o dia 10/10/2008 – P1.....	30
Figura 11	- Previsão de carga para os dias 9/10/2008 e 10/10/2008 – P1.....	31
Figura 12	- Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P1.....	31
Figura 13	- Previsão de carga para o dia 10/10/2008 – P2.....	33
Figura 14	- Previsão de carga para os dias 9/10/2008 e 10/10/2008 – P2.....	33
Figura 15	- Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P2.....	34
Figura 16	- Previsão de carga para o dia 10/10/2008 – P3.....	35
Figura 17	- Previsão de carga para os dias 9/10/2008 e 10/10/2008 – P3.....	36
Figura 18	- Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P3.....	36
Figura 19	- Previsão de carga para o dia 10/10/2008 – P4.....	38
Figura 20	- Previsão de carga para os dias 9/10/2008 e 10/10/2008 – P4.....	38
Figura 21	- Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P4.....	39

LISTA DE TABELAS

Tabela 1	- Parâmetros utilizados na rede neural ARTMAP <i>Fuzzy</i> – P1.....	30
Tabela 2	- Análise comparativa da previsão de carga – P1.....	32
Tabela 3	- Parâmetros utilizados na rede neural ARTMAP <i>Fuzzy</i> – P2.....	32
Tabela 4	- Análise comparativa da previsão de carga – P2.....	34
Tabela 5	- Parâmetros utilizados na rede neural ARTMAP <i>Fuzzy</i> – P3.....	35
Tabela 6	- Análise comparativa da previsão de carga – P3.....	37
Tabela 7	- Parâmetros utilizados na rede neural ARTMAP <i>Fuzzy</i> – P4.....	38
Tabela 8	- Análise comparativa da previsão de carga – P4.....	39

LISTA DE SIGLAS E ABREVIATURAS

ONS	Operador Nacional do Sistema Elétrico
mW	Megawatts
EPE	Empresa de Pesquisa Energética
kW	Kilowatt
kWh	Kilowatt-hora
RNA	Rede Neural Artificial
ART	Adaptative Resonance Theory
LSTM	Long Short-Term Memory
UNESP	Universidade Estadual Paulista
FEIS	Faculdade de Engenharia de Ilha Solteira
RMSE	Root Mean Squared Error

SUMÁRIO

1. Introdução	10
2. Fundamentação Teórica	13
2.1. Carga Elétrica	13
2.1.1. Geração de Energia.....	13
2.1.2. Transmissão de Energia	14
2.1.3. Distribuição de Energia.....	16
2.1.4. Consumo de Energia	16
2.1.5. Sistemas de Energia Elétrica	17
2.1.6. A Previsão de Carga.....	17
2.1.7. Outros Fatores Relevantes na Previsão de Carga.....	17
2.1.8. Horizontes de Previsão.....	18
2.2. Redes Neurais Artificiais	19
2.2.1. Modelo Biológico	19
2.2.2. Neurônio Artificial de <i>McCulloch-Pitts</i>	20
2.2.3. Arquitetura das Redes Neurais Artificiais.....	21
2.2.4. Treinamento de Redes Neurais	22
2.2.5. Tipos de Treinamento	22
2.3. Rede Neural ART	22
2.3.1. Tipos de Rede ART	23
2.4. <i>Matlab</i>	24
3. Metodologia.....	27
3.1. <i>Script</i> do Programa	27
3.2. Erro de Previsão	27
3.3. Fatores Atípicos	28
4. Resultados	29
4.1. Padrão de Entrada Referente à Base de 31 dias	29
4.2. Padrão de Entrada Referente à Base de 62 dias	32
4.3. Padrão de Entrada Referente à Base de 93 dias	34
4.4. Padrão de Entrada Referente à Base de 184 dias	37
5. Análise dos Resultados	40
6. Conclusão	41
Referências Bibliográficas	42

1. INTRODUÇÃO

Prever o consumo de energia elétrica é um dos desafios mais críticos e complexos enfrentados pelo setor de energia elétrica na atualidade. A demanda por eletricidade varia ao longo do tempo, sujeita a inúmeras influências como mudanças climáticas, comportamento do consumidor e outros eventos imprevisíveis. A capacidade de prever com precisão essas variações é fundamental para garantir a estabilidade da rede elétrica, otimizar o planejamento de recursos e promover a eficiência energética [1]. Nesse contexto, a Rede Neural ARTMAP *Fuzzy* vem como uma ferramenta para abordar esse desafio complexo.

A previsão da curva de carga desempenha um papel crucial em uma série de aplicações, que variam desde o dimensionamento adequado de geração e transmissão de energia até o gerenciamento de picos de demanda e a integração eficiente de fontes de energia renovável (como a energia dos painéis solares que vem sendo bastante difundida atualmente, seja nos consumos residenciais ou comerciais). Com a crescente ênfase na sustentabilidade e na redução das emissões de carbono, a previsão precisa da carga elétrica tornou-se ainda mais importante para a gestão inteligente da eletricidade [2].

Existem estudos importantes para os sistemas de energia elétrica como por exemplo, planejamento da expansão, fluxo de potência, operação econômica, análise e controle de segurança de Sistemas de Energia Elétrica que efetivamente dependem do conhecimento futuro do comportamento do perfil da carga do sistema [3, 4], ou seja, da previsão de informações futuras de uma série temporal por extração do conhecimento de valores passados. Por conseguinte, a previsão das cargas elétricas constitui-se num item muito importante de investigação.

A previsão de carga se baseia no estudo futuro do comportamento de séries que variam ao longo do tempo, e que é fundamental em análises e tomada de decisão. Ela se enquadra em um dos principais temas de pesquisa e desenvolvimento na área de sistemas de potência [5].

Até a década de 80 os modelos de previsão desenvolvidos eram baseados em métodos estatísticos e estocásticos [3, 4] e os métodos de abordagem utilizados são baseados nas séries temporais de consumo. Dentre eles destacam-se: técnica de regressão linear simples ou múltipla, alisamento exponencial, estimação de estado,

filtro de Kalman, ARIMA (*AutoRegressive Integrated Moving Average*) de Box & Jenkins [3 - 5].

Tais métodos se baseiam em uma modelagem da carga para que seja realizada a predição. Nesta modelagem são analisados vários fatores que podem influenciar o comportamento e perfil da carga. Entre estes fatores destacam-se: as condições meteorológicas (nebulosidade, velocidade do vento, variações bruscas de temperatura etc.) e fatores diversos como efeito de dias atípicos (feriados, greves etc.). Tais fatores tentam representar da melhor maneira o comportamento da carga para então servir como entrada no algoritmo de previsão escolhido [3 - 5].

Existem também os métodos baseados em sistemas inteligentes e estes têm se mostrado promissores, principalmente, para o caso dos dias especiais. Com o surgimento das redes neurais e popularização a partir da década de 80 a maioria dos modelos propostos para previsão de carga utilizaram redes neurais artificiais na sua modelagem [2, 6-16].

Inspiradas em sistemas biológicos relacionados com o neurônio do cérebro humano, as redes neurais artificiais são capazes de aprender e generalizar com a experiência de dados passados [17-21]. As redes neurais não necessitam de informações sobre a modelagem do sistema a ser previsto, pois tem a capacidade de aprender a partir de exemplos e desta forma generalizar. Tais características atraem pesquisadores de diversas áreas (engenharia, música, biologia, medicina, etc.), e atuam na resolução de vários problemas tais como: reconhecimento de padrão, análise, identificação, controle, otimização, análise de sensibilidade [17].

As Redes Neurais Artificiais (RNAs) são concepções em *hardware* e/ou *software* baseadas no mecanismo de funcionamento do cérebro [21]. A grande vantagem do uso desta tecnologia refere-se a modelagem de problemas complexos, a qual é determinada através do mecanismo de treinamento ou aprendizado supervisionado (estímulo entrada/saída) ou não-supervisionado (baseado somente em estímulos de entrada), ou seja, uma vez concluído o treinamento, a rede armazena, em sua estrutura, o modelo do problema abordado, a princípio, não importando quanto complexo ele é [17].

Uma rede neural que vem sendo bastante utilizada na literatura é a rede neural ARTMAP *Fuzzy* que é uma arquitetura baseada nas redes neurais da família ART. A família ART é baseada na Teoria da Ressonância Adaptativa, *Adaptive Resonance Theory* (ART) [22, 23], e um dos principais atributos das redes ART é a capacidade

de contornar o dilema estabilidade-plasticidade, tal designação compreende algumas questões do sistema: como ser adaptável diante as novas informações (novos dados) e conseguir manter sua estabilidade, ou seja, quando apresentada informações descartáveis; como manter o conhecimento adquirido e armazenar novos dados. Esse tipo de estrutura pode, de forma consciente, fazer a designação de padrões, pelos dados de entrada, conduzidos na similaridade entre os padrões apresentados [24, 25].

As redes neurais ARTMAP *Fuzzy* representam uma evolução nas técnicas de previsão de carga elétrica, incorporando elementos da lógica *Fuzzy* [26]. Essa combinação de abordagens permite a modelagem de sistemas elétricos complexos, lidando de maneira mais eficaz com informações imprecisas ou incertas (o que é comum na previsão de carga elétrica). A capacidade de integrar a incerteza inerente aos dados de carga elétrica torna a Rede Neural ARTMAP *Fuzzy* uma abordagem interessante para o planejamento de energia e para operadores de redes elétricas.

Este trabalho se propõe a explorar e analisar a aplicação da Rede Neural ARTMAP *Fuzzy* na previsão de curvas de carga elétrica. Serão abordados os fundamentos teóricos que sustentam essa abordagem.

Além disso, este trabalho buscará avaliar o desempenho da Rede Neural ARTMAP *Fuzzy* em um cenário real com a base de dados de energia elétrica fornecida por uma concessionária da Nova Zelândia [27]. Os dados representam carga elétrica de $\frac{1}{2}$ em $\frac{1}{2}$ hora de 9 subestações da Nova Zelândia e para efetuar a previsão de carga global foi calculado a carga consumida total em todas as subestações.

2. FUNDAMENTAÇÃO TEÓRICA

Nesta etapa serão abordados os principais fundamentos teóricos que embasam este trabalho, começando pelo entendimento da estrutura do sistema elétrico e seguindo com as redes neurais.

2.1 CARGA ELÉTRICA


Os sistemas de energia elétrica são estruturas complexas que envolvem a geração, transmissão, distribuição e consumo de energia elétrica. A carga elétrica representa a demanda por energia elétrica pelos consumidores finais [28].

Cada componente do sistema de energia elétrica em relação à carga elétrica pode ser descrito da seguinte forma:

2.1.1 GERAÇÃO DE ENERGIA

A geração de energia elétrica envolve a conversão de diferentes fontes de energia (como carvão, gás natural, energia hidrelétrica, solar, eólica, nuclear, entre outras) em energia elétrica. As usinas de geração produzem eletricidade que é fornecida à rede elétrica. A quantidade de energia gerada é determinada com base na previsão de carga elétrica, a fim de atender à demanda dos consumidores [28].

Figura 1 - Carga total do sistema elétrico brasileiro, distribuição por fonte.



Fonte: Adaptado de [29].


A geração de energia elétrica brasileira se concentra na fonte hidrelétrica, mas também possui outras fontes [30] como citado na Figura 1.

Na Figura 1 é possível observar que cerca de 70% da energia elétrica gerada no Brasil provém das hidrelétricas. Isso se deve à grande quantidade de rios e lagos presentes no território, que aliados ao relevo adequado propiciam as circunstâncias ideais para a utilização de usinas hidrelétricas.

2.1.2 Transmissão de Energia

A transmissão de energia elétrica é responsável por transportar a eletricidade gerada em grandes usinas para longas distâncias, utilizando linhas de transmissão de alta tensão.

Figura 2 - Representação do SIN -2017.




Fonte: [31].

Nesse estágio, a carga elétrica é representada pela quantidade de eletricidade transmitida, expressa em megawatts (MW). A transmissão é uma etapa crítica para garantir que a energia elétrica chegue de forma eficiente e confiável às áreas de consumo.

Na Figura 2 é apresentado o diagrama do SIN (sistema interligado nacional), que representa as linhas de transmissão existentes em território brasileiro [31]. Observa-se na Figura 2 uma maior quantidade de linhas de transmissão nas regiões Sul e Sudeste, isso se deve ao grande consumo residencial, comercial e industrial dessas áreas. Como o sistema é interligado, ele facilita a transmissão de energia entre locais onde tem-se maior geração e menor consumo, como mostra a Figura 3.

Figura 3 - Geração e carga por região.



Fonte: [32].

A Figura 3 mostra como está a transmissão de energia em tempo real no Brasil. Pode-se observar que a região Sudeste/Centro-Oeste possui uma carga elétrica maior do que a geração da região e depende das outras regiões para suprir suas necessidades.

2.1.3 Distribuição de Energia


A distribuição de energia elétrica é a etapa final antes do consumo pelos usuários finais. Nesse estágio, a eletricidade é reduzida para tensões menores e distribuída por meio de redes de distribuição para residências, comércios, indústrias e outras instalações, seja por empresas públicas ou privadas [28].

A carga elétrica aqui se refere à demanda específica de energia elétrica de cada consumidor, expressa em quilowatts (kW) ou quilowatt-hora (kWh). Assim como na transmissão, a etapa de distribuição é composta por cabos, por transformadores e por equipamentos de metrologia, de controle e de proteção das redes elétricas. Os sistemas de distribuição e de transmissão se diferenciam bastante quanto às suas ramificações, visto que, de maneira geral, o Sistema de Transmissão leva energia às regiões e o Sistema de Distribuição se ramifica para chegar a cada empresa, comércio e residência [28].

2.1.4 Consumo de Energia

Os consumidores finais são aqueles que utilizam a energia elétrica para diversas finalidades, como iluminação, aquecimento, refrigeração, operação de equipamentos eletrônicos, entre outros. A carga elétrica em relação ao consumo é medida em unidades de potência (kW) ou energia (kWh). A demanda de carga elétrica varia ao longo do dia, devido a fatores como horários de pico, sazonalidade e mudanças de hábitos de consumo [28]. Para que a energia chegue até o consumidor, são necessárias as três etapas citadas nas seções 2.1.1, 2.1.2 e 2.1.3, como exemplificado na Figura 4.

Figura 4 - Geração, transmissão e distribuição da energia.




Fonte: adaptado de [33].

2.1.5 Sistemas de energia elétrica

Os sistemas de energia elétrica são projetados e operados levando em consideração a carga elétrica para garantir o fornecimento confiável de energia aos consumidores. Para gerenciar a carga elétrica de forma eficiente, as empresas de energia realizam estudos de previsão de carga, implementam estratégias de controle de demanda, otimizam a operação do sistema elétrico e buscam formas de diversificar e equilibrar a matriz energética, sendo a principal fonte do território nacional é a hidráulica (hidrelétricas) [28].

Figura 5 - Matriz elétrica nacional, 2022.



Fonte: [34].

A Figura 5 representa a diversificação das matrizes elétricas do Brasil.

2.1.6 A previsão de carga

Área de estudo que visa estimar a demanda futura de energia elétrica com base em padrões históricos e fatores influentes. Essa previsão é fundamental para o planejamento e operação eficiente do sistema de geração, transmissão e distribuição de energia elétrica [35].

2.1.7 Outros fatores relevantes na previsão de carga

Além dos dados históricos de carga elétrica, outros fatores podem ser considerados na previsão, como informações meteorológicas, dados econômicos, sazonalidade, dias úteis, finais de semana, feriados, entre outros. Esses fatores podem influenciar significativamente o consumo de energia elétrica [1].

A previsão de carga elétrica desempenha um papel crucial na gestão do sistema elétrico, permitindo que as empresas de energia tomem decisões informadas sobre a geração de energia, planejamento da capacidade, controle de demanda e otimização dos recursos disponíveis. Uma previsão ajuda a evitar a sobrecarga ou subutilização do sistema elétrico, reduzindo custos operacionais e melhorando a confiabilidade do fornecimento de energia [1].

Existem várias abordagens para realizar a previsão de carga elétrica, sendo as mais comuns [3-16]:

- a) **Métodos Estatísticos:** Esses métodos utilizam técnicas estatísticas para analisar os dados históricos de carga elétrica e identificar padrões e tendências. Entre os métodos estatísticos utilizados estão a análise de regressão, séries temporais e modelos de média móvel.
- b) **Métodos de Aprendizado de Máquina:** Com o avanço da tecnologia, os métodos de aprendizado de máquina têm sido cada vez mais aplicados na previsão de carga elétrica. Algoritmos como regressão linear, redes neurais artificiais e árvores de decisão podem ser utilizados para identificar padrões complexos e fazer previsões mais precisas.
- c) **Métodos Híbridos:** Esses métodos combinam abordagens estatísticas e de aprendizado de máquina para obter previsões mais robustas. Por exemplo, pode-se usar um modelo estatístico como base e, em seguida, aplicar técnicas de aprendizado de máquina para refinar e ajustar as previsões.

É importante ressaltar que a previsão de carga elétrica não é uma tarefa simples, pois envolve a consideração de múltiplos fatores e a incerteza inerente às condições futuras. No entanto, com o avanço das técnicas de previsão e o uso de tecnologias avançadas, as previsões de carga elétrica estão se tornando cada vez mais precisas e confiáveis.

2.1.8 Horizontes de Previsão

A previsão de carga elétrica pode ser feita para diferentes horizontes (intervalos de tempo) [39]. Dito isso, é importante entender como são divididos os intervalos de previsão e quais suas finalidades e melhores aplicações:

- **Curtíssimo prazo:** Intervalos inferiores a uma hora. Por apresentar o perfil instantâneo da carga, é mais bem aplicado em situações como realocação de unidades geradoras, de folgas de potência e operações *online*;
- **Curto prazo:** Intervalos de até uma semana. Bem utilizado em previsões operacionais como a alocação e otimização de geradores visando um menor impacto econômico;
- **Médio prazo:** Intervalos mensais. Pode ser aplicado no planejamento de programas de manutenção e de suprimentos de combustível, visando segurança e economia;
- **Longo prazo:** Intervalos anuais. Utilizado em operações de planejamento de sistemas de potência e estudos de aumento de capacidade de atendimento.


2.2 REDES NEURAIS ARTIFICIAIS

De maneira geral, Redes Neurais Artificiais (RNA) são modelos computacionais inspirados no sistema nervoso central. Para compreender melhor as redes neurais artificiais, é necessário primeiramente entender os elementos funcionais no qual elas se baseiam.

2.2.1 Modelo Biológico

Os neurônios são células nervosas altamente estimuláveis que processam e transmitem informações por meio de sinais eletroquímicos. Na Figura 6 tem-se a representação de um neurônio [17].

Figura 6 - Estrutura de um neurônio biológico.



Fonte: [36].

Dentre as estruturas citadas na Figura 6, destacam-se:

- **Corpo Celular:** Local onde contém o núcleo, responsável por receber e transmitir os impulsos nervosos.
- **Dendritos:** Prolongamentos finos e ramificados. Conduzem os estímulos de outros neurônios ou de células sensoriais.
- **Axônio:** Prolongamento do corpo celular.


Baseando-se nos neurônios biológicos e em sua funcionalidade, foram desenvolvidos os neurônios artificiais.

2.2.2 Neurônio artificial de McCulloch-Pitts

O primeiro neurônio artificial veio da concepção dos americanos Warren McCulloch e Walter Pitts, que em 1943 apresentaram o primeiro modelo computacional de um neurônio, com o intuito de simular processos cognitivos humanos. Uma de suas características é a utilização da lógica booleana (lógica binária) [17].

A partir desse modelo foi possível estabelecer uma conexão entre o funcionamento do neurônio e a lógica proposicional. Na Figura 7 pode-se observar o primeiro modelo proposto.

Figura 7 - Modelo do neurônio de *McCulloch-Pitts*.



Fonte: [37].

Sendo:

g : soma ponderada das entradas x_i ;


f : função que ativa a saída linear g .

2.2.3 Arquiteturas das Redes Neurais Artificiais

As redes neurais artificiais são modelos computacionais inspirados no funcionamento do cérebro humano. Eles são compostos por um conjunto de unidades interconectadas de neurônios artificiais, que processam e transmitem informações através de conexões ponderadas. Assim como os neurônios biológicos, os artificiais também podem receber diversas informações e sinais de entrada, mas apresentam um único valor de saída [21].

A Figura 8 ilustra uma representação de uma rede neural artificial multicamadas na qual pode-se observar as camadas de entrada, intermediária e escondida. A estrutura possui pesos entre as conexões de neurônios que influenciam na decisão de disparo que servem para controlar os estímulos [38].

Figura 8 - Modelo de rede neural artificial.



Fonte: [38].

A estrutura da rede é utilizada para diferenciar e classificar entre os dois tipos, são elas [38]:

- a) **Redes Neurais Recorrentes:** Possui conexões entre a saída de uma camada com a entrada de outra (seja da mesma camada ou de anteriores);

- b) **Redes Neurais Não recorrentes:** A estrutura da rede é disposta em camadas de neurônios, sendo cada camada recebe sinais somente das camadas anteriores.

De forma geral, o que as diferencia é a existência ou não de realimentação entre as camadas.

2.2.4 Treinamento das Redes Neurais Artificiais

Uma das habilidades dessas estruturas é a capacidade de abstrair e representar o conhecimento de um conjunto de dados obtidos a partir da observação de uma determinada tarefa [38].

O treinamento consiste em analisar um banco de dados e utilizar essas informações de forma a ajustar a aplicação dos pesos de maneira mais eficaz. Existem diversos algoritmos de treinamento, a principal diferença entre eles é a maneira como os pesos são alterados [38].

2.2.5 Tipos de Treinamento

Os treinamentos também se dividem em dois grupos distintos, são eles [38]:

- a) **Treinamento Supervisionado:** Considera-se o conjunto de padrões de entrada e ajustam-se os pesos da rede, para que dessa forma se consiga uma saída desejada. Um dos algoritmos mais difundidos desse tipo de treinamento é o retro propagação;
- b) **Treinamento Não-Supervisionado:** Nesse tipo de treinamento considera-se apenas o ajuste de pesos nos padrões de entrada.

2.3 REDE NEURAL ART

As redes neurais da família ART (*Adaptive Resonance Theory*) possuem uma arquitetura em três camadas que a possibilita manter seu conhecimento mesmo diante de novas informações. Esses modelos de rede neural artificial foram propostos por Carpenter e Grossberg após décadas de estudo na área de inteligência artificial e funcionamento do cérebro humano [22].

As redes ART foram projetadas para resolver problemas de aprendizado não supervisionado, especialmente em situações no qual os padrões de entrada são desconhecidos ou mal definidos. A principal característica que distingue as redes ART de outras redes neurais é a capacidade de adaptação dinâmica à entrada, permitindo que elas ajustem sua resposta de acordo com a inserção de novos dados [38].

A ideia central dessas redes é o conceito de "Ressonância Adaptativa". Isso significa que a rede pode ajustar seu nível de resposta com base na similaridade entre a entrada atual e os padrões de memória armazenados. Se a entrada for suficientemente semelhante a um padrão de memória existente, a rede "ressoará" e ativará o neurônio correspondente. Caso contrário, a rede pode criar um novo padrão de memória para a nova entrada, permitindo assim a aprendizagem contínua e a adaptação a novos dados [22].

A rede neural ARTMAP (*Adaptive Resonance Theory MAP*) é um tipo de rede neural que combina elementos da teoria da ressonância adaptativa com mapas auto-organizáveis. Proposto por [3], é especialmente adequado para tarefas de aprendizado supervisionado.

2.3.1 Tipos de Rede ART

Existem diversas variações de redes baseadas na teoria da ressonância adaptativa, desenvolvidas para lidar com diferentes tipos de problemas e dados. Algumas das variações populares incluem:

- **ART1:** É uma das primeiras variações da família ART e é adequado para classificação binária de padrões. Ele utiliza uma estratégia de aprendizado não supervisionado baseada em categorização hierárquica [22];
- **ART2:** É uma extensão do ART1 que lida com padrões de entrada binários e contínuos. Ele permite a classificação de padrões em múltiplas categorias e incorpora aprendizado não supervisionado [40];
- **ARTMAP:** Esta estrutura da família ART possui treinamento supervisionado sendo composta por dois módulos ART (entrada e saída). Ela permite a aprendizagem e classificação contínuas de padrões em fluxos de dados dinâmicos [41];

- **ARTMAP Fuzzy:** Esta variação do ARTMAP e, portanto, possui também treinamento supervisionado como a rede ARTMAP, mas todos seus cálculos fundamentam-se na lógica *fuzzy* (Carpenter et al., 1992) [25].

As redes neurais podem ser usadas em diversas áreas, como previsão de energia elétrica, demanda de tráfego em redes de comunicação e previsão de demanda em sistemas logísticos. A rede neural ARTMAP *Fuzzy*, em particular, pode ser aplicado nesse contexto para realizar previsões de carga.

No caso da previsão de carga de energia elétrica, por exemplo, uma rede neural ARTMAP *Fuzzy* pode ser treinada com dados históricos de consumo de energia, levando em consideração fatores como horário do dia, dia da semana, sazonalidade e outros dados relevantes. A rede neural é capaz de aprender padrões e relações entre esses fatores e o consumo de energia. Durante a fase de treinamento, a rede neural ARTMAP *Fuzzy* ajusta os pesos das conexões entre os neurônios para otimizar a previsão de carga. Uma vez treinada, a rede pode ser utilizada para fazer previsões futuras de consumo de energia com base nos dados de entrada.

É importante ressaltar que a precisão das previsões de carga depende da qualidade dos dados utilizados para treinar a rede neural e da adequação do modelo escolhido para o problema específico. Além disso, as condições externas, como mudanças na economia, condições climáticas e feriados, também podem afetar a precisão das previsões.

No campo da previsão de carga, existem outras técnicas além do ARTMAP *Fuzzy* que também podem ser aplicadas, como redes neurais de *feedforward*, redes neurais recorrentes (como as LSTM – *Long Short-Term Memory*) e modelos de aprendizado de máquina baseados em árvores de decisão.

Em resumo, as redes neurais, incluindo o ARTMAP *Fuzzy*, podem ser usadas para prever a carga em diversas áreas, como energia elétrica, tráfego de redes e sistemas logísticos. A escolha do modelo adequado depende do contexto específico e das características dos dados disponíveis.


2.4 MATLAB

A previsão de carga é feita com base nos dados históricos de consumo e para analisar esses dados foi utilizado o *software Matlab*, versão estudante. O *Matlab*

proporciona um ambiente computacional poderoso e flexível, especialmente adequado para este estudo.

Utilizou-se a versão “estudante” graças à parceria que a faculdade FEIS UNESP tem com a empresa “The MathWorks”, proprietária do *software*, que disponibiliza de forma gratuita o seu produto para todos os estudantes. Ao entrar no *software* o usuário é direcionado para a tela principal, representado na Figura 9 onde tem acesso à área e consequentemente pode escrever os *scripts*, importar dados e diversas outras aplicações.

Figura 9 – Tela inicial Matlab.



Fonte: Software Matlab R2023b – Versão de estudante.

Além da função para qual foi utilizado, o *software* também possibilita diversas outras funções como [42]:

a. Manipulação de Dados:

load e *save*: Permitem carregar e salvar conjuntos de dados, facilitando a importação e exportação de informações relevantes para o seu estudo;

xlsread e *xlswrite*: Facilitam a leitura e escrita de dados em arquivos do Excel, possibilitando a integração com dados externos.

b. Análise e Visualização de Dados:

plot e *plot3*: Essenciais para criar gráficos bidimensionais e tridimensionais, permitindo visualizar padrões nos dados de consumo de energia;

hist e *histogram*: Úteis para criar histogramas, auxiliando na compreensão da distribuição dos dados.

c. Processamento de Sinais e Séries Temporais:

fft: Realiza a Transformada Rápida de Fourier, útil para análise de frequência em séries temporais de consumo de energia;

filter: Aplica filtros a séries temporais, permitindo suavização ou realce de padrões específicos.

d. Desenvolvimento de Algoritmos e Modelagem:

funções e *scripts*: Permitem a criação de funções e *scripts* personalizados para implementar algoritmos específicos, como a rede neural ARTMAP Fuzzy.

e. Estatísticas:

mean, *std*, *corrcoef*: Fornece estatísticas básicas, como média, desvio padrão e coeficientes de correlação, que podem ser cruciais na análise dos resultados.

3. METODOLOGIA

Nesta etapa serão abordados os principais tópicos acerca do desenvolvimento da proposta bem como as métricas utilizadas para avaliação.

3.1 SCRIPT DO PROGRAMA

A rede neural ARTMAP *Fuzzy* foi programada na linguagem *Matlab* para realizar o treinamento e o diagnóstico (previsão de carga elétrica a curto prazo – 24 horas). Foi elaborado um *script* para todas as análises, em que se altera apenas o período utilizado como treinamento.

3.2 ERRO DE PREVISÃO

Para analisar a metodologia desenvolvida foram utilizados os cálculos do erro percentual absoluto médio, representado por MAPE (*Mean Absolute Percentage Error*), o erro máximo e a raiz do erro quadrático médio, representado por RMSE (*Root Mean Squared Error*) apresentados nas Equações 1,2 e 3.

O MAPE é calculado por:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{y}_t - y_t|}{|\hat{y}_t|} \times 100\% \quad (1)$$

sendo:

N = número total de amostras do conjunto;

$\hat{y}_t$ = valor real;

y_t = valor previsto.

O erro máximo é calculado por:

$$Erromaximo = \max \left(\frac{|\hat{y}_t - y_t|}{|\hat{y}_t|} \right) \times 100\% \quad (2)$$

e o RMSE por:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^n (\hat{y}_t - y_t)^2} \quad (3)$$

3.3 FATORES ATÍPICOS

O resultado de uma previsão de carga depende muito dos dados que serão utilizados, e nesse caso, não somente da quantidade de leitura de cargas por exemplo, mas também da variedade. Pode-se citar [1]:

- Interferências climáticas (temperatura, umidade, vento etc.);
- Dias da semana;
- Greves;
- Acontecimentos esporádicos (Grandes eventos esportivos, guerras, chegada de indústrias na região etc.).

Esses fatores podem interferir negativamente na previsão de carga caso não se tenha dados para a rede neural poder entender o que houve. Por exemplo: A chegada de uma massa de ar fria atua de forma incisiva reduzindo drasticamente a temperatura em uma determinada região. Essa queda de temperatura resultará no maior uso do chuveiro elétrico pela população. A grande utilização de aparelhos de alto consumo aliado do uso generalizado da população em questão faz com que haja um aumento imprevisível do consumo de carga elétrica [1].

4. RESULTADOS

Foram testados 4 períodos distintos de análise com previsões em 3 horizontes: 24 horas a frente, 48 horas a frente e 72 horas a frente. Foram utilizados os dados históricos de carga de meia em meia hora e variáveis exógenas (dia, dia da semana e indicação de feriado) codificados em binário. Os dados referem-se ao conjunto total que será subdividido em treinamento e previsão e são formados da seguinte forma:

- **Período 1 – P1:** abrange o período de 10/09/2008 a 10/10/2008, o que totaliza 1488 dados; referente a 31 dias (1 mês);
- **Período 2 – P2:** abrange o período de 10/08/2008 a 10/10/2008, o que totaliza 2976 dados; referente a 62 dias (2 meses);
- **Período 3 – P3:** abrange o período de 10/07/2008 a 10/10/2008, o que totaliza 4464 dados; referente a 93 dias (3 meses);
- **Período 4 – P4:** abrange o período de 10/04/2008 a 10/10/2008, totalizando 8832 dados; referente a 184 dias (6 meses).

A base de dados utilizada é composta de dados históricos de consumo de energia elétrica fornecida por uma concessionária da Nova Zelândia (CDS, 2010). Os dados englobam valores de demanda de $\frac{1}{2}$ em $\frac{1}{2}$ hora referentes ao dia do mês e dia da semana específico. Os dados também informam se o dia é um dia atípico. Foram utilizados os dados referentes ao ano de 2008.

4.1 PADRÃO DE ENTRADA REFERENTE À BASE DE 31 DIAS

Foram realizadas simulações visando a previsão da demanda de carga elétrica a curto prazo em três horizontes:

1. 24 horas: para o treinamento foram utilizados dados de 10/09/2008 a 9/10/2009. A previsão foi para os dados de carga elétrica do dia 10/10/2008;
2. 48 horas: para o treinamento foram utilizados dados de 10/09/2008 a 8/10/2009. A previsão foi para os dados de carga elétrica dos dias 09/10/2008 e 10/10/2008;

3. 72 horas: para o treinamento foram utilizados dados de 10/09/2008 a 7/10/2009. A previsão foi para os dados de carga elétrica dos dias 08/10/2009, 09/10/2008 e 10/10/2008.


A Tabela 1 apresenta os parâmetros utilizados nas fases de treinamento e previsão da rede neural ARTMAP *Fuzzy* para cada horizonte de previsão.

Tabela 1- Parâmetros utilizados na rede neural ARTMAP *Fuzzy* – P1.

Parâmetros	Horizonte de Previsão (horas)		
	24	48	72
ρ_{a_base}	0,610	0,610	0,610
ρ_a	0,900	0,900	0,900
ρ_b	0,992	0,992	0,992
ρ_{ab}	1,000	1,000	1,000
β	1,000	1,000	1,000
α	0,410	0,410	0,410
ε	0,050	0,050	0,050

Fonte: Elaborado pelo autor.


Figura 10 - Previsão de carga para o dia 10/10/2008 – P1.



Fonte: Elaborado pelo autor.


As Figuras 10, 11 e 12 apresentam a carga real e a carga prevista pela rede neural ARTMAP *Fuzzy* nos horizontes de 24, 48 e 72 horas, respectivamente.

Figura 11 - Previsão de carga para os dias 09/10/2008 e 10/10/2008 – P1.



Fonte: Elaborado pelo autor.

Figura 12 - Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P1.



Fonte: Elaborado pelo autor.

A Tabela 2 apresenta os valores os erros percentuais médios e máximos observados em na previsão de carga para cada horizonte. Observe que os erros são menores quando o horizonte de previsão é de 48 horas.

Tabela 2 - Análise comparativa da previsão de carga – P1.

Tipos de erro	Horizonte de Previsão (horas)		
	24	48	72
MAPE (%)	2,8105	2,5883	3,3436
Erro máximo (%)	8,4766	10,1096	10,1096
RMSE (MW)	3329,36712	3122,10156	3832,5964

Fonte: Elaborado pelo autor.

4.2 PADRÃO DE ENTRADA REFERENTE AOS DADOS DE 62 DIAS

Foram realizadas simulações visando a previsão da demanda de carga elétrica a curto prazo em três horizontes:

1. 24 horas: para o treinamento foram utilizados dados de 10/08/2008 a 9/10/2009. A previsão foi para os dados de carga elétrica do dia 10/10/2008;
2. 48 horas: para o treinamento foram utilizados dados de 10/08/2008 a 8/10/2009. A previsão foi para os dados de carga elétrica dos dias 09/10/2008 e 10/10/2008;
3. 72 horas: para o treinamento foram utilizados dados de 10/08/2008 a 7/10/2009. A previsão foi para os dados de carga elétrica dos dias 08/10/2009, 09/10/2008 e 10/10/2008.

Tabela 3 - Parâmetros utilizados na rede neural ARTMAP Fuzzy – P2.


Parâmetros	Horizonte de Previsão (horas)		
	24	48	72
ρ_{a_base}	0,610	0,610	0,610
ρ_a	0,900	0,900	0,900
ρ_b	0,998	0,998	0,998
ρ_{ab}	1,000	1,000	1,000
β	1,000	1,000	1,000
α	1,100	1,100	1,100
ε	0,050	0,050	0,050

Fonte: Elaborado pelo autor.

A Tabela 3 apresenta os parâmetros utilizados nas fases de treinamento e previsão da rede neural ARTMAP *Fuzzy* para cada horizonte de previsão.


As Figuras 13, 14 e 15 apresentam a carga real e a carga prevista pela rede neural ARTMAP *Fuzzy* nos horizontes de 24, 48 e 72 horas, respectivamente.

Figura 13 - Previsão de carga para o dia 10/10/2008-P2.



Fonte: Elaborado pelo autor.


Figura 14 - Previsão de carga para os dias 9/10/2008 e 10/10/2008 – P2.



Fonte: Elaborado pelo autor.

A Tabela 4 apresenta os valores os erros percentuais médios e máximos observados em na previsão de carga para cada horizonte. Observe que os erros são menores quando o horizonte de previsão é de 48 horas.

Figura 15 - Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P2.



Fonte: Elaborado pelo autor.

Tabela 4 - Análise comparativa da previsão de carga - P1.

Tipos de erro	Horizonte de Previsão (horas)		
	24	48	72
MAPE (%)	2,0938	2,0053	2,4764
Erro máximo (%)	10,6536	8,2135	9,4690
RMSE (MW)	2794,5139	2511,8999	2852,9796

Fonte: Elaborado pelo autor.

4.3 PADRÃO DE ENTRADA REFERENTE AOS DADOS DE 93 DIAS

Foram realizadas simulações visando a previsão da demanda de carga elétrica a curto prazo em três horizontes:

1. 24 horas: para o treinamento foram utilizados dados de 10/07/2008 a 9/10/2009. A previsão foi para os dados de carga elétrica do dia 10/10/2008;

2. 48 horas: para o treinamento foram utilizados dados de 10/07/2008 a 8/10/2009. A previsão foi para os dados de carga elétrica dos dias 09/10/2008 e 10/10/2008;
3. 72 horas: para o treinamento foram utilizados dados de 10/07/2008 a 7/10/2009. A previsão foi para os dados de carga elétrica dos dias 08/10/2009, 09/10/2008 e 10/10/2008.


A Tabela 5 apresenta os parâmetros utilizados nas fases de treinamento e previsão da rede neural ARTMAP *Fuzzy* para cada horizonte de previsão.

Tabela 5- Parâmetros utilizados na rede neural ARTMAP *Fuzzy* – P3.

Parâmetros	Horizonte de Previsão (horas)		
	24	48	72
ρ_{a_base}	0,610	0,610	0,610
ρ_a	0,900	0,900	0,900
ρ_b	0,998	0,998	0,998
ρ_{ab}	1,000	1,000	1,000
β	1,000	1,000	1,000
α	0,130	1,100	1,100
ε	0,050	0,050	0,050

Fonte: Elaborado pelo autor.


Figura 16 - Previsão de carga para o dia 10/10/2008 – P3.



Fonte: Elaborado pelo autor.


As Figuras 16, 17 e 18 apresentam a carga real e a carga prevista pela rede neural ARTMAP *Fuzzy* nos horizontes de 24, 48 e 72 horas, respectivamente.

Figura 17 - Previsão de carga para os dias 9/10/2008 e 10/10/2008 – P3.



Fonte: Elaborado pelo autor.

Figura 18 - Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P3.



Fonte: Elaborado pelo autor.

observados em na previsão de carga para cada horizonte. Observe que os erros são menores quando o horizonte de previsão é de 48 horas. Observa-se que quando o horizonte de previsão é aumentado para 72 horas o erro aumenta consideravelmente.

Tabela 6- Análise comparativa da previsão de carga – P3.

Tipos de erro	Horizonte de Previsão (horas)		
	24	48	72
MAPE (%)	2,1181	1,9697	5,5811
Erro máximo (%)	10,7314	10,7314	16,2485
RMSE (MW)	2797,8483	2622,7165	5894,9427

Fonte: Elaborado pelo autor.

4.4 PADRÃO DE ENTRADA REFERENTE AOS DADOS DE 184 DIAS

Foram realizadas simulações visando a previsão da demanda de carga elétrica a curto prazo em três horizontes:

1. 24 horas: para o treinamento foram utilizados dados de 10/04/2008 a 9/10/2009. A previsão foi para os dados de carga elétrica do dia 10/10/2008;
2. 48 horas: para o treinamento foram utilizados dados de 10/04/2008 a 8/10/2009. A previsão foi para os dados de carga elétrica dos dias 09/10/2008 e 10/10/2008;
3. 72 horas: para o treinamento foram utilizados dados de 10/04/2008 a 7/10/2009. A previsão foi para os dados de carga elétrica dos dias 08/10/2009, 09/10/2008 e 10/10/2008.


A Tabela 7 apresenta os parâmetros utilizados nas fases de treinamento e previsão da rede neural ARTMAP *Fuzzy* para cada horizonte de previsão.

Tabela 7 - Parâmetros utilizados na rede neural ARTMAP *Fuzzy* – P4.

Parâmetros	Horizonte de Previsão (horas)		
	24	48	72
ρ_{a_base}	0,610	0,610	0,610
ρ_a	0,900	0,900	0,900
ρ_b	0,998	0,998	0,996
ρ_{ab}	1,000	1,000	1,000
β	1,000	1,000	1,000
α	1,100	1,100	5,030
ε	0,050	0,050	0,050

Fonte: Elaborado pelo autor.


As Figuras 19, 20 e 21 apresentam a carga real e a carga prevista pela rede neural ARTMAP *Fuzzy* nos horizontes de 24, 48 e 72 horas, respectivamente.

Figura 19 - Previsão de carga para o dia 10//10/2008 – P4.

Fonte: Elaborado pelo autor.


A Tabela 8 apresenta os valores os erros percentuais médios e máximos observados em na previsão de carga para cada horizonte. Observe que os erros são menores quando o horizonte de previsão é de 48 horas.

Figura 20 - Previsão de carga para os dias 9/10/2008 e 10/10/2008 – P4.



Fonte: Elaborado pelo autor.

Figura 21 - Previsão de carga para os dias 8/10/2008, 9/10/2008 e 10/10/2008 – P4.



Fonte: Elaborado pelo autor.

Tabela 8- Análise comparativa da previsão de carga – P4.

Tipos de erro	Horizonte de Previsão (horas)		
	24	48	72
MAPE (%)	2,1216	1,9712	2,8077
Erro máximo (%)	10,7314	10,7314	14,5711
RMSE (MW)	2804,1209	2627,1362	3523,7208

Fonte: Elaborado pelo autor.

5. ANÁLISE DOS RESULTADOS

Observou-se que a previsão de carga utilizando a RNA ARTMAP *Fuzzy* se comportou fielmente em relação ao valor real da carga até determinado ponto, os *outliers* ocasionados por algum fator atípico não identificado distorcem a leitura da previsão, pois apresentam um erro máximo elevado e causam bastante impacto na RMSE (devido à forma como é calculado).

Indo contra intuitivamente, os maiores erros de previsão obtido foram obtidos na previsão do horizonte de 72 horas e isso é esperado pelo fato que utilizando o mesmo banco de dados para aumentar o horizonte de previsão reduz-se o número de dados imputados na RNA. Isso se deve ao fato de que o “erro” não entendido pela RNA se propagou na previsão tornando-a mais distorcida.

6. CONCLUSÃO

A previsão de carga elétrica é um fator essencial no desenvolvimento, na gestão e na expansão dos sistemas elétricos, ela propicia maior segurança, economia e confiabilidade. Com o intuito de desenvolver e analisar a eficiência de um dos métodos utilizados para previsão de carga, fez-se o uso da RNA ARTMAP *Fuzzy*.

Utilizando o *software Matlab*, foram feitas seis previsões com padrões de entrada diferentes buscando a cada passo recalibrar a RNA e assim diminuir o erro entre o valor previsto e o valor real. Os erros avaliados foram: Erro máximo (que media a maior diferença entre os valores reais e previstos) e o RMSE (medida de dispersão absoluta dos erros) e o erro percentual médio absoluto – MAPE.

Dentre os testes realizados com períodos diferentes (quantidade de dados utilizados na fase de treinamento) observa-se que ambos apresentaram erros percentuais médios inferiores a 5%, com exceção do P3 no horizonte de 72 horas.

É importante salientar que a curva de previsão acompanhou o valor real da carga na maior parte do tempo demonstrando um bom desempenho da RNA, porém, o valor da RMSE se distancia do ideal devido ao *outlier* sendo o valor previsto se mantém alto e o valor real apresenta uma queda repentina. Esse *outlier* se deu por algum fenômeno atípico não identificado, para melhorar a previsão (diminuir os erros) é necessária uma maior fonte de dados como temperatura, umidade, vento e dias atípicos (feriados, eventos, frentes frias etc.). Outro ponto que vale ressaltar é que tentou-se carregar mais dados para avaliar se o evento atípico era identificado e corrigido pela rede neural, o que não foi o resultado. Carregar mais dados nesse sistema resultou no acúmulo do erro, causando ainda mais distorções na previsão.

7. REFERÊNCIAS

- [1] LOPES, M. L. M. Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica, Tese de Doutorado - Universidade Estadual Paulista (Unesp), Faculdade de Engenharia de Ilha Solteira, 2005.
- [2] ABREU, T., AMORIM, A. J., SANTOS-JUNIOR, C. R., LOTUFO, A. D. P., & MINUSSI, C. R. "Multinodal Load Forecasting for Distribution Systems using a Fuzzy-ARTMAP Neural Network" *Applied Soft Computer*, Vol. 71, pp. 307–316, 2018.
- [3] GROSS, G. AND GALIANA, F. D. "Short Term Load Forecasting", *Proceedings of IEEE*, Vol. 75, No. 12, pp. 1558-1573, 1987.
- [4] O'DONOVAN, T. M. "Short Term Forecasting: An Introduction to the Box-Jenkins Approach", John Wiley & Sons, New York, 1983.
- [5] MOHGRAM, I. and RAHMAN, S. "Analysis and Evaluation of Five Short Term Load Forecasting Techniques", *IEEE Transactions on Power Systems*, Vol. 4, No. 4, pp. 1484-1491, 1989.
- [6] ALMEIDA, C.; FISHWICK P. A. and TANG, Z. "Time Series Forecasting using Neural Networks vs. Box and Jenkins methodology", *Simulation Councies*, Vol. 57, No. 5, pp. 303-310, 1991.
- [7] LIAO, G-C. and TSAO, T-P. "Application of Fuzzy Neural Networks and Artificial Intelligence for Load Forecasting", *Electric Power Systems Research*, Vol. 70, No. 3, pp. 237-244, 2004.
- [8] LOPES, M. L. M.; MINUSSI, C.R. and LOTUFO, A. D. P. "Electric Load Forecasting Using a Fuzzy ART&ARTMAP Neural Network", *Applied Soft Computing*, Vol. 5, No. 2, pp. 235-244, 2005.
- [9] LIN, L.-L.; SUN, J.; WANG, C.-H.; ZHOU, Y.-T.; LIN, K.-P. "Enhanced Gaussian Process Mixture Model for Short-term Electric Load Forecasting, *Inf. Sci.*, Vol. 447, pp.386–398, 2019.

- [10] YANG, Y.; CHE, J.; DENG, C.; LI, L. "Sequential Grid Approach based Support Vector Regression for Short-term Electric Load Forecasting", *Applied Energy*, Vol. 238, pp. 1010–1021, 2019.
- [11] ALY, H. H. H. "A Proposed Intelligent Short-term Load Forecasting Hybrid Models of ANN, WNN and KF based on Clustering Techniques for Smart Grid", *Electric Power Systems, Research*, Vol. 182, pp. 1–13, 2020.
- [12] CAI, Q.; YAN, B.; SU, B.; LIU, S.; XIANG, M.; WEN, Y.; CHEN, N. "Short-term Load Forecasting Method Based on Deep Neural Network with Sample Weights", *International Transactions on Electrical Energy Systems*, Vol. 30, pp.1–19, 2020.
- [13] MOHAMMAD, F.; KIM, Y.-C. "Energy Load Forecasting Model based on Deep Neural Networks for Smart Grids", *International Journal of System Assurance Engineering Management*, Vol. 11, pp. 824–834, 2020.
- [14] WU, L.; KONG, C.; HAO, X.; CHEN, W. "A Short-term Load Forecasting Method based on GRU-CNN Hybrid Neural Network Model", *Mathematical Problems in Engineering*, pp. 1–10, 2020.
- [15] SYED, D.; ABU-RUB, H.; GHAYEB, A.; REFAAT, S. S.; HOUCHATI, M.; BOUHALI, O.; BAÑALES, S. "Deep Learning-based Short-term Load Forecasting Approach in Smart Grid with Clustering and Consumption Pattern Recognition", *IEEE Access*, Vol. 9, pp. 54992–55008, 2021.
- [16] ZHAO, D.; GE, Q.; TIAN, Y.; CUI, J.; XIE, B.; HONG, T. "Short-term Load Demand Forecasting Through Rich Features Based on Recurrent Neural Networks", *IET Generation, Transmission & Distribution*, Vol. 15, pp. 927–937, 2021.
- [17] HAYKIN, S. "Neural Networks and Learning Machines", Prentice-Hall, 3rd edition, 2008.
- [18] JAIN, A. K.; MAO, J. and MOHIUDDIN, K. M. "Artificial Neural Networks: A Tutorial", *IEEE Computer*, Vol. 29, No. 3, pp. 31-44, 1996.
- [19] KARTALOPOULOS, S. V. "Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications", IEEE Press, Piscataway, NJ, USA, 1996.

- [20] KING, R. L. "Artificial Neural Networks and Computational Intelligence", IEEE Computer Application in Power, Vol. 11, pp. 14-25, 1998.
- [21] SIMPSON, P. K. "Artificial Neural Systems: Foundations, Paradigms, Applications, and Implementations", New York, Pergamon Press, 1989.
- [22] GROSSBERG, S. Adaptive pattern classification and universal recoding, I: Parallel development and coding of neural feature detectors. Biological Cybernetics, Heidelberg, v. 23, p. 121–134, 1976.
- [23] GROSSBERG, S. "Adaptive Pattern Classification and Universal Recoding, II: Feedback, Expectation, Olfaction, and Illusions", Biological Cybernetics, Vol. 23, No. 4, pp. 187-202, 1976.
- [24] GROSSBERG, S. "Nonlinear Neural Networks: Principles, Mechanisms, and Architectures," Neural Networks, Vol. 1, No. 1, pp. 17-61, 1988.
- [25] CARPENTER, G. A.; GROSSBERG, S.; MARKUZON, N.; REYNOLD, J. H. and ROSEN, D. B. "Fuzzy ARTMAP: A Neural Network for Incremental Supervised Learning of Analog Multidimensional Maps", IEEE Transactions on Neural Network, Vol. 3, No. 5, pp. 689-713, 1992.
- [26] ZADEH, L. "Fuzzy Sets, Information and Control", Vol. 8, No. 3, pp. 338-353, 1965.
- [27] CDS-Centralized Dataset. Electricity commission for the load dataset. New Zealand, 2010.
- [28] KAGAN, N.; OLIVEIRA, C. C. B. de; ROBBA, E. J. Introdução aos sistemas de distribuição de energia elétrica. 2.ed. São Paulo: Blücher, 2010
- [29] ONS – Operador Nacional do Sistema Elétrico. "Energia Agora : Carga e Geração". Disponível em: <https://www.ons.org.br/paginas/energia-agora/carga-e-geracao>. Acesso em: 30 de nov. de 2023.
- [30] ONS – Operador Nacional do Sistema Elétrico. "O que é o SIN: O sistema Interligado Nacional". Disponível em: <https://www.ons.org.br/paginas/sobre-o-sin/o-que-e-o-sin>. Acesso em: 30 de nov. de 2023.

- [31] EPE – Empresa de Pesquisa Energética. “Plano Decenal de Expansão de Energia 2026”. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Plano-Decenal-de-Expansao-de-Energia-2026>. Acesso em: 30 de nov. de 2023.
- [32] ONS – Operador Nacional do Sistema Elétrico. “Energia Agora: Balanço de Energia”. Disponível em: <https://www.ons.org.br/paginas/energia-agora/balanco-de-energia>. Acesso em: 30 de nov. de 2023.
- [33] BRASIL ESCOLA. “Distribuição de Energia Elétrica no Brasil”. Disponível em: <https://brasilecola.uol.com.br/geografia/distribuicao-energia-eletrica-no-brasil.htm>. Acesso em: 30 de nov. de 2023.
- [34] EPE – Empresa de Pesquisa Energética. “Matriz Energética e Elétrica”. Disponível em: <https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>. Acesso em: 30 de nov. de 2023.
- [35] EPE – Empresa de Pesquisa Energética. “Plano Decenal de Expansão de Energia 2029”. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/Plano-Decenal-de-Expansao-de-Energia-2029>. Acesso em: 30 de nov. de 2023.
- [36] MUNDO EDUCAÇÃO. “Neurônio”. Disponível em: <https://mundoeducacao.uol.com.br/biologia/neuronios.htm>. Acessado em: 30 de nov. de 2023.
- [37] CHANDRA, A. L. “McCulloch-Pitts Neuron — Mankind’s First Mathematical Model Of A Biological Neuron”. Towards Data Science. Disponível em: <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>. Acessado em: 30 de nov. de 2023.
- [38] MINUSSI, C. R.; LOTUFO, A. D. P. Redes neurais: introdução e principais conceitos. 2008. pg. 98.
- [39] AI-KANDARI, A. M.; SOLIMAN, S. A.; EI-HAWARY, M. E. Fuzzy short-term electric load forecasting. Electrical Power & Energy Systems, Guildford, v.26, n.2, p. 111-122, 2004.

[40] CARPENTER, G. A.; GROSSBERG, S. ART2: Self-organization of stable category recognition codes for analog input patterns. Applied Optics: Special Issue on Neural Networks, New York, v. 26, p. 4919–4930, 1987.

[41] CARPENTER, G. A.; GROSSBERG, S.; REYNOLDS, J. H. ARTMAP: Supervised real-time learning and classification of nonstationary data by a self-organizing neural network. Neural Networks, Kidlington, v. 4, n. 5, p. 565–588, 1991.

[42] The MathWorks. (2023). MATLAB. Disponível em: https://www.mathworks.com/products/matlab.html?s_tid=hp_products_matlab. Acessado em: 30 de nov. de 2023.