UNIVERSIDADE ESTADUAL PAULISTA "JÚLIO DE MESQUITA FILHO"
CAMPUS DE ILHA SOLTEIRA

GIOVANNI PANEGOSSI FORMAGGIO

UMA NOVA ABORDAGEM PARA APRIMORAMENTO DA PREVISÃO DA DEMANDA TOTAL DE CARREGAMENTO RESIDENCIAL E ESTAÇÃO DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS UTILIZANDO APRENDIZADO PROFUNDO

Ilha Solteira - SP
2026

Giovanni Panegossi Formaggio

UMA NOVA ABORDAGEM PARA APRIMORAMENTO DA PREVISÃO DA DEMANDA TOTAL DE CARREGAMENTO RESIDENCIAL E ESTAÇÃO DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS UTILIZANDO APRENDIZADO PROFUNDO

Tese, apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia de Ilha Solteira, para obtenção do título de Doutor em Engenharia Elétrica.

Área de Concentração: Automação

Orientador: Profº Dr. Anna Diva Plasencia Lotufo

Ilha Solteira, SP
2026

FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

Formaggio, Giovanni Panegossi.
F724n Uma nova abordagem para aprimoramento da previsão da demanda total de carregamento residencial e estação de carregamento de veículos elétricos utilizando aprendizado profundo / Giovanni Panegossi Formaggio. -- Ilha Solteira: [s.n.], 2026
110 f. : il.

Tese (doutorado em Engenharia Elétrica) - Universidade Estadual Paulista (UNESP), Faculdade de Engenharia, Ilha Solteira. Área de conhecimento: Automação e controle, 2026

Orientador: Anna Diva Plasencia Lotufo

Inclui bibliografia

1. Veículos elétricos. 2. Previsão de cargas elétricas. 3. Pré-processamento. 4. Cargas de veículos elétricos. 5. Perceptron de multicamadas recorrente. 6. Redes neurais artificiais.

Sandra Montibeller - CRB-8/060

IMPACTO POTENCIAL DESTA PESQUISA

Este tese trabalho aponta e aprimora um tema antigo que ressurgiu nas últimas duas décadas, devido a alta adoção por veículos elétricos e preocupação no cenário energético global. A contribuição da pesquisa tem potencial científico para investigar e aprimorar o processo de previsão da demanda energética de veículos elétricos carregados em ambientes residenciais e em estações de carregamento. O tema envolve resolver o problema de previsão em dois ambientes distintos, o que aponta uma lacuna na literatura, já que os estudos só abordam um ambiente. A metodologia baseia-se com robustez em utilizar um aprendizado profundo e treinamento híbrido, sendo uma ferramenta de inteligência artificial muito explorada e utilizada nas últimas décadas. A metodologia inova nesta pesquisa, por utilizar pré-processamentos distintos, com os quais se obtiveram melhorias com alta precisão. Contudo, os resultados apontam baixos erros em comparação com os estudos recentes, o que significa, em termos de energia elétrica, menor desperdício, melhor planejamento energético e projeções futuras. Com isto, a pesquisa fornece resultados robustos e realistas, sendo um tema necessário a ser abordado e atual.

POTENTIAL IMPACT OF THIS RESEARCH

This paper highlights and refines an old topic that has once again become highly relevant and a cause for concern in the global energy scenario. The research contribution has scientific potential to investigate and improve the process of forecasting the energy demand of electric vehicles charged in residential environments and at charging stations. The topic involves solving the forecasting problem in two distinct environments, highlighting a gap in the literature, as studies typically address only one environment. The methodology is robustly based on the use of deep learning and hybrid training, a widely explored and used artificial intelligence tool in recent decades. The methodology innovates in this research by using different pre-processing methods, resulting in high accuracy. With all this, the results point to low errors in comparison with recent studies, which means, in terms of electrical energy, less waste, better energy planning, and future projections. With this, the research provides robust, realistic results, making it a necessary and current topic to address.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: Uma Nova Abordagem para Aprimoramento da Previsão da Demanda Total de Carregamento Residencial e Estação de Carregamento de Veículos Elétricos Utilizando Aprendizado Profundo

AUTOR: GIOVANNI PANEGOSSI FORMAGGIO
ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovado como parte das exigências para obtenção do Título de Doutor em Engenharia Elétrica, área: Automação pela Comissão Examinadora:

Documento assinado digitalmente
gov.br
ANNA DIVA PLASENCIA LOTUFO
Data: 19/02/2026 13:21:48-0300
Verifique em https://validar.iti.gov.br

Profa. Dra. ANNA DIVA PLASENCIA LOTUFO (Participaçao Presencial)
Departamento de Engenharia Elétrica / UNESP / Câmpus de Ilha Solteira - FEIS

Documento assinado digitalmente
gov.br
MARA LUCIA MARTINS LOPES
Data: 19/02/2026 08:56:52-0300
Verifique em https://validar.iti.gov.br

Profa. Dra. MARA LUCIA MARTINS LOPES (Participaçao Presencial)
Departamento de Matemática / UNESP / Câmpus de Ilha Solteira - FEIS

Documento assinado digitalmente
gov.br
CARLOS ROBERTO MINUSSI
Data: 19/02/2026 10:46:25-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. CARLOS ROBERTO MINUSSI (Participaçao Presencial)
Departamento de Engenharia Elétrica / UNESP / Câmpus de Ilha Solteira - FEIS

Documento assinado digitalmente
gov.br
KENJI NOSE FILHO
Data: 18/02/2026 17:21:52-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. KENJI NOSE FILHO (Participaçao Virtual)
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas / UFABC / Universidade Federal do ABC

Documento assinado digitalmente
gov.br
CARLOS ROBERTO DOS SANTOS JUNIOR
Data: 18/02/2026 16:39:26-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. CARLOS ROBERTO DOS SANTOS JÚNIOR (Participaçao Virtual)
Campus Três Lagoas / IFMS / Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul

Ilha Solteira, 13 de fevereiro de 2026.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de pesquisa (88887.817672/2023-00).

À Universidade Estadual Paulista "Júlio de Mesquita Filho", a Faculdade de Engenharia-(FEIS) e ao Laboratório de Sistemas Inteligentes (SINTEL).

A orientadora Professora Doutora Anna Diva Plasencia Lotufo, professores e colegas de laboratórios.

“Then you slowly recall all your mind Why, your soul’s gone cold, and all hope has run dry
Dead inside Never enough to forget that you’re one of the lonely Slowly recall all your mind“
(Disturbed, Dan J Donegan, David Michael Draiman, Michael Wengren, 2005)

LISTA DE ILUSTRAÇÕES

Figura 1 Estrutura de um perceptron multicamadas recorrente. 34
Figura 2 Função *Wavelet Daubechies* 4 (db4) 46
Figura 3 Função *Wavelet Symlets* 4 (sym4) 47
Figura 4 Diagrama da Metodologia 54
Figura 5 Demanda residencial original 55
Figura 6 Demanda VEs nível 1 original 55
Figura 7 Demanda VEs nível 2 original 56
Figura 8 Demanda comercial da cidade de Houston 57
Figura 9 Demanda da estação de carregamento com 2 portas 57
Figura 10 Demanda da estação de carregamento com 6 portas 58
Figura 11 Demanda da estação de carregamento com 6 portas 58
Figura 12 Demandas totais níveis 1 e 2 60
Figura 13 Demanda total nível 1 com wavelet 61
Figura 14 Decomposição da série temporal utilizando a Transformada Wavelet sym4. *Wavelet sym4* 61
Figura 15 Matriz da série temporal X da demanda pré-processada com TW 62
Figura 16 Matriz de covariância C 62
Figura 17 Autovalores λ e autovetores RHO 63
Figura 18 Cálculo das principais componentes PC 64
Figura 19 Cálculo das componentes principais RC 64
Figura 20 Comparação da série original e reconstruída 65
Figura 21 Demanda wavelet pré processada com AES 65
Figura 22 Demanda walvelet AES pré processada com SG 66
Figura 23 Demanda de nível 1 com os 3 pré-processamento e demanda original . . . 67
Figura 24 Demanda nível 1 prevista com treinamento BPAT e BPAT-RB 71
Figura 25 Processo de treinamento da Demanda nível 1 prevista com treinamento BPAT-RB 72
Figura 26 Previsão Demanda nível 1 com TW 73
Figura 27 Processo de treinamento com TW da Demanda nível 1 prevista com treinamento BPAT-RB 73
Figura 28 Previsão Demanda nível 1 com TW+AES 74
Figura 29 Processo de treinamento com AES da Demanda nível 1 prevista com treinamento BPAT-RB 74
Figura 30 Previsão Demanda nível 1 proposta 75
Figura 31 Processo de treinamento com filtro SG da Demanda nível 1 prevista com treinamento BPAT-RB 75

Figura 32 Demanda nível 2 prevista com treinamento BPAT-RB 76
Figura 33 Processo de treinamento com dados originais da Demanda nível 2 prevista com treinamento BPAT-RB 76
Figura 34 Demanda nível 2 prevista com treinamento com TW 77
Figura 35 Processo de treinamento com TW da Demanda nível 2 prevista com treinamento BPAT-RB 77
Figura 36 Demanda nível 2 prevista com treinamento com TW-AES 78
Figura 37 Processo de treinamento com AES da Demanda nível 2 prevista com treinamento BPAT-RB 78
Figura 38 Demanda nível 2 prevista com treinamento proposto 79
Figura 39 Processo de treinamento com método proposto da Demanda nível 2 prevista com treinamento BPAT-RB 79
Figura 40 Previsão com dados originais ambiente com 2 portas 81
Figura 41 Performance com dados originais ambiente com 2 portas 81
Figura 42 Previsão com TW ambiente com 2 portas 82
Figura 43 Performance com TW para o ambiente com 2 portas 82
Figura 44 Previsão com TW+AES para o ambiente com 2 portas 83
Figura 45 Performance com TW+AES para o ambiente com 2 portas 83
Figura 46 Previsão com TW+AES+SG para o ambiente com 2 portas 84
Figura 47 Performance com TW+AES+SG para o ambiente com 2 portas 84
Figura 48 Previsão da demanda com dados originais para 6 portas 85
Figura 49 Performance da demanda com dados originais para 6 portas 85
Figura 50 Previsão da demanda com TW para 6 portas 86
Figura 51 Performance da demanda com TW para 6 portas 86
Figura 52 Previsão da demanda com TW+AES para 6 portas 87
Figura 53 Performance da demanda com TW+AES para 6 portas 87
Figura 54 Previsão da demanda com TW+AES+SG para 6 portas 88
Figura 55 Performance da demanda com TW+AES+SG para 6 portas 88

LISTA DE TABELAS

Tabela 1 – Detalhes da frota dos VEs. 55
Tabela 2 – Ambiente experimentar 69
Tabela 3 – PARÂMETROS DE TREINAMENTO E ARQUITETURA DA MLPR . . . 70
Tabela 4 – MAPES DOS RESULTADOS DA DEMANDA NÍVEL 1 77
Tabela 5 – MAPES DOS RESULTADOS DA DEMANDA NÍVEL 2 78
Tabela 6 – GANHOS DE MAPES PREVISTOS DA DEMANDA NÍVEL 1 80
Tabela 7 – GANHOS DE MAPES PREVISTOS DA DEMANDA NÍVEL 2 80
Tabela 8 – MAPES DOS RESULTADOS DA DEMANDA COM 2 PORTAS 83
Tabela 9 – GANHOS DE MAPES PREVISTOS DA DEMANDA COM 2 PORTAS . . 84
Tabela 10 – MAPES DOS RESULTADOS DA DEMANDA COM 6 PORTAS 88
Tabela 11 – GANHOS DE MAPES PREVISTOS DA DEMANDA COM 6 PORTAS . . 89

RESUMO

Este trabalho tem como objetivo investigar, aprimorar e sugerir melhorias na previsão de curto prazo da demanda total gerada pelo carregamento descontrolado de Veículos Elétricos Plugáveis (VEPs) de nível 1 e 2 em residências e estação de carregamento com 2 e 6 portas de 350 kW de potência, utilizando uma rede neural artificial (RNA) multicamada perceptron recorrente (MLPR) de aprendizado profundo. O treinamento foi realizado com o algoritmo *backpropagation* através do tempo (BPAT), com regularização bayesiana (RB), formando um treinamento supervisionado híbrido bayesiano. Para aprimorar a previsão, além do treinamento híbrido e do aprendizado profundo, foram aplicadas três técnicas de pré-processamento: transformada *wavelet* (TW), análise de espectro singular (AES) e o filtro digital Savitsky-Golay (SG). As técnicas adotadas resultaram em uma melhora significativa no desempenho do treinamento, dos testes e das previsões, quando comparadas ao treinamento com *backpropagation* (BP) original e sem o uso de pré-processamento, ajustando melhor as cargas previstas em relação às reais. O método proposto reduziu o erro percentual absoluto médio (MAPE), apresentando previsões mais exatas, acertivas e seguras, o que facilita o planejamento e a gestão das cargas dos VEPs. O estudo demonstra a robustez, a eficiência energética e a aplicabilidade em cenários de grande escala, fornecendo dados importantes para planejar novas taxas de inclusão dos VEPs no sistema elétrico, permitindo otimizar o gerenciamento destas cargas, significativamente para o desenvolvimento de novas estratégias e aprimoramentos na previsão de cargas dos VEPs. Os resultados oferecem informações relevantes e acertivas para o planejamento do sistema de energia elétrica atual e futuro, o que precisa acompanhar o avanço da mobilidade elétrica em nível global. As previsões de demandas agregadas com as cargas residenciais e a demanda comercial mostraram-se relevantes e realistas, podendo ser aplicadas em cenários do mundo real.

Palavras-Chave: veículos elétricos; previsão de cargas elétricas; previsão de demanda; cargas de veículos elétricos; perceptron de multicamadas recorrente; redes neurais artificiais; backpropagation; backpropagation através do tempo; pré-processamento; transformada wavelet; análise de espectro singular; filtro Savitsky-Golay; aprimoramento.

ABSTRACT

This work aims to investigate, improves, and suggests enhancements to the short-term forecasting of total demand generated by the uncontrolled charging of Tier 1 and Tier 2 Plug-in Electric Vehicles (PEVs) in homes and charging stations with 2 and 6 ports of 350 kW power, using a multilayer recurrent perceptron (MLPR) deep learning artificial neural network (ANN). Training was performed with the backpropagation through time (BPAT) algorithm, with Bayesian regularization (RB), forming a hybrid Bayesian supervised training. To improve the forecast, in addition to hybrid training and deep learning, three preprocessing techniques were applied: wavelet transform (TW), singular spectrum analysis (SSA), and the Savitsky-Golay digital filter (SG). The techniques adopted resulted in a significant improvement in training, testing, and forecasting performance when compared to training with the original backpropagation (BP) method without preprocessing, better adjusting predicted loads to actual loads. The proposed method reduced the mean absolute percentage error (MAPE), presenting more accurate, reliable, and safe forecasts, which facilitates the planning and management of electric vehicle (EPV) loads. The study demonstrates the robustness, energy efficiency, and applicability in large-scale scenarios, providing important data for planning new rates of inclusion of EPVs in the electrical system, allowing for optimization of load management, significantly contributing to the development of new strategies and improvements in EPV load forecasting. The results offer relevant and accurate information for planning the current and future electrical power system, which needs to keep pace with the advancement of electric mobility globally. The aggregate demand forecasts, including residential and commercial loads, proved to be relevant and realistic, and can be applied to real-world scenarios.

Keywords: Electric vehicles; electric load forecasting; demand forecasting; electric vehicle loads; recurrent multilayer perceptron; artificial neural networks; backpropagation; backpropagation through time; preprocessing; wavelet transform; singular spectrum analysis; Savitsky-Golay filter; enhancement.

SUMÁRIO

1	**INTRODUÇÃO**	**16**
1.1	OBJETIVOS E CONTRIBUIÇÕES	18
2	**IMPACTOS DOS VEÍCULOS ELÉTRICOS PLUGÁVEIS NO SISTEMA DE ENERGIA ELÉTRICA**	**20**
2.1	CARREGAMENTO DESCONTROLADOS DE VEÍCULOS ELÉTRICOS PLUGÁVEIS	22
2.2	ESTUDOS SOBRE IMPACTOS DOS CARREGAMENTOS RESIDENCIAIS DE VEPs AO SISTEMA DE ENERGIA ELÉTRICA	22
2.3	IMPACTOS DA ESTAÇÃO DE CARREGAMENTO DOS VEPs NO SISTEMA ELÉTRICO	25
3	**ESTUDO SOBRE PREVISÕES DE CARGAS ELÉTRICAS**	**27**
3.1	CATEGORIAS DE PREVISÃO DE CARGAS ELÉTRICAS	28
3.2	PREVISÃO DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS PLUGÁVEIS	29
3.3	APLICAÇÕES DE APRENDIZADO DE MÁQUINA NA PREVISÃO DA DEMANDA POR CARREGAMENTO DE VEPs	30
4	**REDE NEURAL ARTIFICIAL PERCEPTRON MULTICAMADAS RECORRENTE**	**34**
4.1	ALGORITMO DE TREINAMENTO *BACK-PROPAGATION*	35
4.2	TREINAMENTO PADRÃO COM BP	36
4.3	TREINAMENTO *BACK-PROPAGATION* ATRAVÉS DO TEMPO (BPAT)	36
4.4	MELHORANDO O TREINAMENTO BP	38
4.5	TREINAMENTO BPAT COM REGULARIZAÇÃO BAYESIANA RB	39
4.5.1	**otimização de parâmetros de regularização**	**40**
4.5.2	**cálculo da aproximação de Gauss-Newton para a matriz hessiana**	**41**
5	**PRÉ-PROCESSAMENTO**	**44**
5.1	TRANSFORMADA *WAVELET*	45
5.2	TRANSFORMADA *WAVELET DAUBECHIES* e *SYMLETS*	46
5.3	FILTRO DIGITAL SAVIZKY-GOLAY (SG)	47
5.4	ANÁLISE DE ESPECTRO SINGULAR (AES)	49
5.5	AES APLICADO NA SÉRIE TEMPORAL	50
5.5.1	**passo 1: introdução da série temporal original**	**50**

5.5.2 passo 2: decomposição de valor singular (DVS) 50
5.5.3 passo 3: agrupamento 51
5.5.4 passo 4: cálculo da média diagonal 51

6 MATERIAIS E MÉTODOS 53
6.1 BANCO DE DADOS DE CARREGAMENTO RESIDENCIAL 53
6.2 BANCO DE DADOS DE ESTAÇÃO DE CARREGAMENTO 53
6.3 EXTRAÇÃO DA SÉRIE TEMPORAL (CARGAS ELÉTRICAS) CARREGAMENTO RESIDENCIAL 56
6.4 EXTRAÇÃO DA SÉRIE TEMPORAL (CARGAS ELÉTRICAS) É PRÉ-PROCESSAMENTO DO BANCO DE DADOS DE ESTAÇÃO DE CARREGAMENTO 56
6.5 PRÉ-PROCESSAMENTO DO BANCO DE DADOS DE CARREGAMENTO RESIDENCIAL 59
6.6 PARÂMETROS E AJUSTES DOS PRÉ-PROCESSAMENTOS DE CARREGAMENTOS RESIDENCIAL 59
6.7 SEPARAÇÃO DOS CONJUNTOS DE TREINAMENTOS E TESTES . . . 67
6.8 NORMALIZAÇÃO E TREINAMENTO 67
6.9 AJUSTES DO MODELO, PREVISÕES E RESULTADOS 68
6.10 PREVISÕES E RESULTADOS 69
6.11 PREVISÕES E RESULTADOS: DEMANDA TOTAL NÍVEL 1 (CAREGAMENTO RESIDENCIAL) 70
6.12 PREVISÃO DAS DEMANDA EM NÍVEIS 1 E 2 COM METODOLOGIA PROPOSTA 72
6.13 PREVISÕES DAS DEMANDAS DAS ESTAÇÕES DE CARREGAMENTO COM 2 E 6 PORTAS 80
6.14 RESULTADOS E DISCUSSÕES 89

7 CONCLUSÃO E TRABALHOS FUTUROS 92

REFERÊNCIAS 94

APÊNDICE A – PRÉ-PROCESSAMENTO 103

DADOS CURRICULARES 111

1 INTRODUÇÃO

A eletrificação do setor de transporte desempenha um papel crucial e apresenta grande potencial para aumentar a segurança energética, ao reduzir a dependência de fontes de energia baseadas em petróleo (Fan et al., 2018). Isto, por sua vez, contribui para a diminuição das emissões de gases poluentes, promovendo gradualmente melhorias na qualidade do ar e do clima. O setor de transporte é um dos maiores responsáveis pelo aumento dos gases de efeito estufa, que representam uma parcela significativa da poluição em nível local e global (Kriegler et al., 2014).

Diante das recorrentes crises energéticas globais dos últimos anos, muitos países têm se mobilizado em direção a um futuro mais limpo e sustentável, com foco em fontes de energia alternativas e renováveis. Grandes potências mundiais, como China, Estados Unidos, Japão e União Europeia, estão à frente do movimento de descarbonização do setor de transporte (Fan et al., 2018). A mobilidade elétrica mais sustentável já é uma realidade há anos em grandes centros urbanos de alguns países, e o mundo reconhece essa transição como uma necessidade urgente, tanto no presente quanto no futuro (Fan et al., 2018) (Nikitha et al., 2017).

Neste seguimento, os veículos elétricos (VEs) surgem como uma opção promissora neste cenário, sendo considerados um dos elementos essenciais nas estratégias de médio e longo prazo para reduzir gradualmente as fontes poluentes no setor de transporte a combustão. A meta é a transição progressiva e parcial do transporte a combustão para um sistema parcialmente ou totalmente elétrico, visando um futuro mais sustentável e seguro (Nirala et al., 2025).

A adoção de (VEs) tem crescido significativamente nas últimas duas décadas. Em um cenário otimista, o relatório da Agência Internacional de Energia (AIE) projeta que, até 2030, os VEs representarão 7% de toda a frota de veículos rodoviários (International Energy Agency (IEA), 2023). Este crescimento é impulsionado pela postura adotada por países e consumidores, que reconhecem o potencial dos VEs para reduzir as emissões de gases de efeito estufa (Hasan, 2021).

É fundamental destacar que esta transição é complexa, lenta e envolve um conjunto de variáveis incertas e voláteis relacionadas à forma como os veículos elétricos plugáveis (VEPs) são integrados ao sistema elétrico de potência existente. Com o aumento generalizado da demanda por carregamento dos VEPs, o setor energético precisará investir esforços no gerenciamento destas cargas, não apenas para garantir que todas as novas demandas energéticas possam ser atendidas, mas também para lidar com as características temporais da curva de carregamento dos VEPs e os custos resultantes da manutenção destas cargas (Mills; Macgill, 2014).

Atualmente, os sistemas de distribuição de energia elétrica (SDEE) enfrentam desafios devido ao aumento das demandas relacionadas a aspectos sociais, tecnológicos e ambientais. Isso exige que as empresas de distribuição de energia elétrica estejam prontas para atender às expectativas dos consumidores, garantindo uma operação eficiente e segura, além de atender a metas de

sustentabilidade ambiental (Ipakchi; Albuyeh, 2009).

O rápido crescimento no uso dos VEPs representa um novo desafio não apenas para o sistema de geração de energia elétrica, mas também para os sistemas de transmissão e distribuição. O planejamento dessa nova demanda torna-se essencial, incluindo a projeção da expansão, o planejamento e a operação do sistema. Para assegurar uma gestão energética eficaz diante dessas novas demandas, é crucial adotar critérios de adequação e procedimentos de gestão específicos, além de investigar as perturbações causadas pela inserção dos VEPs (Aliasghari et al., 2018).

Em relação ao sistema elétrico de potência, os VEPs alteram o padrão de demanda energética nos setores residencial, industrial, comercial e público, resultando em um aumento geral na necessidade de geração de energia elétrica. Este acréscimo pode comprometer a eficiência energética e a segurança do abastecimento. Por causa das características de uso, podem surgir situações específicas que impactem a rede de transmissão, como o congestionamento causado por recargas simultâneas dos VEPs (Hartmann; Özdemir, 2011).

A elevada taxa de adoção dos VEPs pode provocar alterações expressivas nos perfis de demanda em nível sistêmico, impactando diretamente a programação e geração de energia elétrica. Isto ocorre porque o padrão de carregamento dos VEPs está fortemente correlacionado com diversos perfis de usuários, que, por exemplo, compartilham horários de trabalho, horários de almoço, grandes eventos, períodos escolares e férias (Fathabadi, 2017).

A demanda de carregamento descontrolado dos VEPs e veículos elétricos híbridos plugáveis (VEHPs) impactará o sistema elétrico de diversas maneiras. O principal fator é o aumento significativo da demanda adicional para o carregamento das baterias, que geralmente ocorre em ambientes residenciais e em estações de carregamento. À medida que o uso dos VEPs cresce, haverá também um aumento nos carregamentos simultâneos em residências e estações de recarga (Muratori, 2018).

No nível da rede de distribuição, esta nova demanda gerada pelos VEPs pode provocar quedas de tensão, sobrecargas nos componentes da rede e violação dos limites operacionais, além de causar aumentos descontrolados das cargas e picos (Turker; Bacha, 2018). A introdução do carregamento de VEPs na demanda elétrica residencial resultará em um grande acréscimo de potência, impactando diretamente a infraestrutura de geração e transmissão de energia (Muratori, 2018).

Uma das estratégias para garantir que a demanda energética atenda ao consumo é realizar previsões de cargas elétricas no sistema de energia com antecedência de algumas horas. Isto proporciona vantagens econômicas, estratégicas e operacionais. As previsões desempenham um papel crucial ao influenciar diretamente decisões operacionais importantes, como despacho de energia, compromissos de unidade, programação de manutenção e novas projeções energéticas (El-Sharkawi; Marks; Weerasooriya, 1991).

A busca pela previsão da demanda de carregamento dos VEPs tornou-se um tema atraente na pesquisa acadêmica, em concessionárias de eletromobilidade e no setor comercial da engenharia elétrica. Realizar previsões de carga a curto prazo no mercado de energia elétrica é cada

vez mais crucial e desafiador para garantir competitividade econômica. A previsão de cargas, tanto convencionais quanto dos VEPs, não é uma tarefa simples, pois envolve diversos fatores, como o horário de carregamento, condições climáticas, sazonalidades, variabilidades aleatórias, comportamento humano, flutuações, alta periodicidade e volatilidade (Hippert; Pedreira; Souza, 2001).

Existem diversas técnicas de modelagem disponíveis para a previsão de cargas elétricas. Normalmente, as técnicas empregadas na previsão incluem métodos de séries temporais, técnicas estruturais (Ringwood; Bofelli; Murray, 2001), métodos bayesianos (Guinel, 1987), métodos de Box-Jenkins (Watson; Pastuszek; Cody, 1987), lógica fuzzy (Al-Anbuky; Bataineh; Al-Aqtash, 1995) e redes neurais artificiais (RNAs) (Park et al., 1991).

No que diz respeito ao método das RNAs, a maior parte das pesquisas na literatura aborda questões de previsão de perfis de demanda diária ou picos diários. As RNAs são empregadas para prever a demanda máxima e também para prever as demandas em um período de 24 horas (Asar; McDonald; Khan, 1992) (Lee et al., 1993) (Kermanshahi; Iwamiya, 2002).

A aplicação de métodos de Inteligência Artificial (IA) com RNAs possibilita a solução eficaz de questões como a previsão de cargas futuras, uma vez que as RNAs aprendem com padrões passados e armazenam essas informações para uso futuro, com projeções futuras (Haykin, 1998).

Cargas elétricas residenciais, comerciais e informações sobre as cargas durante o carregamento dos VEPs são dados que apresentam muita instabilidade, são ruidosos e podem apresentar inconsistências. As informações do mundo real sobre o carregamento dos VEPs, as cargas elétricas em residências e comerciais são frequentemente instáveis, ruidosas e inconsistentes, apresentando algumas tendências e comportamentos lineares, o que dificulta o processo de previsão. O carregamento de informações incorretas pode resultar em erros no processamento de dados e no processo de previsão quando não há pré-processamento (Pecht; Kang, 2018).

Com isto, o pré-processamento é uma das técnicas mais significativas em séries temporais e aprendizado de máquina. Portanto, esta etapa deve ser realizada antes de ser inserida no modelo sugerido. No âmbito da ciência de dados, o pré-processamento é uma etapa necessária, complexa e extensa de todo o processo, visando aprimorar as informações dos dados e diminuir suas complexidades (Ramírez-Gallego et al., 2017).

Assim, o pré-processamento no aprendizado de máquina é importante para compreender o comportamento dos dados, extrair informações pertinentes e, posteriormente, processá-los conforme o método sugerido. Em geral, o pré-processamento engloba a limpeza dos dados, normalização e padronização, eliminação de tendências e sazonalidades, obtenção de informações, filtragem e ajustes dos dados (Liu et al., 2019).

1.1 OBJETIVOS E CONTRIBUIÇÕES

Com isto em mente, esta tese sugere a aplicação de três pré-processamentos: transformada wavelets, filtro digital Savitzky-Golay e análise de espectro singular, visando suavizar as cargas

elétricas dos bancos de dados originais.

A tese aborda e sugere analisar as previsões não somente nas cargas dos VEPs, mas também nos ambientes onde eles são carregados, já que, na maioria da literatura, apresentam essa lacuna e abordam somente as cargas dos VEPs. E ainda nesta, foram analisados dois ambientes distintos para explorar e prever estas demandas. Gerando previsões de nível 1 e 2 de potência para o ambiente residencial e previsões de estação de carregamento com 350 kW de potência.

Os bancos de dados analisados apresentam alta quantidade de cargas e são de grande porte, com dados realistas e alto grau de validação. Os dados apresentam naturezas com medições das cargas dos VEs de maneira aleatória, ruidosas, sem padrões, com carregamentos descontrolados, para os dois ambientes propostos. A pesquisa busca preencher essa lacuna e resolver estes problemas, sendo uma exploração e uma nova abordagem para a previsão desta nova demanda total.

A tese realizou uma abordagem sólida para prever a demanda total resultante do carregamento dos VEPs nas residências e nas estações de carregamento durante um período de 24 horas, proposta por dois bancos de dados distintos. Este estudo atingiu um ajuste ideal ao tentar afinar o modelo aos dados analisados, obtendo um aprendizado profundo com três camadas ocultas com poucos neurônios por camada, o que levou a um custo computacional reduzido e a uma rápida convergência.

A utilização de um treinamento híbrido de *backpropagation* através do tempo (BPAT) com regularização bayesiana (RB) é sugerida para melhorar a qualidade do aprendizado profundo do perceptron multicamada recorrente (MLPR). Este método enfatiza a procura por novas informações ocultas em suas camadas, juntamente com a recorrência dos vetores de treinamento.

O trabalho tem como objetivo principal aprimorar o processo de previsão nos dois ambientes propostos. Outro objetivo é contornar e melhorar o processo de treinamento BPAT clássico, que apresenta muitas limitações. Com isto, preparar os dados com pré-processamento para melhorar o processo de aprendizagem.

E, por fim, o trabalho também apresenta uma análise com vários estudos sobre os possíveis impactos negativos que os VEs causam no cenário energético, em diversos cenários.

2 IMPACTOS DOS VEÍCULOS ELÉTRICOS PLUGÁVEIS NO SISTEMA DE ENERGIA ELÉTRICA

Pode-se entender como VEs todo transporte que tem como fonte de energia para se locomover a eletricidade e funciona com motores elétricos ou baterias para armazenar cargas carregadas ou convertidas. Existem atualmente vários transportes que utilizam eletricidade para se mover, tais como automóveis, motocicletas, patinetes, trem, bicicletas, ônibus, caminhões e até aviões e navios (Guarnieri, 2011).

O início dos VEs, mesmo que possa parecer recente, ocorreu em meados de 1830. Os primeiros testes feitos objetivavam obter movimentos por eletricidade. Nesta época, os VEs eram muito rudimentares e limitados ao seu tempo, com baterias de baixa eficiência e alcance. Mas o grande impulso na eficiência dos VEs em termos de motores elétricos de corrente contínua aconteceu na França em meados de 1873, com baterias de chumbo totalmente recarregáveis (Guarnieri, 2011).

Poucos anos depois, as baterias e os veículos já eram comercializados na Europa, e um dos seus primeiros usos foi nas carruagens, que antes eram movidas por tração animal. Em 1889, a fabricante belga de armas, chamada PIEPER, começou a produção de carruagens elétricas e depois alguns produziram o primeiro veículo híbrido conhecido como carro híbrido paralelo (Guarnieri, 2011).

Mesmo com estes avanços, os VEs não alcançaram sucesso de comercialização, somente no final dos anos 1900 despontaram como sucesso de vendas, com carros que podiam transportar até seis passageiros a uma velocidade de 16 km/h. Logo depois, introduziu-se a primeira frenagem regenerativa, que podia recarregar as baterias dos VEs. Com isso, a França, na época, se tornou a maior fabricante de automóveis elétricos do mundo e assim permaneceu até 1904, quando foi superada pelos Estados Unidos da América (Guarnieri, 2011).

As indústrias dos Estados Unidos da América, da época, estavam muito dedicadas à produção de VEs, o que levou a um grande crescimento na disseminação do setor de transporte elétrico em 1880. Esse cenário acelerou a criação de novas redes elétricas comerciais em corrente contínua, introduzidas por Thomas Edison, que formavam as infraestruturas das redes para carregamento das baterias dos VEs (Guarnieri, 2011).

Os VEs, nesta época, já eram um polo industrial muito forte no cenário de transporte americano, chegando a eletrificar os táxis de Nova York, e justamente de 1900 a 1910, Thomas Edison projetou sua primeira bateria alcalina de níquel-ferro, chegando a ser a bateria mais leve do século XX. Neste cenário, o transporte elétrico atinge seu auge de sucesso até então, e o transporte americano era composto por 40% de veículos a vapor, 22% de veículos a gasolina e 38% de VEs (Guarnieri, 2011).

Pode-se elencar vantagens e desvantagens para cada um destes tipos de veículos, na época. Os VEs eram bem mais silenciosos que os carros a gasolina e a vapor, sem emissão de gases,

confiáveis, de mais simples condução, não precisavam de trocas de marchas e eram mais fáceis para dar partida. Em contrapartida, os VEs eram lentos em comparação aos outros meios e também de baixo alcance, mas com a introdução de baterias removíveis, em 1910, tornou-se mais fácil o acesso a recargas rápidas (Guarnieri, 2011).

Os VEs eram tidos como artigos de luxo na época, custando mais que o dobro dos veículos a combustão. Os VEs atingiram seu pico de produção em 1912, com valores de mercado que variavam de 1750 a 3000 dólares, enquanto o modelo básico Ford a gasolina custava cerca de 650 dólares (Guarnieri, 2011).

A indústria de automóveis estava crescendo de forma acelerada; as tecnologias, economias e o meio ambiente passavam por transformações. Iniciando a década de 1920, as rodovias começam a se expandir e conectar as cidades estadunidenses. Com o surgimento de estradas longas e pavimentadas, a nova estrutura necessitava de veículos com maior autonomia e alcance, e, paralelamente a esse cenário, dava-se a descoberta de grandes reservas petrolíferas em solo estadunidense. Com isso, a nova abundante fonte de combustíveis, a gasolina, teve seu preço reduzido significativamente e se tornou um combustível mais acessível. Por consequência, os preços dos veículos a combustão também foram reduzidos e começaram a ser fabricados em linhas de produção em larga escala (Guarnieri, 2011).

Os veículos a gasolina se tornaram então mais confiáveis e confortáveis devido a seus avanços tecnológicos, mas ainda tinham um problema de partida no motor de combustão interna, que depois foi solucionado com a inserção da partida elétrica. Com isso, garantiu-se a total difusão e domínio dos veículos a gasolina no mercado, o que foi de grande contribuição para a queda da utilização e da fabricação dos VEs (Guarnieri, 2011).

Com o passar dos anos, após 1920, os VEs começaram gradualmente a perder relevância e praticamente desapareceram do cenário de transporte, permanecendo somente para serviços de transporte com alcance limitado, como carrinhos de golfe, pequenas entregas e empilhadeiras (Guarnieri, 2011).

Recentemente, para promover e incentivar o uso de VEs, governos e grandes montadoras globais estão empenhados em adotar novas tecnologias em eletromobilidade. Nos últimos 20 anos, o uso de VEs aumentou de forma acelerada e continua em ritmo crescente, com uma tendência de crescimento exponencial e de se tornar globalizado (Cui; Hall; Lutsey, 2020).

Esta nova crescente dos VEs voltou a ter relevância devido a seus impactos e desafios por se tornar um novo cenário para o sistema elétrico atual projetado. Sabe-se que a adoção em larga escala de VEs trará impactos econômicos, energéticos e de infraestruturas (Richardson, 2013). Em primeiro lugar, do ponto de vista do sistema de energia elétrica, haverá um aumento significativo na demanda por potência de carregamento, o que exigirá uma maior capacidade de geração de energia elétrica (Talebizadeh; Abdollahi, 2014).

2.1 CARREGAMENTO DESCONTROLADOS DE VEÍCULOS ELÉTRICOS PLUGÁVEIS

Chamado na literatura com o termo em inglês "$DumbCharging$", podendo ter várias traduções como carregamento simples, apresenta com a integração máxima dos VEPs à rede elétrica tanto residencial quanto estação de carregamento sem que haja qualquer tipo de controle sobre o carregamento realizado, com total liberdade dos usuários. As cargas dos VEPs começam automaticamente quando plugados a tomadas, durante várias horas (Lopes; Soares; Almeida, 2011).

Este método de carregamento é considerado o mais simples e econômico para carregar os VEPs, sendo o mais utilizado atualmente. No entanto, os VEPs são conectados de forma aleatória, não apresentando horário e estratégias para carregar; a potência máxima fornecida pelo carregador é entregue sem interrupções durante o processo de carga. O fluxo de energia permanece constante até que as baterias estejam completamente carregadas, momento em que o VEP é desconectado da rede elétrica. Este carregamento descontrolado causa impactos negativos significativos nas redes de distribuição, como aumento das cargas de pico sobre a demanda base, redução da vida útil de transformadores e cabos devido a sobrecargas, maior incidência de quedas de tensão, aumento do desequilíbrio do sistema por conta do carregamento em conexões monofásicas, além de perdas de potência e distorções harmônicas (Shareef; Islam; Mohamed, 2016) (Alshahrani; Khalid; Almuhaini, 2019).

É esperado que o carregamento descontrolado em altos níveis de potência e taxas de penetração represente impactos negativos ao sistema de energia elétrica. Estes impactos são variados e geram possíveis problemas no sistema devido ao aumento da demanda base, aumento da demanda de pico, desvios de tensões dos limites aceitáveis, desequilíbrio de fase aos carregamentos monofásicos, injeções de harmônicos, sobrecargas dos equipamentos do sistema elétrico, aumento de potência e perdas de potência do sistema (Habib et al., 2018).

Este tipo de carregamento restringe o nível aceitável de penetração dos VEPs, já que a maioria dos proprietários recarrega seus veículos em casa, geralmente após o expediente, coincidindo com o horário de pico da demanda residencial. Com as novas conexões dos VEPs à rede de distribuição, a demanda total sofrerá alterações (Papathanassiou; Strunz, 2005). Além disto, este modelo de carregamento requer atualizações e modificações nas infraestruturas e arquiteturas existentes.

2.2 ESTUDOS SOBRE IMPACTOS DOS CARREGAMENTOS RESIDENCIAIS DE VEPS AO SISTEMA DE ENERGIA ELÉTRICA

Vários estudos realizam a avaliação dos impactos dos carregamentos dos VEs no pico de demanda e dos perfis das cargas elétricas no sistema de distribuição. Nesta seção serão explorados estudos para exemplificar os impactos negativos em diferentes redes de distribuição, de vários países, com diferentes arquiteturas e características distintas.

O carregamento descontrolado em altos níveis de potência e taxas de penetração pode ter efeitos adversos no sistema de energia elétrica. Estes impactos são diversos e podem causar problemas no sistema, como aumento da demanda base, elevação da demanda de pico, variações de tensão fora dos limites aceitáveis, desequilíbrios de fase em cargas monofásicas, injeções de harmônicos, sobrecargas nos equipamentos do sistema elétrico, além do aumento de potência e perdas no sistema (Habib et al., 2018).

Existem muitos estudos que analisam estes impactos. Os efeitos dos carregamentos de VEPs dependem de diversas condições e apresentam várias incertezas que devem ser devidamente abordadas e modeladas (Bohn; Feustel; Agsten, 2015) (Ahmadian; Mohammadi-ivatloo; Elkamel, 2020).

Um exemplo disto é apresentado em (Wang; Paranjape, 2015), onde o pico de demanda base aumentou em 53% quando foi utilizado o carregamento descontrolado dos VEPs, com apenas uma taxa de penetração de 30%. Já em (McCarthy; Wolfs, 2011), foram analisados os efeitos do carregamento descontrolado de VEPs leves com até 100% de penetração, e os resultados indicaram um aumento significativo na demanda de pico.

Em um estudo recente (Crozier; Morstyn; McCulloch, 2020), que analisou os impactos do carregamento descontrolado de VEPs no sistema elétrico da Inglaterra, considerou-se a adoção do carregamento controlado no cenário estudado. Para o nível de distribuição, uma taxa de penetração de 100% exigirá um aumento de 28% na capacidade de potência. Além disto, com esta mesma taxa de penetração, verificou-se que a demanda de pico aumentou em 8 GW nos níveis de geração e transmissão de energia elétrica.

Em (Kelly; Rowe; Wild, 2009), foi avaliado o impacto do carregamento descontrolado de VEs na demanda elétrica total em três redes de distribuição, urbana, suburbana e rural, com várias capacidades diferentes. Essa análise considerou uma taxa de penetração de até 25%. O estudo demonstrou que para a taxa mais alta, a demanda de pico aumentou 9% para redes urbanas e rurais e 11% para a rede suburbana. Foi concluído que esse aumento fez com que a rede rural ultrapassasse o limite de capacidade máxima, porém as redes urbanas e suburbanas não o ultrapassaram.

Em outro estudo (Drovtar et al., 2013), foi analisado o sistema elétrico da Estônia com uma taxa de penetração de 30%. As análises indicaram um aumento de 5% na carga de pico com o carregamento descontrolado e de 4% com o carregamento controlado.

Em (Schneider et al., 2008), observou-se que o carregamento rápido dos VEPs durante períodos de pico fez com que os limites do equipamento fossem ultrapassados, mesmo com uma baixa taxa de penetração dos VEPs. Contudo, verificou-se que o carregamento lento nos períodos de pico permitia que a rede de distribuição suportasse até 50% da taxa de penetração sem exceder os limites dos equipamentos.

Em um estudo recente (Crozier; Morstyn; McCulloch, 2020) que avaliou os impactos do carregamento descontrolado de VEPs no sistema elétrico da Inglaterra, foi considerada a implementação do carregamento controlado no cenário analisado. O estudo adotou uma taxa

de penetração de 100% e constatou que a demanda de pico aumentou em 8 GW no nível de geração e transmissão de potência. No que diz respeito ao nível de distribuição, com uma taxa de penetração de 100%, será necessário um incremento de 28% na potência.

Em (Gray; Morsi, 2014), são apresentados os efeitos dos carregamentos descontrolados de VEPs em transformadores da rede de distribuição com potências nominais de 25 kVA e 50 kVA. A análise englobou duas taxas de penetração, 30% e 50%, para os tipos VEP e VEHP nos carregamentos de níveis 1 e 2 de potência. Os resultados indicam que a taxa de penetração de 50% resultou em sobrecarga de 50% dos transformadores de 25 kVA e 35% dos transformadores de 50 kVA. Ademais, os VEPs com carregamento nos níveis 1 e 2 provocaram um aumento de 10% no número de transformadores sobrecarregados em comparação com os VEHP no nível 1.

A nova demanda adicional provocada pelo carregamento dos VEPs resultará em potências mais elevadas e perdas extras de energia em diversos componentes do sistema elétrico, como transformadores, cabos e geradores. Isto será uma das principais preocupações das concessionárias (Habib et al., 2018).

Em (Fernández et al., 2011), foram analisados os impactos do carregamento descontrolado dos VEPs em um sistema de distribuição de grande porte, considerando três taxas de penetração: 35%, 51% e 62%. As cargas dos VEPs geraram um aumento significativo nas perdas de energia e no custo de investimento requerido.

No artigo (Pillai; Bak-Jensen, 2010), foram analisados os impactos em uma rede de distribuição na Dinamarca. Os dados coletados indicaram que, com uma taxa de penetração de 50%, o carregamento descontrolado resultou em um aumento de 40% nas perdas energéticas da rede, enquanto o carregamento controlado provocou um aumento de apenas 10%.

No artigo (Masoum; Moses; Smedley, 2011), foi investigado o impacto do carregamento dos VEPs nas perdas de potência dos transformadores de distribuição. Os resultados mostraram que as perdas nos transformadores superaram 300%, com taxas de penetração variando de 2% a 40%.

Em (Chang et al., 2019), foram analisados os aumentos das perdas energéticas em uma rede de distribuição que atende cargas residenciais e comerciais na Coreia. Os resultados indicaram que as perdas diárias aumentaram em 66% com uma taxa de penetração de 40% de VEPs.

No artigo (Dharmakeerthi; Mithulananthan; Saha, 2014), foi investigada a estabilidade de tensão em um sistema de distribuição com 43 barras do Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE). Os resultados mostraram que a estabilidade de tensão da rede de distribuição foi significativamente afetada, sendo altamente reduzida pelo uso do carregamento rápido dos VEPs.

Em (Clement-Nyns; Haesen; Driesen, 2010), foi avaliado o impacto do carregamento descontrolado no desvio de tensão em diferentes horários do dia. Os resultados mostraram um aumento significativo no desvio de tensão, que se aproximou de ultrapassar os limites aceitáveis, especialmente durante o horário de pico de carregamento dos VEPs. O estudo propõe estratégias de programação estocástica para minimizar esses desvios de tensão.

Alguns estudos indicam que as cargas dos VEPs têm efeitos tanto significativos quanto

não significativos na distorção harmônica. No estudo de (Jiang et al., 2014), foram utilizados métodos de Monte Carlo para implementar os harmônicos, e os resultados mostraram que a rede de distribuição sofreu um impacto pequeno.

No artigo de (Nguyen; Tran-Quoc; Seddik, 2013), a distorção harmônica da tensão aumentou para 11,4% devido ao carregamento descontrolado, ultrapassando assim o limite de 8% estabelecido por norma.

Analisando todos esses estudos anteriores, fica bem claro que a integração maciça do carregamento descontrolado de VEPs levará a um aumento significativo e expressivo na demanda de pico. Estes aumentos resultarão em maiores problemas ao sistema elétrico, que poderá aumentar os custos de operação devido ao novo perfil de geração ser mais caro nos horários de pico. Foi possível observar que o carregamento com atraso e o carregamento controlado são eficazes para minimizar o aumento da demanda de pico gerada pelos VEs e os impactos negativos associados, permitindo um número maior de taxas de penetração de VEs.

2.3 IMPACTOS DA ESTAÇÃO DE CARREGAMENTO DOS VEPS NO SISTEMA ELÉTRICO

Os impactos negativos das estações de carregamento de VEPs na rede de distribuição elétrica têm grande expressão no setor energético. As altas cargas geradas pelos VEs resultam em maiores demandas de carga de pico, margens de reserva reduzidas, instabilidade de tensão e problemas de confiabilidade. Observa-se que sistemas de potência com barras robustas podem suportar um maior número de instalações de estações de carregamento em níveis de potência mais elevados. Já em barras mais fracas, o sistema pode apresentar dificuldades de operação para um bom funcionamento e estabilidade (Deb et al., 2018).

Neste sentido, o desenvolvimento da arquitetura e infraestrutura de carregamento tornou-se indispensável para o uso necessário e eficiente de transferência de potência (Alam et al., 2017), para atender a todos os requisitos energéticos de operação dos VEs (Foley et al., 2010).

A instalação de uma estação de carregamento impõe cargas de alta potência adicionais à rede elétrica e pode degradar os parâmetros operacionais da rede de distribuição. Estes impactos negativos podem degradar o perfil de tensão, aumentar a carga de pico, causar distorções harmônicas, entre outros efeitos aos dispositivos da rede de distribuição. Vários estudos demonstram o impacto negativo das cargas dos VEs em diversos parâmetros da rede de distribuição (Geske et al., 2010), (Zhang et al., 2016), (McCarthy; Wolfs, 2011).

O estudo de (Geske et al., 2010) analisa o impacto de uma estação de carregamento dos VEs em uma rede elétrica de distribuição de baixa tensão na Europa, com diferentes taxas de penetração dos VEs. Os resultados mostram que a rede era robusta apenas para suportar uma pequena taxa de penetração de até 2%. Porém, observou-se que o perfil de tensão onde as cargas foram inseridas resultou na degradação em certa medida e as altas cargas dos VEs causaram degradação no perfil de tensão dos barramentos mais fracos da rede elétrica.

No estudo de (Zhang et al., 2016) foram analisados os impactos das cargas dos VEs em uma rede de distribuição com 14 barras. Os autores concluíram que o índice de estabilidade de tensão transitória degradou com a alta taxa de penetração dos VEs.

Em (Dharmakeerthi; Mithulananthan; Saha, 2014), (Zhang et al., 2016), foram analisados os impactos do carregamento de VEs na instabilidade da rede de distribuição elétrica. Foi observado que a maioria das redes de distribuição poderia suportar uma certa taxa de penetração dos VEs, mas as redes, que foram projetadas há uma década, não estão preparadas para uma expansão da integração dos VEs em larga escala.

Em (Gomez; Morcos, 2003), foi analisada a influência das cargas dos VEs na qualidade de energia do sistema de distribuição e os resultados apontaram que o ciclo de vida dos ativos da rede de distribuição foi reduzido pela distorção harmônica produzida pelas cargas dos VEs.

No estudo de (Basu; Gaughan; Coyle, 2004), as cargas dos VEs geraram distorção harmônica de até 50% nos casos mais extremos. Em (Jiang et al., 2014), foram simulados dados de harmônicos causados por VEHPs pelo método de Monte Carlo probabilístico. Os resultados mostraram que o nível 1 de potência resultou em um grave impacto na qualidade da energia.

Em (McCarthy; Wolfs, 2011), foram examinados os efeitos das cargas dos VEHPs na rede de distribuição metropolitana austríaca e os resultados mostraram que, com carregamento descoordenado com 100% de taxa de penetração dos VEs, foi necessário 43% de deslocamento de carga de pico para a rede de distribuição funcionar normalmente.

No estudo de (Sehar; Rahman; Pipattanasomporn, 2012), os pesquisadores analisaram os impactos de VEs na demanda de carga de um edifício de varejo e os resultados apontam que 38% da demanda de carga de VEHPs poderia ser integrada pelo gerenciamento de demanda e energia fotovoltaica.

3 ESTUDO SOBRE PREVISÕES DE CARGAS ELÉTRICAS

Atualmente, existe uma alta necessidade de fornecimento sem interrupção de energia elétrica no cenário das usinas modernas, devida à alta demanda global energética requerida. Isso acaba gerando uma necessidade de previsões adequadas sobre as demandas de cargas elétricas atuais e futuras com baixo erro de projeção. A busca desse objetivo na área acadêmica científica, a literatura tenta desenvolver métodos opcionais e com mais eficiência, chamados de previsão de carga, objetivando a projeção futura destas cargas elétricas. Muitas decisões, como despacho e alocações de combustíveis, comprometimento com concessionárias, diversas operações e rede $off - line$, são diretamente ligadas e controladas pela previsão de carga (Bunn, 2000).

Isso fornece um conceito estratégico às concessionárias de energia sobre a demanda de eletricidade futura e no tempo atual, com o objetivo de reduzir a diferença entre a demanda prevista e a energia consumida. O papel da previsão de carga é reduzir o custo operacional de geração de energia e apoiar na organização do sistema. Existem diversas técnicas baseadas em aprendizado de máquina que são utilizadas pelas empresas de energia elétrica para adequar a demanda e a geração, prevendo a demanda de potência necessária. A técnica de previsão de cargas serve para gerenciar a oferta e a demanda destas cargas; no entanto, essa tarefa não é fácil; é necessária a análise de diferentes fatores diretos e indiretos. Embora esta técnica apresente muitos benefícios em previsão de carga, há um certo desafio em termos de precisão de cada modelo proposto (Hippert; Pedreira; Souza, 2001).

O processo de previsão é uma tarefa complexa; os dados sofrem influência devido à diversos fatores como, por exemplo, fatores climáticos e sociais. As cargas atuais dependem da carga na hora anterior, da carga do dia anterior, dos dados demográficos, das condições climáticas, dos dados econômicos, dos números de clientes e do tipo de cliente. Portanto, é essencial manter previsões de baixos erros; métricas de medidas como Erro Absoluto Médio (MSE), Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio (MAPE) são de grande importância e determinam a precisão das previsões de cargas (Ahmad et al., 2022).

Para a avaliação de um determinado algoritmo, os valores devem ser mantidos dentro de uma faixa de poucos erros percentuais, com erros inferiores a 10% e mais eficientes inferiores a 5%. O fator-chave do modelo de previsão de carga elétrica é o conjunto de dados de carga. Para treinar o modelo, é necessário conhecer o padrão de consumo dos dados de carga. A previsão precisa e exata das cargas elétricas pode gerar muito lucro para as concessionárias de energia, porém, erros percentuais elevados e desnecessários podem causar perdas de infraestrutura e grandes prejuízos financeiros (Ahmad et al., 2022).

Os autores Haida e Muto et al. (Haida; Muto, 1994) descreveram que erros negativos e positivos nas previsões podem aumentar o custo da eletricidade. Apenas uma redução de 1% no (MAPE) deixa um impacto de 3% a 5% no lado da produção, minimizando o custo de geração de 0,1% a 0,3% (Gao et al., 2019).

As redes inteligentes são redes de distribuição e transmissão de eletricidade modernas, com uma comunicação mais rápida e precisa. A segurança, confiabilidade, eficiência e precisão da rede são desenvolvidas através do uso de controle, tecnologias, rede de comunicação e informações modernas. O planejamento e a operação do sistema de energia elétrica dependem fortemente do processo de previsão de carga. Em termos de horizonte temporal de planejamento, a previsão de carga é dividida em curtíssimo prazo, curto prazo, médio prazo e longo prazo (Powell et al., 2024).

Há algumas décadas, muitos pesquisadores buscam aprimorar os lucros e a eficiência energética das concessionárias de distribuição e geração de energia, resultando em modelos preditivos cada vez mais precisos. Os avanços científicos sobre previsão resultaram na criação de diversos métodos de última geração até agora. O fornecimento e a transmissão econômicos podem ser viabilizados por meio de previsões da demanda energética. O consumo excessivo ou insuficiente da capacidade de produção pode ser evitado com boas estratégias e melhorias de previsão. O grande objetivo das previsões é ajudar a utilizar da melhor forma possível a otimização e a capacidade de eletricidade. Com isso, as instalações de futuras usinas podem ser feita com mais precisão baseadas nos resultados previstos desta demanda futura de consumo e auxiliar a tomada de decisão humana (Ahmad et al., 2022).

Recentemente, os pesquisadores tiveram que enfrentar diferentes desafios para melhorar a exatidão e a precisão desses modelos. Pode-se destacar alguns, como mudanças bruscas nos preços e nas demandas energéticas que dificultam a previsão, dificuldades para encontrar e investigar os melhores modelos de previsão em séries temporais, as mudanças climáticas repentinas e imprevisíveis, que podem causar erros nas previsões de cargas e gerar impactos negativos na eficiência energética (Ahmad et al., 2022).

Além destas dificuldades, falhas inesperadas nos sistemas de geração de energia provocam ineficiência e deixam as previsões pouco confiáveis e com deficiência, e, por fim, as concessionárias de energia podem ter que lidar com médias e grandes perdas caso não se entendem e fazem escolhas em relação a um nível tolerável de falha nas previsões de demanda de curto prazo (Ahmad et al., 2022).

3.1 CATEGORIAS DE PREVISÃO DE CARGAS ELÉTRICAS

Recentemente, na literatura, vários trabalhos realizam revisões focando na resolução de problemas nas previsões de carregamento dos VEPs.

Pode-se destacar dois grandes grupos, sendo os principais (Hippert; Pedreira; Souza, 2001), quando citados em métodos de previsão de cargas elétricas, os métodos classificados e baseados em inteligência artificial. Como anteriormente foram citados alguns aspectos em diferentes características que afetam as previsões de cargas, como aspectos econômicos, tipos de clientes, população, indicadores, fatores temporais, condições climáticas, novas tecnologias e preços de energia (Amjady, 2001). As abordagens clássicas, como métodos estatísticos, são usadas para

prever o futuro (Singh; Ibraheem; Muazzam, 2013). Métodos de mínimos quadrados, regressão linear e suavização exponencial apresentam-se como ferramentas clássicas de previsão de cargas (Ghods; Kalantar, 2011).

É possível citar métodos computacionais em inteligência artificial; podendo destacar RNAs, máquinas de vetores de suporte (SVM), redes de wavelets, algoritmos genéticos e lógica fuzzy (Ghods; Kalantar, 2011). É válido ressaltar que a dependência do modelo de previsão baseado na análise matemática é dividida em dois grupos: métodos quantitativos, em que a previsão futura é relacionada a uma base de dados no passado; portanto, somente é válida quando há disponibilidade de dados passados. E para métodos qualitativos, é fortemente dependente do julgamento e da opinião de especialistas e consumidores, pois neste caso não há disponibilidade de uma base de dados no passado (Singh; Ibraheem; Muazzam, 2013).

3.2 PREVISÃO DE CARREGAMENTO DE VEÍCULOS ELÉTRICOS PLUGÁVEIS

A adoção acelerada de VEPs levou à alta implantação de novas tecnologias e infraestruturas de estação de carregamento e de carregamento residencial, devido à necessidade de autonomia, porém, junto a isso, torna-se um grande desafio. No ano de 2023, o cenário demonstrou que a frota dos VEPs necessitou de aproximadamente 130 TWh de potência, o que representou cerca de 0,5% do consumo de potência total do mundo (International Energy Agency (IEA), 2023). É projetado que até 2035 os VEPs possam consumir até 2.700 TWh de potência, chegando de 6% a 8% da demanda total de energia elétrica. Os dados mostram também que os EUA devem ter um incremento acentuado da demanda de potência em 2035, passando de 0,6% em 2023 para 15,6% em 2035 (International Energy Agency (IEA), 2023).

O sistema elétrico de potência existente, especialmente o sistema de distribuição, é fortemente afetado pela alta taxa de penetração dos VEPs. A qualidade da energia elétrica pode ser comprometida pela adoção generalizada de VEPS, devido a seus efeitos negativos citados anteriormente. O carregamento simultâneo em grande escala dos VEPs durante os horários de pico certamente irá degradar o sistema atual, que pode ser melhorado por um planejamento e adequações das infraestruturas de carregamento. A previsão desta demanda de carga de VEPs fornece uma base de dados teórica para este novo planejamento e melhoras nas infraestruturas da rede elétrica, com novas ideias sobre os padrões de carga futuros (Chen, 2018).

Este tema, mesmo que possa parecer atual, já apresenta vários desafios no setor energético há anos; a previsão da demanda de carregamento de VEPs demonstra ser um desafio muito versátil e complexo, que apresenta uma demanda de natureza estocástica e uma escassez de dados públicos disponíveis (Chen, 2018). Além desta natureza das cargas, este perfil demonstra uma variabilidade espacial e temporal altamente introduzida no cenário energético atual e com complexidade significativa, influenciada por fatores como condições climáticas, padrões de tráfego e infraestrutura de recargas diretas entre regiões (Koohfar; Woldemariam; Kumar, 2023).

A maioria da literatura atual aborda esses desafios utilizando métodos probabilísticos ou

baseados em dados reais, simulação de Monte Carlo (Rasheed et al., 2023), teoria de filas (Dong et al., 2016) e cadeia de Markov (Zhang et al., 2016), todos estes métodos utilizados na previsão de demanda de carregamento de VEPs. Embora haja falta de dados reais da demanda dos VEPs, os métodos probabilísticos apresentam-se eficazes na geração desta demanda de carregamento, devido à sua natureza estocástica. Portanto, esses métodos são totalmente dependentes de amostras aleatórias para se aproximar do comportamento real (Rasheed et al., 2023).

Entretanto, a precisão da previsão pode ser comprometida devido às cargas serem totalmente aleatórias e desviarem-se da demanda real do sistema. Além disso, esses métodos probabilísticos são custosos em termos computacionais, o que acaba se tornando inviável quando abordados em grandes escalas e grande porte. Quando comparadas às abordagens probabilísticas, as abordagens baseadas em dados históricos reais dos VEPs demonstram maior capacidade de precisão e flexibilidade (Xing et al., 2020). Métodos como regressão estatística, aprendizado profundo e aprendizado de máquina apontam ser eficazes na extração de padrões e relações de dados históricos no processo de previsão das demandas de carregamento futuras dos VEPs. Os métodos baseados em dados históricos possuem a capacidade de entender e capturar as dinâmicas de cada ambiente específico, como o perfil residencial e a estação de carregamento dos VEPs, gerando, assim, previsões mais realistas e precisas (Goh et al., 2022).

3.3 APLICAÇÕES DE APRENDIZADO DE MÁQUINA NA PREVISÃO DA DEMANDA POR CARREGAMENTO DE VEPS

Embora o processo de previsão de cargas elétricas convencionais já tenha sido bastante explorado na literatura há 40 anos, a previsão de cargas dos VEs começou a ter relevância e ser tratada a partir do ano de 2010 e, nos últimos 5 anos, ganhou muita notoriedade na comunidade científica. A literatura recente apresenta vários trabalhos que tratam de diferentes métodos para prever a demanda de carregamento de VEs.

Mudgal et.al (2025) (Mudgal et al., 2025) propõem um trabalho que classifica estações residenciais, de espaço de trabalho e instantâneas via Agrupamento Espacial Baseado em Densidade de Aplicações com ruído (HDBSCAN) e Método do Cotovelo, e o método de previsão é realizado com Modelos de Regressão incluindo Floresta Aleatória, SVM e Regressão Logística.

Nazir et.al (2025) (Nazir et al., 2025) propõem um modelo que melhora a previsão de energia para veículos elétricos, empregando uma correção de *outlier* usando como técnica de previsão um codificador denso de séries temporais.

Fahim et.al (2025) (Fahim; Akbar; Amayri, 2025) usam uma rede de caminhos Residual Dual BiLSTM-CNN para incluir dados de carregamento de EV ausentes, capturando as dependências temporais e de longo prazo em vários cenários.

Mohsenimanesh e Entchev (2024) (Mohsenimanesh; Entchev, 2024) propõem três estratégias de carregamento para reduzir o carregamento geral em períodos de pico com base na carga

prevista usando uma abordagem de aprendizado de máquina híbrida que combina seleção de dia semelhante, decomposição completa do modo de conjunto e redes neurais profundas.

Tang et.al (2024) (Tang et al., 2024) propõem um algoritmo de otimização de gelo e gelo (RIME) de decomposição modal variacional (VMD) - rede neural de memória longa e curta bidirecional (Bi-LSTM) para evitar problemas de baixa precisão.

Shi et.al (2024) (Shi et al., 2024) propõem uma estratégia probabilística de previsão de carga com regressão de processo gaussiano estruturada de maneira diária, incluindo recursos relacionados a hábitos de EV e informações meteorológicas.

Lu et.al (2024) (Lu et al., 2024) propõem um método que contém uma interação em tempo real com informações de várias fontes, bem como a cobrança de preços de consumo ao longo do caminho. Uma otimização de cone de segunda ordem é usada para otimizar a distribuição espaço-temporal da carga regional.

Gowda et.al (2024) (Gowda et al., 2024) empregam aprendizado de transferência e meta-aprendizado de modelo com um modelo básico de pré-treinamento que fornece melhores resultados do que os métodos clássicos como o LSTM tradicional.

Rasheed et.al (2023) (Rasheed et al., 2023) propõem uma Rede Neural Profunda baseada em aprendizado supervisionado aprimorada incorporando Unidade Recorrente Fechada (GRU), (LSTM), (RNN), Totalmente Conectada (FC) e Rede Neural Convolucional (CNN) que melhora o processo de treinamento de refinamento de previsão com recursos e informações adicionais.

Yang et.al (2022) (Yang et al., 2022) usam uma abordagem de aprendizado aprimorada para resolver o problema de previsão intratável que acomoda os fatores que afetam as cargas de carregamento.

Para melhorar a precisão da previsão de carga de veículos elétricos de curto prazo, os autores (Sun et.al, 2024) (Sun et al., 2024) combinaram o modelo de previsão baseado no *Sparrow Search Algorithm (SSA)* e no (SVM).

Os autores (Tang et.al, 2023) (Tang et al., 2023) propõem usar a frequência de pilhas de carregamento com valores históricos de carga como dados de entrada para uma rede neural *LSTM* que executa a previsão de carga.

Amini (2016) (Amini; Kargarian; Karabasoglu, 2016) aborda o impacto da demanda de carga de VEs usando o método *ARIMA (Autoregressive Integrated Moving Average)* para prever a demanda de cargas elétricas convencionais e a demanda de carregamento em veículos elétricos simultaneamente. A previsão é feita para o dia seguinte com resolução de uma hora. Como resultado, a previsão integrada obteve um (MAPE) de 7,25% e a desacoplada obteve 1,44%.

Buzna (2019) (Buzna et al., 2019), desenvolveu uma pesquisa comparativa entre modelos de previsões de cargas em VEs utilizando métodos de séries temporais e IA. Seu conjunto de dados foi extraído de 1700 estações de carregamento na Holanda. Foram utilizadas cinco ferramentas para as previsões: *SARIMAX (Seasonal Autoregressive Integrated Moving Average)* e *SARIMAX Alternative*, *Random Forests (RF)*, *Gradient Boosting Regression Trees (GBRT)* e *Persistence Method (PM)*. As previsões foram feitas para 7, 14 e 28 dias. Obteve-se o melhor resultado na

previsão de 7 dias com método *SARIMAX* e MAPE de 12,02%. O resultado da previsão para 14 dias foi alcançado com SARIMAX Alternative MAPE de 12,15% e para 28 dias, também pelo mesmo método, obteve MAPE de 12,60%.

Lu (2018) (Lu et al., 2018), apresenta um método de previsão de cargas em estações de carregamento para VEs com algoritmo RF combinado com algoritmos de regressão e classificação. Os dados utilizados são de várias estações em Shenzhen no período de 2016 até 2018, para a previsão de cargas de carregamento para uma única e várias estações. As entradas para as características em comum foram ano, mês, dia, indicador de atividade e índice de prosperidade e para as características únicas foram símbolo de fim de semana, símbolo de feriado, carga medida com resolução de 15 minutos e valor cobrado. Para as características de várias estações de carregamento, as entradas foram: símbolo da semana, indicador de capacidade, longitude, latitude e cobrança dos dias anteriores. As saídas foram capacidade de carga e tempos de carregamento. A divisão dos dados foi de 90% para treinamento e 10% para testes. A previsão em uma única estação de carregamento obteve MAPE de 9,76% e em várias estações alcançou 12,8%.

Zhang (2018) (Zhang, 2018), propõe um novo modelo híbrido que combina agrupamento *fuzzy*, máquina de vetores de suporte de mínimos quadrados (LSSVM) e algoritmo *Wolfpack* para fazer a previsão de carga para estações de carregamento de ônibus elétrico. Foi utilizado agrupamento *fuzzy* para extrair amostras em dias semelhantes e o algoritmo de *WolfPack* foi empregado para otimizar os parâmetros do LSSVM. Os dados foram obtidos de uma estação de carregamento em Baoding, China, em 2017. As entradas selecionadas foram tipo de dia, temperatura máxima, temperatura mínima, condição meteorológica, número diário acumulado de recargas e cargas no mesmo momento nos três dias anteriores. A previsão obteve MAPE de 2,20% no verão, 2,35% no outono e 1,90% no inverno.

Os autores Lee (2019), (Lee et al., 2019), usam métodos de inferência bayesiana com convolução, que prevê as cargas nas próximas 24 horas. Os resultados foram comparados com uma regressão linear. Foram utilizados dados de 30 dias de consumo agregado de 3 kW gerados pelo automóvel de uma família, medidos no intervalo de 1 hora. A distribuição gaussiana foi utilizada como modelo para a distribuição de probabilidade anterior e os dados foram treinados e comparados com dados mais recentes, com o método de regressão linear. O modelo proposto obteve MAPE de 3,09% e a regressão linear, 3,17%.

No estudo de Nair *et. al.* (2019) (Nair et al., 2019) foi proposta uma previsão a curto prazo da demanda doméstica de carregamentos de VES com RNAs profundas. Utilizou o conjunto de dados do mesmo estudo proposto nesta pesquisa (Muratori, 2018). Foi utilizada uma rede do tipo *feedforward* com 3 camadas escondidas e treinamento *backpropagation*. Os domicílios foram agrupados de acordo com os perfis de demanda e os consumidores agrupados são usados como parâmetros de previsão. Foram treinadas 52.416 amostras de consumo de energia e validadas 1440 amostras. Os resultados foram divididos em 4 tipos de agrupamento criados a partir dos perfis. O primeiro grupo contendo 7 residências obteve uma média de $2,46\%$ de erro, o segundo, com 4 residências, obteve erro médio de $3,29\%$, terceiro grupo contendo 7 residências, obteve

erro médio de $1,782\%$ e, por fim, o quarto grupo contendo 26 residências, com erro médio de $2,5\%$.

Em Zhu *et. al.* (2019) (Zhu et al., 2019) os autores elaboram uma previsão de carga a curto prazo em estação de carregamento de VEs. O conjunto de dados é de cargas de uma grande estação de carregamento em *Liuyue*, na China. As entradas foram sequenciamento de carga, sequenciamento de tempo de cobrança, sequenciamento de preços da eletricidade e informações sobre e dia, semana, fins de semana e feriados. Os métodos usados para previsões foram RNAs profundas, *Long Short Term Memory* (LSTM), redes neurais recorrentes (RNN) e *Gated Recurrent Unit* (GRU). Foram usadas 3 estruturas diferentes para cada ferramenta, variando de 1 a 4 camadas escondidas. As RNAs profundas obtiveram melhor resultado com 2 camadas escondidas ($3,81\%$ de erro); nas RNN, o melhor resultado foi com 1 e 2 camadas escondidas (erro de $2,91\%$). A rede LSTM apresentou melhor resultado também com 1 e 2 camadas escondidas ($3,36\%$ de erro) e com GRU, o melhor resultado foi $2,89\%$ de erro, alcançado com 1 camada escondida.

Embora todos estes trabalhos disponíveis na literatura propõem o uso de diferentes técnicas, o presente trabalho usa uma técnica muito consolidada na literatura, sendo a *Backpropagation* através do tempo com regularização bayesiana para previsão de carga de VEs, fornecendo resultados comparáveis com o da literatura.

4 REDE NEURAL ARTIFICIAL PERCEPTRON MULTICAMADAS RECORRENTE

As Redes Neurais Artificiais Recorrentes (RNAR) são estruturas de redes que incorporam realimentação, ou seja, possuem laços de recorrência que permitem que os dados continuem a se propagar, mantendo informações ao longo do tempo. Esta arquitetura é especialmente utilizada para o processamento e modelagem de dados que dependem do tempo (Haykin, 1998).

A RNAR é um modelo baseado na (MLP) clássica, onde as informações são interligadas camada por camada. Nesta rede, os neurônios mantêm suas informações por um intervalo de tempo e as utilizam para propagar dados no próximo passo temporal. No entanto, a RNAR se diferencia da MLP tradicional, pois as recorrências aproveitam as informações temporais dos dados de entrada durante o treinamento, tornando-a mais adequada para dados de séries temporais. As recorrências nesta rede utilizam conexões com realimentação entre camadas e neurônios (Haykin, 1998).

A estrutura da RNAR permite um ou mais laços de realimentação, possibilitando diversas configurações, como realimentações locais ou globais (Haykin, 1998).

A arquitetura de MLP recorrente (MLPR) (Puskorius; Feldkamp; Davis, 1996) possui uma ou mais camadas ocultas, mantendo a mesma estrutura padrão do MLP clássico. Nesta rede, cada camada apresenta realimentação ao seu redor, conforme ilustrado na Figura 1

Figura 1 – Estrutura de um perceptron multicamadas recorrente.



Fonte: Autoria própria

Sendo $z^{-}1I$ como os vetores de atraso (recorrentes), $u(n)$, vetor de entrada da rede, $X_0(n+1)$, vetor de saída da rede. $X_I(n)$ a saída da primeira camada oculta, $X_{II}(n)$ a saída da segunda camada oculta, se propagando até a camada de saída. O vetor $X_0(n)$ pode ser considerado como saída da última camada da rede. O comportamento da MLPR pode ser expresso, em resposta a um vetor $u(n)$ de entrada, pela Equação (1) (Haykin, 1998):

$$\left\{ \begin{array}{l} X_I(n+1) : f_1(X_I(n), u(n)) \\ X_{II}(n+1) : f_2(X_{II}(n), X_I(n+1)) \\ \\ X_0(n+1) : f_0(X_0(n), X_k(n+1)) \end{array} \right\} \quad (1)$$

onde f_1, f_2 e f_0 são as funções de ativação da primeira até a camada de saída da MLPR, n denota a unidade de tempo e k o número de camadas ocultas.

4.1 ALGORITMO DE TREINAMENTO *BACK-PROPAGATION*

O treinamento ocorre por meio da correção do erro utilizando o algoritmo de *Back Propagation (BP)* (Werbos, 1974). Este algoritmo envolve um passo para frente, chamado de propagação, e um passo para trás, conhecido como retropropagação. O processo acontece entre a camada de saída e a camada de entrada, avançando camada por camada. Na etapa de propagação, os sinais de entrada são aplicados aos pesos e bias do neurônio, transmitindo esse sinal para as camadas seguintes até o último neurônio. Este processo resulta em uma resposta de saída calculada pela rede (Haykin, 1998).

No processo de retropropagação, os pesos da rede são ajustados por meio da correção do erro. A resposta gerada pela propagação da rede é subtraída da resposta alvo desejada, resultando em um erro. Este erro é então retropropagado através da rede, permitindo que os pesos sejam ajustados e atualizados. O algoritmo de retropropagação supervisionada tem uma capacidade de aprendizado baseada na experiência ao longo do treinamento. No entanto, o BP apresenta algumas limitações (Haykin, 1998).

Uma das limitações do algoritmo de retropropagação é a necessidade de um grande volume de dados para alcançar uma generalização satisfatória. Além disto, os valores dos pesos da rede podem se tornar extremamente grandes ou pequenos (positivos ou negativos) devido ao cálculo de uma função não linear. Isto pode levar os pesos a se ajustarem a valores muito próximos de zero, saturando o algoritmo de BP (Kröse et al., 1993). Outra limitação ocorre quando o erro da rede converge para mínimos locais, devido ao cálculo da derivada local do erro . Neste caso, a resposta da rede pode ficar estagnada em um mínimo local, dificultando a obtenção de uma resposta generalizada.

Por fim, a normalização dos dados é fundamental para o treinamento, e a convergência pode ser lenta devido à inicialização aleatória dos pesos, o que gera oscilações instáveis no gradiente descendente. Isto pode prolongar o tempo de treinamento à medida que a dimensão dos dados aumenta. Existem diversas técnicas e métodos para aprimorar este algoritmo. Uma abordagem para mitigar essas limitações é a introdução de métodos probabilísticos, estatísticos, heurísticos e metaheurísticos, que podem melhorar e contornar o processo de aprendizado generalizado (Kröse et al., 1993).

4.2 TREINAMENTO PADRÃO COM BP

Inicialmente introduzido por Werbos em 1974, o algoritmo BP atualiza e ajusta os pesos dos neurônios das camadas de saídas até os neurônios das camadas de entrada, com base na correção dos erros (Werbos, 1974). Em 1986, Rumelhart, Hinton e Williams propuseram o ajuste dos pesos no sentido inverso, retropropagando o erro ao longo das camadas da rede MLP (Rumelhart; Hinton; Williams, 2002).

O processo de adaptação do erro envolve a minimização da soma dos erros quadráticos da rede, com base no gradiente descendente (Werbos, 1974). Esta soma começa na última camada (saída da rede) em cada neurônio, conforme expresso na equação (2) (Haykin, 1998):

$$E_i^2 = \sum_{i=1}^{nc} (d_i - y_i)^2 \tag{2}$$

sendo $E_{(i)}^2$ erro quadrático da rede, d_i saída alvo do i-ésimo neurônio da última camada da rede, y_i saída calculada do i-ésimo neurônio da última camada da rede e nc número de neurônios da última camada da rede. Os ajustes dos pesos da rede utilizam-se do método do gradiente descendente, descrito na equação (3) (Haykin, 1998).

$$W_{(m+1)} = W_m - a \times (\frac{\partial E^2}{\partial W_m}) \tag{3}$$

em que $W_{(m+1)}$ novo peso atualizado, W_m peso atual, a taxa de aprendizado, $(\frac{\partial E^2}{\partial W_m})$ gradiente do erro quadrático em relação aos pesos.

O BP pode ser simplificado em 5 etapas (Haykin, 1998) :

1. Apresentar à rede um padrão de entrada e saída, utilizando pesos iniciais aleatórios entre 0 e 1.

2. Calcular o erro quadrático gerado pela saída da rede em cada camada.

3. Realizar a retropropagação do erro, utilizando as derivadas parciais em relação aos respectivos pesos e funções de ativação.

4. Atualizar todos os pesos, desde a última camada até a primeira.

5. Retornar ao primeiro passo, inserindo novos padrões de entrada na rede, até que o erro seja minimizado e ocorra a convergência, com base em uma tolerância previamente estabelecida.

4.3 TREINAMENTO *BACK-PROPAGATION* ATRAVÉS DO TEMPO (BPAT)

O treinamento padrão de uma MLP com o algoritmo de retropropagação (BP) (Werbos, 1974) (Rumelhart; Hinton; Williams, 2002) e o da MLPR são praticamente iguais, sendo a MLPR uma extensão do BP tradicional, chamada de retropropagação através do tempo (BPAT). Este processo pode ser representado pelo desdobramento da operação temporal da MLPR, onde os dados são alimentados adiante em camadas, com a arquitetura da rede incluindo uma camada adicional a cada passo de tempo (Haykin, 1998).

Se considera uma matriz de conjunto de treinamento para uma MLPR, onde n_0 representa o tempo de início de uma época e n_1 o tempo final. Com isto, pode-se expressar o cálculo do somatório do erro quadrático médio do BPAT na equação (4) (Haykin, 1998):

$$\epsilon_{total(n_0,n_1)} = \frac{1}{2} \sum_{n=n_0}^{n_1} \sum_{j \in A} e_j^2(n) \tag{4}$$

em que A é o conjunto de índices j associados aos neurônios da rede e $e_j(n)$ o erro na saída da rede. Sendo o cálculo feito através da correção do $\epsilon_{total(n_0,n_1)}$ entre a diferença do valor alvo e o calculado pela rede, chamado de $e_j^2(n)$.

Com isto, inicia o cálculo das derivadas parciais de $\epsilon_{total(n_0,n_1)}$ em relação a cada peso da MLPR (Williams; Peng, 1990).

No primeiro passo, é executado o processo de propagação para frente *(forward)* através de toda a MLPR para os intervalos n_0 e n_1. Neste estágio, todo o conjunto de dados de treinamento é passado pela entrada, junto com os pesos da rede e as respostas desejadas para este intervalo. Os dados de entrada, os pesos da rede e as respostas desejadas são então armazenados. Após completar a passagem para frente, realiza-se o passo para trás BPAT, onde são calculadas as derivadas parciais da equação (5) (Haykin, 1998).

$$S_j(n) = -\left(\frac{\partial \epsilon_{total(n_0,n_1)}}{\partial v_j(n)} \right) \tag{5}$$

onde para todo j pertencente a A e $n_0 < n < n_1$ e $\partial v_j(n)$ a derivada do peso local, podendo ser calculado pela equação (6) (Haykin, 1998)

$$S_j(n) = \begin{cases} f'(v_j(n))e_j(n) \\ f'(v_j(n))[e_j(n) + \sum_{k \in A} w_{jk} S_k(n+1)] \end{cases} \tag{6}$$

onde para $n = n_1$ e $n_0 < n < n_1$, f' sendo a primeira derivada da função de ativação ao seu peso local $v_j(n)$, o local introduzido do neurônio j e w_{jk} peso do neurônio k .

A equação (4) se repete inicialmente no tempo n_1 e retropropaga-se para trás, passo a passo, até chegar ao tempo n_0. Com isso, finaliza-se o cálculo de uma época do treinamento. Uma vez que é feito o processo do BPAT ao tempo $n_0 + 1$, sendo a próxima iteração do algoritmo de treinamento, em seguida são calculados pela equação (7) os ajustes dos pesos w_{ji} da MLPR respectivos ao neurônio j (Haykin, 1998):

$$\Delta w_{ji} = -a_1 \times \left(\frac{\partial \epsilon_{total(n_0,n_1)}}{\partial w_{ji}} \right) = a_1 \sum_{n=n_0+1}^{n_1} S_j(n) xi(n-1) \tag{7}$$

onde Δw_{ji} é a derivada parcial em relação ao peso atual w_{ji}, a_1 é a taxa de aprendizado e $xi_{(n-1)}$ é a entrada aplicada ao i-ésimo neurônio j no tempo $(n-1)$.

Ao comparar o algoritmo BPAT com o algoritmo BP padrão, observou-se que há poucas diferenças entre ambos. No algoritmo BPAT, as respostas desejadas são especificadas para os

neurônios em várias camadas da MLPR, uma vez que a camada de saída real é replicada várias vezes quando o comportamento temporal da MLPR é desdobrado (Haykin, 1998).

4.4 MELHORANDO O TREINAMENTO BP

A busca por melhorar e contornar as limitações do BP motiva muitos pesquisadores a acrescentarem métodos, ferramentas e outros treinamentos na tentativa de desenvolver um algoritmo híbrido. Uma destas melhorias envolve o uso de modelos probabilísticos bayesianos, visando aprimorar o aprendizado. Um exemplo é o método explorado no artigo (Lauret et al., 2008), que demonstra a aplicação de modelos bayesianos com RNAs para a previsão de cargas elétricas a curto prazo. A técnica bayesiana apresenta vantagens significativas em relação a outros métodos de treinamento na literatura e ao próprio BP. O modelo bayesiano pode ajudar a mitigar problemas de *overfitting* e *underfitting*, sendo aplicável a problemas tanto simples quanto complexos.

No artigo em (Saini, 2008), os autores utilizam esta técnica na previsão de picos de cargas elétricas. A proposta demonstrou melhorias no aprendizado do BP com a introdução do método bayesiano.

No processo de aprendizagem de uma RNA, obter respostas generalizadas depende de baixos erros e de um alto grau de aprendizado, além da capacidade de inserir novos dados de entrada e gerar respostas com erros reduzidos. O objetivo de um treinamento híbrido é melhorar a aprendizagem de forma que, ao inserir novos dados, a rede seja capaz de produzir consistentemente respostas aprimoradas (Hagan et al., 2014).

Neste contexto, um destes métodos é conhecido como regularização, que visa restringir o tamanho dos pesos da rede. A Regularização Bayesiana (RB) ajuda a evitar o *overfitting* durante o treinamento, promovendo melhorias na generalização do aprendizado. Este treinamento adiciona um novo coeficiente ao processo de otimização, penalizando a função objetivo (MacKay, 1992). Como a arquitetura da MLPR proposta contém mais de uma camada oculta, totalizando três camadas, a intenção de aprimorar o treinamento BP ao incorporar outra técnica para criar um algoritmo híbrido destaca a ênfase do estudo em extrair o máximo de informações durante o processo de treinamento da rede, gerado pelo aprendizado profundo.

O método proposto por Mackay em 1992 utiliza técnicas bayesianas para otimizar a regularização (MacKay, 1992). Esta abordagem envolve cálculos da matriz hessiana, que são minimizados pelo método de aproximação Gauss-Newton (Foresee; Hagan, 1997b). Esta aproximação pode ser aplicada pelo algoritmo de Levenberg-Marquardt (LM), cujo objetivo é minimizar a função objetivo (Hagan; Menhaj, 1994). Em (Foresee; Hagan, 1997b), o treinamento de Regularização Bayesiana (RB) é aplicado em RNAs, utilizando a aproximação de Gauss-Newton para calcular a matriz Hessiana. O algoritmo de Levenberg-Marquardt (LM) visa reduzir o custo computacional associado ao cálculo de matrizes inversas.

4.5 TREINAMENTO BPAT COM REGULARIZAÇÃO BAYESIANA RB

Na RB, se modifica a função objetivo F acrescentando os erros vindos do treinamento do BPAT. Introduzindo o BPAT, sendo o somatório dos erros quadráticos da rede MLPR, já conhecido breviamente como $\epsilon_{total(n_0,n_1)}$, na sequência, a função F é acrescida pelo termo E_w, sendo a soma dos erros gerados pela rede $(pesos)$ e $(bias)$, na equação (8) (MacKay, 1992):

$$F = \beta\epsilon_{total(n_0,n_1)} + \alpha E_w \tag{8}$$

onde α e β são os parâmetros de regularização da função F e E_w é dado pela equação (9) (MacKay, 1992):

$$E_w = \frac{1}{n}\sum_{m=0}^{n}(w_m)^2 \tag{9}$$

onde w_m sendo o i-ésimo peso e $bias$ da rede MLPR.

O tamanho relativo aos parâmetros α e β de F controla a ênfase para o treinamento. Quando α < β, a regularização foca em minimizar os erros do treinamento. Caso α > β, os valores dos pesos calculados pela rede são minimizados. O principal objetivo do método de RB é definir os melhores parâmetros de F. No processo bayesiano, os pesos são iniciados com valores aleatórios não nulos, em sequência dos dados inseridos no treinamento. Com isto, a função de densidade dos pesos W é atualizada pela equação (10) de Bayes (MacKay, 1992):

$$P(W|D,\alpha,\beta,M) = \frac{P(D|W,\beta,M)P(W|\alpha,M)}{P(D|\alpha,\beta,M)} \tag{10}$$

onde D é o conjunto de treinamento; M o modelo da rede; W o conjunto de pesos; $P(W|\alpha,M)$ densidade anterior, aprendizagem dos pesos antes de qualquer dado ser coletado; $P(D|W,B,M)$ a função de verossimilhança dos pesos W, sendo a probabilidade de dado evento ocorrer; $P(D|\alpha,\beta,M)$ fator de normalização garantindo que a probabilidade total seja 1.

Se for assumido que os dados no conjunto de treinamento possuem uma distribuição *Gaussian* e sua distribuição anterior para os pesos é também *Gaussian*, então as densidades de probabilidade podem ser escritas na seguinte equação (11) (MacKay, 1992):

$$P(W|D,\alpha,\beta,M) = \frac{1}{Z_D^\beta}e^{(-\beta\epsilon_{total(n_0,n_1)})}$$

$$P(W|\alpha,M) = \frac{1}{Z_W^\alpha}e^{(-\alpha E_W)} \tag{11}$$

onde $Z_D^\beta = (\frac{\pi}{\beta)})^{n/2}$ e $Z_W^\alpha = (\frac{\pi}{\alpha})^{N/2}$.

Substituindo essas probabilidades na equação (11), reestruturando o cálculo da seguinte forma (12) (MacKay, 1992):

$$
\begin{aligned}
P(W|D,\alpha,\beta,M) &= \frac{\frac{1}{Z_W^{\alpha}}\frac{1}{Z_D^{\beta}}e^{(-(\beta\epsilon_{total(n_0,n_1)}+\alpha E_W))}}{FN} \\
&= \left(\frac{1}{Z_F(\alpha,\beta)}e^{-F(W)}\right) \qquad (12)
\end{aligned}
$$

onde FN é o fator de normalização.

Nesta etapa bayesiana, os pesos ótimos maximizam a probabilidade posterior $P(W|D, \alpha, \beta, M)$. Então, maximizar a probabilidade posterior equivale a minimizar a função objetivo regularizada $F = \beta\epsilon_{total(n_0,n_1)} + \alpha E_W$.

4.5.1 otimização de parâmetros de regularização

Nesta etapa, é apresentado a aplicação do teorema de Bayes para calcular a otimização dos parâmetros α e β da função objetivo F pela equação (13) (MacKay, 1992):

$$
P(\alpha,\beta|D,M) = \frac{P(D|\alpha,\beta,M)P(\alpha,\beta|M)}{P(D|M)} \qquad (13)
$$

De acordo com a densidade $P(\alpha, \beta|M)$ para os parâmetros de regularização α e β, maximizar a densidade posterior é possível calculando sua função de verossimilhança $P(D|\alpha, \beta, M)$. Observa-se que esta função é o fator de normalização para (8). Supondo que todas as distribuições são gaussianas, a forma para a densidade posterior dada (8) é conhecida. Foi demonstrado em (10) e pode ser resolvido (8) para o fator de normalização (14) (MacKay, 1992):

$$
\begin{aligned}
P(D|\alpha,\beta,M) &= \frac{P(D|W,\beta,M)P(W|\alpha,M)}{P(W|D,\alpha,\beta,M)} \\
&= \frac{\left(\left[\frac{1}{Z_D^{(\beta)}}e^{(-(\beta\epsilon_{total(no,n1)}))}\right]\left[\frac{1}{Z_W^{(\alpha)}}e^{(-(\alpha E_W))}\right]\right)}{\frac{1}{Z_F^{(\alpha,\beta)}}e^{(-(\alpha E_W))}} \\
&= \frac{Z_F^{(\alpha,\beta)}}{Z_D^{(\beta)}Z_W^{(\alpha)}}\frac{e^{(-\beta E_{total(n_0,n_1)}-\alpha E_W)}}{e^{(-FW)}} \\
&= \frac{Z_F^{(\alpha,\beta)}}{Z_D^{(\beta)}Z_W^{(\alpha)}} \qquad (14)
\end{aligned}
$$

As constantes $Z_D^{(\beta)}$ e $Z_W^{(\alpha)}$ calculadas em (9) são conhecidas. A única constante desconhecida é $Z_F^{(\alpha,\beta)}$.Com isto, os cálculos da expansão em série de Taylor, pode-se expandir $F(W)$ em torno do ponto mínimo da densidade posterior W^{MP}, onde o cálculo do gradiente é nulo. Calculando as constantes de normalização (15) (MacKay, 1992):

$$Z_F \approx (2\pi)^{\frac{N}{2}} (\det((H^{MP})^{-1}))^{\frac{1}{2}} e^{(-F(W^{MP}))} \tag{15}$$

onde $H = \beta\nabla^2\epsilon_{total(n_0,n_1)} + \alpha\nabla^2 E_W$ é uma matriz Hessiana da função objetivo F.

Com o resultado do cálculo em (15), são calculados agora os valores ótimos para α e β no ponto mínimo. Tomar a derivada em relação a cada um dos *log* de (12) e defini-los iguais a zero resultará em (16) (MacKay, 1992):

$$\alpha^{MP} = \frac{\gamma}{2E_W(W^{MP})}$$

$$\beta^{MP} = \frac{n-\gamma}{2\epsilon_{total(n_0,n_1)}(W^{MP})} \tag{16}$$

onde $\gamma = N - 2\alpha^{MP}(H^{MP})^{-1}$ é chamado de número efetivo de parâmetros e N é o número total de parâmetros na rede. O parâmetro γ é uma medida de quantos parâmetros de rede neural são efetivamente usados para minimizar a função objetivo de erro. Pode variar de zero a N.

4.5.2 cálculo da aproximação de Gauss-Newton para a matriz hessiana

O treinamento RB requer o cálculo da matriz hessiana (H) da função objetivo $F(W)$ para o ponto mínimo W^{MP}. Esta aproximação pode ser calculada usando o algoritmo de otimização Levenberg-Marquardt (LM) para encontrar o ponto mínimo (Lee et al., 1993).

O algoritmo de LM foi projetado para se aproximar da velocidade de treinamento de segunda ordem sem precisar calcular a matriz Hessiana. Quando a função de desempenho tem a forma de uma soma de quadrados, a matriz Hessiana H pode ser aproximada pela equação (17) (Hagan; Menhaj, 1994):

$$H = J^T J \tag{17}$$

o gradiente pode ser calculado pela equação (18):

$$g = J^T e \tag{18}$$

o termo J é a matriz Jacobiana que contém as derivadas primeira ordem dos erros da rede em relação aos pesos e bias, e e é um vetor de erros da rede. A matriz Jacobiana pode ser calculada através de uma técnica padrão de retropropagação (Hagan; Menhaj, 1994), que é muito menos complexa do que o cálculo da matriz hessiana. O algoritmo de LM usa essa aproximação da matriz Hessiana na seguinte atualização semelhante à de Newton pela equação (19):

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \tag{19}$$

Quando o escalar μ é zero, trata-se apenas do método de Newton, utilizando a matriz hessiana aproximada. Quando μ é grande, isso se torna um gradiente descendente com um pequeno tamanho de passo. O método de Newton é mais rápido e preciso perto de um mínimo erro; portanto, o objetivo é mudar para o método de Newton o mais rápido possível. Assim, μ é diminuído após cada passo bem-sucedido (redução na função de desempenho) e é aumentado apenas quando um passo provisório aumenta a função de desempenho. Desta forma, a função de desempenho é sempre reduzida a cada iteração do algoritmo (THE MATHWORKS Inc., 2015).

A descrição original do algoritmo LM é apresentada em (Marquardt, 1963). A aplicação do LM ao treinamento de RNAs é descrita em (Hagan; Menhaj, 1994). Este algoritmo apresenta-se como o método mais rápido para treinar RNAs feedforward de tamanho moderado (até várias centenas de pesos).

O algoritmo de LM suporta o treinamento com vetores de validação e teste se a propriedade de divisão da rede estiver definida como uma função de divisão de dados, pelo *software* Matlab. Os vetores de validação são usados para interromper o treinamento antecipadamente se o desempenho da rede nos vetores de validação não melhorar ou permanecer o mesmo pelo valor máximo de épocas consecutivas. Os vetores de teste são usados como uma verificação adicional para garantir que a rede esteja generalizando bem, mas não têm nenhum efeito sobre o treinamento (THE MATHWORKS Inc., 2015).

O algoritmo pode ser resumido em 5 etapas descritas, a seguir (MacKay, 1992) (Foresee; Hagan, 1997a):

1. Inicialização dos pesos W de maneira aleatória, não nulos. São escolhidos $\alpha = 0$ e $\beta = 1$ e é usado o método Nguyen-Widrow para se inicializar os pesos. Após a primeira etapa de treinamento, os parâmetros da função objetivo serão recuperados da configuração inicial.

2. Execução de uma etapa do algoritmo de LM para minimizar a função objetivo $F(W) = \beta\epsilon_{total(n_0,n_1)} + \alpha E_w$;

3. Cálculo do número efetivo de parâmetros $\gamma = N - 2\alpha\ (H)^{-1}$ usando a aproximação de Gauss-Newton para a matriz H disponível no algoritmo de treinamento de LM $H = \nabla^2 F(W) \approx 2\beta J^T J + 2\alpha I_N$, sendo J a matriz Jacobiana dos erros do conjunto de treinamento;

4. Cálculo de novas estimativas para os parâmetros da função objetivo $\alpha = \frac{\gamma}{2E_W(W)}$ e $\beta = \frac{n-\gamma}{2\epsilon_{total(n_0,n_1)}(W)}$;

5. Execução das etapas 2 e 4 até a convergência.

O treinamento é interrompido quando qualquer uma destas condições ocorre: O número máximo de épocas (repetições) for atingido, o tempo máximo for excedido, o desempenho for minimizado para a meta, o gradiente de desempenho ficar abaixo do valor minímo estabelecido, μ exceder o valor máximo de Marquardt e o desempenho da validação (erro de validação) aumentar

mais do que o valor máximo de falhas a frente vezes desde a última vez que diminuiu (ao usar a validação) (THE MATHWORKS Inc., 2015).

5 PRÉ-PROCESSAMENTO

O pré-processamento dos dados é uma tarefa bastante importante e necessária para o ajuste dos dados. Porém, ele é menos citado e conhecido do que outras etapas. Esta parte da análise dos dados geralmente depende de grandes esforços de tempo e dedicação, podendo ultrapassar 50% de todo o tempo dedicado a uma determinada tarefa. Os dados brutos podem apresentar anomalias, imperfeições, valores ausentes, ruídos, inconsistências e/ou até redundâncias. O pré-processamento influencia significativamente a qualidade e a confiança dos dados antes de serem utilizados no modelo sugerido, já que o desempenho dos algoritmos é afetado por dados de baixa qualidade (Ramírez-Gallego et al., 2017).

Portanto, esta primeira preparação dos dados tem como objetivo principal de transformar, limpar, normalizar e filtrar os dados brutos de entrada do modelo, para extrair com alta qualidade o processo de aprendizagem subsequente. Esta preparação geralmente é considerada obrigatória para elevar a qualidade do processamento (García et al., 2015).

Neste contexto, a Transformada *Wavelet* (TW) é um instrumento matemático que decompõe uma série temporal em diferentes componentes de frequência, que podem ser examinados individualmente. As diversas partes de alta frequência se manifestam através de ruídos e variações inesperadas, enquanto as partes de baixa frequência procuram as tendências subjacentes (Daubechies, 1992).

A utilização de filtros digitais Savitsky-Golay (SG) de suavização pode aumentar a precisão na extração de informações pertinentes e importantes nos dados analisados. Para aprimorar o aprendizado em amostras de dados temporais, a remoção de amostragens ruidosas traz melhorias na precisão do modelo na previsão de séries temporais. Além disto, melhora a aparência visual das informações originais devido aos ruídos indesejados. O objetivo é extrair as informações e padrões mais relevantes dos dados, destacando-os dos ruídos originais (Liu et al., 2019).

Além das duas estratégias já mencionadas em pré-processamento, este estudo também tratará da utilização da Análise de Espectro Singular (AES). Uma ferramenta destinada à coleta de dados de uma série temporal de curta duração e com interferências. Esta metodologia desmembra a série temporal analisada em um conjunto de séries, reconhecidas como tendências, componentes periódicas ou quase periódicas ou ruídos. Posteriormente, a série original é reconstruída (Nilsson, 2004) (Hassani; Mahmoudvand; Yarmohammadi, 2010a).

Devido a presença de ruídos de baixa frequência, linearidade, tendências complexas e sazonalidades nos dados das cargas dos VEPs e das residências, esta ferramenta é capaz de extrair essas anomalias e inconsistências da série temporal original, possibilitando a suavização das cargas elétricas. O estudo engloba componentes de estatísticas multivariadas, geometria multivariada, análise de séries temporais convencionais, sistemas dinâmicos e pré-processamento de sinais (Golyandina; Nekrutkin; Zhigljavsky, 2001).

Um benefício desta abordagem é que, normalmente, séries temporais são univariadas e que,

nesse caso, é vantajoso usar a AES. A AES não requer muitos parâmetros de ajuste, tem um custo computacional reduzido e não apresenta atraso em relação à série temporal original (Golyandina; Nekrutkin; Zhigljavsky, 2001) (Guo et al., 2020).

5.1 TRANSFORMADA *WAVELET*

As transformadas *wavelets* (TW) são ferramentas de matemática aplicada desenvolvidas recentemente, a partir de 1982, conforme apresentado nos trabalhos (Grossmann; Morlet, 1984) e (Meyer; Ryan, 1993). Nos últimos anos, sua aplicação no pré-processamento de sinais vem crescendo aceleradamente (Grossmann; Morlet, 1984).

A análise da TW apresenta várias vantagens em relação a métodos clássicos, pois permite explorar a periodicidade de séries temporais em diferentes escalas de variabilidade. Além disto, a TW não depende de séries temporais estacionárias. Esta ferramenta possibilita a avaliação de dados irregulares e ruidosos, com muitas linearidades e não linearidades, além de lidar com séries temporais não estacionárias em diversas frequências (Braga; Santos, 2010).

As wavelets representam uma função matemática relativamente simples e possuem uma ampla gama de aplicações em processamento de sinais. Por esta razão, a TW se tornou uma ferramenta acessível e comuns para a análise de sinais com altas variações e ruídos. Há diversos estudos e aplicações que utilizam as TW em áreas como engenharia, astronomia, processamento de imagens, vídeo e áudio, saúde, reconhecimento de voz, meteorologia e monitoramento de cargas elétricas, entre outras (Graps, 1995).

O objetivo fundamental das (TW) é avaliar os dados de acordo com sua escala. As wavelets são funções que requerem cálculos matemáticos subjacentes, permitindo que os algoritmos que as utilizam processem dados em diversas escalas ou dimensões. Quando aplicadas a um sinal de grande escala, as TW podem lidar com dados ruidosos, dados estacionários e não estacionários, enquanto em um sinal de menor escala, é possível observar características mais sutis (Graps, 1995).

Isto nos motiva a introduzir a TW neste trabalho, uma vez que todo o conceito descrito as torna extremamente atraente e útil para a aplicação em cargas elétricas de VEs e residenciais, onde os dados analisados neste trabalho apresentam características não estacionárias e ruidosas. Neste contexto, as wavelets propostas neste trabalho atuarão como uma transformação inicial das cargas elétricas.

O processo de análise wavelet baseia-se em uma função chamada wavelet-mãe ou *wavelet* de análise. Esta análise em séries temporais é realizada utilizando uma versão de alta frequência da wavelet-mãe, enquanto a análise de frequência é feita com uma versão expandida e de baixa frequência da mesma *wavelet*-mãe (Daubechies, 1992).

Podemos representar uma wavelet baseada em uma função $q(t) \in P^2$ real , sendo uma função de energia finita, satisfazendo a condição de admissibilidade descrita na equação (20) (Grossmann; Morlet, 1984) (Daubechies, 1992) (Graps, 1995).

$$c_q = \int_0^{+\infty} \frac{|Y(\Omega)^2|}{\Omega} < +\infty \tag{20}$$

onde $Y(\Omega)$ é a transformada de Fourier (TF) da função wavelet, ficando escrito da seguinte forma (21)

$$Y(\Omega) = \int_{-\infty}^{+\infty} q(t)\, e^{-j\Omega t}\, dt \tag{21}$$

onde j a unidade imaginária.

A TW pode ser caracterizada por meio do seu número de momentos nulos, sendo quanto mais momentos nulos, mais suavizada se torna a função wavelet. A TW possui M momentos nulos podendo ser expresso na (22) (Morlet et al., 1982).

$$\int_{-\infty}^{+\infty} s^n q(t)\, dt = 0,\ n = 0, 1,\ ..., M-1 \tag{22}$$

5.2 TRANSFORMADA *WAVELET DAUBECHIES* E *SYMLETS*

A TW pode ser do tipo contínuo, utilizando modelos transladados e escalonados, ou, do tipo discreto, que envolve a discretização dos parâmetros de escala e translação (Daubechies, 1992). Tanto na TW contínua quanto na discreta, existe uma grande variedade de funções wavelet. Esta análise pode ser realizada através de análise multirresolução, que pode ser ortogonal ou bi-ortogonal, incluindo filtros e funções (Donoho; Johnstone, 1994).

Figura 2 – Função *Wavelet Daubechies* 4 (db4)



Fonte : Adaptado de Grossmann & Morlet (1984)

A TW da família Daubechies (db) e a do tipo Symlets (sym) apresentam uma wavelet ortogonal de suporte compactado (Grossmann; Morlet, 1984). Podendo ser chamado de (dbM), em que M é o número de momentos nulos, indica que o filtro interno desta wavelet possui comprimento $2M$. Exemplo a *wavelet* de função (db4) representada na (Figura 2).

Figura 3 – Função *Wavelet Symlets* 4 (sym4)



Fonte : Adaptado de Grossmann & Morlet (1984)

Quando se fala das wavelets do tipo symlets, apresentam a mesma estrutura da TW (db), com algumas mudanças. Esta família da TW é menos assimétrica do que a (db), sendo quase simétrica. A *walvelet* $(symM)$ representa M momentos nulos, e seus filtros possuem comprimento de $2M$ (Daubechies, 1992).Pode-se observar a função symlets na (Figura 3).

5.3 FILTRO DIGITAL SAVIZKY-GOLAY (SG)

Uma das principais vantagens das técnicas de suavização é a detecção de sazonalidades nos dados, o que melhora o desempenho de algoritmos de aprendizado de máquina que lidam com dados dependentes do tempo. Na maioria das técnicas de suavização abordadas na literatura, destacam-se a média móvel e a suavização exponencial, devido a sua simplicidade e ao bom desempenho em previsões de séries temporais (Liu et al., 2019).

Entretanto, muitas destas técnicas enfrentam problemas e limitações quando aplicadas a dados que apresentam várias sazonalidades e ruídos, o que dificulta o ajuste de parâmetros (Ryu; Noh; Kim, 2016). Uma das abordagens que se mostram eficazes para superar essas dificuldades é o uso do filtro desenvolvido por Savitzky-Golay (SG) (SAVITZKY; GOLAY, 1964), que tem como objetivo suavizar dados ruidosos de baixas amplitudes.

A técnica de (SG) propõe uma metodologia que suaviza dados com base em cálculos de mínimos quadrados locais, utilizando a aproximação de um polinômio em uma janela móvel deslizante. O modelo ajusta um polinômio a um conjunto de dados de entrada e, em seguida, avalia o resultado do polinômio resultante em um ponto dentro do intervalo de aproximação. Trata-se de um filtro passa-baixas de média móvel que aplica esta técnica para calcular coeficientes de suavização de dados com altos ruídos e não estacionariedade, melhorando assim os dados de alta frequência e sazonalidade, ao remover ruídos e linearidades (SAVITZKY; GOLAY, 1964).

Este tipo de filtro é amplamente reconhecido por sua capacidade de suavizar dados com

vários ruídos em um espectro. A técnica demonstra eficácia na redução de informações ruidosas, mantendo as características e informações originais, como amplitudes, formatos de onda e picos. Isto se deve à sua tendência de preservar valores máximos, mínimos e as características de largura da distribuição. Além disso, esta técnica pode suavizar os dados no domínio do tempo sem a necessidade de conversão para o domínio da frequência (Schafer, 2011).

Esta propriedade do filtro SG de conservar a amplitude e os picos dos dados originais torna sua aplicação muito atraente em diversas áreas de pesquisa, com diferentes tipos de dados. Por exemplo, ele tem sido utilizado na área da saúde para o processamento de dados de eletrocardiogramas (Pandia et al., 2010) e no processamento de imagens de ultrassom e radares (Suhling et al., 2004).

Como este trabalho se concentra em dados de séries temporais relacionados a cargas elétricas não estacionárias, os filtros SG se mostram uma opção promissora. Isto se deve ao fato de que os dados da demanda residencial e dos VEs são frequentemente ruidosos, não estacionários e altamente flutuantes. As cargas elétricas não estacionárias, por sua vez, também apresentam diversas linearidades devido à adição das cargas dos VEs à demanda residencial. Assim, a introdução deste filtro nas análises de cargas elétricas é bastante relevante. Apesar de sua capacidade de suavizar os dados, o filtro preserva as características originais, como largura, picos e amplitudes (Suhling et al., 2004).

Obter uma boa resposta de suavização está diretamente relacionado à escolha do grau do polinômio e ao tamanho da janela deslizante. Este ajuste pode envolver um grau e um tamanho de janela elevados, moderados ou baixos. O objetivo da aplicação deste filtro é melhorar a curva de cargas da demanda das residências e dos veículos elétricos. A suavização e eliminação de linearidades das carga elétricas estão ligadas diretamente às escolhas e ajustes dos parâmetros escolhidos do filtro (SAVITZKY; GOLAY, 1964).

O filtro consiste em gerar $2n + 1$ pontos equidistantes em que n está centrado em 0 $(n = 0)$ com representação de um polinômio de grau p. A filtagem requer especificamente o sinal de entrada, o grau do polinômio e o tamanho da janela móvel deslizante. Com isto, é possível fazer os ajustes destes três elementos com o objetivo de suavizar e alcançar melhores resultados filtrados (SAVITZKY; GOLAY, 1964).

O grau do polinômio determina o nível de suavização da largura dos dados de entrada, juntamente com o tamanho da amostra da janela móvel deslizante. A filtragem ocorre a partir do cálculo do valor do polinômio de mínimos quadrados locais no ponto zero, ao longo de toda a série temporal amostrada (SAVITZKY; GOLAY, 1964).

Para compreender o desempenho da filtagem SG, foi denotado um conjunto temporal chamado de $xt_{(n)}$, sendo a série temporal estimada, enquanto é chamado a série temporal observada de $y_{(n)} = xt_{(n)} + wt_{(n)}$, sendo $wt_{(n)}$ o sinal de ruído aplicado em $y_{(n)}$ (SAVITZKY; GOLAY, 1964). Agora será aplicado o filtro SG à série temporal, sendo $xt_{(n)}$ a saída, podendo ser calculada na seguinte forma (23).

$$xt_{(n)} = \sum_{K=-M}^{M} h_{(n)} y_{(n-K)} \tag{23}$$

Sendo M o parâmetro do filtro SG, $h_{(n)}$ a resposta ao impulso do filtro, dada por $(|h| <= M)$. A filtagem se define em $xt_{(n)}$ em $(n = 0)$ como sendo o coeficiente do polinômio K que melhor se ajusta a $y_{(n)}$ sobre o impulso $(|n| <= M)$.

Agora pode-se calcular o erro quadrático E entre o sinal filtrado e o sinal não filtrado junto ao polinômio $p_{(n)}$, nas equações (24) e (25).

$$p_n = \sum_{K=0}^{K} C_K n^K \tag{24}$$

$$E = \sum_{n=-M}^{M} (y_{(n)} - p_{(n)})^2) \tag{25}$$

O melhor ajuste do polinômio de $xt_{(n)}$, é dado por $p_{(o)} = c_{(o)}$, sendo $c_{(o)}$ o melhor ajuste do coeficiente do polinômio $xt_{(n)}$. Satisfazendo a ordem do polinômio K em que $(0 < K <= 2M)$, com isto, a resposta ao impulso $h_{(n)}$ seja simétrica em torno de $(n = 0)$, resultando assim em $h_{(n)} = h_{(n)}$ (Dai et al., 2017). Ao dar a resposta ao impulso $h_{(n)}$, pode ser calculada a função de transferência do filtro SG pela equação (26).

$$H_{(z)} = \sum_{n} h_{(n)} Z^{-n} \tag{26}$$

5.4 ANÁLISE DE ESPECTRO SINGULAR (AES)

A Análise de Espectro Singular (AES), também conhecida como *Singular Spectrum Analysis* (SSA), é uma ferramenta confiável e eficaz para o tratamento de séries temporais. Ela é utilizada para identificar e extrair tendências, além de componentes periódicos ou ruídos de maneira parcial (Golyandina; Nekrutkin; Zhigljavsky, 2001).

A AES se baseia na decomposição da série temporal original, que pode conter ruídos ou anomalias. O objetivo principal desta técnica é dividir a série em uma soma de componentes, permitindo identificar tendências, ruídos e informações periódicas ou quase periódicas. Após esta decomposição, a série original é reconstruída (Golyandina; Nekrutkin; Zhigljavsky, 2001). Alguns estudos na literatura utilizam a AES como um filtro, visando a remoção de ruídos (Guo et al., 2020) (Hassani; Mahmoudvand; Yarmohammadi, 2010a).

Como o objetivo deste trabalho é suavizar as cargas elétricas dos VEs e das residências utilizando as três técnicas juntas, a AES é introduzida para remover os picos ruidosos gerados pela periodicidade dos carregamentos dos VEs. Estes picos de carga introduzem muitas linearidades na demanda padrão, distorcendo significativamente a série temporal da demanda de cargas residenciais.

A AES é basicamente dividida em quatro etapas: a decomposição da série temporal original em uma matriz; a decomposição via valor singular (DVS); a reconstrução das subséries através da média diagonal; e, por fim, o reagrupamento das séries temporais, removendo ruídos e anomalias (Golyandina; Nekrutkin; Zhigljavsky, 2001). O termo Espectro tem origem na decomposição espectral de uma matriz X através do cálculo dos autovalores λ chamados de conjunto espectral. E o termo singular se refere ao cálculo da matriz singular det (X - λI) (Golyandina; Nekrutkin; Zhigljavsky, 2001).

5.5 AES APLICADO NA SÉRIE TEMPORAL

Nesta seção serão apresentados todos os processos da AES divididos em 4 etapas.

5.5.1 passo 1: introdução da série temporal original

Na primeira etapa da AES, é expressa uma série temporal original de vetor Y = $[y_1, y_2, ..., y_n]^T$, gerada em n pontos. A dimensão de incorporação da AES é chamada de L, sendo K = n - L + 1, e os vetores L-atrasados podem ser definidos pela equação (27) (Golyandina; Nekrutkin; Zhigljavsky, 2001).

$$X_i = [y_i, (y(i+1), \ldots, y(i+L-1]^T, i = 1, 2, ..., K \tag{27}$$

A matriz de trajetória é definida como mostra a equação (28) (Golyandina; Nekrutkin; Zhigljavsky, 2001)

$$X = \begin{pmatrix} y_1 & y_2 & \cdots & y_K \\ y_2 & y_3 & \cdots & y_{K+1} \\ \vdots & \vdots & \ddots & \vdots \\ y_L & y_{L+1} & \cdots & y_n \end{pmatrix} \tag{28}$$

É possível observar que a matriz X é uma matriz quadrada, em que os elementos dela na diagonal $i + j = const$ são iguais.

5.5.2 passo 2: decomposição de valor singular (DVS)

Nesta etapa é considerada a matriz de covariância $S = XX^T$. A decomposição da matriz S é para produzir um conjunto de L autovalores representados por [λ_1, λ_2, …, λ_L] e autovetores correspondentes a [U_1, U_2,…, U_L].

Seja d = max (i, tal que λ_i > 0) e V_i = $X^T \mathrm{U}_i \sqrt{\lambda_i}$ com (i = 1, 2,…, d). A decomposição da matriz de trajetória pode ser expressa na equação (29) (Hassani; Mahmoudvand; Yarmohammadi, 2010a).

$$X = E_1 + E_2 + \ldots + E_d \tag{29}$$

onde E_i = $\sqrt{}\lambda_i U_i V_i^T$ são matrizes elementares, sendo o posto da matriz Xi que é igual a 1. Os vetores (V_1, V_2,..., V_d) são chamados de componentes principais (CP), e os termos $\sqrt{}\lambda_i$, U_i, V_i são denominados como $i - sima$ tripla de decomposição da matriz X.

5.5.3 passo 3: agrupamento

Em seguida da decomposição DVS, é considerada a divisão dos componentes de índice j = (1, ..., d) em m grupos disjuntos (I_1, I_2, ..., I_m). É denotado por I = (i_1, i_2, ..., i_p) como um grupo de índices. Com isto, a matriz resultante X_I corresponde ao grupo I e é definida como sendo X_I = X_{i1} + X_{i2} + ... + X_{ip}. Neste passo, a decomposição da matriz de trajetória pode ser apresentada na equação (30) (Hassani; Mahmoudvand; Yarmohammadi, 2010a).

$$X = X_{I1} + X_{I2} + \ldots + X_{Im} \tag{30}$$

Para um dado I_i, a contribuição do componente X_{Ii} pode ser computada pela parte dos autovalores respectivos como ilustra a equação (31) (Hassani; Mahmoudvand; Yarmohammadi, 2010a)

$$\sum_{i \in Ii} \lambda_i / \sum_{i=1}^{d} \lambda_i \tag{31}$$

O número de valores singulares selecionados de d será denotado neste processo por r, que é chamado de grupo para reconstrução.

5.5.4 passo 4: cálculo da média diagonal

Nesta etapa é feito o cálculo da média diagonal, em que cada matriz é transferida para uma série temporal. Dado Z sendo uma matriz $(L \times K)$ com elementos Z_{ij}, com 1 $\leq$i$\leq$Le1$\leq$j$\leq$K.

Definindo L^* = $min\ (L, K)$, e K^* = $max\ (L, K)$ e n = K + L - 1. Seja Z_{ij}^* = Z_{ij} se L < K, caso contrário, Z_{ij}^* = Z_{ij}. Após esta etapa, a média diagonal transfere a matriz Z para uma série temporal [Z_1, Z_2, ..., Z_n] calculada da equação (32) (Hassani; Mahmoudvand; Yarmohammadi, 2010a):

$$y_K = \begin{cases} \frac{1}{K} \sum_{q=1}^{K+1} Z_q^*, K - q + 1, 1 \leq K \leq L^* \\ \frac{1}{L^*} \sum_{q=1}^{L^*} Z_q^*, K - q + 1, L^* < K \leq K^* \\ \\ \frac{1}{n-K+1} \sum_{q=K-K^*+1}^{n-K^*+1} Z_q^*, K - q + 1, K^* < K \leq n \end{cases} \tag{32}$$

A equação (32) calcula a média dos elementos da matriz ao longo das diagonais $i + j = K + 1$. Após este cálculo, é gerada uma série temporal Y de comprimento n, através da média diagonal descrita aplicada a matriz X_{In} com $n = 1, 2$. Com isto, a série temporal com ruídos original Y_0 pode ser decomposta em uma soma de duas séries pelo (AES), conforme a equação (33) (Hassani; Mahmoudvand; Yarmohammadi, 2010a).

$$Y_0 = Y_1 + Y_2 \tag{33}$$

A dimensão de comprimento L, também chamada de comprimento da janela, e o número de componentes selecionados por r são os dois principais parâmetros de exigência na AES. Os parâmetros L e r podem ser definidos a partir da série temporal estudada (Golyandina; Nekrutkin; Zhigljavsky, 2001).

O comprimento da janela L é selecionado geralmente, sendo $L < \frac{T}{2}$. Dependendo das características distintas do tipo de série temporal estudada originalmente, pode-se definir L como proporcional a este período, obtendo-se uma melhoria na separação dos componentes (Hassani; Mahmoudvand; Yarmohammadi, 2010b).

6 MATERIAIS E MÉTODOS

6.1 BANCO DE DADOS DE CARREGAMENTO RESIDENCIAL

Para aplicar o método proposto, foram considerados três conjuntos de dados do mundo reais, conforme descrito em (Muratori, 2018). Os dados abrangem 200 residências na região centro-oeste dos Estados Unidos (EUA), compostos por 502 indivíduos e 348 VEs. As medições de carga foram registradas em termos de potência elétrica em watts (W), com uma resolução de 10 minutos ao longo de um ano de 2018, totalizando 52.560 medições para cada conjunto de dados.

Os tipos de VEs que constam nos bancos de dados apresentaram duas configurações: na primeira, um VEHP com 60% elétrico, com um alcance de aproximadamente 322 km de autonomia; na segunda, abordam os veículos elétricos híbridos plugáveis (VEHP) com uma taxa de 40% de carga elétrica e um alcance total de cerca de 65 km. Ambos foram carregados por meio de tomadas de níveis 1 e 2, com potências de 1920 W e 6600 W, respectivamente.

Desta forma, o primeiro banco de dados explorará as medições dos 348 VEPs em nível 1 de potência, o segundo abordará os 348 VEPs em nível 2 de potência, e o terceiro incluirá as medições das 200 residências.

Para os dois bancos de dados serão apresentadas todas as etapas da metodologia desenvolvidas neste trabalho por meio de um diagrama, na figura Figura 4.

Os dados originais foram extraídos em dois arquivos distintos: um referente ao nível 1 de carregamento e o outro ao nível 2 de carregamento. Ambos os arquivos incluem o mesmo banco de dados das cargas residenciais. As medições possuem uma resolução de 10 minutos e estão organizadas por domicílios, totalizando 200 residências com 502 indivíduos habitando. Os carregamentos foram realizados de maneira descontrolada e aleatória, distribuídos nas 200 residências, apresentando a mesma configuração, mas com 348 veículos elétricos sendo carregados, tanto para o nível 1 quanto para o nível 2 de potência (Muratori, 2018).

6.2 BANCO DE DADOS DE ESTAÇÃO DE CARREGAMENTO

Os dados são descritos como estação de carregamento de uma grande loja varejista, como Walmart Supercenter ou Kroger Marketplace, onde os clientes utilizam as estações de recarga enquanto frequentam as lojas. Os dados contêm as demandas dos edifícios comerciais e suas estações de carregamento, conforme descritos em (Gilleran et al., 2021).

As cargas elétricas dos edifícios são de Phoenix, Houston, Denver e Minneapolis, e a construção total é de 19.500 metros quadrados. O perfil da carga elétrica não apresenta mudanças ao longo de uma semana, pois o perfil do edifício opera sempre da mesma forma diariamente, funcionando 24 horas por dia, 7 dias por semana, com medições de um intervalo de 10 minutos

Figura 4 – Diagrama da Metodologia



Fonte : Autoria própria

no ano de 2021.

Os VEPs utilizados nestas estações são diversos, como veículos esportivos, caminhões, VEPs com 150, 275 e 350 km de autonomia, caminhões híbridos com 50% elétrico, VEHP com 20% e 50% elétrico. As estações de carregamento apresentam 3 níveis de potência de carga, sendo 50 kW, 150 kW e 350 kW. E cada nível de potência possui saídas de conexão com 2 portas e 6 portas, com variedades de eventos de conexão, sendo 2, 8 e 16.

Os tipos e os perfis dos VEPs utilizados nestas estações podem ser vistos na tabela 1.

Figura 5 – Demanda residencial original



Fonte : Autoria própria

Figura 6 – Demanda VEs nível 1 original



Fonte: Autoria própria

Tabela 1 – Detalhes da frota dos VEs.

Tipo de VEs	Compartilhamento	Autonomia (milhas)	Bateria (kWh)	Carregamento (kW)
Carro esportivo	1 %	250	87,5	300
Caminhão	25 %	200	95	150
VE 275	27 %	275	82,5	150
VE 350	6 %	350	75	75
VE 150	13 %	150	45	50
Caminhão 50	8 %	50	23,75	nenhum
VEHP 50	13 %	50	15,5	nenhum
VEHP 20	7 %	20	5	nenhum

Fonte: Elaborada pelo autor

Figura 7 – Demanda VEs nível 2 original



Fonte: Autoria própria

6.3 EXTRAÇÃO DA SÉRIE TEMPORAL (CARGAS ELÉTRICAS) CARREGAMENTO RESIDENCIAL

Para facilitar a visualização, as Figura 5, Figura 6 e Figura 7 mostram como se comportam ao longo do tempo as medições dos dados descritos, ao longo de uma semana.. Todas as três figuras estão representadas em uma janela temporal de 144 medições, correspondendo às primeiras medições do início do ano, referentes à primeira semana de janeiro do banco de dados.

A Figura 5 representa a demanda total residencial medida já com resolução de 1 hora; esta demanda será chamada em diante de $D_{residencial}$.

A próxima demanda total vista pela figura Figura 6 é a dos VEs de nível 1 de potência com 1920 W. Esta demanda pode ser chamada também de $D_{veiculonivel1}$.

Por fim, a figura Figura 7 apresenta a demanda total de nível 2 de potência com 6600 W. Podendo ser chamada também por $D_{veiculonivel2}$.

6.4 EXTRAÇÃO DA SÉRIE TEMPORAL (CARGAS ELÉTRICAS) É PRÉ-PROCESSAMENTO DO BANCO DE DADOS DE ESTAÇÃO DE CARREGAMENTO

Os dados originais da demanda comercial e da estação de carregamento se encontram na resolução de 1 minuto, em curtíssimo prazo, com medições no período de 1 ano. Inicialmente, optou-se por mudar esta resolução de medição de minutos para horas no intervalo de 00 horas a 23 horas, resultando em curto prazo. Com isto, foram diminuídos os dados de 525.600 amostras para 8.760 amostras.

Foram analisadas todas as 4 demandas comerciais das 4 cidades do banco de dados, e foi escolhida a cidade de Houston por apresentar o maior consumo de potência ao longo do ano. E para o perfil da estação de carregamento, optou-se por utilizar a estação com 2 e 6 portas com 16

eventos de carregamento de nível 3 de potência com 350 kW. Esta escolha foi feita por apresentar o cenário mais agressivo, com maiores impactos no setor de potência elétrica, onde se observa o maior grau de preocupação, dificuldade de previsão e a maior quantidade de energia necessária.

Com isto, foi utilizado o mesmo processo do banco de dados residencial, onde foi somada a demanda comercial da cidade de Houston a cada demanda das duas estações de carregamento. Com isto, foram geradas duas demandas para o processo visto anteriormente, ficando uma demanda total com duas portas e outra demanda total com 6 portas. A seguir, a Figura 8 apresenta como se comporta a demanda comercial de Houston em um período de 1 semana.

Figura 8 – Demanda comercial da cidade de Houston



Fonte: Autoria própria

Na Figura 9 será apresentado a demanda de estação de carregamento com 2 portas, 16 eventos de recargas e nível 3 de potência com 350 kW, em um período de 1 semana.

Figura 9 – Demanda da estação de carregamento com 2 portas



Fonte: Autoria própria

E, por fim, será apresentada na Figura 10 demanda de estação de carregamento com 6 portas, 16 eventos de recarga e nível 3 de potência com 350 kW, em um período de 1 semana.

Figura 10 – Demanda da estação de carregamento com 6 portas



Fonte: Autoria própria

Em seguida, foi somada cada demanda da estação à demanda comercial, resultando assim em duas demandas totais, como visto na Figura 11.

Demanda total considerando a demanda comercial + estação de carregamento com 6 portas (em azul) e a demanda comercial + estação de carregamento com 2 portas (vermelho).

Figura 11 – Demanda da estação de carregamento com 6 portas



Fonte: Autoria própria

Estas duas demandas geradas serão usadas em diante para todo o processo de pré-processamento, treinamento, testes e previsões.

6.5 PRÉ-PROCESSAMENTO DO BANCO DE DADOS DE CARREGAMENTO RESIDENCIAL

Os dados originais, apresentados com resolução de 10 minutos e totalizando 52.560 amostras, foram agrupados para uma resolução de 1 hora. Todas as medições das residências e dos carregamentos dos VEPs em cada hora foram somadas, resultando em medições que variam de 00:00 até 23:00. Esta transformação reduziu as 144 medições (com 10 minutos cada) para 24 medições (com 1 hora cada) em cada dia. Com isto, o conjunto total de dados foi reduzido para 8.760 medições, correspondendo a um ano inteiro.

Os dados foram organizados em três categorias de demanda: a primeira corresponde às 200 residências, a segunda aos 348 VEPs do nível 1, com uma potência de 1920 W, e a terceira aos 348 VEPs do nível 2, com uma potência de 6600 W. Para cada demanda, foi gerada uma coluna única contendo todas as medições, resultando na soma das 200 residências e dos 348 veículos, formando dois vetores de 8760 × 1 para cada nível de potência, representando os consumos ao longo de um ano. As demandas totais foram calculadas pela soma de todas as cargas correspondentes a cada hora, dia e mês, tanto para a demanda residencial quanto para os VEPs, nos níveis 1 e 2 de potência, conforme apresentado na equação (34).

$$D_{total1} = D_{residencial} + D_{veiculonivel1} \tag{34}$$

onde D_{total1} a demanda agregada total para previsão respectivo ao nível 1; $D_{residencial}$ a demanda total residencial; $D_{veiculo}$ a demanda total VEs nível 1.

A equação (35) apresenta o mesmo processo referente ao banco do nível 2 de potência de 6660 W.

$$D_{total2} = D_{residencial} + D_{veiculonivel2} \tag{35}$$

onde D_{total2} a demanda agregada total para previsão respectivel ao nível 2; $D_{residencial}$ a demanda total residencial; $D_{veiculonivel2}$ a demanda total de VEs nível 2.

Após a realização de todo este processo, pode-se observar como ficaram as novas demandas, que serão utilizadas em seguida nos pré-processamentos, treinamento e previsões da metodologia.

A (Figura 12) ilusta os resultados das duas somas feitas pelas demandas de nível 1 e 2, demonstrada parcialmente em 48 horas. Sendo que a Demanda total nível 1 se refere a D_{total1} e a Demanda total nível 2 se refere a D_{total2}, que serão utilizadas depois para o pré-processamento, treinamento e previsão.

6.6 PARÂMETROS E AJUSTES DOS PRÉ-PROCESSAMENTOS DE CARREGAMENTOS RESIDENCIAL

Nesta etapa, serão discutidos e demonstrados todos os processos, etapas e parâmetros envolvidos nos três pré-processamentos utilizados para desenvolver a metodologia proposta,

Figura 12 – Demandas totais níveis 1 e 2



Fonte: Autoria própria

seguindo a ordem cronológica das técnicas aplicadas, uma de cada vez, sendo iniciadas com a TW, a AES e o Filtro SG. Os pré-processamentos serão realizados nas duas demandas geradas, focando exclusivamente nas cargas elétricas, representadas por D_{total1} e D_{total2}. Para facilitar a visualização, as técnicas aplicadas serão ilustradas apenas na demanda de nível 1, permitindo uma comparação mais clara das séries temporais das cargas elétricas, com o objetivo de reduzir a quantidade de gráficos apresentados. Vale ressaltar que os pré-processamentos foram aplicados separadamente nas duas demandas analisadas.

Primeiramente, foi utilizada a técnica da transformada wavelet, aplicada aos dados originais das cargas elétricas. Para implementar esta técnica, foram empregadas as ferramentas *Signal Analyzer* e *Wavelet Denoising* do *software Matlab 2023b*. Estas ferramentas permitem analisar a série temporal das cargas elétricas originais e, em seguida, determinar a melhor função wavelet e seus parâmetros, adequados a esta série temporal estudada.

Após a análise das duas demandas totais, selecionaram-se alguns parâmetros para aplicar a TW. O primeiro passo foi identificar a função que mais se adequava a série temporal original. Com base na análise, a função *Wavelet* escolhida foi a do tipo Symlet 4 (*sym4*). Como a série contém 8760 dados, a decomposição foi definida em 10 níveis, utilizando o método de decomposição bayesiana com uma regra de limite baseada no cálculo da mediana. Todos estes parâmetros foram determinados por meio da ferramenta *Signal Analyzer* no Matlab 2023b.

Com isto, os dados originais foram inseridos na ferramenta *Wavelet Denoising* para aplicar a transformação das cargas elétricas e a decomposição da série temporal. A série foi decomposta em 10 níveis e, em seguida, reconstruída, resultando na transformação dos dados originais processados pela função *sym4*. Esta transformação pode ser visualizada na Figura 13.

Em seguida serão demonstrados os níveis de decomposição da transformada *Wavelet sym4* aplicado à série da demanda total de nível 1, como é visto na Figura 14

Em seguida, será apresentado o segundo pré-processamento, no qual será inserida a série

Figura 13 – Demanda total nível 1 com wavelet



Fonte: Autoria própria

Figura 14 – Decomposição da série temporal utilizando a Transformada Wavelet sym4. *Wavelet sym4*



Fonte: Autoria própria

temporal das cargas elétricas resultante da transformada *Wavelet sym4*.

A segunda técnica aplicada é a Análise Espectral Singular (AES), que considera uma série com 8760 dados, conforme descrito no algoritmo na seção 5 como o parâmetro r. O outro parâmetro utilizado é o L, que representa o comprimento da janela móvel deslizante, atribuído a um valor de 5.

É possível descrever as etapas feitas pelo algoritmo da AES, com todos os processos e cálculos previamente descritos (Golyandina; Nekrutkin; Zhigljavsky, 2001).

Após a criação da série temporal da demanda total *sym4*, procede-se ao cálculo da matriz de covariância C, seguido pelo cálculo da matriz de trajetória. Em seguida, escolhe-se a estimativa da covariância, e realiza-se o cálculo dos autovalores λ e dos autovetores, denominados RHO.

Com estes cálculos, são determinadas as componentes principais PC. Após a conclusão destas etapas, inicia-se a fase de reconstrução, em que se calculam as componentes reconstruídas RC e compara-se a reconstrução com a série temporal original (Golyandina; Nekrutkin; Zhigljavsky, 2001).

Pode-se ilustrar todo o processo descrito acima de maneira sequencial de como foram feitas todas as etapas do algoritmo da AES. Os dados da demanda pré-processada com a TW são inseridos na matriz X, sendo o início do novo pré-processamento Figura 15.

Figura 15 – Matriz da série temporal X da demanda pré-processada com TW



Fonte: Autoria própria

Em seguida, é calculada a matriz de covariância C, com $L = 5$, ilustrada pela, equação (36)

Figura 16 – Matriz de covariância C



Fonte: Autoria própria

Nesta parte foi descrito a matriz C calculada pela equação (36)

$$C = \begin{pmatrix} 0,9997 & 0,9540 & 0,8911 & 0,8045 & 0,70475 \\ 0,9540 & 0,9995 & 0,9539 & 0,8910 & 0,8044 \\ 0,8911 & 0,9539 & 0,9994 & 0,9538 & 0,8910 \\ 0,8045 & 0,8910 & 0,9538 & 0,9994 & 0,9538 \\ 0,7047 & 0,80443 & 0,8910 & 0,9538 & 0,99950 \end{pmatrix} \tag{36}$$

Para o próximo passo, são calculados os autovalores λ e os autovetores RHO da matriz C. Com este cálculo, são retornadas duas matrizes, sendo a matriz RHO com autovetores em colunas e a matriz λ com autovalores pela diagonal principal Figura 17.

Figura 17 – Autovalores λ e autovetores RHO



Fonte: Autoria própria

A matriz C previamente apresentada anterior, calculadas pelo respectivos autovalores apresentado por λ, pode ser descrita na equação (37)

$$\lambda = \begin{pmatrix} 4,52496313043172 \\ 0,377814118144527 \\ 0,047232426337992 \\ 0,025488931374379 \\ 0,022145334870979 \end{pmatrix} \tag{37}$$

E para a matriz RHO com os autovetores, foi calculado e resulta na seguinte equação 38

$$RHO = \begin{pmatrix} 0,430374 & -0,61820 & 0,536279 & 0,343168 & -0,165050 \\ 0,45522 & -0,343128 & -0,212054 & -0,6181667 & 0,4979323 \\ 0,463870 & -3,51265^{-5} & -0,578598 & -0,00027446 & -0,670856 \\ 0,455202 & 0,343149 & -0,212295 & 0,6183695 & 0,49758346 \\ 0,4303076 & 0,61833264 & 0,536275 & -0,343109 & -0,164877 \end{pmatrix} \tag{38}$$

Em seguida, são calculadas as componentes principais PC, dadas pelo produto escalar entre Y e os vetores de RHO. Estas componentes podem ser visualizadas pelas curvas da Figura 18.

Figura 18 – Cálculo das principais componentes PC



Fonte: Autoria própria

No estágio seguinte, as componentes de reconstrução dos RC são calculadas. Essa reconstrução dos RC é obtida através da inversão da projeção PC. Assim, a média ao longo das antidiagonais fornecerá as componentes de reconstrução RC para a matriz original X. É possível analisar o comportamento das RC na Figura 19.

Figura 19 – Cálculo das componentes principais RC



Fonte: Autoria própria

Por fim, pode-se observar a comparação da série original com a reconstruída, usando os 5 autovalores de r. É possível observar que a série temporal original X pode ser completamente reconstruída pela soma de todos os componentes reconstruídos RC. Com isto, a função original pode ser reconstruída com o primeiro par de RC, apresentada na Figura 20.

Figura 20 – Comparação da série original e reconstruída



Fonte: Autoria própria

O primeiro gráfico da Figura 20 todo em vermelho representa a reconstrução sem erros dos cálculos, com isso, os dados originais e reconstruídos ficam sobrepostos. Já no segundo gráfico, é apresentada a mesma série original e reconstruída aplicando o AES, onde a série foi pré-processada.

Após a reconstrução correta da série pré-processada com a AES, é possível observar o aprimoramento dos aspectos visuais dos dados com a aplicação desta segunda técnica, conforme ilustrado na Figura 21. Comparação das curvas de carga ao longo de 48 horas pré-processadas com a Transformada Wavelet e com a Transformada Wavalet + AES.

Figura 21 – Demanda wavelet pré processada com AES



Fonte: Autoria própria

Embora a demanda ainda apresente alguns ruídos e linearidades, a segunda técnica conseguiu atenuar estas características indesejáveis, resultantes dos carregamentos descontrolados dos

VEs, que distorcem o perfil padrão da demanda residencial. Observa-se que esta técnica proporcionou uma melhoria significativa na suavização, permitindo que a AES se aproximasse e acompanhasse o perfil da demanda com wavelet, sem comprometer as características da demanda pré-processada. Além disto, a série reconstruída a partir do cálculo das componentes reconstruídas (RC) demonstrou um bom alinhamento com a série original utilizando TW.

Após a aplicação das duas primeiras técnicas de pré-processamento, agora será introduzido a última, que utiliza um filtro de suavização. Esta técnica possui apenas dois parâmetros: o primeiro é o grau ou ordem do polinômio utilizado, e o segundo é o parâmetro de janela deslizante, chamado de *framelen*, que define a quantidade de dados selecionados da série temporal analisada. O terceiro método que usamos para pré-processar os dados é o filtro digital Savitzky-Golay, que já foi mencionado antes. Esse filtro funciona aproximando os dados com um polinômio, e escolhemos um polinômio de terceira ordem para isso. Além disso, definimos o tamanho da janela deslizante como 5.

Após feito a filtagrem com SG, pode-se observar pela Figura 22 como se comporta este último pré-processamento.

Figura 22 – Demanda walvelet AES pré processada com SG



Fonte: Autoria própria

Inicialmente, foi possível observar que a técnica levemente suavizou tanto os picos quanto os vales da demanda, além de eliminar as características lineares dos picos, resultando em uma resposta promissora para o processamento. Também foi notável que esta terceira técnica não provocou a perda das características pré-processadas anteriormente, mantendo a suavização e preservando a tendência da demanda analisada.

Após a realização dos três pré-processamentos, que compõem a metodologia proposta neste trabalho, a demanda resultante será utilizada para o treinamento, combinando as técnicas wavelet, AES e SG. Pode-se observar graficamente o resultado da aplicação desses três pré-processamentos ao compararmos com a demanda original, conforme ilustrado na Figura 23.

Figura 23 – Demanda de nível 1 com os 3 pré-processamento e demanda original



Fonte: Autoria própria

6.7 SEPARAÇÃO DOS CONJUNTOS DE TREINAMENTOS E TESTES

Inicialmente, todas as separações foram feitas para os dois bancos de dados propostos nesta pesquisa. Para aplicar a metodologia proposta neste trabalho, os dados foram divididos em dois conjuntos: 70 % para treinamento e 30 % para teste nos 3 primeiros meses dos banco de dados, utilizando a demanda total nos níveis 1 e 2. O conjunto total, composto por 8.760 medições, foi segmentado para avaliar a metodologia, com os primeiros três meses do ano, de 01/01 até 31/03, contendo 2.232 medições. Com base nesta divisão, foram geradas previsões para as próximas 24 horas de cada dia. As dimensões do conjunto de treinamento são 5×1561 entrada de treinamento, 1×1561 saída de treinamento, 5×668 entrada de teste e 1×668 saída de teste. As matrizes de entrada e teste para ambas as demandas são compostas pelas seguintes variáveis:

- Dias: $[1 \ldots 31]$ = variável referente aos dias;
- Semanas: $[1 \ldots 7]$ = variáveis para as semanas de segunda a domingo;
- Meses: $[1 \ldots 12]$ = variáveis dos meses de janeiro a dezembro;
- Tempos: $[00 \ldots 23]$ = variáveis para as horas (h) no período de 24 horas;
- Cargas (h): [demanda agregada total] = variáveis de carga referentes à hora (h) em *Watts*.

O conjunto de saída da RNA é composto pela variável de demanda agregada total, com $(h + 1)$ representando as medições de carga para a hora seguinte $(h + 1)$, em *Watts*.

6.8 NORMALIZAÇÃO E TREINAMENTO

Foi testada inicialmente a normalização nos vetores das demandas 1 e 2 e da estação de carregamento, utilizando, por padrão, normalização no intervalo de 0 a 1. Porém, ao testar o

modelo com esta normalização junto do treinamento e teste, os resultados não foram satisfatórios quanto a não normalizá-los. Com isto, foi investigado que esta piora nos resultados foi devida ao conflito da própria normalização interna que é feita no processo de regularização bayesiana, visto já por $P(|D, \alpha, \beta, M)$, onde este processo representa a normalização que garante que a probabilidade total seja 1. Por fim, não foi necessário normalizar as cargas neste trabalho.

6.9 AJUSTES DO MODELO, PREVISÕES E RESULTADOS

Para obter uma melhor configuração da arquitetura da MLPR neste trabalho, foram realizados testes exaustivos variando o número de camadas ocultas e o número de neurônios nas camadas ocultas. A melhor configuração encontrada foi aquela com seis neurônios na primeira camada oculta, 2 na segunda camada oculta e 1 na terceira camada oculta. Foi utilizada a função de ativação tangente hiperbólica (Sigmóide 1). Na parte dos vetores de recorrência entre as camadas, foi utilizado um único vetor de atraso entre as camadas da MLPR.

O *software* utilizado para modelagem, transformada *Wavelet*, AES, filtragem, treinamento e previsão foi o software Matlab 2015b e 2023b. No treinamento, o conjunto de dados é dividido aleatoriamente por padrão; mesmo ao dividir o conjunto em 70%, o algoritmo divide esse valor em ordem aleatória atualizando todas as vezes que os dados são treinados, para tornar o processo de treinamento mais robusto sem estar associado a uma única resposta. Dentro do próprio processo de treinamento, é demonstrado também como os dados se comportam com uma validação dos dados e testes em tempo real. Feito todo este processo, foram utilizados os 30% dos testes para obter as previsões das demandas 1 e 2 e da estação de carregamento.

A metodologia utilizada para avaliar acertos e erros tanto do treinamento e do teste quanto da previsão das duas demandas 1 e 2 e da estação de carregamento foi o erro percentual médio absoluto (MAPE) visto pela equação (39) (Kim; Kim, 2016) (Park et al., 1991).

$$MAPE = \frac{1}{num} \sum_{h=1}^{num} \left(\left| \frac{Dtreal_{(h)} - Dtprevisto_{(h)}}{Dtreal_{(h)}} \right| \right) * 100 \tag{39}$$

o valor num é o número total de horas; $Dtreal_{(h)}$ o valor real no tempo h da demanda total e $Dtprevisto_{(h)}$ o valor previsto pela rede no tempo h da demanda total. A previsão da demanda será feita em um período de 24 horas em cada dia; portanto, serão analisadas 24 medições, no intervalo de 00 a 23 horas.

Para fins de comparações entre as metodologias apresentadas, será avaliado o MAPE antes da aplicação do pré-processamento e o MAPE após a aplicação do pré-processamento, sendo gerado assim um ganho de MAPE como demonstrado na equação (40) (Kim; Kim, 2016) (Park et al., 1991).

$$MAPE_{ganho} = \left| \frac{MAPE_{anterior} - MAPE_{atual}}{MAPE_{anterior}} \right|) * 100 \tag{40}$$

para o $MAPE_{anteriror}$ é a avaliação da previsão da demanda antes do pré-processamento, e $MAPE_{atual}$ a avaliação da previsão da demanda após o pré-processamento. Este processo será utilizado para comparar, a cada demonstração de aplicação dos pré-processamentos, os quais serão comparados com os três: transformada wavelet, AES, filtro SG e o método proposto com os 3 aplicados juntos e separados.

6.10 PREVISÕES E RESULTADOS

Para aplicar todo o pré-processamento e processamento da metodologia proposta, foi utilizado um ambiente experimental com um $Notebook\ Gamer\ Acer\ Predator$ modelo $PH315-54$. Pode-se observar melhor as informações descritas do hardware e do software na Tabela 2.

Tabela 2 – Ambiente experimentar

Sistema operacional	*Windows* 11
Processador	*Intel Core* i7 11 geração 2.3 GHz 8 núcleos
Placa gráfica dedicada *off board*	*NVIDIA GeForce RTX* 3600 6 GB
Memória RAM	16 GB
Memória de armazenamento	SSD NVMe 1 TB
Placa de vídeo on board	Intel gráfica UHD 2 GB
Software processamento	Matlab 2015b
Software pré-processamento 1	Matlab 2023b (*Synal analysed*)
Software pré-processamento 1	Matlab 2023b (*Walvelet denoised*)
Software pré-processamento 2	Matlab 2023b (AES)
Software pré-processamento 3	Matlab 2023b (SG)

Fonte: Elaborada pelo autor

Foram realizados inúmeros testes nas configurações das camadas ocultas e no número de neurônios, e observou-se que a melhor configuração da rede foi com três camadas ocultas, caracterizando um aprendizado profundo. Esta configuração apresentou o melhor desempenho em termos de precisão e estabilidade durante o treinamento. Quando um número elevado de neurônios foi utilizado nas camadas ocultas, o treinamento ficou superajustado, com baixa taxa de erro. No entanto, ao serem testados para previsões, os erros aumentaram significativamente, prejudicando os resultados.

Observou-se que, com menos de três camadas ocultas, a rede perdia precisão, revelando uma limitação na arquitetura durante o treinamento. Por outro lado, com mais de três camadas ocultas, a rede perdia estabilidade no treinamento. A arquitetura do modelo proposto conseguiu alcançar uma melhoria significativa no processo de aprendizagem, identificando a melhor configuração em relação ao número de neurônios e camadas ocultas para os dados estudados.

Outro ponto relevante foi que, ao utilizar um aprendizado profundo com três camadas ocultas e poucos neurônios por camada, o custo computacional se manteve baixo, com processamento eficiente em termos de tempo, memória e rápida convergência.

Nesta parte serão apresentados todos os parâmetros encontrados para a melhor configuração do treinamento e da MLPR, como ilustrado na Tabela 3:

Tabela 3 – PARÂMETROS DE TREINAMENTO E ARQUITETURA DA MLPR

Função de ativação	Tangente hiperbólica
Números de neurônios por camada	(5-6-2-1-1)
Números de camadas ocultas	3
Números de neurônios por camadas ocultas	(6-2-1)
Função de desempenho	Erro quadrático médio (mse)
Taxa de aprendizagem a_1	0.005
Regulação bayesiana inicial α	0
Regulação bayesiana inicial β	1
Número máximo de épocas	5000
Objetivo de desempenho	0
Fator de decrescimento LM (μ)	0.1
Fator de crescimento LM (μ)	10
Valor máximo LM (μ)	1x10^{10}
Valor máximo de falhas à frente	500
Valor mínimo do gradiente	1x10^{-9}
Tempo de treinamento (s)	∞

Fonte: Elaborada pelo autor

Primeiramente, serão apresentados todos os processos e resultados dos treinamentos com 70 %, testes 30 % e os dias das previsões. Para realizar comparações entre as técnicas propostas, foi utilizado as mesmas datas de início e término para o treinamento, assim como para as previsões, assegurando que todas as comparações sejam feitas prevendo o mesmo dia. Neste contexto, foram previstos os primeiros dias de cada técnica.

Foram feitos os cálculos dos MAPEs do conjunto de treinamento e teste e da previsão em 24 horas do dia. Todo este processo será aplicado nas duas demandas totais 1 e 2 e na estação de carregamento.

6.11 PREVISÕES E RESULTADOS: DEMANDA TOTAL NÍVEL 1 (CAREGAMENTO RESIDENCIAL)

Primeiramente, serão apresentadas as comparações entre as técnicas e modelos utilizados, incluindo o BPAT isoladamente e o BPAT em conjunto com a RB proposta sem pré-processamento. Como o BPAT necessita da normalização dos dados, esta comparação será realizada apenas com os dados das cargas elétricas normalizados entre 0 e 1.

Como o BPAT exige uma grande quantidade de dados para convergir, ele não se mostrou satisfatório com apenas 1560 dados de treinamento com cargas elétricas originais. Por isto, o número de épocas de treinamento foi aumentado, passando de 5.000 para um máximo de 25.000 épocas. A taxa de aprendizado utilizada foi de 0,01 com um valor mínimo de gradiente de 10^{-4}. O algoritmo foi executado até atingir o limite máximo de 500 falhas estipuladas.

O treinamento começa a estabilizar a performance do gradiente a partir de 10.000 épocas, diminuindo o seu erro de treinamento, alcançando a melhor performance em 25.000 épocas. Os valores iniciais do gradiente estavam próximos de 10^{-1} e chegaram a cerca de 10^{-3}. Ao final do treinamento e do cálculo do gradiente, o melhor valor obtido foi de 0,0017, representando a somatório do erro quadrático médio do BPAT.

Junto ao treinamento representado em azul nos gráficos, também foram analisados a validação onde representa as curvas em verde nos gráficos e os testes em vermelho nos gráficos, tudo isso ilustrado de forma simultânea. Observou-se que o treinamento, a validação e o teste apresentaram a mesma convergência. Assim, foi possível calcular o MAPE para ambos os conjuntos. Para o conjunto total de treinamento, o MAPE foi de 9,33%, enquanto para o conjunto total de teste, o MAPE foi de 11,24%. Para fins de comparação entre todos os processos verificados nesta pesquisa, serão analisadas as primeiras 24 horas do conjunto de testes, que apresentaram uma previsão com MAPE de 9,31%.

Para o treinamento proposto com BPAT e RB, o valor do gradiente inicia-se em torno de 10^{-1}, alcançando a melhor performance com 10^{-3}, resultando em um somatório do erro quadrático médio de 0.0012. Diferentemente do BPAT sem a RB, onde o melhor desempenho foi alcançado na época 85, no caso com RB, o MAPE do conjunto total de treinamento caiu para 6,23%, enquanto o MAPE do conjunto total de teste foi de 8,53%. A previsão apresentou um MAPE de 5,52%.

Figura 24 – Demanda nível 1 prevista com treinamento BPAT e BPAT-RB



Fonte: Autoria própria

É possível observar como foi o desempenho das previsões das demandas com BPAT e BPAT-RB, apresentado na figura Figura 24.

Para uma análise visual mais detalhada, a Figura 25 mostra como foi o processo de treinamento, teste e validação do treinamento BPAT-RB com os dados originais da demanda total de nível 1.

Figura 25 – Processo de treinamento da Demanda nível 1 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Como observado, o treinamento proposto melhorou o processo aplicado na demanda de nível 1. Para fins de comparação do modelo, nesta etapa foi apresentada apenas a metodologia para o nível 1, mas os resultados também indicaram uma significativa melhoria nas previsões. Para evitar a sobrecarga de gráficos nesta pesquisa, optou-se por mostrar apenas os dados referentes ao nível 1, relacionados ao BPAT e ao BPAT com RB.

6.12 PREVISÃO DAS DEMANDA EM NÍVEIS 1 E 2 COM METODOLOGIA PROPOSTA

Para validar a metodologia proposta com pré-processamento, nesta seção serão apresentados os resultados obtidos dos treinamentos, testes e previsões das demandas dos níveis 1 e 2. A primeira técnica a ser analisada é a transformada wavelet. Para a demanda de nível 1, o MAPE do conjunto de treinamento foi de 2,4969%, enquanto o MAPE do teste foi de 3,7137% e a previsão resultou em um MAPE de 4,1258%. Pode-se observar na Figura 26 a previsão da demanda em nível 1 utilizando a transformada wavelet.

Para uma análise visual mais detalhada, a Figura 27 mostra como foram o processo de treinamento, o teste e a validação do treinamento do BPAT-RB com a aplicação da transformada wavelet sym4 na demanda total de nível 1.

Inicialmente, foi possível observar o quanto houve uma melhora no processo de treinamento com a diminuição do gradiente, quando comparamos com o método só com dados originais. O número de épocas treinadas também cai com a aplicação da TW sym4, apresentando mais facilidade na compreensão dos dados treinados.

No próximo pré-processamento, com a introdução do AES, serão apresentados os resultados obtidos. O MAPE do treinamento apresentou um erro de 1,4921%, enquanto o teste teve um MAPE de 2,67%. Para a previsão, o MAPE foi de 2,9655%, como pode ser observado na Figura 28.

Figura 26 – Previsão Demanda nível 1 com TW



Fonte: Autoria própria

Figura 27 – Processo de treinamento com TW da Demanda nível 1 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Para uma análise visual mais detalhada, a Figura 29 mostra como foram o processo de treinamento, o teste e a validação do treinamento do BPAT-RB com a aplicação da AES na demanda total de nível 1.

Por último, serão apresentados os resultados da metodologia proposta neste trabalho com a utilização dos três pré-processamentos juntos, TW+AES+SG. Os resultados do treinamento obtiveram um MAPE de 1,1130%, teste com MAPE de 2,2152% e, para a previsão, o MAPE foi obtido com 2,4028% observado na Figura 30.

Para uma análise visual mais detalhada, a Figura 31 demonstra como foi o processo de treinamento, teste e validação do treinamento BPAT-RB com a aplicação do filtro SG na demanda total de nível 1, sendo o método proposto.

Figura 28 – Previsão Demanda nível 1 com TW+AES



Fonte: Autoria própria

Figura 29 – Processo de treinamento com AES da Demanda nível 1 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Nesta próxima etapa serão apresentados os resultados obtidos da demanda total em nível 2.

Inicialmente, serão mostrados os resultados obtidos em relação aos dados originais da demanda em nível 2, com o treinamento BPATRB. Para o MAPE de treinamento foi obtido um erro de 6,0113%, teste com MAPE 9,3501% e na previsão o MAPE foi de 7,0258% podendo ser visto na figura Figura 32.

Para uma análise visual mais detalhada, a Figura 33 demonstra como foram o processo de treinamento, o teste e a validação do treinamento do BPAT-RB com dados originais na demanda total de nível 2.

A próxima técnica utilizada é a TW, e o treinamento obteve um MAPE de 3,5423%, teste MAPE de 6,3856% e previsão com MAPE de 4,8541%, com resultados previstos, na Figura 34.

Figura 30 – Previsão Demanda nível 1 proposta



Fonte: Autoria própria

Figura 31 – Processo de treinamento com filtro SG da Demanda nível 1 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Para uma análise visual mais detalhada, a Figura 35 demonstra como foi o processo de treinamento, teste e validação do treinamento BPAT-RB com aplicação da TW na demanda total de nível 2.

Para a técnica com a introdução da AES neste cenário em nível 2, o MAPE no treinamento foi de 2,3126%, teste com MAPE de 4,2590% e com a previsão de MAPE de 3,8553%, podendo ser observado na figura Figura 36.

Para uma análise visual mais detalhada, a Figura 37 demonstra como foram o processo de treinamento, o teste e a validação do treinamento do BPAT-RB com aplicação da AES na demanda total de nível 2.

Por fim, temos a metodologia proposta para a demanda em nível 2 com as três técnicas juntas,

Figura 32 – Demanda nível 2 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Figura 33 – Processo de treinamento com dados originais da Demanda nível 2 prevista com treinamento BPAT-RB



Fonte: Autoria própria

TW+AES+SG. Para o treinamento, o MAPE foi de 1,7099%, teste com MAPE de 3,7020% e previsão com MAPE de 3,0642%, podendo ser observado na figura Figura 38.

Para uma análise visual mais detalhada, a Figura 39 demonstra como foram o processo de treinamento, o teste e a validação do treinamento do BPAT-RB, com a aplicação do método (TW+AES+SG) proposto, na demanda total de nível 2.

Para simplificar os resultados obtidos e seus pré-processamentos para as demandas nos níveis 1 e 2, são apresentados nas Tabelas 4 e 5, respectivamente.

Figura 34 – Demanda nível 2 prevista com treinamento com TW



Fonte: Autoria própria

Figura 35 – Processo de treinamento com TW da Demanda nível 2 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Tabela 4 – MAPES DOS RESULTADOS DA DEMANDA NÍVEL 1

Treinamento com TW	2,4969 %
Treinamento com TW+AES	1,4921 %
Treinamento com método proposto (TW+AES+SG)	1,1130 %
Teste com TW	3,7137 %
Teste com TW+AES	2,6700 %
Teste com método proposto (TW+AES+SG)	2,2152 %
Previsão com TW	4,1258 %
Previsão com TW+AES	2,9655 %
Previsão método proposto (TW+AES+SG)	2,4028 %

Fonte: Elaborada pelo autor

Figura 36 – Demanda nível 2 prevista com treinamento com TW-AES



Fonte: Autoria própria

Figura 37 – Processo de treinamento com AES da Demanda nível 2 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Tabela 5 – MAPES DOS RESULTADOS DA DEMANDA NÍVEL 2

Treinamento com TW	3,5423 %
Treinamento com TW+AES	2,3126 %
Treinamento com método proposto (TW+AES+SG)	1,7099 %
Teste com TW	6,3856 %
Teste com TW+AES	4,2590 %
Teste com método proposto (TW+AES+SG)	3,7020 %
Previsão com TW	4,8541 %
Previsão com TW+AES	3,8553 %
Previsão método proposto (TW+AES+SG)	3,0642 %

Fonte: Elaborada pelo autor

Figura 38 – Demanda nível 2 prevista com treinamento proposto



Fonte: Autoria própria

Figura 39 – Processo de treinamento com método proposto da Demanda nível 2 prevista com treinamento BPAT-RB



Fonte: Autoria própria

Também foi calculado o ganho do MAPE em relação às técnicas aplicadas em cada pré-processamento utilizado para as previsões das demandas, a fim de comparar a melhoria proporcionada pela metodologia proposta. Serão realizadas quatro comparações para cada nível, considerando os dados originais, a transformada wavelet (TW), a combinação TW+AES e o método proposto (TW+AES+SG).

Inicialmente, serão comparados os ganhos das previsões da demanda em níveis 1 e 2 representados nas tabelas 6 e 7.

Tabela 6 – GANHOS DE MAPES PREVISTOS DA DEMANDA NÍVEL 1

Dados originais com TW	25,26 %
TW com TW+AES	28,12 %
TW+AES com método proposto	18,97 %
Método proposto com dados originais	56,52 %

Fonte: Elaborada pelo autor

Tabela 7 – GANHOS DE MAPES PREVISTOS DA DEMANDA NÍVEL 2

Dados originais com TW	30,91 %
TW com TW+AES	20,57 %
TW+AES com método proposto	20,51 %
Método proposto com dados originais	50,38 %

Fonte: Elaborada pelo autor

6.13 PREVISÕES DAS DEMANDAS DAS ESTAÇÕES DE CARREGAMENTO COM 2 E 6 PORTAS

Nesta parte serão apresentados todos os resultados e comparações das métricas de avaliação aplicadas, igualmente à seção anterior. Foi utilizada a mesma metodologia apresentada no ambiente de carregamento residencial. Serão apresentados os resultados do treinamento, teste e previsão para as duas estações de carregamento abordadas.

Inicialmente, serão apresentados os desempenhos nos ambientes com 2 e 6 portas, com os dados originais, sem pré-processamento. No primeiro ambiente 2, serão ilustrados os resultados, com avaliação do MAPE para treinamento, teste e previsão, e serão comparados com os dados originais das cargas elétricas, com a aplicação da transformada wavelet, com o AES e com o filtro SG.

Para os dados originais, os resultados de treinamento apontam um MAPE de 6,4427%, MAPE de teste 10,0721% e MAPE de previsão 9,5575%. A Figura 40 apresenta o resultado de previsão.

É possível observar a performance de treinamento, teste e validação com dados originais na Figura 41.

É possível observar inicialmente que a performance da função do MSE inicia com um valor alto na casa do valor 10^{14}, o que aponta um erro elevado.

Em seguida, serão apresentados os resultados da primeira aplicação do pré-processamento com transformada wavelet nos dados originais. Para a aplicação da TW, o MAPE de treinamento apresenta 3,1778%, teste 6,3094% e previsão 5,9709%, observa-se graficamente como se comportou a previsão deste cenário Figura 42.

É possível observar a performance de treinamento, teste e validação com aplicação da TW, na Figura 43.

Para a performance após a aplicação da TW, foi possível observar que a função de desempenho MSE inicia abaixo do valor 10^{14}, o que apresenta uma leve diminuição do erro.

Figura 40 – Previsão com dados originais ambiente com 2 portas



Fonte: Autoria própria

Figura 41 – Performance com dados originais ambiente com 2 portas



Fonte: Autoria própria

Na seguinte aplicação do pré-processamento com TW+AES, o MAPE de treinamento resultou em 1,4695%, teste 2,4233% e previsão 2,4250%. A Figura 44 ilustra como se comportou a previsão neste cenário.

A performance do treinamento, teste e validação é vista na seguinte Figura 45

Para este cenário, a função de desempenho MSE se inicia perto do valor 10^{13}, o que afirma um avanço no processo de aprendizagem da rede e diminuição do erro.

Por fim, é aplicado no cenário com 2 portas com o método proposto TW+AES+SG. Para o treinamento, obteve o MAPE com 1,4057%, teste com 2,2137% e previsão 2,2780%. A seguir, a Figura 46 demonstra como se comportou a previsão.

A performance do treinamento, teste e validação para o método proposto com TW+AES+SG é vista na Figura 47.

Figura 42 – Previsão com TW ambiente com 2 portas



Fonte: Autoria própria

Figura 43 – Performance com TW para o ambiente com 2 portas



Fonte: Autoria própria

Para este cenário, sendo o método proposto com os 3 pré-processamentos, a função de desempenho MSE se inicia perto do valor acima de 10^{13}, o que demonstra um avanço no processo de aprendizagem da rede e diminuição do erro.

Para facilitar e melhorar a visualização dos resultados com MAPE de treinamento, teste e previsão, a Tabela 8 apresenta esses dados.

Figura 44 – Previsão com TW+AES para o ambiente com 2 portas



Fonte: Autoria própria

Figura 45 – Performance com TW+AES para o ambiente com 2 portas



Fonte: Autoria própria

Tabela 8 – MAPES DOS RESULTADOS DA DEMANDA COM 2 PORTAS

Treinamento com dados originais	6,4427 %
Treinamento com TW	3,1778 %
Treinamento com TW+AES	1,4695 %
Treinamento com método proposto (TW+AES+SG)	1,4057 %
Teste com dado originais	10,0721 %
Teste com TW	6,3094 %
Teste com TW+AES	2,4233 %
Teste com método proposto (TW+AES+SG)	2,2137 %
Previsão com dados originais	9,5575 %
Previsão com TW	5,9709 %
Previsão com TW+AES	2,4250 %
Previsão método proposto (TW+AES+SG)	2,2780 %

Fonte: Elaborada pelo autor

Figura 46 – Previsão com TW+AES+SG para o ambiente com 2 portas



Fonte: Autoria própria

Figura 47 – Performance com TW+AES+SG para o ambiente com 2 portas



Fonte: Autoria própria

Em seguida, são apresentados os ganhos de MAPE em relação à previsão, comparando os pré-processamentos entre as 3 ferramentas conforme a Tabela 9.

Tabela 9 – GANHOS DE MAPES PREVISTOS DA DEMANDA COM 2 PORTAS

Dados originais com TW	37,53 %
TW com TW+AES	59,39 %
TW+AES com método proposto	6,10 %
Método proposto com dados originais	76,16 %

Fonte: Elaborada pelo autor

Nesta parte em diante, serão apresentados todos os resultados e processos, igualmente aos processos de treinamento, teste, previsão e ganhos dos resultados, com os pré-processamentos

para a demanda com 6 portas com 350 kW de potência.

Inicialmente, serão mostrados como se comportaram os resultados quando foram utilizados os dados originais da demanda de potência. Para o MAPE de treinamento, resultou em 9,5969%, teste 11,3234% e previsão 10,1144%. A figura Figura 48 ilustra como se comportou a previsão.

Figura 48 – Previsão da demanda com dados originais para 6 portas



Fonte: Autoria própria

Para a performance de treinamento, teste e validação para este cenário com dados originais, a Figura 49 apresenta estes resultados.

Figura 49 – Performance da demanda com dados originais para 6 portas



Fonte: Autoria própria

Para este cenário com dados originais, onde se observa inicialmente que a função de desempenho MSE se iniciou em um valor alto de 10^{15}.

No próximo cenário serão apresentados os resultados com a aplicação da TW na demanda de potência. Para o treinamento, resultou-se em um MAPE de 4,4587%, teste 4,8466% e

previsão 6,7174%. Na Figura 50, abaixo, o resultado da previsão com TW pode ser observado graficamente.

Figura 50 – Previsão da demanda com TW para 6 portas



Fonte: Autoria própria

Para a performance de treinamento, teste e validação deste cenário com aplicação em TW, a Figura 51 apresenta estes resultados.

Figura 51 – Performance da demanda com TW para 6 portas



Fonte: Autoria própria

No próximo cenário serão apresentados os resultados com a aplicação da TW+AES na demanda de potência. Para o treinamento, resultou-se em um MAPE com 2,0413%, teste 2,8565% e previsão 1,9147%. Na Figura 52 abaixo, o resultado da previsão com Tw pode ser observado graficamente.

Para a performance de treinamento, teste e validação deste cenário com aplicação em TW+AES, a Figura 53 apresenta estes resultados.

Figura 52 – Previsão da demanda com TW+AES para 6 portas



Fonte: Autoria própria

Figura 53 – Performance da demanda com TW+AES para 6 portas



Fonte: Autoria própria

No próximo cenário serão apresentados os resultados com a aplicação da TW+AES+SG na demanda de potência. Para o treinamento, resultou-se em um MAPE com 1,9778%, teste 2,7879% e previsão 1,8000%. Na Figura 54 abaixo, o resultado da previsão com Tw pode ser observado graficamente.

Para a performance de treinamento, teste e validação deste cenário com aplicação em TW+AES+SG, a Figura 55 apresenta estes resultados.

Para observar melhor os resultados, a Tabela 10 apresenta os resultados de treinamento, teste e previsão comparados com os pré-processamentos aplicados.

Figura 54 – Previsão da demanda com TW+AES+SG para 6 portas



Fonte: Autoria própria

Figura 55 – Performance da demanda com TW+AES+SG para 6 portas



Fonte: Autoria própria

Tabela 10 – MAPES DOS RESULTADOS DA DEMANDA COM 6 PORTAS

Treinamento com dados originais	9,5969 %
Treinamento com TW	4,4587 %
Treinamento com TW+AES	2,0413 %
Treinamento com método proposto (TW+AES+SG)	1,9798 %
Teste com dados originais	11,3234 %
Teste com TW	7,8466 %
Teste com TW+AES	2,8565 %
Teste com método proposto (TW+AES+SG)	2,7879 %
Previsão com dados originais	10,1144 %
Previsão com TW	6,7174 %
Previsão com TW+AES	1,9147 %
Previsão método proposto (TW+AES+SG)	1,8000 %

Fonte: Elaborada pelo autor

Em seguida, são apresentados os ganhos de MAPE em relação à previsão, comparando os pré-processamentos entre as 3 ferramentas para a demanda com 6 portas, apresentados na Tabela 11.

Tabela 11 – GANHOS DE MAPES PREVISTOS DA DEMANDA COM 6 PORTAS

Dados originais com TW	33,59 %
TW com TW+AES	71,50%
TW+AES com método proposto	5,990 %
Método proposto com dados originais	82,21 %

Fonte: Elaborada pelo autor

6.14 RESULTADOS E DISCUSSÕES

Inicialmente, foi possível observar que, nos dois ambientes estudados, a metodologia proposta melhorou os resultados e as performances de treinamento, teste e previsão. E utilizando apenas o treinamento BPAT isoladamente, a resposta não foi satisfatória, sendo necessário normalizar as cargas elétricas para convergir o resultado. Por isto, foi proposto o treinamento híbrido. Embora a normalização das cargas elétricas antes do treinamento BPAT tenha sido aplicada, a previsão ainda não foi adequada, já que o algoritmo de Regularização Bayesiana realiza automaticamente uma normalização entre 0 e 1. Com a combinação dos dois treinamentos, unindo o BPAT a RB, a rede apresentou uma melhora significativa nos resultados. Por exemplo, para o ambiente residencial, o treinamento BPAT obteve um MAPE de 9,31%, enquanto o treinamento BPAT RB alcançou um MAPE de 5,52%. Esta melhoria deve-se ao fato da RB determinar a probabilidade de um evento ocorrer com base no aprendizado previamente armazenado.

Com estas melhorias, a arquitetura MLPR e o treinamento híbrido propostos aumentaram sua eficácia. Ao utilizar apenas uma única camada oculta, as respostas mostraram-se satisfatórias, porém elas ficam estagnadas em um ótimo local. No entanto, ao adicionar mais camadas ocultas com recorrências, a rede começou a apresentar melhorias, alcançando seu melhor desempenho na terceira camada oculta, onde os resultados de treinamento, teste e previsão foram melhorados com o aprendizado profundo.

É possível observar também que a metodologia proposta analisou somente 3 meses de dados, sendo divididos em treinamento e teste, e, com isto, somente poucos dados. A rede gerou resultados satisfatórios e pertinentes em relação à literatura, com MAPE de previsões abaixo de 4%, o que realça a metodologia proposta.

Ao utilizar aprendizado profundo na metodologia, a rede obteve um maior poder de processamento e capacidade de buscar novas informações das demandas elétricas, permitindo a extração de mais dados relevantes. Na literatura, diversos estudos empregam um número significativo de neurônios nas camadas ocultas, variando de 10 a 168 ou mais. No entanto, neste trabalho, foi possível obter resultados satisfatórios com apenas 6, 2 e 1 neurônios nas respectivas camadas ocultas, com poucos segundos de convergência. Os laços de recorrência da rede foram fundamentais para melhorar o desempenho em comparação com modelos sem essa característica,

como a MLP clássica e outras redes, resultando em uma diminuição do erro de previsão. A recorrência, nesse contexto, desempenha um papel crucial ao permitir que os dados treinados sejam reintroduzidos para extrair novas informações.

Também foi observado que o treinamento proposto BPAT com RB obteve uma notória melhora quando comparado só com BPAT, com um ganho do MAPE de 40%, o que realça a eficiência do algoritmo híbrido bayesiano proposto, sendo uma lacuna na literatura. É válido ressaltar também que, na literatura, poucos estudos abordam e promovem soluções eficientes para o treinamento BPAT, principalmente nesta área de previsão.

Por fim, o treinamento proposto utiliza dois métodos distintos, em que resultou em um algoritmo híbrido (BPAT+RB), o método de LM para acelerar os cálculos das inversões das matrizes H, derivadas de segunda ordem e função objetivo F no cálculo do ponto mínimo, entretanto este método é conhecido pela sua ráipida convergência, e quando se utiliza um volume de grandes dados a convergência se torna lenta e as vezes inviável, mas neste trabalho como foram utilazados poucos dados e poucos neurônios, a convergência apresentou ser rápida em poucos segundos.

É destacada inicialmente a importância das técnicas de pré-processamento nas demandas elétricas. Houve uma notável diferença neste trabalho com a utilização dos três pré-processamentos. Este processo permitiu que as demandas elétricas fossem aprimoradas, preparando-as para serem processadas pela MLPR.

No ambiente residencial com a demanda de níveis 1 e 2 e nas estações de carregamento com 2 e 6 portas, é observado que nos processos de performance para o treinamento, teste e validação, houve melhoras em todas as etapas de pré-processamento, demonstrando a diminuição dos erros MSE em cada processo. Com isto, foi possível chegar aos melhores resultados.

Para o ambiente residencial, a demanda de nível 1 demonstrou um desempenho de diminuição do MSE do treinamento, teste e validação em cada processo de pré-processamento, e também, devido a esta melhora, o treinamento, teste e validação da rede acabaram se esticando ao longo das épocas, extraindo mais informações da demanda treinada. Na primeira aplicação com TW, os números de épocas convergiram para o melhor resultado de validação, um pouco mais de 70 épocas. Já na segunda aplicação com TW+AES, a rede obteve o melhor desempenho com um pouco a mais de 100 épocas, com a convergência do treinamento, teste e validação seguindo o mesmo padrão. E por fim, com a metodologia proposta com TW+AES+SG, o desempenho da rede passou de 400 épocas, em que obteve o melhor processo de aprendizagem da rede.

Foi possível ressaltar também que, em todas as aplicações do pré-processamento a performance da demanda residencial de nível 1, o erro MSE sempre começa com um valor perto de 10^{12} e, na aplicação do último pré-processamento, a rede converge para um valor de 10^{9}, onde obtém os melhores resultados de treinamento, teste, validação e previsão.

Para o ambiente da demanda de nível 2, apresentou também, em todos os processos de aplicação do pré-processamento, a rede melhoras significativas. Ao passo de cada pré-processamento, a performance do MSE decai e o número de épocas de treinamento aumenta, extraindo mais

informações. Com isto, a aplicação dos 3 pré-processamentos nesta metodologia atingiu a melhor resposta com 400 épocas de treinamento e convergência do MSE com um valor perto de 10^9.

Para o ambiente de estação de carregamento com 2 portas, a metodologia também apresentou o mesmo comportamento dos resultados, melhorando em todas as etapas de pré-processamento, sendo elas treinamento, teste, validação e previsão. Porém, como os dados neste ambiente são mais inconsistentes e não periódicos, como explorados no início da pesquisa, o MSE se inicia em um valor maior do que o outro ambiente estudado residencial, começando em 10^{14}.

Em cada aplicação dos pré-processamentos, os números de épocas de treinamento, teste e validação demonstraram um avanço nos números treinados, fazendo com que aumente o processo de aprendizado da rede, e isto demonstrou ser favorável, pois gerou resultados de treinamento, teste e previsão com baixos erros. Nas duas demandas de níveis 1 e 2 com carregamento residencial, com a aplicação dos 3 pré-processamentos, o número de épocas treinadas chegou a cerca de 400 épocas e passou disso. Com isto, foi possível chegar aos melhores resultados.

Para o ambiente de estação de carregamento, a metodologia também demonstrou ser eficaz e com resultados satisfatórios e pertinentes. Com isto, é possível observar que a metodologia funcionou para os dois ambientes distintos, sendo que em todos os processos de treinamento, validação, teste e previsão, os erros sempre foram diminuídos. Devido ao fato de a previsão de estação de carregamento ser uma tarefa mais difícil em comparação à residencial, os resultados apresentam-se promissores e realçam-se pela sua eficiência com baixos erros.

Nos pré-processamentos para os dois ambientes, primeiramente, a transformada *wavelet sym 4* ajudou a melhorar o aspecto ruidoso das cargas, quebrando algumas linearidades; isto demonstrou visualmente e, com os resultados de previsões, apontou, embora isto ainda não fosse suficiente em termos de resultados. Em seguida, a introdução da AES proporcionou uma suavização significativa nas cargas elétricas, eliminando certos ruídos, linearidades instáveis persistentes e picos e cargas aleatórios. Por último, o filtro SG conseguiu extrair e suavizar ainda mais os dados, atenuando os picos e vales das demandas nos dois ambientes. Além do fato visual dos pré-processamentos, os resultados de treinamentos, testes e previsões.

Outra observação importante neste trabalho foi que, mesmo com a aplicação dos três pré-processamentos nas demandas nos dois ambientes, as características originais das demandas foram preservadas. Isto garante que o processo se mantém no perfil dos dados brutos.

Por fim, este novo método proposto de previsão da demanda total nos ambientes onde os VEs são carregados demonstra ser uma solução promissora e confiável em aspectos de cenários realistas, obtendo resultados confiáveis e mais precisos em relação a somente prever a demanda dos VEs. O que isto gera é mais opções e uma nova abertura de pesquisa e busca por novas soluções de previsão.

7 CONCLUSÃO E TRABALHOS FUTUROS

Com o aumento da demanda de carregamento dos VEPs em ambientes residenciais e em estações de carregamento, surgirão diversos problemas e congestionamentos na rede elétrica atual e futura, conforme explorado neste trabalho. A previsão desta nova demanda oferece dados precisos e realistas sobre como projetar e gerenciar estas cargas ao longo do tempo. Enquanto muitos estudos na literatura se concentram apenas nas previsões de carga dos VEPs, este trabalho apresenta uma nova abordagem promissora e necessária, buscando resolver questões relacionadas ao ambiente em que os VEPs são carregados. A metodologia proposta, que integra a demanda residencial e a dos VEPs e a demanda comercial com VEs, pode servir como uma ferramenta eficaz para enfrentar estes desafios. Além disto, é importante ressaltar que o trabalho explora dois níveis de potência no carregamento residencial, o que é relevante, uma vez que a maioria dos estudos aborda somente um único nível de potência.

Pode-se destacar a relevância e a importância do pré-processamento nas demandas elétricas, no qual se observaram mudanças no comportamento das curvas diárias ao remover ruídos indesejados e linearidades nos picos de carga. Como discutido, os resultados com e sem pré-processamento mostraram que o uso da MLPR resultou em uma melhoria significativa nos treinamentos, testes e previsões para as duas demandas abordadas nos dois ambientes. A arquitetura de aprendizado profundo, com seu vetor de recorrência, foi capaz de extrair novas informações ocultas das três camadas, o que resultou na melhor configuração da MLPR.

Além de todas estas conclusões, é importante ressaltar a relevância do treinamento híbrido nesta pesquisa, que visou contornar e aprimorar os métodos clássicos da literatura. Foi observado que o algoritmo BPAT não apresentou resultados satisfatórios e realistas. No entanto, com a introdução da RB, houve um avanço significativo no processo de treinamento, validação, teste e previsão, resultando em melhorias notáveis na performance da MLPR.

Os resultados das previsões para as duas demandas residenciais mostraram que a metodologia proposta teve um desempenho favorável, com baixos erros em relação à métrica MAPE. As demandas previstas apresentaram valores de MAPE inferiores a 3% e 4%. Em termos de fornecimento de energia elétrica no cenário dos VEs, isto resulta em melhores decisões, planejamento, gerenciamento e expansão dessas demandas energéticas. Os ganhos de MAPE entre as ferramentas de pré-processamento reforçam ainda mais a eficácia da metodologia proposta, que combina as três ferramentas. Observou-se uma melhoria nas três técnicas propostas em ambas as demandas, com os dados mostrando avanços positivos nas previsões na faixa de 20 a 30%. Quando comparada aos dados originais, a metodologia proposta melhorou cerca de 50% no MAPE de previsão.

Para o ambiente de estação de carregamento com 2 e 6 portas, os resultados de previsão demonstraram baixo erro com MAPE menor que 3% e 2%, isto demonstra algo promissor e valioso, pois a previsão de estação de carregamento apresenta dados complexos e ruidosos. Isto

acaba sendo algo promissor e realista, devido a se tratar de um ambiente mais robusto e instável.

Os resultados de previsão para os ambientes residenciais 1 e 2 e para o ambiente de estação de carregamento, com o método proposto, demonstraram baixo erro de previsão em 24 horas. Isto realça o método proposto neste trabalho, que foi capaz de funcionar para os dois ambientes distintos.

Com isto, esta pesquisa visou a buscar estas melhorias no processo de previsão, onde foram investigadas estas melhorias e comprovadas com seus resultados, o que, em termos adiante de pesquisas futuras, abre um novo leque de ideias, novas soluções para a melhoria no processo de previsão. E também, devido aos resultados, forneceram dados valiosos e pertinentes ao tema, novas estratégias e tomadas de decisão em relação às previsões destas demandas.

Por fim, pode-se concluir que este trabalho é relevante no cenário atual e futuro, proporcionando informações valiosas para o setor energético. Os resultados obtidos podem auxiliar na agregação de demandas e na elaboração de projeções realistas, com o objetivo de tornar as previsões aliadas estratégicas para o setor de energia elétrica. Diante das crises energéticas e dos desafios de gestão que o cenário global enfrenta, esta pesquisa aborda um tema de grande urgência e importância.

Para o trabalho futuro, em nível de pós-doutorado, serão introduzidos diversos níveis de potência, taxa de penetração e eventos de recarga, para os estudos de possíveis impactos destas recargas. Será também proposta a previsão junto ao preço das demandas dos VEs. Além disto, será proposta a introdução do filtro de Kalman e do filtro gaussiano para o pré-processamento das cargas elétricas, visando estimar as cargas de carregamento. Junto com estas propostas, serão também sugeridas novas ferramentas para o processo de previsão, como LSTM, SVM, Random Forest, CNN ou ART-MAP fuzzy.

Também serão propostos novos estudos sobre as degradações da saúde das baterias dos VEs perante os ciclos de recarga, visando prever o estado de saúde das baterias (SOH) e o estado de carregamento (SOC) dos VEs baseando-se nas variáveis de corrente (A), tensão (V), temperatura (T), potência (W), SOC (%) e SOH (%).

REFERÊNCIAS

AHMAD, N. et al. Load forecasting techniques for power system: Research challenges and survey. **IEEE Access**, 07 2022.

AHMADIAN, A.; MOHAMMADI-IVATLOO, B.; ELKAMEL, A. A review on plug-in electric vehicles: Introduction, current status, and load modeling techniques. **Journal of Modern Power Systems and Clean Energy**, v. 8, 02 2020.

AL-ANBUKY, A.; BATAINEH, S.; AL-AQTASH, S. Power demand prediction using fuzzy logic. **Control Engineering Practice**, v. 3, n. 9, p. 1291–1298, 1995.

ALAM, M. M. et al. Dynamic charging of electric vehicle with negligible power transfer fluctuation. **Energies**, v. 10, n. 5, 2017. ISSN 1996-1073. Disponível em: https://www.mdpi.com/1996-1073/10/5/701.

ALIASGHARI, P. et al. Optimal scheduling of plug-in electric vehicles and renewable micro-grid in energy and reserve markets considering demand response program. **Journal of Cleaner Production**, v. 186, 03 2018.

ALSHAHRANI, S.; KHALID, M.; ALMUHAINI, M. Electric vehicles beyond energy storage and modern power networks: Challenges and applications. **IEEE Access**, PP, p. 1–1, 07 2019.

AMINI, M. H.; KARGARIAN, A.; KARABASOGLU, O. ARIMA-based decoupled time series forecasting of electric vehicle charging demand for stochastic power system operation. **Electric Power Systems Research**, Elsevier B.V., v. 140, p. 378–390, 2016.

AMJADY, N. Short-term hourly load forecasting using time-series modeling with peak load estimation capability. **IEEE Transactions on Power Systems**, v. 16, n. 3, p. 498–505, 2001.

ASAR, J. Azzam-ul; MCDONALD, J.; KHAN, M. A specification of neural network applications in the load forecasting problem. In: **[Proceedings 1992] The First IEEE Conference on Control Applications**. [S.l.: s.n.], 1992. p. 577–582 vol.1.

BASU, M.; GAUGHAN, K.; COYLE, E. Harmonic distortion caused by ev battery chargers in the distribution systems network and its remedy. In: INTERNATIONAL UNIVERSITIES POWER ENGINEERING CONFERENCE, 39., 2004, Bristol, UK. **Anais[...]**. [S.l.], 2004. v. 1, p. 869–873.

BOHN, S.; FEUSTEL, R.; AGSTEN, M. Mc-based risk analysis on the capacity of distribution grids to charge pevs on 3-ph 0.4-kv distribution grids considering time and location uncertainties. **SAE International Journal of Passenger Cars - Electronic and Electrical Systems**, v. 8, 05 2015.

BRAGA, I.; SANTOS, C. Viability of precipitation frequency use for reservoir sizing in condominiums. **Journal of Urban and Environmental Engineering (JUEE); Vol 4, No 1 (2010)**, v. 4, p. 23–28, 03 2010.

BUNN, D. Forecasting loads and prices in competitive power markets. **Proceedings of the IEEE**, v. 88, n. 2, p. 163–169, 2000.

BUZNA, L. et al. Electric vehicle load forecasting: A comparison between time series and machine learning approaches. **SyNERGY MED 2019 - 1st International Conference on Energy Transition in the Mediterranean Area**, p. 1–5, 2019.

CHANG, M. et al. Impact of electric vehicle charging demand on a jeju island radial distribution network. In: **2019 IEEE Power Energy Society Innovative Smart Grid Technologies Conference (ISGT)**. [S.l.: s.n.], 2019. p. 1–5.

CHEN, Y. Prediction algorithm of pm2.5 mass concentration based on adaptive bp neural network. **Computing**, Springer-Verlag, Berlin, Heidelberg, v. 100, n. 8, p. 825–838, ago. 2018. ISSN 0010-485X. Disponível em: https://doi.org/10.1007/s00607-018-0628-3.

CLEMENT-NYNS, K.; HAESEN, E.; DRIESEN, J. The impact of charging plug-in hybrid electric vehicles on a residential distribution grid. **IEEE Transactions on Power Systems**, v. 25, n. 1, p. 371–380, 2010.

CROZIER, C.; MORSTYN, T.; MCCULLOCH, M. The opportunity for smart charging to mitigate the impact of electric vehicles on transmission and distribution systems. **Applied Energy**, v. 268, p. 114973, 2020. ISSN 0306-2619. Disponível em: https://www.sciencedirect.com/science/article/pii/S0306261920304852.

CUI, H.; HALL, D.; LUTSEY, N. **Update on the global transition to electric vehicles through 2019**. [S.l.], 2020. 15 p.

DAI, W. et al. A nonlinear generalization of the savitzky-golay filter and the quantitative analysis of saccades. **Journal of Vision**, v. 17, p. 10, 08 2017.

DAUBECHIES, I. **Ten Lectures on Wavelets**. Society for Industrial and Applied Mathematics, 1992. (CBMS-NSF Regional Conference Series in Applied Mathematics). ISBN 9780898712742. Disponível em: https://books.google.com.br/books?id=9t5SG06AiT0C.

DEB, S. et al. Impact of electric vehicle charging station load on distribution network. **Energies**, v. 11, n. 1, 2018. ISSN 1996-1073. Disponível em: https://www.mdpi.com/1996-1073/11/1/178.

DHARMAKEERTHI, C.; MITHULANANTHAN, N.; SAHA, T. Impact of electric vehicle fast charging on power system voltage stability. **International Journal of Electrical Power Energy Systems**, v. 57, p. 241–249, 2014. ISSN 0142-0615. Disponível em: https://www.sciencedirect.com/science/article/pii/S0142061513005218.

DONG, X. et al. Planning of fast ev charging stations on a round freeway. **IEEE Transactions on Sustainable Energy**, v. 7, p. 1–1, 10 2016.

DONOHO, D. L.; JOHNSTONE, I. M. Ideal spatial adaptation by wavelet shrinkage. **Biometrika**, v. 81, n. 3, p. 425–455, 09 1994. ISSN 0006-3444. Disponível em: https://doi.org/10.1093/biomet/81.3.425.

DROVTAR, I. et al. Large scale electric vehicle integration and its impact on the estonian power system. In: . [S.l.: s.n.], 2013. p. 1–6.

EL-SHARKAWI, M. A.; MARKS, R. J.; WEERASOORIYA, S. Neural networks and their application to power engineering. In: LEONDES, C. (Ed.). **Analysis and Control System Techniques for Electric Power Systems, Part 1 of 4**. [S.l.]: Academic Press, 1991, (Control and Dynamic Systems, v. 41). p. 359 – 461.

FAHIM, B.; AKBAR, M.; AMAYRI, M. Residualnet: A novel electric vehicle charging data imputation technique to enhance load forecasting accuracy. **Building Simulation**, v. 18, 02 2025.

FAN, Y. et al. A review on air emissions assessment: Transportation. **Journal of Cleaner Production**, v. 194, p. 673–684, 2018.

FATHABADI, H. Novel solar powered electric vehicle charging station with the capability of vehicle-to-grid. **Solar Energy**, v. 142, p. 136–143, 2017. ISSN 0038-092X. Disponível em: https://www.sciencedirect.com/science/article/pii/S0038092X16305771.

FERNáNDEZ, L. P. et al. Assessment of the impact of plug-in electric vehicles on distribution networks. **IEEE Transactions on Power Systems**, v. 26, n. 1, p. 206–213, 2011.

FOLEY, A. et al. A strategic review of electricity systems models. **Energy**, v. 35, n. 12, p. 4522–4530, 2010. ISSN 0360-5442. The 3rd International Conference on Sustainable Energy and Environmental Protection, SEEP 2009. Disponível em: https://www.sciencedirect.com/science/article/pii/S0360544210001866.

FORESEE, F.; HAGAN, M. Gauss-newton approximation to bayesian learning. **Proceedings of International Conference on Neural Networks (ICNN'97)**, v. 3, p. 1930–1935, 1997.

FORESEE, F. D.; HAGAN, M. Gauss-newton approximation to bayesian learning. In: **Proceedings of International Conference on Neural Networks (ICNN'97)**. [S.l.: s.n.], 1997. v. 3, p. 1930–1935 vol.3.

GAO, W. et al. Different states of multi-block based forecast engine for price and load prediction. **International Journal of Electrical Power Energy Systems**, v. 104, p. 423–435, 2019. ISSN 0142-0615. Disponível em: https://www.sciencedirect.com/science/article/pii/S0142061517319865.

GARCÍA, S. et al. **Data preprocessing in data mining**. [S.l.]: Springer, 2015. v. 72.

GESKE, M. et al. Modeling and simulation of electric car penetration in the distribution power system — case study. In: . [S.l.: s.n.], 2010. p. 1 – 6.

GHODS, L.; KALANTAR, M. Different methods of long-term electric load demand forecasting: A comprehensive review. **Iranian Journal of Electrical and Electronic Engineering**, v. 7, p. 249–259, 12 2011.

GILLERAN, M. et al. Impact of electric vehicle charging on the power demand of retail buildings. **Advances in Applied Energy**, v. 4, p. 100062, 2021. ISSN 2666-7924. Disponível em: https://www.sciencedirect.com/science/article/pii/S2666792421000548.

GOH, H. H. et al. Mid- and long-term strategy based on electric vehicle charging unpredictability and ownership estimation. **International Journal of Electrical Power Energy Systems**, v. 142, p. 108240, 2022. ISSN 0142-0615. Disponível em: https://www.sciencedirect.com/science/article/pii/S0142061522002691.

GOLYANDINA, N.; NEKRUTKIN, V.; ZHIGLJAVSKY, A. Analysis of time series structure: Ssa and related techniques. **Monographs on Statistics and Applied Probability**, v. 90, 01 2001.

GOMEZ, J.; MORCOS, M. M. Impact of ev battery chargers on the power quality of distribution systems. **IEEE Transactions on Power Delivery**, v. 18, n. 3, p. 975–981, 2003.

GOWDA, S. et al. Short-term aggregate electric vehicle charging load forecasting in diverse conditions with minimal data using transfer and meta-learning. **Energy Systems**, p. 1–20, 06 2024.

GRAPS, A. An introduction to wavelets. **IEEE Computational Science and Engineering**, v. 2, n. 2, p. 50–61, 1995.

GRAY, M.; MORSI, W. Power quality assessment in distribution systems embedded with plug-in hybrid and battery electric vehicles. **IEEE Transactions on Power Systems**, v. 30, p. 1–9, 07 2014.

GROSSMANN, A.; MORLET, J. Decomposition of hardy functions into square integrable wavelets of constant shape. **SIAM Journal on Mathematical Analysis**, v. 15, p. 723–736, 07 1984.

GUARNIERI, M. When cars went electric, part 1. **IEEE Industrial Electronics Magazine**, IEEE, v. 5, n. 03, p. 61–62, 2011.

GUINEL, I. Forecasting system energy demand. **Journal of Forecasting**, v. 6, n. 2, p. 137–156, 1987.

GUO, T. et al. A combined strategy for wind speed forecasting using data preprocessing and weight coefficients optimization calculation. **IEEE Access**, PP, p. 1–1, 02 2020.

HABIB, S. et al. A comprehensive study of implemented international standards, technical challenges, impacts and prospects for electric vehicles. **IEEE Access**, PP, p. 1–1, 03 2018.

HAGAN, M. et al. **Neural Network Design**. Martin Hagan, 2014. ISBN 9780971732117. Disponível em: https://books.google.com.br/books?id=4EW9oQEACAAJ.

HAGAN, M.; MENHAJ, M. Training feedforward networks with the marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, 1994.

HAIDA, T.; MUTO, S. Regression-based peak load forecasting using a transformation technique. **IEEE Transactions on Power Systems**, v. 9, n. 4, p. 1788–1794, 1994.

HARTMANN, N.; ÖZDEMIR, E. Impact of different utilization scenarios of electric vehicles on the german grid in 2030. **Journal of Power Sources**, v. 196, n. 4, p. 2311–2318, 2011. ISSN 0378-7753. Disponível em: https://www.sciencedirect.com/science/article/pii/S0378775310017246.

HASAN, S. Assessment of electric vehicle repurchase intention: A survey-based study on the norwegian ev market. **Transportation Research Interdisciplinary Perspectives**, v. 11, p. 100439, 2021. ISSN 2590-1982. Disponível em: https://www.sciencedirect.com/science/article/pii/S2590198221001457.

HASSANI, H.; MAHMOUDVAND, R.; YARMOHAMMADI, M. Filtering and denoising in linear regression analysis. **Fluctuation and Noise Letters - FLUCT NOISE LETT**, v. 09, 12 2010.

HASSANI, H.; MAHMOUDVAND, R.; YARMOHAMMADI, M. Filtering and denoising in linear regression analysis. **Fluctuation and Noise Letters - FLUCT NOISE LETT**, v. 09, 12 2010.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 2nd. ed. USA: Prentice Hall PTR, 1998.

HIPPERT, H.; PEDREIRA, C.; SOUZA, R. Neural networks for short-term load forecasting: A review and evaluation. **IEEE Transactions on Power Systems**, v. 16, p. 44 – 55, 03 2001.

International Energy Agency (IEA). Report, **"Electricity demand by mode"**. EUA: Paris, 2023. Accessed: [Data de Acesso]. Disponível em: Available:https://www.iea.org/data-and-statistics/charts/electricitydemand-by-mode-2023-2035/. Acesso em: 1 set. 2023.

IPAKCHI, A.; ALBUYEH, F. Grid of the future. **IEEE Power and Energy Magazine**, v. 7, n. 2, p. 52–62, 2009.

JIANG, C. et al. Method to assess the power-quality impact of plug-in electric vehicles. **IEEE Transactions on Power Delivery**, v. 29, n. 2, p. 958–965, 2014.

KELLY, L.; ROWE, A.; WILD, P. Analyzing the impacts of plug-in electric vehicles on distribution networks in british columbia. In: **2009 IEEE Electrical Power Energy Conference (EPEC)**. [S.l.: s.n.], 2009. p. 1–6.

KERMANSHAHI, B.; IWAMIYA, H. Up to year 2020 load forecasting using neural nets. **International Journal of Electrical Power Energy Systems**, v. 24, n. 9, p. 789–797, 2002. ISSN 0142-0615. Disponível em: https://www.sciencedirect.com/science/article/pii/S0142061501000862.

KIM, S.; KIM, H. A new metric of absolute percentage error for intermittent demand forecasts. **International Journal of Forecasting**, v. 32, p. 669–679, 07 2016.

KOOHFAR, S.; WOLDEMARIAM, W.; KUMAR, A. Prediction of electric vehicles charging demand: A transformer-based deep learning approach. **Sustainability**, v. 15, n. 3, 2023. ISSN 2071-1050. Disponível em: https://www.mdpi.com/2071-1050/15/3/2105.

KRIEGLER, E. et al. The role of technology for achieving climate policy objectives: Overview of the emf 27 study on global technology and climate policy strategies. **Climatic Change**, v. 123, p. 353–367, 04 2014.

KRöSE, B. et al. An introduction to neural networks. **J Comput Sci**, v. 48, 01 1993.

LAURET, P. et al. Bayesian neural network approach to short time load forecasting. **Energy Conversion and Management**, v. 49, n. 5, p. 1156–1166, 2008. ISSN 0196-8904. Disponível em: https://www.sciencedirect.com/science/article/pii/S0196890407003032.

LEE, D. H. et al. Forecasting of Electric Vehicles Charging Pattern Using Bayesians method with the Convolustion. **IFAC-PapersOnLine**, Elsevier Ltd, v. 52, n. 4, p. 413–418, 2019.

LEE, K. et al. Short-term load forecasting using diagonal recurrent neural network. In: **[1993] Proceedings of the Second International Forum on Applications of Neural Networks to Power Systems**. [S.l.: s.n.], 1993. p. 227–232.

LIU, L. et al. Maximum likelihood recursive identification for the multivariate equation-error autoregressive moving average systems using the data filtering. **IEEE Access**, v. 7, p. 41154–41163, 2019.

LOPES, J. A. P.; SOARES, F. J.; ALMEIDA, P. M. R. Integration of electric vehicles in the electric power system. **Proceedings of the IEEE**, v. 99, n. 1, p. 168–183, 2011.

LU, J. et al. Ev charging load forecasting and optimal scheduling based on travel characteristics. **Energy**, v. 311, p. 133389, 10 2024.

LU, Y. et al. The application of improved random forest algorithm on the prediction of electric vehicle charging load. **Energies**, v. 11, n. 11, 2018.

MACKAY, D. Bayesian interpolation. **Neural Computation**, v. 4, p. 415–447, 05 1992.

MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the Society for Industrial and Applied Mathematics**, v. 11, n. 2, p. 431–441, 1963.

MASOUM, M.; MOSES, P.; SMEDLEY, K. Distribution transformer losses and performance in smart grids with residential plug-in electric vehicles. In: . [S.l.: s.n.], 2011. p. 1–7. ISBN 978-1-61284-218-9.

MCCARTHY, D.; WOLFS, P. The hv system impacts of large scale electric vehicle deployments in a metropolitan area. 01 2011.

MEYER, Y.; RYAN, R. **Wavelets: Algorithms & Applications**. Society for Industrial and Applied Mathematics, 1993. (Miscellaneous Bks). ISBN 9780898713091. Disponível em: https://books.google.com.br/books?id=0vpQAAAAMAAJ.

MILLS, G.; MACGILL, I. Potential power system and fuel consumption impacts of plug in hybrid vehicle charging using australian national electricity market load profiles and transportation survey data. **Electric Power Systems Research**, v. 116, p. 1–11, 11 2014.

MOHSENIMANESH, A.; ENTCHEV, E. Charging strategies for electric vehicles using a machine learning load forecasting approach for residential buildings in canada. **Applied Sciences**, v. 14, p. 11389, 12 2024.

MORLET, J. et al. Wave propagation and sampling theory–part ii: Sampling theory and complex waves. **Geophysics**, v. 47, p. 222–236, 02 1982.

MUDGAL, Y. et al. Advanced cluster-based load forecasting and peak demand management for electric vehicle charging networks. **IEEE Access**, PP, p. 1–1, 01 2025.

MURATORI, M. Impact of uncoordinated plug-in electric vehicle charging on residential power demand. **Nature Energy**, Springer US, v. 3, n. 3, p. 193–201, 2018. ISSN 20587546.

NAIR, A. S. et al. Optimal Operation of Residential EVs using DNN and Clustering based Energy Forecast. **2018 North American Power Symposium, NAPS 2018**, IEEE, 2019.

NAZIR, A. et al. Enhancing energy consumption forecasting for electric vehicle charging stations with time series dense encoder (tide). **e-Prime - Advances in Electrical Engineering, Electronics and Energy**, v. 12, p. 100997, 2025. ISSN 2772-6711. Disponível em: https://www.sciencedirect.com/science/article/pii/S2772671125001044.

NGUYEN, V.-L.; TRAN-QUOC, T.; SEDDIK, B. Harmonic distortion mitigation for electric vehicle fast charging systems. In: . [S.l.: s.n.], 2013. p. 1–6.

NIKITHA, L. et al. Effect of electrical vehicle charging on power quality. In: . [S.l.: s.n.], 2017. p. 1–6.

NILSSON, M. Singular spectrum time-series analysis and continuous transformation groups. **Proceedings: Mathematical, Physical and Engineering Sciences**, The Royal Society, v. 460, n. 2043, p. 929–938, 2004. ISSN 13645021. Disponível em: http://www.jstor.org/stable/4143192.

NIRALA, P. K. et al. Renewable power integration for electric vehicle charging system: A review. In: **2025 IEEE 1st International Conference on Smart and Sustainable Developments in Electrical Engineering (SSDEE)**. [S.l.: s.n.], 2025. p. 01–05.

PANDIA, K. et al. Motion artifact cancellation to obtain heart sounds from a single chest-worn accelerometer. In: **2010 IEEE International Conference on Acoustics, Speech and Signal Processing**. [S.l.: s.n.], 2010. p. 590–593.

PAPATHANASSIOU, S.; STRUNZ, K. A benchmark low voltage microgrid network. **CIGRE Symposium**, 01 2005.

PARK, D. et al. Electric load forecasting using an artificial neural network. **IEEE Transactions on Power Systems**, v. 6, n. 2, p. 442–449, 1991.

PECHT, M.; KANG, M. **Prognostics and Health Management of Electronics: Fundamentals, Machine Learning, and the Internet of Things**. Wiley, 2018. (IEEE Press). ISBN 9781119515302. Disponível em: https://books.google.com.br/books?id=vitpDwAAQBAJ.

PILLAI, J.; BAK-JENSEN, B. Impacts of electric vehicle loads on power distribution systems. In: . [S.l.: s.n.], 2010. p. 1 – 6.

POWELL, J. et al. Smart grids: A comprehensive survey of challenges, industry applications, and future trends. **Energy Reports**, v. 11, p. 5760–5785, 2024. ISSN 2352-4847. Disponível em: https://www.sciencedirect.com/science/article/pii/S2352484724003299.

PUSKORIUS, G.; FELDKAMP, L.; DAVIS, L. Dynamic neural network methods applied to on-vehicle idle speed control. **Proceedings of the IEEE**, v. 84, n. 10, p. 1407–1420, 1996.

RAMíREZ-GALLEGO, S. et al. A survey on data preprocessing for data stream mining: Current status and future directions. **Neurocomputing**, v. 239, p. 39–57, 2017. ISSN 0925-2312. Disponível em: https://www.sciencedirect.com/science/article/pii/S0925231217302631.

RASHEED, T. et al. Improving the efficiency of deep learning models using supervised approach for load forecasting of electric vehicles. **IEEE Access**, PP, p. 1–1, 08 2023.

RICHARDSON, D. B. Electric vehicles and the electric grid: A review of modeling approaches, Impacts, and renewable energy integration. **Renewable and Sustainable Energy Reviews**, v. 19, n. C, p. 247–254, 2013.

RINGWOOD, J. V.; BOFELLI, D.; MURRAY, F. T. Forecasting electricity demand on short, medium and long time scales using neural networks. **J. Intell. Robotics Syst.**, Kluwer Academic Publishers, USA, v. 31, n. 1–3, p. 129–147, maio 2001. ISSN 0921-0296. Disponível em: https://doi.org/10.1023/A:1012046824237.

RUMELHART, D.; HINTON, G.; WILLIAMS, R. Learning representations by back-propagating errors. In: ____. [S.l.: s.n.], 2002. p. 213–222. ISBN 9780262281744.

RYU, S.; NOH, J.; KIM, H. Deep neural network based demand side short term load forecasting. In: . [S.l.: s.n.], 2016. p. 308–313.

SAINI, L. M. Peak load forecasting using bayesian regularization, resilient and adaptive backpropagation learning based artificial neural networks. **Electric Power Systems Research**, v. 78, n. 7, p. 1302–1310, 2008. ISSN 0378-7796. Disponível em: https://www.sciencedirect.com/science/article/pii/S0378779607002258.

SAVITZKY, A.; GOLAY, M. J. E. Smoothing and differentiation of data by simplified least squares procedures. **Analytical Chemistry**, v. 36, p. 1627–1639, 1964. Disponível em: https://pubs.acs.org/doi/abs/10.1021/ac60214a047.

SCHAFER, R. W. What is a savitzky-golay filter? [lecture notes]. **IEEE Signal Processing Magazine**, v. 28, n. 4, p. 111–117, 2011.

SCHNEIDER, K. et al. Impact assessment of plug-in hybrid vehicles on pacific northwest distribution systems. In: . [S.l.: s.n.], 2008. p. 1 – 6.

SEHAR, F.; RAHMAN, S.; PIPATTANASOMPORN, M. Impacts of ice storage on electrical energy consumptions in office buildings. **Energy and Buildings**, v. 51, p. 255–262, 2012. ISSN 0378-7788. Disponível em: https://www.sciencedirect.com/science/article/pii/S0378778812002575.

SHAREEF, H.; ISLAM, M. M.; MOHAMED, A. A review of the stage-of-the-art charging technologies, placement methodologies, and impacts of electric vehicles. **Renewable and Sustainable Energy Reviews**, v. 64, p. 403–420, 2016. ISSN 1364-0321. Disponível em: https://www.sciencedirect.com/science/article/pii/S1364032116302568.

SHI, N. et al. Short-term load forecasting considering ev charging loads with prediction interval evaluation. In: . [S.l.: s.n.], 2024. p. 1–6.

SINGH, A.; IBRAHEEM, K.; MUAZZAM, M. An overview of electricity demand forecasting techniques. **Proceedings of the National Conference on Emerging Trends in Electrical, Instrumentation Communication Engineering**, v. 3, p. 38–48, 01 2013.

SUHLING, M. et al. Multiresolution moment filters: theory and applications. **IEEE Transactions on Image Processing**, v. 13, n. 4, p. 484–495, 2004.

SUN, J. et al. Optimization research on short-term load forecasting method for electric vehicles based on ssa-svm. **Advances in Engineering Technology Research**, v. 11, p. 15, 05 2024.

TALEBIZADEH, E.; ABDOLLAHI, A. Evaluation of plug-in electric vehicles impact on cost-based unit commitment. **Journal of Power Sources**, v. 248, p. 545–552, 02 2014.

TANG, J. et al. A novel ultra short-term load forecasting method for regional electric vehicle charging load using charging pile usage degree. **Energy Engineering**, v. 120, n. 5, p. 1107–1132, 2023. ISSN 0199-8595. Disponível em: https://www.sciencedirect.com/science/article/pii/S0199859523000441.

TANG, M. et al. Short-term load forecasting of electric vehicle charging stations accounting for multifactor idbo hybrid models. **Energies**, v. 17, n. 12, 2024. ISSN 1996-1073. Disponível em: https://www.mdpi.com/1996-1073/17/12/2831.

THE MATHWORKS Inc. **MATLAB version: 8.6.0 (R2015b)**. Natick, Massachusetts, United States: The MathWorks Inc., 2015.

TURKER, H.; BACHA, S. Optimal minimization of plug-in electric vehicle charging cost with vehicle-to-home and vehicle-to-grid concepts. **IEEE Transactions on Vehicular Technology**, v. 67, n. 11, p. 10281–10292, 2018.

WANG, Z.; PARANJAPE, R. An evaluation of electric vehicle penetration under demand response in a multi-agent based simulation. **Proceedings - 2014 Electrical Power and Energy Conference, EPEC 2014**, p. 220–225, 02 2015.

WATSON, M.; PASTUSZEK, L.; CODY, E. Forecasting commercial electricity sales. **Journal of Forecasting**, v. 6, n. 2, p. 117–136, 1987.

WERBOS, P. **Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Science. Thesis (Ph. D.). Appl. Math. Harvard University**. 01 1974. Tese (Doutorado), 01 1974.

WILLIAMS, R.; PENG, J. An efficient gradient-based algorithm for on-line training of recurrent network trajectories. **Neural Computation**, v. 2, p. 490–501, 12 1990.

XING, Q. et al. Urban electric vehicle fast-charging demand forecasting model based on data-driven approach and human decision-making behavior. **Energies**, v. 13, n. 6, 2020. ISSN 1996-1073. Disponível em: https://www.mdpi.com/1996-1073/13/6/1412.

YANG, Z. et al. Hierarchical high resolution load forecasting for electric vehicle charging: A deep learning approach. **IEEE Journal of Emerging and Selected Topics in Industrial Electronics**, PP, 09 2022.

ZHANG, X. Short-term load forecasting for electric bus charging stations based on fuzzy clustering and least squares support vector machine optimized by Wolf pack algorithm. **Energies**, v. 11, n. 6, 2018.

ZHANG, Y. et al. Research of voltage stability analysis method in distribution power system with plug-in electric vehicle. In: . [S.l.: s.n.], 2016. p. 1501–1507.

ZHU, J. et al. Electric vehicle charging load forecasting: A comparative study of deep learning approaches. **Energies**, v. 12, n. 14, p. 1–19, 2019.

APÊNDICE A – PRÉ-PROCESSAMENTO

Nesta parte é inserido o código utilizado para todo o processo contendo todas as etapas e comentários do pré-processamento de Análise de Espectro Singular (AES) e do filtro Savitzky-Golay (SG), onde foi desenvolvido no software MATLAB (THE MATHWORKS Inc., 2015).

```
% Definir parâmetros gerais
load demanda
M = 5;     % comprimento da janela = dimensão de↙
incorporação
N = 8760;   % comprimento da série temporal gerada
stdnoise = 1; % relação ruído do sinal

% Criar série temporal X

t = (1:N)';
X = demanda;
%noise = stdnoise*randn(size(X));
%X = X - mean(X);              % remover valor médio
%X = X/std(X,1);               % normalizar para o desvio↙
padrão 1

figure(1);
set(gcf,'name','Time series X');
clf;
plot(t,X,'b-');

% Calcular a matriz de covariância C (abordagem↙
Toeplitz)
% A seguir, calculamos a matriz de covariância. Existem↙
diversas abordagens numéricas para estimar C.
% Aqui calculamos a função de covariânncia com CORR e↙
construí-mos C com a funçãoo TOEPLITZ.

covX = xcorr(X,M-1,'unbiased');
Ctoep=toeplitz(covX(M:end));

figure(2);
set(gcf,'name','Covariance matrix');
clf;
imagesc(Ctoep);
```

```
axis square
set(gca,'clim',[-1 1]);
colorbar

% Calcular matriz de covariância (abordagem de↙
trajetória)
% Uma abordagem alternativa são determinar C diretamente↙
a partir do produto escalar de Y, a incorporaçãoo↙
retardada de X.
% Embora esta estimativa de C não forneça uma estrutura↙
Toeplitz, com os autovetores não sendo simétricos ou↙
antissimétricos,
% ela garante um semi-positivo positivo. matriz de↙
covariância definida.

Y=zeros(N-M+1,M);
for m=1:M
  Y(:,m) = X((1:N-M+1)+m-1);
end;
Cemb=Y'*Y / (N-M+1);

figure(2);
set(gcf,'name','Covariance matrix');
clf;
imagesc(Cemb);
axis square
set(gca,'clim',[-1 1]);
colorbar

% Escolha a estimativa de covariância
% Escolha entre a abordagem Toeplitz (cf. Vautard &↙
Ghil) e a abordagem de trajetória (cf. Broomhead &↙
King).

% C=Ctoep;
```

```
C=Cemb;

% Calcular autovalores LAMBDA e autovetores RHO
% Para determinar os autovalores e autovetores de C,↙
usamos a funçãoo EIG.
% Esta função retorna duas matrizes,
% a matriz RHO com autovetores dispostos em colunas e a↙
matriz LAMBDA com autovalores ao longo da diagonal.

[RHO,LAMBDA] = eig(C);
LAMBDA = diag(LAMBDA);                  % extrair os↙
elementos diagonais
[LAMBDA,ind]=sort(LAMBDA,'descend'); % classificar↙
autovalores
RHO = RHO(:,ind);                       % e autovetores

figure(3);
set(gcf,'name','Eigenvectors RHO and eigenvalues↙
LAMBDA')
clf;
subplot(3,1,1);
plot(LAMBDA,'o-');
subplot(3,1,2);
plot(RHO(:,1:2), '-');
legend('1', '2');
subplot(3,1,3);
plot(RHO(:,3:4), '-');
legend('3', '4');

% Calcular componentes principais PC
% Os componentes principais sÃ£o dados como o produto↙
escalar entre Y,
% a incorporação retardada de X e os vetores próprios↙
RHO.
```

```
PC = Y*RHO;

figure(4);
set(gcf,'name','Principal components PCs')
clf;
for m=1:4
  subplot(4,1,m);
  plot(t(1:N-M+1),PC(:,m),'k-');
  ylabel(sprintf('PC %d',m));
  ylim([-10 10]);
end;

% Calcular componentes reconstrução-dos RC
% Para determinar os componentes reconstrução-dos RC,
% temos que inverter a projelão PC = Y*RHO; ou seja, RC↙
= Y*RHO*RHO'=PC*RHO'.
% A média ao longo das antidiagonais fornece os RCs para↙
a entrada original X.

RC=zeros(N,M);
for m=1:M
  buf=PC(:,m)*RHO(:,m)'; % projeção invertida
  buf=buf(end:-1:1,:);
  for n=1:N % média antidiagonal
    RC(n,m)=mean( diag(buf,-(N-M+1)+n) );
  end
end;

figure(5);
set(gcf,'name','Reconstructed components RCs')
clf;
for m=1:4
  subplot(4,1,m);
  plot(t,RC(:,m),'r-');
  ylabel(sprintf('RC %d',m));
```

```
  ylim([-1 1]);
end;

% Compare a reconstrução e as séries temporais originais
% Observe que a série temporal original X pode ser↙
completamente reconstruí-da pela soma de todos os↙
componentes reconstruí-dos RC (painel superior).
% A funçãoo oirignal pode ser reconstruí-da com o↙
primeiro par de RCs (painel inferior).

figure(6);
set(gcf,'name','Original time series X and↙
reconstruction RC')
clf;
subplot(2,1,1)
plot(t,X,'b-',t,sum(RC(:,:),2),'r-');
legend('Original','Complete reconstruction');

subplot(2,1,2)
plot(t,X,'b','LineWidth',2);
plot(t,X,'b-',t,sum(RC(:,1:2),2),'r-');
legend('Original','Reconstruction with RCs 1-2');

% Sepração das componentes e série reconstruída
SERIERESENCSTRUIDA = sum(RC(:,1:2),2);

% Série original
SEIEREAL = X;
```

```
order = 3;  % ordem do polinomio
framelen = 5; % valores impares, janela deslizante

sgf = sgolayfilt(demanda,order,framelen);

plot(demanda,':')
hold on
plot(sgf,'.-')
legend('original','filtrado')
```

DADOS CURRICULARES

IDENTIFICAÇÃO	
	Drs. Giovanni Panegossi Formaggio 01/12/1994
Nacionalidade	Brasileiro
Nome em citações bibliográficas	Formaggio, Giovanni Panegossi Formaggio, G.P.
Currículo Lattes	http://lattes.cnpq.br/8720985268725588
ORCID	https://orcid.org/0000-0002-2420-1793
E-MAIL	giovanni.formaggio@unesp.br
FORMAÇÃO ACADÊMICA	
2013/2017	Graduação em Engenharia Mecatrônica. Unisalesiano- Araçatuba, SP, Brasil
2019/2021	Mestrado em Engenharia Elétrica (Automação e Controle) Universidade Estadual Paulista Júlio de Mesquita Filho, UNESP, Brasil.
2022/2026	Doutorado em Engenharia Elétrica (Automação e Controle) Universidade Estadual Paulista Júlio de Mesquita Filho, UNESP, Brasil
PRODUÇÃO BIBLIOGRÁFICA	
Formaggio, G.P. Short-Term Forecasting of Total Aggregate Demand in Uncontrolled Residential Charging with Electric Vehicles Using Artificial Neural Networks. Inventions, 2025.	
Formaggio, G.P. Análise do impacto de carregamentos de veículos elétricos plugáveis no sistema de energia elétrica, UNESP, 2022. (Apresentação de Trabalho/Conferência ou palestra.)	
Formaggio, G.P. Submissão, UMA NOVA ABORDAGEM PARA MELHORAR A PREVISÃO DA DEMANDA TOTAL DE CARREGAMENTO RESIDENCIAL E DE VEÍCULOS ELÉTRICOS USANDO APRENDIZADO PROFUNDO foi recebida pela Electric Power Systems Research. Ele recebeu o seguinte número de manuscrito: EPSR-D-26-00274.	
BANCAS DE TRABALHOS DE CONCLUSÃO	
LOTUFO, A. D. P.; VILELA, D. B.; Giovanni Panegossi Formaggio . Participação em banca de Renan Ferreira Felix.PREVISÃO DE PREÇOS DE COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA POR REDES NEURAIS ARTIFICIAIS. 2022.Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) - Universidade Estadual Paulista Júlio de Mesquita Filho.	
LOPES, M. L. M.; Giovanni Panegossi Formaggio ; SANTOS,D. C. Participação em banca de Gustavo Libralon Kosaki.DETECÇÃO DE FALHAS EM MOTORES UTILIZANDOREDES NEURAIS ARTIFICIAIS. 2023. Trabalho de Conclusão de Curso (Graduação em Engenharia Mecânica) - Universidade Estadual Paulista Júlio de Mesquita Filho.	
LOTUFO, A. D. P.; Montenegro, Paula Andrea; Giovanni Panegossi Formaggio . Participação	