

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE ENGENHARIA – CAMPUS DE ILHA SOLTEIRA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

GIOVANNI PANEGOSSO FORMAGGIO

**Previsão de Demanda de Carregamento para Veículos Elétricos a Curto
Prazo Utilizando Rede Neural Artificial**

ILHA SOLTEIRA
2021



GIOVANNI PANEGOSSİ FORMAGGIO

Previsão de Demanda de Carregamento para Veículos Elétricos a Curto Prazo Utilizando Rede Neural Artificial

Dissertação apresentada à Faculdade de Engenharia do Campus de Ilha Solteira – UNESP, como parte dos requisitos para obtenção do título de Mestre em Engenharia Elétrica.

Prof^ª. Dr^ª. Anna Diva Plasencia Lotufo
Orientadora

ILHA SOLTEIRA

2021



FICHA CATALOGRÁFICA
Desenvolvido pelo Serviço Técnico de Biblioteca e Documentação

F724p Formaggio, Giovanni Panegossi.
Previsão de demanda de carregamento para veículos elétricos a curto prazo
utilizando rede neural artificial / Giovanni Panegossi Formaggio. -- Ilha Solteira:
[s.n.], 2021
92 f. : il.

Dissertação (mestrado) - Universidade Estadual Paulista. Faculdade de
Engenharia de Ilha Solteira. Área de conhecimento: Automação e Controle,
2021

Orientador: Anna Diva Plasencia Lotufo
Inclui bibliografia

1. Previsão de demanda de carregamento. 2. Veículos elétricos. 3. Rede
neural artificial.


Raiane da Silva Santos

Supervisora Técnica de Seção
Seção Técnica de Referência, Atendimento ao usuário e Documentação
Diretoria Técnica de Biblioteca e Documentação
CRB/8 - 9999



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Ilha Solteira

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Previsão de Demanda de Carregamento para Veículos Elétricos a Curto Prazo Utilizando Rede Neural Artificial

AUTOR: GIOVANNI PANEGOSSO FORMAGGIO

ORIENTADORA: ANNA DIVA PLASENCIA LOTUFO

Aprovado como parte das exigências para obtenção do Título de Mestre em ENGENHARIA ELÉTRICA, área: Automação pela Comissão Examinadora:

Prof.^a. Dr.^a. ANNA DIVA PLASENCIA LOTUFO (Participação Virtual)
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira - UNESP

Prof. Dr. MAURO DE SOUZA TONELLI NETO (Participação Virtual)
MacPhail School of Energy - Southern Alberta Institute of Technology - Calgary, AB, Canadá

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

Ilha Solteira, 09 de abril de 2021

Dedico a todos aqueles que nunca acreditaram em mim, me criticaram sempre e duvidaram muito. Muito obrigado por me fazerem chegar onde cheguei.

AGRADECIMENTOS

Em primeiro lugar agradeço ao pai eterno criador do universo.

Agradeço minha família por tudo, aos meus pais Elaine e Roberto que me fizeram, ao meu pai que sempre deixou seus sonhos em segundo plano para dar de tudo a nós, a minha mãe por dedicar sua vida toda a cuidar dos filhos, a minha avó Alice da Bahia Alves do Santos Menegati de 96 anos, por sempre comprar lanches, sorvetes e refrigerantes.

A minha irmã Giullia, por ser a coisa mais bonita e importante que aconteceu na minha vida.

Aos meus avós de Lavínia Eunice e José e aos meus padrinhos de batismo e crisma que sempre me deram tudo.

A minha companheira de jornadas das estrelas Danieli, por me aturar o tempo todo, ser sempre essa namorada incrível, obrigado por sempre ser leal e íntegra, por sempre me inspirar e me ajudar em tudo (vida longa e próspera para nós).

Agradeço do fundo do coração a Prof^ª. Dr^ª. Anna Diva Plasencia Lotufo, minha orientadora, por ter me passado o tema de pesquisa e depositado sua confiança em mim, pelo tempo dedicado a pesquisa, educação e paciência pelas minhas idas a sua sala, que eu sei que foi difícil aturar as dúvidas.

Agradeço a CAPES e CNPQ, pelo apoio financeiro da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

A Prof^ª. Dr^ª. Mara Lúcia Martins e o Prof^º. Dr. Carlos Roberto Minussi, pelo carinho, motivação e contribuições, por sempre serem atenciosos e profissionais de altíssimo nível. Muito obrigado por existirem e que orgulho de terem os senhores como inspirações.

Ao Pós-doutorando Mauro de Souza Tonelli Neto, por ser meu coorientador não oficial e ajudar em tudo no meu processo de aprendizagem sobre previsão de cargas.

A Prof^ª. Dr^ª. Monara Pereira da Rosa Carvalho, por tirar sempre minhas dúvidas e pelo trabalho de auxílio do uso da toolboxes para previsão de cargas.

A todos os pós-graduandos do laboratório SINTEL.

A todos os apoiadores da UNESP, PPGEE e FEIS com a segurança, assistência técnica, assistência de limpeza e transporte, obrigado por sempre deixar tudo em perfeitas condições de trabalho.

Agradeço aos meus colegas Jeferson e Evandro, por me deixaram ficar na casa deles sem cobrar nada de quinta-feira, enquanto fazia aulas como aluno especial.

*“Você sabe que seus dias estão contados, conte-os um por um, como entalhes no cabo de
uma arma de um fora da lei.
Você pode escapar do diabo, se tentar, mas nunca escapará das mãos do tempo.”*

Mark Collie

RESUMO

Veículos elétricos vêm se tornando cada vez mais presentes no nosso cotidiano e a sua implantação e crescimento apresentam novos desafios ao sistema de energia elétrica, devido à alta necessidade de cargas armazenadas pelo carregamento. A previsão da demanda de cargas gerada pelo carregamento desses veículos utilizando redes neurais artificiais demonstra ser uma ferramenta muito eficiente para resolução desse tipo de problema. Foi proposto nesse trabalho o uso de uma rede do tipo *feedforward* com multicamadas usando o treinamento de regularização bayesiana. Nessa pesquisa, utiliza-se banco de dados reais para o processo de treinamento e teste, com intuito de gerar um resultado de previsão realista. Foram utilizados três bancos de dados separados em dois ambientes distintos, um para estação de carregamento e outro de carregamento de veículos residenciais. A metodologia proposta apresentou bons resultados, tendo potencial para ser aplicada na prática em todos os ambientes estudados. Foi observado também que no ambiente de estação de carregamento a previsão apresentou uma dificuldade em relação a ambiente de carregamentos residenciais, por se tratar de um ambiente com um tipo de carregamento mais imprevisível.

Palavras-chave: Veículos elétricos. Redes neurais artificiais. Previsão de cargas elétricas. Rede *feedforward* de multicamadas. Estação de carregamento. Carregamento residencial. Treinamento de regularização bayesiana.

ABSTRACT

Electric vehicles are becoming increasingly present in our daily lives and their implementation and growth present great new challenges to the electric power system, due to the high need for charges stored by charging. The load forecasting, generated by loading these vehicles, using artificial neural networks proves to be a very efficient tool for solving this type of problem. This work proposes the use of a feedforward network with multilayers using Bayesian regularization training. In this research, real databases are used for the training and testing process, in order to generate a realistic forecasting result. Three separate databases were used in two different environments, one for the charging station and the other for the loading of residential vehicles. The proposed methodology presented good results and pertinent to the theme, with potential to be applied in practice in all studied environments. It was also observed that, in the charging station environment, the forecast presented a difficulty in relation to the residential loading environment, as it is an environment with a more unstable loading type.

Keywords: Electric vehicles. Artificial neural networks. Load forecasting. Feedforward multilayer network. Charging station. Residential charging. Bayesian regularization training.

LISTA DE ILUSTRAÇÕES

Figura 1 – Vendas acumuladas de veículos elétricos em 2019 por mercados.	21
Figura 2 – Vendas anuais de veículos elétricos de passageiros por mercados de 2010 a 2019.	21
Figura 3 – Classificação de coordenação de carregamento de VEs.	24
Figura 4 – Aumento no consumo de eletricidade nos EUA devido a VEs.	27
Figura 5 – Demanda dos VEs durante um dia da semana.	29
Figura 6 – Demanda dos VEs durante um dia no fim de semana.	29
Figura 7 – Perfil durante os dias da semana: residencial + VEs.	30
Figura 8 – Perfil durante o fim de semana: residencial + VEs.	30
Figura 9 – Demanda horária.	34
Figura 10 – Demandas semanais.	34
Figura 11 – Demandas anuais.	35
Figura 12 – Séries temporais: não estacionárias e estacionárias.	36
Figura 13 – Modelo de um neurônio artificial.	39
Figura 14 – Tipos de funções de ativação.	41
Figura 15 – Função sigmoide 1 e sigmoide 2.	41
Figura 16 – Estrutura <i>feedforward</i> multicamadas.	42
Figura 17 – Fluxo <i>feedforward</i> (direção).	44
Figura 18 – Erro retropropagado.	45
Figura 19 – Demanda diária de carregamento da JPL e CALTECH.	54
Figura 20 – Demanda total nas 200 residências.	55
Figura 21 – Demanda total do carregamento dos 348 veículos.	56
Figura 22 – Metodologia para previsão de cargas em estação de carregamento.	57
Figura 23 – Arquitetura da RNA proposta para o Ambiente 1.	60
Figura 24 – Metodologia para previsão de carregamento residencial.	61
Figura 25 – Demanda residencial total das 200 residências.	63
Figura 26 – Demanda total de carregamento com 348 VEs.	63
Figura 27 – Comparação das demandas geradas pelas residências e carregamentos dos VEs.	64
Figura 28 – Impacto do carregamento dos 348 VEs nas 200 residências.	65
Figura 29 – Impacto na demanda residencial causado pelos carregamentos dos VEs em 24 horas.	65
Figura 30 – Impacto na demanda residencial gerado pelo carregamento dos VEs.	66
Figura 31 – Demanda de cargas totais por estações do ano.	67
Figura 32 – Arquitetura da RNA utilizada para o Ambiente 2.	68
Figura 33 – Previsão para a primavera.	74
Figura 34 – Previsão para o verão.	75

Figura 35 – Previsão para o outono.	75
Figura 36 – Previsão para o inverno.	76

LISTA DE TABELAS

Tabela 1 – Níveis de potência de carregamento.	24
Tabela 2 – Parâmetros de treinamento.	52
Tabela 3 – Organização dos dados da CALTECH e JPL.	58
Tabela 4 – Configuração dos dados de demanda residencial e de carregamento dos VEs.	62
Tabela 5 – Dimensões dos conjuntos de treinamento e teste.	67
Tabela 6 – Parâmetros e configurações da RNA.	70
Tabela 7 – Tipos de RNA e resultados.	70
Tabela 8 – Resultados da previsão da RNA <i>feedforward</i>	71
Tabela 9 – Valores reais e previstos JPL.	71
Tabela 10 – Valores reais e previstos CALTECH.	71
Tabela 11 – Parâmetros das redes NARX e ELMAN.	72
Tabela 12 – Resultados obtidos.	72
Tabela 13 – Testes e resultados para a primavera e verão.	73
Tabela 14 – Especificações da RNA <i>feedforward</i>	74
Tabela 15 – Resultados das previsões por estação.	74
Tabela 16 – Porcentagem de erros mínimos e máximos obtidos por estação.	76
Tabela 17 – Resultados das previsões em cada hora para todas as estações.	77
Tabela 18 – Desempenho dos treinamentos: tempo de processamento e iterações. . .	77

LISTA DE ABREVIATURAS E SIGLAS

ACN	<i>Adaptive Charging Network</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
CEL	Cargas Elétricas Convencionais
CDE	Demanda de Carregamento em Veículos Elétricos
GBRT	<i>Gradient Boosting Regression Trees</i>
GEE	Gases de Efeito Estufa
GRU	<i>Recurring Unit Closed</i>
IA	Inteligência Artificial
KNN	<i>K-Nearest Neighbor</i>
LSSVM	Máquina de Vetor de Suporte de Mínimos Quadrados
LSTM	<i>Long Short Term Memory</i>
MAPE	Erro Percentual Absoluto Médio
MCI	Motor de Combustão Interna
PSF	<i>Pattern Sequence Forecasting</i>
RBF	Rede Neural Artificial de Função Base Radial
RECS	<i>Residential Energy Consumption Survey</i>
RF	<i>Random Forests</i>
RNAs	Redes Neurais Artificiais
RNN	Redes Neurais Recorrentes
SARIMAX	<i>Seasonal Autoregressive Integrated Moving Average</i>
SMAPE	Erro Percentual Absoluto Médio Simétrico
SVM	<i>Support Vector Machine</i>
VEAEs	Veículos Elétricos de Alcance Estendido
VEBs	Veículos Elétricos Totalmente a Bateria

VEs	Veículos Elétricos
VEHs	Veículos Elétricos Híbridos
VEHPs	Veículos Elétricos Híbridos Plugáveis
VEPs	Veículos Elétricos Plugáveis

SUMÁRIO

1	INTRODUÇÃO	11
1.1	OBJETIVO DO TRABALHO E CONTRIBUIÇÃO	13
1.2	ORGANIZAÇÃO DO TRABALHO	13
2	TRABALHOS CORRELATOS	15
2.1	MÉTODOS ESTATÍSTICOS	15
2.2	MÉTODOS DE INTELIGÊNCIA ARTIFICIAL	16
3	VEÍCULOS ELÉTRICOS	19
3.1	CRESCIMENTO DO MERCADO CONSUMIDOR DE VEs	20
3.2	TIPOS DE VEÍCULOS ELÉTRICOS	22
3.3	CARREGAMENTO DOS VEs	22
3.3.1	Tipos de carregamento e níveis de energia	23
3.3.1.1	Carregamento não coordenado (descoordenado)	23
3.3.1.2	Carregamento coordenado	23
3.3.1.3	Níveis de energia	24
3.3.2	Localização	25
3.3.2.1	Estação de carregamento para VEs	25
3.3.2.2	Carregamento residencial de VEs	25
3.4	DEMANDA ENERGÉTICA	26
3.5	IMPACTOS GERADOS PELOS VEs AO SISTEMA DE ENERGIA ELÉTRICA	27
3.5.1	Impacto do carregamento dos VEs agregados a demanda residencial	28
3.5.1.1	Impacto do carregamento descontrolado de VEs agregado a demanda residencial	28
3.5.2	Impacto das estações de carregamento de VEs na rede elétrica	31
4	PREVISÃO DE CARGAS ELÉTRICAS	33
4.1	PADRÃO DE COMPORTAMENTO DAS CARGAS ELÉTRICAS	35
4.2	FATORES QUE INFLUENCIAM AS CARGAS ELÉTRICAS	36
4.3	CLASSIFICAÇÃO DAS PREVISÕES DE CARGAS ELÉTRICAS	37
4.4	CARACTERÍSTICAS E DIFICULDADES NA PREVISÃO DE CARGAS EM VEÍCULOS ELÉTRICOS	37
5	REDES NEURAIS ARTIFICIAIS E TREINAMENTO	39
5.1	ESTRUTURA DA REDE NEURAL ARTIFICIAL	41
5.1.1	Redes neurais <i>feedforward</i> de multicamadas	41

5.2	TREINAMENTO DE UMA REDE NEURAL ARTIFICIAL	46
5.2.1	Treinamento com regularização bayesiana	46
5.2.1.1	Algoritmo de regularização bayesiana	47
5.2.1.2	Otimização dos parâmetros de regularização	49
5.2.1.3	Aproximação de Gauss-Newton para a matriz Hessiana	50
5.3	PARÂMETROS DE TREINAMENTO	51
6	AMBIENTES DE ESTUDO	53
6.1	AMBIENTE 1: ESTAÇÕES DE CARREGAMENTO PARA VEs . . .	53
6.2	AMBIENTE 2: CARREGAMENTO RESIDENCIAL DE VEs DESCO- ORDENADOS	54
7	METODOLOGIA	57
7.1	AMBIENTE 1	57
7.2	AMBIENTE 2	61
8	RESULTADOS E DISCUSSÃO	69
8.1	RESULTADOS AMBIENTE 1	69
8.2	RESULTADOS AMBIENTE 2	71
9	CONCLUSÃO E TRABALHOS FUTUROS	78
9.1	TRABALHO FUTUROS	80
	REFERÊNCIAS	82

1 INTRODUÇÃO

Uma medida significativa para dar suporte a um desenvolvimento mais sustentável é a redução dos gases poluentes emitentes na atmosfera. Os gases de efeito estufa (GEE), principalmente o dióxido de carbono CO_2 , são os gases que mais contribuem para a poluição causadora das mudanças climáticas (UNCC, 2018). Com isso, a preocupação global devido a essas emissões antropogênicas vem sendo direcionada principalmente para os GEE.

As redes de meios de transporte se encontram no centro da cadeia de abastecimento e são a base econômica de um país. O setor de transporte é um dos maiores contribuintes para as emissões dos gases poluentes na atmosfera, tanto GEE quanto outros poluentes atmosféricos (EPA, 2016).

O cenário atual de transporte vem crescendo de uma forma acelerada, aumentando a busca por veículos a combustão. Nesse segmento, o aumento de emissões dos GEE gerados pelo setor de transporte é responsável por 27% das emissões de gases poluentes e 32% dessas emissões são de CO_2 (FAN et al., 2018).

A busca por fontes de energias alternativas e limpas tornou-se uma opção indispensável nesse contexto, já que a poluição derivada das queimas de combustíveis fósseis no setor de transportes causa um grande impacto e preocupação em nosso presente e futuro próximo (JAHANGIR et al., 2019). Portanto, os veículos elétricos híbridos (VEHs), veículos elétricos a bateria (VEBs) e veículos elétricos híbridos plugáveis (VEHPs) vem se tornando cada vez mais populares e demonstrando uma opção promissora para um futuro mais sustentável (RASKIN; SAURIN, 2006).

Os veículos elétricos (VEs) podem certamente substituir os veículos convencionais. De acordo com a pesquisa realizada em 2017 (MUKHERJEE; GUPTA, 2017), no Estados Unidos da América (EUA), a previsão era de que se houvesse um crescimento em sua frota nacional de 10% até 2020 e aumento de 50% nas vendas de veículos elétricos, que serão inseridos na frota até 2050. Esse crescimento de novos VEs apresenta um novo desafio para o sistema elétrico de potência, que necessita de planejamento para um novo cenário de geração de energia, controle e operações de energias existentes (ALIASGHARI et al., 2018).

O carregamento das baterias dos veículos elétricos plugáveis (VEPs) provocará um aumento na demanda de energia elétrica nas redes de distribuição. É previsto que esse aumento poderá causar quedas de tensão, sobrecargas térmicas e um aumento nas perdas (PAPADOPOULOS et al., 2012). Os VEPs geram uma alta demanda de carga durante seu carregamento, o que poderá forçar a rede elétrica fazendo com que não atenda a sua capacidade de entrega de energia, gerando falhas e complicações. O grande desafio

do sistema elétrico para os VEPs é como a cobrança de demanda de carregamento pode afetar o sistema de energia, devido aos picos de consumo das cargas dos veículos, que podem ser feitas por carregamentos em estacionamentos públicos, privados ou residenciais (CLEMENT-NYNS; HAESSEN; DRIESEN, 2010).

Ao introduzir o carregamento de VEPs na demanda elétrica residencial haverá um acréscimo na demanda, impactando a infraestrutura de geração e transmissão de energia (MURATORI et al., 2013).

Uma das abordagens para garantir que a demanda energética atenda o consumo é fazer previsões de cargas elétricas no sistema de energia, com variações de prazos de horas para dias, meses e anos, e isso irá garantir vantagens econômicas, estratégicas e outras. As previsões têm um papel de influenciar diretamente nas decisões operacionais importantes como despacho, compromisso da unidade e programação de manutenção (EL-SHARKAWI; MARKS; WEERASOORIYA, 1991).

A busca pela previsão da demanda de cargas elétricas se tornou um tema atrativo na área de pesquisa e comercial no ramo da engenharia elétrica. Fazer uma previsão de carga a curto prazo no mercado de energia elétrica é cada vez mais importante para se manter em nível competitivo. A previsão de cargas não é uma tarefa fácil, pois ela depende de vários fatores, por exemplo, a carga em uma determinada hora não depende somente da carga na hora anterior e sim da carga correspondente no dia ou semana anterior na mesma hora. Variáveis do tipo exógenas devem ser consideradas, especialmente as relacionadas ao fator climático (HIPPERT; PEDREIRA; SOUZA, 2001).

Para previsão de cargas elétricas existem uma ampla variedade de técnicas de modelagem. Estes métodos variam de acordo com a experiência do operador (LONERGAN; RINGWOOD, 1995) até com abordagens matemáticas formais, como técnicas estruturais (BRUCE; JURKE; THOMSON, 1994), métodos bayesianos (GUINEL, 1987), métodos de Box-Jenkins (WATSON; PASTUSZEK; CODY, 1987), lógica *fuzzy* (AL-ANBUKY; BATAINEH; AL-AQTASH, 1995) e sistemas inteligentes como redes neurais artificiais (RNA's) (PARK et al., 1991).

No caso do método das RNAs, a maioria dos estudos da literatura resolvem problemas de previsão de perfis de demanda diária ou de pico de demanda diária. As RNAs são usadas para prever a demanda de pico e também prever as demandas em 24 horas (ASAR; J., 1994)(LEE et al., 1993)(KERMANSNAHI et al., 1993).

O uso de técnicas de inteligência artificial faz com que problemas como prever as cargas futuras possam ser implantados e resolvidos de uma maneira eficiente, pois as RNAs aprendem com padrões anteriores e guardam essas informações para uso posterior. O neurônio artificial se assemelha ao neurônio biológico que processa essas informações armazenando o conhecimento aprendido ao longo do tempo (HAYKIN, 1999).

Nesse sentido, essa pesquisa se propõe a fazer previsões das demandas diárias de carregamento a curto prazo em estações de carregamento para VEPs e previsões da demanda total gerada pelo carregamento descontrolado de VEPs em ambiente residencial em 24 horas. Utiliza-se a RNA do tipo *feedforward* de multicamadas (MINSKY; PAPERT, 1969) via treinamento de regularização bayesiana (MACKAY, 1992) em que os bancos de dados são de perfis reais de consumo obtidos diretamente no carregamento dos veículos. Estações de carregamento (Ambiente 1): um ambiente de trabalho exclusivo para funcionários do *Jet Propulsion Laboratory* (JPL), um ambiente universitário, porém aberto ao público, do *California Institute of Technology* (CALTECH) e carregamento residencial (Ambiente 2) um ambiente residencial com carregamento de VEPs exclusivamente em residências.

1.1 OBJETIVO DO TRABALHO E CONTRIBUIÇÃO

O trabalho tem como objetivo o desenvolvimento de uma metodologia baseada na arquitetura da rede *feedforward* com treinamento de regularização bayesiana para previsão da demanda de carregamento de VEs em dois ambientes bem distintos, estações de carregamento e carregamento residencial.

A proposta é aplicar a técnica para resolver o problema de previsão de cargas em carregamento para veículos elétricos considerando ambientes distintos, prevendo os próximos dias e 24 horas das demandas totais de carregamentos coordenados ou controlados (Ambiente 1) e descoordenados ou não coordernados (Ambiente 2).

A contribuição geral deste estudo é usar uma arquitetura e treinamento conceituado na literatura para promover uma aplicação para um assunto recente em termos de pesquisa totalmente aplicável na área de previsão a curto prazo em carregamentos de veículos elétricos. O diferencial desta pesquisa é aplicar a previsão de cargas para veículos elétricos em ambientes distintos.

1.2 ORGANIZAÇÃO DO TRABALHO

Esse trabalho foi dividido em nove capítulos, organizados em introdução ao tema, introdução e história sobre os veículos elétricos, demanda energética e impactos gerados pelos carregamentos dos veículos, previsão de cargas elétricas convencionais e de veículos, ambiente de estudo usado, trabalhos correlatos ao tema, redes neurais artificiais e treinamento, metodologia usada no trabalho, testes e resultados e por fim as considerações finais e trabalhos futuros.

No Capítulo 2 é feita uma breve revisão de trabalhos da literatura sobre previsões de cargas e carregamentos dos veículos elétricos utilizando técnicas de modelos estatísticos e inteligência artificiais.

No Capítulo 3 é apresentada uma introdução a veículos elétricos, sua história e evoluções, tipos de veículos existentes com seus níveis de carga e variações de carregamentos, abordagens do mercado e crescimento da utilização. Também foi apresentado o funcionamento da demanda de cargas para os veículos e seus ambientes de carregamentos. E finalizando, os impactos gerados pelos VEs ao sistema de energia elétrica, com os impactos nas demandas residenciais e em estação de carregamento.

No Capítulo 4 será apresentado o padrão de comportamento das cargas elétricas, fatores que influenciam as cargas elétricas, tipos de cargas, classificações das previsões de cargas elétricas e características e dificuldades na previsão de cargas elétricas em VEs.

No Capítulo 5 são apresentados o conceito de modelo de um neurônio artificial, a estrutural da RNA utilizada neste trabalho e seu algoritmo de treinamento.

O Capítulo 6 apresenta a natureza dos bancos de dados utilizados no trabalho, com ambientes diversificados. É mostrado e descrito os dados e variáveis de todos os ambientes que serão utilizados para a resolução do problema.

No Capítulo 7 são apresentadas as metodologias utilizadas para as previsões de carregamentos nos dois ambientes propostos.

No Capítulo 8 são apresentados todos os testes feitos, com os melhores parâmetros e resultados obtidos, que serão discutidos para cada ambiente proposto.

Por fim o Capítulo 9 apresenta a conclusão do trabalho e passos futuros.

2 TRABALHOS CORRELATOS

Os trabalhos correlatos apresentados neste capítulo serão divididos em dois grandes grupos, de acordo com os tipos de ferramentas utilizadas nas previsões, sendo elas métodos estatísticos e métodos de inteligência artificial.

2.1 MÉTODOS ESTATÍSTICOS

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 (CEL) e a demanda de carregamento em veículos elétricos (CDE) simultaneamente. Foi proposta uma previsão de demanda desacoplada devido aos padrões sazonais. Foram apresentadas duas abordagens, previsão integrada (CEL + CDE) e previsão desacoplada (CEL e CDE). A previsão é feita para o dia seguinte com resolução de uma hora. Como resultado a previsão integrada obteve um erro percentual absoluto médio (MAPE) de 7,25% e a desacoplada obteve 1,44%.

Majidpour (2016) (MAJIDPOUR et al., 2016) prevê o consumo de energia na estação de carregamento para VES do campus da (UCLA) Universidade da Califórnia em Los Angeles. Foram utilizados algoritmos estatísticos *K-Nearest Neighbor* (KNN), ARIMA, *Pattern Sequence Forecasting* (PSF) e um algoritmo proposto *Pattern Sequence Forecasting Modified* (MPSF). O conjunto de dados reais foi dividido em 90% para treinamento e 10% para testes e foram utilizados como entrada o consumo médio de energia do dia com resolução de 24 horas. Para validar a previsão utilizou o erro percentual absoluto médio simétrico (SMAPE), e os resultados obtidos foram de [15,42%, 15,02%] no KNN, [24,96%, 35,26%] no ARIMA, [42,29%, 25,32%] no PSF e [13,78% 13,51%] no algoritmo proposto.

Louie (2017) (LOUIE, 2017) avalia e propõe a utilização do modelo ARIMA para prever consumo agregado de VEs em estação de carregamento. Os dados são de consumo de energia de 2400 estações de carregamento medidos no período de 2 anos, no estado de *Washington* e na cidade *San Diego, Califórnia*. Os conjuntos de dados são de consumo real de energia agregados das estações de carregamento em cada região. Os dados originais são de valores médios medidos com resolução de 15 minutos e convertidos para médias horárias. Nesses termos, foi feita uma previsão de carga a curto prazo agregada. Foram feitas duas previsões: a primeira para a semana aplicada em 10 dias e a segunda para final de semana aplicada em 4 dias. As previsões nas próximas 24 horas na semana alcançaram um MAPE de 15,5% e no final de semana 17,3%.

Lee (2019) (LEE; LI; LOW, 2019) utiliza o banco de dados ACN para prever o

comportamento dos usuários nos dois ambientes (CALTECH) e (JPL). Foi levado em consideração os horários de chegadas e seu respectivo consumo de energia para prever o horário de partida de um usuário. O modelo proposto para prever o comportamento do usuário foi de mistura gaussiana (GMM), para validar o resultado utilizou-se SMAPE e os melhores resultados foram obtidos com 14,4273% (CALTECH) e 12,25% (JPL).

Buzna (2019) (BUZNA et al., 2019) desenvolveu uma pesquisa comparativa entre modelos de previsões de cargas em VEs utilizando métodos de séries temporais e inteligência artificial (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 variáveis de entrada foram números de estações de carregamento ativas, números de usuários ativos estimados pelos cartões de identificação respectivos aos horários de entrada e saída das medições, números de estações de carregamentos em função do número de conectores e valores do consumo máximo de carregamento. 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%.

Para lidar com a crescente demanda de carga, Lee (2019) (LEE et al., 2019) propõe o uso de 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 3kW gerados pelo automóvel de uma família, medido no intervalo de 1 hora. A distribuição gaussiana foi utilizada como modelo para distribuição de probabilidade anterior e os dados foram treinados e comparados com dados mais recentes, comparando-os com o método de regressão linear. O modelo proposto obteve MAPE de 3,09%, e a regressão linear 3,17%.

2.2 MÉTODOS DE INTELIGÊNCIA ARTIFICIAL

Beccali (2004) (BECCALI et al., 2004) utilizou uma RNA *feedforward* com algoritmo de treinamento *backpropagation* com momento, fazendo uma previsão de carga a curto prazo em VEs urbanos. Foi utilizada a RNA auto-organizável de *Kohonen* para classificação dos dados históricos. As variáveis de entrada foram temperatura, umidade, radiação solar e cargas, com 136 entradas. Os resultados obtidos para a previsão das próximas 24 horas individuais foram de 1,97% de erro médio, 3,81% erro máximo e 0,09% erro mínimo.

No trabalho de Xydas (2013) (XYDAS et al., 2013) foi proposto o uso de *Support Vector Machines* (SVM) como uma técnica de inteligência artificial para fazer uma previsão de carga de curto prazo. Foram usados dados históricos reais das estações de carregamento

de VEs usados nos jogos olímpicos de Pequim. Para testar o desempenho do modelo utilizou-se o método estocástico de Monte Carlo. Os dados de entrada foram de 50 semanas, as variáveis usadas foram os números das semanas, dias das semanas, horários das medições, números de conexões dos VEs, cargas normais e cargas normalizadas dos dias, semanas e as médias das 4 semanas anteriores. O método com SVM obteve um MAPE de 3,69% enquanto o Monte Carlo teve um MAPE de 8,99%.

Xiaobo (2014) (XIAOBO; LIU W.AND XI; TIANYANG, 2014) analisa fatores que influenciam as cargas diárias das estações de carregamento em ônibus elétricos, utilizando a *Grey Model* (GM) que estabelece amostras de dias semelhantes que foram usados para a previsão com SVM. O autor também propõe um algoritmo de evolução diferencial (DE) com o objetivo de melhorar a previsão. Os dados foram coletados de estação de carregamento de ônibus elétrico em Pequim, China. O método padrão de SVM obteve RMSE de 12,37%, o SVM proposto melhorado obteve erro mínimo de 6,96%, o ARIMA obteve 10,93% e a regressão linear obteve 11,99%.

No estudo de Hu (2015) (HU et al., 2015) é proposto um novo método híbrido de previsão de carga de curto prazo, junto à análise singular de espectro com uma RNA de Função de Base Radial (RBF). A utilização da análise singular de espectro se dá no sentido de melhorar as curvas das cargas a serem inseridas no treinamento e tem como objetivo decompor a série temporal original em componentes independentes, diminuindo os ruídos dos componentes da previsão. Os dados foram coletados de VEs individuais e familiares carregados em casa. Os dados de entradas de treinamento foram cargas de pico, dias da semana, horários do dia, indicadores sobre dias úteis de trabalho, temperatura e umidade. Os resultados da previsão das próximas 24 horas obtiveram MAPE de 3,12% para a RBF e 0,14% para o modelo híbrido.

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 vetor de suporte de mínimos quadrados (LSSVM) e

algoritmo *Wolf pack* 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 *Wolf pack* 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.

No estudo de Nair *et. al.* (2019) (NAIR et al., 2018) foi proposta uma previsão a curto prazo da demanda doméstica de carregamentos de VES com RNAs profundas. Utilizou o conjunto de dados RECS apresentado no capítulo 5 e os perfis foram gerados utilizando a modelagem proposta por Muratori (2018) (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 52416 amostras de consumo de energia e validadas 1440 amostras. Os resultados foram divididos em 4 tipos de agrupamentos criados a partir dos perfis. O primeiro grupo contendo 7 residências obteve um uma média de 2,46% de erro, o segundo com 43 residências obteve erro médio de 3,29%, terceiro grupo contendo 7 residências com erro médio de 1,782% e por fim o quarto grupo contendo 26 residências com erro médio de 2,5%.

Zhu *et. al.* (2019) (ZHU et al., 2019b)(ZHU et al., 2019a) elaboraram uma previsão de carga a curto prazo em estação de carregamento de VEs. O conjunto de dados são 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 dias, semanas, fim de semanas e feriados. Os métodos usados para previsões foram RNAs profundas, *Long Short Term Memory* (LSTM), redes neurais recorrentes (RNN) e *Recurring Unit Closed* (GRU). Foram usadas 3 estruturas diferentes para cada ferramenta, variando de 1 à 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.

3 VEÍCULOS ELÉTRICOS

Os veículos elétricos (VEs), ao contrário do que possa parecer atualmente, tiveram um período de forte desenvolvimento já no século passado quando comparados aos convencionais veículos com motor de combustão interna (MCI), estando a frente desses em grande parte do século em aspectos tecnológicos (GUARNIERI, 2011).

Em meados de 1800 o inventor suíço François Isaac de Rivaz deu origem ao primeiro MCI, embora com um projeto inicial e bruto, utilizando como combustível uma mistura de hidrogênio e oxigênio, que permaneceu sendo utilizada por décadas. De maneira semelhante, o físico e químico Christian Orsted, em 1820, deu início às primeiras tentativas usando propulsão elétrica para obter movimentos mecânicos (GUARNIERI, 2011). O matemático e físico inglês Peter Barlow, em 1822, deu início a rotação contínua em um disco provocada pela interação de um campo magnético e corrente elétrica, embora não tenha sido mecanicamente funcional.

Seguindo-se a essas descobertas, surgiram outros dispositivos capazes de gerar forças eletrodinâmicas mais eficientes e fortes, como o multiplicador eletromagnético (a primeira bobina) desenvolvido pelo físico alemão Johann Schweigger em 1820. Logo, em 1825, o físico inglês William Sturgeon construiu o eletroímã com núcleo de ferro. Embasados nessas conquistas, os primeiros motores elétricos iniciais foram desenvolvidos com objetivo de mover carros. Em 1828, o inventor e padre húngaro Ányos Jedlik, conhecido como o pai do dínamo, construiu um protótipo minúsculo de um carro movido pelo primeiro motor elétrico bruto. Tendo por base esse avanço, logo em seguida na Escócia, o inventor Robert Anderson desenvolveu em 1832-1839 uma carruagem elétrica primitiva, e em 1835 o holandês Sibrandus Stratingh construiu um carro de pequeno porte (GUARNIERI, 2011).

Ainda em 1835 se iniciaram os primeiros experimentos relacionados a vagões elétricos. O inventor ferreiro americano Thomas Davenport construiu, em 1835, um modelo de vagão de brinquedo e o inventor escocês Robert Davidson, em 1838, desenvolveu um modelo em tamanho real. O experimento elétrico americano de Charles Grafton Page, em 1851, conseguiu dar movimentos a uma locomotiva movida por um motor elétrico alternativo (GUARNIERI, 2011).

Apesar de todos esses experimentos e avanços os VEs iniciais eram muito rudimentares e não apropriados ao desenvolvimento prático. Os motores eram basicamente constituídos por eletroímãs combinados, operados automaticamente por comutadores primitivos, porém de baixo rendimento. Além disso, naquela época os geradores existentes eram as primeiras células eletroquímicas, que mesmo melhoradas com células despolarizadas, foram descartadas devido ao seu valor elevado. Os motores e baterias não eram muito eficientes, mas funcionavam, e seu desenvolvimento estava marcadamente à frente dos veículos a MCI (GUARNIERI, 2011).

As baterias recarregáveis no século XIX não eram eficientes o suficiente, pois só poderiam ser recarregadas pelas células primárias, resultando em operações com baixa eficiência. Os dínamos só se tornaram viáveis em 1860, devido aos experimentos de Werner Siemens em (1856-1867), Antonio Pacinotti (1860) e Zenobe Gramme (1869). Esses geradores eletromecânicos produziam energia elétrica de baixo custo quando comparados com células eletroquímicas primárias, e com isso, se deu início a aplicação em larga escala em diversas áreas da eletricidade (GUARNIERI, 2011).

Quando os geradores se tornaram comerciais, a primeira célula recarregável de chumbo e ácido surgiu em 1859, criada por Gaston Plante. Esse modelo foi aprimorado por Camille Alphonse Faure em 1881 e obteve um grande avanço e sucesso, inserindo a célula nos VEs produzidos nos anos seguintes. Na mesma época, os motores elétricos de corrente contínua (CC) foram desenvolvidos junto aos geradores, antes do princípio da reversibilidade desenvolvida por Siemens em 1867 e mostrados por Pacinotti em 1869 e Gramme em 1873 (GUARNIERI, 2011).


Dessa forma, os VEs se tornaram um projeto aplicável na prática, devido a cada um dos experimentos e estudos desenvolvidos ao longo do século XIX (GUARNIERI, 2011). Graças a esses avanços, os motores elétricos e as baterias recarregáveis tornaram-se uma realidade alternativa com grande contribuição para impulsionar os VEs.

3.1 CRESCIMENTO DO MERCADO CONSUMIDOR DE VES

De maneira geral, governos espalhados em todo o mundo estão motivados a buscar alternativas para alcançar objetivos de melhoria do clima, qualidade do ar, entre outras, e para tais objetivos, a diminuição das emissões de combustíveis fósseis tem papel central. Nesse cenário, percebe-se uma tendência global de políticas para acelerar o avanço da adoção de VEs pelas populações e o setor industrial de transportes está passando por grandes mudanças e atualizações na produção de veículos (CUI; HALL; LUTSEY, 2020).


As vendas globais de VEs crescem a cada ano, ultrapassando a casa de milhões. Em 2015 ultrapassaram 1 milhão de vendas, em 2017 cerca de 3 milhões e em 2018 atingiram 5 milhões. Em 2019 as vendas acumuladas passaram a casa de 7 milhões, como mostrados na Figura 1, que ilustra as vendas acumuladas dos VEs até 2019 e suas localizações (EV, 2020).

Dentre os principais mercados consumidores de VEs, EUA e China ultrapassam 1 milhão de vendas, e com esse número são os dois maiores mercados consumidores de VEs no mundo. Os 10 maiores mercados juntos correspondem a mais de 90% das vendas globais acumuladas de VEs até 2019. O crescimento na venda dos VEs de 2010 a 2019 ultrapassou 7 milhões de unidades, e, quando comparado com o período de 2000 a 2009, foi duas vezes mais rápido (CUI; HALL; LUTSEY, 2020).

Figura 1 – Vendas acumuladas de veículos elétricos em 2019 por mercados.

Fonte: (EV, 2020).

Na Figura 2 são mostradas as vendas anuais dos VEs divididas entre os países, nos anos de 2010 a 2019. A taxa média de crescimento anual das vendas de VEs em todo mundo chegou a 50% de 2012 a 2019.

Figura 2 – Vendas anuais de veículos elétricos de passageiros por mercados de 2010 a 2019.

Fonte: (EV, 2020).

3.2 TIPOS DE VEÍCULOS ELÉTRICOS

O termo veículo elétrico pode incluir qualquer veículo movido a energia elétrica, seja carros, motocicletas, bicicletas, patinetes e qualquer outro veículo que utilize motor elétrico. Existem algumas variações na nomenclatura de veículos movidos a energia elétrica ou parcialmente movidos. Atualmente os termos e divisões utilizadas são: veículos elétricos híbridos (VEHs), veículos elétricos híbridos plugáveis (VEHPs), veículos elétricos plugáveis (VEPs) e veículos elétricos totalmente a bateria (VEBs) (ASHIQUE et al., 2016).

Os veículos totalmente elétricos são chamados de VEBs e são movidos por um ou por um conjunto de motores elétricos. Esses veículos carregam suas baterias diretamente na rede elétrica armazenando energia em sua própria estrutura. São veículos que não utilizam combustível à base de petróleo, com 100% de uso elétrico (ASHIQUE et al., 2016).

Para veículos que combinam motores a combustão interna (MCIs) e motores elétricos a bateria o termo utilizado é veículos elétricos híbridos (VEHs). Esses veículos possuem tecnologias que regeneram (carregando) suas baterias devido a transformação de energia usada pela frenagem, ou seja, os motores elétricos fornecem economias de combustíveis. Os VEHs não são veículos que carregam por conexão à rede elétrica, eles dependem do uso exclusivo de combustível alternativos ou de petróleo (ASHIQUE et al., 2016).

Veículos elétricos plugáveis (VEPs) são veículos que usam toda sua energia elétrica ou parte dela, carregadas diretamente à rede elétrica. São veículos que carregam sua bateria conectados exclusivamente a uma tomada. Esse tipo de configuração de veículos inclui os VEBs e os VEHPs (ASHIQUE et al., 2016).

O uso de motores elétricos alimentados por baterias carregados a rede elétrica e motores a combustão interna à base de combustível, são denominados veículos elétricos híbrido plugáveis (VEHPs). Esses tipos de veículos podem ser considerados também veículos elétricos de alcance estendido (VEAEs) (ASHIQUE et al., 2016).

3.3 CARREGAMENTO DOS VES

Para entender o fator chave sobre carregamento de VEs é necessário saber que a demanda energética será voltada em função da voltagem e amperagem da conexão à rede. A capacidade de armazenamento da bateria determinará o tempo que precisa ser carregada e isso dependerá de quanto e como a energia será entregue (HADLEY; W, 2006). Nesse sentido, são necessárias informações e detalhamentos das operações de carregamento dos VEs.

3.3.1 Tipos de carregamento e níveis de energia

Existem dois tipos de carregamentos: os não coordenados (descontrolados) e os coordenados. Um grande número de VEs carregados descontroladamente, pode chegar a ultrapassar o limite de potência elétrica, sobrecarregar os transformadores e aumentar as perdas em suas linhas (RICHARDSON, 2013). As cargas de carregamento dos VEs mal gerenciadas podem gerar alguns impactos negativos nas operações e na confiabilidade da rede e até aumentar o preço das energias (HE et al., 2013). O carregamento coordenado (controlado), demonstra ter vantagens quando comparado ao não coordenado por possuir um valor conhecido aos operadores da rede elétrica (DALLINGER; DEAC; WIETSCHERL, 2013).

3.3.1.1 Carregamento não coordenado (descoordenado)

As cargas do carregamento não coordenado indicam que as baterias dos VEs iniciam a carregar imediatamente quando são conectadas, de forma aleatória, à rede elétrica ou após um atraso de tempo configurado pelo usuário. Esse tipo de carregamento não é muito incentivado atualmente por não conter todas as informações necessárias para um carregamento agendado, o que garante a otimização de VEs carregados a rede elétrica. O atraso do início do carregamento serve para que os usuários dos VEs tenham a possibilidade de carregar as baterias fora de horários de pico (CLEMENT-NYNS; HAESEN; DRIESEN, 2010).

Nesse tipo de carregamento não há informações disponíveis sobre preços de energias, uma vez que o usuário pode decidir, sem nenhum tipo de controle ou estratégia, quando irá conectar seu VE e quando irá desconectar, ou até quando terá carregado a bateria 100% (RICHARDSON, 2013).

3.3.1.2 Carregamento coordenado


O carregamento coordenado é introduzido com o objetivo de direcionar a cobrança do VE, indicando sinais de preços de energia ou incentivando o uso em determinado período, a fim de diminuir os impactos que geram problemas a rede (RICHARDSON, 2013).

No carregamento anterior, as cargas das baterias se iniciam aleatoriamente, começando imediatamente ou com um atraso após a conexão. O carregamento coordenado é considerado ideal a rede elétrica pois minimiza as perdas de energia. A coordenação desse carregamento utiliza um gerenciamento com medições inteligentes que enviam informações individuais ao VEs (CLEMENT-NYNS; HAESEN; DRIESEN, 2010).

Além disso, o carregamento coordenado pode ser realizado com diferentes arquiteturas de comunicação e controle. Os dois principais conceitos de arquitetura de controle são

centralizados e descentralizados. Essas duas categorias fazem referências ao nível em que as decisões de cobranças são tomadas (LOWELL; HUNTINGTON, 2019). Para classificar as duas arquiteturas de coordenação, a Figura 3 fornece uma arquitetura mista básica.

Figura 3 – Classificação de coordenação de carregamento de VEs.



Fonte: Malone (1987) (MALONE, 1988).

A arquitetura de carregamento centralizado se baseia em cargas agendadas. Esses carregamentos muitas vezes dependem de um cronograma de planejamento, que é comunicado a uma programação central, ou assume um controle de carga direto. Esse controle tem objetivo de assegurar que todas as operações sejam seguras e confiáveis a rede elétrica (VAYÁ; ANDERSSON, 2012).

3.3.1.3 Níveis de energia

Os carregadores dos VEs possuem um conector padrão para cada tipo de carregamento e cada padrão é compatível com a infraestrutura disponível. As cargas dos VEs podem ser recarregadas tanto por cabos quanto sem fio.

Os carregadores plugáveis podem fornecer cargas rápidas ou lentas, variando de cada tipo de nível e estrutura diferente. Os VEs também podem ser carregados por indução, ou seja, transferindo energia com um campo eletromagnético sem fio e cabo. Com base em cada classificação de energia, os níveis de energias (Tabela 1) podem ser divididos em nível 1, nível 2 e nível 3 (NREL, 2019).

Tabela 1 – Níveis de potência de carregamento.

Nível de energia	Uso típico	Potência (kW)	Tempo de carregamento (h)
1	Residencial	2	4 – 11
2	Estação/casa	20	1 – 4
3	Carga rápida	100	$\leq 0,5$

Fonte: (NREL, 2019).

O carregamento de nível 1 é utilizado em ambiente residencial (casa) ou em ambiente de trabalho, usando tomadas de 120 volts. No carregamento de nível 2 utilizam-se tomadas de 240 volts, típicas de residências ou também de 208 volts em ambientes comerciais. Carregamentos rápidos (nível 3) usam tomadas de 480 volts, o que permite uma carga rápida e são, geralmente, utilizados em postos de carregamentos públicos. Esse nível de carregamento necessita de um grande fluxo de potência (NREL, 2019).

3.3.2 Localização

O carregamento dos VEs pode ser feito em estações de carregamentos públicas ou privadas e carregamentos residenciais. Porém, observa-se que os padrões de carregamentos em questão de tempo e duração de cargas dependem da localização do carregamento (residencial ou comercial) (KAMRUZZAMAN; BENIDRIS, 2018).

Dessa forma, é importante diferenciar as curvas de carregamentos dos perfis em cada local, sendo estações de carregamentos e carregamento residencial. Por outro lado, a variabilidade do padrão de direção dos veículos pode modificar o consumo de carregamento, devido as diferenças de padrões durante os dias da semana e finais de semana (AEP, 2013).

3.3.2.1 Estação de carregamento para VEs

Uma estação de carregamento fornece energia para VEs que possuem baterias recarregáveis. Entende-se por estação de carregamento uma seção controlada (eletronicamente) de energia elétrica de ação rápida, de maneira que um conector transfere a energia por cabos para os VEs e uma interface com cabos de sinais transporta dados de status. Em particular, estações de carregamento fornecem carregadores de alta potência elétrica, podendo carregar as baterias dos VEs de uma maneira bem rápida, eficiente e segura (NOR, 1993).

A estação de carregamento controla totalmente a transferência de cargas as baterias dos VEs. Os carregamentos são feitos através de diferentes níveis e modos de energias. A Sociedade de Engenheiros Automotivos (SAE) e a Comissão Eletrotécnica Internacional (IEC) padronizou os carregamentos dos VEs para fins de diferenciar os níveis de potência e modos de carregamento. De acordo com essa padronização as duas modalidades de carregamento para VEs são com cabo ou sem fio, para os três níveis de energia (MA, 2019).

3.3.2.2 Carregamento residencial de VEs

A integração maciça de VEs no sistema de energia elétrica, em particular para o sistema de distribuição de energia, apresentará alguns desafios devido ao aumento descontrolado de conexões de VEs carregados nas residências. A carga gerada no carregamento

simultâneo pode levar um grande aumento de pico, criando congestionamento na rede ou problemas de tensão (LéGIFRANCE., 2015).

No carregamento residencial, as cargas dos VEs são conectadas por um longo período de tempo e sua demanda de carga pode coincidir com o pico de demanda residencial do sistema elétrico. A introdução de carregamentos descontrolados residenciais dos VEs pode levar alguns impactos significantes a infraestrutura de distribuição elétrica (LOPES; Soares; Almeida, 2011) ; (SCHROEDER, 2011).


3.4 DEMANDA ENERGÉTICA

As necessidades futuras por eletricidade dos VEs inseridos na rede elétrica irão depender de quando, onde e com que velocidade os veículos serão carregados. De um ponto de vista da demanda total de energia, os níveis reais do consumo de VEs, a curto prazo, geram aumentos significativos na demanda atual da rede. Pode-se tomar como exemplo um VE dirigido por 19312 km por ano, cerca de 53 km por dia. Esse VE requer um consumo de 300 Watts-horas por km. Dessa forma, a necessidade desse VE em um ano é 3600 KWh, ou convertido, 10 KWh por dia (FHWA, 2018).

Nos EUA, como visto na Figura 4, a demanda energética de VEs aumenta 16% ao ano. Com isso, é gerado um aumento no consumo de eletricidade em pelo menos de 10% da geração total. São feitas projeções para 2040 de acordo com a porcentagem de VEs em utilização.

Essa análise feita mostra que esses aumentos na produção do sistema de energia elétrica dos EUA podem fornecer energia para sustentar um possível crescimento significativo na frota de VEs. Um estudo do Laboratório Nacional do Noroeste Pacífico (LNNP) indica que o sistema de rede elétrica atual dos EUA poderia garantir o fornecimento de energia para lidar com 73% dos VEHPs (Veículos Elétricos Híbridos Plugáveis) leves atuais. Esse dado cai para 43% caso os veículos sejam carregados somente durante o período noturno. O laboratório nacional de energia renovável relatou e concluiu que a capacidade existente de geração de energia poderia atender as cargas de carregamento no período noturno dos veículos limitados com um nível de penetração de até 20% nos EUA (KINTNER-MEYER et al., 2010) (DENHOLM; SHORT, 2006).

Na mesma linha de raciocínio, outro relatório demonstrou que a eletrificação completa para VEs de passageiros aumentaria a demanda total de energia em 13% (DULEEP et al., 2011). Os dados mostrados são de estimativas razoáveis quanto aos requisitos de capacidade de geração de energia a longo prazo. É necessário analisar com mais detalhes para compreender como a capacidade de geração elétrica deve ser configurada e ajustada para otimizar o novo cenário gerado pela penetração dos VEs na rede.

Figura 4 – Aumento no consumo de eletricidade nos EUA devido a VEs.

Fonte: (LOWELL; HUNTINGTON, 2019).

Esse novo cenário requer uma análise mais complexa, considerando, por exemplo, custos de atualização da infraestrutura de distribuição, impactos na capacidade de geração de energia já existente e custo da nova capacidade de geração. Fazer um planejamento de confiabilidade regional necessita analisar alguns fatores que geram impacto na rede elétrica, como o número total de VEs, fornecimento de energia em grande escala, comportamento da carga carregadas (tempo de carregamento) e infraestrutura (capacidade de carregamento e distribuição) (LOWELL; HUNTINGTON, 2019).

3.5 IMPACTOS GERADOS PELOS VES AO SISTEMA DE ENERGIA ELÉTRICA

As concessionárias de energia elétrica geralmente representam as demandas dos clientes classe a classe, usando as curvas de cargas com picos de energias em 24 horas (WILLIS, 2004). Cada tipo de curva representa um perfil diferente e a demanda pode ser classificada em residencial, comercial e industrial (SHAFIEE; FOTUHI-FIRUZABAD; RASTEGAR, 2013). Os VEs podem ser considerados como cargas ativas e geram um aumento da demanda durante o carregamento na rede elétrica. Portanto, os impactos gerados pelo VEs são significativos devido à alta capacidade de energia no carregamento e a

implementação em massa de VEs por qual o setor de transportes está passando (PUTRUS et al., 2009).

3.5.1 Impacto do carregamento dos VES agregados a demanda residencial

De um modo geral, o carregamento de VEPs afetará o sistema de energia elétrica de duas formas, a primeira é introduzindo uma carga adicional na demanda residencial. Essas cargas são utilizadas principalmente nas residências quando os VEPs estão parados nas garagens carregando suas baterias, e especialmente no período noturno. Isso gera um impacto na demanda total de energia e adicionará uma nova dificuldade ao gerenciamento da geração, transmissão e distribuição de energia elétrica (MURATORI, 2018).


Em segundo lugar, os VEPs podem serem considerados como uma tecnologia de armazenamento distribuído ou carregamentos flexíveis, que atuam como uma usina virtual. Os carregamentos coordenados dos VEPs à rede apresentam uma saída promissora e, com *smart grids* integradas cria-se uma forma oportunista para facilitar a integração de fontes de energia renováveis não despacháveis (MURATORI, 2018).

3.5.1.1 Impacto do carregamento descontrolado de VEs agregado a demanda residencial


A implantação massiva de novas conexões de VEs na rede de distribuição elétrica pode trazer alguns problemas de operação, como o congestionamento de ramais ou até quedas de tensão (LOPES; Soares; Almeida, 2011). Os sistemas de distribuição são tipicamente projetados para capacidade de tráfego de carga específica com base em perfis dos consumidores. Quando os VEPs são implementados, ou seja, quando os usuários dos VEs usam o sistema elétrico para carregar seus carros, em casas, edifícios e locais comerciais, há uma mudança significativa nos perfis e na demanda de energia elétrica (ROE et al., 2008).

Para apresentar esse impacto gerado pelo carregamento dos VEs, Jairo Quirós-Tortós em 2015, (QUIRÓS-TORTÓS; OCHOA; LEES, 2015) fez uma análise estatística sobre o comportamento de cargas em 221 usuários reais de VEs, carregados em ambiente residencial, com o modelo Nissan LEAF de 3,6 kW. Os dados formaram perfis diários de acordo com os horários de carregamento, durante os dias de semana e fins de semana. As Figuras 5 e 6 mostram as demandas de carregamento com 1 e 2 conexões em 24 horas, para dias da semana e fim de semana, respectivamente.

A diversificação da demanda corresponde à demanda agregada pelo carregamento dos VEs. Para o carregamento dos VEs durante os dias de semana a carga adicional não afetou tanto o pico de carga noturna, porém afetou o pico no período da manhã (QUIRÓS-TORTÓS; OCHOA; LEES, 2015).

Figura 5 – Demanda dos VEs durante um dia da semana.

Fonte: Quirós-Tortós *et. al.* (2015) (QUIRÓS-TORTÓS; OCHOA; LEES, 2015).

Figura 6 – Demanda dos VEs durante um dia no fim de semana.


Fonte: Quirós-Tortós *et. al.* (2015) (QUIRÓS-TORTÓS; OCHOA; LEES, 2015).

Quando são inseridas duas conexões é gerado um efeito significativo no consumo diário, aumentado assim a demanda diária total. Para o consumo diário com uma única conexão, a demanda durante a semana é acrescida, em média, de 13,9 para 17,8 kWh e, com duas conexões aumenta de 13,7 para 16,9 kWh (QUIRÓS-TORTÓS; OCHOA; LEES, 2015). Dessa forma, concluiu-se que as novas adoções de VEs geram um aumento à demanda líquida nas redes elétricas.

As Figuras 7 e 8 mostram dois conjuntos de demandas residenciais diversificadas


de 1000 famílias no Reino Unido no período de um dia para a semana e fim de semana. Esses perfis residenciais foram criados por Richardson, 2010 (RICHARDSON et al., 2010) para mostrar a diversificação da demanda líquida incluindo as cargas residenciais e cargas dos VEs.

Figura 7 – Perfil durante os dias da semana: residencial + VEs.



Fonte: Quirós-Tortós *et. al.* (2015) (QUIRÓS-TORTÓS; OCHOA; LEES, 2015).

Figura 8 – Perfil durante o fim de semana: residencial + VEs.



Fonte: Quirós-Tortós *et. al.* (2015) (QUIRÓS-TORTÓS; OCHOA; LEES, 2015).

Como observado nas Figuras 7 e 8 independentemente do tipo de dia, com pelo menos uma conexão de VE na residência é gerado um aumento de mais de 100% na demanda. Por fim, foi concluído que aproximadamente 70% dos VEs são plugados na

residência pelo menos uma vez por dia, não apresentando grandes diferenças entre semana e fim de semana (QUIRÓS-TORTÓS; OCHOA; LEES, 2015).

3.5.2 Impacto das estações de carregamento de VEs na rede elétrica

As estações de carregamento de VEs, sejam do tipo carregamento doméstico, carregamento comercial ou carregamento público, podem resultar na redistribuição das cargas de energia, causando mudanças na rede e aumento de perda energética (AYOB et al., 2014).

Com o carregamento descontrolado de VEs, o impacto na carga influencia na potência do sistema elétrico, levando a algumas alterações nos parâmetros do processo de transmissão. Este novo tipo de demanda energética está se modificando e cada vez ocorrendo com maior frequência. Esse fenômeno pode causar certas mudanças no sistema, causando perdas no controle de operação, diminuição da integridade na distribuição e o sistema de alimentação perder estabilidade (LIU et al., 2015).

Quando ocorre um acesso de carregamento relativamente grande no sistema, a saída do gerador aumenta, fazendo com que a frequência da rede diminua. A redução na frequência causa uma queda na rotação do gerador e com isso o sistema perderá seu ritmo de funcionamento. Em consequência a essas dinâmicas o sistema pode ser levado a um colapso (LIU et al., 2015).

Os potenciais impactos causados pelo carregamento de VEs vêm sendo investigados por vários autores. No estudo de Geske (2010) (GESKE et al., 2010), é analisado o impacto do carregamento de VEs em estação de carregamento em uma rede elétrica de baixa tensão para vários cenários de penetração de veículos. O autor concluiu que a rede suportaria uma pequena demanda de apenas 2% de conexões dos VEs.

Já Dharmakeerthi *et. al* (2016) (DHARMAKEERTHI; MITHULANANTHAN; SAHA, 2014) e Zhang *et. al* (2016) (ZHANG et al., 2016) mostraram o impacto das cargas de carregamentos na instabilidade da distribuição da rede elétrica. Foi observado que a maioria dos sistemas de distribuição não conseguem suportar um grande número de penetração de VEs na rede, suportam somente até um certo nível de conexões. Uma conclusão importante foi que as redes atuais existentes não foram projetadas e não tem capacidade de suportar uma integração de VEs em grande escala conectados ao mesmo tempo.

Gomez e Morcos (2003) (GOMEZ; MORCOS, 2003) observaram que o ciclo de vida da rede de distribuição foi reduzido devido a distorção harmônica causada pelas cargas adicionais dos VEs. No estudo de Basu *et. al* (2004) (BASU; GAUGHAN; COYLE, 2004) os autores relatam que as cargas de carregamento dos VEs causam distorção harmônica

podendo chegar até 50% nos casos mais caóticos.

No estudo de Jiang *et. al.* (2014) (JIANG et al., 2014) os autores simulam os harmônicos causados pelas conexões residenciais de VEHPs usando métodos probabilísticos de Monte Carlo. Concluiu-se que os veículos carregados nas residências de nível 1 geram um grande impacto na qualidade de energia.

Recentemente os pesquisadores tem analisado e quantificado a variação da demanda de pico após o uso de estações de carregamento de VEPs na rede de distribuição. McCarthy (2010) (MCCARTHY; WOLFS, 2010) examinou os efeitos causados pelos VEHPs na rede de distribuição da Austrália. Foi observado que com carregamento descoordenado com penetração de 100% dos VEs foi necessário fazer o deslocamento de carga de pico em 43% para garantir o bom funcionamento da rede elétrica. Com isso os autores concluíram que a demanda descoordenada pelos carregamentos dos VEs aumentaria consideravelmente o pico da demanda (FAN et al., 2013).

4 PREVISÃO DE CARGAS ELÉTRICAS


Para garantir um sistema de geração de energia elétrica confiável deve ser feito um planejamento para atender a demanda de carga estimada e diminuir gastos gerados por desperdícios. O planejamento do sistema requer estimativas realistas para a demanda futura. A previsão de carga baseia-se na projeção de uma maneira inteligente com padrões do passado e presente, que determinam a carga futura. Deve ser feita uma avaliação com precisão e cautela para garantir que nenhuma previsão seja feita superestimando a demanda das cargas, o que poderá trazer perdas no capital investido, ou no caso contrário, subestimar a demanda poderá causar falta do fornecimento de energia. Com isso, prever a carga para um valor um pouco maior do que o esperado faz com que o sistema planejado seja mais confiável (MEHTA et al., 2007).

A previsão de carga elétrica em um sistema com prazos variados possui vantagens do ponto de vista econômico. As cargas previstas podem ser usadas para auxiliar a otimização de energia entre concessionárias, diminuindo os custos. As previsões também possuem um papel de influenciar de maneira significativa as tomadas de decisões operacionais importantes, como o despacho, programação de manutenção e comprometimento da unidade. Por esses motivos, esforços no desenvolvimento de técnicas precisas de previsões de cargas são considerados como investimento (EL-SHARKAWI; MARKS; WEERASOORIYA, 1991).


Há vários anos as técnicas de previsão de carga vêm sendo usadas no sistema elétrico de potência. As previsões de cargas a curto prazo, de alguns minutos, horas ou vários dias, ajudam o operador do sistema com a programação de alocação da reserva de energia com mais eficiência. Além da razão econômica, a previsão de carga é útil para a segurança do sistema e pode fornecer informações valiosas para detectar situações de vulnerabilidade com antecedência (PARK et al., 1991).

As abordagens citadas anteriormente geralmente são classificadas em duas categorias, de acordo com as técnicas usadas. A abordagem que trata o padrão de carga como um sinal de série temporal e faz previsão da carga futura pode ser chamada de técnica de análise de séries temporais (Toyoda; Chen; Inoue, 1970)(MEHRA, 1970). Uma segunda abordagem trata em reconhecer que o padrão de carga é dependente de variáveis exógenas, como dados meteorológicos, que encontram uma relação entre as variáveis meteorológicas e as cargas elétricas do sistema. Com isso, a previsão é feita devido as informações meteorológicas inseridas (GUPTA; YAMADA, 1972) (JABBOUR et al., 1988).

As demandas elétricas acumuladas em várias escalas de tempo apresentam certas características diferentes para o modelo de séries temporais. Para diferenciar os tipos de escalas de tempo, as Figuras 9, 10 e 11 mostram as demandas acumuladas baseados nos horários, semanais e anuais (RINGWOOD; BOFELLI; MURRAY, 2001).


Figura 9 – Demanda horária.

Fonte: Ringwood (2001) (RINGWOOD; BOFELLI; MURRAY, 2001).

Figura 10 – Demandas semanais.

Fonte: Ringwood (2001) (RINGWOOD; BOFELLI; MURRAY, 2001).

Em particular, observe que as variações detalhadas no perfil diário se perdem à medida que a demanda vai acumulando até o nível semanal. E as variações sazonais são perdidas posteriormente devido a acumulação em nível anual (RINGWOOD; BOFELLI; MURRAY, 2001).

Figura 11 – Demandas anuais.

Fonte: Ringwood (2001) (RINGWOOD; BOFELLI; MURRAY, 2001).


4.1 PADRÃO DE COMPORTAMENTO DAS CARGAS ELÉTRICAS

As abordagens de séries temporais se baseiam no entendimento de que o padrão da carga elétrica é um sinal temporal com dados periódicos sazonais, semanais, diários e horários conhecidos. Os dados periódicos fornecem uma previsão com resultados mais próximos da carga de um determinado período, dia da semana e hora do dia. Há uma diferença entre o resultado de previsão e os dados reais das cargas, que podem ser considerados como estocásticas. Analisando esses sinais aleatórios, podemos chegar em previsões mais precisas (PARK et al., 1991).

As técnicas que abordam as séries temporais possuem várias aplicações e funcionalidades, porém, quando acontecem mudanças bruscas nas variáveis ambientais ou sociológicas o padrão da carga elétrica pode ser afetado diretamente. Caso essas mudanças ocorram, podem dificultar o processo da técnica de série temporal.

Pode-se descrever o comportamento de uma carga elétrica no tempo através de duas classes de séries temporais, com objetivo de determinar o seu perfil de comportamento. Na Figura 12 são mostrados os dois tipos de evolução da carga ao longo do tempo, por meio de duas séries temporais (O'DONOVAN, 1983).

Uma série temporal do tipo estacionária pode ser entendida como perfis de cargas que apresentam flutuações e não apresentam perfis periódicos ao longo do tempo. No gráfico a esquerda da Figura 12, as curvas mostram como as cargas estacionárias se comportam no tempo.

Figura 12 – Séries temporais: não estacionárias e estacionárias.

Fonte: Autoria própria.

Já no perfil não estacionário as cargas se comportam com variações ao longo do tempo, apresentando comportamentos cíclicas e com tendências. Esse perfil mostrado na Figura 12 na curva da direita, por exemplo, apresenta uma série temporal mais periódica com poucas cargas aleatórias. Essas cargas são denominadas cargas não estacionárias.

4.2 FATORES QUE INFLUENCIAM AS CARGAS ELÉTRICAS

As cargas elétricas de uma concessionária possuem diferentes tipos de consumidores. O principal consumidor, geralmente, são atividades industriais. Outra parte é consumida por residências particulares, para iluminação, máquinas elétricas, entre outras. Também são exigidas por uma demanda da sociedade, como serviços de iluminação pública e tráfego (MURTO; HäMäLäINEN, 1998).

As cargas elétricas são afetadas de formas diferentes de acordo com as unidades de consumo. As cargas no setor industrial costumam ser estáveis, porém, do ponto de vista das concessionárias, as indústrias costumam agregar incertezas nas projeções. O grande problema desse cenário é gerar possíveis eventos inesperados, que causam grandes distúrbios no nível de carga (MURTO; HäMäLäINEN, 1998).

Nos cenários residenciais os fatores que determinam as cargas são mais difíceis de analisar. Cada usuário tem um comportamento específico e individual e esse comportamento representa seu perfil de consumo. Muitos fatores sociais e comportamentais podem influenciar as cargas elétricas, como eventos de grande escala, feriados prolongados e até eventos televisionados (GROSS; GALIANA, 1987)(KARANTA; RUUSUNEN, 1990)(KWANG-HO et al., 1995).

Os fatores mais importantes que podem ser levados em considerações são (GROSS;

GALIANA, 1987):

- A curto prazo: fatores climáticos e meteorológicos causam grandes variações na carga agregada, como temperatura, velocidade do vento, nuvens cobertas e umidade (CHOW; LEUNG, 1996)(KALLIO, 1985)(KHOTANZAD et al., 1996);
- A longo prazo: fatores econômicos e demográficos (MURTO; HÄMÄLÄINEN, 1998).

De um ponto de vista da previsão, os fatores temporais são os mais essenciais. Eles possuem vários efeitos sazonais e comportamentos cíclicos, como ritmos diários e semanais, bem como ocorrências de feriados (MURTO; HÄMÄLÄINEN, 1998).

Outros fatores podem influenciar, causando distúrbios que podem ser classificados como fatores de caráter aleatório que, geralmente, são insignificantes no caso de consumidores individuais, embora grandes eventos podem influenciar. As indústrias, por outro lado, podem causar alguns distúrbios de grande escala (MURTO; HÄMÄLÄINEN, 1998).

4.3 CLASSIFICAÇÃO DAS PREVISÕES DE CARGAS ELÉTRICAS

A previsão de carga com prazos de entrega de algumas horas a vários meses auxilia o operador do sistema a agendar a alocação de energia com eficiência. As previsões podem ser divididas em 4 tipos (METAXIOTIS et al., 2003):

- Curtíssimo prazo: previsões que ocorrem até 15 minutos;
- Curto prazo: previsões que ocorrem no intervalo de tempo de 30 minutos a poucas horas, podendo chegar a 1 dia ou até 1 semana;
- Médio prazo: previsões que ocorrem no período de poucas semanas podendo chegar a alguns anos;
- Longo prazo: realizada em período de alguns meses, podendo chegar a muitos anos.

4.4 CARACTERÍSTICAS E DIFICULDADES NA PREVISÃO DE CARGAS EM VEÍCULOS ELÉTRICOS

A previsão de cargas a curto prazo tornou-se uma ferramenta muito importante para o controle inteligente de sistemas de carregamento em VEs. Porém, essa previsão não é uma tarefa fácil, devem ser levados em considerações alguns aspectos como o conhecimento profundo do perfil de usuário e o seu consumo apresentado.

Há vários modos de carregamento, cobranças e gerenciamentos de veículos elétricos. Para analisar as demandas de diferentes modos de carregamento é necessário fazer estudos e desenvolver métodos para previsão de acordo com o cenário proposto.

As cargas de carregamentos dos VEs possuem características diferentes das cargas convencionais. Esses carregamentos possuem características de distribuição espacial e temporal. O carregamento exerce uma alta demanda devido suas características altamente periódicas e flutuantes. As curvas de cargas dos VEs geram vários picos de energia, especialmente em um intervalo pequeno de tempo (ZHU et al., 2019b).

A maneira tradicional de previsão é por meio de dados históricos de cargas elétricas, dessa forma, elas desempenham um papel diretamente decisivo na previsão de cargas. Mas as previsões com VEs envolvem muitas incertezas por se tratar de um novo tipo de carga, com as características já descritas. Seus perfis de cargas possuem regras de crescimento e características ainda pouco exploradas e que necessitam de muitos estudos (CHUNLIN et al., 2012).


Como principais dificuldades na previsão da demanda de carregamento para VEs podemos citar (CHUNLIN et al., 2012):

1. A falta de dados históricos para executar projeções da carga futura;
2. Descrever as características de distribuição espacial e temporal das cargas dos VEs: representação em escalas multi-temporais e espaciais e se deslocando em diferentes escalas;
3. Modos e gerenciamento de carregamento: os VEs carregam suas baterias em ambientes diferentes, com isso, cada modo de carregamento representa um perfil distinto de demanda energética;
4. Como existe uma diferença nos números de penetrações de VEs em cada região, essa característica também é acrescentada as dificuldades, uma vez que a taxa de VEs plugados determina o quanto o sistema pode suportar e atender as necessidades de entrega de carga;
5. O crescimento descontrolado de carregamento dos VEs e surgimento de picos de consumo.

5 REDES NEURAIS ARTIFICIAIS E TREINAMENTO

O modelo de um neurônio artificial surgiu baseado no neurônio biológico humano. O neurônio pode ser visto como um conjunto de processamentos em paralelo de informações que são fundamentais para o funcionamento de uma rede neural (HAYKIN, 1999). O neurônio artificial é a unidade básica fundamental de uma RNA e sua estrutura pode ser observada na Figura 13.

Figura 13 – Modelo de um neurônio artificial.



Fonte: Adaptado de (HAYKIN, 1999).

A estrutura do neurônio da RNA é composta por 3 elementos básicos (HAYKIN, 1999):

- Um conjunto de sinapses caracterizadas por um peso. Dado sinal x_j , na entrada da sinapse j ligada ao neurônio k , será multiplicado pelo peso sináptico w_{kj} ;
- Uma combinação linear das entradas e dos pesos entra em uma componente somatória e, se a soma ponderada das entradas for maior que o peso *bias* o neurônio é ativado e provoca um sinal de saída.
- Uma função de ativação é dada para delimitar a amplitude da saída de um neurônio, limitando o seu intervalo permitido ao sinal de saída a um valor finito. Geralmente, limitando entre $[0, 1]$ ou $[-1, 1]$, para fins de normalização.

O neurônio artificial (Figura 13) possui também um *bias*, dado por b_k , um parâmetro externo do neurônio artificial k . Ele tem a função de aumentar ou diminuir a entrada da

função de ativação, dependendo se o sinal for positivo ou negativo. A descrição matemática de um neurônio artificial é apresentada em (1) e (2):

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

$$y_k = F(s)(u_k + b_k) \quad (2)$$

sendo:

- $[x_1, x_2, \dots, x_m]$: sinais de entrada;
- $[w_{k1}, w_{k2}, \dots, w_{km}]$: pesos sinápticos do neurônio k ;
- u_k : saída linear do neurônio k ;
- b_k : *bias*;
- $F(s)$: função de ativação;
- y_k : sinal de saída não linear do neurônio k .


A função de ativação, ou função de transferência, define o tipo da saída de um neurônio. Pode-se citar como funções de ativações básicas: função do tipo relé, função semi-linear e função sigmoide (KROSE; SMAGT; SMAGT, 1993), mostradas na Figura 14. A função sigmoide pode ser dividida em função do tipo tangente hiperbólica, chamada de sigmoide 1 (*tansig*) 3 e logística sigmoide 2 (*logsig*) 4, apresentadas graficamente na Figura 15:

$$f(x) = \frac{(1 - e^{-\lambda x})}{(1 + e^{-\lambda x})} \quad (3)$$


$$f(x) = \frac{1}{(1 + e^{-\lambda x})} \quad (4)$$

sendo:

- λ : inclinação da curva.

Figura 14 – Tipos de funções de ativação.

Fonte: Adaptado de (KROSE; SMAGT; SMAGT, 1993).

Figura 15 – Função sigmoide 1 e sigmoide 2.

Fonte: Autoria própria.

5.1 ESTRUTURA DA REDE NEURAL ARTIFICIAL

Uma RNA pode ser entendida como um processador distribuído em paralelo, composto por unidades de processamento mais simples (os neurônios) que, por meio das conexões entre si, enviam sinais entre as camadas e armazenam conhecimento experimental (HAYKIN, 1999). Os dois tipos mais básicos de estruturas de RNA são:

- Redes *feedforward* ou não recorrentes: As conexões se estendem de saídas de unidades a entradas de unidades das camadas anteriores para as camadas atuais. Nenhuma camada contém laços de realimentação (KROSE; SMAGT; SMAGT, 1993).
- Recorrentes: Contém laços de realimentação entre a camada de saída voltando para camada de entrada ou para as camadas anteriores (HAYKIN, 1999).

5.1.1 Redes neurais *feedforward* de multicamadas


Uma rede do tipo *feedforward* de multicamadas possui uma estrutura totalmente conectadas em camadas. O neurônio em qualquer camada da rede é sempre conectado a todos os demais neurônios da camada anterior. Com isso, o sentido do fluxo de sinal através da rede se prolonga para frente, como uma progressão (*feedforward*), vinda da

esquerda para direita se propagando em camadas (HAYKIN, 1999)(KROSE; SMAGT; SMAGT, 1993).

As redes do tipo *feedforward* multicamadas são restritas de não possuir a propriedade de realimentação (*feedback*, ou seja, não possui laços realimentados). De uma maneira em geral, a rede *feedforward* multicamadas adiciona os valores sucessivos às entradas e a todos os neurônios das seguintes camadas ocultas e de saída garantindo que os neurônios recebam apenas as conexões de entradas (HAYKIN, 1999).

Um exemplo de uma rede feedforward multicamadas é mostrada na Figura 16.

Figura 16 – Estrutura *feedforward* multicamadas.



Fonte: Autoria própria.

em que:

- x_d : neurônios de entrada;
- z_m : neurônios da camada oculta (escondida);
- y_c : neurônios de saída;
- x_0 : *bias* da camada de entrada;
- z_0 : *bias* da camada oculta.

Note que as camadas que não são chamadas como camadas de saída são chamadas de camadas ocultas (escondidas). Nessa estrutura de rede existem entradas d , neurônios

m (ocultos) e saídas c . A saída da camada oculta j -ésima é obtida pela combinação linear ponderada dos valores de entrada d , e com a adição do *bias* formando a seguinte equação:

$$a_j = \sum_{i=1}^d w_{ji}^{(1)} + w_{j0}^{(1)} \quad (5)$$

em que $w_{ji}^{(1)}$ se encontra os pesos na primeira camada, indo da entrada i para a camada oculta j , e $w_{j0}^{(1)}$ indica a tendência para a camada escondida j , mostrado na Figura 16 os termos de tendência para as camadas ocultas, através da inclusão do termo bias na camada de entrada, cujo valor é fixado em $x_0 = 1$. Dessa forma podemos reescrever a equação 5 na seguinte maneira:

$$a_j = \sum_{i=0}^d w_{ji}^{(1)} x_i \quad (6)$$

A ativação da camada oculta j será obtido pela transformação da somatória linear em 6, por meio de uma função de ativação $g(s)$ resultando em:

$$z_j = g(a_j) \quad (7)$$

As saídas da rede são obtidas através da transformação das ativações das camadas ocultas por meio de uma segunda camada de elementos de processamento. Com isso, para cada neurônio de saída k , é construído uma combinação linear das saídas das camadas ocultas expressa na seguinte forma:

$$a_k = \sum_{j=1}^m w_{kj}^{(2)} + w_{k0}^{(2)} \quad (8)$$

Novamente, podemos absorver o *bias* nos pesos para chegar em:

$$a_k = \sum_{j=0}^m w_{kj}^{(2)} z_j \quad (9)$$

Que podem ser representados esquematicamente pela inclusão de uma camada escondida adicional com ativação $z_0 = 1$, como mostrado na Figura 16. A ativação da k -ésima neurônio de saída é obtida pela transformação dessa combinação linear usando uma função não linear, com isso, obtemos a seguinte equação:

$$y_k = \tilde{g}(a_k) \quad (10)$$

Foi utilizada a notação $\tilde{g}(s)$ para a função de ativação dos neurônios de saída para enfatizar que não precisa ser a mesma função utilizada para as camadas ocultas. A

combinação das equações 6, 7, 9 e 10, obtém-se uma expressão explícita para a função que foi representada pela rede na Figura 16, equacionada da seguinte forma:

$$y_k = g\left(\sum_{j=0}^m w_{kj}^{(2)} g + \left(\sum_{i=0}^d w_{ji}^{(1)} x_i\right)\right) \quad (11)$$


Assim, a saída do neurônio k é obtida de uma soma ponderada linear com uma função de ativação não linear para chegar em:

$$z_k = g\left(\sum_{j=0}^m w_{kj} x_j\right) \quad (12)$$

Onde a somatória se estende ao longo de todas as entradas e neurônios que enviam as conexões para o neurônio k (com o bias incluído na soma). Dado um conjunto de valores de entrada da rede, o uso seguinte equação 12 garante que sejam avaliadas as ativações dos demais neurônios da rede incluindo os neurônios de saída. Esse processo pode ser considerado como uma propagação para frente (*feedforward*) dos sinais através da rede (HAYKIN, 1999).

Com isso, podemos representar o fluxo de propagação de um sinal da rede *feedforward* na seguinte forma (Figura 17):

Figura 17 – Fluxo *feedforward* (direção).



Fonte: Autoria própria.


A rede *feedforward* de multicamadas possui três características essenciais:

- Cada neurônio da rede possui uma função de ativação não linear, geralmente utilizada por funções com não linearidade do tipo sigmoide 1 e sigmoide 2. Que satisfazem essa exigência (HAYKIN, 1999);
- A estrutura da rede contém uma ou mais camadas ocultas (escondidas), que não fazem parte da entrada ou saída. Com isso, essa estrutura proporciona uma capacidade da rede aprender com padrões mais complexos, extraíndo as características mais pertinentes dos sinais de entrada da rede (HAYKIN, 1999);
- arquitetura da rede possui um alto grau de conectividade, que é determinado através das sinapses da rede. Quando se modifica a conectividade da rede, gera uma mudança nas amostras das conexões sináptica ou dos seus pesos (HAYKIN, 1999).

Além da rede possuir um sentido do fluxo de sinal propagado para frente, ela possui também um sinal de erro que se apresenta no sentido inverso ao sentido *feedforward*. Com isso, o sinal do erro se inicia em um neurônio de saída da rede se propagando para trás, camada por camada pela rede, chamado de retropropagação (*backpropagation*) (HAYKIN, 1999).

O sinal de erro pode ser expresso conforme a seguinte figura:

Figura 18 – Erro retropropagado.



Fonte: Autoria própria.

Para cada neurônio oculto ou saída de um sinal *feedforward* de multicamadas, se projeta a realização de dois cálculos:

- Calcular o sinal feedforward que se encontra na saída de um neurônio, expressado por uma função não linear vinda do sinal de entrada e dos pesos sináptico referente a aquele neurônio (HAYKIN, 1999);
- Cálculo estimável do vetor gradiente, da superfície de erro relacionado aos pesos interligados às entradas de um neurônio, com isso, esse processo é fundamental para a retropropagação através da rede (HAYKIN, 1999).

Minsky e Papert (1969) mostraram que uma rede *feedforward* com duas camadas pode resolver vários problemas (MINSKY; PAPERT, 1969). Werbos (1974) (WERBOS, 1974) apresenta uma solução inicial do algoritmo *backpropagation*, que ajusta os pesos das camadas de entrada para as camadas ocultas. Mas só em 1986 Rumelhart, Hinton e Williams propuseram o ajuste dos pesos de uma RNA nas camadas de entrada para as camadas de saída, propagando o erro no sentido inverso da camada de saída, chamando de *backpropagation* (RUMELHART; GEOFFREY; WILLIAMS, 1986).

5.2 TREINAMENTO DE UMA REDE NEURAL ARTIFICIAL

A característica mais importante de uma rede neural é sua capacidade de aprender a partir de informações previamente apresentadas, podendo, inclusive, melhorar as informações através de um processo de aprendizagem realizado através do ajuste dos pesos (HAYKIN, 1999). Este ajuste de pesos pode ser chamado de treinamento. Pode-se classificar o treinamento de uma RNA em três tipos:

- Treinamento supervisionado: consiste em inserir padrões de entradas e saídas a rede. Assim, é necessário um professor externo para fornecer informações (KROSE; SMAGT; SMAGT, 1993);
- Treinamento não-supervisionado: não possui um professor externo. Consiste na aprendizagem estatisticamente individual da rede de acordo com estímulos da entrada (KROSE; SMAGT; SMAGT, 1993);
- Treinamento híbrido: É a alternância entres os treinamentos supervisionado e não supervisionado.

5.2.1 Treinamento com regularização bayesiana

No período do treinamento de uma RNA o principal objetivo é gerar uma performance que produzirá um baixo erro de aprendizado, e, principalmente, que esse aprendizado

seja capaz de representar uma resposta adequada a novos dados de treinamento. Se isso ocorre podemos dizer que a rede tem uma boa capacidade de generalização de dados.

Um dos métodos considerados eficientes no processo de aperfeiçoar a generalização de um treinamento de uma rede é a regularização, um método que se baseia na restrição dos valores dos pesos da RNA procurando minimizar sua função de desempenho. Essa regularização tem como objetivo manter os pesos com valores pequenos, o que possibilita uma saída mais suavizada para a rede (MACKAY, 1992).

Nesse sentido, a regularização bayesiana proposta por MacKay (1992) tem como objetivo evitar os *overfittings* (sobreajustes) de treinamento e melhoria na capacidade de generalização da RNA. Esse treinamento acrescenta um novo termo no processo de otimização, um termo que penaliza a função objetivo com o acréscimo do número de coeficientes, com isso, permite que o número de neurônios das camadas ocultas se redefina automaticamente durante o treinamento (MACKAY, 1992).

A regularização bayesiana apresenta algumas características importantes:

- Não necessita de um conjunto de validação, pois os dados de treinamento podem ser dedicados ao ajuste e à comparação do modelo;
- Os parâmetros de regularização podem ser otimizados on-line, ou seja, simultaneamente com a otimização dos parâmetros do modelo comum;
- A função objetivo do modelo bayesiano não possui ruídos.
- A possibilidade de otimização de vários parâmetros de controle simultaneamente.

5.2.1.1 Algoritmo de regularização bayesiana

Na regularização bayesiana (MACKAY, 1992) a função objetivo F é modificada, utilizando geralmente a somatória dos erros quadráticos médios E_D (equação 13):

$$F = E_D = \frac{1}{n} \sum_{i=1}^n (e_i)^2 \quad (13)$$

Na sequência a função objetivo é acrescida pelo termo adicional E_w , que é a soma dos erros quadrados da rede (pesos) e (*bias*) (equação 14):

$$F = \beta E_D + \alpha E_w \quad (14)$$

em que α e β são os parâmetros de regularização da função objetivo e E_w é dado pela equação 15:

$$E_w = \frac{1}{n} \sum_{j=0}^n (w_j)^2 \quad (15)$$

O tamanho ou magnitude relativo aos parâmetros da função objetivo controlam a ênfase para o treinamento. Se $\alpha \ll \beta$ o algoritmo de treinamento focará em minimizar os erros dos dados treinados. E se $\alpha \gg \beta$, o treinamento enfatizará em minimizar os valores dos pesos gerados pelos erros da rede, produzindo uma resposta de saída da rede mais suavizada.

O desafio principal do método de regularização bayesiana é como definir quais são os melhores valores de parâmetros da função objetivo. No método bayesiano, os pesos são tratados como variáveis aleatórias. Na sequência da obtenção dos dados de treinamento, a função de densidade dos pesos é atualizada pelo teorema de *Bayes* (16):

$$P(W|D, \alpha, \beta, M) = \frac{P(D|W, \beta, M)P(W|\alpha, M)}{P(D|\alpha, \beta, M)} \quad (16)$$

em que:

- D representa o conjunto de treinamento;
- M é o modelo de rede usada;
- W é o vetor de pesos;
- $P(W|\alpha, M)$ é a densidade anterior, representando o conhecimento dos pesos antes de qualquer dado ser coletado;
- $P(D|W, \beta, M)$ é a função verossimilhança, que é a probabilidade de dado evento ocorrer, dados os pesos W ;
- $P(D, \alpha, \beta, M)$ é o fator de normalização, o que garante que a probabilidade total é 1.

Se assumirmos que o ruído no conjunto de treinamento é do tipo *Gaussiano* e a sua distribuição anterior para os pesos é *Gaussiana*, então podem ser escritas as densidades de probabilidade (equação 17) na seguinte forma:

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

$$P(W|\alpha, M) = \frac{1}{Z_W^\alpha} e^{(-\alpha E_W)} \quad (17)$$

em que:

- $Z_D^\beta = (\frac{\pi}{\beta})^{n/2}$;
- $Z_W^\alpha = (\frac{\pi}{\alpha})^{N/2}$

Substituindo essas probabilidades na equação 16 se obtém (18):

$$\begin{aligned} P(W|D, \alpha, \beta, M) &= \frac{\frac{1}{Z_W^\alpha} \frac{1}{Z_D^\beta} e^{-(\beta E_D + \alpha E_W)}}{\text{Fator de normalização}} \\ &= \left(\frac{1}{Z_F(\alpha, \beta)} e^{-F(W)} \right) \end{aligned} \quad (18)$$

Nessa etapa bayesiana os pesos ótimos maximizam a probabilidade posterior $P(W|D, \alpha, \beta, M)$. Maximizar a probabilidade posterior equivale a minimizar a função objetivo regularizada $F = \beta E_D + \alpha E_W$.

5.2.1.2 Otimização dos parâmetros de regularização

Esta etapa demonstra a aplicação do teorema de Bayes para otimizar os parâmetros da função objetivo α e β (equação 19):

$$P(\alpha, \beta|D, M) = \frac{P(D|\alpha, \beta, M)P(\alpha, \beta|M)}{P(D|M)} \quad (19)$$

Assumindo a densidade anterior uniforme $P(\alpha, \beta|M)$ para os parâmetros de regularização α e β , então maximizar a posterior é possível maximizando sua função verossimilhança $P(D|\alpha, \beta, M)$. Com isso, é observado que essa função de verossimilhança é o fator de normalização para a equação 16. Uma vez que todas as probabilidades possuem uma forma Gaussiana, conhecemos a forma para a densidade posterior dado equação 16. Foi demonstrado na equação 18 e podemos resolver a equação 16 para o fator de normalização (equação 20):

$$\begin{aligned} P(D|\alpha, \beta, M) &= \frac{P(D|W, \beta, M)P(W|\alpha, M)}{P(W|D, \alpha, \beta, M)} \\ &= \frac{\left(\left[\frac{1}{Z_D^{(\beta)}} e^{-(\beta E_D)} \right] \left[\frac{1}{Z_W^{(\alpha)}} e^{-(\alpha E_W)} \right] \right)}{\frac{1}{Z_F^{(\alpha, \beta)}} e^{-(\alpha E_W)}} \end{aligned}$$

$$= \frac{Z_F^{(\alpha,\beta)}}{Z_D^{(\beta)} Z_W^{(\alpha)}} \frac{e^{(-\beta E_D - \alpha E_W)}}{e^{(-FW)}} = \frac{Z_F^{(\alpha,\beta)}}{Z_D^{(\beta)} Z_W^{(\alpha)}} \quad (20)$$

Note que são conhecidas as constantes $Z_D^{(\beta)}$ e $Z_W^{(\alpha)}$ encontradas na equação 17. A única constante desconhecida é $Z_F^{(\alpha,\beta)}$. Pode-se estimá-la pela expansão da série de Taylor. Podemos expandir $F(W)$ em torno do ponto mínimo da densidade posterior W^{MP} , onde o gradiente é zero. Resolvendo para os rendimentos das constantes de normalização:

$$Z_F \approx (2\pi)^{\frac{N}{2}} (\det((H^{MP})^{-1}))^{\frac{1}{2}} e^{(-F(W^{MP}))} \quad (21)$$

em que $H = \beta \nabla^2 E_D + \alpha \nabla^2 E_W$ é uma matriz Hessiana da função objetivo.

Com o resultado da equação 20 podemos resolver os valores ótimos para α e β no ponto mínimo. Tomando a derivada em relação a cada um dos $\log$ da equação 20 e definindo-os iguais a zero, resultará em:

$$\begin{aligned} \alpha^{MP} &= \frac{\gamma}{2E_W(W^{MP})} \\ \beta^{MP} &= \frac{n - \gamma}{2E_D(W^{MP})} \end{aligned} \quad (22)$$

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

5.2.1.3 Aproximação de Gauss-Newton para a matriz Hessiana

O método de otimização bayesiana dos parâmetros de regularização requer o cálculo da matriz Hessiana de $F(W)$ no ponto mínimo W^{MP} . A aproximação de Gauss-Newton para a matriz Hessiana está prontamente disponível se o algoritmo de otimização de Levenberg-Marquardt for usado para encontrar o ponto mínimo. O cálculo adicional necessário para a otimização da regularização é mínimo (FORESEE; HAGAN, 1997).

Podemos simplificar em 5 etapas necessárias para a otimização bayesiana dos parâmetros de regularização, com a aproximação de Gauss-Newton para a matriz H:

1. Inicialização de α , β e os pesos. É escolhido $\alpha = 0$, $\beta = 1$ e usado o método Nguyem-Widrow para se inicializar os pesos (NGUYEN; WIDROW, 1990). Após a primeira etapa de treinamento os parâmetros da função objetivo serão recuperados da configuração inicial;

2. Execução de uma etapa do algoritmo de Levenberg-Marquardt para minimizar a função objetivo $F(W) = \beta E_D + \alpha E_W$;
3. Cálculo do número efetivo de parâmetros $\gamma = N - 2\alpha \text{tr}(H)^{-1}$ usando a aproximação de Gauss-Newton para a matriz H disponível no algoritmo de treinamento de Levenberg-Marquardt $H = \nabla^2 F(W) \approx 2\beta J^T J + 2\alpha I_N$, sendo J a matriz Jacobiana dos erros do conjunto de treinamento (FORESEE; HAGAN, 1997);
4. Cálculo de novas estimativas para os parâmetros da função objetivo $\alpha = \frac{\gamma}{2E_W(W)}$ e $\beta = \frac{n-\gamma}{2E_D(W)}$;
5. Execução das etapas 2 e 4 até a convergência.

5.3 PARÂMETROS DE TREINAMENTO

O treinamento foi feito de acordo com os parâmetros padrões do algoritmo de treinamento de regularização bayesiana do software MATLAB[®] R2015 (*toolboxes*). Os parâmetros e valores são apresentados na Tabela 2.

O valor máximo de falhas de validação recebe o parâmetro infinito por padrão, pois ele garante que o treinamento ocorra até que a combinação ideal dos erros e pesos seja encontrada. A função de otimização usa o Jacobiano para os cálculos, cujo desempenho é a soma dos erros quadráticos. Então este treinamento usa como função de desempenho o Erro Quadrático Médio (MSE).

A regularização bayesiana ocorre dentro do algoritmo de Levenberg-Marquardt. O erro de retropropagação conhecido como *backpropagation* é utilizado para calcular o Jacobiano de desempenho em relação às variáveis de peso e a polarização X (RUMELHART; GEOFFREY; WILLIAMS, 1986). Cada variável é ajustada conforme o algoritmo de Levenberg-Marquardt, descrito na equação 23:

$$\begin{aligned}
 jj &= jXjX \\
 je &= jXE \\
 dx &= \frac{-(jj + Im\mu)}{je}
 \end{aligned} \tag{23}$$

em que:

- E : todos os erros;
- I : matriz de identidade;

- $m\mu$: parâmetro de *Marquardt*.

Tabela 2 – Parâmetros de treinamento.

Parâmetros	Valores
Parâmetro de regularização α	0
Parâmetro de regularização β	1
Números máximo de épocas para treinar	1000
Objetivo de desempenho	0
Função de desempenho	MSE
Parâmetro de <i>Marquardt</i> inicial (μ)	5×10^{-3}
Fator de decrescimento do parâmetro de <i>Marquardt</i> (μ)	1×10^{-1}
Fator de crescimento do parâmetro de <i>Marquardt</i> (μ)	10
Máximo valor do parâmetro de <i>Marquardt</i> (μ)	1×10^{10}
Máximo valor de falhas de validação	∞
Valor mínimo do gradiente de desempenho	1×10^{-7}
Limite de tempo de treinamento	∞

Fonte: Autoria própria.

O valor adaptativo de (μ) é aumentado pelo fator de crescimento de Marquardt (μ) até que a alteração na equação 23 resulte em um valor de desempenho reduzido. Essa alteração é feita através da diminuição do fator de decrescimento do parâmetro de Marquardt (μ). O treinamento de regularização bayesiana será interrompido assim que alguma dessas condições ocorra:

- O número máximo de épocas de treinamento é atingido;
- O tempo máximo foi ultrapassado;
- O desempenho de objetivo é minimizado;
- O valor do gradiente de desempenho ultrapassa o valor mínimo escolhido;
- (μ) ultrapasse o máximo valor de falhas de validação.

6 AMBIENTES DE ESTUDO

A busca por banco de dados reais é essencial para garantir uma boa resposta de comparação entre valores reais e calculados. Nesse sentido, esse trabalho utiliza dois cenários de aplicação distintos utilizando bancos de dados reais. No primeiro cenário de aplicação (Ambiente 1) são utilizados dados de usuários de VEs em duas estações de carregamento, com diferentes características no perfil de utilização. No segundo cenário (Ambiente 2) é utilizado um banco de dados de demandas de residências que além do padrão de utilização de energia comum utilizam também carregamento de VEPs em sua rede residencial.

6.1 AMBIENTE 1: ESTAÇÕES DE CARREGAMENTO PARA VES

Os dois bancos foram extraídos de um portal de pesquisa em redes de carregamentos adaptáveis que é nomeado pela sigla (ACN) e servem como uma fonte de pesquisa na área de cobranças, carregamentos e comportamentos de usuários em veículos elétricos. Esses conjuntos de dados de carregamentos são de consumos dinâmicos de sessões de carregamentos de VEs em local de trabalho e um local público (LEE; LI; LOW, 2019).


Os dados coletados são de consumos diários de carregamentos, contendo os horários de entradas de cada VE e suas respectivas saídas, medidos por kiloWatts hora (kWh), com um carregador rápido de 50 kW. Esses dados são de dois ambientes diferentes, o primeiro é disponibilizado pelo Instituto de tecnologia da Califórnia (CALTECH), coletados de, inicialmente, 54 VEs da estação de carregamento do próprio campus, que funciona de segunda-feira à domingo. Fazem uso dessa garagem professores, funcionários, alunos e também é aberto ao público. Aos finais de semana, é frequente o carregamento por motoristas que não são da CALTECH durante a manhã e a noite, porque o campus está localizado perto de uma academia (LEE; LI; LOW, 2019).

O segundo banco de dados é referente ao consumo de carregamento de, inicialmente, 52 VEs da estação de carregamento do laboratório de pesquisa nacional (JPL) na Califórnia, cujo espaço é utilizado somente por funcionários em horários normais de trabalho. É utilizado com maiores frequências de segunda à sexta-feira, nos finais de semanas o consumo diário é baixo, quase nulo, devido as reduções no corpo de funcionários. A penetração nesse ambiente é alta, pela exclusividade de uso dos funcionários, característica que levou a utilização de um gerenciador programado para que os motoristas liberem seus veículos quando terminarem seus carregamentos fazendo que outro veículo conecte para a próxima recarga (LEE; LI; LOW, 2019).

Para ilustrar a natureza dos dados, a Figura 19 mostra as medições da demanda de carregamento diária em kiloWatts (kW), no período de 14 semanas nos ambientes da

CALTECH e JPL. Os dados mostram o consumo no período de 100 dias, e são referentes a semana iniciada no sábado no dia (23/03/2019) até (30/06/2019) em um domingo, onde as cargas diárias de cada VE são somadas para obter a demanda diária total.

Figura 19 – Demanda diária de carregamento da JPL e CALTECH.



Fonte: Autoria própria.

6.2 AMBIENTE 2: CARREGAMENTO RESIDENCIAL DE VES DESCOORDENADOS

Os VEPs estão criando um novo cenário de penetração de energia, gerando novas conexões no setor de transportes elétricos. Suas cobranças e demandas energéticas irão gerar vários desafios para o sistema energético e as dinâmicas de utilização estão cada vez mais complexas e crescentes. O carregamento descoordenado dos VEPs gera uma mudança significativa na demanda residencial agregada, com impactos para a infraestrutura da rede (RICHARDSON et al., 2010).

Com isso, Muratori *et. al.* (2018) (MURATORI, 2018) propôs um modelo para avaliar o impacto do carregamento não coordenado de VEPs na demanda residencial. Para estimar dados realistas do impacto ocasionado pelos VEPs descoordenados na demanda residencial total foram simulados pelo autor dados de 200 residências na região centro-oeste dos Estados Unidos usando modelos estatísticos e estocásticos. A composição dos domicílios incluiu 502 indivíduos e 348 veículos de passeio, números extraídos de amostras representativas de unidades habitacionais incluídas na pesquisa de consumo residencial de energia RECS (*Residential Energy Consumption Survey*) da região.

Os autores identificaram algumas limitações na literatura. Uma delas é que os carregamentos dos VEPs podem acontecer em quaisquer horários, isso significa fora ou dentro do horário de pico. Observa-se então que o carregamento de um VEP nesse cenário é


uma variável estocástica. Outra limitação é que a maioria dos métodos utilizam estatísticas médias para estimar o perfil de consumo de carregamento dos VEPs, e seu tempo de carregamento é estimado com base na disponibilidade presumida do veículo, ou seja, as estimativas de carregamento dos veículos são feitas durante um período de tempo predeterminado (MURATORI, 2018).

Para resolver essas limitações o autor se baseou na modelagem de Markov usando dados coletados pelo *Bureau of Labor Statistics* dos EUA a partir de comportamentos de consumo reais de energia e uso de veículos. Esses modelos geraram perfis de consumo de energia com resolução de 10 minutos para residências individuais e recargas de VEPs nas residências (MURATORI et al., 2012) (MURATORI et al., 2013).

Os perfis da demanda de energia são selecionados aleatoriamente de 200 residências entre os conjuntos de dados da pesquisa RECS de 2009 na região Centro Oeste do EUA no período de 1 ano inteiro. Os perfis são de padrões reais de consumo que foram validados por dados medidos, com resolução de 10 minutos. As residências variam em tamanho e número de ocupantes e os perfis são medidos em uso total de eletricidade em termos de potência elétrica medida em Watts (W) (MURATORI, 2018).

Os dados originalmente contêm dias da semana, meses e as medições das cargas. O consumo é medido durante um ano completo, totalizando 52559 amostras. Na Figura 20, o consumo total de potência para 200 residências é apresentado.

Figura 20 – Demanda total nas 200 residências.




Fonte: Autoria própria.

Os perfis de carregamento dos VEPs foram gerados por 348 veículos associados as 200 residências e selecionados aleatoriamente entre o conjunto. As medições também são validadas com resolução de 10 minutos (Figura 21). A simulação dos consumos foi feita em três passos: modelagem do comportamento dos motoristas, geração dos perfis de direção

realistas e simulação de energia de vários tipos de veículos.

Figura 21 – Demanda total do carregamento dos 348 veículos.



Fonte: Autoria própria.

Foram considerados veículos do tipo VEBs de 60% de carga com alcance de cerca de 322 km e veículos VEHP de 40% de carga com alcance total de cerca de 65 km. O tipo de carregamento utilizado foi do nível 1 de 1920 Watts (W) e a demanda total gerada do carregamento dos VEPs é totalmente do tipo plugável, ou seja, quando o veículo é carregado com cabo diretamente na tomada.


7 METODOLOGIA

A metodologia utilizada será apresentada separadamente para o ambiente de estação de carregamento para VEs e para carregamento de VEs em ambiente residencial.

7.1 AMBIENTE 1

Para demonstrar o procedimento da metodologia usada para a previsão de cargas nas estações de carregamentos fez-se um diagrama apresentando os passos utilizados e as descrições em cada etapa (Figura 22).

Figura 22 – Metodologia para previsão de cargas em estação de carregamento.



Fonte: Autoria própria.

1. Criação dos conjuntos de dados de entrada e saída

Para estruturar os dados de entradas foram levados em consideração: dias das semanas, meses, consumo diário de carregamentos, dias de trabalhos e quantidades de veículos plugados na rede. O consumo diário de carregamento foi obtido por meio da somatória das cargas de carregamento de cada VE plugado no dia, medido em kWh. A saída da previsão será o consumo diário de carregamento no dia seguinte.

Para mostrar as organizações dos dados das variáveis de entrada da rede a Tabela 3 representa os dados dos dois ambientes.

Tabela 3 – Organização dos dados da CALTECH e JPL.

Dia da semana	Meses	Demanda de carregamento (kW)		Dia de trabalho	Nº de VEs	
		CALTECH	JPL		CALTECH	JPL
quarta-feira	setembro	0,6054	0,6274	1	82	67
quinta-feira	setembro	0,7350	0,6175	1	91	66
sexta-feira	setembro	0,7916	0,2963	1	104	46
•	•	•	•	•	•	•
•	•	•	•	•	•	•
•	•	•	•	•	•	•
domingo	fevereiro	0,0928	0,0320	0	4	7

Fonte: Autoria própria.

2. Adequação dos dados

Fez-se uma análise nos bancos de dados para descobrir valores ausentes e abaixo das médias. De um total de 559 dados foram encontrados nos dois bancos 86 dados a serem substituídos, sendo eles 20 valores faltantes (zeros), entre dia sem consumo e sem veículo carregado, e 66 valores abaixo das médias, sendo consumo muito abaixo da média e poucos veículos carregados.

Para garantir uma substituição de maneira realista, foram feitas as médias de cada dia da semana no conjunto dos 559 dados, gerando assim 7 médias de segunda – feira até domingo dos consumos diários de carregamento de cada dia.

Uma rotina foi desenvolvida para gerar dois sorteios de forma aleatória contendo os 5 valores das médias semanais e 2 valores das médias dos finais de semanas. Dessa forma, as substituições foram feitas preenchendo os dados faltantes.

Devido a substituição dos consumos médios as quantidades dos VEPs também foram substituídas e calculadas de acordo com o valor das médias preenchidas nos dados faltantes. Assim, foram feitos dois cálculos, apresentados nas equações 24 e 25 para encontrar o novo valor médio da quantidade de veículos carregados no dia:

$$média = \sum_{i=1}^{num} \frac{Cdi}{Qvei} \quad (24)$$

$$novo\ valor = \frac{Carga\ d}{média} \quad (25)$$

sendo:

- *média*: consumo total real em kwh/quantidade total real de VEs;
- *Cdi*: somatória total do consumo de carregamento real em kWh;
- *Qvei*: somatória total da quantidade de veículo plugado real;
- *Carga d*: Nova carga substituída pela média em kWh;
- *novo valor*: quantidade atualizada total de VEs plugados no dia;
- *num*: Número total de amostras.

3. Formato dos padrões de entradas e saída da RNA

O conjunto de entradas da RNA foi composto pelas seguintes variáveis:

- *Dia da semana*: $[1 \dots 7]$ de segunda-feira a domingo;
- *Mês*: $[1 \dots 12]$ de janeiro a dezembro;
- *Consumo(d)*: consumo total em kWh normalizado no dia d ;
- *Dia de trabalho*: $[0, 1]$ codificação binária para indicar que de segunda a sexta-feira a variável recebe $[1]$ referente ao dia de trabalho e sábado e domingo recebe $[0]$ indicando que não é dia de trabalho;
- *Quantidade de veículos*: número total de veículos carregados no dia d ;

O conjunto de saída da RNA é dado por:

- *Consumo(d + 1)* : consumo normalizado total em kWh do próximo dia d .

4. Normalização dos dados

Como os dados do consumo diário de carregamento tem intervalos diferentes, optou-se pela normalização dos valores de consumo de carregamento, de maneira que estejam entre o intervalo $[0, 1]$. Foram acrescentados 20% em sua carga máxima para a normalização. Descreve-se a normalização pela equação 26:

$$CargaN(d) = \frac{Cr(d)}{Crmax\ 1.2} \quad (26)$$

sendo:

- *CargaN(d)*: Consumo normalizado no dia (d);
- *Cr(d)*: Consumo real no dia (d);

- *Crmax*: Consumo real máximo.

5. Criação do conjunto de treinamento e teste


Para determinar os conjuntos de dados foram utilizados nos dois bancos de dados os mesmos dias de início e término do treinamento e teste. O treinamento começa na data de 05/09/2018 em uma quarta-feira e termina no dia 29/02/2020, no sábado. O teste se inicia no dia 01/03/2020, em um domingo, e termina no dia 16/03/2020 em uma segunda-feira.

O banco possui 559 dados e foram divididos em 543 para treinamento e 16 para teste. As duas semanas de teste foram as duas primeiras do mês de março de 2020. Dessa forma, as matrizes entrada e saída de treinamento possuem, respectivamente, as dimensões 5×542 e 1×542 . E as matrizes de entrada e saída de teste tem dimensões 5×15 e 1×15 , respectivamente.

6. Seleção da arquitetura da RNA

A RNA é composta por 5 neurônios na camada de entrada, 11 neurônios na camada escondida e 1 neurônio na camada de saída (Figura 23), com função de ativação do tipo tangente hiperbólica (*tansig*).

Figura 23 – Arquitetura da RNA proposta para o Ambiente 1.



Fonte: Autoria própria.

7. Avaliação do desempenho da previsão da carga

Nessa última etapa será mostrada a maneira de avaliar o desempenho da previsão, comparando a saída real com a saída prevista pela RNA. Para avaliar os resultados, utilizou-se o erro percentual absoluto médio (MAPE), mostrado na equação 27 (PARK et al., 1991):

$$MAPE = \frac{1}{N} \sum_{d=1}^N \left(\left| \frac{Cr(d) - Cprevisto(d)}{Cr(d)} \right| \right) * 100 \quad (27)$$


sendo:

- N : Número total de dias;
- $Cr(d)$: Valor real no dia d ;
- $Cprevisto(d)$: Valor previsto pela rede no dia d .

7.2 AMBIENTE 2

Para demonstrar a metodologia usada na previsão no ambiente de carregamento residencial a Figura 24 apresenta um diagrama com a divisão de cada processo.

Figura 24 – Metodologia para previsão de carregamento residencial.



Fonte: Autoria própria.

1. Banco de dados original

Os dados dos consumos residenciais e carregamentos dos VEs são extraídos de maneira aleatória do conjunto total REC de 200 residências que possuem 348 VEs no total, variando o tamanho e quantidade de moradores.

Como os dados são de medições no período de um ano, a matriz de medições de consumo $\times$ residências tem dimensão 52559×200 , o que resulta em um total de 10511800 medições. Já os dados de carregamentos dos VEs tem dimensão de 52559×348 , representando as medições de carregamento $\times$ quantidade de VEs, totalizando 18290532 medições. Para esse estudo foram utilizados 100% do conjunto de dados em questão, isto é, com as 200 residências e os 348 veículos.

2. Pré-processamento e processamento

Os dados originais estão com resolução de medições em 10 minutos e optou-se por agrupar as medições em horas, com resolução de 1 hora. Foram somadas todas as medições das residências e todos os carregamentos dos VEs em cada hora, formando medições no período de 00 horas até 23 horas. A transformação foi feita reduzindo 144 medições (resolução de 10 minutos) para 24 medições (resolução de 1 hora) em cada dia.

Os dados foram separados em duas demandas: a primeira representada pelo consumo residencial e a segunda o consumo de carregamento dos VEs. Com isso, foram geradas em cada demanda uma única coluna contendo todas as medições, devido a somatória das 200 residências e 348 veículos, formando duas matrizes de 8760×1 , dados dos dois consumos no período de um ano. Para mostrar as configurações geradas e a organização dos dados extraídos do banco de dados original, a Tabela 4 apresenta os dados organizados da demanda residencial e da demanda de carregamento dos VEs.

Tabela 4 – Configuração dos dados de demanda residencial e de carregamento dos VEs.

Dias	Semana	Meses	Horários	Demanda(W)	
				Residencial	VEs
01	sexta-feira	janeiro	00	1111666	5760
01	sexta-feira	janeiro	01	1057865	11520
01	sexta-feira	janeiro	02	1036167	15360
•	•	•	•	•	•
•	•	•	•	•	•
•	•	•	•	•	•
31	sexta-feira	dezembro	23	930417	606720


Fonte: Autoria própria.

3. Dados organizados e perfis gerados

Os dados da demanda de consumo residencial e demanda de carregamento dos VEs foram organizados de acordo com os dias, dia da semana, meses, horários e as


medições das cargas. A Figura 25 ilustra a demanda total de consumo residencial das 200 casas gerada pela organização dos dados e a Figura 26 a demanda total de carregamento dos 348 veículos elétricos nas 200 residências.

Figura 25 – Demanda residencial total das 200 residências.



Fonte: Autoria própria.

Figura 26 – Demanda total de carregamento com 348 VEs.



Fonte: Autoria própria.

Com isso foram geradas as duas demandas separadas, uma para o consumo residencial e outra para o consumo exclusivo do carregamento dos VEs (Figura 27). Este trabalho visa prever o consumo total da demanda gerada pelos VEs carregados nas residências (equação 28), obtida por meio da somatória entre todas as cargas respectiva a cada


hora, dia e mês entre as duas demandas mostradas na Figura 27:

$$DT = DR + DVE \quad (28)$$

em que:

- DT: Demanda total para previsão;
- DR: Demanda residencial total;
- DVE: Demanda dos veículos elétricos;


Figura 27 – Comparação das demandas geradas pelas residências e carregamentos dos VEs.




Fonte: Autoria própria.

Após essa somatória foi obtida a demanda total, apresentada na Figura 28), que ilustra o impacto causado na demanda residencial pela penetração de carregamentos descoordenados dos VEs. A demanda total foi obtida por meio da soma entre a demanda do consumo residencial e a demanda de carregamento dos VEs.

Para melhorar a visualização, a Figura 29 mostra o impacto gerado pelo carregamento dos VEs no período de 24 horas.


Figura 28 – Impacto do carregamento dos 348 VEs nas 200 residências.

Fonte: Autoria própria.

Figura 29 – Impacto na demanda residencial causado pelos carregamentos dos VEs em 24 horas.

Fonte: Autoria própria.

Ao adicionar as cargas de carregamento dos VEs na demanda residencial, essa nova demanda gerada modifica totalmente a curva característica residencial. O impacto gerado pelos carregamentos descoordenados dos VEs causa um aumento significativo na demanda residencial. A Figura 30 apresenta esse acréscimo em cada hora no período de 24 horas de medições.

Figura 30 – Impacto na demanda residencial gerado pelo carregamento dos VEs.

Fonte: Autoria própria.

4. Criação dos conjuntos de treinamentos e testes

Para formular os conjuntos de dados para treinamentos e testes foi utilizado o perfil de demanda total gerada. O conjunto total composto por 8760 medições foi dividido nas 4 estações do ano. Dessa forma, foram propostas 4 previsões para as próximas 24 horas, uma para cada estação do ano. Os dados foram separados da seguinte forma:

- Primavera (março - maio): inicia em 01/03 (segunda-feira) e termina em 31/05 (segunda-feira), totalizando 2208 dados;
- Verão (junho - agosto): inicia em 01/06 (terça-feira) e termina em 31/08 (terça-feira), totalizando 2208 dados;
- Outono (setembro - novembro): inicia em 01/09 (quarta-feira) e termina em 30/11 (terça-feira), totalizando 2184 dados;
- Inverno (dezembro - fevereiro): inicia em 01/12 (quarta-feira) e termina em 28/02 (domingo), totalizando 2159 dados.

O conjunto de entradas da RNA para todas as previsões é composto pelas variáveis:


- *Dias*: $[1 \dots 31]$ = Representação dos dias;
- *Semanas*: $[1 \dots 7]$ = Representação das semanas de segunda-feira à domingo;
- *Meses*: $[1 \dots 12]$ = Representação dos meses de Janeiro à Dezembro;
- *Horários*: $[0 \dots 23]$ = Medições em horas (h) no período de 24 horas;
- *Cargas(h)*: [consumo] = Medições das cargas na hora (h) em Watts.

E o conjunto de dados de saída da RNA é composto por:

- $Cargas(h + 1)$: [consumo] = Medições das cargas na hora (h) seguinte em Watts.

A Figura 31 apresenta o perfil da demanda dividida nas quatro estações do ano.

Figura 31 – Demanda de cargas totais por estações do ano.



Fonte: Autoria própria.

5. Divisão dos conjuntos de dados

Os dados foram separados em 83% para treinamento e 17% para teste. Esse valor se deu devido ao treinamento começar na segunda-feira e terminar no domingo e o teste começar na segunda-feira terminando no domingo. As dimensões dos conjuntos de dados estão apresentadas na Tabela 5.

Tabela 5 – Dimensões dos conjuntos de treinamento e teste.

Conjuntos	Treinamento		Teste	
	Entrada	Saída	Entrada	Saída
Primavera	5×1847	1×1847	5×359	1×359
Verão	5×1823	1×1823	5×383	1×383
Outono	5×1799	1×1799	5×383	1×383
Inverno	5×1823	1×1823	5×335	1×335


Fonte: Autoria própria.

6. Seleção da arquitetura da RNA

A RNA utilizada para a previsão também foi a *feedforward* de multicamadas com treinamento por regularização bayesiana (HAYKIN, 1999). A arquitetura da rede é formada por 5 neurônios na camada de entrada, 6 neurônios na primeira camada escondida, 2 neurônios na segunda camada escondida, 1 neurônio na terceira camada

escondida e 1 neurônio na camada de saída (Figura 32). Utilizou-se a função de ativação tangente hiperbólica (*tansig*).

Figura 32 – Arquitetura da RNA utilizada para o Ambiente 2.



Fonte: Autoria própria.

7. Avaliação do desempenho da previsão de carregamento residencial

A maneira utilizada para avaliar o desempenho da previsão também foi o MAPE (equação 29) (PARK et al., 1991). Foi utilizado, adicionalmente, o erro percentual mínimo e máximo (equações 30 e 31, respectivamente) referente a cada hora prevista:

$$MAPE = \frac{1}{Num} \sum_{h=1}^{Num} \left(\left| \frac{Cr(h) - Cprevisto(h)}{Cr(h)} \right| \right) * 100 \quad (29)$$

$$Erro\ mínimo(\%) = \min \left\{ \left| \frac{Cr(h) - Cprevisto(h)}{Cr(h)} \right| \right\} * 100 \quad (30)$$

$$Erro\ máximo(\%) = \max \left\{ \left| \frac{Cr(h) - Cprevisto(h)}{Cr(h)} \right| \right\} * 100 \quad (31)$$

sendo:

- *Num*: Número total de horas;
- *Cr(h)*: Valor real na hora *h*;
- *Cprevisto(h)*: Valor previsto pela rede na hora *h*.

8 RESULTADOS E DISCUSSÃO

Nesse capítulo serão apresentados todos os critérios e testes para formular a resolução das previsões nos 2 ambientes propostos, prevendo o dia seguinte para JPL e CALTECH e as próximas 24 horas para o carregamento residencial.

Para testar a eficiência da metodologia usada nesse trabalho, serão mostrados alguns resultados obtidos com outras RNAs (GRNN, NARX e ELMAN). O treinamento utilizado para as redes NARX e ELMAN foi de regularização bayesiana.

O programa utilizado para fazer as configurações da rede tanto como escolha dos parâmetros, treinamento e teste foi o software computacional MATLAB® 2015b com a caixa de ferramentas *nntool* (*toolbox*). O software de treinamento utiliza por padrão a divisão do conjunto de dados de maneira aleatória, ou seja, mesmo dividindo o conjunto de treinamento em uma certa porcentagem, ele automaticamente divide esse valor em ordem aleatória.

Os bancos de dados referentes as estações do ano foram divididos de formas diferentes para cada ambiente de estudo, devido as dimensões não serem iguais. Essas divisões foram escolhidas a partir de alguns testes feitos, para descobrir qual a melhor configuração para que o processo de aprendizado ocorra de maneira eficiente.

O uso da função de ativação sigmoide 1 (*tansig*) se deu por apresentar as melhores performance e resultados no treinamento e teste quando comparada a *logsig*. Inicialmente, para os dois ambientes, os parâmetros de regularização $\alpha = 0$ e $\beta = 1$. Como β é maior que α o algoritmo de treinamento focará em minimizar os erros de treinamento.

8.1 RESULTADOS AMBIENTE 1

Inicialmente foram testados algumas RNA e treinamento diferentes da toolbox do MATLAB® para chegar na melhor opção para resolver os problemas de previsões de cargas. A escolha dos parâmetros da rede para o treinamento de regularização bayesiana é apresentada na Tabela 6.

Para esse ambiente foi proposta uma divisão de 97% para treinamento e 3% para teste, o que se deve, também, à falta de um banco de dados maior.

Foram feitas algumas mudanças nos coeficientes dos parâmetros de treinamento como a alteração do valor mínimo do gradiente de desempenho de 1×10^{-7} para 1×10^{-9} . Com isso, o melhor valor obtido foi de 1×10^{-9} .

O número de iterações (épocas) para treinamento também foi alterado para um valor alto, com objetivo de que o treinamento ocorra até que encontre o melhor valor. Porém, geralmente, o algoritmo de treinamento encontra a melhor performance antes de

chegar no valor máximo de iterações pré-estabelecido.

Tabela 6 – Parâmetros e configurações da RNA.

Parâmetros	Valores
Função de ativação	Sigmoide 1
Números de neurônios por camadas	5 – 11 – 1
Números de camadas escondidas	1
Função de desempenho	MSE
Parâmetro de <i>Marquardt</i> inicial (μ)	5×10^{-3}
Fator de decrescimento do parâmetro de <i>Marquardt</i> (μ)	1×10^{-1}
Fator de crescimento do parâmetro de <i>Marquardt</i> (μ)	10
Máximo valor do parâmetro de <i>Marquardt</i> (μ)	1×10^{10}
Máximo valor de falhas de validação	∞
Valor mínimo do gradiente de desempenho	1×10^{-9}
Limite de tempo de treinamento	∞

Fonte: Autoria própria.

A função de desempenho do tipo MSE foi escolhida devido ao treinamento bayesiano apresentar uma melhora no processo de treinamento com o uso desta função e as funções do tipo soma dos erros quadráticos (SSE) não apresentaram melhoras no treinamento.

As previsões para os dois bancos de dados de carregamento serão feitas para 3 dias a frente. Para JPL serão previstos de segunda-feira até quarta-feira e para a CALTECH de quinta-feira até sábado. Esses dias foram escolhidos por serem os dias mais frequentados e com o maior número de conexões e demanda de carregamentos nas duas estações de carregamento.

Foram testadas as variáveis de entrada originais do banco de dados com objetivo de obter os melhores resultados e nesse processo retirou-se a variável dias do mês ([1 ... 31]).

Foram escolhidas algumas redes conhecidas na literatura para testar e comparar os resultados com a rede proposta nesse trabalho. Os parâmetros de treinamento usados foram os mesmos em cada tipo de rede. Estas redes não provaram ser mais eficientes no processo de treinamento. A Tabela 7 apresenta os 3 tipos de RNA com uma comparação de seus treinamentos para testes iniciais e resultados.

Tabela 7 – Tipos de RNA e resultados.

RNAs	Treinamento	MAPE JPL (%)	MAPE CALTECH (%)
GRNN	Spread 0,8	2,9284	64,8586
NARX	Regularização bayesiana	3,313	22,39143
ELMAN	Regularização bayesiana	3,3781	18,50875

Fonte: Autoria própria.

Para os resultados da JPL as redes comparadas não apresentaram muita diferença entre os MAPE. Entretanto, para o perfil da CALTECH foi observada uma diferença

relevante nos resultados, principalmente na rede GRNN que obteve um aumento de MAPE em 55,56%, seguida pela NARX com aumento de 13,1% e ELMAN com 9,21% de aumento no MAPE. Foi concluído que a rede aprendeu melhor sem a variável dias do mês e devido a normalização das cargas originais, obteve-se uma melhoria nos resultados da previsão.

Devido aos resultados sofrerem algumas variações de MAPE, o trabalho propõe o uso da RNA tipo *feedforward* com o treinamento de regularização bayesiana. Os parâmetros utilizados para a rede *feedforward* foram os mesmos das outras redes apresentadas na Tabela 6. Com isso obtiveram-se novos resultados apresentados na Tabela 8.

Tabela 8 – Resultados da previsão da RNA *feedforward*.

RNA	Treinamento	MAPE JPL (%)	MAPE CALTECH (%)
<i>Feedforward</i>	Regularização bayesiana	2,5459	9,30231

Fonte: Autoria própria.

As Tabelas 9 e 10 mostram comparações dos valores reais e os valores previstos pela rede em cada dia, para o JPL e CALTECH, respectivamente.

Tabela 9 – Valores reais e previstos JPL.

Ambiente	Primeiro dia	Segundo dia	Terceiro dia
JPL	segunda-feira	terça-feira	quarta-feira
Valor real (kWh)	0,715894	0,6263001	0,687736
Valor previsto (kWh)	0,704208	0,6511077	0,673675

Fonte: Autoria própria.

Tabela 10 – Valores reais e previstos CALTECH.

Ambiente	Primeiro dia	Segundo dia	Terceiro dia
CALTECH	quinta-feira	sexta-feira	sábado
Valor real (kWh)	0,190196	0,206818	0,096911
Valor previsto (kWh)	0,209477	0,240516	0,098341

Fonte: Autoria própria.

8.2 RESULTADOS AMBIENTE 2

Inicialmente foi testada a normalização das cargas para as quatro estações do ano, e pode-se observar que o resultado não melhorou. Portanto, não foi necessário o uso da normalização das cargas nesse ambiente.

Para os testes e previsão da demanda total de cargas em ambiente residencial, foram testadas diversas combinações diferentes entre tipos de RNAs, treinamentos, parâmetros e estruturas. Com isso, foi gerada a melhor combinação para o problema proposto no

ambiente estudado. A Tabela 11 mostra os parâmetros escolhidos para as redes NARX e ELMAN e a Tabela 12 apresenta os resultados obtidos das previsões para cada estação do ano.

Tabela 11 – Parâmetros das redes NARX e ELMAN.

Parâmetros	Valores
Função de ativação	Sigmoide 1
Números de neurônios por camadas	5 – 6 – 2 – 1 – 1
Números de camadas escondidas	3
Função de desempenho	MSE
Parâmetro de <i>Marquardt</i> inicial (μ)	5×10^{-3}
Fator de decrescimento do parâmetro de <i>Marquardt</i> (μ)	1×10^{-1}
Fator de crescimento do parâmetro de <i>Marquardt</i> (μ)	10
Máximo valor do parâmetro de <i>Marquardt</i> (μ)	1×10^{10}
Máximo valor de falhas de validação	∞
Valor mínimo do gradiente de desempenho	1×10^{-9}
Limite de tempo de treinamento	∞

Fonte: Autoria própria.

Tabela 12 – Resultados obtidos.

RNA	Treinamento	MAPE (%)			
		Primavera	Verão	Outono	Inverno
GRNN	Spread 0,05	12,7672	13,93	9,9243	9,2707
NARX	Regularização bayesiana	4,6409	5,1684	4,4956	3,5362
ELMAN	Regularização bayesiana	4,9866	5,4520	3,7004	3,5637

Fonte: Autoria própria.

Também foram utilizadas as mesmas três redes para comparação e pode-se observar que nesse ambiente as três redes apresentaram uma melhoria em relação ao desempenho do Ambiente 1, mas não alcançaram resultados melhores que a rede *feedforward* proposta para a previsão. Os resultados mais próximos foram obtidos pela NARX e ELMAN.

Inicialmente foram feitos testes com as duas primeiras estações do ano para garantir o melhor parâmetro da rede, com a melhor configuração e menor erro possível e posteriormente aplicá-los nas demais estações. Essa análise feita para encontrar a melhor configuração foi validada pelo MAPE usando o conjunto total de dados de testes com os 17%, ou seja, com 359 para primavera e 383 para o verão.

Foram feitos vários testes com variações de números de camadas ocultas, números de neurônios por camada e parâmetros de treinamento para encontrar o melhor parâmetro de treinamento e estrutura de rede para a previsão. Esses parâmetros são os mesmos apresentados na Tabela 11 anteriormente, que foram utilizados para comparação com as demais RNA.

Foram feitas várias aplicações nas duas estações do ano variando os números de camadas ocultas da rede *feedforward*. Com isso, foi observado que as performances de cada configuração variaram de acordo com a quantidade de camadas. A Tabela 13 apresenta as configurações e resultados com as quantidades de camadas escondidas para as previsões em duas estações do ano, primavera e verão. Para validar as previsões o MAPE foi feito no conjunto de testes total.

Tabela 13 – Testes e resultados para a primavera e verão.

Aplicações	Nº de camadas ocultas	MAPE (%)	
		Primavera	Verão
1	0	13,657	14,048
2	1	7,341	9,942
3	2	6,592	7,644
4	3	5,465	7,732
5	4	5,304	7,871
6	5	6,261	10,917
7	6	9,894	12,226
8	7	16,595	14,103
9	8	30,834	22,121

Fonte: Autoria própria.

Foi observado que para os testes da primavera a rede apresentou uma melhoria nos resultados a partir da 1 camada oculta, e começa a cair seu desempenho a partir da 5 camada oculta, sendo desnecessário usar 5 camadas ocultas ou mais. Com nenhuma camada oculta (que significa a perda de dados de treinamento) o conjunto de treinamento teve um aprendizado razoável, mas o teste não foi de bons resultados (*underfitting*).

Como visto na Tabela 13, as duas melhores configurações foram observadas para três e quatro camadas ocultas, com 5,465 e 5,304 de MAPE, respectivamente. .

Para os testes do verão os melhores desempenhos foram obtidos na segunda camada oculta até a quarta, com poucas variações dos MAPE entre as três. Os melhores resultados foram: para duas camadas ocultas 7,644%, três camadas 7,732% e quatro camadas ocultas 7,871% (MAPE).

Como o objetivo da previsão é encontrar a melhor previsão possível em 24 horas, uma camada e duas camadas ocultas não apresentaram os melhores resultados. Para essas duas configurações, as performances da rede não apresentam um resultado estável ou preciso, apresentando flutuações e muitas variações.

Foram feitos mais testes sobre as configurações das camadas ocultas e seus números de neurônios e foi observado que a melhor configuração da rede é com três camadas ocultas. Essa configuração foi a de melhor desempenho devido a precisão e estabilidade da resposta. A Tabela 14 mostra as especificações da RNA *feedforward* com a melhor configuração

encontrada e os resultados das previsões nas próximas 24 horas para cada estação do ano.

Tabela 14 – Especificações da RNA *feedforward*.

Pârametros	Primavera	Verão	Outono	Inverno
Nº de vetores	1847	1823	1799	1823
Nº de neurônios por camadas ocultas	[6 -2 -1]	[6 -2 -1]	[6 -2 -1]	[6 -2 -1]
Nº de camadas ocultas	3	3	3	3
Nº de neurônios por camadas	[5-6-2-1-1]	[5-6-2-1-1]	[5-6-2-1-1]	[5-6-2-1-1]

Fonte: Autoria própria.

A Tabela 15 apresenta os resultados de MAPE obtidos para cada estação do ano.


Tabela 15 – Resultados das previsões por estação.

Resultados	Primavera	Verão	Outono	Inverno
MAPE(%)	4,425	5,010	3,684	3,41


Fonte: Autoria própria.

As Figuras 33, 34, 35 e 36 apresentam os resultados obtidos da previsão de carregamento residencial nas próximas 24 horas para a primavera, verão, outono e inverno, respectivamente.


Figura 33 – Previsão para a primavera.




Fonte: Autoria própria.

Figura 34 – Previsão para o verão.

Fonte: Autoria própria.

Figura 35 – Previsão para o outono.

Fonte: Autoria própria.

Figura 36 – Previsão para o inverno.

Fonte: Autoria própria.

A Tabela 16 a porcentagem de erros mínimos e máximos obtidos nas quatro previsões.

Tabela 16 – Porcentagem de erros mínimos e máximos obtidos por estação.

Estação	Erros (%)	
	Mínimo	Máximo
Primavera	0,402	10,860
Verão	0,646	20,228
Outono	0,004	9,540
Inverno	0,301	15,934

Fonte: Autoria própria.

A Tabela 17 apresenta os erros obtidos em cada hora prevista para todas as estações.

Tabela 17 – Resultados das previsões em cada hora para todas as estações.

	Primavera	Verão	Outono	Inverno
Horas (h)	Erro (%)			
00	6,239	2,541	0,4505	0,5045
01	3,429	3,540	9,5395	3,6718
02	6,186	4,3713	1,1651	2,6317
03	3,945	20,2283	8,0746	6,2430
04	2,275	5,319	2,8937	0,4194
05	3,782	1,3131	3,4359	2,4689
06	0,402	7,781	8,5443	3,9771
07	8,267	3,5782	7,4859	15,9345
08	2,103	5,1311	1,18703	0,7600
09	10,644	0,9561	1,0460	3,6699
10	3,021	5,7085	5,2915	0,3787
11	4,393	10,7167	3,1600	4,2278
12	3,667	1,8155	0,0040	1,8180
13	1,525	0,9441	1,4414	0,7350
14	5,250	4,5838	8,2559	0,3014
15	7,460	2,6384	8,2195	2,7159
16	0,467	2,2934	6,0489	1,9443
17	1,429	1,8058	1,2933	0,6210
18	1,788	6,6604	1,6127	4,2329
19	10,653	4,2347	0,5151	4,2612
20	10,860	0,6465	0,8306	9,1025
21	10,860	10,2427	1,1546	6,0543
22	2,935	10,6634	1,5865	0,6621
23	2,601	2,5308	4,4864	4,4566

Fonte: Autoria própria.

Os treinamentos nos dois ambientes apresentaram baixo tempo de treinamento convergindo para os melhores resultados em poucas iterações, conforme Tabela 18.

Tabela 18 – Desempenho dos treinamentos: tempo de processamento e iterações.

Ambientes	Tempo de treinamento (s)	Número de iterações	Número de vetores
Ambiente 1	[3 - 5]	[100 - 200]	543
Ambiente 2	[5 - 15]	[200 - 500]	[1799 - 1847]

Fonte: Autoria própria.

9 CONCLUSÃO E TRABALHOS FUTUROS

O crescimento de utilização de VEs com carregamento agregado ao consumo residencial e estação de carregamento apresentou um grande impacto ao sistema elétrico de potência. A previsão de demanda de carregamento dos VEs se apresenta como um cenário em ampla tendência de crescimento e com grande abertura para ser explorado.

A RNA *feedforward* multicamadas via treinamento de regularização Bayesiana apresentou uma boa capacidade de generalização, com resultados satisfatórios e rápida convergência.

Inicialmente quando utilizados outros algoritmos de treinamento os resultados não apresentaram uma grande diferença em relação ao proposto, mas quando modificou-se as estruturas (quantidade de camadas ocultas e números de neurônios por camada oculta) o treinamento bayesiano foi capaz de melhorar a performance da rede. Notou-se também que a função de ativação do tipo logsig não apresentou a melhor resposta mesmo que os dados de entrada e saída se encontrem em um intervalo de zero e 1. A função tansig apresentou uma melhor performance e resultados.

Para o Ambiente 1 o perfil de carregamento no ambiente CALTECH apresentou uma variação de demanda total no dia em termo de consumo (kW) e concluiu-se que fazer a previsão para vários dias não apresentaria um resultado aceitável devido à instabilidade das cargas por serem cargas estacionárias. A rede não conseguiu ter uma boa generalização após quatro dias nesse ambiente devido a seu perfil apresentar uma variação ao longo da semana em que as cargas se comportavam de uma forma muito diferente e sem padrão nos finais da semana. Com isso, é justificável o uso do treinamento bayesiano pelo comportamento estocástico das cargas.

Para o perfil da JPL, pode-se observar que as demandas de carregamento apresentam cargas não estacionárias, com isso o perfil se mostra mais estável ao longo do tempo. Esse comportamento ocorre somente nos dias da semana, nos finais de semana as cargas são baixas e instáveis. Nesse ambiente, a rede melhorou a sua aprendizagem e conseguiu generalizar melhor em relação à CALTECH: os resultados foram satisfatórios prevendo 5 dias a frente, mas para fins de comparação entre os dois bancos de dados optou-se por prever para 3 dias a frente. Nesse ambiente a rede conseguiu generalizar melhor devido as cargas apresentarem um comportamento mais periódico e contínuo.

Para os dados da JPL os resultados foram mais satisfatórios que os da CALTECH, prevendo os 3 dias a frente, mostrando que nesse ambiente a rede conseguiu generalizar melhor devido as cargas apresentarem um comportamento mais periódico e contínuo.

Foi possível observar também que para o Ambiente 1 não foi necessário aumentar o número de camadas ocultas, não houve melhora a partir de uma única camada oculta. A

aplicação para JPL apresentou um melhor resultado em relação a CALTECH nos três dias de previsão. Como conclusão final do Ambiente 1, a previsão em estações de carregamento é uma tarefa difícil e devem ser levados em considerações vários aspectos como: tipo de estação de carregamento, localização, mais dados históricos e melhoria na aquisição dos dados.

Para o Ambiente 2 observou-se que ao utilizar 3 camadas ocultas a rede apresentou uma melhoria no desempenho de treinamento e também os melhores resultados, isso deve-se ao processo de aprendizagem bayesiano não cair em *overfitting* ou *underfitting*. A utilização de três camadas ocultas foi de grande importância para o processo de generalização do treinamento, aumentando a qualidade dos resultados. Para as tarefas de suporte ao sistema de geração, distribuição e planejamento, as previsões de cargas com erro inferior a 5% apresentam reduções expressivas nos custos de operação.

Para a previsão da primavera foi observado que os horários que possuíram os maiores erros de previsão foram no período da noite, entre as 19 a 21 horas, com erros médios de $\pm 10\%$. Foi também visto que no período da manhã precisamente as 9 horas a rede apresentou um erro de 10,644%.

Foi observado que os maiores picos de cargas devido a penetração dos VEs se encontram no período da manhã (entre 07 e 12 horas) e também no noturno (entre 18 e 21 horas). Com isso, a demanda residencial perdeu sua curva característica padrão devido o acréscimo do consumo dos VEs.

A previsão para o verão apresentou os maiores erros quando comparada as outras três estações, com três horários de erro bem acentuados: no período da manhã com 20 % de erro, no período do almoço com 10 % de erro e no período noturno, entre as 21 e 22 horas, com 10 % de erro. Foi concluído também que devido ao verão ser a estação do ano na qual as cargas apresentaram maiores picos devidos as cargas adicionais, a previsão de verão ainda alcançou um resultado satisfatório.

Para o período do inverno a rede obteve os menores erros em comparação com as outras estações, entretanto obteve um erro máximo de 15,9345% no horário de pico da manhã e nesse ponto a rede foi otimista, ou seja, ela superestimou a demanda no horário previsto.

A estação do outono obteve a segunda melhor previsão, com erros um pouco maiores que os do inverno. No horário de pico de carregamento o erro máximo foi de 9,540%. Essa porcentagem de erro no horário de pico foi o menor erro máximo entre todas as outras previsões.

Observou-se também que as previsões, em sua maioria foram otimistas para as 4 estações do ano, o que é um resultado positivo por se tratar do tema de cargas elétricas.

Foi possível observar também que, dos 96 pontos previstos para todas as estações,

31 deles obtiveram erro de previsão maior que 5%, o que representa um total de 32% das previsões.

Observou-se também que os horários que apresentaram maiores erros foram o das 03, 06 e 07 horas no período da manhã e no período da tarde foi entre as 14 e 15 horas. No período noturno o horário de maior erro se encontra no intervalo de 19 a 22 horas.

Para o Ambiente 1, na previsão para JPL, a demanda diária de carregamento em um dia foi otimista, prevendo um pouco acima da demanda real. Já para a CALTECH, a previsão foi otimista nos três dias previstos. De um modo geral, no Ambiente 2 as quatro previsões apresentaram resultados otimistas prevendo na maioria dos horários em 24 horas um pouco a mais da demanda real.

Para o Ambiente 2 a rede apresentou um poder bem maior de generalização e com isso os resultados foram satisfatórios e pertinentes para o tema estudado. Observou-se também que as duas melhores previsões foram para o outono e inverno, com MAPEs menores que 4 %. Com isso, foi concluído que a rede apresentou uma boa performance de treinamento e previsão, sendo que ela foi capaz de entender esse aumento de cargas descontroladas geradas pelos VEs. Pelos resultados obtidos nesse ambiente, essa metodologia tem potencial para ser aplicada na prática e em um cenário de grande porte.

Esse trabalho teve como contribuição o estudo em diferentes ambientes de carregamentos para VEs e trouxe a rede de arquitetura *feedforward* com a regularização bayesiana aplicados na previsão de demanda em carregamento dos VEs, e também trouxe um desenvolvimento para encontrar o melhor parâmetro e configuração de camadas ocultas e números de neurônios. Outra contribuição geral foram previsões direcionadas para as estações do ano.

A metodologia de previsão proposta nesta pesquisa pode contribuir para estudos subsequentes no intuito de elaborar uma estratégia de carregamento de VEs para o Brasil, com objetivo de preparar o sistema de energia elétrica para novas penetrações de VEs, verificando qual o impacto esperado dos carregamentos descoordenados de VEPs e também contribuir para previsão de cargas para estações de carregamento.

9.1 TRABALHO FUTUROS

Para o Ambiente 1 uma sugestão é fazer uma expansão dos VEs carregados fazendo projeções de carregamentos futuros e aumentar a quantidade de dados históricos para demanda de estação de carregamento. Usar métodos estatísticos, filtragem de dados e transformadas Wavelet para tratar com mais precisão os sinais das cargas elétricas e estudar a fundo melhorias no algoritmo de treinamento bayesiano, como combinações de outros algoritmos de treinamento.

No Ambiente 2 explorar mais as variações de divisão de treinamento e dos níveis de carregamento, acrescentando o nível 2 para fins de análise do impacto causado por vários níveis de carregamento na rede elétrica. Pesquisar sobre como melhorar o processo de carregamento dos VEs usando redes neurais artificiais para prever qual é o melhor horário de carregamento para diminuir o impacto gerado no sistema elétrico.

Outra sugestão é fazer novas classificações de previsões além de curto prazo, como curtíssimo e médio prazo, com intuito de fazer projeções estratégicas para esse novo cenário de carregamento de VEs e fazer previsões em ambientes descontrolados, devido a esse cenário apresentar mais semelhança com a realidade de utilização e grau de desafio maior.

Por fim, elaborar uma estratégia de carregamento de VEs para o Brasil com objetivo de projetar o sistema de energia elétrica para novas penetrações de VEs, verificar se o atual sistema elétrico suportaria e estaria preparado para um aumento de novas cargas geradas por carregamentos descoordenados de VEPs e qual o impacto gerado.

REFERÊNCIAS

- AEP, O. P. C. *A Community-Based Approach to Leading the Nation in Smart Energy Use*. [S.l.], 2013.
- AL-ANBUKY, A.; BATAINEH, S.; AL-AQTASH, S. Power demand prediction using fuzzy logic. *Control Engineering Practice*, Oxford, v. 3, n. 9, p. 1291–1298, 1995.
- 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*, Amsterdam, v. 186, p. 293–303, 2018.
- 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*, Amsterdam, v. 140, p. 378–390, 2016.
- ASAR, A.; J., M. A specification of neural network applications in the load forecasting problem. *IEEE Transactions on Control Systems Technology*, Piscataway, v. 2, n. 2, p. 135–141, 1994.
- ASHIQUE, R. H. et al. Integrated photovoltaic-grid dc fast charging system for electric vehicle: A review of the architecture and control. *Renewable and Sustainable Energy Reviews*, Oxford, v. 69, p. 1243–1257, 12 2016.
- AYOB, A. et al. Review on electric vehicle, battery charger, charging station and standards. *Research Journal of Applied Sciences, Engineering and Technology*, Reading, UK, v. 7, p. 364–373, 01 2014.
- BASU, M.; GAUGHAN, K.; COYLE, E. Harmonic distortion caused by ev battery chargers in the distribution systems network and its remedy. In: 39TH INTERNATIONAL UNIVERSITIES POWER ENGINEERING CONFERENCE, 2004. UPEC 2004, 39., 2004, Bristol, UK. **Anais[...]**. [S.l.], 2004. v. 1, p. 869–873.
- BECCALI, M. et al. Forecasting daily urban electric load profiles using artificial neural networks. *Energy Conversion and Management*, London, v. 45, n. 18-19, p. 2879–2900, 2004.
- BRUCE, A.; JURKE, S.; THOMSON, P. Forecasting load-duration curves. *Journal of Forecasting*, Oxford, v. 13, n. 6, p. 545–559, 1994.
- 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*, New York, p. 1–5, 2019.
- CHOW, T. W. S.; LEUNG, C. T. Neural network based short-term load forecasting using weather compensation. *IEEE Transactions on Power Systems*, Piscataway, v. 11, n. 4, p. 1736–1742, 1996.
- CHUNLIN, G. et al. A method of electric vehicle charging load forecasting based on the number of vehicles. In: INTERNATIONAL CONFERENCE ON SUSTAINABLE POWER GENERATION AND SUPPLY (SUPERGEN 2012), 2012, Hangzhou. **Anais[...]**. [S.l.]: Hangzhou, China, 2012. p. 1–5.

- CLEMENT-NYNS, K.; HAESSEN, E.; DRIESEN, J. The impact of charging plug-in hybrid electric vehicles on a residential distribution grid. *Power Systems, IEEE Transactions on*, Piscataway, v. 25, p. 371 – 380, 03 2010.
- CUI, H.; HALL, D.; LUTSEY, N. *Update on the global transition to electric vehicles through 2019*. [S.l.], 2020. 15 p.
- DALLINGER, D.; DEAC, G.; WIETSCHEL, M. Integration of intermittent renewable power supply using grid-connected vehicles: A 2030 case study for california and germany. *Applied Energy*, Oxford, v. 104, p. 666–682, 01 2013.
- DENHOLM, P.; SHORT, W. Evaluation of utility system impacts and benefits of optimally dispatched plug-in hybrid electric vehicles (revised). *Contract*, Darien, 01 2006.
- DHARMAKEERTHI, C.; MITHULANANTHAN, N.; SAHA, T. Impact of electric vehicle fast charging on power system voltage stability. *International Journal of Electrical Power and Energy Systems*, London, v. 57, p. 241–249, 2014.
- DULEEP, G. et al. Impacts of electric vehicles - assessment of electric vehicle and battery technology. *CE Delft*, v. 2, p. 9–29, 01 2011.
- 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.]: San Diego, 1991, (Control and Dynamic Systems, v. 41). p. 359 – 461.
- EPA. *Multipollutant Comparison*. 2016. Acessado: 05 dez. 2020. Disponível em: <<https://www.epa.gov/air-emissions-inventories/multi-pollutant-comparison>>. Acesso em: 05 dez. 2020.
- EV, D. C. The electric vehicle world sales database. 2020. Disponível em: <<http://www.ev-volumes.com/datacenter/>>. Acesso em: 28 nov. 2020.
- FAN, Y. et al. Impact of electric vehicle charging on power load based on tou price. *Energy and Power Engineering*, Irvine, v. 05, p. 1347–1351, 01 2013.
- FAN, Y. et al. A review on air emissions assessment: Transportation. *Journal of Cleaner Production*, Amsterdam, v. 194, p. 673–684, 09 2018.
- FHWA. *Highway Statistics Series*. 2018. Acessado: 05 nov. 2020. Disponível em: <<https://www.fhwa.dot.gov/policyinformation/statistics.cfm>>. Acesso em: 19 nov. 2020.
- FORESEE, F. D.; HAGAN, M. Gauss-newton approximation to bayesian learning. In: PROCEEDINGS OF INTERNATIONAL CONFERENCE ON NEURAL NETWORKS (ICNN'97). *Anais[...]*. [S.l.]: Houston, 1997. v. 3, p. 1930–1935.
- GESKE, M. et al. Modeling and simulation of electric car penetration in the distribution power system — case study. In: 2010 MODERN ELECTRIC POWER SYSTEMS. *Anais[...]*. [S.l.]: Amsterdam, 2010. p. 1–6.
- GOMEZ, J.; MORCOS, M. M. Impact of ev battery chargers on the power quality of distribution systems. *IEEE Transactions on Power Delivery*, Piscataway, v. 18, n. 3, p. 975–981, 07 2003.

- GROSS, G.; GALIANA, F. D. Short-term load forecasting. *Proceedings of the IEEE*, New York, v. 75, n. 12, p. 1558–1573, 12 1987.
- GUARNIERI, M. When cars went electric, part 1. *IEEE Industrial Electronics Magazine*, Piscataway, v. 5, n. 03, p. 61–62, 03 2011.
- GUINEL, I. Forecasting system energy demand. *Journal of Forecasting*, Oxford, v. 6, n. 2, p. 137–156, 1987.
- GUPTA, P. C.; YAMADA, K. Adaptive short-term forecasting of hourly loads using weather information. *IEEE Transactions on Power Apparatus and Systems*, Piscataway, PAS-91, n. 5, p. 2085–2094, 09 1972.
- HADLEY, S.; W, S. Impact of plug-in hybrid vehicles on the electric grid. Darien, p. 1–31, 10 2006.
- HAYKIN, S. *Neural Networks: Princípios e práticas*. 2. ed. New Jersey, USA: Prentice-Hall, 1999. 823 p.
- HE, F. et al. Optimal deployment of public charging stations for plug-in hybrid electric vehicles. *Transportation Research Part B: Methodological*, Oxford, v. 47, p. 87–101, 01 2013.
- HIPPERT, H.; PEDREIRA, C.; SOUZA, R. Neural networks for short-term load forecasting: A review and evaluation. *IEEE Transactions on Power Systems*, Piscataway, v. 16, n. 1, p. 44 – 55, 02 2001.
- HU, X. et al. Short-term load forecasting with radial basis functions and singular spectrum analysis for residential electric vehicles recharging control. In: IEEE 15TH INTERNATIONAL CONFERENCE ON ENVIRONMENT AND ELECTRICAL ENGINEERING (EEEIC). *Anais[...]*. [S.l.]: Piscataway, 2015. p. 1783–1788.
- JABBOUR, K. et al. Alfa: automated load forecasting assistant. *IEEE Transactions on Power Systems*, Piscataway, v. 3, n. 3, p. 908–914, 08 1988.
- JAHANGIR, H. et al. Charging demand of plug-in electric vehicles: Forecasting travel behavior based on a novel rough artificial neural network approach. *Journal of Cleaner Production*, Amsterdam, v. 229, p. 1029–1044, 08 2019.
- JIANG, C. et al. Method to assess the power-quality impact of plug-in electric vehicles. *IEEE Transactions on Power Delivery*, Piscataway, v. 29, n. 2, p. 958–965, 04 2014.
- KALLIO, M. Master's thesis, *Lämpötilatekijä sähkönkulutuksen ennustamisessa*. Finlândia, 1985. 106 p. Disponível em: <<http://urn.fi/URN:NBN:fi:aalto-2020120235484>>.
- KAMRUZZAMAN, M.; BENIDRIS, M. Effective accessible energy to accommodate load demand of electric vehicles. In: 2018 IEEE INDUSTRY APPLICATIONS SOCIETY ANNUAL MEETING (IAS). *Anais[...]*. [S.l.]: Piscataway, 2018. p. 1–8.
- KARANTA, I.; RUUSUNEN, J. A model for electricity demand forecasting in a communal electric utility. In: SYSTEM MODELLING AND OPTIMIZATION. *Anais[...]*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1990. p. 790–799.

- KERMANSHAHI, B. et al. Artificial neural network for forecasting daily loads of a canadian electric utility. In: INTERNATIONAL FORUM ON APPLICATIONS OF NEURAL NETWORKS TO POWER SYSTEMS, 2., 1993. *Anais*[...]. [S.l.], 1993. p. 302–307.
- KHOTANZAD, A. et al. An artificial neural network hourly temperature forecaster with applications in load forecasting. *IEEE Transactions on Power Systems*, Piscataway, v. 11, n. 2, p. 870–876, 05 1996.
- KINTNER-MEYER, M. et al. *Impact Assessment of Plug-in Hybrid Vehicles on the U.S. Power Grid*. [S.l.], 2010.
- KROSE, B.; SMAGT, P. van der; SMAGT. An introduction to neural networks. *Journal of Computer Science* 48, Amsterdam, v. 48, p. 136, 01 1993.
- KWANG-HO, K. et al. Implementation of hybrid short-term load forecasting system using artificial neural networks and fuzzy expert systems. *IEEE Transactions on Power Systems*, Piscataway, v. 10, n. 3, p. 1534–1539, 08 1995.
- LEE, D. H. et al. Forecasting of Electric Vehicles Charging Pattern Using Bayesians method with the Convolustion. *IFAC-PapersOnLine*, Amsterdam, v. 52, n. 4, p. 413–418, 06 2019.
- LEE, K. et al. Short-term load forecasting using diagonal recurrent neural network. In: SECOND INTERNATIONAL FORUM ON APPLICATIONS OF NEURAL NETWORKS TO POWER SYSTEMS, 2., 1993, Yokohama. *Anais*[...]. [S.l.]: Piscataway, 1993. p. 227–232.
- LEE, Z. J.; LI, T.; LOW, S. H. ACN-Data: Analysis and Applications of an Open EV Charging Dataset. In: PROCEEDINGS OF THE TENTH INTERNATIONAL CONFERENCE ON FUTURE ENERGY SYSTEMS. *Anais*[...]. [S.l.], 2019. (e-Energy '19).
- LÉGIFRANCE. *LOI n° 2015-992 du 17 août 2015 relative à la transition énergétique pour la croissance verte*. 2015. Acessado: 28 jan. 2021. Disponível em: <www.legifrance.gouv.fr/eli/loi/2015/8/17/2015-992/jo/texte>. Acesso em: 28 jan. 2021.
- LIU, Q. et al. The impact of electric vehicle charging station on the grid. In: STATE GRID HENAN ELECTRIC POWER COMPANY LUOYANG POWER SUPPLY COMPANY. *Anais*[...]. [S.l.]: Tulsa, 2015.
- LONERGAN, T.; RINGWOOD, J. Linguistic modelling of short-timescale electricity consumption using fuzzy modelling techniques. In: PROCEEDINGS OF THE IRISH DSP AND CONTROL COLLOQUIUM (IDSPCC), 1995, Belfast. *Anais*[...]. [S.l.]: Belfast, 1995.
- LOPES, J. A. P.; Soares, F. J.; Almeida, P. M. R. Integration of electric vehicles in the electric power system. *Proceedings of the IEEE*, Piscataway, v. 99, n. 1, p. 168–183, 01 2011.
- LOUIE, H. M. Time-series modeling of aggregated electric vehicle charging station load. *Electric Power Components and Systems*, New York, v. 45, n. 14, p. 1498–1511, 12 2017.

- LOWELL, D.; HUNTINGTON, A. *Overview*. 2019. Acessado: 14 jun. 2020. Disponível em: <<http://www.mjbradley.com/>>. Acesso em: 14 jun. 2020.
- LU, Y. et al. The application of improved random forest algorithm on the prediction of electric vehicle charging load. *Electrical Power and Energy System*, Oxford, v. 11, n. 11, 11 2018.
- MA, C. T. System planning of grid-connected electric vehicle charging stations and key technologies: A review. *Electrical Power and Energy System*, Oxford, v. 12, n. 21, 2019.
- MACKAY, D. J. Bayesian interpolation. *Neural Computation*, Cambridge, v. 4, n. 3, p. 415–447, 1992.
- MAJIDPOUR, M. et al. Forecasting the EV charging load based on customer profile or station measurement? *Applied Energy*, Oxford, v. 163, p. 134–141, 02 2016.
- MALONE, T. W. Modeling coordination in organizations and markets. *Management Science*, Catonsville, v. 33, n. 10, p. 1317–1332, 06 1988.
- MCCARTHY, D.; WOLFS, P. The hv system impacts of large scale electric vehicle deployments in a metropolitan area. In: AUSTRALASIAN UNIVERSITIES POWER ENGINEERING CONFERENCE, Christchurch, New Zealand. *Anais[...]*. [S.l.], 2010. v. 20, p. 1–6.
- MEHRA, R. On the identification of variances and adaptive kalman filtering. *IEEE Transactions on Automatic Control*, 04 1970.
- MEHTA, A. et al. A multi-layer artificial neural network architecture design for load forecasting in power system. *International Journal of Applied Mathematics and Computer Science*, Zielona Gora, v. 10, p. 227–240, 04 2007.
- METAXIOTIS, K. et al. Artificial intelligence in short term electric load forecasting: a state-of-the-art survey for the researcher. *Energy Conversion and Management*, London, v. 44, n. 9, p. 1525 – 1534, 06 2003.
- MINSKY, M.; PAPERT, S. Perceptrons - an introduction to computational geometry. *science*, Washington, v. 165, 08 1969.
- MUKHERJEE, J. C.; GUPTA, A. Distributed charge scheduling of plug-in electric vehicles using inter-aggregator collaboration. *IEEE Transactions on Smart Grid*, Piscataway, v. 8, n. 1, p. 331–341, 01 2017.
- MURATORI, M. Impact of uncoordinated plug-in electric vehicle charging on residential power demand. *London*, Springer US, v. 3, n. 3, p. 193–201, 01 2018. ISSN 20587546.
- MURATORI, M. et al. Energy consumption of residential hvac systems: A simple physically-based model. In: POWER AND ENERGY SOCIETY GENERAL MEETING. *Anais[...]*. [S.l.], 2012. p. 1–8.
- MURATORI, M. et al. A highly resolved modeling technique to simulate residential power demand. *Applied Energy*, Oxford, v. 107, p. 465–473, 07 2013.
- MURTO, P.; HäMäläINEN, R. P. *Neural network models for short-term load forecasting*. [S.l.], 1998.

- NAIR, A. S. et al. Optimal operation of residential evs using dnn and clustering based energy forecast. In: 2018 NORTH AMERICAN POWER SYMPOSIUM (NAPS), New York. **Anais**[...]. [S.l.], 2018. p. 1–6.
- NGUYEN, D.; WIDROW, B. Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. In: IJCNN INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS. **Anais**[...]. [S.l.]: Oxford, 1990. v. 3, p. 21–26.
- NOR, J. K. *Patent: Charging Station For Electric Vehicles, USOO5202617A*. [S.l.]: Mississauga, Canadá, 1993.
- NREL. *National Renewable Energy Laboratory*. 2019. Acessado: 14 dez. 2020. Disponível em: <<http://www.nrel.gov/>>. Acesso em: 14 dez. 2020.
- O'DONOVAN, T. M. *Short Term Forecasting: An introduction to the Box-Jenkins approach*. 2. ed. Hoboken, New Jersey: John Wiley & Sons, 1983. 823 p.
- PAPADOPOULOS, P. et al. Electric vehicles' impact on british distribution networks. *Electrical Systems in Transportation*, Oxford, v. 2, p. 91–102, 09 2012.
- PARK, D. C. et al. Electric load forecasting using an artificial neural network. *IEEE Transactions on Power Systems*, Piscataway, v. 6, n. 2, p. 442–449, 1991.
- PUTRUS, G. et al. Impact of electric vehicles on power distribution networks. In: IEEE VEHICLE POWER AND PROPULSION CONFERENCE. **Anais**[...]. [S.l.], 2009. v. 5, p. 827 – 831.
- QUIRÓS-TORTÓS, J.; OCHOA, L.; LEES, B. A statistical analysis of ev charging behavior in the uk. In: IEEE PES INNOVATIVE SMART GRID TECHNOLOGIES LATIN AMERICA (ISGT LATAM). **Anais**[...]. [S.l.]: Piscataway, 2015. p. 445–449.
- RASKIN, A.; SAURIN, S. *The Emergence of Hybrid Vehicles*. [S.l.], 2006. 56 p.
- RICHARDSON, D. B. Electric vehicles and the electric grid: A review of modeling approaches, Impacts, and renewable energy integration. *Renewable and Sustainable Energy Reviews*, Piscataway, v. 19, n. C, p. 247–254, 03 2013.
- RICHARDSON, I. et al. Domestic electricity use: A high-resolution energy demand model. *Energy and Buildings*, Amsterdam, v. 42, p. 1878–1887, 10 2010.
- RINGWOOD, J.; BOFELLI, D.; MURRAY, F. Forecasting electricity demand on short, medium and long time scales using neural networks. *Journal of Intelligent and Robotic Systems*, Dordrecht, v. 31, p. 129–147, 05 2001.
- ROE, C. et al. Power system level impacts of plug-in hybrid electric vehicles using simulation data. In: IEEE ENERGY 2030 CONFERENCE, Atlanta. **Anais**[...]. [S.l.], 2008. p. 1–6.
- RUMELHART, D.; GEOFFREY, E. H.; WILLIAMS, R. J. Learning representations by back-propagating errors. *London*, v. 323, p. 533–536, 10 1986.
- SCHROEDER, A. Modeling storage and demand management in power distribution grids. *Applied Energy*, Oxford, v. 88, n. 12, p. 4700–4712, 12 2011.

- SHAFIEE, S.; FOTUHI-FIRUZABAD, M.; RASTEGAR, M. Investigating the impacts of plug-in hybrid electric vehicles on power distribution systems. *IEEE Transactions on Smart Grid*, Piscataway, v. 4, n. 3, p. 1351–1360, 09 2013.
- Toyoda, J.; Chen, M.; Inoue, Y. An application of state estimation to short-term load forecasting, part ii: Implementation. *IEEE Transactions on Power Apparatus and Systems*, Piscataway, PAS-89, n. 7, p. 1683–1688, 09 1970.
- UNCC. *Reporting Requirements*. 2018. Acessado: 20 nov. 2020. Disponível em: <<https://unfccc.int/process-and-meetings/transparency-and-reporting/reporting-and-review-under-the-convention/greenhouse-gas-inventories-annex-i-parties/reporting-requirements>>. Acesso em: 20 nov. 2020.
- VAYÁ, M.; ANDERSSON, G. Centralized and decentralized approaches to smart charging of plug-in vehicles. In: IEEE POWER AND ENERGY SOCIETY GENERAL MEETING. *Anais*[...]. [S.l.], 2012. p. 1–8.
- WATSON, M.; PASTUSZEK, L.; CODY, E. Forecasting commercial electricity sales. *Journal of Forecasting*, Oxford, v. 6, n. 2, p. 117–136, 07 1987.
- WERBOS, P. Beyond Regression : New Tools for Prediction and Analysis in the Behavioral. Cambridge, n. January 1974, p. 906, 01 1974.
- WILLIS, H. L. *Power Distribution Planning Reference Book*. [S.l.]: Kansas, 2004.
- XIAOBO, X.; LIU W.AND XI, Z.; TIANYANG, Z. Short-term load forecasting for the electric bus station based on gra-de-svr. In: IEEE INNOVATIVE SMART GRID TECHNOLOGIES - ASIA (ISGT ASIA), Kuala Lumpur. *Anais*[...]. [S.l.], 2014. p. 388–393.
- XYDAS, E. S. et al. Forecasting electric vehicle charging demand using support vector machines. In: INTERNATIONAL UNIVERSITIES’ POWER ENGINEERING CONFERENCE (UPEC), Bahawalpur, Paquistão. *Anais*[...]. [S.l.], 2013. v. 48, p. 1–6.
- 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*, Basel, Suíça, v. 11, n. 6, 06 2018.
- ZHANG, Y. et al. Research of voltage stability analysis method in distribution power system with plug-in electric vehicle. In: IEEE PES ASIA-PACIFIC POWER AND ENERGY ENGINEERING CONFERENCE (APPEEC), Xi’an, China. *Anais*[...]. [S.l.], 2016. p. 1501–1507.
- ZHU, J. et al. Short-term load forecasting for electric vehicle charging stations based on deep learning approaches. *Applied Sciences (Switzerland)*, Basel, Suíça, v. 9, n. 9, 2019.
- ZHU, J. et al. Electric vehicle charging load forecasting: A comparative study of deep learning approaches. *Energies*, Basel, Suíça, v. 12, n. 14, p. 1–19, 2019.