

# Aplicação de Modelos de Aprendizado de Máquina na Predição de Curvas de Carga

C. A. Urzagasti, J.J.G. Ledesma and J.N. Maciel

**Abstract**— One of the most important research topics in Smart Grid technology is load curve prediction. This allows electric power transmission and distribution operators to carry out operations with greater efficiency in the dispatch of electric power. Therefore, the relevance of knowing the characteristics of the electricity consumption profiles of consumers is highlighted, in order to then make load predictions, which can be done in different prediction horizons and with different methods. Therefore, this study aims to present machine learning techniques to perform load predictions within 30 minutes, ANN and LSTM techniques are analyzed. From a database containing load curve information of a 4-year distribution system (2013 to 2016), 4 machine learning models were made, two from RNA and two from LSTM. A comparison of both models was made, where a better performance was found for the LSTM models with accuracy greater than 0.95. It should be noted that this work only made a comparison for a single forecast horizon, therefore it remains as future work to analyze for different forecast horizons and search for new open databases to complement this study.

**Keywords** — Load Forecasting, Short-term Load Forecasting, MLP, LSTM

## I. INTRODUÇÃO

Os sistemas elétricos de potência (SEP) tem como função garantir que usuários residenciais, comerciais ou industriais, recebam energia elétrica com qualidade e confiabilidade do fornecimento de energia elétrica [1]. Nos últimos anos, ocorreu o desenvolvimento tecnológico dos SEP, onde ressalta-se a integração de tecnologias de informação e automação da rede elétrica vinculado ao conceito de *Smart Grids*, os quais permitem gerenciar o fluxo de energia bidirecional. Estas tecnologias possibilitam gerar grandes volumes de dados de medições vinculadas ao funcionamento do sistema elétrico de potência. Portanto, existe o desafio de transformar dados em informações significativas que proporcionam aprimorar o gerenciamento do sistema elétrico. [2]

Deste modo, é de grande importância a previsão da carga dos consumidores [3], com vantagens para empresas de distribuição de energia elétrica, as quais visam identificar e analisar comportamento da carga demandada pelos consumidores, possibilitando reduzir custos de produção ao

detectar descargas ineficientes [4], além disso, permite detectar pontos de demanda máxima e mínima contribuindo para um melhor planejamento dos SEP [5].

As pesquisas da literatura apontam um aumento no uso de baterias para armazenamento de energia elétrica, que tem como base fundamental no processo de transição energética, que significa a passagem de uma matriz energética focada nos combustíveis fósseis para uma com baixa ou zero emissões de carbono, baseada em fontes renováveis [6] – [9].

Já outros estudos mencionam a importância de prever picos de cargas para realizar operações de gestão de energia com maior eficiência e autonomia, utilizando sistemas de baterias em conjuntos com sistemas de energia solar fotovoltaica, com objetivo de suprir picos de demandas [10], [11].

Por tanto, este trabalho contribui no sentido de apresentar modelos de aprendizado de máquina, com diferentes configurações experimentais, contribuindo com resultados comparativos de diferentes modelos, assim contribuindo para futuras pesquisas sobre predição de curvas de cargas de curto prazo.

O Brasil está numa situação diferente de países desenvolvidos, pois, ainda passa por um momento de inflexão tecnológica relativa à digitalização, já que as empresas de distribuição de energia elétricas brasileiras, na grande maioria ainda não possuem sistemas públicos que demonstrem o consumo individual ou regional em tempo real para usuários finais. O procedimento de leitura mensal do consumo ainda realizado manualmente para aproximadamente 90% do território nacional. Consequentemente existe uma insuficiência de base de dados que permitam realizar pesquisas para entender a dinâmica das necessidades energéticas do país [14].

Com relação às técnicas de predição de carga, a carga pode ser analisada em diferentes horizontes temporais [15], no caso de este trabalho será analisada em horizontes de curto prazo. No entanto, não existe um consenso literário definido sobre a exata delimitação temporal destes horizontes de predição. Em geral, pode classificar-se as predições em curto prazo para períodos inferior a 24 horas (*Short-Term Load Forecasting* - STLF), médio prazo para horizontes entre 24 horas até uma semana (*Medium-Term Load Forecasting* - MTLF) e longo prazo para períodos acima de uma semana (*Long-Term Load Forecasting* - LTLF). Considerando o constante crescimento do consumo de carga e a importância cada vez maior de prever o comportamento futuro dos consumos de energia e potência, as empresas de transmissão e distribuição de energia elétrica consideram relevante a predição de carga de curto prazo, para a gestão energética e operações mais eficientes de despacho de energia [16]. Por isto, este trabalho focou na STLF considerado

C.A. Urzagasti, graduando no curso de Engenharia de Energía, Universidade Federal da integração Latinoamericana – UNILA, e-mail: [carlos.uzzagasti@aluno.unila.edu.br](mailto:carlos.uzzagasti@aluno.unila.edu.br)

J. J. G. Ledesma, professor da Universidade Federal da Integração Latino-Americana - (UNILA), Foz do Iguacu, Paraná, Brasil, e-mail: [jorge.ledesma@unila.edu.br](mailto:jorge.ledesma@unila.edu.br).

J.N. Maciel, professor da Universidade Federal de Integración Latino-Americana - (UNILA), Foz do Iguacu, Paraná, Brasil, e-mail: [joylan.maciell@unila.edu.br](mailto:joylan.maciell@unila.edu.br)

o horizonte de predição de 30 minutos.

Atualmente, tem-se pesquisas sobre a previsão da carga STLF, entre eles, cita-se técnicas de Series Temporais [17], Métodos baseados em regressão [18], Suporte de Máquina Vectorial [19], algoritmos de decisão e métodos de inteligência artificial [20]. Da mesma forma, evidencia-se que fatores meteorológicos podem influenciar na análise e na modelagem da carga. Entre esses fatores destaca-se que a variável da temperatura ambiente tem maior impacto na correlação para os métodos de STLF, porque está diretamente relacionada na dinâmica de consumo elétrico [13]

Diante deste contexto, destaca-se a relevância de conhecer a caracterização da carga dos consumidores, definida como a potência absorvida por todos seus equipamentos elétricos [1]. Considerando que o regime dessas cargas não é fixo, varia de um valor mínimo a um valor máximo, por tanto o sistema de distribuição deve estar preparado para atender as demandas solicitadas [12]. É importante mencionar que a dinâmica da carga pode variar de acordo a localização geográfica, sazonalidade, aspecto socioeconômicos e eventos culturais, representando um desafio à operação do SEP. Além disso, a carga também pode ser analisada em consumo de potência ativa e potência reativa [13], neste trabalho foi realizado um estudo no consumo de carga de potência ativa de um alimentador primário.

Por tanto, este estudo tem como objetivo aplicar técnicas de aprendizado de máquina para realizar a predição da curva de carga de curto prazo (30 minutos), a partir de uma única base de dados com históricos de cargas e variáveis meteorológicas, os dados foram obtidos da empresa de transmissão e distribuição elétrica de França (RTE) [41]. Desse modo, com esta análise pretende-se contribuir para desenvolvimento das tecnologias de *Smart Grid*, fomentando e ampliando estudos nesta relevância área de pesquisa. Portanto, os objetivos específicos deste estudo contemplam: (i) revisão literária sobre STLF e algoritmos de aprendizado de máquina, (ii) seleção e experimentação dos métodos de aprendizado de máquina aplicados na predição de STLF, (iii) análise comparativa dos resultados e acurácia de predição dos modelos de STLF empregados.

Com base nisso, na Seção II é apresentada uma revisão dos trabalhos relacionados à predição de carga e se classifica as principais referências com base nos horizontes de predição. Na Seção III realiza-se uma fundamentação teórica abordando detalhes sobre o sistema elétrico de potência, métodos de inteligência artificial e principais indicadores de desempenho utilizados para avaliar os resultados dos modelos. Na Seção IV são apresentados os materiais e o método utilizados nesta pesquisa, incluindo a base de dados empregada. Na Seção V são descritos os resultados e discussões. Por fim, na Seção VI são descritas as conclusões, as considerações finais e os trabalhos futuros.

## II. ESTADO DA ARTE

Nesta seção foi desenvolvido uma revisão sistemática da literatura sobre os principais estudos sobre a predição de curvas de carga, com base nisso foi realizada a escolha dos métodos de

aprendizado de máquina que foram utilizados neste trabalho.

Uma quantidade significativa de pesquisas tem sido realizada nos últimos anos para desenvolver métodos de predição de carga [21], A partir destes estudos, o nível de significância de algumas variáveis exógenas dentro do comportamento típico da demanda energética pode variar por causa dos horizontes de predição [22]. Portanto, a seguir apresenta uma revisão destes estudos publicados sob o ponto de vista da influência dos parâmetros e modelos nos resultados de predição de carga.

Entre os modelos aplicados na literatura, destaca-se o método ARIMA (*Auto Regressive Integrated Mobile Médio*), cujo desempenho mostrou-se compatível para predições de curto prazo, conforme os trabalhos [23]–[25] Logo, em trabalhos como propostos em [23], [24], [26]–[30] as variáveis de entrada mais utilizadas são os históricos da demanda de energia elétrica e variáveis climáticas, tais como a temperatura, umidade relativa e pressão atmosférica. Assim, destacam modelos de *Machine Learning* (ML) e *Deep Learning* (DL) como as (Redes Neurais Artificiais - RNA), (Redes de Memória longa de curto prazo – LSTM), (Máquina de Vetores de Suporte – SVM), (Multicamadas Perceptron – MLP). Na Tabela I é apresentado os principais métodos aplicados na predição de carga, detalhando as variáveis de entrada e horizontes temporais empregados.

Na Tabela I, evidencia-se que os métodos de ML e DP estão entre as técnicas mais utilizadas no estado da arte para predição da curva de carga de curto prazo. Na literatura não estabelece uma técnica ideal de previsão. Neste aspecto o estado da arte converge na medida em que sua adequação depende do caso de aplicação e o tipo de série temporal a ser estimada.

## III. FUNDAMENTAÇÃO TEÓRICA

Nesta seção, descreve-se as características de um sistema elétrico de potência, com enfoque em diferentes tipos de curvas de cargas. Também se detalham os métodos de previsão de carga que foram utilizados neste trabalho, assim sendo os métodos de MLP e LSTM.

### A. Sistema elétrico de potência e curvas de cargas

Os sistemas elétricos de potência, tem como função essencial fornecer energia elétrica aos usuários, com qualidade adequada, e no instante que for solicitada. Um SEP é formado por centrais elétricas, subestações de transformação, linhas e receptores de potência, todos eles ligados entre si. Logo, ele pode ser dividido em três grandes blocos: geração, transmissão e distribuição [1] conforme a Fig. 1.

Na elaboração de este trabalho, os modelos preditivos foram realizados com base nas medições da saída de uma subestação de distribuição elétrica francesa, medidas no transformador de potência no começo da distribuição primária.

Além disso, um SEP pode ser classificado por padrões de consumo a través de uma análise dos valores de energia consumida

TABELA I  
PRINCIPAIS MÉTODOS DE PREDIÇÃO DE CURVA DE CARGA PARA DIFERENTES HORIZONTES DE PREDIÇÃO

Horizonte de predição	Método de predição	Métricas de Erro	Variáveis de entrada	Variável de saída	Dataset	Ano de publicação	Ref.
5 min	ARIMA, MLP	MAPE	Horas, dias, carga	Potência Ativa em [MW]	Sete dias de medições de carga em MW com intervalos de 5 minutos, na subestação de Ubatuba-SP.	2009	[24]
1h	MLP	MAPE, $R^2$	Temperatura média, máxima e mínima, mês, hora, dia, carga, umidade relativa	Potência Ativa em [W]	Quatro meses de medições de duas empresas de distribuição de energia elétrica com localizações geográficas diferentes, nos EUA	2014	[26]
30 min	MLP	MAE, MAPE	Potência, temperatura, frequência, ciclos	Potência Ativa em [MW]	18 meses de medições de duas subestações da rede de distribuição francesa	2018	[27]
24h 48h	LSTM, SVM	MAPE, $R^2$	Temperatura, dia da semana, feriados, hora	Potência Ativa em [MW]	Dois anos de medições de um sistema de distribuição de energia elétrica	2019	[31]
1h	MLP SVM LSTM	RMSE MAE $R^2$	Temperatura, velocidade do vento, umidade, dia, hora, mês, estação do ano, pressão atm., tipo de nuvens	Potência Ativa em [MW]	Dados de carga da região da Mongólia Interior, dos anos 2004 até 2006. Com dois anos de treinamento, 11 meses de teste e 1 mês de validação	2020	[29]
1h 24h	AD MLP SVM	MSE MAE $R^2$	Temperatura, velocidade do vento, umidade, dia, hora, mês, pressão atm.	Potência Ativa [P.U.]	Dados de dois transformadores instalados em duas subestações da região sul do Brasil, nas cidades de Santa Maria e São Leopoldo	2020	[30]

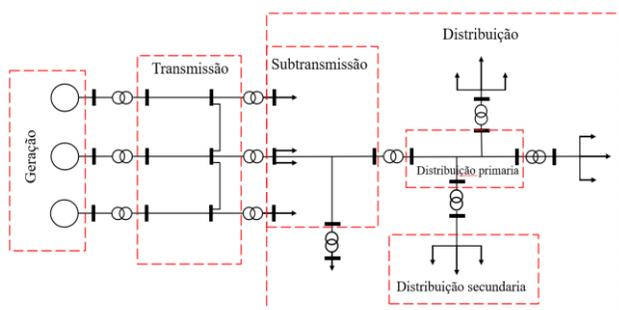


Fig. 1. Representação de um sistema elétrico de potência. Note que este se encontra dividido em geração, transmissão e distribuição,

Independentemente do tipo de consumidor, o consumo de energia elétrica possui um comportamento sazonal e cíclico que pode ser evidenciado através das tipologias de curvas do consumo dos usuários. O comportamento regular desta curva é chamado de perfil de consumo, conforme ilustrado na Fig. 2, que também representa um fluxo de carga de um sistema de distribuição primária e secundária [32].

Conseqüentemente, nos sistemas de distribuição, são gerados perfis de consumo definidos como curvas de cargas, que apresentam a demanda em função do tempo,  $D(t)$ , para um período de tempo ( $T$ ) conforme a Fig. 3 que representa uma curva de carga comercial num período de 24 horas. A curva de carga é delineada como a energia total consumida no período,  $\epsilon_T$ , é medida pela área entre a curva e eixo dos tempos

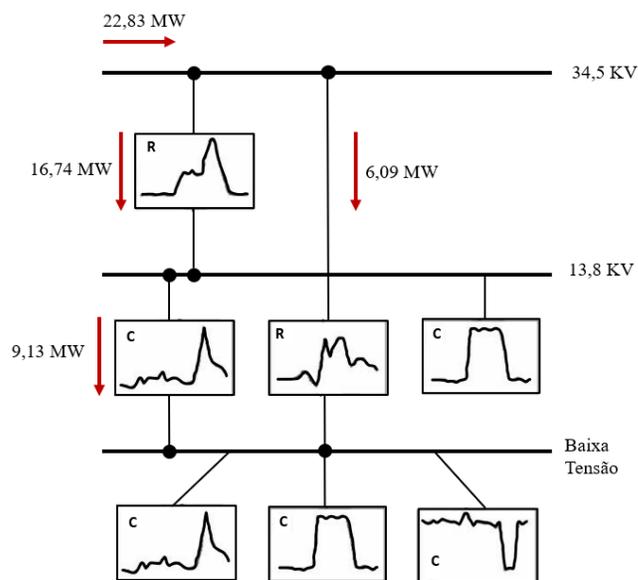


Fig. 2. Níveis de tensão e perfis típicos de consumo para barramentos de média e baixa tensão do sistema de distribuição de energia elétrica

As curvas de cargas podem variar de acordo a sazonalidade do ano, onde o consumo de carga das pessoas está diretamente vinculado com as condições climáticas e estações do ano. À medida que diminui a temperatura, aumenta o consumo de carga, isso é devido ao maior uso de chuveiros elétricos, aquecedores ou outros equipamentos geradores de calor. [3]

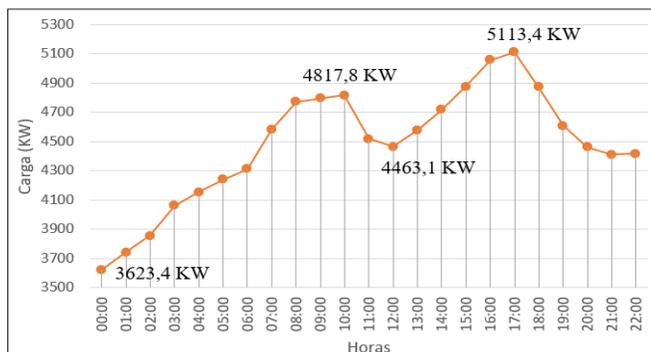


Fig. 3. Representação da curva de carga comercial típica num período de 24 horas, observe-se que o maior pico de carga encontrasse no horário 17:00 a 18:00h com um valor de 5113,4 KW

A partir da revisão da literatura sobre a STLF, apenas deve ser gerado um método de predição para cada tipo de curva de carga. Porém, devido a semelhança nos procedimentos, a mesma metodologia pode ser aplicada para qualquer tipo de perfil de carga. [33]

### B. Métodos de aprendizado de máquina

Nesta Seção, são mencionados dois métodos, empregados nesta pesquisa. Eles serão detalhados a seguir:

#### 1. Rede Neural Artificial

As Redes Neurais Artificiais (RNAs) são formadas por um conjunto de unidades básicas de processamento (neurônios) interconectadas e organizadas em camadas. Cada neurônio produz sua saída tomando uma combinação linear de sinais de entrada e transformando-a usando uma função chamada função de activação. Os pesos dessa combinação linear estão associados às conexões numéricas (pesos sinápticos) que ligam o neurônio a todos os neurônios pertencentes à camada superior.

A saída de um neurônio em função dos sinais de entrada pode ser escrita como

$$y_j = f\left(\sum_{i=1}^n w_{ji}x_i - b\right) \quad (1)$$

onde  $y_j$  é a saída do neurônio genérico pertencente à camada  $j$ ;  $x_i$  são os sinais de entrada para o neurônio;  $w_{ji}$  é o peso sináptico associado à conexão entre neurônios genéricos pertencentes às camadas  $j$  e  $i$ , respectivamente;  $b$  é o termo de polarização (outro peso do neurônio);  $f$  é a função de activação, conforme representado na Fig. 4(a).

Dentro dos estudos das RNA se encontra o *Perceptron Multicamadas* (MLP) caracterizado por possuir várias camadas, porém, a arquitetura mais frequentemente empregada consiste em três camadas: uma camada de entrada, uma camada oculta e uma camada de saída como é representado na Fig. 4(b) [34].

Em um MLP totalmente conectado, cada neurônio de uma camada está conectado a cada neurônio da próxima camada. Não há conexões de *feedback*. A aprendizagem é a fase mais importante na utilização de um modelo baseado em RNA.

Durante o aprendizado, conjuntos de padrões de entrada-saída conhecidos são apresentados à rede, e os pesos de conexão entre as unidades de processamento são ajustadas de acordo com as regras de aprendizado impostas. O algoritmo de atualização de peso mais utilizado para o treinamento de redes MLP é o chamado de *backpropagation*.

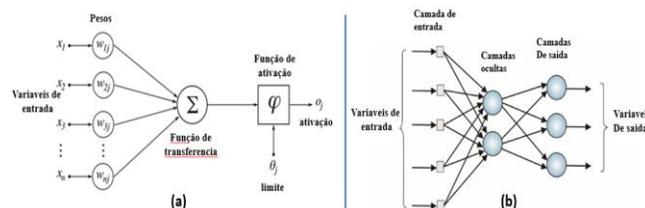


Fig. 4. Na figura (a) está representado um exemplo de um neurônio, logo na figura (b) corresponde uma estrutura de uma RNA

A idéia básica do algoritmo de aprendizado de *backpropagation* consiste na repetição aplicação da regra para calcular a influência de cada peso na rede em relação a uma função de erro arbitrário.

$$\frac{\partial E}{\partial w_{ji}} = \frac{\partial E}{\partial o_i} \frac{\partial o_j}{\partial net_j} \frac{\partial net_j}{\partial w_{ji}} \quad (2)$$

onde  $w_{ji}$  é o peso associado à conexão do neurônio  $i$  ao neurônio  $j$ ,  $o_j$  é a saída e  $net_j$  é a soma ponderada das entradas para o neurônio  $j$ . Uma vez que a derivada parcial para cada peso é conhecida, o objetivo de minimizar a função de erro é alcançado executando um simples gradiente descendente, de acordo com a regra de atualização.

$$w_{ji}(t+1) = w_{ji}(t) - \eta \frac{\partial E}{\partial w_{ji}}(t) \quad (3)$$

onde  $\eta$  é a taxa de aprendizado, um termo que reduz a derivada e tem um efeito importante no tempo necessário até que a convergência seja alcançada. Se  $\eta$  for muito pequeno, a convergência requer muitos passos até chegar a uma solução aceitável. Por outro lado, uma grande taxa de aprendizado pode levar a oscilações, evitando que o erro caia abaixo de um valor limite fixo. O valor de  $E(t)$  está relacionado com a diferença, no momento da iteração  $t$ , entre os valores de saída e de destino. [35], [36]. Na prática, não foi utilizado o desenvolvimento matemático, pois esses algoritmos já são implementados em bibliotecas de aprendizado de máquinas utilizadas e explicadas na Seção de materiais e métodos

#### 2. Redes de memória longa de curto prazo (LSTM)

A rede LSTM é uma variante especial das Redes Neurais Recorrentes (RNR) capaz de aprender dependências de longo prazo. Ela foi projetada especificamente para evitar o problema de dissipação/explosão do gradiente. Uma LSTM é adequada para classificar e prever dados de séries temporais e sua

principal característica é que existe uma célula de memória conectada na estrutura LSTM ao longo do tempo que continua rastreando os estados internos aprendidos das entradas sequenciais. O estado interno e a entrada em uma instância de tempo determinam a saída desse intervalo de tempo específico juntos [37].

Essa arquitetura comum da célula de LSTM é composta por um estado da célula ( $ct$ ), uma saída chamada de *hidden state* ( $ht$ ), um *input gate* ( $it$ ), um *output gate* ( $ot$ ) e um *forget gate* ( $ft$ ) apresentado na Fig. 5. A principal fórmula de cálculo do LSTM [38] é como segue:

$$f_t = \sigma(W_f(h_{t-1}, x_t) + b_f) \quad (4)$$

$$i_t = \sigma(W_i(h_{t-1}, x_t) + b_i) \quad (5)$$

$$g_t = \tanh(W_g(h_{t-1}, x_t) + b_g) \quad (6)$$

$$c_t = f_t c_{t-1} + i_t g_t \quad (7)$$

$$o_t = \tanh(W_o(h_{t-1}, x_t) + b_o) \quad (8)$$

$$h_t = o_t \tanh(c_t) \quad (9)$$

Onde  $f_t$ ,  $i_t$ ,  $g_t$  e  $o_t$  determinam os valores de saída dos *forget gate*, *input gate*, *update* e *output gate* respectivamente. Logo,  $W_f$ ,  $W_i$ ,  $W_g$  e  $W_o$  demonstram as métricas dos pesos,  $b_f$ ,  $b_i$ ,  $b_g$  e  $b_o$  ilustram os vetores das *bias*,  $c_t$  e  $\sigma$  apresentam a célula de memória e a função de ativação sigmoide, respectivamente. Além disso, as entradas dos 4 *gates* a LSTM com os valores de  $h_{t-1}$  em um passo de tempo passado  $t - 1$  [39]

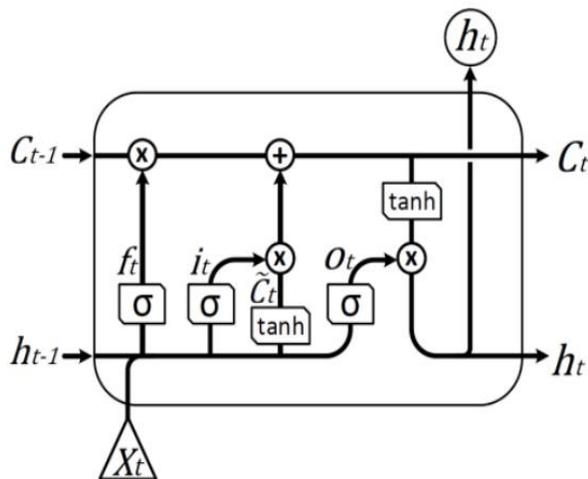


Fig. 5. Representação de uma estrutura LSTM [39]

### C. Indicadores para avaliar o desempenho dos modelos

Existem vários indicadores populares para avaliar o desempenho da previsão, que incluem principalmente erro quadrático médio (RMSE), erro médio absoluto (MAE), erro quadrático médio (MSE) e erro percentual absoluto médio (MAPE). Neste trabalho são utilizadas as métricas de erro  $R^2$ ,  $RMSE$  e  $MAE$  onde o  $R^2$  mensura o coeficiente de determinação parâmetro para determinar acurácia dos resultados, o RMSE mede o erro quadrático médio e MAE

medo o erro médio absoluto [40]. Onde  $y_i$  corresponde ao valor real das medições e  $\gamma_i$  ao valor da predição.

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \gamma_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (10)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \gamma_i)^2}{N}} \quad (11)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \gamma_i| \quad (12)$$

As métricas de erro foram escolhidas com base na revisão da literatura da Seção II, onde se recomenda utilizar esse conjunto de métricas para avaliação do desempenho dos modelos

## IV. MATERIAIS E METODOS

Com base nos estudos anteriormente citados selecionou-se para avaliação comparativa, desta pesquisa, os métodos de MLP e LSTM. Os MLP constituem historicamente os métodos de ML mais utilizados na literatura, enquanto o LSTM são sua evolução e atualmente os mais empregados nas análises de dados em séries temporais com horizontes de predição de curto prazo. A metodologia proposta fundamenta-se na predição de curvas de cargas típicas considerando a influência de variáveis meteorológicas. Neste estudo será empregada uma base de dados de medição de carga de um alimentador primário, com cargas que variam de 2 a 6 MW. Por outro lado, nos itens seguintes são descritos a base de dados que será utilizada, a implementação dos métodos propostos e as ferramentas empregadas na realização experimental dos modelos.

### A. Banco de dados (dataset)

Os modelos de MLP e LSTM foram desenvolvidos e avaliados a partir do *dataset* no período de 2013 à 2016 (Vide a Tabela II), da empresa RTE de transmissão e distribuição de energia elétrica da França [39], a qual disponibiliza dados públicos sobre consumo de energia elétrica.

TABELA II  
NÚMERO DE REGISTROS, HORIZONTE DE PREDIÇÃO E VARIÁVEIS DOS DATASET EMPREGADOS NESTE ESTUDO

Variáveis	RTE dataset [41]			
	Horizonte de predição	Treinamento (2 anos)	Teste (1 ano)	Validação (1 ano)
Temperatura do ar, mês, dia, hora, carga, estação do ano	30 min	35040	8736	8736

Visando evitar *overfitting*, que significa que um modelo de ML se adapta a os dados de treinamento, mas não consegue generalizar para novos dados [38] utilizou-se no experimento a técnica de validação cruzada *3-fold* no *dataset*

Nela, o conjunto de dados se divide em um número  $k$  onde se realiza o treinamento dos modelos de ML, exceto em um ( $k-1$ ) dos conjuntos de dados e, em seguida, se avalia o modelo no conjunto de dados que não foi usado para treinamento. Este processo é repetido  $k$  vezes, com um subconjunto diferente reservado para avaliação (e excluído do treinamento).

Na Tabela III se apresenta a divisão dos dados de treinamento, teste e validação utilizando o método de validação cruzada. Neste caso o ano 2016 será utilizado como um conjunto de dados de teste que o modelo não conhece.

TABELA III  
DIVISÃO DE CONJUNTOS DE DADOS UTILIZADA PARA VALIDAÇÃO CRUZADA

Folds/Anos	2013	2014	2015	2016
Fold 1	Treino	Treino	Teste	Validação
Fold 2	Treino	Teste	Treino	Validação
Fold 3	Teste	Treino	Treino	Validação

Desta forma previne-se o problema de overfitting com os modelos sendo validados com 3 conjuntos distintos de dados. A média destes 3-folds é calculada e considerada para definição do desempenho de acurácia de cada modelo.

### B. Delineamento metodológico e estrutura dos modelos

Para o desenvolvimento metodológico, foi realizado um procedimento sistemático. Primeiramente são carregados os dados brutos do *dataset*, os quais são pré-processados até obter um *dataframe* com as variáveis de entrada e saída. Posteriormente, esses dados são normalizados nua faixa de [0,1] para melhor adequar-se ao treinamento com as bibliotecas de *Machine Learning* utilizadas. Os dados normalizados são separados em dados de treino e teste, sendo então submetidos aos modelos com estruturas previamente configuradas. Isso se repete para cada modelo de MLP e LSTM, conforme observa-se no fluxograma da Fig. 6.

Cada uma das etapas sugeridas, busca seguir um método sistemático para ser aplicado para qualquer tipo de curva de carga. Neste estudo não foram analisados e considerados a zona geográfica, os feriados e os aspectos socioeconômicos. Na Tabela IV estão descritas as variáveis exógenas e endógenas, as configurações dos modelos, a quantidade de dados utilizados para o treinamento, teste e os horizontes de predição considerados.

TABELA IV  
CONFIGURAÇÕES DOS MODELOS MLP E LSTM, UTILIZADAS NESTE ESTUDO

	MLP	LSTM
Variáveis de entrada	Temperatura do ar Mês, hora, minuto	Temperatura do ar Mês, hora, minuto
Variáveis de saída	Carga	Carga
Horizonte de predição	30 min	30 min
Topologia dos modelos	MLP-1 (4x30x30x1) MLP-2 (4x60x1)	LSTM-1 (4x128x64x1) LSTM-2 (4x50x1)
Set de treino	24 meses	24 meses
Set de teste	12 meses	12 meses
Set de validação	12 meses	12 meses
Função de ativação	ReLU	ReLU
Epochs	100	100

As configurações e estrutura dos modelos, foi escolhida como na metodologia proposta em [42] para MLP, e para a estrutura LSTM foi considerada uma configuração com base nos estudos feitos por [43]

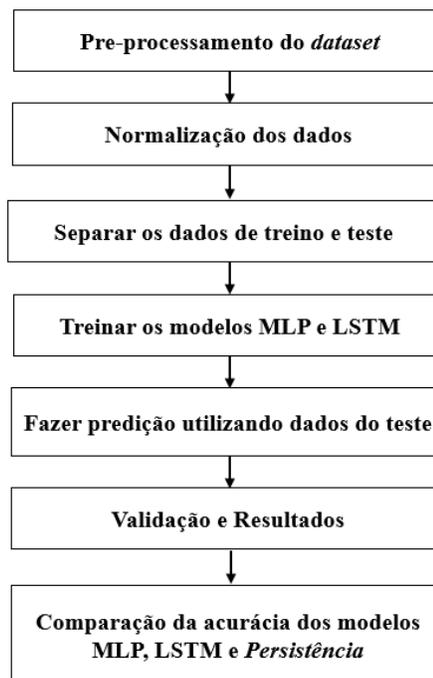


Fig. 6. Detalhamento dos processos realizados na experimentação dos modelos implementados

### C. Ferramentas e tecnologias

Durante a etapa experimental realizada nesta pesquisa foram utilizadas diversas ferramentas digitais, com prioridade em tecnologias open-source. Dentre elas, as principais estão: linguagem de programação Python e bibliotecas relevantes como *Scikit-Learn*, *Keras*, *Numpy* e *Pandas* [44] que são determinantes para criação de modelos de ML. Por outro lado, foi utilizado o ambiente de desenvolvimento *Google Colabority (Colab)* [45] e por último nas análises estatísticas foi utilizado o software livre *Jamovi* [46] Este conjunto de ferramentas e tecnologia é bastante utilizado pelos pesquisadores para desenvolver e testar modelos de ML, por serem de fonte aberta, assim como alguns do Grupo de Pesquisa em Energia & Sustentabilidade Energética da Universidade Federal da Integração Latinoamericana [47], [48]

## V. RESULTADOS E DISCUSSÃO

Após execução experimental, foram obtidos os resultados das métricas de desempenho para os modelos de predição de acordo com as configurações explicadas no Capítulo IV. Foi testado para dois modelos de MLP e dois modelos LSTM, utilizando uma única base de dados, neste caso o *dataset* RTE [41] e também com um único horizonte de predição de 30 min. Além disso, utilizou-se um quinto modelo de persistência (*baseline*) como referencial de comparação. Essa abordagem é

amplamente utilizada na literatura em problemas de regressão. O modelo de persistência é simples e realiza a predição considerando o valor no passo do tempo anterior ( $t - 1$ ) para prever o resultado esperado no tempo ( $t + 1$ ), satisfazendo as três propriedades do algoritmo de persistência: simples, rápido e repetível [38]. Os resultados das avaliações permitem determinar que modelo teve melhor desempenho tomando como referência base os resultados do modelo de persistência

### A. Resultados da predição da curva de carga

Esta seção descreve os resultados dos experimentos a partir dos treinamentos e dos testes dos cinco modelos descritos na seção anterior, sendo dois modelos de MLP, dois modelos de LSTM e o modelo de persistência (*baseline*). Foi utilizado um conjunto de dados (Tabela III) que permitiu ampliar a confiabilidade dos resultados. O tempo médio de treinamento variou de 20 a 60 minutos, sendo que o modelo LSTM mais complexo de duas células foi o que teve maior tempo de treinamento. Os resultados podem ser visualizados na Tabela V.

TABELA V  
RESULTADO DAS MÉTRICAS DE DESEMPENHO DOS MODELOS RTE

Modelo	Métricas	Fold1	Fold2	Fold3	Media
MLP-1 (4x30x30x1)	$R^2$	0,86	0,85	0,84	<b>0,85</b>
	RMSE	36,5	54,2	42,5	<b>44,4</b>
	MAE	17,6	24,8	29,7	<b>24,0</b>
MLP-2 (4x60x1)	$R^2$	0,85	0,78	0,80	<b>0,84</b>
	RMSE	53,3	72,8	48,8	<b>58,3</b>
	MAE	35,4	42,9	31,5	<b>36,6</b>
LSTM-1 (4x50x1)	$R^2$	0,95	0,97	0,92	<b>0,95</b>
	RMSE	24,6	33,6	41,3	<b>33,1</b>
	MAE	12,9	15,8	21,8	<b>16,8</b>
LSTM-2 (4x128x64x1)	$R^2$	0,98	0,93	0,97	<b>0,96</b>
	RMSE	17,6	23,1	26,1	<b>22,2</b>
	MAE	8,97	9,85	11,8	<b>10,2</b>
Persistência	$R^2$	0,65	0,70	0,73	<b>0,69</b>
	RMSE	123,5	92,8	134,6	<b>116,9</b>
	MAE	54,6	61,8	92,8	<b>69,73</b>

Os parâmetros de desempenho são representados pelas três métricas  $R^2$ ,  $RMSE$  e  $MAE$  que refletem os erros da predição. Estas métricas permitem ter resultados em variáveis quantitativas para ter como referência para outros modelos. O primeiro parâmetro de desempenho que se obteve, foi a métrica  $R^2$  que representa o percentual da variância dos dados que é explicado pelo modelo, onde os resultados variam de 0 a 1. Logo, quanto maior o valor de  $R^2$ , mais explicativo é o modelo em relação os dados previstos, porem esta métrica não é suficiente para considerar uma predição confiável, por isso também foi utilizado a  $RMSE$  que calcula a média de diferença entre o valor predito e o valor real e aplicada a raiz quadrática, está métrica tem a vantagem de ter uma avaliação mais criteriosa sobre as previsões do modelo. Por último para complementar foi implementada a métrica  $MAE$  que é similar que anterior, calcula a diferença entre o valor real e o valor previsto, porem este valor do resultado é elevado ao quadrado, desta forma permite deixar mais evidente a diferença da predição e o valor real.

Com base na Tabela de resultados, observa-se que os modelos MLP e LSTM apresentam melhores desempenhos que o modelo de persistência. Portanto, a seguir, os resultados serão analisados e discutidos

### B. Análise e discussões das predições

Para determinar qual dos modelos apresentou a melhor precisão foi realizado uma análise do desvio padrão, onde graficamente se pode observar na Fig. 7. Nota-se que os modelos LSTM e MLP superaram o modelo de persistência. Por esse motivo as comparações seguintes consideram somente os modelos de LSTM e MLP, os quais apresentam melhores acurácias de RMSE em relação ao modelo de persistência. Por outro lado, também, se observa que o modelo LSTM-2 tem uma melhor precisão em comparação aos modelos MLP.

A precisão média dos modelos MLP e LSTM pode ser observada mediante o coeficiente de determinação ( $R^2$ ) conforme se observa na Fig. 8, se bem os modelos apresentam resultados superiores de acurácia  $> 0.8$  onde a literatura considera um resultado aceitável, no entanto os modelos LSTM apresentam uma leve vantagem de 11% entre o melhor coeficiente de determinação e o pior. Considerando que os modelos LSTM tem um melhor desempenho com relação aos modelos MLP, comparou-se ambos os modelos de LSTM, observa-se que existem muito pouca diferença entre ambos modelos, tanto em métricas  $R^2$  e  $RMSE$ . Isso indica que um modelo LSTM mais simples de uma célula tem acurácias próximas a o modelo mais complexo de duas células, com uma diferença mínima de 1% para o coeficiente de determinação.

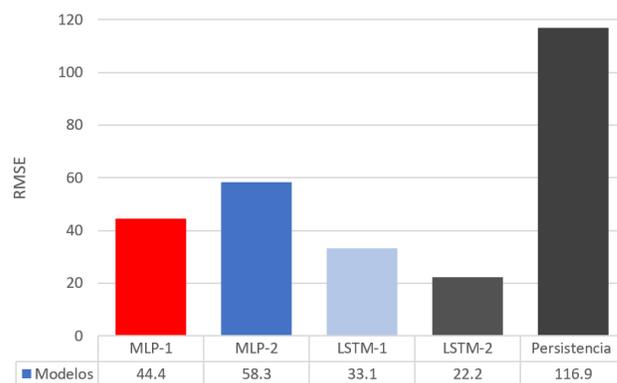


Fig. 7. Valores do RMSE os diferentes modelos, quanto menor a métrica, melhor o resultado

Sobre a base dos resultados desta análise, pode se afirmar que os modelos LSTM com estrutura simples tem uma acurácia levemente superior que os outros modelos de comparação.

Finalmente, na Fig. 9 apresenta-se um exemplo da predição da curva de carga para os modelos considerados durante este estudo. A curva se considera uma semana para frente com horizontes de predição de 30 minutos, observa-se que evidentemente o modelo LSTM segue com melhor tendência a curva da carga real. Se realizou uma ampliação na curva para visualizar o que acontece num período de 30 minutos e se observa que as curvas dos modelos seguem a tendência da curva

de carga real, onde novamente nota-se uma melhor tendencia na curva para os modelos LSTM.

Também, na Fig. 9 encontra-se sinalizado dois pontos onde ocorram picos de demanda máxima e demanda mínima para determinados dias da semana. Note-se que na segunda feira ocorreram picos de demanda máxima entre os horários das 16:00 até 20:00, como foi mencionado a curva de carga pertence ao um alimentador primário, nesses horários são produzidos picos de carga por horários comerciais. Por outro lado, na quarta-feira ocorreu um pico de demanda mínima nos horários das 22:00 até 02:00, que correspondem a horários de menor atividade de consumo elétrico. Por tanto, a curva de carga analisada representa um perfil de consumo comercial, pois a dinâmica de carga aumenta em horários laborais e diminui fora desses horários.

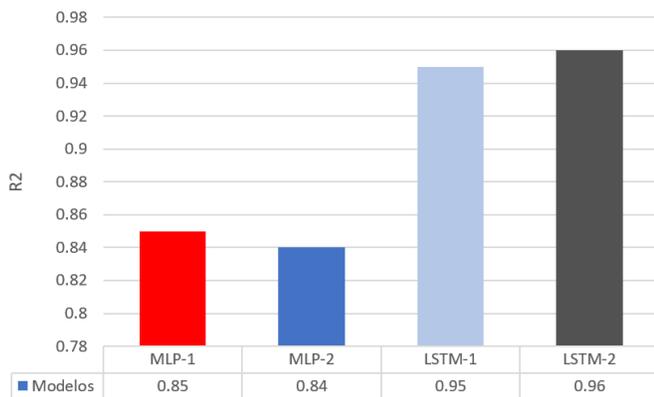


Fig. 8. Representação do coeficiente de determinação, quanto maior o valor melhor resultado da acurácia

Certamente em ambas análises verificou-se que os modelos LSTM tem melhor desempenho para as duas métricas de erros analisadas, tanto  $R^2$  e  $RMSE$ . A vista disso, na tabela VI se tomou como referência a  $R^2$  para representar a acurácia dos modelos, onde é identificado a média  $R^2$ , o menor valor  $R^2$

obtido durante os testes experimentais e o maior  $R^2$  dos experimentos, a traves disso se identifica os maiores e menores desempenhos dos modelos aplicados, e que foram comparados nas Fig. 7 e Fig.8. A traves disso

TABELA VI  
VALORES DAS ACURÁCIAS DO MENOR A MAIOR DOS MODELOS APLICADOS

Modelos	Media $R^2$	Menor $R^2$	Maior $R^2$
LSTM-2	0,96	0,93	0,98
LSTM-1	0,95	0,92	0,97
MLP-2	0,84	0,78	0,85
MLP-1	0,85	0,84	0,85

Queda comprovado que os modelos LSTM-2 possui a maior acurácia, seguido pelo modelo LSTM-1, depois MLP-2 e finalmente o modelo MLP-1 apresentou o desempenho mais baixo.

### CONCLUSÃO

Neste trabalho realizou-se a avaliação de modelos de ML na predição da curva de carga de curto prazo, considerando um único horizonte de predição de 30 minutos à frente. Foram comparadas as acurácias dos modelos de MLP e LSTM. A metodologia proposta foi definida para realizar predições de uma curva independente dos valores da carga, tornando o método válido tanto para alimentadores primários e secundários, quando considerados os parâmetros de entrada usados neste estudo. Além disso a metodologia de predição de este trabalho é válida para ser aplicada em outras configurações e estruturas de modelos de ML. Não foram considerados vários fatores que podem influenciar na variação da curva carga, como preço da energia elétrica, condições socioeconômicas e culturais, dias festivos ou condições meteorológicas mais específicas como umidade, velocidade do vento, índice de nuvens e outros.

Em relação aos resultados, a comparação dos modelos MLP e LSTM demonstraram maior precisão que o modelo de

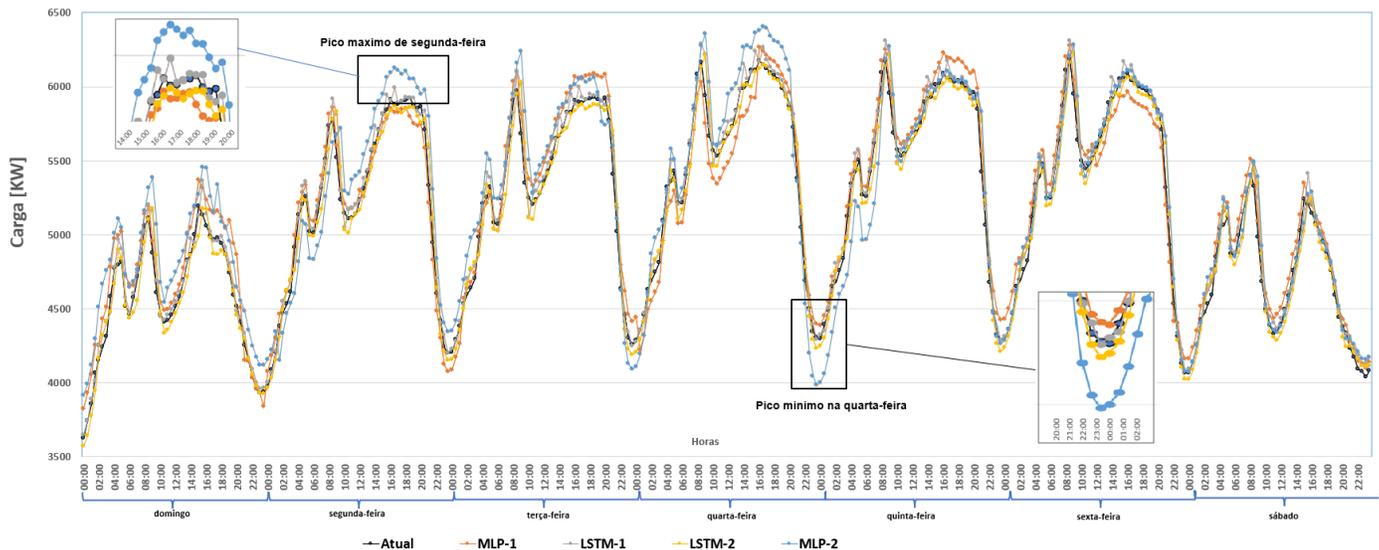


Fig. 9. Predição da curva de carga de uma semana, com horizontes de predição de 30 min

persistência utilizado como base de referência. Em função disso foi realizada a comparação dos modelos LSTM e MLP com duas configurações diferentes cada. Os resultados demonstraram que para a base de dados utilizada com variáveis de entradas básicas, como mês, dia, hora e temperatura ambiente com horizontes de previsão de 30 minutos, a rede LSTM simples se adaptaram melhor que uma MLP. Inclusive, se obteve resultados muito similares que uma rede LSTM mais complexa de 2 células. No entanto existem diversas pesquisas que realizam a previsão da curva de carga com métodos mais complexos e maior quantidade de variáveis de entrada, sendo assim fica como proposta de trabalhos futuros utilizar os mesmos modelos e configurações de este trabalho, aplicando em variáveis de entradas diferentes ou complementando as utilizadas neste trabalho; Além, este estudo pode ser utilizado para criar modelos de referências similares a modelos de persistência, pois o tempo de cálculo da rede LSTM simples leva em torno de 25 minutos.

Vale destacar que os resultados de este trabalho podem ser melhorados utilizando uma base de dados com maior quantidade de informações como foi mencionado anteriormente. Além disso, os modelos de MLP e LSTM foram analisados sem realização do ajuste de hiperparâmetros (*Hiper-Parameter Tuning*). Outra possibilidade é a avaliação de outros horizontes de previsão, por exemplo 1 min, 15 min, 60 min. E realizar as mesmas comparações com os modelos. Também, seria interessante avaliar curvas de cargas mais específicas, por exemplo para fins de semanas, dias festivos ou feriados. Finalmente também se sugere realizar uma análise mais profunda em quanto a dinâmica do funcionamento do fluxo de carga dos consumidores e pesquisar e implementar novos métodos e modelos com fim de otimizar e melhorar a previsão de carga.

#### NOMENCLATURA

RNA:	Rede Neural Artificial
ML:	<i>Machine Learning</i>
MLP	<i>Multilayer Perceptron</i>
R2:	Coefficiente de determinação
LSTM:	<i>Long Short-Term Memory</i>
LTLF:	<i>Long-Term load forecasting</i>
MTLF:	<i>Medium-Term Load Forecasting</i>
STLF:	<i>Short-Term Load Forecasting</i>
SVR:	<i>Support Vector Machine</i>
ARIMA:	<i>Autoregressive Integrated Moving Average</i>

#### AGRADECIMENTOS

Este título está dedicado para minha mãe, como ela disse `O maior presente que posso te dar, é apoiar na educação de você` minha mãe não sabe ler, porém, ela entende quanto importante é a educação. Muito obrigado, mãe.

#### REFERÊNCIAS

- [1] Kagan, Nelson; de Oliveira, Carlos César Barioni; Robba, Ernesto João. "Introdução aos sistemas de distribuição de energia elétrica". editora blucher, 2005.
- [2] M. N. Q. Macedo, J. J. M. Galo, L. A. L. Almeida, and A. C. C. Lima, "Typification of load curves for DSM in Brazil for a smart grid environment," *International Journal of Electrical Power and Energy Systems*, vol. 67, pp. 216–221, 2015.
- [3] Marques, Marthiello Santos, Fatima Cibele Soares, and Jumar Luis Russi. "Modeling Typical Power Demand Curves Using Climatic Data." *IEEE Latin America Transactions*, 2016.
- [4] A. Baliyan, K. Gaurav, and S. Kumar Mishra, "A review of short term load forecasting using artificial neural network models," in *Procedia Computer Science*, 2015, vol. 48, no. C, pp. 121–125
- [5] P. H. Kuo and C. J. Huang, "A high precision artificial neural networks model for short-Term energy load forecasting," *Energies (Basel)*, vol. 11, no. 1, 2018, doi: 10.3390/en11010213.
- [6] A. Ahmed; N. Etherden, "The potential for balancing the Swedish power grid with residential home batteries," *he 26th International Conference and Exhibition on Electricity Distribution, 2021*, pp. 2104–2108, 2021.
- [7] Doménech, Carmen Bas, and Miguel Heleno. "Estimating the value of second life batteries for residential prosumers." 2019 IEEE Milan PowerTech. IEEE, 2019.
- [8] P. Parmeshwarappa, R. Gundlapalli, and S. Jayanti, "Power and energy rating considerations in integration of flow battery with solar PV and residential load," *Batteries*, vol. 7, no. 3, Sep. 2021, doi: 10.3390/batteries7030062.
- [9] Parra, David, et al. "An interdisciplinary review of energy storage for communities: Challenges and perspectives." *Renewable and Sustainable Energy Reviews* 79 (2017): 730-749.
- [10] Islam, Shama Naz, et al. "Comparative Analysis of Commonly used Batteries for Residential Solar PV Applications." 2019 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC). IEEE, 2019.
- [11] D. Shaw-Williams, C. Susilawati, and G. Walker, "Value of residential investment in photovoltaics and batteries in networks: A techno-economic analysis." *Energies (Basel)*, vol. 11, no. 4, Apr. 2018, doi: 10.3390/en11041022.
- [12] Apostila de Unesp "Aspectos gerais de sistemas de distribuição" [Online]. Available: [https://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/apostila\\_sdee\\_01](https://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/apostila_sdee_01)
- [13] A. T. Diefenthaler, A. T. Z. R. Sausen, P. S. Sausen, and M. de Campos, "Modelagem matemática da curva de carga de um sistema elétrico real a partir de séries de Fourier," *Revista Brasileira de Computação Aplicada*, vol. 11, no. 2, pp. 64–73, Jun. 2019, doi: 10.5335/rbca.v11i2.8805.
- [14] "Uso de novas tecnologias digitais para medição de consumo de energia e níveis de eficiência energética no Brasil Baseado nas experiências da Alemanha." [Online]. Available: [www.energypartnership.com.br](http://www.energypartnership.com.br)
- [15] Shi, Jinwei, and Yan Zhang. "Short-term Power Load Forecasting based on Machine Learning." *International Core Journal of Engineering* 7.6 (2021): 333-341.
- [16] M. N. Q. Macedo, J. J. M. Galo, L. A. L. Almeida, and A. C. C. Lima, "Typification of load curves for DSM in Brazil for a smart grid environment," *International Journal of Electrical Power and Energy Systems*, vol. 67, pp. 216–221, 2015, doi: 10.1016/j.ijepes.2014.11.029.
- [17] University of Illinois (Urbana-Champaign campus) and Institute of Electrical and Electronics Engineers, *2015 IEEE Power and Energy Conference at Illinois (PECI) : Peci 2015 : University of Illinois at Urbana-Champaign, I-Hotel and Conference Center, Champaign, IL, February 20-21, 2015*.
- [18] H. Jiang, Y. Zhang, E. Muljadi, J. J. Zhang, and D. W. Gao, "A Short-Term and High-Resolution Distribution System Load Forecasting Approach Using Support Vector Regression with Hybrid Parameters Optimization," *IEEE Transactions on Smart Grid*, vol. 9, no. 4, pp. 3331–3350, Jul. 2018, doi: 10.1109/TSG.2016.2628061.
- [19] G. Li, C.-T. Cheng, J.-Y. Lin, and Y. Zeng, "Short-Term Load Forecasting Using Support Vector Machine with SCE-UA Algorithm\*," 2007.
- [20] IEEE Power & Energy Society. and Institute of Electrical and Electronics Engineers, *2016 IEEE PES PowerAfrica : June 28 2016-July 3 2016*.
- [21] Padrón Hernández, Santiago. *Inteligencia artificial en la operación de redes eléctricas: aplicación a sistemas aislados*. Diss. 2015.
- [22] M. Q. Raza and A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings," *Renewable and Sustainable Energy Reviews*, vol. 50.

- Elsevier Ltd, pp. 1352–1372, Jun. 18, 2015. doi: 10.1016/j.rser.2015.04.065.
- [23] A. Azadeh, S. F. Ghaderi, and S. Sohrabkhani, “A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran,” *Energy Policy*, vol. 36, no. 7, pp. 2637–2644, Jul. 2008, doi: 10.1016/j.enpol.2008.02.035.
- [24] Andrade, Luciano Carli Moreira, and Ivan Nunes da Silva. “Very short-term load forecasting based on ARIMA model and intelligent systems.” 2009 15th International Conference on Intelligent System Applications to Power Systems. IEEE, 2009.
- [25] S. J. Huang and K. R. Shih, “Short-term load forecasting via ARMA model identification including non-Gaussian process considerations,” *IEEE Transactions on Power Systems*, vol. 18, no. 2, pp. 673–679, May 2003, doi: 10.1109/TPWRS.2003.811010.
- [26] I. Drezga and S. Rahman, “INPUT VARIABLE SELECTION FOR ANN-BASED SHORT-TERM LOAD FORECASTING,” 1998.
- [27] N. Ding, C. Benoit, G. Foggia, Y. Besanger, and F. Wurtz, “Neural network-based model design for short-term load forecast in distribution systems,” *IEEE Transactions on Power Systems*, vol. 31, no. 1, pp. 72–81, Jan. 2016, doi: 10.1109/TPWRS.2015.2390132.
- [28] IEEE Communications Society. and Institute of Electrical and Electronics Engineers, 2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm): 29-31 Oct. 2018.
- [29] D. Niu, Y. Wang, and D. D. Wu, “Power load forecasting using support vector machine and ant colony optimization,” *Expert Systems with Applications*, vol. 37, no. 3, pp. 2531–2539, Mar. 2010, doi: 10.1016/j.eswa.2009.08.019.
- [30] Butzge, Luiza. “Aplicação de algoritmos inteligentes para previsão de carga no curto prazo em sistemas de distribuição.” (2020).”
- [31] A. Wahab, M. A. Tahir, N. Iqbal, F. Shafait, and S. M. R. Kazmi, “Short-Term Load Forecasting using Bi-directional Sequential Models and Feature Engineering for Small Datasets,” Nov. 2020, [Online]. Available: <http://arxiv.org/abs/2011.14137>
- [32] De Oliveira, Luiz Antonio Alves. “Tratamento de dados de curvas de carga via análise de agrupamentos e transformada wavelets.” Universidade Federal do Rio de Janeiro (2013).
- [33] Chen, S-T., David C. Yu, and Alireza R. Moghaddamjo. “Weather sensitive short-term load forecasting using nonfully connected artificial neural network.” *IEEE Transactions on Power Systems* 7.3 (1992): 1098-1105.
- [34] D. C. Park, M. A. El-Sharkawi, R. J. Marks, L. E. Atlas, and M. J. Damborg, “Electric Load Forecasting Using An Artificial Neural Network,” 1991.
- [35] M. Djukanovic, B. Babic, D. J. Sobajic, and Y.-H. Pao, “Unsupervised/supervised 24-hour load forecasting.”
- [36] IEEE Power Electronics Society., 2007 *IEEE Lausanne Power Tech : proceedings, 1-5 July 2007, Lausanne, Switzerland*. IEEE, 2007.
- [37] E. Choi, S. Cho, and D. K. Kim, “Power demand forecasting using long short-term memory (LSTM) deep-learning model for monitoring energy sustainability,” *Sustainability (Switzerland)*, vol. 12, no. 3, Feb. 2020, doi: 10.3390/su12031109.
- [38] S. J. Taylor and B. Letham, “Forecasting at Scale.” [Online]. Available: <https://www.tandfonline.com/doi/abs/10.1080/00031305.2017.1380080>
- [39] K. Wang, X. Qi, and H. Liu, “Photovoltaic power forecasting based LSTM-Convolutional Network,” *Energy*, vol. 189, Dec. 2019, doi: 10.1016/j.energy.2019.116225.
- [40] C. A. Gueymard, “A review of validation methodologies and statistical performance indicators for modeled solar radiation data: Towards a better bankability of solar projects,” *Renewable and Sustainable Energy Reviews*, vol. 39. Elsevier Ltd, pp. 1024–1034, 2014. doi: 10.1016/j.rser.2014.07.117.
- [41] Banco de dados do consumo de carga de Francia. Available: <https://data.rte-france.com>
- [42] I. Drezga and S. Rahman, “INPUT VARIABLE SELECTION FOR ANN-BASED SHORT-TERM LOAD FORECASTING,” 1998.
- [43] H. J. Sadaei, P. C. de Lima e Silva, F. G. Guimarães, and M. H. Lee, “Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series,” *Energy*, vol. 175, pp. 365–377, May 2019, doi: 10.1016/j.energy.2019.03.081.
- [44] E. Mining, *Python Machine Learning: Understand Python Libraries (Keras, NumPy, Scikit-Lear, TensorFlow) for Implementing Machine Learning Models in Order to Build Intelligent Systems*. 2019.
- [45] E. Bisong, “Google Colaboratory,” in BuildingMachine Learning and Deep Learning Models on Google Cloud Platform,”
- [46] Jamovi, “The jamovi project (2021).” Computer Software, 2021. Available: <https://www.jamovi.org/about.html>
- [47] Urzagasti, Carlos Alejandro, et al. “Comparação da Acurácia de Modelos de Redes Neurais Artificiais na Predição da Irradiância Solar e Geração de Energia Fotovoltaica.” Anais do XVIII Congresso Latino-Americano de Software Livre e Tecnologias Abertas. SBC, 2021.
- [48] V. H. Wentz, J. N. Maciel, M. N. Kapp, J. J. G. Ledesma, O. H. Ando Junior, and O. H. A. Junior, “Comparação de Modelos de Redes Neurais Artificiais para a Predição da Irradiância Solar na Geração de Energia Fotovoltaica,” *Anais do I Congresso Brasileiro Interdisciplinar em Ciência e Tecnologia*, p. 8, 2020, [Online]. Available: <https://www.even3.com.br/anais/icobicet2020/265096-comparacao-de-modelos-de-redes-neurais-artificias-para-a-predicao-de-irradiancia-solar-na-geracao-de-energia-foto/>