

ANÁLISE COMPARATIVA ENTRE OS MODELOS ARIMA E LSTM NA PREVISÃO DE CURTO PRAZO DA DEMANDA DE POTÊNCIA ATIVA

Ubiratan da Silva Tavares (UCP) E-mail: ubiratan.41840108@ucp.br

Giovane Quadrelli (UCP) E-mail: giovane.quadrelli@ucp.br

Resumo: No Brasil, um problema relacionado ao consumo de energia elétrica para um usuário conectado ao sistema de distribuição, em média e alta tensão, é a ultrapassagem da demanda. Este problema ocorre quando a demanda medida excede em mais de 5% a demanda contratada. Como avaliar a eficiência de um modelo computacional como solução para o problema de previsão de curto prazo da demanda de potência ativa, visando a sua utilização como método de controle para aplicação em controladores de demanda? Este estudo tem como objetivo avaliar a eficiência do modelo estatístico ARIMA e do modelo de rede neural profunda LSTM como métodos de controle. Com base nos dados históricos de medição, foram desenvolvidas etapas visando os ajustes, as previsões e as avaliações dos modelos em um estudo de caso de usuário em média tensão conectado ao sistema de distribuição da concessionária Enel/RJ. Foi possível observar que o modelo ARIMA obteve uma eficiência de 46%, isto é, 46% dos valores previstos com variação percentual máxima de 5% (grau de precisão) dos valores medidos, enquanto o modelo LSTM obteve 13%.

Palavras-chave: previsão, demanda, potência, LSTM, ARIMA

COMPARATIVE ANALYSIS BETWEEN ARIMA AND LSTM MODELS IN SHORT-TERM FORECAST OF ACTIVE POWER DEMAND

Abstract: In Brazil, a problem related to electricity consumption for a user connected to the distribution system, in medium and high voltage, is demand overrun. This problem occurs when the measured demand exceeds the contracted demand by more than 5%. How to evaluate the efficiency of a computational model as a solution to the short-term forecast problem of active power demand, aiming its use as a control method for application in demand controllers? This study aims to evaluate the efficiency of the ARIMA statistical model and the LSTM deep neural network model as control methods. Based on historical measurement data, steps were developed to adjust, forecast and evaluate the models in a case study of a medium voltage user connected to the distribution system of the Enel/RJ concessionaire. It was possible to observe that the ARIMA model obtained an efficiency of 46%, that is, 46% of the predicted values with a maximum percentage variation of 5% (degree of precision) of the measured values, while the LSTM model obtained 13%.

Keywords: forecast, demand, power, LSTM, ARIMA

1. Introdução

No contexto da gestão de energia elétrica, nunca foi tão necessário implementar medidas visando alcançar um nível de desempenho com a eficiência energética da instalação elétrica de uma unidade consumidora no atual cenário de geração, transmissão e distribuição elétrica brasileira. Estas medidas visam assegurar uma instalação energeticamente eficiente, tendo como foco a redução do consumo de energia e consequentemente do custo associado a este consumo.

Rocha e Monteiro (2005) destacam que o acompanhamento de itens de controle, tais como, demandas (contratadas, medidas e faturadas), consumos de energia, fatores de utilização da instalação (fator de carga, fator de demanda, fator de potência); a atuação com foco na medição dos itens de controle, as indicações corretivas, as propostas de alterações, as melhorias das implementações para o uso eficiente de energia são algumas das medidas a serem adotadas.

Com relação aos itens de controle, a adoção do gerenciamento de energia pelo lado da demanda, tendo como uma das ações possíveis a instalação de controlador de demanda na unidade consumidora, é uma medida possível para se alcançar uma meta específica em um plano de eficiência energética.

Segundo Campos (2004), a função básica do controlador de demanda é monitorar e limitar a demanda do consumidor, podendo ser aplicado em consumidores industriais, comerciais e residenciais. Vale ressaltar que, em geral, um controlador mais moderno usa microprocessador que pode ser programado.

Há dois tipos básicos de controladores de demanda: o tipo cíclico e o limitador de demanda. O primeiro, possui um timer programado, que tem como função evitar que determinadas demandas de potência entre em operação em determinado horário. Já o segundo, utiliza os dados de potência, que quando comparado a potência máxima permitida para cada horário decide pelo desligamento de cargas, mantendo a potência controlada, conforme as prioridades estabelecidas pelo usuário do sistema elétrico, restabelecendo as cargas assim que constatado à normalidade da demanda, sendo todo este controle efetuado de forma automática (CAMPOS, 2004)

Fernandes, Bispo, Ferraz (2011) afirmam que o objetivo do limitador de demanda, isto é, o controlador de demanda automático, é realizar o supervisionamento da demanda de energia elétrica de uma instalação em tempo real, adequando à operacionalidade das cargas estabelecidas previamente pelo consumidor.

Quanto às funcionalidades básicas, o controlador de demanda automático deve delimitar o uso das cargas, conforme configuração estabelecida pelo usuário; controlar e ordenar à operacionalidade das cargas; atender as especificações, efetuando as manobras das cargas de forma instantânea; e obter dados de medição da concessionária em tempo real, para a tomada de decisão (FERNANDES; BISPO; FERRAZ, 2011).

No Brasil, os dados de medição da concessionária advêm do medidor de energia elétrica, que nos casos dos usuários conectados ao sistema de distribuição, em média e alta tensão (Grupo A), devem ser capazes de apurar, para consumo e/ou geração, de acordo com as características do usuário, a demanda integralizada em intervalo programável de 5 (cinco) a 60 (sessenta) minutos (em kW), a demanda reativa (em kVAr) e as energias ativa (kWh) e reativa (em kVArh), além de prover entre outros, saída de pulsos para o controlador de demanda (ANEEL, 2021).

Com base nos dados de medição do medidor de energia e informação da demanda contratada, no horário de ponta e/ou fora de ponta, conforme especificado em contrato firmado entre o consumidor e a concessionária, é realizada a tomada de decisão do controlador de demanda, desligando uma ou mais cargas elétricas em operação, com a finalidade de manter a demanda instantânea abaixo do(s) limite(s) da(s) demanda(s) contratada(s), evitando assim a ocorrência de ultrapassagem de demanda.

Para os consumidores em média e alta tensão (Grupo A), quando a demanda de potência excede em mais de 5% (cinco por cento) a demanda contratada, é adicionado ao faturamento à cobrança pela ultrapassagem de demanda, cuja tarifa aplicável é o dobro da tarifa de demanda de potência (ANEEL, 2010), podendo representar um aumento significativo no custo final da fatura de energia elétrica.

A tomada de decisão do controlador de demanda é baseada em algoritmos computacionais que realizam o processamento, dado as variáveis de entrada, por meio dos métodos de controle, que definem as estratégias de decisões e determinam grau de precisão e eficiência de um controlador (FERNANDES; BISPO; FERRAZ, 2011).

Fernandes, Bispo, Ferraz (2011) descrevem alguns métodos de controle, tais como: o método da janela móvel, o método preditivo adaptativo, o método de controle por lógica Fuzzy, o método por algoritmo genético e o método por redes neurais artificiais. Destaca-se que, muitos fabricantes de controladores de demanda especificam, no software dos seus equipamentos, o método de controle adotado.

Neste trabalho optou-se por avaliar a eficiência do modelo estatístico clássico ARIMA (*AutoRegressive Integrated Moving Average*) e do modelo de aprendizagem profunda LSTM (*Long Short-Term Memory*) como métodos de controle para aplicação em controladores de demanda considerando o problema de previsão de curto prazo da demanda de potência ativa.

2. Aspectos Regulatórios

No Brasil, as unidades consumidoras de energia elétrica do Grupo A, grupamento composto pelas unidades consumidoras com tensão de fornecimento igual ou superior a 2,3 kV ou atendidas a partir de sistema subterrâneo de distribuição em tensão secundária, são obrigadas a firmar contratos de fornecimento de energia com as concessionárias, onde em uma das cláusulas, é definido a demanda contratada, mecanismo fundamental para administrar a segurança, a confiabilidade e a estabilidade dos sistemas elétricos de potência (ANEEL, 2010)

Neste contexto, a unidade consumidora do Grupo A, ao solicitar a ligação de sua unidade à rede elétrica da concessionária, necessita declarar a demanda de potência ativa que pretende utilizar, e com base nesta informação, dimensionar o sistema elétrico de potência que irá atendê-lo. Portanto, a análise da variação desta variável ao longo do tempo é de suma importância, entre outras coisas, para definir em contrato um valor otimizado da demanda contratada.

A ANEEL (2010) estabelece a conceituação dos diferentes tipos de demanda, a saber:

- **demanda (D)**: média das potências elétricas: ativas, expressa em quilowatts (kW) e reativas, expressa em quilovolt-ampère-reactivo (kvar). As demandas ativas ou reativas são solicitadas ao sistema elétrico pela parcela de carga instalada em operação na unidade consumidora, durante um intervalo de tempo especificado.
- **demanda medida (D_M)**: a maior demanda de potência ativa, verificada por medição, durante o período de faturamento, que consiste em um intervalo de tempo de aproximadamente de 30 dias, podendo variar de um intervalo mínimo de 27 dias e máximo de 33 dias;
- **demanda contratada (D_C)**: potência ativa que deve ser obrigatoriamente e continuamente disponibilizada pelo sistema elétrico da distribuidora, no ponto de entrega, para atender os equipamentos elétricos da unidade consumidora do Grupo A, conforme valor e período de vigência fixados em contrato, e que deve ser integralmente paga, seja ou não utilizada durante o período de faturamento;
- **demanda faturável (D_F)**: valor da demanda de potência ativa considerada para fins de faturamento, com aplicação da respectiva tarifa, que corresponde ao maior valor dentre os definidos a seguir: demanda contratada, se $D_M \leq D_C$ ou demanda medida, se $D_C < D_M \leq 1,05.D_C$, exceto para unidade consumidora da classe rural ou reconhecida como sazonal;
- **ultrapassagem de demanda (D_U)**: ocorre quando os montantes de demanda de potência ativa ou de uso do sistema de distribuição medidos excederem em mais de 5% a demanda contratada, isto é, $D_U = D_M - D_C$, se $D_M > 1,05.D_C$. Na ocorrência da ultrapassagem de demanda é adicionado ao faturamento regular a cobrança do valor correspondente à demanda de potência ativa excedente (custo pela ultrapassagem de demanda), por posto tarifário, quando cabível, em reais.

3. Previsão de Séries Temporais

Em muitas aplicações no mundo real os dados são capturados ao longo do tempo, constituindo uma série temporal (GAMBOA, 2017).

Para Box et al. (2015), uma série temporal é uma sequência de observações tomadas sequencialmente no tempo.

Segundo Gamboa (2017), as séries temporais geralmente contêm dependências temporais que fazem com que dois pontos de tempo idênticos pertençam a classes diferentes ou revejam comportamentos diferentes.

Shmueli e Junior (2016) afirmam que na modelagem descritiva ou análise de séries temporais, uma série temporal é modelada para determinar seus componentes em termos de padrões sazonais, tendências, relação a fatores externos e similares. Por outro lado, a previsão de séries temporais usa as informações em uma série temporal (talvez com informações adicionais) para prever valores futuros dessa série.

Fazer previsões sobre o futuro é chamado de extrapolação no tratamento estatístico clássico de dados de séries temporais, onde os campos mais modernos se concentram no tópico e se referem a ele como previsão de séries temporais. A previsão envolve ajustar os modelos aos dados históricos e usá-los para prever observações futuras. A habilidade de um modelo de previsão de séries temporais é determinada por seu desempenho em prever o futuro. A previsão de séries temporais envolve o desenvolvimento e o uso de um modelo preditivo nos dados em que existe um relacionamento ordenado entre as observações.

A previsão de séries temporais é difícil e diferentemente dos problemas mais simples de classificação e regressão, os problemas de séries temporais acrescentam a complexidade da ordem ou dependência temporal entre as observações, e isto, de certa forma, dificulta o tratamento em muitos problemas de previsão de séries temporais, e isso pode ser difícil, pois o manuseio especializado dos dados é necessário ao ajustar e avaliar modelos.

4. Modelo ARIMA

O modelo ARIMA é um método estatístico popular e amplamente utilizado para análise e previsão de dados de séries temporais. Este modelo captura um conjunto de diferentes estruturas temporais padrão em dados de séries temporais, fornecendo uma metodologia simples, para fazer previsões hábeis de séries temporais.

De acordo com Hyndman e Athanasopoulos (2018), o modelo ARIMA é aplicado nos casos em que os dados mostram evidências de não estacionariedade, adicionando a noção de integração, visando eliminar a não estacionariedade, sendo uma generalização do modelo ARMA (*AutoRegressive Moving Average*). Ambos os modelos são ajustados aos dados da série temporal para se prever valores futuros da série.

O **AR** (*AutoRegressive*) descreve o aspecto de que o modelo usa a relação dependente entre uma observação e um certo número de observações defasadas; o **I** (*Integrated*) descreve o aspecto de que o modelo faz uso de diferenciação de observações brutas para tornar a série temporal estacionária; e o **MA** (*Moving Average*) descreve o aspecto de que o modelo usa a dependência entre uma observação e um erro residual do modelo de média móvel aplicado a observações defasadas. Cada aspecto do modelo é especificado explicitamente como um parâmetro. Uma notação padrão usada é ARIMA(p, d, q), onde os parâmetros são substituídos por valores inteiros especificando um modelo ARIMA.

Segundo Hyndman e Athanasopoulos (2018), os parâmetros do modelo ARIMA são:

– **p**: ordem da parte autoregressiva, também chamado de ordem de defasagem, que representa o número de observações de defasagem incluídas no modelo;

- d : O grau de diferenciação envolvido, que representa o número de vezes que as observações brutas são diferenciadas;
- q : a ordem da parte média móvel, que representa o tamanho da janela da média móvel.

5. Modelo LSTM

Esta seção fornece um breve histórico da rede neural artificial LSTM que é um tipo especial de rede neural recorrente, capaz de aprender dependências temporais. Este modelo foi proposto por Hochreiter e Schmidhuber (1997), sendo posteriormente refinado e popularizado por muitas pessoas que contribuíram com o LSTM moderno.

Na Figura 1 é apresentado a unidade comum de uma arquitetura LSTM, que consiste de uma célula de memória, uma porta de entrada, uma porta de saída e uma porta de esquecimento.

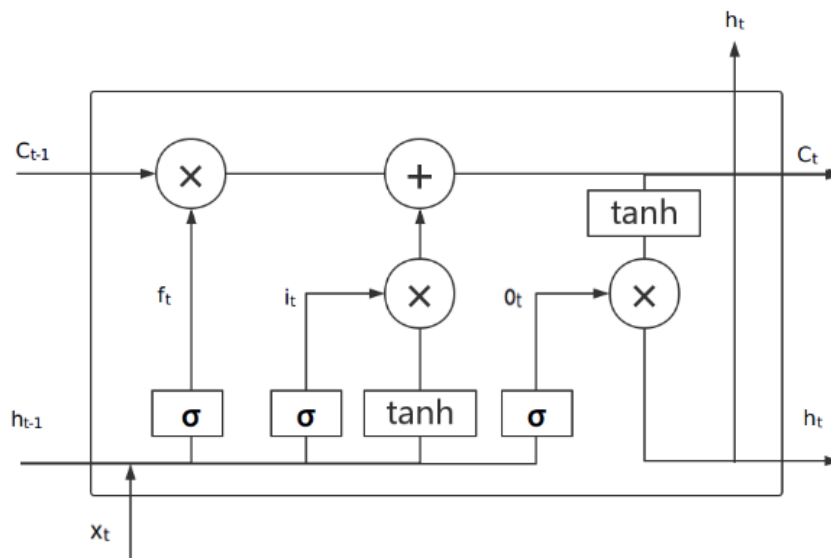


Figura 1 - Estrutura interna da unidade da arquitetura LSTM (Tian, 2018)

Tian et al. (2018) explica, com relação a unidade da arquitetura LSTM apresentada na Figura 1, que no tempo t , a entrada X_t é seletivamente salva na célula C_t determinada pela porta de entrada e o estado da célula C_{t-1} no tempo $t-1$ é seletivamente esquecido pela porta de esquecimento. Finalmente, a porta de saída controla qual parte da célula C_t é adicionada à saída h_t .

Brownlee (2019) afirma que o modelo LSTM pode ser usado para modelar problemas de previsão de série temporal univariada. O modelo LSTM aprende uma função que mapeia uma sequência de observações anteriores como entrada para uma observação de saída. Como tal, a sequência de observações deve ser transformada em várias amostras que são utilizadas no aprendizado supervisionado do modelo.

A arquitetura do modelo LSTM adotado neste trabalho possui uma camada oculta e uma camada de saída que realiza a previsão.

Na camada oculta são configurados: o número de unidades LSTM (número de nós), a função de ativação, *Rectified Linear Unit (ReLU)* e a forma da entrada de cada amostra.

Como normalmente há várias amostras, o modelo espera que a forma de entrada seja uma matriz tridimensional contendo número de amostras, número de etapas de tempo, número de recursos.

O modelo adotado é compilado usando o algoritmo de otimização *Adaptive Movement Estimation (Adam)*, extensão da descida do gradiente, e a função de perda *Mean Squared Error (MSE)* e ajustado ao conjunto de dados de treinamento no formato de aprendizado

supervisionado, uma vez configurado o número de períodos de treinamento, sendo posteriormente utilizado para prever um novo valor da série.

Os hiperparâmetros utilizados na configuração do modelo LSTM adotado são:

- **input**: o número de entradas anteriores a serem usadas como entrada para o modelo;
- **nodes**: o número de nós a serem usados na camada oculta;
- **epochs**: o número de períodos de treinamento;
- **batch**: O número de amostras a serem incluídas em cada mini batch.

6. Métrica de Desempenho

As métricas de desempenho dos modelos ARIMA e LSTM foram medidas e quantificadas adotando-se o erro quadrático médio (RMSE). Tian et al. (2018) apresenta o cálculo para a medida de erro RMSE, definida da seguinte forma:

$$RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (1)$$

onde N é o tamanho das amostras de teste e \hat{y}_i , o i-ésimo valor previsto e y_i , o i-ésimo valor medido.

O RMSE representa o desvio padrão da amostra das diferenças entre os valores previstos e os valores medidos. Quanto menor o valor do RMSE, melhor é o desempenho da previsão.

7. Material Utilizado

O estudo de caso analisado neste trabalho concentrou-se na unidade consumidora com tensão de fornecimento de 11,4 kV (média tensão), conectado ao sistema de distribuição da concessionária Enel/RJ, classificado no subgrupo A4 com modalidade tarifária verde, e demanda contratada de 135 kW com posto tarifário único (fora de ponta). A referida unidade situa-se na Avenida José Mendonça de Campos, 1111, Colubandê, São Gonçalo, Rio de Janeiro/RJ.

Para a previsão de curto prazo da demanda de potência ativa foram utilizados os dados históricos de medição (série temporal) da potência ativa presente na memória de massa da unidade, disponibilizada em planilha eletrônica pela concessionária.

Os dados de medição foram registrados pelo medidor eletrônico de energia elétrica da unidade, fabricante Landis+Gyr, modelo 8701, que atende às normas técnicas 14519, 14520 e 14522 da ABNT; as exigências do módulo 5 do PRODIST/ANEEL e portarias 587/2012, 586/2012 e 520/2014 do INMETRO, quanto aos critérios metrológicos e de segurança do *firmware*, totalizando 5.856 medições efetuadas da 00:00:00h do dia 01/11/2020 até 23:45:00h do dia 31/12/2020, o que corresponde a 61 dias, com cada dia contendo 96 medições com intervalo de 15 em 15 minuto, sendo utilizados 5.760 medições para os ajustes e 96 medições para as avaliações dos modelos ARIMA e LSTM.

8. Metodologia

O desenvolvimento da metodologia foi realizada em etapas implementadas computacionalmente na linguagem Python com a utilização de pacotes e bibliotecas (*Statsmodels*, *Numpy*, *Pandas* *Scikit-learn*, *Keras* e *Matplotlib*), no ambiente de desenvolvimento científico *Spyder*. Este ambiente integra a distribuição gratuita Anaconda.

Este desenvolvimento teve como alvo a realização dos ajustes, previsões e avaliações dos modelos ARIMA e LSTM aplicado ao estudo de caso mencionado na seção 7.

Na Figura 2 é apresentado o diagrama de blocos das funcionalidades implementadas em cada etapa que visou avaliar a eficiência dos modelos ARIMA e LSTM como candidatos a métodos de controle para aplicação em controladores de demanda.

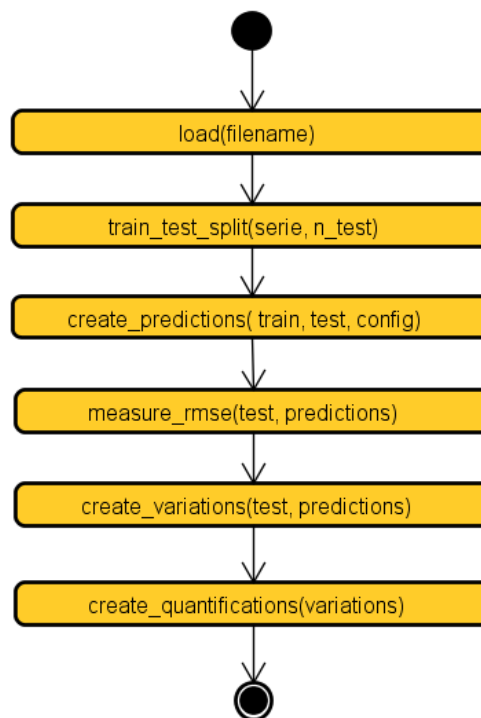


Figura 2 - Diagrama de blocos

A primeira etapa inicia-se com a informação da base histórica dos dados contendo 5.856 medições como entrada para a funcionalidade `load(filename)`. Esta funcionalidade carrega e armazena os dados da série temporal univariada da potência ativa na variável `serie`. Em seguida, cria-se a variável `n_test`, que armazena as 96 últimas medições da base de dados para serem utilizadas para avaliações dos modelos.

Na segunda etapa, as variáveis `serie` e `n_test` são passadas como entradas para a funcionalidade `train_test_split(serie, n_test)` que divide a série temporal univariada em dois conjuntos de dados: o conjunto de treinamento armazenado na variável `train` e o conjunto de teste armazenado na variável `test`.

Na terceira etapa, cria-se a variável `config` que representa a configuração a ser utilizada por um modelo específico, que define os parâmetros necessários para o ajuste dos dados ao modelo. Para o modelo ARIMA, foi configurado na variável `config = (p, d, q) = (2, 2, 2)`. Esta configuração foi obtida por meio da pesquisa em grade dos hiperparâmetros do modelo, resultando na configuração que originou o menor RMSE entre 81 configurações avaliadas. Já para o modelo LSTM, foi configurado na variável `config = (input, nodes, epochs, batch) = (7, 5, 50, 3)`. Esta configuração foi obtida por meio de vários testes interativos onde foi mantido fixo um dos parâmetros e variando-se outros, resultando na configuração que originou o menor RMSE entre 144 configurações avaliadas. A variável `config`, juntamente com as variáveis `train` e `test` são passadas como entradas para a funcionalidade `create_predictions(train, test, config)` que realiza as previsões e armazena-os na variável `predictions`. Neste estudo foram realizadas 96 previsões que foram utilizadas para avaliar a performance de cada modelo. A implementação desta funcionalidade é diferenciada para cada um dos modelos utilizados.

No modelo ARIMA, a funcionalidade `create_predictions(train, test, config)` chama a

funcionalidade auxiliar *model_fit(history, config)* que ajusta os dados armazenados na variável *train* na arquitetura do modelo ARIMA, retornando um modelo ARIMA ajustado aos dados de treinamento, sendo posteriormente utilizado para realizar as previsões.

Já no modelo LSTM, a funcionalidade *create_predictions(train, test, config)* chama a funcionalidade auxiliar *series_to_supervised(train, n_input)* que prepara os dados armazenados na variável *train* para o aprendizado supervisionado criando as variáveis *train_x* e *train_y*, e formatando a variável *train_x* para o formato 3D, e posteriormente chama a funcionalidade auxiliar *model_fit(train_x, train_y, config)* que ajusta os dados armazenados nas variáveis *train_x* e *train_y* na arquitetura do modelo LSTM, retornando um modelo LSTM ajustado aos dados de treinamento, sendo utilizado para realizar as previsões.

As variáveis *test* e *predictions* são passadas, na quarta etapa, como entradas para a funcionalidade *measure_rmse(test, predictions)* que calcula o desvio médio quadrático ou erro quadrático médio entre os 96 valores medidos e previstos, armazenando-o na variável *rmse*. Elas também são passadas, na quinta etapa, como entradas para a funcionalidade *create_variations(test, predictions)* que calcula o módulo da variação percentual de cada um dos 96 valores medidos e previstos, armazenando-os na variável *variations*.

Na última etapa, a variável *variations* é passada como entrada para a funcionalidade *create_quantifications(variations)* que contabiliza a quantidade de valores previstos com módulo da variação percentual menor ou igual a um determinado percentual específico, calculando também a taxa percentual desta quantidade pelo total de valores previstos, armazenando-os na variável *quantifications*.

9. Resultados e Discussão

Nesta seção são apresentados os resultados e discussões das avaliações dos modelos ARIMA e LSTM.

Na Figura 3 é apresentado o gráfico de demanda de potência ativa da unidade consumidora no dia 31/12/2020 com os 96 valores medidos e previstos por meio do modelo ARIMA. A aferição da qualidade do ajuste do modelo ARIMA resultou em um RMSE de 3,98 kW, representando o erro obtido entre os valores medidos e previstos, sendo o menor valor alcançado por meio da configuração ARIMA(2, 2, 2).




Figura 3 - Gráfico dos valores medidos e previstos (ARIMA) da demanda de potência ativa em 31/12/2020

As previsões do modelo ARIMA acompanham a tendência temporal dos valores medidos da demanda de potência ativa, tendo uma dificuldade perceptível para alcançar o pico máximo da demanda ocorrido às 22:00h do dia 31/12/2020 como pode ser observado na Figura 3.

Na Figura 4 é apresentado o gráfico de demanda de potência ativa da unidade consumidora no dia 31/12/2020 com os 96 valores medidos e previstos por meio do modelo LSTM. A aferição da qualidade do ajuste do modelo LSTM resultou em um RMSE de 3,69 kW, representando o erro obtido entre os valores medidos e previstos, sendo o menor valor alcançado por meio da configuração LSTM (7, 5, 10, 3).




Figura 4 - Gráfico dos valores medidos e previstos (LSTM) da demanda de potência ativa em 31/12/2020

As previsões do modelo LSTM, assim como o modelo ARIMA, acompanham a tendência temporal dos valores medidos da demanda de potência ativa, também tendo uma dificuldade perceptível para alcançar o pico máximo da demanda ocorrido às 22:00h do dia 31/12/2020 como pode ser observado na Figura 4, tendo uma aproximação melhor do valor previsto pelo modelo LSTM comparado com a aproximação do valor previsto pelo modelo ARIMA ao valor do pico máximo de demanda.

Na Figura 5 é apresentado o gráfico da quantidade de valores previstos versus o módulo da variação percentual entre os valores medidos e previstos.




Figura 5 - Gráfico da quantidade de valores preditos em função da variação percentual dos valores medidos

Como pode-se observar na Figura 5, ambos os modelos previram todos os valores com variação máxima de 75% abaixo ou acima dos valores medidos. Outro ponto que pode ser observado é que o modelo ARIMA obteve uma quantidade de valores previstos superior ao do modelo LSTM para uma variação máxima de 20% abaixo ou acima dos valores medidos. Por outro lado, o modelo LSTM obteve uma quantidade de valores previstos superior ao modelo ARIMA para variação mínima de 20% e máxima de 45% e variação mínima de 50% e máxima de 65% dos valores medidos. Finalmente, é possível observar que o modelo ARIMA obteve uma eficiência de 46%, isto é, 46% dos valores previstos possuem uma variação máxima de 5% (grau de precisão) abaixo ou acima dos valores medidos, enquanto o modelo LSTM obteve 13%, considerando-se as configurações definidas em cada modelo.

10. Conclusões

Conclui-se que o modelo ARIMA apresentou uma eficiência melhor do que o modelo LSTM. Entretanto, se uma eficiência igual ou maior do que 95% com grau de precisão máxima de 5%, isto é, 95% ou mais dos valores preditos com diferença percentual máxima de 5% do valor medido for definido como critério de aceitabilidade para um modelo seja escolhido como método de controle em um controlador de demanda, verifica-se que ambos os modelos não seriam aceitos. Destaca-se ainda que, o modelo ARIMA pode ser utilizado como linha de base para avaliação de outros modelos computacionais, possibilitando avaliar se um determinado modelo venha alcançar uma eficiência melhor do que o modelo ARIMA. Garantir que o modelo tenha uma eficiência igual ou maior do que 95% com base no critério de aceitabilidade e seja utilizado como método de controle é necessário para que o controlador de demanda seja assertivo em sua decisão pelo desligamento de cargas, quando for a demanda de potência ativa prevista for maior do que a demanda contratada, e portanto não havendo o risco de que a demanda medida seja maior do que a demanda contratada mais 5%.

Referências

ANEEL. *Resolução normativa nº 414*. 2010.

BOX, G.E.; JENKINS, G.M.; REINSEL, G.C. & LJUNG, G.M. *Time Series Analysis: Forecasting and Control*. 5. ed. Wiley, 2015.

BROWNLEE, J. *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery, 2019.

CAMPOS, A. *Gerenciamento pelo Lado da Demanda*. Dissertação apresentada ao Programa Interunidades de Pós Graduação em Energia da Universidade de São Paulo. São Paulo, 2004.

FERNANDES, U.B.; BISPO, D. & FERRAZ, J.H.S. *Controle de Demanda de Energia de um Sistema Elétrico*. Uberlândia, 2011.

GAMBOA, J. *Deep learning for time-series analysis*. Cornell University. p. 10, 2017.

HOCHREITER, S. & SCHMIDHUBER, J. *Long short-term memory*. Neural Computation 9(8): 1735–1780, 1997.

HYNDMAN, R.J. & ATHANASOPOULOS, G. *Forecasting: Principles and Practice*. 2. ed. Libgen Librarian, 2018.

ROCHA, L.R.R.; MONTEIRO, M.A.G. *Gestão energética*. Rio de Janeiro: Eletrobras; Procel, 2005.

SHMUELI, G. & JUNIOR, K.C.L. *Practical TimeSeries Forecasting with R: A Hands-On Guide*. 2. ed. AxelrodSchnall Publishers, 2016.

TIAN C.; MA J.; ZHANG C. & ZHAN P. *A deep neural network model for short-term load forecast based on long short-term memory network and convolutional neural network*. Vol. 11. Energies, 2018.