

PREVISÃO DE DEMANDA EM UMA EMPRESA DE SERVIÇOS ELÉTRICOS: UMA ANÁLISE COMPARATIVA DOS MODELOS ARIMA E SARIMA

Fernanda Raquel Rodrigues Costa*  fernanda.costa@alunos.ufersa.edu.br

Miriam Karla Rocha*  miriam.rocha@ufersa.edu.br

Macilene Maria Monteiro Maia*  macilene.maia@alunos.ufersa.edu.br

Gabrielli Harumi Yamashita**  gabrielli.yamashita@ufc.br

*Universidade Federal Rural do Semi-Árido (UFERSA), Mossoró, RN, Brasil

**Universidade Federal do Ceará (UFC), Russas, CE, Brasil

Resumo: A distribuição de energia elétrica tem uma função essencial no cotidiano da sociedade atual, por isso atender as demandas dos clientes em tempo hábil é de extrema importância. Dessa forma, é preciso realizar o planejamento da produção com antecedência, em virtude do tempo de resposta após a tomada de decisões. Portanto, esse trabalho tem como objetivo realizar previsão de demanda do atendimento emergencial de uma empresa prestadora de serviços elétricos utilizando os modelos de previsão baseados em séries temporais, ARIMA e SARIMA. A pesquisa se caracteriza como aplicada, pois teve o intuito de utilizar os conhecimentos adquiridos para resolução de problemas. Para isso, foram utilizados dados de janeiro de 2021 a junho de 2023, e com a aplicação dos métodos observou-se que, O resultado alcançado com o modelo ARIMA se mostrou apropriado, pois apresentou um erro percentual absoluto médio de 7,91% e um coeficiente de determinação de 0,62, mostrando que 62% do que foi previsto pode ser explicado pelos dados coletados. Ao final do trabalho o objetivo foi alcançado, no entanto, alguns fatores externos incontroláveis acabam interferindo nos resultados impossibilitando a sua melhoria.

Palavras-chave: Serviços elétricos. Atendimento emergencial. Previsão de demanda. ARIMA. SARIMA.

1 INTRODUÇÃO

Os serviços de distribuição de energia desempenham um papel fundamental na sociedade, pois são essenciais para a indústria, hospitais, empresas e residências, e sua disponibilidade é indispensável no cotidiano. Contudo, a demanda por serviços elétricos na rede é muito dinâmica e está sujeita a uma série de fatores, em virtude disso, um bom dimensionamento das equipes pode significar redução de custos e melhoria da entrega do serviço ao cliente (MAGRO, 2003).

Lima e Nogueira (2022) abordam que devido a sua complexidade e extensão, os sistemas de distribuição de eletricidade estão propensos a apresentar muitas falhas, que acarretam a falta do fornecimento de energia. Nesse contexto, é importante para uma organização atender às necessidades de seus clientes. Contudo, isso requer um planejamento e controle de produção eficiente, considerando que a maior parte de seu investimento está na operação (CORRÊA e CORRÊA, 2022).

Assim, se torna indispensável fazer o planejamento das necessidades futuras, pois elas estão diretamente ligadas a capacidade, no qual, possui uma característica primordial para obtenção dos recursos, a inércia decisória, ou seja, o tempo que existe

entre tomar a decisão e começar a visualizar as suas consequências. Isso se deve ao fato de que, para aumentar a capacidade produtiva, é necessário tempo para exercer algumas atividades como, selecionar e treinar novos funcionários, comprar novos equipamentos, expandir as instalações, e esse tempo é proporcional a sua expansão. (CORRÊA et al., 2018)

Nesse contexto, conforme indicado por Corrêa et al. (2018), ter um direcionamento estratégico que diga para onde está indo e a forma que será realizado previnem reagir aos problemas a curto prazo, evitando o desgaste da operação. Logo, a utilização de metodologias como a previsão de demanda contribui para tomada de decisão.

Na literatura existem muitas publicações que tratam a respeito desse tema com aplicações para indústria, na fabricação de produtos ou relacionado a vendas, no entanto, em relação ao setor de serviços o volume é bem reduzido. Assim, o planejamento da produção em serviços é de vital importância, justificado pelas suas características de simultaneidade, que implicam na impossibilidade de estocagem, ou seja, eles são consumidos e criados ao mesmo tempo, e perecibilidade, destacando que cada vez que um serviço não é realizado, representa uma oportunidade perdida (FITZSIMMONS e FITZSIMMONS, 2014).

Se tratando do setor elétrico alguns autores abordam acerca da previsão de demanda por energia elétrica, como Irffi et al. (2009) que utiliza do método OLS dinâmico e mudança de regime e Andrade (2010) que em seu trabalho aplica a abordagem Neurofuzzy. Já, Soruco (2018) teve por objetivo elaborar um método que calculasse a demanda prevista e fizesse o dimensionamento do mercado de materiais elétricos.

Outros autores abordam a temática de maneira diferente, como Magro (2003) que utiliza dos dados da demanda para realizar o dimensionamento de equipes para uma empresa prestadora de serviços elétricos. Com isso, nota-se que na literatura existe um déficit de trabalhos que abordem sobre a previsão da demanda de serviços no setor elétrico, um reflexo de que possivelmente não vêm sendo aplicado também nos processos das empresas, ressaltando a importância da sua aplicação.

Portanto, o propósito deste estudo é realizar previsões de demanda para uma empresa de serviços elétricos. Para atingir esse objetivo, serão utilizados os modelos de Média Móvel Integrada Autoregressiva (ARIMA) e Média Móvel Integrada Autoregressiva com Sazonalidade (SARIMA). O foco é identificar o modelo mais

apropriado com base nos dados, visando apoiar a organização na otimização de recursos e no aprimoramento do planejamento estratégico de suas operações.

2 REFERENCIAL TEÓRICO


Esta sessão abordará os conceitos principais para entendimento da pesquisa, sendo: previsão de demanda, séries temporais, modelo ARIMA e SARIMA.

2.1 Previsão de Demanda

Uma previsão é uma análise dos eventos que acontecerão no futuro com intuito de contribuir no planejamento. Elas auxiliam a planejar os recursos existentes e a escolher artifícios adicionais caso necessário (RITZMAN E KRAJEWSKI, 2003).

De acordo com Corrêa e Corrêa (2022), as previsões de demanda são fundamentais para dar suporte às decisões na operação e devem ser acompanhadas do erro esperado e do que se pode fazer para reduzir esse erro. Em concordância, Tubino (2017) aborda que ela é o fator mais importante para o planejamento e controle da produção, pois ajuda os administradores a enxergarem o futuro e planejar acertadamente suas ações. E, podem ser construídas em cinco fases, conforme a Figura 1.

Figura 1 - Etapas de um modelo de previsão




Fonte: Tubino (2017)

Inicialmente, é definido o motivo e para qual produto ou serviço surgiu a necessidade de realização da previsão. Posteriormente, os dados são coletados e analisados, sendo levado em consideração o tamanho da amostra coletada, sua caracterização real da demanda e suas variações anormais. Com isso, deve-se definir qual a técnica de previsão será usada para então obter a previsão, monitorar seu erro e fazer ajustes se necessário (TUBINO, 2017).

Alguns autores como Ritzman e Krajewski (2003), Corrêa e Corrêa (2022), Tubino (2017) e Lage Jr. (2019) coincidem com o preceito de que existem dois grupos gerais para se dividir as técnicas de previsão de demanda, as técnicas qualitativas e as quantitativas, conforme a Figura 2.

Figura 2 - Técnicas de previsão de demanda



Fonte: Corrêa e Corrêa (2022)

A escolha da técnica de previsão adequada está sujeita à natureza dos dados e sua existência. As técnicas qualitativas são baseadas na análise e entendimento de especialistas e as quantitativas compreende analisar tecnicamente os dados passados (TUBINO, 2017).

De acordo com Corrêa e Corrêa (2022) as técnicas quantitativas são divididas em intrínsecas que é quando a tendência, declínio ou ciclicidades do passado são replicadas no futuro, e as extrínsecas que leva em consideração que as causas que explicam os dados do passado continuam a interferir no seu comportamento futuro. Já Ritzman e Krajewski (2003) apresentam a perspectiva de que os processos quantitativos são subdivididos em método causal e a análise de séries temporais.

2.2 Série temporal

“Uma série temporal é qualquer conjunto de observações ordenadas no tempo.” (MORETTI e TOLOI, 2018).

Lage Jr(2019) aborda que o objetivo principal da sua utilização é previsão do futuro com base nos dados históricos, sendo mais adequado às situações de curto prazo. Moretti e Toloi (2018) comentam que é possível realizar uma análise de séries temporais com o intuito de investigar a sua geração, fazer previsões ou descrever seu

comportamento. Para isso, um pressuposto inicial é que elas sejam estacionárias, ou seja, seus dados evoluem no tempo de maneira aleatória em torno de uma média constante.

Uma série temporal pode apresentar três principais componentes: tendência, ciclicidade e aleatoriedade. A primeira é representada pelo crescimento ou decrescimento dos dados, a segunda diz respeito aos padrões que se repetem em períodos definidos, e o terceiro é representado pelas variáveis imprevisíveis (CORRÊA e CORRÊA, 2022).

2.3 Modelo ARIMA

De acordo com Sato (2013) o modelo ARIMA foi elaborado por George Box e Gwilym Jenkins em 1970 com o intuito de utilizar a matemática para descrever séries temporais. Sua forma mais geral para modelos não sazonais é (p,d,q) , onde p representa a parte autorregressiva, d o grau de diferenciação e q é a ordem da média móvel.

Este modelo está apto a descrever de maneira apropriada tanto séries estacionárias como as não estacionárias. Ele é construído com base em um ciclo iterativo, que é estruturado com fundamentos nos próprios dados. Primeiramente, é feita a etapa de especificação onde é escolhida uma classe geral do modelo aplicado. Em seguida, é realizada a identificação na qual a série temporal é analisada para identificar os padrões. Posteriormente, iniciar a fase de estimação que representa a escolha dos parâmetros adequados. E, por fim, o modelo é verificado através do estudo dos resíduos (MORETTI e TOLOI, 2018).

2.4 Modelo SARIMA

Quando a série temporal apresenta componentes de sazonalidade é utilizado o modelo SARIMA, que nada mais é do que o modelo ARIMA acrescentado a esse fator. Sendo assim, o modelo SARIMA compreende uma parte não sazonal com os parâmetros (p,d,q) e uma parte sazonal com os parâmetros (P,D,Q) (ESPINOSA et al. , 2010).

Um exemplo de aplicação do SARIMA está no trabalho de Water et al.(2013), o qual utiliza desse modelo na previsão de vendas de motocicletas, e se mostrou mais

adequado em virtude do comportamento sazonal da série. Também foi aplicado por Sanches et al. (2019) com o intuito de realizar a previsão de demanda de usuários de transporte público.

3 PROCEDIMENTOS METODOLÓGICOS


Nesta seção será apresentada a caracterização da empresa do estudo em questão, assim como a classificação da pesquisa e suas etapas.

3.1 Caracterização da empresa

A empresa em análise oferta uma gama de serviços que incluem manutenção de redes elétricas, atendimento emergencial e comercial, além da construção de sistema de redes de distribuição de energia para empresas distribuidoras de energia elétrica no Brasil. O contrato em que o estudo foi aplicado atende um total de 24 cidades da região sul do Ceará. Para isso, a organização conta com 7 equipes de manutenção, sendo elas compostas por 5 equipes com 5 colaboradores e 2 equipes com 2 integrantes. Também conta com 33 turmas de atendimento emergencial e 34 para serviços comerciais ambas formadas por 2 funcionários. E, 15 equipes para o setor de obras, contando cada uma com 6 colaboradores.

Os processos de cada uma dessas atividades variam. Pois, para manutenção e construção de redes são ofertados pacotes de serviços trimestrais que são programados para execução durante esse período. No caso dos trabalhos comerciais, esses são disponibilizados semanalmente, além disso, existem demandas diárias com prazo de execução de 48h. O atendimento emergencial segue um processo diferente, conforme ilustrado na Figura 3.

Figura 3 - Fluxo do atendimento emergencial




Para a execução do atendimento emergencial, a demanda de serviços é oferecida diretamente pelo cliente, ou seja, quando ele se encontra com falta de fornecimento de energia elétrica podendo ser apenas na unidade consumidora ou em várias localidades, faz uma reclamação que é recebida pelo *call center* e registrada no sistema. Desse modo, um setor da empresa é responsável por monitorar em tempo real a chegada das reclamações e roteirizar as equipes, que por sua vez têm a responsabilidade de verificar o que foi passado para então executar. Ao finalizar a entrega do serviço, a reclamação é registrada como concluída.

3.2 Classificação e etapas da pesquisa

De acordo com Gil (2019) a pesquisa tem o intuito de encontrar soluções para os problemas por meio de processos científicos, podendo ser classificadas quanto a sua finalidade, objetivos e natureza. Dessa forma, o presente trabalho se caracteriza como uma pesquisa aplicada, visto que objetiva utilizar os conhecimentos para a resolução de problemas específicos dentro de uma realidade. Quanto aos objetivos é exploratória, pois pretende esclarecer conceitos e levantar hipóteses acerca de um fenômeno. Quanto à natureza de seus dados, é considerada quantitativa, pois faz uso de números e medidas estatísticas para representar fenômenos.

Portanto, para realizar previsões de demanda em uma empresa de serviços elétricos, o estudo seguiu 5 etapas, conforme ilustrado na Figura 4.

Figura 4 - Etapas da pesquisa



Fonte: Autoria própria (2023)

Inicialmente, foi realizada uma análise para identificação dos serviços da empresa para os quais havia informações precisas sobre a demanda real dos clientes. Visto que, em alguns casos, não havia uma solicitação direta dos consumidores, pois os serviços eram oferecidos por meio de pacotes e metas. Nesse contexto, ao aplicar esse critério, notou-se que o serviço de atendimento emergencial disponibilizava dados satisfatórios para o prosseguimento da pesquisa.

Na etapa 2, foram coletados dados referentes ao período 01 de janeiro de 2020 a 31 de junho de 2023. Após isso, foi iniciada a preparação da base de dados utilizando a linguagem de programação Python no ambiente Google Colab, realizando a exclusão das solicitações que tinham o status de “ANULADO”, pois representam reclamações repetidas ou geradas erroneamente, com isso foi realizada uma contagem da demanda mensal sendo agrupado em tabelas.

Em seguida na etapa 3, iniciou-se a análise descritiva dos dados utilizando a linguagem de programação Python, onde foi utilizada a tabela da etapa anterior para criar o gráfico da demanda e fazer uma análise visual do seu comportamento, também

foi realizada a decomposição da série para analisar a tendência, sazonalidade e os resíduos. E, por fim, foi verificada a estacionariedade da série utilizando os testes de raiz unitária de Dickey-Fulley Aumentado (ADF) e Kwiatkowski–Phillips–Schmidt–Shin (KPSS).

A etapa 4 iniciou com a aplicação dos métodos ARIMA e SARIMA na série temporal, para isso os dados foram divididos em conjuntos de treino e teste. Assim, os dados de janeiro de 2020 a dezembro de 2022 foram utilizados para aprendizagem do modelo, já o período de janeiro de 2023 a junho de 2023 foi usado para testar a previsão obtida. No entanto, visando obter resultados mais acurados, foi aplicada a função `auto.Arima` para identificar o parâmetro com o desempenho mais otimizado, com base na métrica de Critério de Informação de Akaike (AIC).

Por fim, na etapa 5, conduziu-se uma análise comparativa dos resultados dos modelos, utilizando as métricas disponíveis na biblioteca “`sklearn.metrics`”, em que $\hat{y}_i$ é o valor previsto do i -ésimo período e y_i o valor real correspondente da série temporal, as equações utilizadas foram:

- Raiz do Erro Quadrático Médio (RMSE), onde nesse caso será aplicada a raiz na equação do MSE, conforme Equação 1:

Equação 1 - Equação MSE

$$\text{MSE}(y, \hat{y}) = \frac{1}{n_{\text{samples}}} \sum_{i=0}^{n_{\text{samples}}-1} (y_i - \hat{y}_i)^2.$$

Fonte: `sklearn.metrics`(2023)

Essa métrica calcula qual a diferença entre o valor predito e o valor real, e o resultado está na mesma escala dos dados utilizados na previsão em virtude da aplicação da raiz quadrada

- Erro Absoluto Médio (MAE), conforme Equação 2:

Equação 2- Equação MAE

$$\text{MAE}(y, \hat{y}) = \frac{1}{n_{\text{samples}}} \sum_{i=0}^{n_{\text{samples}}-1} |y_i - \hat{y}_i|.$$

Fonte: sklearn.metrics(2023)

Esta função mede a média do módulo da diferença entre o valor real com o predito, em virtude da existência de valores negativos e positivos, sendo que o valor da saída está na mesma escala dos dados de entrada.

- R-quadrado ou coeficiente de determinação, conforme Equação 3:

Equação 3 - Equação R^2

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

Fonte: sklearn.metrics(2023)

É utilizado para verificar o percentual do modelo que pode explicar a variável prevista.

- Erro Percentual Médio Absoluto (MAPE), conforme a Equação 4:

Equação 4 - Equação MAPE

$$\text{MAPE}(y, \hat{y}) = \frac{1}{n_{\text{samples}}} \sum_{i=0}^{n_{\text{samples}}-1} \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)}$$

Fonte: sklearn.metrics(2023)

Essa métrica reflete a porcentagem de erro em relação aos valores reais, sendo mais sensível aos erros relativos.

4 RESULTADOS

Os dados foram adquiridos a partir do sistema interno da empresa. Após a decisão de conduzir o estudo com foco no serviço de atendimento emergencial, procedeu-se à preparação da base de dados. As informações foram agregadas mensalmente, resultando em 42 períodos, conforme ilustrado na Tabela 1. Sendo estes utilizados para realizar análise descritiva.


Tabela 1 - Quantidade de serviços por mês

Período	Qtd.	Período	Qtd.	Período	Qtd.	Período	Qtd.
01-2020	5270	01-2021	4354	01-2022	5818	01/2023	6345
02-2020	4770	02-2021	4554	02-2022	4441	02/2023	5763
03-2020	5259	03-2021	5134	03-2022	6371	03/2023	7177
04-2020	4368	04-2021	3986	04-2022	5737	04/2023	6061
05-2020	4250	05-2021	3614	05-2022	4953	05/2023	5059
06-2020	3523	06-2021	3059	06-2022	3989	06/2023	4610
07-2020	3691	07-2021	3826	07-2022	4224		
08-2020	3880	08-2021	3980	08-2022	4293		
09-2020	3801	09-2021	4230	09-2022	4449		
10-2020	4028	10-2021	4881	10-2022	4930		
11-2020	4126	11-2021	4640	11-2022	4926		
12-2020	3968	12-2021	5193	12-2022	4888		

Fonte: Autoria Própria (2023)

Inicialmente, foi utilizado a linguagem de programação Python na ferramenta do Google Colab para obtenção do gráfico da demanda, que permitiu analisar visualmente o seu comportamento entre janeiro de 2020 a junho de 2023, conforme a Figura 5.

Figura 5 - Demanda de Serviços 2020-2023




Fonte: Autoria Própria (2023)

Em seguida, foi realizado o teste de estacionariedade utilizando o ADF, que para hipótese nula levou em consideração a presença de raiz unitária nos dados, indicando a não estacionariedade. Dessa forma o teste apresentou um valor de p-value menor que 0,05 e coeficiente maior que os valores críticos de 5% e 10%. Já o teste KPSS, que considera para hipótese nula a ausência de raiz unitária, indicando que a série é estacionária, apresentou o valor de p-value maior que 0,05 e o coeficiente menor que todos os valores críticos. Com isso, foi possível concluir que a série é estacionária.

Para a decomposição foi escolhido o método aditivo visto que os resultados apresentam a mesma grandeza dos dados. Assim, de acordo com os gráficos presentes na Figura 6, conclui-se que o gráfico apresentou uma leve tendência de crescimento, uma possível sazonalidade e os resíduos se comportam de maneira aleatória.

Figura 6 - Decomposição da série




Fonte: Autoria Própria (2023)

Dessa forma, procedeu-se com a divisão dos dados em conjuntos de treino e teste, abrangendo o período de janeiro de 2020 a dezembro de 2022 para o treino e os primeiros seis meses de 2023 para teste.

Posteriormente, identificou-se através da função `auto.arima` quais são os melhores parâmetros a serem trabalhados nos dois modelos. Para o ARIMA foi encontrado que (1,0,0) era o modelo com um menor índice de AIC, já em relação ao SARIMA os parâmetros (0,0,1)(1,1,0) [12] se apresentou preferível.

Com a implementação do modelo de previsão do ARIMA, foi efetuada a previsão para janeiro a junho de 2023. Foi obtida representação gráfica dos dados de teste em azul e previstos em vermelho, conforme demonstrado na Figura 7.


Figura 7 - Previsão de demanda método ARIMA



Fonte: Autoria Própria (2023)

Além disso, o modelo SARIMA também foi empregado para fins de comparação, conforme ilustrado na Figura 8, na qual os dados de teste estão representados em azul, enquanto os valores previstos estão em verde. Observa-se que esse modelo, que leva em consideração a sazonalidade, apresenta uma previsão que segue a mesma tendência da curva real, embora com valores abaixo do esperado.

Figura 8 - Previsão de Demanda com Sazonalidade



Fonte: Autoria Própria (2023)

Para comparar os resultados de cada modelo foram calculados quatro tipos de erros, os resultados encontrados podem ser visualizados na Tabela 2.

Tabela 2 - Erros para o modelo ARIMA e SARIMA

Modelo	RMSE	MAE	R²	MAPE
ARIMA	517.125	451.224	0.62	7.91%
SARIMA	912.063	859.628	-0.18	14.68%

Fonte: Autoria Própria (2023)

Para as métricas do RMSE e MAE temos o resultado na mesma escala dos dados utilizados na previsão, no entanto o segundo não é afetado pelos dados discrepantes. Portanto, constatou-se que o ARIMA, em comparação com o SARIMA, demonstrou uma discrepância significativamente menor na quantidade de erros, tanto positivos quanto negativos. Além disso, apresentou um percentual médio de erro em relação aos valores reais da série menor. No entanto, mesmo que o MAPE para o SARIMA tenha sido baixo, essa resposta não é aceitável, considerando que esse percentual expressa representa uma necessidade de recursos adicionais.

O coeficiente de determinação mostra o percentual que a variável prevista pode ser explicada pelos dados exploratórios, variando entre 0 e 1 (Martins, 2018). Conforme salientado por Batista (2004), não existe uma classificação absoluta que determine a melhor medida para analisar o R^2 isso dependerá da ocasião aplicada. Portanto, como consequência dos modelos utilizados, encontrou-se que utilizando o ARIMA os dados explicam 62% da variação da previsão encontrada e o SARIMA -18%. Apesar de ser inaceitável um valor negativo para essa métrica a biblioteca “sklearn.metrics” aceita esse valor como resultado e argumenta em seu repositório que isso é causado pois modelo pode ser arbitrariamente pior (SCIKIT-LEARN,2023)

Nesse contexto, os resultados dos modelos utilizados revelam que o modelo ARIMA se destaca como a escolha mais apropriada para esse tipo de dado, devido à sua capacidade de proporcionar resultados mais precisos. Por outro lado, o modelo SARIMA não se revela a opção mais adequada, embora visualmente seja possível identificar um padrão por meio da decomposição dos dados.

5 CONCLUSÃO

A pesquisa teve como objetivo a realização de uma previsão de demanda de serviços emergenciais por meio da aplicação dos modelos ARIMA e SARIMA, aplicados a uma empresa que presta serviços elétricos, de forma a contribuir na otimização dos recursos e no planejamento estratégico da empresa. Este fim foi atingido, visto que ao final do trabalho, os erros encontrados para aplicação do primeiro modelo se mostraram satisfatórios.

O resultado alcançado com o modelo ARIMA se mostrou apropriado, pois apresentou um erro percentual absoluto médio de 7,91% e um coeficiente de determinação de 0,62, mostrando que 62% do que foi previsto pode ser explicado pelos dados coletados. Já para o método SARIMA, os resultados encontrados não foram satisfatórios, pois o valor para o erro médio absoluto foi elevado. Considerando que esse tipo de serviço apresenta uma inércia decisória alta, não seria possível preparar uma equipe e deixa- lá apta a tempo da realização do serviço, desse modo, não é recomendado a consideração do modelo SARIMA.

Mesmo com os resultados encontrados vale ressaltar que existem fatores externos que influenciam diretamente na demanda como clima, ventos e manutenção preventiva. Para o tipo de serviço analisado, a manutenção preventiva é primordial para manter a rede de distribuição preservada, se ela não for realizada, existe um aumento de avarias e necessidade de atendimento emergencial, ou seja, é inversamente proporcional ao volume da demanda. Porém, apesar de ser possível de mensurar matematicamente, esses fatores não podem ser utilizados nas técnicas de séries temporais

Outra consideração a ser levantada é que, para a pesquisa se tornar útil no dia a dia da empresa, seria necessário a implementação do BI com os resultados encontrados, funcionando assim como uma ferramenta para tomada de decisões.

REFERÊNCIAS

ANDRADE, Luciano Carli Moreira de. **Abordagem neurofuzzy para previsão de demanda de energia elétrica no curtíssimo prazo**. 2010. Tese de Doutorado. Universidade de São Paulo.

BATISTA, João L. F. **Análise de Regressão Aplicada**. Piracicaba: Departamento de Ciências Florestais ESALQ - USP, 2004. Disponível em: <http://cmq.esalq.usp.br/wiki/lib/exe/fetch.php?media=biometria:encontros:applied-regression.pdf>. Acesso em: 24 set. 2023.

CORRÊA, Henrique L.; CORRÊA, Carlos A. **Administração de Produção e Operações: Manufatura e Serviços: Uma Abordagem Estratégica**. Barueri [SP]: Grupo GEN, 2022. E-book. ISBN 9786559773268. Disponível em: <https://app.minhabiblioteca.com.br/#!/books/9786559773268/>. Acesso em: 20 set. 2023.

CORRÊA, Henrique L.; GIANESI, Irineu Gustavo N.; CAON, Mauro. **Planejamento, Programação e Controle da Produção - MRP II / ERP**, 6ª edição. São Paulo: Grupo GEN, 2018. E-book. ISBN 9788597018554. Disponível em: <https://app.minhabiblioteca.com.br/#!/books/9788597018554/>. Acesso em: 02 out. 2023.

ESPINOSA, Mariano Martinez; PRADO, Silvia Maria; GHELLERE, Maikelli. Uso do modelo SARIMA na previsão do número de focos de calor para os meses de junho a outubro no Estado de Mato Grosso. **Ciência e Natura**, v. 32, n. 2, p. 7-21, 2010.

FITZSIMMONS, James A.; FITZSIMMONS, Mona J. **Administração de serviços: operações, estratégia e tecnologia da informação**. Porto Alegre: Grupo A, 2014. E-book. ISBN 9788580553291. Disponível em: <https://app.minhabiblioteca.com.br/#!/books/9788580553291/>. Acesso em: 29 ago. 2023.

GIL, Antonio C. **Métodos e Técnicas de Pesquisa Social**, 7ª edição. São Paulo: Grupo GEN, 2019. E-book. ISBN 9788597020991. Disponível em: <https://app.minhabiblioteca.com.br/#!/books/9788597020991/>. Acesso em: 18 set. 2023.

IRFFI, Guilherme et al. Previsão da demanda por energia elétrica para classes de consumo na região Nordeste, usando OLS dinâmico e mudança de regime. **Economia Aplicada**, v. 13, p. 69-98, 2009.

LAGE JUNIOR, M. **Planejamento e Controle da Produção: teoria e prática**. Rio de Janeiro: LTC, 2019. E-book. ISBN 9788521636304. Disponível em: <https://app.minhabiblioteca.com.br/#!/books/9788521636304/>. Acesso em: 20 set. 2023.

LIMA, Natalia Almeida; NOGUEIRA, Fernando José. **Melhorias nos sistemas de distribuição de energia elétrica**. Caderno de Estudos em Engenharia Elétrica, v. 4, n. 1, 2022.

MAGRO, Magda Alexandra De Bona. **Dimensionamento de equipes baseado em modelos de previsão, simulação e alocação**: caso de uma empresa do setor elétrico. 2003.

MARTINS, E. G. M. Coeficiente de determinação. **Revista Ciência Elementar**, v. 6, n. 1, p. 24, 2018.

MORETTIN, Pedro A.; TOLOI, Clélia MC. **Análise de séries temporais: modelos lineares univariados**. Editora Blucher, 2018.

RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da produção e operações**. 1. ed. São Paulo: Pearson, 2004. E-book. Disponível em: <https://plataforma.bvirtual.com.br>. Acesso em: 20 set. 2023.

SATO, Renato Cesar. **Gerenciamento de doenças utilizando séries temporais com o modelo ARIMA**. Einstein (São Paulo), v. 11, p. 128-131, 2013.

SANCHES, Camila Romão da Silva et al. Modelo Sarima Aplicado à Previsão de Demanda de Usuários de Transporte Público Entre Campos dos Goytacazes e São João Da Barra. **Revista Interdisciplinar Pensamento Científico**, v. 5, n. 3, 2019.

SCIKIT-LEARN. **scikit-learn: machine learning in Python** — scikit-learn 0.20.3 documentation. Disponível em: <<https://scikit-learn.org/stable/index.html>>.

SORUCO, Ricardo Gastal. **Dimensionamento de mercados e previsão de demanda no setor elétrico brasileiro**. 2018.

TUBINO, Dalvio F. **Planejamento e Controle da Produção** - Teoria e Prática, 3ª edição. São Paulo: Grupo GEN, 2017. E-book. ISBN 9788597013726. Disponível em: <https://app.minhabiblioteca.com.br/#!/books/9788597013726/>. Acesso em: 20 set. 2023.

WALTER, Olga Maria Formigoni Carvalho et al. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta**, v. 11, n. 1, p. 77-88, 2013.