

PREVISÃO DE DEMANDA DE INSUMOS CRÍTICOS NA ÁREA DE TELECOMUNICAÇÕES

FORECASTING DEMAND FOR CRITICAL SUPPLIES IN THE TELECOMMUNICATIONS SECTOR

Maria Vanessa dos Santos Ferreira^{1*}, Thiago Magalhães Amaral², Ana Cristina Gonçalves Castro Silva³,
Pedro Vieira Souza Santos⁴

^{1,2,3,4} [Universidade Federal do Vale do São Francisco, Petrolina-PE, Brasil](http://www.univasf.edu.br)

¹mariavreserva@gmail.com ²thiago.magalhaes@univasf.edu.br ³castroanasilva@gmail.com

⁴pedrovieirass@hotmail.com

*Autor Correspondente: Ferreira, M.V.S.

RESUMO: O setor de telecomunicações desempenha um papel fundamental na conectividade e no desenvolvimento econômico e social. No entanto, empresas do setor enfrentam desafios na previsão de demanda de insumos críticos, como roteadores e ONU (*Optical Network Units*), que impactam diretamente na eficiência operacional. Este trabalho teve como objetivo aplicar o modelo ARIMA para prever a demanda trimestral desses insumos em uma empresa provedora de internet localizada no Vale do São Francisco. Para isso, foi realizada uma análise de séries temporais utilizando dados históricos organizados e tratados no software R 4.4.1, complementada por comparação com outro método média móvel simples. Os resultados indicaram que o ARIMA apresentou menor erro percentual absoluto médio em relação à média móvel para roteadores, destacando sua eficácia em capturar variações. No caso das ONUs, a previsão permaneceu estável, sugerindo a necessidade de ampliar a base de dados ou testar outros métodos como redes neurais para esse insumo. Conclui-se que o ARIMA é uma ferramenta eficaz para otimizar o planejamento de compras e gestão de estoque em empresas do setor. Para trabalhos futuros, recomenda-se explorar técnicas complementares, como aprendizado de máquina, para aumentar a precisão e capturar padrões mais complexos das séries temporais.

PALAVRAS-CHAVE: Previsão da demanda. ARIMA; Séries temporais; Internet; Telecomunicações.

ABSTRACT: The telecommunications sector plays a fundamental role in connectivity and economic and social development. However, companies in the sector face challenges in forecasting the demand for critical inputs, such as routers and ONU (*Optical Network Units*), which directly impact operational efficiency. This study aimed to apply the ARIMA model to forecast the quarterly demand for these inputs in an internet service provider located in the São Francisco Valley. A time series analysis was conducted using historical data organized and processed in the R 4.4.1 software, complemented by a comparison with another method, simple moving average. The results indicated that ARIMA demonstrated a lower

mean absolute percentage error compared to the moving average for routers, highlighting its effectiveness in capturing variations. For ONUs, the forecast remained stable, suggesting the need to expand the data set or test other methods such as neural networks for this input. It is concluded that ARIMA is an effective tool for optimizing purchase planning and inventory management in companies in the sector. For future studies, it is recommended to explore complementary techniques, such as machine learning, to increase accuracy and capture more complex patterns in time series.

KEYWORDS: Demand forecasting; ARIMA; Time Series; Internet; Telecommunications.

1 INTRODUÇÃO

A telecomunicação de banda larga desempenha um papel crucial ao conectar pessoas, empresas e instituições, possibilitando a troca rápida de informações, impulsionando a inovação, e promovendo o desenvolvimento econômico e social em escala global. A ANATEL (2020) define provedor de internet ou *Internet Service Provider* (ISP) como uma empresa que oferece serviços de conexão à internet para os usuários finais. Esses serviços podem incluir acesso à internet via conexões de banda larga, como fibra óptica, cabo, *Digital Subscriber Line* (DSL) e tecnologias sem fio, como Wi-Fi.

Para o crescimento das empresas de telecomunicação, é crucial investir em infraestrutura, atendimento de qualidade, equipe, captação de clientes eficiente e numa boa gestão financeira e operacional. O planejamento adequado das atividades é fundamental em todas as fases dos processos, sendo um desafio para os gestores, especialmente no setor de serviços. A previsão de demanda precisa é essencial para alinhar o custo operacional ao padrão de qualidade exigido, permitindo à empresa obter lucro. Essa previsão oferece informações sobre a quantidade necessária de produtos e o momento em que serão demandados, utilizando métodos quantitativos e qualitativos (Arvan, 2019).

Roteadores e ONUs são considerados insumos críticos e de alto valor agregado, uma vez que a empresa investe aproximadamente R\$ 217,00 por roteador e R\$ 99,99 por ONU. No entanto, o excesso de aquisições desses itens pode gerar retenção de capital de giro, custos de armazenagem e risco de obsolescência tecnológica, uma vez que a tecnologia desses equipamentos muda rapidamente. Além disso, é essencial que os investimentos em tecnologia sigam uma ordem de prioridades, garantindo que a infraestrutura básica, como o cabeamento, esteja em ordem antes de investir em *softwares*. Um cabeamento robusto é crucial para suportar outras aplicações e facilitar o fluxo de dados (CADE, 2023).

Poucos estudos são direcionados à previsão da demanda em provedores de internet e têm como objetivo comum o aprimoramento da qualidade dos serviços oferecidos pelas empresas de telecomunicações. Por exemplo, a demanda por suporte em uma empresa do setor foi investigada por meio dos modelos ARIMA e Holt Winters, comparando sua confiabilidade e precisão na previsão de demandas (Campos; Campolim, 2022).

Em outro estudo, uma análise de curva ABC e previsão da demanda em um provedor de internet foi realizada, com foco na identificação de produtos de classe A e na previsão de demanda por métodos como média móvel simples, média móvel ponderada e exponencial (Abreu et al., 2023). Em contraste com abordagens mais simples, Araújo et al., 2021 apresentaram um modelo adaptativo de previsão de recursos de rede em provedores, utilizando dados reais e sugerindo melhorias em relação às técnicas de previsão tradicionais.

Dessa forma, esta pesquisa busca responder à seguinte pergunta: Como que a aplicação de um método de previsão da demanda trimestral de ONU e Roteador em um provedor de internet pode melhorar a gestão destes dispositivos? O objetivo geral deste trabalho foi aplicar o método ARIMA para prever a demanda de insumos críticos (roteadores e ONUs) afim de melhorar a gestão desses dispositivos em uma empresa prestadora de serviços de telecomunicações de banda larga.

O ARIMA foi escolhido como método de previsão de demanda uma vez que é robusto, captura padrões temporais complexos, ajusta automaticamente os parâmetros, e oferece melhor desempenho em previsões de longo prazo (APTECH, 2024). Isso resulta em previsões mais precisas e confiáveis, levando a uma melhor gestão de estoque, planejamento de produção e otimização de recursos na empresa.

2 REFERENCIAL TEÓRICO

Equipamentos de internet e Wi-Fi 6

A qualidade do serviço de internet residencial depende do bom funcionamento de equipamentos essenciais, como uma Unidade de Rede Óptica (ONU) é um equipamento utilizado em redes de fibra óptica que converte sinais ópticos recebidos da central do provedor em sinais elétricos, distribuindo-os para dispositivos finais (Intelbras, 2022). Outros equipamentos, como o *access point* e as antenas setoriais, expandem a cobertura da rede *wireless* e melhoram a qualidade do sinal. Esses componentes são comuns tanto em residências quanto em empresas, e a instalação de uma extensão óptica é necessária para conectar outros aparelhos à rede (Aloo, 2021).

Com a evolução constante da tecnologia, novos hardwares mais poderosos estão sendo desenvolvidos para atender à crescente demanda por aplicações robustas e redes sem fio de alta capacidade. Um roteador é um dispositivo de rede responsável por encaminhar pacotes de dados entre diferentes redes, conectando múltiplas sub-redes e gerenciando o tráfego de informações (Cloudflare, 2024). O Wi-Fi 6, por exemplo, oferece navegação em alta velocidade e suporte para um maior número de dispositivos conectados simultaneamente, com tecnologias otimizadas como OFDMA e MU-MIMO (ABRANET, 2022). Diante dessa evolução, o planejamento eficaz de compras é essencial para garantir a reposição contínua de materiais, preservando a saúde financeira da empresa (Gonçalves, 2013).

Técnicas de previsão da demanda

Segundo Slack, Chambers e Johnston (2009), os modelos de previsão podem ser classificados em objetivos versus subjetivos e causais versus não causais. Técnicas objetivas seguem procedimentos sistemáticos, enquanto as subjetivas dependem de julgamentos pessoais. As técnicas não causais utilizam dados passados para prever o futuro, enquanto as causais identificam relações de causa e efeito. Os modelos qualitativos, que dependem de opiniões de especialistas e são usados quando não há dados históricos confiáveis (Lemos, 2006; Santos, 2020; Soares et al., 2022).

As métricas de erro, como o Erro Médio Absoluto (MAE), o Erro Percentual Absoluto Médio (MAPE) e o Erro Quadrático Médio (RMSE), são amplamente utilizadas para avaliar o desempenho de modelos de previsão. Cada métrica oferece *insights* específicos: enquanto o MAE mede o erro absoluto médio, o RMSE enfatiza erros maiores devido à elevação ao quadrado, e o MAPE avalia o erro em termos percentuais, facilitando a interpretação em diferentes escalas (Ritzman; Krajewski, 2004; Santos, 2019).

Séries temporais

Modelos de previsão baseados em séries temporais utilizam dados históricos para projetar a demanda futura, partindo do pressuposto de que esses dados são constantes e previsíveis (Lemos, 2006). Esses modelos consideram observações igualmente espaçadas no tempo e pressupõem que os valores futuros podem ser estimados com base nos valores passados, sem associar a demanda a outras variáveis (Moreira, 2008). Uma das suposições comuns é que as séries temporais são estacionárias, ou seja, variam aleatoriamente em torno de uma média constante, apresentando equilíbrio estável (Morettin; Toloi, 2006).

A previsão exata de séries temporais aleatórias é impossível, uma vez que essas séries têm um comportamento não determinístico, ou seja, os valores futuros têm uma distribuição de probabilidade condicionada pelo conhecimento dos valores passados (Cordeiro, 2002). As organizações utilizam diversos métodos de previsão, desde técnicas simples e intuitivas até abordagens mais quantitativas e complexas (Morettin; Toloi, 2006). O quadro 1 apresenta as principais técnicas de previsão de séries temporais.

Quadro 1 – Técnicas de previsão de séries temporais

Técnicas de previsão de séries temporais	Características dos modelos	Modelo matemático
Média Móvel Simples	Pondera-se um período de tempo contendo um número de pontos dividindo a soma dos valores dos pontos pelo número dos pontos. Cada um deles, tem influência igual.	$F_t = \frac{A_{t-1} + A_{t-2} + A_{t-3} + \dots + A_{t-n}}{n}$
Média Móvel Ponderada	Pontos específicos podem ser ponderados mais ou menos do que outros, como parecerem adequados pela experiência.	$F_t = W_1 A_{t-1} + W_2 A_{t-2} + \dots + W_n A_{t-n}$
Suavização Exponencial	Pontos recentes são ponderados mais ou menos do que outros, declinando exponencialmente à medida que outros dados se tornam mais antigos.	$Y_{t+k} = L_t + K T_t$
Análise de regressão simples	Adapta uma linha reta aos dados passados, geralmente relacionando os valores de dados no tempo.	$Y = a + bX + \varepsilon$
Técnica Arima	Técnica estatística mais precisa disponível. Relaciona uma classe de modelos estatísticos aos dados e adapta o modelo à série temporal.	$Y_t^* = \mu + \beta_1 u_{t-1} + \beta_2 u_{t-2}$

Fonte: Jacobs, Chase e Aquilano (2006).

Modelo ARIMA

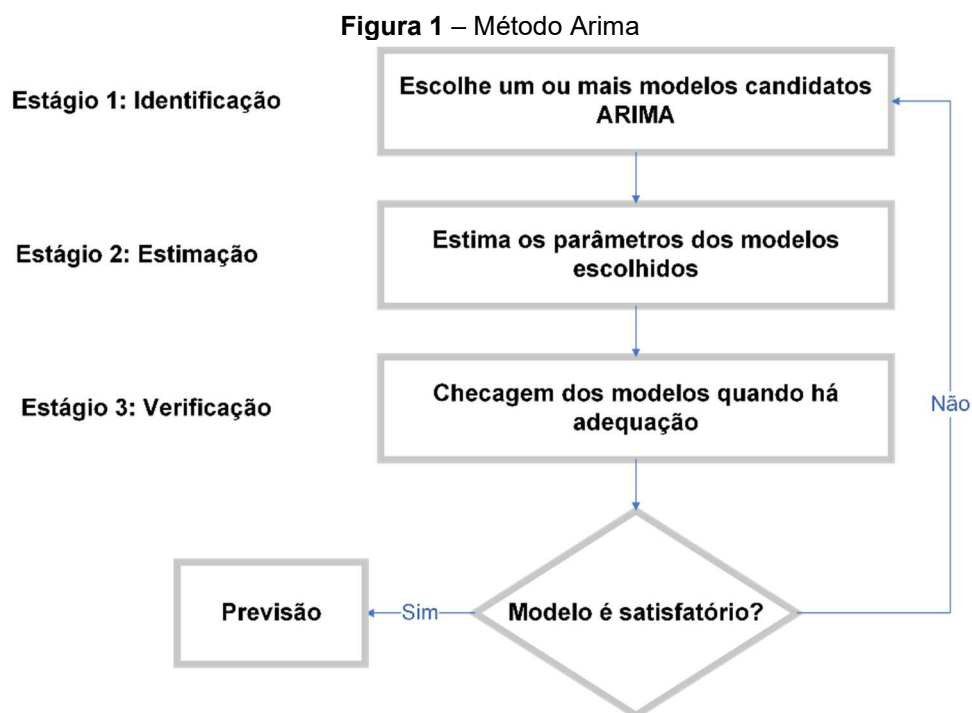
Os modelos de *Box-Jenkins*, também conhecidos como *Auto Regressive Integrated Moving Averages* (ARIMA), são usados em séries temporais e empregam algoritmos matemáticos complexos para projetar valores futuros. Essa abordagem é amplamente reconhecida e utilizada na análise de dados de séries temporais devido à sua versatilidade; pode lidar com uma variedade de séries, seja estacionária ou não, com ou sem elementos sazonais, e possui programas de computador bem documentados, contribuindo significativamente para sua popularidade. Embora os criadores da metodologia Arima não tenham sido os pioneiros ou os principais contribuidores no campo dos modelos de previsão, eles desempenharam um papel crucial em sua popularização e acessibilidade (Maddala, 2003).

Os modelos desenvolvidos por *Box-Jenkins* são estruturas matemáticas elaboradas através de um processo iterativo, cujo objetivo é identificar a correlação sequencial entre os valores de uma série temporal (Ballou, 2005). Ao combinar termos de Autorregressão

(AR), Integração (I) e Médias Móveis (MM), o método busca encontrar modelos capazes de representar a série temporal, permitindo realizar previsões precisas dos próximos valores da sequência (Consul; Werner, 2010). Enquanto os modelos autorregressivos são definidos como uma soma ponderada de valores anteriores da série, os modelos de médias móveis realizam a regressão dos valores utilizando os erros passados.

Nkongolo (2023) aplicou o modelo ARIMA para prever tendências de uso de dados em uma empresa de telecomunicações, obtendo melhores resultados que a Rede Neural Convolucional (CNN). Almaafi (2023) comparou o modelo ARIMA com o XGBoost na previsão de preços de fechamento semanais das ações da Saudi Telecom Company, a maior empresa de telecomunicações do Oriente Médio. Os resultados mostraram que o XGBoost superou o ARIMA em todas as métricas, destacando a eficácia dos métodos de aprendizado de máquina para esse propósito.

O ARIMA utiliza da combinação de denominados “filtros”. Essa combinação dos três filtros é característica dos modelos ARIMA, e a escolha entre eles depende da adequação aos dados e das necessidades específicas de previsão (Campos; Clemente; Cordeiro, 2006). A Figura 1 descreve as etapas do método ARIMA.



Fonte: Girardi, Camargo e Motta (2013).

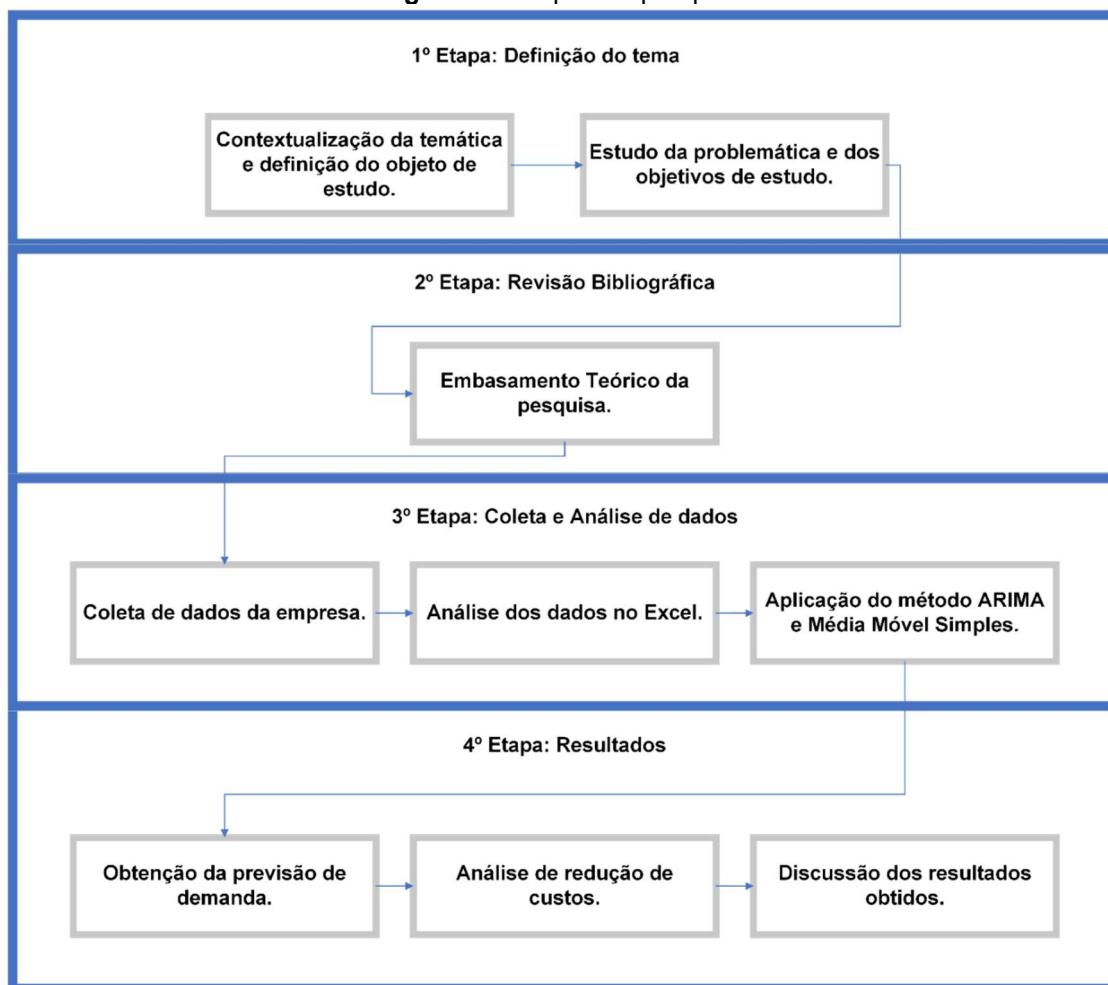
3 METODOLOGIA

Etapas da pesquisa

Na primeira fase, foram definidos o tema, o objeto de estudo, a problemática e os objetivos da pesquisa. Na segunda fase, foi realizada uma revisão bibliográfica para fornecer embasamento teórico e reunir fontes de pesquisa. Na terceira fase, ocorre a coleta de dados sobre os insumos críticos da empresa nos últimos três anos, incluindo suas demandas. Esses dados foram organizados no Microsoft Excel 2016 para analisar o comportamento da demanda e verificar a adequação do método utilizado. Em seguida, os dados foram aplicados ao método ARIMA para que se pudesse comparar a média móvel simples com $n=1$. A quarta fase envolve a previsão da demanda de roteadores e ONUs para o próximo trimestre.

Os resultados foram discutidos, com sugestões de compras e ações trimestrais para aumentar a eficiência operacional e reduzir custos. As fases e as ações realizadas estão representadas na Figura 2.

Figura 2 – Etapas da pesquisa



Fonte: Os Autores (2025).

Coleta de dados

Para a coleta de dados, foi estabelecida uma filtragem das informações referentes ao uso de roteadores e ONUs no período entre 2021 e o 2º semestre de 2024. O objetivo foi obter uma amostragem ampla o suficiente para permitir um estudo detalhado e preciso da demanda por esses equipamentos. Assim, realizou-se uma pesquisa no banco de dados da empresa, com o apoio de um especialista de dados, para identificar a quantidade requisitada desses dispositivos mensalmente ao longo desse período, focando na matriz que abrange as cidades de Petrolina, Juazeiro e Senhor do Bonfim.

A Tabela 1 representa parte da base de dados de materiais requisitados no período que se estende a pesquisa.

Tabela 1 – Base de dados

ORIGEM	PROJETO	QTD	UN	CODIGO_PRODUTO	DESCRICAO_PRODUTO
Manual	- APOIO	1	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	1	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	1	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	1	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	3	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	3	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	15	UN	41868	ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200 - TP-LINK EC220-G5
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	1	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	1	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				
Manual	- APOIO	2	UN	42768	[R] TP-LINK EC220-G5 - ROTEADOR GIGABIT WIRELESS DUAL BAND AC1200
Consumo	OPERACIONAL				

Fonte: Os Autores (2025).

O estudo concentrou-se na utilização de novos equipamentos, em vez de revalidados, uma vez que o foco era em materiais de investimento. Em parceria com o gerente do setor, foram analisados cenários que poderiam influenciar essa demanda. Observou-se que, ao longo dos anos, os kits (roteador + ONU) foram utilizados de maneira semelhante, com a principal variação sendo a troca de marcas – de Huawei, Fiberhome e


Chima para TP-Link, que se tornou predominante nos últimos dois anos. Além disso, o aumento no número de clientes contribuiu para o crescimento no volume de instalações. Em seguida, foi criada uma tabela dinâmica para facilitar a extração das quantidades requisitadas de roteadores e ONUs, por mês e ano, além de filtrar o polo da Matriz.

Após essa etapa, foi realizada uma validação junto aos colaboradores mais experientes do setor, que participam diretamente do processo, para garantir a confiabilidade dos dados. Com isso, foi possível seguir com os cálculos necessários para analisar o comportamento dos dados para cada equipamento no Excel e, posteriormente, aplicar o software R para obter a previsão da demanda trimestral como resultado final da análise.

4 Resultados e Discussão


No Excel, com os dados organizados por mês e ano e consumo do roteador e ONU, foi observado que as séries não são estacionárias e não apresentam uma sazonalidade, conforme teste de sazonalidade X13-ARIMA SEATS, para um nível de confiança de 95%. Em entrevistas com gestores, foi explicado que, entre 2021 e 2022, o consumo se concentrou em novos equipamentos para instalações e trocas. Nas Figuras 3 e 4, é possível visualizar esses picos de consumo tanto para as ONUs quanto para os roteadores respectivamente no software R, uma vez que ambos são utilizados em conjunto nas ordens de serviço.

Figura 3 – Consumo mensal de roteador 2021-2024



Fonte: Os Autores (2025).

Figura 4 – Consumo mensal de ONU 2021-2024



Fonte: Os Autores (2025).

Para aplicar o modelo ARIMA no R e prever a demanda, inicialmente foram inseridos os dados de consumo histórico e organizados como uma série temporal com frequência mensal. Em seguida, foi utilizada a função *auto ARIMA* para identificar automaticamente os melhores parâmetros do modelo para os dados, garantindo que a série fosse estacionária e adequada às especificidades do consumo analisado. Após o ajuste do modelo, a função *forecast* foi usada para gerar previsões para os próximos meses, que foram visualizadas em um gráfico junto com os dados históricos, permitindo uma análise clara entre o consumo real e a previsão futura.

No modelo ARIMA, os parâmetros p , d , q representam a estrutura não sazonal da série: p é o número de termos autorregressivos (influência dos valores passados), d é o número de diferenciações aplicadas para tornar a série estacionária, e q é o número de termos de média móvel (influência dos erros passados). Para modelos sazonais, os parâmetros P , D , Q desempenham funções semelhantes. Por exemplo $(p,d,q)(P,D,Q)$, uma diferenciação foi aplicada para estacionarizar a série, com um termo de média móvel não sazonal e um termo de média móvel sazonal. A Tabela 2 apresenta o resumo do modelo ARIMA ajustado para a série de consumo do roteador, com a estrutura ARIMA (0,1,1) (0,0,1). Esse modelo indica que foi aplicada uma diferenciação de ordem 1 para tornar a série estacionária, e inclui um termo de média móvel (MA) regular e um termo de média móvel sazonal (SMA).

Tabela 2 – Aplicação dos dados de Roteadores no R

Parâmetro	Valor
Modelo ARIMA	(0,1,1)(0,0,1)
Erro médio (ME)	-4,7264
Erro quadrático médio (RMSE)	180,33
Erro absoluto médio (MAE)	132,94
Erro percentual médio (MPE)	-7,0796
Erro percentual absoluto médio (MAPE)	23,0677
Erro absoluto médio escalado (MASE)	0,5711

Fonte: Os Autores (2025).

Em relação aos erros de previsão, o modelo apresenta um ME de -4,726383, sugerindo um leve viés negativo nas previsões. O RMSE igual a 180,33, representa a magnitude média dos erros de previsão. O MAE de 132,94, indica o desvio médio absoluto entre os valores previstos e os reais. Já a métrica MAPE igual a 23,07%, sugere que, em média, o erro nas previsões é de aproximadamente 23%. A Tabela 3 mostra o resumo de um modelo ARIMA (0,1,1), que utiliza uma diferenciação de ordem 1 para tornar a série estacionária e inclui um termo de média móvel de ordem 1. O coeficiente do termo de média móvel (ma1) é -0,7075, com um erro padrão de 0,1367, indicando que esse coeficiente é estatisticamente significativo.

Tabela 3 - Aplicação dos dados de ONU no R

Parâmetro	Valor
Modelo ARIMA	(0,1,1)
Erro médio (ME)	-4,5804
Erro quadrático médio (RMSE)	151,21
Erro absoluto médio (MAE)	103,58
Erro percentual médio (MPE)	-6,6522
Erro percentual absoluto médio (MAPE)	19,66
Erro absoluto médio escalado (MASE)	0,5714

Fonte: Os Autores (2025).

A previsão gerada para os meses de julho, agosto e setembro, apresentada nas Tabelas 4 e 5, mostra os resultados no R e resultado da média móvel simples da previsão da demanda para roteadores e ONU, respectivamente.

Tabela 4 – Previsões dos roteadores

Período	Previsão (R)	Previsão MMS
jul. 2024	443,3987	430
ago. 2024	472,0743	-
set. 2024	481,3239	-

Fonte: Os Autores (2024).

Tabela 5 – Previsões das ONUs

Período	Previsão (R)	Previsão MMS
jul. 2024	331,4226	326
ago. 2024	322,9849	-
set. 2024	314,5472	-

Fonte: Os Autores (2025).

O método de média móvel simples foi aplicado a um mês de previsão apenas $n=1$, assim como a empresa utiliza atualmente. Para os roteadores, o modelo ARIMA previu valores de 443, 472 e 481 unidades para os meses de julho, agosto e setembro de 2024, com um MAPE de 23,07%, indicando razoável precisão. Em comparação, a média móvel simples previu 430 unidades para julho, com um MAPE de 25,18%, evidenciando que a melhor precisão é do ARIMA e que este conseguiu capturar melhor os padrões da série temporal.

Já para as ONUs, o ARIMA apresentou previsões de 331, 323, 324 unidades para os meses de julho, agosto e setembro de 2024, com um MAPE de 19,66%, sugerindo boa precisão. Já a média móvel simples previu 326 unidades para julho, com um MAPE de 21,49%, indicando maior imprecisão. Em ambos os casos, o ARIMA demonstrou maior capacidade de adaptação aos dados, menor variabilidade nos erros e previsões mais consistentes, sendo mais adequado para planejamento de compras e gestão de estoque.

Nas Tabelas 6 e 7 estão distribuídos os valores dos intervalos de confiança de 95% inferior e superior de ambos os equipamentos, isso significa que, se o processo de previsão fosse repetido várias vezes, 95% das vezes os valores reais do consumo estariam dentro desse intervalo. É notável que os intervalos superiores aumentam a cada mês no roteador diferente da ONU, o que pode indicar que a acurácia do método pode ser comprometida com a extensão das previsões para mais de um período.

Tabela 6 – Intervalos de confiança dos roteadores

Período	Inferior	Superior
jul. 2024	76,36517	810,4323
ago. 2024	82,30880	861,8398
set. 2024	70,08106	892,5667

Fonte: Os Autores (2024).

Tabela 7 – Intervalos de confiança das ONUs

Período	Inferior	Superior
jul. 2024	38,47410	624,3711
ago. 2024	30,03640	615,9334
set. 2024	21,59869	607,4957

Fonte: Os Autores (2025).

Estratégias e redução de custos com base nas previsões

Com base nas previsões de demanda para roteadores e ONU, a melhor estratégia de compra é realizar aquisições trimestrais ajustadas à demanda projetada, evitando excessos e custos desnecessários de armazenamento ou obsolescência. Após a análise da previsão trimestral no ARIMA, o método foi validado pelo gerente da área, que enviou as demandas para um fornecedor fixo do estado da Bahia, responsável pelo fornecimento desses materiais. Esse fornecedor foi escolhido estrategicamente para evitar o pagamento de DIFAL. Foram enviadas as quantidades previstas tanto pelo ARIMA (compras trimestrais) quanto pela média móvel simples (compras mensais, como anteriormente).

Os orçamentos e propostas recebidas foram analisados pelo gerente e pelo coordenador. O gestor solicitou condições de pagamento a prazo devido às restrições de fluxo de caixa da empresa. Para a compra mensal, o valor unitário do roteador foi de R\$ 217,00 e da ONU, R\$ 99,99, com parcelamento em 6 vezes, frete grátis e prazo de entrega de 15 a 20 dias. Já para a compra trimestral, o valor unitário do roteador foi reduzido para R\$ 199,89 e da ONU para R\$ 89,00, com parcelamento em 12 vezes, frete grátis e prazo de entrega de uma semana, além da possibilidade de até dois meses de carência.

Embora a previsão do ARIMA tenha indicado 13 unidades a mais de roteadores e 5 unidades a mais de ONUs em comparação à média móvel simples, a economia total ao aderir à previsão fornecida pelo ARIMA seria de R\$ 7.896,47 no primeiro mês de compra. Em um segundo momento, os modelos foram apresentados junto os orçamentos recebidos para toda a gestão do setor de operações, destacando as considerações de ambos e

sugerindo estratégias para a melhor tomada de decisão. Como o espaço do estoque da empresa é limitado, foi apresentada a alternativa de negociação com o fornecedor para o envio programado das quantidades mensalmente, de forma programada, com base na previsão trimestral obtida pelo ARIMA.

Esse modelo mostrou-se mais vantajoso, tanto pelo menor tempo de entrega, quanto pelas melhores condições de pagamento e valor unitário reduzido. Por fim, foi também sugerido como estratégia de redução, investir nos processos de recuperação e revalidação destes equipamentos em campo para que sua reutilização supra não só a demanda de atendimentos de reparo, mas também a de ativação e com isso o volume de compra tende a diminuir.

5 CONSIDERAÇÕES FINAIS

Este trabalho aplicou o modelo ARIMA para realizar previsões de demanda de insumos críticos, como roteadores e ONUs, em uma empresa de telecomunicações. Os resultados indicaram que o ARIMA é uma ferramenta eficaz, apresentando previsões mais precisas do que métodos simples, como a média móvel, o que possibilitou otimizar o planejamento de compras e a gestão de estoque. No entanto, enfrentou-se uma limitação significativa relacionada à escassez de estudos específicos sobre previsão de demanda no setor de telecomunicações. Essa lacuna dificultou a comparação dos resultados obtidos com outros trabalhos similares e evidenciou a necessidade de ampliar as pesquisas na área.

Ainda assim, o modelo demonstrou ser uma solução viável e vantajosa para o cenário estudado, especialmente em relação à redução de custos operacionais e melhorias no planejamento logístico. A adoção do modelo ARIMA possibilita uma tomada de decisão mais embasada para a empresa, garantindo maior eficiência operacional e mitigando problemas como falta de materiais ou excesso de estoque. Como continuidade, recomenda-se expandir a análise para incluir outros insumos e variáveis externas que influenciam nas decisões de compra, estoque e nos modelos dos equipamentos. E expandir o método para aplicação em todas as cidades, visto que, este estudo se estendeu apenas a Matriz que compete 3 das 13 cidades.

Além disso, explorar métodos complementares de previsão, como redes neurais, pode aprimorar ainda mais a acurácia dos resultados e permitir a identificação de diferentes padrões de consumo, ampliando os períodos das previsões e a aplicabilidade das

estratégias desenvolvidas. Ademais, a integração de técnicas de inteligência artificial, como modelos avançados de aprendizado de máquina, pode proporcionar insights mais profundos, automatizar processos de tomada de decisão e melhorar a adaptabilidade às mudanças nas condições de mercado.

REFERÊNCIAS

AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES (ANATEL). **Banda Larga Fixa**. Disponível em: <<https://informacoes.anatel.gov.br/paineis/acessos/banda-larga-fixa>>. Acesso em: 09 mar. 2025.

AGÊNCIA NACIONAL DE TELECOMUNICAÇÕES (ANATEL). **Provedor de internet: conheça seus direitos**. Disponível em: <https://www.gov.br/anatel/pt-br/consumidor/conheca-seus-direitos/banda-larga/provedor>. Acesso em: 10 mar. 2025.

ALMAAFI, A.; BAJABA, S.; ALNORI, F. Previsão de preços de ações usando modelos ARIMA versus XGBoost: o caso da maior empresa de telecomunicações do Oriente Médio. **International journal of information technology**. v. 15, p. 1813–1818, 2023.

APTECH. **Introdução aos fundamentos de dados e análises de séries temporais**. Disponível em: <<https://www.aptech.com/blog/introduction-to-the-fundamentals-of-time-series-data-and-analysis/>>. Acesso em: 18 mar. 2025.

ARVAN, M.; FAHIMNIA, B.; REISI, M.; SIEMSEN, E. Integrating human judgement into quantitative forecasting methods: A review. **Omega**, v, 86, p. 237-252, 2019.

BALLOU, Ronald H. **Gerenciamento da cadeia de suprimentos: logística empresarial**. 5. ed. Porto Alegre: Bookman, 2005.

CAMPOS, A.S.; CAMPOLIM, T. A. O. **Previsão de demanda em uma empresa no setor de serviços de tecnologia**. Trabalho de Conclusão de Curso de Graduação - Universidade Tecnológica Federal do Paraná, Ponta Grossa, jun., 2022.

CAMPOS, P. A. C.; CLEMENTE, A.; DE CORDEIRO, A. A. L. **Aplicação do modelo ARIMA para previsão do preço do frango inteiro resfriado no grande atacado do estado de São Paulo**. In: CONGRESSO BRASILEIRO DE CUSTOS, 2006, Belo Horizonte, 12, Anais [...].Belo Horizonte: Associação Brasileira de Custos. p. 1-16.

CADE. **Mercado de telecomunicações: telefonia, acesso à internet e infraestrutura**. Brasília, 2023. Disponível em:<https://cdn.cade.gov.br/Portal/centrais-de-conteudo/publicacoes/estudos-economicos/cadernos-do-cade/Mercados-de-Telecomunicacoes_2023.pdf>. Acesso em: 5 abr. 2025.

CONSUL, B. Fabrício; WERNER, Liane. **Avaliação de técnicas de previsão de demanda utilizadas por um software de gerenciamento de estoques no setor farmacêutico**. Porto Alegre: UFRGS, 2010.

CORDEIRO, D. M. **Séries temporais - análise quantitativa: teoria e aplicações**. Recife: EDUPE, 2002.

CLOUDFLARE. What is a router? Disponível em: <https://www.cloudflare.com/pt-br/learning/network-layer/what-is-a-router/>. Acesso em: 30 nov. 2024.

DA SILVA, José Neto Aristides; DE SOUZA LIMA, José Claudio. **Gestão de materiais: almoxarifado hospitalar**. Cadernos UNISUAM de Pesquisa e Extensão, v. 5, n. 4, p. 35-45, 2016.

GIRARDI, G.; CAMARGO, E. M.; MOTTA, E. M. **Previsão de vendas através de modelos integrados: o caso do setor têxtil de uma empresa**. 2013.120f. Dissertação (Mestrado em Administração) – Universidade de Caxias do Sul.

GONÇALVES, Paulo Sérgio. **Administração de Materiais**. 7 ed. Rio de Janeiro: Elsevier, 2013.

INTELBRAS. **ONU e ONT: entenda a diferença**. Blog Intelbras, [s. l.], [s. d.]. Disponível em: <https://blog.intelbras.com.br/onu-ont-entenda-a-diferenca/>. Acesso em: 30 mar. 2025.

INTELBRAS. **Provedores de internet: como escolher equipamentos de alto desempenho**. Disponível em: <<https://blog.intelbras.com.br/equipamentos-para-provedor-de-internet/>>. Acesso em: 09 mar. 2025.

JACOBS, F. R.; CHASE, R. B.; AQUILANO, N. J. **Administração da produção para a vantagem competitiva**. 10. ed. Porto Alegre: Bookman, 2006.

LEMONS, F. O. **Metodologia para seleção de métodos de previsão de demanda**. Dissertação (Pós-Graduação em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção – Universidade Federal do Rio Grande do Sul, Porto Alegre, RS. 2006.

MADDALA, G. S. **Introdução à econometria**. 3. ed. Rio de Janeiro: LTC – Livros Técnicos e Científicos, 2003.

MOREIRA, D. Augusto. **Administração da produção e operações**. São Paulo: Pioneira, 2008.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blücher, 2006.

NKONGOLO, M. Usando ARIMA para prever o crescimento no uso de dados de assinantes. **Eng.**, v. 4, p. 92-120, 2023. <https://doi.org/10.3390/eng4010006>.

RITZMAN, P. Larry, KRAJEWSKI, J. Lee. **Administração da Produção e Operações**. São Paulo: Pearson Prentice Hall, 2004.

SANTOS, P. V. S. Previsão da demanda por produção de Café no Brasil: uma análise. **Latin American Journal of Business Management**, v. 11, p. 19-28, 2020.

SANTOS, P. V. S. Previsão da demanda como suporte à filosofia lean. **EXACTA** (ONLINE), v. 18, p. 226-243, 2019.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da produção**. 3. ed. São Paulo/SP: Atlas, 2009.

SOARES, L. M. C.; SILVA, A. C. G. C.; SILVA, J. C.; SANTOS, P. V. S. Previsão de demanda de peças sobressalentes utilizando rede neural artificial. **Revista Eletrônica Sistemas & Gestão**, v. 17, p. 1, 2022.

HISTÓRICO

ORIGINAL RECEBIDO EM: 24-10-2025

ACEITO PARA PUBLICAÇÃO EM: 18-12-2025