

**FÁBIO POLOLA MAMEDE**

**Uso de modelos de aprendizado de máquina e estatísticos para a previsão de demandas de transporte**

**São Paulo  
2023**

**FÁBIO POLOLA MAMEDE**

**Uso de modelos de aprendizado de máquina e estatísticos para a previsão de demandas de transporte**

**Versão Corrigida**

Dissertação apresentada à Escola Politécnica da Universidade de São Paulo para a obtenção do título de Mestre em Ciências

**São Paulo**  
**2023**

**FÁBIO POLOLA MAMEDE**

**Uso de modelos de aprendizado de máquina e estatísticos para a previsão de demandas de transporte**

**Versão Corrigida**

Dissertação apresentada à Escola  
Politécnica da Universidade de São  
Paulo para a obtenção do título de  
Mestre em Ciências

Área de Concentração: Engenharia de  
Sistemas Logísticos

Orientador: Prof. Livre-Docente Carlos  
Eduardo Cugnasca

**São Paulo**

**2023**

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Este exemplar foi revisado e corrigido em relação à versão original, sob responsabilidade única do autor e com a anuência de seu orientador.

São Paulo, 22 de março de 2023

Assinatura do autor: Fábio Roberto Mamede

Assinatura do orientador: 

### Catálogo-na-publicação

Mamede, Fábio

Uso de modelos de aprendizado de máquina e estatísticos para a previsão de demandas de transporte / F. Mamede -- versão corr. -- São Paulo, 2023.

118 p.

Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais.

1.Aprendizado de Máquina 2.Previsão de Demandas 3.Cadeia de Suprimentos I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Computação e Sistemas Digitais II.t.

## **AGRADECIMENTOS**

As conquistas na vida, o cumprimento de cada passo ou etapa são motivos para regozijo, quando rememoramos todo o percurso, principalmente quando superamos as dificuldades, oposições, desafios ou até nossa própria vontade. Mas todo caminho só é vitorioso quando sabemos que não estamos sós. Minha gratidão a Deus por esta etapa a ser realizada, pois foi Ele quem me deu forças e me conduziu para chegar até aqui. Agradeço ao professor Carlos que a todo momento foi receptivo e me orientou nessa pesquisa. Ao Roberto que sempre se disponibilizou em ajudar e contribuir para o trabalho. Meu agradecimento também à minha esposa, meus pais e irmão que sempre me incentivaram e apoiaram em cada etapa, inclusive nos momentos mais difíceis. Além disso, muitas outras pessoas que poderia citar para reconhecer o incentivo e apoio, que certamente não caberiam neste breve texto, a estes o meu total agradecimento.

## RESUMO

Uma atividade de importância para os operadores logísticos e transportadoras é a previsão de demanda por transportes, que permite tomar decisões relacionadas às suas operações, infraestrutura, gestão e planejamento do uso de recursos. Na década de 2010 foi observado um aumento do uso de modelos de aprendizagem de máquina para previsões nas cadeias de suprimentos, destacando-se a implementação de redes neurais profundas. O objetivo deste trabalho foi realizar um estudo de caso na previsão de demandas agregadas de transportes das unidades expedidoras de uma transportadora brasileira. Os métodos de simulação computacional e estudo de caso foram aplicados, explorando as características dos conjuntos de dados, nos quais foram aplicados os modelos *Autoregressive Integrated Moving Average* e suas variações, e também as redes neurais profundas *Long Short-Term Memory networks*. Nove cenários foram explorados, considerando-se diferentes técnicas para detecção e tratamento de dados, avaliando os respectivos reflexos nas previsões e a influências de variáveis exógenas. Além disso, foram realizadas divisões entre conjuntos de dados de treino e teste durante a validação cruzada, e avaliação dos hiperparâmetros relevantes para cada modelo. Observou-se que redes neurais *Long Short-Term Memory*, obtiveram previsões mais assertivas que os modelos estatísticos em noventa e quatro por cento das unidades expedidoras entre os cenários avaliados, enquanto os modelos *Autoregressive Integrated Moving Average* em apenas os cinco por cento restantes.

Palavras-chaves: Previsão de demandas de transporte. Cadeia de Suprimentos. LSTM. ARIMA. Aprendizagem de Máquina.

## ABSTRACT

An activity of importance for logistics operators and carriers is the transportation demand forecast, leveraging business operation decisions, infrastructure, management and resource planning. In 2010's years, an increase in the use of machine learning models in supply chain has been observed, remarking Deep neural networks implementation. The objective of this work was to perform a case study of aggregated transportation demand forecasts in distribution centers of a Brazilian carrier. The computational simulation and case study methods were applied, exploring the characteristics of the datasets, applied through Autoregressive Integrated Moving Average (ARIMA) and its variations and a deep neural network, Long Short-Term Memory, known as LSTM. Nine scenarios were explored, considering different data preprocessing, evaluating how the outliers and exogenous variables can affect the demands forecasts. Moreover, splitting training and testing datasets during cross-validation, and relevant hyperparameters for each model. It was observed that the long short-term memory networks outperformed the statistics methods in ninety four percent of the dispatching units over the evaluated scenarios, while the Autoregressive Integrated Moving Average models the remaining five percent.

Keywords: Transportation demand forecast. Supply Chain. LSTM. ARIMA. Machine learning.

## LISTA DE ILUSTRAÇÕES

Figura 1 – Exemplo de fluxo de uma cadeia de suprimentos .....	17
Figura 2 – Arquitetura rede neural .....	21
Figura 3 – Diagrama de rede neural LSTM.....	23
Figura 4 – Arquitetura de rede neural LSTM, com 2 camadas ocultas com 8 neurônios cada.....	25
Figura 5 – Fluxograma do método .....	29
Figura 6 – Demandas agregadas das unidades U12, U38, U19, U27, U20, U45 e U51 (ordem) com respectivas médias móveis e desvio padrão móvel... 41	
Figura 7 – Gráficos de autocorrelação, autocorrelação parcial e série original e diferenciada da unidade U05 .....	42
Figura 8 – Decomposição sazonal (dados originais, tendência, sazonalidade e resíduos) da unidade U19.....	43
Figura 9 – Demandas agregadas das categorias Produtos Alimentícios, Cosméticos, Bolsas e Calçados (ordem) com respectivas médias móveis e desvio padrão móvel .....	44
Figura 10 – Demandas agregadas da categorias Informática com respectivas médias móveis e desvio padrão móvel .....	45
Figura 11 – Valores selecionados da componente AR em cada unidade, por cenário .....	47
Figura 12 – (a) Distribuição dos valores AR nos cenários. (b) Contagem dos possíveis valores AR em cada cenário .....	48
Figura 13 – Autocorrelação parcial diferenciada da unidade U03 .....	49
Figura 14 – Valores selecionados da componente I(d) em cada unidade, por cenário .....	50
Figura 15 – Distribuição dos valores I(d) nos cenários .....	52
Figura 16 – Valores selecionados da componente MA em cada unidade, por cenário .....	52
Figura 17 – Distribuição dos valores MA(q) nos cenários.....	54
Figura 18 – Distribuição dos valores SAR nos cenários .....	55
Figura 19 – Proporções de valores SAR entre os cenários em cada unidades no modelo SARIMA.....	55



Figura 20 – Distribuição dos valores AR nos cenários para o modelo SARIMA	56
Figura 21 – Proporções de valores AR entre os cenários em cada unidades no modelo SARIMA	56
Figura 22 – Distribuição dos valores I nos cenários para o modelo SARIMA	57
Figura 23 – Distribuição dos valores S-I nos cenários para o modelo SARIMA	57
Figura 24 – Proporções de valores MA entre os cenários em cada unidades no modelo SARIMA	58
Figura 25 – Distribuição dos valores MA nos cenários para o modelo SARIMA	58
Figura 26 – Proporções de valores S-MA entre os cenários em cada unidades no modelo SARIMA	59
Figura 27 – Distribuição dos valores S-MA nos cenários para o modelo SARIMA	59
Figura 28 – Componente sazonal de um período da unidade U05	60
Figura 29 – Valores selecionados de <i>batch</i> em cada unidade, por cenário	62
Figura 30 – Distribuição valores <i>batch</i> nos cenários para o modelo LSTM	63
Figura 31 – Valores selecionados de <i>epoch</i> em cada unidade, por cenário	64
Figura 32 – Distribuição valores <i>epoch</i> nos cenários para o modelo LSTM	65
Figura 33 – Gráficos curva de aprendizado variando o <i>epoch</i> na (a) unidade U37/Cenário 4; (b) unidade U03/Cenário 5; (c) unidade U51/Cenário 7; (d) unidade U43/Cenário 9	67
Figura 34 – Valores selecionados de <i>lag size</i> em cada unidade, por cenário	69
Figura 35 – Distribuição valores <i>lag size</i> nos cenários para o modelo LSTM	71
Figura 36 – Valores selecionados <i>hidden layers</i> em cada unidade, por cenário	73
Figura 37 – Distribuição valores <i>hidden layers</i> nos cenários para o modelo LSTM	74
Figura 38 – Valores selecionados <i>neurons</i> em cada unidade, por cenário	74
Figura 39 – Distribuição valores <i>neurons</i> nos cenários para o modelo LSTM	75
Figura 40 – Acumulo de unidades com os menores erros em cada cenário	80
Figura 41 – Previsão x Real, Cenários 2, 3(U54), 4, 5, 7, 8, 9	81
Figura 42 – Acumulo de unidades com os menores erros em cada cenário LSTM	82

Figura 43 – (a) Proporções de tempo de processamento entre os cenários em cada unidades no modelo ARIMA. (b) Média, mediana e desvio padrão mínimos em cada unidade no modelo ARIMA.....	88
Figura 44 – Tempos mínimos e máximos entre todos os cenários em cada unidade no modelo ARIMA .....	89
Figura 45 – (a) Proporções de tempo de processamento entre os cenários em cada unidades no modelo SARIMA. (b) Média, mediana e desvio padrão mínimos em cada unidade no modelo SARIMA .....	91
Figura 46 – Tempos mínimos e máximos entre todos os cenários em cada unidade no modelo SARIMA.....	92
Figura 47 – (a) Proporções de tempo de processamento entre os cenários em cada unidades no modelo LSTM. (b) Média, mediana e desvio padrão mínimos em cada unidade no modelo LSTM.....	94
Figura 48 – Tempos mínimos e máximos entre todos os cenários em cada unidade no modelo LSTM.....	95
Figura 49 – Tempos mínimos (a) e máximos (b) entre as unidades em todos os cenários em todos os modelos. (c) Tempos mínimos (c) e máximos (d) entre as unidades em todos os cenários nos modelos ARIMA.....	96

## LISTA DE TABELAS

Tabela 1 – Cenários selecionados para a pesquisa .....	34
Tabela 2 – Categorias/Classificação de produtos.....	34
Tabela 3 – Componente AR(p) do modelo ARIMA selecionada em cada unidade/cenário.....	47
Tabela 4 – Componente I(d) do modelo ARIMA selecionada em cada unidade/cenário.....	50
Tabela 5 – Componente MA(q) do modelo ARIMA selecionada em cada unidade/cenário.....	54
Tabela 6 – Valores <i>batch</i> do modelo LSTM selecionados em cada unidade/cenário e contagem por variações. ....	61
Tabela 7 – Valores <i>epoch</i> do modelo LSTM selecionados em cada unidade/cenário e contagem por variações. ....	66
Tabela 8 – Valores <i>lag size</i> do modelo LSTM selecionados em cada unidade/cenário.....	70
Tabela 9 – Valores <i>hidden layers</i> do modelo LSTM selecionados em cada unidade/cenário.....	72
Tabela 10 – Valores <i>neurons</i> do modelo LSTM selecionados em cada unidade/cenário.....	76
Tabela 11 – Métricas dos testes MAE de todas unidades e cenários.....	78
Tabela 12 – Relação entre quantidade de neurônios, cenários e total de unidades selecionadas com o hiperparâmetro. ....	83
Tabela 13 – Métricas MSE e MAE para a unidade U45, considerando as variáveis exógenas, destacando em negrito os menores índices de cada categoria. ....	85
Tabela 14 – Métricas para unidade U45, desconsiderando variáveis exógenas. .....	86
Tabela 15 – Tempo de processamento de treino e validação das unidades em cada cenário no modelo ARIMA. ....	87
Tabela 16 – Tempo de processamento de treino e validação das unidades em cada cenário no modelo SARIMA.....	90
Tabela 17 – Tempo de processamento de treino e validação das unidades em	

cada cenário no modelo LSTM. .... 93

## LISTA DE ABREVIATURAS E SIGLAS

<b>ADF</b>	<i>Augmented Dickey Fuller</i>
<b>AIC</b>	<i>Akaike Information Criterion</i>
<b>AR</b>	<i>Autoregressive</i>
<b>ARIMA</b>	<i>Autoregressive Integrated Moving Average</i>
<b>B2B</b>	<i>Business to Business</i>
<b>B2C</b>	<i>Business to Consumer</i>
<b>CD</b>	<i>Centro de Distribuição</i>
<b>CPU</b>	<i>Central Process Unit</i>
<b>CSV</b>	<i>Comma Separated Values</i>
<b>GRU</b>	<i>Gated Recurrent Unit</i>
<b>LSTM</b>	<i>Long Short-Term Memory</i>
<b>MA</b>	<i>Moving Average</i>
<b>MAE</b>	<i>Mean Absolute Error</i>
<b>MSE</b>	<i>Mean Square Error</i>
<b>RAM</b>	<i>Random Access Memory</i>
<b>RMSE</b>	<i>Root Mean Square Error</i>
<b>SARIMA</b>	<i>Seasonal Autoregressive Integrated Moving Average</i>
<b>SQL</b>	<i>Search Query Language</i>
<b>SVM</b>	<i>Support Vector Machine</i>

## SUMÁRIO

<b>1. INTRODUÇÃO</b>	<b>12</b>
1.1 OBJETIVO	13
1.1.2 OBJETIVO GERAL	13
1.1.2 OBJETIVOS ESPECÍFICOS	13
1.1.3 PERGUNTAS DE PESQUISA	14
1.1.4 JUSTIFICATIVAS E METODOLOGIA	14
1.2 ESTRUTURA DO TRABALHO	15
<b>2. REVISÃO DA LITERATURA</b>	<b>16</b>
2.1 CADEIA DE SUPRIMENTOS	16
2.2 MODELOS ARIMA	19
2.3 REDES NEURAIS ARTIFICIAIS	20
2.4 LSTM	21
2.5 PRÉ-PROCESSAMENTO DE DADOS	26
<b>3. MATERIAIS E MÉTODOS</b>	<b>28</b>
3.1 DEFINIÇÃO DE REQUISITOS DA PESQUISA	29
3.2 COLETA DE DADOS	30
3.3 MANIPULAÇÃO E MODELAGEM DA BASE DE DADOS	31
3.4 PREPARAÇÃO DA BASE DE DADOS	31
3.5 ANÁLISE EXPLORATÓRIA DOS DADOS	32
3.6 PROCESSAMENTO DOS DADOS	33
3.7 IMPLEMENTAÇÃO DOS MODELOS	34
3.8 TREINAMENTO DOS MODELOS	35
3.9 RESULTADOS E MÉTRICAS	35
3.10 RECURSOS TÉCNICOS	36
3.11 PLANO DE GESTÃO DE DADOS	36
<b>4. RESULTADOS</b>	<b>38</b>
4.1 ANÁLISE EXPLORATÓRIA DOS DADOS	39
4.1.1 CARACTERÍSTICAS DOS CONJUNTOS DE DADOS	39
4.1.2 CATEGORIAS	43
4.1.3 IMPACTO DA PANDEMIA NAS DEMANDAS	44
4.2. SELEÇÃO DE HIPERPARÂMETROS NA BASE DE TREINO	45
4.2.1 TREINO ARIMA E SARIMA	45

4.2.1.1 ARIMA (AR/p) .....	46
4.2.1.2 ARIMA (I/d) .....	49
4.2.1.3 ARIMA (MA/q) .....	52
4.2.1.4 SARIMA (S-AR) .....	54
4.2.1.5 SARIMA (S-I) .....	57
4.2.1.5 SARIMA (S-MA) .....	58
4.2.1.6 SARIMA (Sazonalidade) .....	60
4.2.2 TREINO LSTM .....	60
4.2.2.1 <i>Batch</i> .....	60
4.2.2.2 <i>Epoch</i> .....	63
4.2.2.3 <i>Lag Size</i> .....	68
4.2.2.4 <i>Hidden Layers</i> .....	71
4.2.2.5 <i>Neurons</i> .....	74
4.3. ANÁLISE DOS MODELOS NO CONJUNTO DE VALIDAÇÃO .....	77
4.4. IMPACTO DE VARIÁVEIS EXÓGENAS .....	83
4.5. ANÁLISE TEMPORAL .....	86
4.5.1 ARIMA .....	86
4.5.2 SARIMA .....	89
4.5.3 LSTM .....	92
4.5.4 COMPARAÇÃO DE DESEMPENHO .....	95
<b>5. DISCUSSÕES .....</b>	<b>98</b>
5.1 ANÁLISE EXPLORATÓRIA DE DADOS .....	98
5.2 PRÉ-PROCESSAMENTO .....	99
5.3 RESULTADOS OBTIDOS .....	99
5.4 TEMPO DE PROCESSAMENTO .....	100
5.5 TRATAMENTO DE OUTLIERS .....	101
5.6 AVALIAÇÕES DE ASPECTOS SECUNDÁRIOS .....	102
5.7 DISCUSSÕES FINAIS .....	102
<b>6. CONCLUSÕES .....</b>	<b>103</b>
6.1 PRINCIPAIS CONTRIBUIÇÕES .....	103
6.2 OUTRAS CONTRIBUIÇÕES .....	103

6.3 PRINCIPAIS DIFICULDADES E LIMITAÇÕES DA PESQUISA.....	105
6.4 TRABALHOS FUTUROS .....	107
6.5 CONSIDERAÇÕES FINAIS .....	107
<b>REFERÊNCIAS.....</b>	<b>108</b>



## 1. INTRODUÇÃO

Os operadores logísticos e transportadoras de grande porte buscam estruturar suas operações através da definição de locais de apoio para consolidação e distribuição de mercadorias de seus clientes para os respectivos clientes finais. Estes pontos de apoio são conhecidos como centros de distribuição (CDs) ou unidades expedidoras.

Os operadores logísticos atendem a clientes de diferentes setores, como insumos (AIASSI et al., 2020), atacado (ABURTO; WEBER, 2007) varejo (HOFMANN; RUTSCHMANN, 2018), industrial, *e-commerce*, entre outros. O transporte de produtos gera demandas de transporte, que é relacionada ao volume e ao ciclo de pedidos (KOCHAK; SUMAN, 2015). A execução do serviço de entrega depende das informações disponibilizadas pelas demandas dos clientes (MIAO; XI, 2008).

Nas cadeias de suprimentos, as variações de demandas em clientes, fornecedores de transporte, riscos organizacionais e *lead times* geram incertezas (ABURTO; WEBER, 2007; AIASSI et al., 2020; HOFMANN; RUTSCHMANN, 2018; REN et al., 2020; SEYEDAN; MAFAKHERI, 2020; VARGAS; ELIZONDO CORTÉS, 2017). No caso de etapas como produção, armazenamento e transporte, estas incertezas impactam no desempenho operacional. Nestes casos, a qualidade da previsão é essencial para as decisões a serem tomadas. A previsão ou estimativa das demandas de transporte, ou seja, a quantidade de carga em peso, volume ou produtos expedidos em um período, é relevante pois permite a realização do planejamento (KANTASA-ARD et al., 2021) do uso de recursos, como os veículos necessários para uma determinada operação. Ademais, uma maior precisão e antecedência de previsão resultam em oportunidades e auxiliam a tomada de decisões por parte das transportadoras e operadores logísticos (MIAO; XI, 2008; REN et al., 2020).

A literatura destaca métodos de aprendizado de máquina para tratar a previsão de demandas (KANTASA-ARD et al., 2021). SEYEDAN e MAFAKHERI (2020) verificaram que os cinco principais grupos de modelos utilizados para a previsão de demandas na cadeia de suprimentos são: redes neurais artificiais, modelos de regressão, modelos estatísticos, *Support Vector Machines* (SVM) e árvores

de decisão ou *decision trees*. Estes autores também observam que o estado da arte atual é o uso de redes neurais artificiais.

O trabalho de YUAN et al. (2018) realizou uma pesquisa em previsões de demandas logísticas em uma empresa de transportes, aplicando modelos de redes neurais profundas, verificando que existe potencial de aplicação em situações práticas.

## **1.1 OBJETIVO**

Este item apresenta os objetivos do presente projeto de pesquisa, descrevendo o objetivo geral, os objetivos específicos, as perguntas de pesquisa de visam serem respondidas e as contribuições que se esperam da pesquisa.

### **1.1.2 OBJETIVO GERAL**

O objetivo desta pesquisa é avaliar o uso de modelos da família ARIMA (*Auto Regressive Integrated Moving Average*) e redes neurais LSTM (*Long Short-Term Memory*) para previsão da demanda agregada de transportes em unidades expedidoras de transportadoras.

### **1.1.2 OBJETIVOS ESPECÍFICOS**

Os objetivos específicos desta pesquisa são:

- Realizar um levantamento dos requisitos funcionais e não-funcionais para a previsão de demandas em transportadoras, considerando os modelos da família ARIMA e LSTM;
- Realizar o processamento de dados históricos para a análise exploratória dos dados, identificando variáveis relevantes, tendências, sazonalidades, autocorrelações, análises estatísticas e avaliar a influência de *outliers*;
- Elaborar e implementar os modelos de aprendizados de máquina, como modelo ARIMA e variações e a rede neural LSTM, considerando a análise de seus principais hiperparâmetros;

- Realizar uma avaliação quantitativa dos resultados dos modelos, avaliando a acurácia das previsões e o tempo de processamento;
- Realizar a avaliação de aspectos relacionados à implementação dos modelos em diferentes conjuntos de dados;
- Disponibilizar os conjuntos de dados para que outros pesquisadores possam evoluir em iniciativas.

### 1.1.3 PERGUNTAS DE PESQUISA

As seguintes perguntas de pesquisa foram propostas: (i) Qual dentre os modelos avaliados apresenta melhor resultado (menores valores de métricas de erros) nas previsões? (ii) O comportamento dos modelos é equivalente para todas unidades expedidoras? (iii) Como o tratamento de dados influencia nos resultados de previsões? (iv) Como variáveis exógenas contribuem para os resultados de previsões? (v) Como a pandemia de COVID-19 influenciou nas previsões nos conjuntos de dados?

### 1.1.4 JUSTIFICATIVAS E METODOLOGIA

Dentre os trabalhos encontrados no estado atual da arte destaca-se o trabalho de Yuan et al. (2018), que avalia previsões de demandas de logísticas em transportadoras através de redes neurais artificiais, identificando que podem ser explorados métodos preditivos para este tipo de aplicação, e deixando precedentes para melhorias. Outros trabalhos endereçam outras abordagens de previsões de demandas nas cadeias de suprimentos, que contribuem para o tema em questão (VARGAS; GONZÁLES, 2017; REN, 2020; ABBASIMEHR et al., 2020; FU; CHIEN; LIN, 2018).

Esta pesquisa tem a motivação em um problema real de uma transportadora brasileira, que carece prever as demandas agregadas de transporte em seus locais de expedição, no intuito de aprimorar a sua operação e o controle de recursos.

Esta empresa de transportes possui filiais distribuídas no Brasil, que funcionam como *hubs*, recebendo e despachando cargas. A frota da transportadora possui

mais de 800 veículos que são utilizados para transferir as demandas entre as filiais, de acordo com o destino da mercadoria. Após a chegada ao destino, o veículo pode ser carregado novamente (caso tenha demanda a partir daquela origem) ou ser reposicionado para outra filial para embarcar novas demandas.

Os modelos adotados para esta pesquisa são baseados em trabalhos que evidenciam a aderência e tendência na implementação de redes neurais em previsões em demandas na cadeia de suprimentos (SEYEDAN; MAFAKHERI, 2020), assim como trabalhos que utilizam modelos preditivos (BABU; REDDY, 2014; FANG-MEI; HSIAO-CHENG; GWO-HSIUNG, 2002; KANTASA-ARD et al., 2021; MIRCETIC et al., 2016; ÖMER FARUK, 2010; REN et al., 2020; VARGAS; ELIZONDO CORTÉS, 2017; YAMAK; YUJIAN; GADOSEY, 2019; ZHANG, 2003).

Através dos métodos simulação computacional (NEGAHBAN; YILMAZ, 2014) a pesquisa realiza um estudo de caso considerando dados reais desta transportadora brasileira.

## **1.2 ESTRUTURA DO TRABALHO**

Este trabalho está dividido em seis capítulos, sendo distribuído da seguinte forma: (I) a Introdução, contendo a visão geral do problema da pesquisa, o contexto e motivações, assim como os seus objetivos. (II) a revisão da literatura, referenciando o estado da arte do tema da pesquisa e conceitos utilizados. Em seguida, (III) a metodologia utilizada, seguido pelos (IV) resultados obtidos, que são posteriormente discutidos no (V) capítulo cinco. O último capítulo (VI) apresenta as conclusões obtidas, as principais limitações observadas e sugestões para trabalhos futuros. Ao final, têm-se as referências citadas na pesquisa.

## 2. REVISÃO DA LITERATURA

Este capítulo trata da revisão dos principais conceitos utilizados na pesquisa.

### 2.1 CADEIA DE SUPRIMENTOS

O gerenciamento da cadeia de suprimentos se concentra no fluxo de bens, serviços e informações dos pontos de origem aos clientes através de uma cadeia de entidades e atividades que estão conectadas umas às outras (SEYEDAN; MAFAKHERI, 2020), como é descrito na [Figura 1](#), (BALLOU, 2006). Essas atividades inter-relacionadas envolvem a tomada de decisões complexas sob incerteza e risco, devido à volatilidade dos ambientes de negócio. Neste contexto, as previsões podem ter aplicações nas cadeias de suprimentos, como planejamento produtivo, gestão de inventário, estratégias de vendas, análises de perfis de consumo, entre outros, baseados em dados históricos.

Os elos na cadeia nem sempre trabalham de maneira colaborativa (CARBONNEAU; LAFRAMBOISE; VAHIDOV, 2008), ou seja, não executam suas atribuições em prol dos demais. Previsões de demandas precisas nas cadeias de suprimentos previnem interrupção em todo o processo (HOFMANN; RUTSCHMANN, 2018).

Os recursos de tecnologia da informação fazem parte das medidas estratégicas, táticas e operacionais, realizando o controle e gestão dos dados e do processo (BALLOU, 2006). Estes recursos produzem dados em todos segmentos do processo (SEYEDAN; MAFAKHERI, 2020) que são utilizados para interpretação operacional, ou previsões, com destaque para a previsão de demandas.

Excluído: Fig

Figura 1 - Exemplo de fluxo de uma cadeia de suprimentos



Fonte: baseado em Ballou (2006).

A capacidade de prever o futuro com base em dados históricos é um recurso nas cadeias de suprimentos (KOCHAK; SUMAN, 2015), apoiando a tomada de decisão individual e organizacional. A literatura destaca a relevância da previsão de demandas, com aplicações crescentes a partir do ano de 2005 (SEYEDAN; MAFAKHERI, 2020). As previsões podem direcionar o planejamento (CARBONNEAU; LAFRAMBOISE; VAHIDOV, 2008), determinando o abastecimento de matérias-primas. Ademais, pesquisas aplicadas a distribuidores e atacadistas apontam que as previsões e metas de vendas são direcionadores para a política de estoques e ressuprimento de inventário (ABURTO; WEBER, 2007). O trabalho de Yuan et al. (2018) ilustra um exemplo de pesquisa no contexto do setor de transporte.

SEYEDAN e MAFAKHERI (2020) destacam que o aprendizado de máquina é aplicável à previsão de demandas, e que a mesma possui uma característica de série temporal (KANTASA-ARD et al., 2021), definida através de uma base

histórica (CARBONNEAU; LAFRAMBOISE; VAHIDOV, 2008; YUAN et al., 2018). KANTASA-ARD *et al.* (2020) utilizam redes neurais artificiais para a previsão de demandas, pois estes modelos são adequados à modelagem de séries-temporais não-lineares. Por outro lado, séries lineares são aderentes (ABURTO; WEBER, 2007) a modelos regressivos. ZHANG (2003) propõe a composição de modelos e arquiteturas de aprendizado de máquina para casos reais e que são dinâmicos, devido ao fato de que estes podem se comportar tanto de maneira linear quanto não linear.

YAMAK *et al.* (2019) realizou uma comparação entre modelos ARIMA, LSTM e *Gated Recurrent Unit* (GRU) para previsões, obtendo resultados com o modelo ARIMA até 25% mais precisos que com os LSTM e GRU. SEYEDAN e MAFAKHERI (2020) identificaram que em cada seis trabalhos para previsões na cadeia de suprimentos, a partir do ano de 2005, utilizou modelos ARIMA e suas variações, com aplicações em setores de tecnologia, varejo, químico e consumo. VARGAS e ELIZONDO CORTÉS (2017) destacam o modelo ARIMA na previsão de demandas de peças automotivas na linha de produção, em um de três casos alcançou as menores métricas de erros em previsões. ZHANG (2003) realizou experimentos com o modelo ARIMA, redes neurais e a combinação de ambos, identificando que em um horizonte de 12 meses o modelo ARIMA realizou as melhores previsões.

AHMED et al. (2010) realizaram um comparativo entre modelos de aprendizado de máquina aplicados à cadeia de suprimentos. A literatura mostra que existem trabalhos que implementam mais de um modelo (FANG-MEI; HSIAO-CHENG; GWO-HSIUNG, 2002; KANTASA-ARD *et al.*, 2020; MAHBUB; PAUL; AZEEM, 2013; ÖMER FARUK, 2010), utilizando modelos preditivos baseados em processos estatísticos para o *benchmark* dos resultados, no intuito de comparar os resultados entre os métodos. Outras referências aplicam a combinação de métodos (ABURTO; WEBER, 2007; BABU; REDDY, 2014; FANG-MEI; HSIAO-CHENG; GWO-HSIUNG, 2002; ÖMER FARUK, 2010; VARGAS; ELIZONDO CORTÉS, 2017), no intuito de aprimorar os resultados, superando deficiências específicas de cada método.

REN et al. (2020a) utilizam as redes neurais LSTM em conjunto com ARIMA para prever estoques e determinar a capacidade de serviços de transporte, sendo o estado da arte destes modelos para a previsão de demandas de transporte.

Estes afirmam que os serviços de logística possuem uma natureza aleatória, tornando-se um desafio em tomadas de decisão e apresentam resultados satisfatórios para previsão de séries-temporais, inclusive a séries sujeitas a variações (KANTASA-ARD et al., 2021). As definições conceituais dos modelos que serão utilizados neste trabalho se encontram nas próximas seções.

## 2.2 MODELOS ARIMA

São modelos preditivos baseados em técnicas estatísticas ou econometria utilizados para previsões de séries temporais, com destaque para séries lineares (REN et al., 2020). É um modelo simples de se implementar, rápido, e oferece resultados satisfatórios (KANTASA-ARD et al., 2021). Alguns dos principais trabalhos da literatura que utilizam estes métodos para a demanda de transportes são: VARGAS e GONZÁLES (2017); REN (2020); ABBASIMEHR et al. (2020). YAMAK et al. (2019) afirmam que estes modelos se adequam a séries com características lineares. Apesar de apresentarem uma implementação simples e exigirem reduzidos recursos computacionais (REN et al., 2020), os modelos ARIMA podem apresentar resultados imprecisos em séries com padrões não-lineares (ZHANG et al., 2003), como é o caso da demanda agregada por transportes.

O modelo ARIMA pode receber outras componentes na sua estrutura, como variáveis exógenas (ARIMAX) e componentes sazonais (S-ARIMA ou SARIMA), que podem agregar dados e conteúdo no intuito de aprimoramento dos resultados.

Ademais, estes modelos são utilizados para *benchmark* de modelos de redes neurais (ZHANG et al., 2003). A avaliação da série temporal é realizada graficamente, podendo atribuir uma componente sazonal caso haja correspondências em períodos recorrentes, denominado SARIMA (ZHANG; QI, 2005).

O modelo ARIMA caracteriza-se por três componentes (YAMAK; YUJIAN; GADOSEY, 2019): (1) auto regressivo ou  $p$ , que engloba uma regressão linear utilizando os dados históricos da série e um intervalo de autocorrelação; (2) diferenciação ou  $d$ , que é aplicada à série para que ela se torne estacionária; (3) média móvel ou  $q$ , caracterizado como o intervalo de autocorrelação utilizado



para o cálculo da média móvel dos erros. Para o modelo SARIMA, adicionam-se sazonais a cada um destes componentes, resultando em sete componentes finais. O modelo ARIMA utiliza a nomenclatura: ARIMA (p,d,q), que indica as ordens dos termos AR, I e MA, respectivamente. As previsões são realizadas através de uma combinação linear destes termos e são correlacionados com os valores sucessores, conforme a seguinte fórmula:

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_q \epsilon_{t-q}$$

*AR = p = índice autoregressivo*

*I = diferenciação*

*MA = q = índice médias móveis*

*$\phi$  = Média móvel*

*$\alpha$  = termo de erro*

A determinação de hiperparâmetros para modelos ARIMA e SARIMA, que são determinados pelas componentes do modelo (p,d,q) é realizada através de métodos analíticos, um deles o uso da métrica *Akaike Information Criteria* (AIC) e da aplicação de funções de autocorrelação e autocorrelação parcial (ÖMER FARUK, 2010).

A seção seguinte detalha as características das redes neurais artificiais.

### 2.3 REDES NEURAS ARTIFICIAIS

As redes neurais artificiais (DOUGHERTY, 1995) são compostas por elementos de processamento, chamados neurônios, que são alimentados por variáveis de entrada e são computadas em um resultado final, através de uma função de ativação.

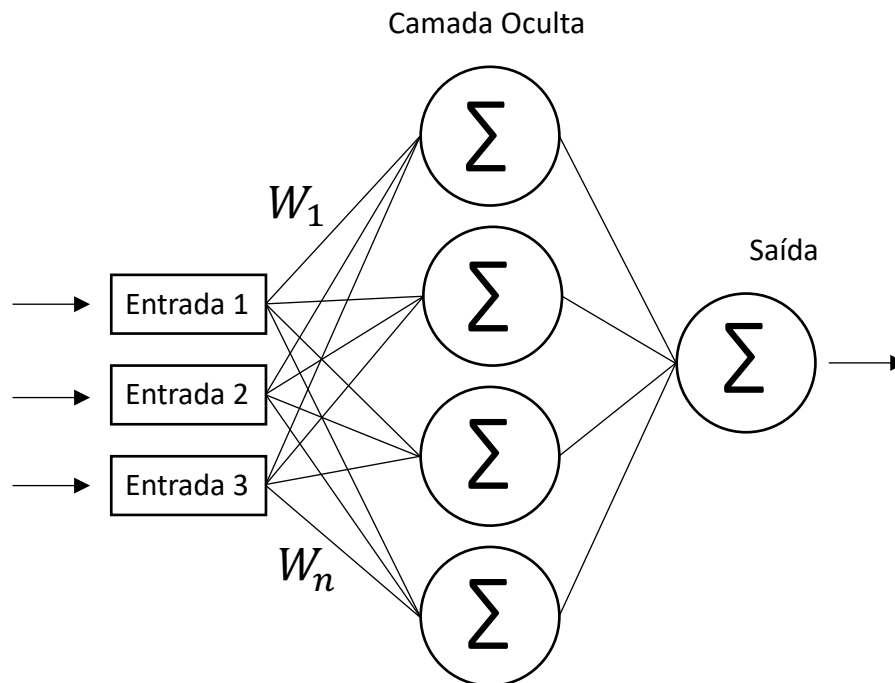
Os neurônios são ligados por conexões ponderadas, fluindo os dados de acordo com a escala, pesos e valores de entrada. Os neurônios artificiais são treinados para que os pesos sejam regulados de acordo com a função e modelo de rede neural utilizada. A [Figura 2](#) (DOUGHERTY, 1995) ilustra a arquitetura de uma rede neural simples, com os valores de entrada, pesos, soma, a função transferência e o resultado final. O trabalho de (VARGAS; ELIZONDO CORTÉS,

Excluído: Fig

Formatado:

2017) reforça o uso de redes neurais artificiais para previsão de demandas, aplicadas ao cenário de peças automotivas. DOUGHERTY (1995) relacionou uma revisão da literatura, apontando aplicações de redes neurais artificiais em previsões nas cadeias de suprimentos, em diferentes aplicações e segmentos.

Figura 2 - Arquitetura rede neural



Fonte: baseado em Dougherty (1995).

A seção seguinte detalha as redes neurais artificiais LSTM, assim como os seus principais hiperparâmetros.

## 2.4 LSTM

A LSTM é um modelo de rede neural derivado das redes neurais recorrentes (HOCHREITER; SCHMIDHUBER, 1997) e pode ser aplicado para a implementação de previsão de séries-temporais sequenciais (YAMAK; YUJIAN; GADOSEY, 2019), destacando-se séries não-lineares (KANTASA-ARD et al., 2021; MEMARZADEH; KEYNIA, 2020; YAMAK; YUJIAN; GADOSEY, 2019). Dentre as arquiteturas de redes neurais artificiais, a literatura mostra que o modelo LSTM é aderente na resolução de problemas em previsões de demandas (ABBASIMEHR; SHABANI; YOUSEFI, 2020; FU; CHIEN; LIN, 2018; KANTASA-

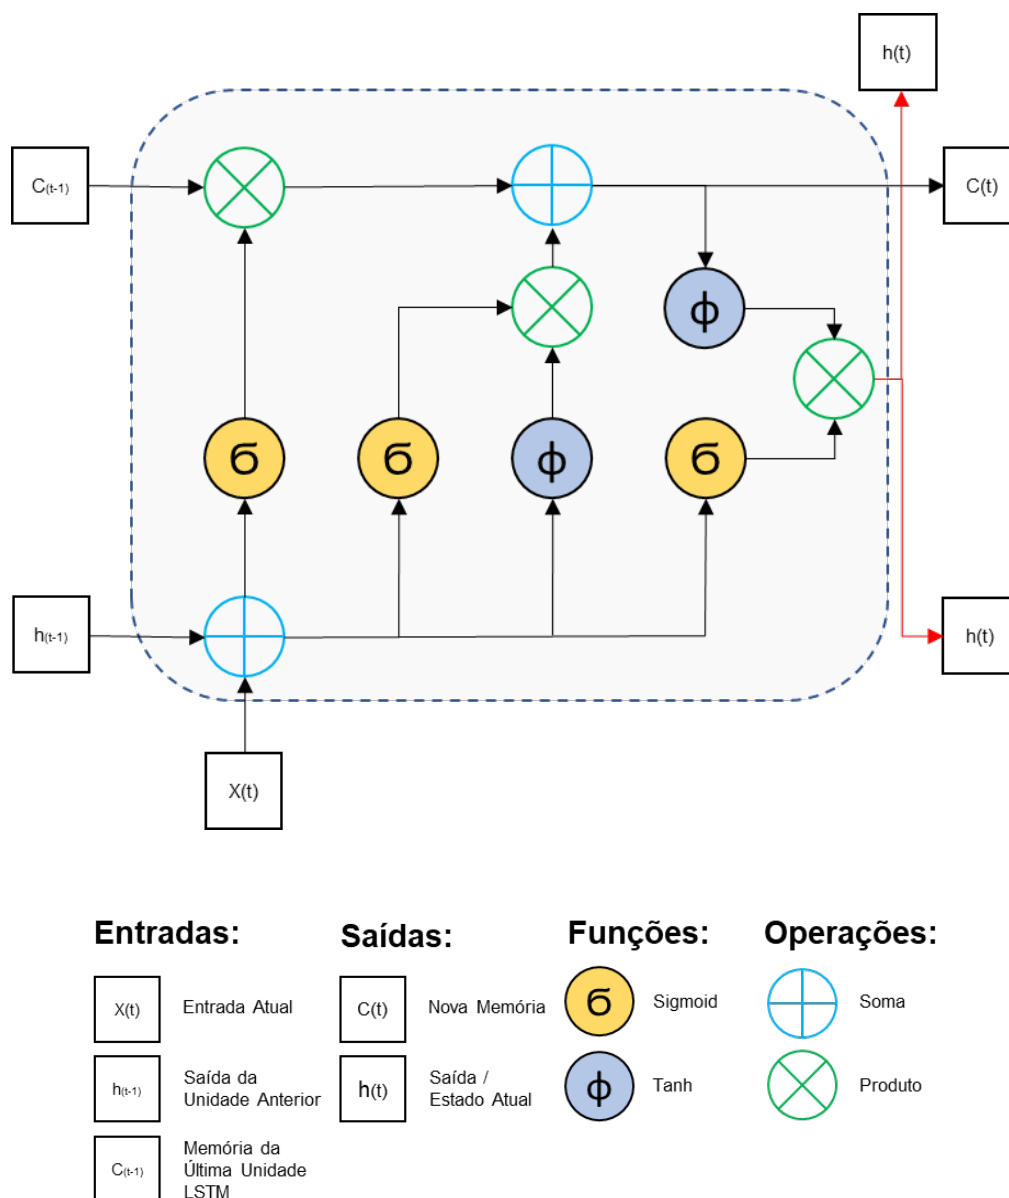
ARD et al., 2021; REN et al., 2020).

A LSTM possui *gates* para os dados e a sua arquitetura permite que o modelo determine de que forma estes dados são tratados e processados, priorizando ou não, memorizando dados relevantes e desconsiderando outros. O estado dos neurônios e das camadas ocultas são utilizados para coletar os dados para processamento no próximo estado. A [Figura 3](#) descreve a arquitetura de uma célula de uma rede neural LSTM.

Excluído: Fig

Formatado:

Figura 3 - Diagrama de rede neural LSTM



Fonte: o autor.

As redes neurais LSTM podem ser modeladas para implementar problemas que envolvam previsões (DOUGHERTY, 1995), adequando-se a partir da determinação de hiperparâmetros (LI et al., 2021). Estes são os que definem a arquitetura da rede e de que maneira os dados serão processados. Os hiperparâmetros em redes neurais podem ser determinados através de análises gráficas, alinhadas com testes combinatórios ou heurísticas, não existindo um método que identifique os hiperparâmetros com as previsões mais assertivas (GORGOLIS et al., 2019). A relação dos hiperparâmetros utilizados na implementação de redes neurais recorrentes LSTM, e suas definições, são

(ABBASIMEHR; SHABANI; YOUSEFI, 2020):

1. **Lag Size (time steps):** os valores de cada período da série temporal são relacionados a um vetor multidimensional que é composto de um valor  $X_t$  em um tempo  $t$  e seus  $n$  valores precedentes, sendo  $n$  o *lag size*.
2. **Hidden Layers:** quantidade de camadas de neurônios conectada a camada de entrada, sendo que as *hidden layers* estão interligadas, até a camada de saída da rede neural;
3. **Quantidade de Neurônios (camada):** as camadas são definidas com uma quantidade de neurônios;
4. **Batch Size:** este hiperparâmetro define o tamanho do lote de processamento para atualização dos valores dos pesos entre os nós conectados;
5. **Epochs:** define a quantidade de vezes que a rede neural deverá processar a base de dados para treinamento.

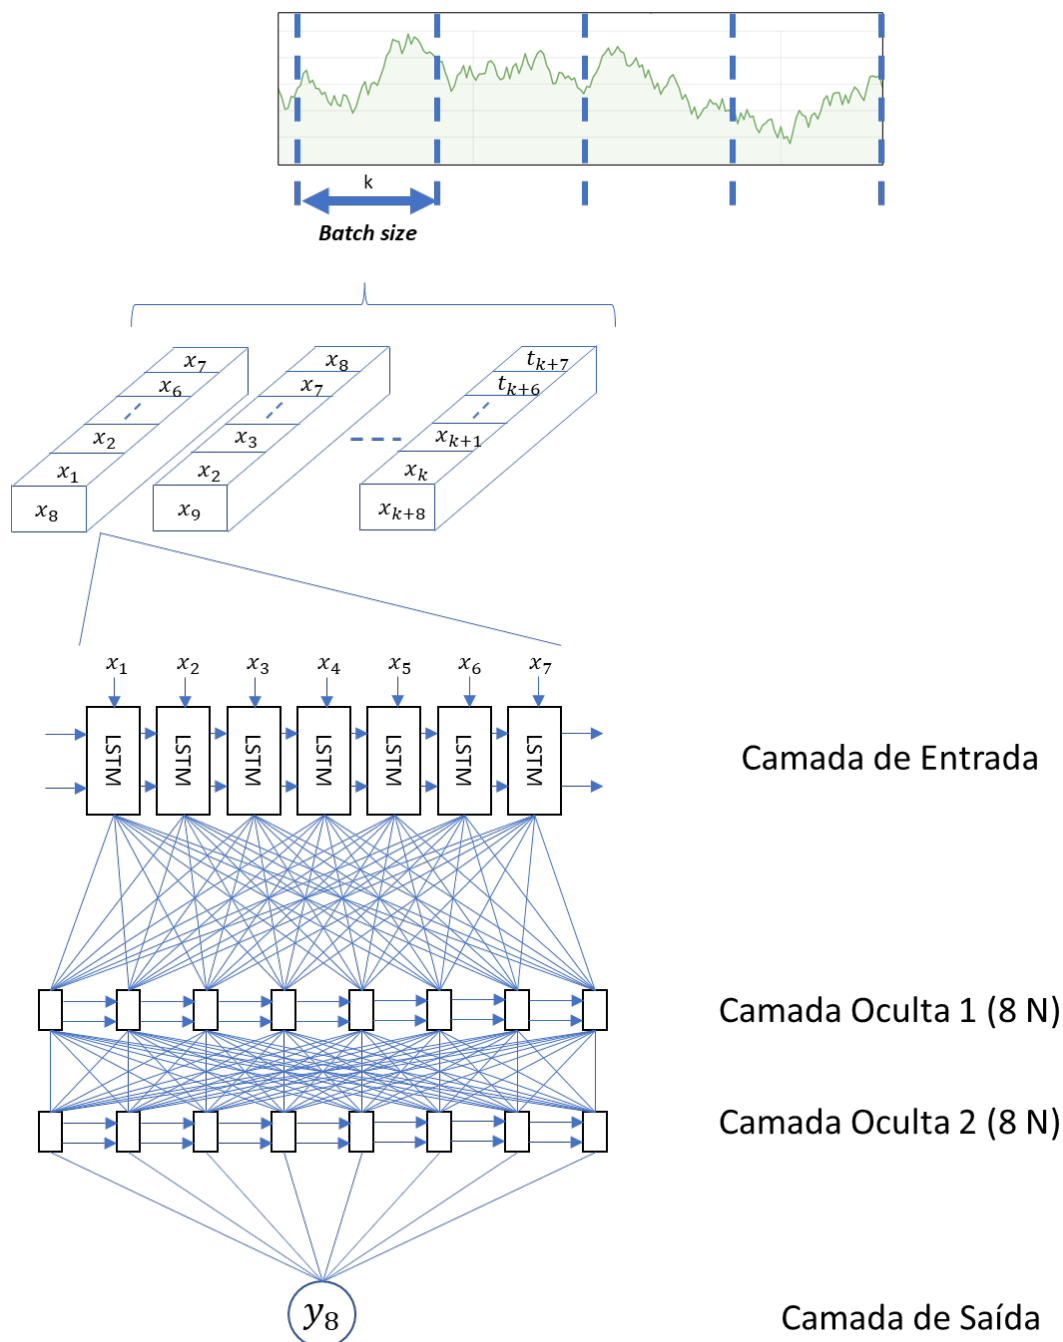
Os hiperparâmetros e alguns outros termos foram utilizados ao longo do texto do trabalho sem tradução, com origem na língua inglesa, devido a dois fatores. O primeiro, que estes termos e palavras são comuns para pessoas que estão ligadas a áreas relacionadas. O segundo motivo é que algumas traduções podem induzir a ambiguidade ou trazer alguma confusão, dificultando a leitura e interpretação textual.

A [Figura 4](#), ilustra uma rede neural LSTM modelada para uma série temporal,

Excluído: Fi

com sete unidades de *time steps*, e duas camadas com oito neurônios cada.

Figura 4 - Arquitetura de rede neural LSTM, com 2 camadas ocultas com 8 neurônios cada



Fonte: o autor.

ABBASIMEHR et al. (2020) observaram que as redes neurais geram resultados precisos, comparados aos métodos estatísticos tradicionais. KANTASA-ARD et al. (2020) identificaram que a LSTM é capaz de capturar padrões para previsão de demanda, atingindo um grau de relação superior a 94% em todos os testes.

REN et al. (2020) constataram que a LSTM é capaz de modelar a dinâmica do sistema e as relações de dependência em variações de demandas de serviços de logística, atingindo percentuais de redução de custos operacionais diários de até 64,72%. Fu et al. (2018) obtiveram os resultados, avaliando a previsão de demanda de semicondutores, dentre vários métodos, o destaque foi para o LSTM: MAE de 588,1, enquanto os modelos por métodos estatísticos atingiram 814,6.

Este hiperparâmetros selecionados são baseados em outros trabalhos (ABBASIMEHR; SHABANI; YOUSEFI, 2020; CARBONNEAU; LAFRAMBOISE; VAHIDOV, 2008; GORGOLIS et al., 2019; KANTASA-ARD et al., 2021; MAHBUB; PAUL; AZEEM, 2013; ZHANG; QI, 2005). Existem outros hiperparâmetros para a arquitetura, que não são explorados na pesquisa, tendo ênfase nos principais apontados pela literatura.

## 2.5 PRÉ-PROCESSAMENTO DE DADOS

Um conjunto de dados extenso pode apresentar *outliers* devido a aleatoriedade ou ruídos (JEENANUNTA et al., 2018). Todos esses padrões e *outliers* imprevisíveis e indetectáveis podem reduzir a precisão da previsão. A detecção adequada de *outliers* e sua substituição por dados tratados ajudam a reduzir erros na previsão. A mesma pesquisa utilizou filtros de bandas (intervalos mínimos e máximos) para identificar *outliers* e substituiu pela média móvel de um período pré-determinado, além do uso de interpolações.

NESPOLI et al. (2021) avaliou o impacto da qualidade dos dados em previsões utilizando redes neurais LSTM, substituindo os *outliers* detectados pela mediana do conjunto de dados, determinando cenários distintos para validar diferentes tratamentos de *outlier*, assim como nenhuma manipulação.

Outras referências que realizaram tratativas de *outliers* nos conjuntos de dados foram: ASSOC ANASTASIA STEFANOVA KONDUKTOROVA et al., 2021, que substituiu os *outliers* detectados através de bandas de limites superiores e inferiores pelos percentuais quantis, SHIN; CHUNG; PARK, 2020 substituiu pelo desvio absoluto mediano, NETO et al., 2018 utilizaram a interpolação de dados como método.

Existem outras técnicas que podem ser utilizadas para detecção de *outliers*, além

das comuns (percentual quantil, por exemplo) existem métodos estatísticos, analíticos ou computacionais que identificam anomalias como descreve HU et al., 2021, que dentre as técnicas descreve e aplica o método *Isolation Forest* para detectar anomalias, que nos seus resultados alcançou redução de até 57,5% dos erros em previsões ao utilizar esta técnica.

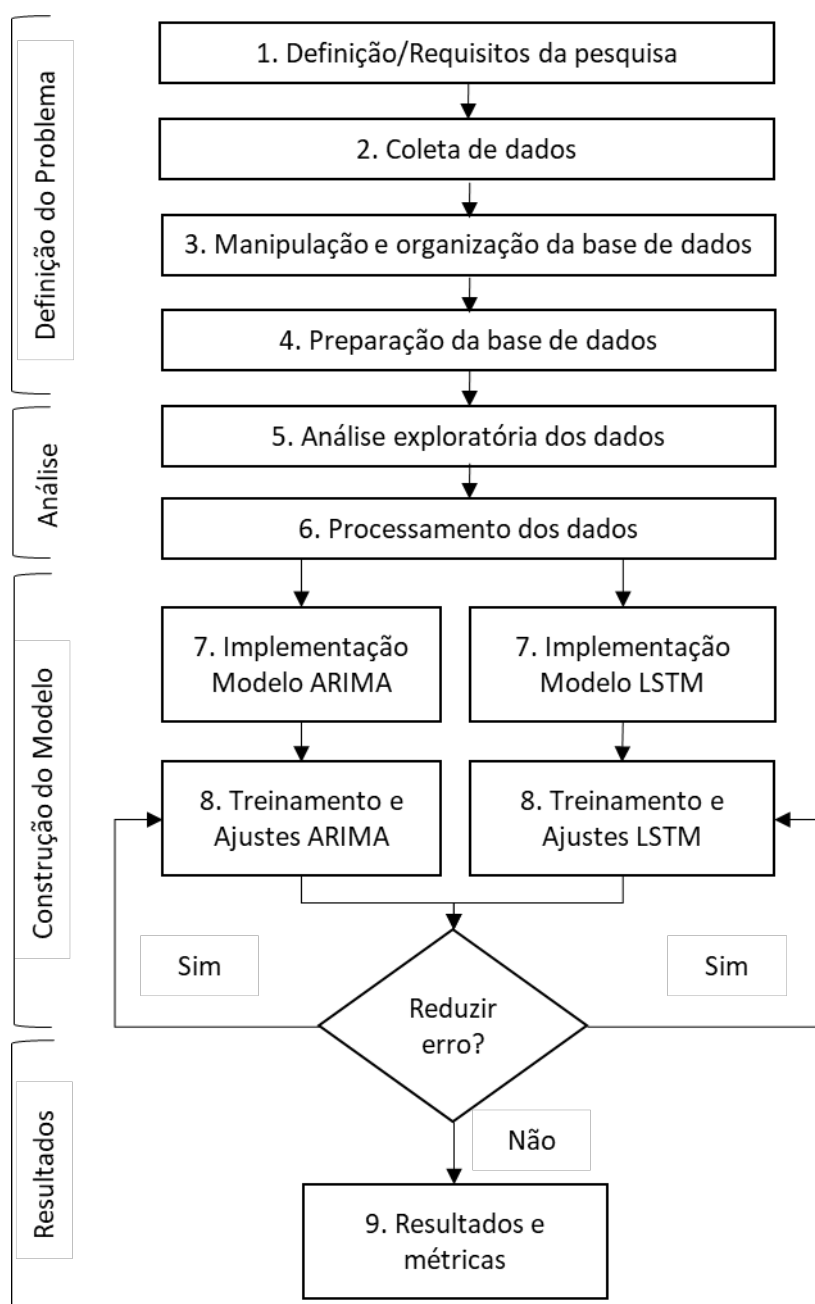
O capítulo seguinte descreve as etapas da metodologia adotada.



### 3. MATERIAIS E MÉTODOS

Esta pesquisa utiliza dois métodos: simulação computacional (NEGAHBAN; YILMAZ, 2014) e estudo de caso (TELLIS, 1997). O primeiro método envolve a implementação de um modelo computacional que permita simular as características de um problema em questão, visando obter *insights* e realizar previsões sobre variáveis ou comportamentos de interesse. Este método foi inspirado pelas metodologias adotadas nos seguintes trabalhos de aprendizagem de máquina aplicados a previsões de séries temporais: Kara *et al.*, (2011) e Sezer *et al.*, (2020). O segundo método utilizado é relacionado à aplicação do modelo implementado em uma situação real, utilizando dados coletados em uma empresa de representatividade no mercado para a distribuição de produtos de diferentes naturezas, origens e destinos. As etapas da pesquisa, representadas na [Figura 5](#), estão descritas nas subseções de 3.1 a 3.9.

Figura 5 - Fluxograma do método



Fonte: o autor.

### 3.1 DEFINIÇÃO DE REQUISITOS DA PESQUISA

O teor da presente pesquisa está fundamentado na ciência de dados, segundo definições mencionadas por Zhu; Xiong (2015) aplicando as técnicas, modelos e recursos de aprendizados de máquina e estatísticos para aplicação de um problema, não sendo sua finalidade a criação de novas arquiteturas ou modelos, ou tecnológica/computacional, mas sim, com objetivo de extrair conhecimento

neste domínio de aplicação.

Compreendendo as necessidades, a maneira que se alcança determinados objetivos e os critérios para interpretação e avaliação dos resultados para a simulação computacional de previsões de demandas, aplicadas ao domínio de transportes. Os principais requisitos e condições para a implementação são:

- I. Determinação dos modelos para previsões a serem avaliados no tema em pesquisa;
- II. Definição dos conjuntos de dados diferentes e que representem localidades distintas, com características próprias e que tenham possibilidade de avaliar componentes (variáveis) exógenas, como categorias de itens/produtos;
- III. Determinação da viabilidade técnica, ou seja, os modelos possíveis de construir ou desenvolver, e para os quais existam recursos computacionais que sejam capazes de processar os resultados;
- IV. Garantia que os modelos de previsões possuam tempo de processamento adequados para aplicação na atual pesquisa;
- V. Definição das métricas que indiquem erros que não distorçam o resultado de previsões, ou que esteja dentro de uma tolerância;
- VI. Avaliação da resiliência dos modelos em diferentes conjuntos de dados, cenários e variações;

### **3.2 COLETA DE DADOS**

Uma empresa de transportes de produtos brasileira, proveu os dados para serem aplicados e utilizados na pesquisa. Estes dados são base para a realização da simulação computacional e do estudo de caso. A base de dados coletada na pesquisa possui informações operacionais dos anos 2019 e 2020, com as demandas de transportes diárias para diferentes produtos em suas 54 unidades expedidoras, considerando os seguintes dados: (1) peso, (2) volume, (3) unidade expedidora de origem, (4) segmento do cliente e (5) documento de viagens. Os dados foram disponibilizados em um arquivo no formato CSV, totalizando o arquivo original em 1,06 Gigabytes de espaço de armazenamento. Os códigos das unidades foram anonimizados e estão numeradas de 1 a 54, com a

nomenclatura no texto referenciando a cada unidade pelo código U + número da unidade (com dois dígitos), por exemplo U01.

### 3.3 MANIPULAÇÃO E MODELAGEM DA BASE DE DADOS

A base de dados foi disponibilizada através de um arquivo CSV contendo todas as demandas agregadas de transporte nos anos 2019 e 2020, contendo dados como identificador da demanda, unidade expedidora de origem/destino, peso da demanda, volume da demanda, data de expedição e categoria da demanda.

Para início da manipulação dos dados, é necessário abrir a base, que devido ao tamanho do arquivo torna-se ineficiente utilizando ferramentas como Excel, pois são lentas e algumas vezes incapazes de abrir arquivos extensos. Como alternativa, foram encontradas ferramentas que auxiliam na manipulação de dados, sendo a primeira Tad<sup>1</sup>, que é um software gratuito para visualização de dados tabulares, que permite abrir e manipular arquivos que contém bases de dados com mais rapidez quando comparado com ferramentas como o Excel. A outra ferramenta é o *DB Browser for SQLite*<sup>2</sup>, que é uma ferramenta de código livre gratuita, usada para criar, projetar e editar bancos de dados *SQLite*. Com esta ferramenta é possível rearranjar os dados através de consultas no formato SQL e gerando a base de dados manipulada, segundo os critérios definidos.

### 3.4 PREPARAÇÃO DA BASE DE DADOS

Após a etapa de manipulação e organização dos dados, os dados precisam ser revisados para que estejam prontos para as análises.

O processo inicia com a avaliação dos campos, os tipos de dados de cada campo, formatos de data, caracteres especiais e possíveis inconsistências de dados, para que sejam ajustados e/ou reparados. Em seguida, os dados são organizados, eliminando-se os campos inutilizados (por exemplo, identificação única da demanda), agrupando-se o total de demandas diárias por unidade de origem, ou seja, a soma total de demandas em um local expedidor por dia. Este

---

1 <https://www.tadviewer.com/>

2 <https://sqlitebrowser.org/>

agrupamento permite que se tenham os dados preparados para a etapa seguinte e também reduzindo o conjunto de dados, permitindo que o processamento de dados utilize uma base menor em espaço de armazenamento, agilizando o processamento dos dados, reduzindo o arquivo CSV em 20% de espaço de armazenamento, aproximadamente.

### **3.5 ANÁLISE EXPLORATÓRIA DOS DADOS**

A etapa de análise exploratória dos dados tem sua importância para o entendimento das principais características dos dados, comportamentos, e precede uma análise de como essas informações extraídas podem ser endereçadas e interpretadas, tendo uma contribuição direta na análise de resultados e conclusões da pesquisa. Isso pode ser realizado através de gráficos e análises estatísticas dos conjuntos de dados. A análise é iniciada a partir da impressão dos seguintes gráficos:

- I. Demandas agregadas de transporte diárias para cada unidade., denominado séries originais, no intuito de visualizar as características de cada unidade. Adjunto a este gráfico os valores de médias móveis e desvio padrão móvel são impressos para que se interprete o comportamento do conjunto de dados;
- II. Gráficos das séries diferenciadas (diferenciação estatística, para tornar a série estacionária), de grau um até o três, para identificar a necessidade de diferenciar a série para torná-la estacionária para aplicação dos modelos ARIMA/SARIMA;
- III. Decomposição sazonal, separando a série em valores, tendência, sazonalidade e resíduos, para identificar as características de comportamento e mudanças da série no período em questão.
- IV. Autocorrelação e autocorrelação parcial, para apoiar na interpretação e/ou determinar alguns hiperparâmetros dos modelos estatísticos.
- V. Histogramas para identificar os valores (demandas) com maiores frequências em cada unidade;

Os mesmos gráficos (número (I) até (V)) são impressos para as categorias de produtos, para que as mesmas análises sejam realizadas sob a perspectiva de categorias de itens em vez de unidades.

### 3.6 PROCESSAMENTO DOS DADOS

O processamento dos dados envolve identificar *outliers* e verificar qual tratamento adequado para estes valores, determinando variações de cenários para verificação dos modelos, considerando tarefas relacionadas à identificação de dados faltantes e *outliers* nas diferentes séries temporais geradas. Foi realizada a separação dos dados em conjuntos de treino e de teste. Nesta etapa foram definidos nove experimentos, segundo diferentes técnicas de tratamento de dados (ajuste de *outliers*) e modelos de implementação, com suas características apresentadas na [Tabela 1](#).

O Cenário 1 tem o intuito de validar o comportamento de variáveis exógenas no conjunto de dados, que neste caso, são as categorias dos itens, totalizando 32 diferentes categorias que foram aplicadas a uma unidade específica (U45). Todos os modelos de previsões da pesquisa foram avaliados neste cenário. As categorias referenciadas da base de dados estão listadas na [Tabela 2](#).

Os Cenários 2 e 4 validam os modelos ARIMA/SARIMA e LSTM, respectivamente, em todas as unidades expedidoras sem nenhum tratamento de *outlier*. Os Cenários 3 e 5 implementam ARIMA/SARIMA e LSTM, respectivamente, realizando tratamento de *outliers*, substituindo os valores identificados pela banda de limites inferiores ou superiores. Os Cenários 6 e 7 implementam ARIMA/SARIMA e LSTM, respectivamente, em todos os conjuntos de dados, descartando-se os *outliers* identificados. Por fim, os Cenários 8 e 9 implementam ARIMA/SARIMA e LSTM, respectivamente, em todos os conjuntos de dados com tratamento de *outliers* utilizando técnicas avançadas de detecção de anomalias em séries de dados, utilizando a biblioteca em Python *pycaret*, utilizando o método *Isolation Forest*, substituindo os pontos identificados pela mediana do conjunto de dados.

Todos os cenários foram executados aplicando a técnica de *cross-validation* dividindo a base de treino em quatro partes (25%, 50%, 75%, e 100% do total de

Excluído: Ta

Excluído: Ta

dados no subconjunto de treino) (YU *et al.*, 2020), com os dados normalizados (de 0 a 1), visando que as métricas dos modelos estejam na mesma escala.

Tabela 1 - Cenários selecionados para a pesquisa

Cenários	Métodos	Tratamento de <i>Outliers</i>	Variáveis Exógenas	Conjuntos de dados
<b>Cenário 1 (C1)</b>	ARIMA/SARIMA/LSTM	Não	Sim	(1x) 32
<b>Cenário 2 (C2)</b>	ARIMA/SARIMA	Não	Não	54
<b>Cenário 3 (C3)</b>	ARIMA/SARIMA	Sim	Não	54
<b>Cenário 4 (C4)</b>	LSTM	Não	Não	54
<b>Cenário 5 (C5)</b>	LSTM	Sim	Não	54
<b>Cenário 6 (C6)</b>	ARIMA/SARIMA	Não	Não	54
<b>Cenário 7 (C7)</b>	LSTM	Não	Não	54
<b>Cenário 8 (C8)</b>	ARIMA/SARIMA	Sim	Não	54
<b>Cenário 9 (C9)</b>	LSTM	Sim	Não	54

Fonte: o autor.

Tabela 2 - Categorias/Classificação de produtos

<b>Categorias</b>	
Agropecuária	Fiação Fibras Artificiais e Sintéticas
Autopeças	Informática
Bebidas	Itens infantis
Bolsas	Laboratórios e Medicamentos
Brinquedos em Geral	Maquinas
Calçados	Material de Construção
Construção Civil	Material elétrico
Cosméticos	Material Esportivo
Diversos	Material Hospitalar
Eletrodomésticos em Geral	Moveis
Eletrônicos diversos	Papelaria/Livraria
Embalagens	Produtos alimentícios
Equipamento de Segurança	Produtos gráficos
Equipamentos para indústria	Tecidos e Confecções
Fabricação de colchões	Transp. rod. cargas em geral
Ferramentas	Utilidades Domésticas

Fonte: o autor.

### 3.7 IMPLEMENTAÇÃO DOS MODELOS

Para a aplicação dos modelos realizou-se a implementação e análise de hiperparâmetros dos modelos preditivos, incluindo os modelos ARIMA e

SARIMA. Através de bibliotecas que implementam o *Grid Search*, que realiza uma permutação entre os possíveis hiperparâmetros, validando sua aderência através de testes estatísticos, como o AIC, sendo, assim, os hiperparâmetros dos conjuntos de dados são identificados. Em complemento, podem ser realizadas análises dos gráficos de autocorrelação e autocorrelação parcial para identificar/modificar potenciais hiperparâmetros para os modelos.

Também realizou-se a implementação e análise de hiperparâmetros do modelo de *deep learning*, a LSTM. O conjunto de hiperparâmetros avaliados foram: *batch size* (32, 64, 128), número de camadas (1 ou 2), quantidade de neurônios por camada (16, 32, 64, 128, 256, 1024), *epochs* (25, 100, 200) e *time steps* (7 ou 14), com o conjunto de valores previamente definidos a partir de testes iniciais com amostragens dos diferentes conjuntos de dados.

### **3.8 TREINAMENTO DOS MODELOS**

Através do método *Grid Search*, foram testadas as combinações de opções de hiperparâmetros para cada modelo, armazenando-se as métricas obtidas nos dados de treinamento (primeiros 80% dos dados da base total), e no final ordenando-se segundo o critério das menores métricas MAE crescente. Ao final os hiperparâmetros com a menor métrica MAE da base de treinamentos foram selecionados para que fossem aplicados na base de validação (últimos 20% dos dados da base total);

### **3.9 RESULTADOS E MÉTRICAS**

Foi realizada a comparação final dos modelos nos cenários avaliados, considerando como métricas: MSE, MAE e tempo de processamento. Foram realizadas: (i) uma avaliação para cada unidade expedidora, nos Cenários 2 a 9, visando identificar os modelos com a menor métrica de erro e a influência do tratamento de dados; e (ii) avaliação do Cenário 1, considerando todas as categorias em todos os modelos em pesquisa.

O critério para avaliação das métricas MAE e MSE é utilizado, buscando sempre os resultados com as métricas menores. Os dados foram normalizados (de 0 a



1), o que simplifica a interpretação e compreensão da dimensão dos erros obtidos. A métrica MAE tem uma interpretação objetiva, pois os valores estão absolutos em relação aos dados. Por outro lado, o MSE penaliza os conjuntos de dados que possuem quantidades consideráveis de *outliers*, transmitindo uma outra referência de erro, sujeito à característica da série.

### 3.10 RECURSOS TÉCNICOS

A pesquisa utilizou a linguagem de programação Python<sup>3</sup>, utilizando as bibliotecas: keras<sup>4</sup>, tensorflow<sup>5</sup>, pandas<sup>6</sup>, matplotlib<sup>7</sup>, statsmodels<sup>8</sup>, scikit-learn<sup>9</sup>, statistics<sup>10</sup>, sklearn<sup>11</sup>, numpy<sup>12</sup>, pycaret<sup>13</sup> e seaborn<sup>14</sup>.

O tempo de processamento de todos os cenários, incluindo ajustes e reprocessamentos, ultrapassou 1.500 horas (aproximadamente 63 dias corridos). Por este motivo, utilizou-se mais de um computador em paralelo para aquisição dos resultados, com as seguintes especificações: (i) computador com processador Intel Core (TM) i7-5500U CPU 2,40 GHz e 8 GB RAM; (ii) computador com processador Intel Core (TM) i3-4005U CPU 1,70 GHz e 4 GB RAM; e (iii) computador na nuvem<sup>15</sup> (virtual) com 32 processadores e 16 Gb de RAM, recurso utilizado por apenas por 30 dias, devido ao seu custo.

### 3.11 PLANO DE GESTÃO DE DADOS

Definiu-se nesta pesquisa um Plano de Gestão de Dados, para que os dados fossem geridos corretamente (captura, armazenagem, proteção), e garantindo a sua acessibilidade e uso adequado, permitindo que as informações extraídas

---

3 <https://www.python.org/>

4 <https://keras.io/>

5 <https://www.tensorflow.org/>

6 <https://pandas.pydata.org>

7 <https://matplotlib.org/>

8 <https://www.statsmodels.org>

9 <https://scikit-learn.org/>

10 <https://docs.python.org/3/library/statistics.html>

11 <https://scikit-learn.org/>

12 <https://numpy.org/>

13 <https://pycaret.org/>

14 <https://seaborn.pydata.org/>

15 <https://azure.microsoft.com/>

possam agregar valor à pesquisa e a pesquisadores, garantindo que os dados sejam protegidos e anonimizados, evitando perdas de conhecimento e permitindo o respaldo da presente pesquisa (EARLEY; HENDERSON, 2017).

O plano contempla todas as etapas da metodologia da pesquisa, iniciando-se pelo planejamento, definindo-se quais dados são necessários, a sua fonte e a sua finalidade. Em seguida procedeu-se à coleta de dados, adquirindo-os e determinando os respectivos formatos da base, recursos e tecnologias. Os dados são assegurados, através da revisão, verificando-se erros, perdas e inconsistências.

O processo descritivo dos dados é possível após a sua adaptação para os processos computacionais, inclusive a anonimização, requerida pela fonte em questão, modificando os dados que caracterizam a operação, como os códigos das unidades, que foram classificados por uma nova nomenclatura, específico da pesquisa, retirando qualquer evidência física, geográfica e institucional, sem comprometimento com a qualidade e usabilidade.

Para preservação dos dados, foram utilizados diversos *backups* em mídias físicas, em repositórios provenientes da fonte e também repositórios de *backup* virtuais, todos com restrições de acessos.

Para o respaldo e validação desta pesquisa e possíveis evoluções, o conjunto de dados foi publicado (MAMEDE, 2022) e torna-se acessível, o que é uma das contribuições desta pesquisa. Da mesma forma o código-fonte dos programas foi disponibilizado (POLOLA MAMEDE, 2022).

## 4. RESULTADOS

Este capítulo contém todo o detalhamento dos resultados da pesquisa, e suas respectivas análises, contemplando os modelos ARIMA, SARIMA e LSTM nos 9 cenários definidos na metodologia.

A partir das diferentes frentes de trabalho nesta pesquisa, obtêm-se os seguintes resultados:

- Identificação dos principais requisitos para a aplicação de modelos de aprendizagem de máquina na previsão de demanda de transportes em operadores logísticos;
- Identificação dos cenários que devem ser aplicados nos modelos, referente a análise exploratória da base de dados, avaliando o método de tratamento de *outliers* que seja adequado as unidades, individualmente;
- Identificação dos principais hiperparâmetros que influenciam nos modelos implementados no trabalho;
- Avaliação comparativa dos modelos ARIMA e LSTM aplicados ao problema de pesquisa, comparando as métricas, e discussão em profundidade de seu comportamento a todo o conjunto de filiais presente na base de dados;
- Avaliação do comportamento dos modelos, avaliando a influência geográfica, tipos de produtos e a sensibilidade a *outliers*.

Cabe destacar que algumas tabelas apresentadas nos resultados podem conter alguns dados em branco, ou vazios, devido aos seguintes motivos: (i) problemas de qualidade em alguns conjuntos de dados; (ii) alguma falha de processamento; ou (iii) a quantidade de dados no conjunto não foi suficiente para a obtenção dos resultados em um determinado método.

Os resultados são descritos nas subseções, apresentando pela (i) análise exploratória dos dados, em que as características das unidades e das categorias são expostas; (ii) seleção de hiperparâmetros na base de treino; (iii) métricas obtidas da validação dos modelos nos cenários; (iv) apresentação da influência de variáveis exógenas nos modelos desta pesquisa; e (v) análises dos resultados sob a perspectiva de tempo de processamento.

## 4.1 ANÁLISE EXPLORATÓRIA DOS DADOS

A análise exploratória dos dados permite que a interpretação dos dados e resultados seja enriquecida, correlacionando as características aos resultados e métodos aplicados. Do total dos 54 diferentes conjuntos de dados utilizados nesta pesquisa, obteve-se os seguintes tipos de gráfico: (i) plotagem da série original (os dados de demanda em uma unidade no período de dois anos); (ii) as séries originais acrescentadas das médias móveis e o desvio padrão móvel, que permite observar as flutuações dos dados; (iii) os gráficos com a série diferenciada (até a terceira diferenciação), para avaliar características de estacionaridade dos conjuntos de dados; (iv) gráfico de autocorrelação e autocorrelação parcial, para identificar a relação entre os dados do conjunto, possíveis recorrências e contribuições para os modelos ARIMA/SARIMA; (v) gráficos de decomposição da série temporal, separando o conjunto em 4 componentes: dados, tendência, sazonalidade e resíduos, permitindo que sejam identificadas características como período de sazonalidade, interferência de *outliers* e o formato da tendência dos dados, caso exista; (vi) histograma dos conjuntos de dados, para identificar a frequência dos dados e observar se existem polarizações dos dados ou se estão distribuídos. Além disso, as mesmas plotagens foram realizadas para as categorias classificadas para o Cenário 1.

### 4.1.1 CARACTERÍSTICAS DOS CONJUNTOS DE DADOS

Cada conjunto de dados possui características independentes, o que tornam os mesmos únicos e distintos. Este detalhe contribui no quesito de avaliação dos modelos da pesquisa em diferentes conjuntos de dados, identificando como os modelos podem ser aplicados e suas características em aplicações distintas.

Os gráficos da [Figura 6](#), são alguns exemplos que reforçam a heterogeneidade dos conjuntos de dados, que possuem escalas (quantidade de demandas) distintas e variações em diferentes períodos. Estes gráficos retratam os conjuntos de dados e as características estatísticas de cada unidade, contendo as médias móveis e desvio padrão, e a quantidade de demandas por dia nos anos 2019 e 2020, sem qualquer tratamento de *outliers*.

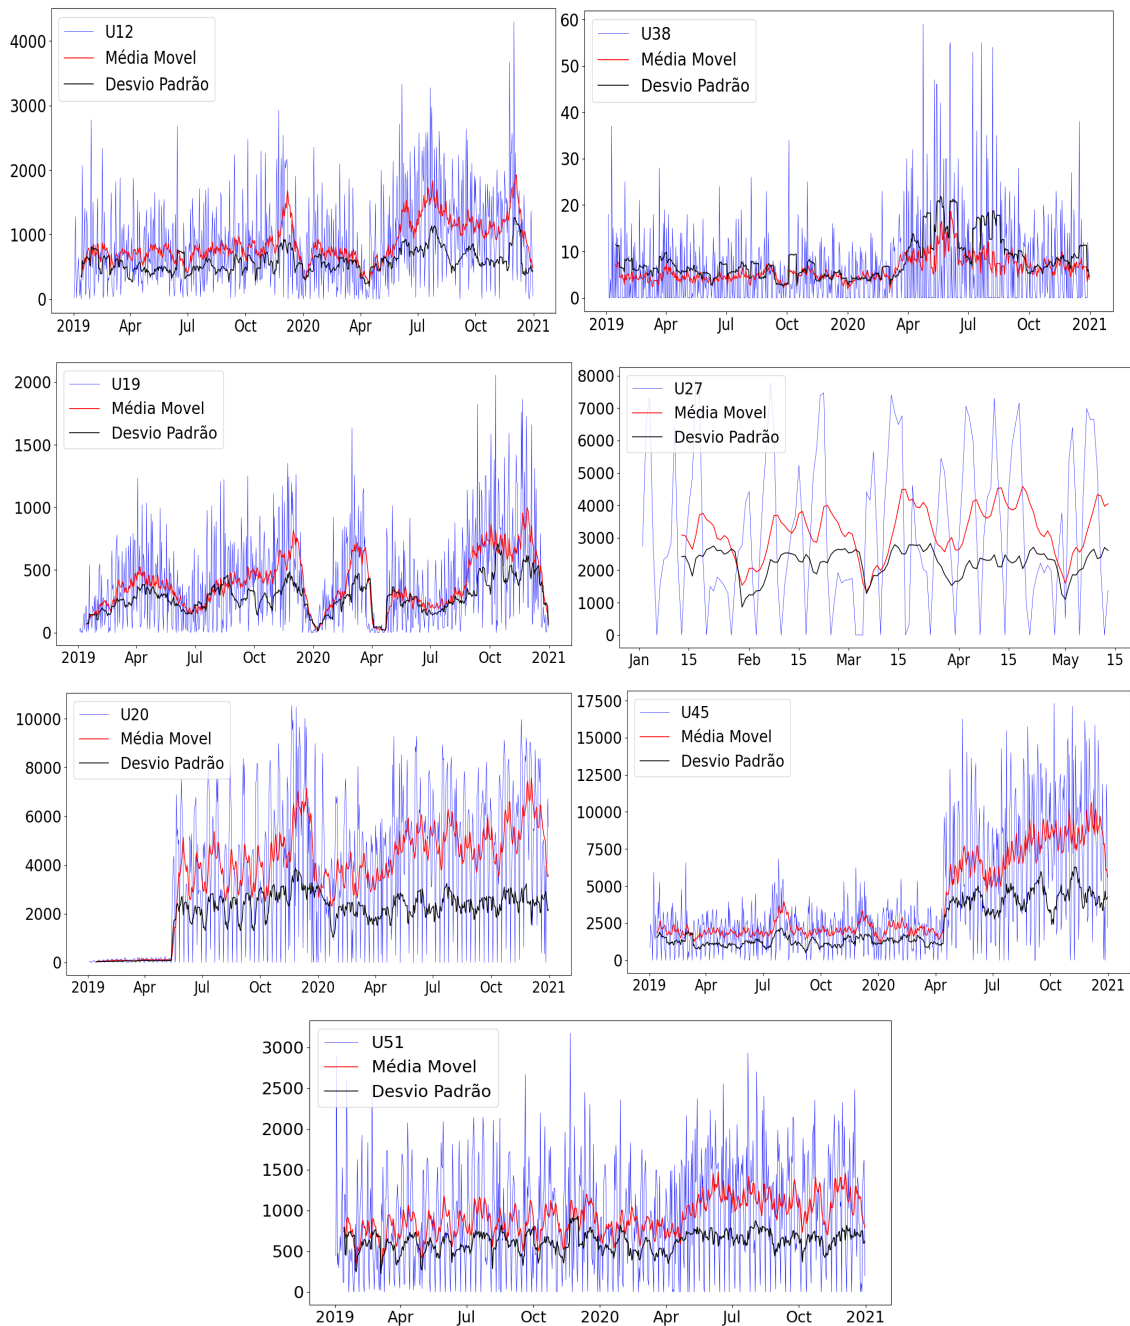
A unidade U38 apresentou a menor ordem de grandeza de quantidade de

demandas, não ultrapassando 60 demandas diárias, enquanto o gráfico da unidade U45 descreve uma unidade com maior intensidade de volumes transacionados, ultrapassando 17.000 demandas em um único dia. O gráfico da unidade U12 exemplifica uma unidade que obteve variações em diferentes períodos, com crescentes e decrescentes de demandas, enquanto outras unidades como a do gráfico da unidade U51 que apresentaram regularidade ao longo do período de amostragem.

Outra característica de algumas unidades pode ser vista como no gráfico da unidade U19, que apesar de também existirem variações em todo o período, as médias móveis e desvio padrão móvel tiveram curvas que podem levar ao entendimento de que existem recorrências ou sazonalidades ao longo do período avaliado. Algumas unidades como a exibida no gráfico da Figura 6, a unidade U27 estão incompletas no período devido à interrupção ou transferência operacional para outra localidade.

Também pode-se observar casos de unidades que expandiram sua operação no período como os gráficos das unidades U20 e U45. Estes são alguns exemplos que contextualizam que as unidades executam diferentes operações, norteados por quesitos como demanda regional, zonas industriais, rotas logísticas, entre outras. Além disso, pode-se verificar como os métodos e dentre os métodos de tratamento de *outliers* se comportam em diferentes situações.

Figura 6 - Demandas agregadas das unidades U12, U38, U19, U27, U20, U45 e U51 (ordem) com respectivas médias móveis e desvio padrão móvel



Fonte: o autor.

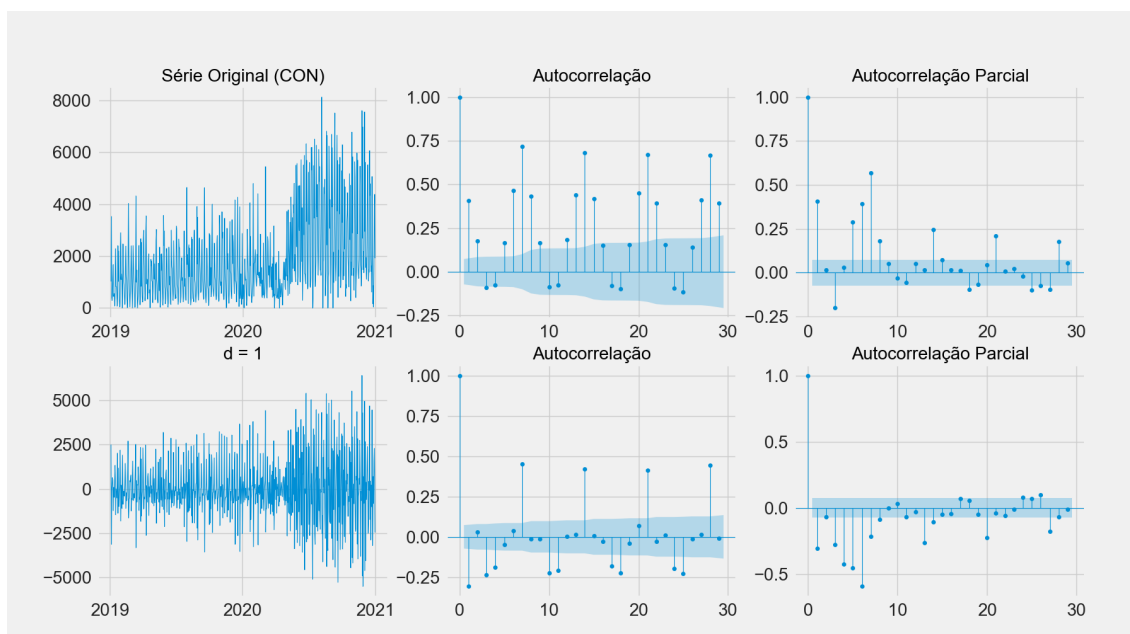
Uma característica que pode ser observada em todas as unidades é que existem dias com valores de demanda zero em todo o período, ou próximo a zero. Isto ocorre devido dias que as unidades estão operacionalmente inativas, como fins de semana ou feriados.

Para a avaliação da estacionaridade (propriedades estatísticas constantes ao longo do tempo) de cada conjunto, os testes *Augmented Dickey Fuller test* (ADF)

são realizados. Considerando os dados originais (sem tratamento de *outliers*), aproximadamente 80% das unidades são não-estacionárias. Para que os modelos ARIMA/SARIMA sejam aplicados, é necessário que as séries sejam diferenciadas a um grau que seja possível tornar a série temporal estacionária. A [Figura 7](#), que contém o gráfico de autocorrelação/parcial da unidade U05, pode-se observar a série original com seus respectivos gráficos de autocorrelação e autocorrelação parcial e abaixo a diferenciação da série, seguidos do resultado de autocorrelação e autocorrelação parcial da série diferenciada. Estes gráficos permitem identificar os termos do modelo ARIMA, que contribuem para complemento da análise feita em complemento à métrica AIC que é calculado para todas as unidades dentro de um conjunto de possibilidades de combinações dos hiperparâmetros da família ARIMA. Estes gráficos também auxiliam na identidade de características sazonais.

Excluído: Fig

Figura 7 - Gráficos de autocorrelação, autocorrelação parcial e série original e diferenciada da unidade U05



Fonte: o autor.

Outras características das unidades são obtidas através da decomposição sazonal em cada conjunto, como mostra a [Figura 7](#), separando os dados em valor base, tendência, sazonalidade e resíduos, no qual os 4 somados resultam na série original. Em todas as unidades identifica-se a característica de sazonalidade com recorrência semanal, ou seja, repete a cada 7 ciclos. Outra


Excluído: Fig

característica comum entre os conjuntos de dados é a amplitude e aleatoriedade dos resíduos, o que sugere características como presença de *outliers* e não estacionariedade do conjunto.

A curva de tendência descreve possíveis oscilações em determinados períodos, como por exemplo ocorre no fim de 2019 e início de 2020 como mostra a unidade na [Figura 8](#),

Excluído: Fig

Figura 8 - Decomposição sazonal (dados originais, tendência, sazonalidade e resíduos) da unidade U19



Fonte: o autor.

#### 4.1.2 CATEGORIAS

Com relação às 32 categorias que classificam as demandas, foram feitas as mesmas análises realizadas em cada unidade, considerando as séries originais de cada categoria, gráficos de decomposição sazonal, autocorrelação e autocorrelação parcial, histogramas, que permitam identificar as características e as influências de categorias nas unidades, denominado Cenário 1.

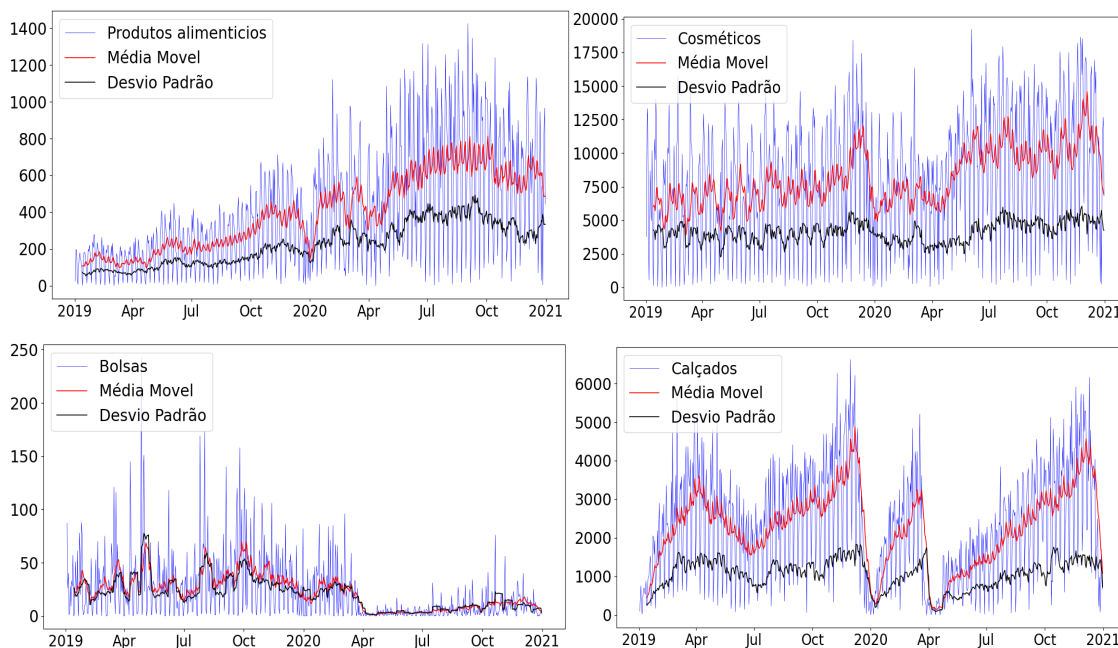
Alguns destaques extraídos da análise exploratória das categorias das demandas agregadas de transporte estão apresentados na [Figura 9](#), que contém os gráficos que agregam as demandas por categorias, em que os produtos alimentícios tiveram uma tendência de crescimento no período, com algumas oscilações em determinados períodos; cosméticos apresentou certa

Excluído: Fig



regularidade ao longo do período; a categoria bolsas obteve queda após abril de 2020; e o gráfico de calçados mostra que é possível identificar que a mesma possui uma sazonalidade regular, comparando-se os anos de 2019 e 2020 se assemelham, exceto entre março e maio que obteve quedas súbitas.

Figura 9 - Demandas agregadas das categorias Produtos Alimentícios, Cosméticos, Bolsas e Calçados (ordem) com respectivas médias móveis e desvio padrão móvel



Fonte: o autor.


#### 4.1.3 IMPACTO DA PANDEMIA NAS DEMANDAS

No período avaliado nesta pesquisa, a partir de dezembro de 2019 pôde-se observar alguns indícios de pandemia do COVID-19 tendo já no início de 2020 restrições sanitárias e medidas de isolamento que, afetam algumas áreas da economia (positivamente ou negativamente). Algumas unidades tiveram oscilações visíveis no ano de 2020, com destaque para o início do ano, como pode ser visto na [Figura 6](#), nas unidades U19 e U15. Da mesma forma alguns indícios podem ser observados em algumas categorias de produtos como bolsas e calçados. Por outro lado, a categoria Informática ([Figura 10](#)) obteve aumento de demanda após o mês de maio de 2020, o que se pode interpretar que decorreu do aumento do trabalho em casa e facilidades domésticas para evolução do ambiente doméstico durante o isolamento.

Excluído: Fi

Excluído: Fi

Figura 10 - Demandas agregadas da categorias Informática com respectivas médias móveis e desvio padrão móvel



Fonte: o autor.

A base de treino para os métodos contempla 80% dos dados e os 20% restantes para validação, ou seja, de janeiro de 2019 até meados de agosto de 2020 são utilizados para treino. Os efeitos da pandemia foram perceptíveis em aproximadamente metade das unidades e das categorias. Estas oscilações podem afetar as previsões dos modelos ARIMA e SARIMA, que possuem relação direta com as médias móveis e dados retroativos, que podem distorcer previsões futuras. O modelo LSTM, apesar de também possuir dependência com os dados passados, é capaz de discernir e se adaptar à características irregulares, o que pode favorecer este método.

## 4.2. SELEÇÃO DE HIPERPARÂMETROS NA BASE DE TREINO

Esta seção relaciona o processo de treinamento dos modelos, assim como a obtenção dos valores identificados para cada hiperparâmetro, segundo as métricas definidas na pesquisa.

### 4.2.1 TREINO ARIMA E SARIMA

Esta subseção apresenta os resultados obtidos sob a perspectiva dos hiperparâmetros dos modelos ARIMA e SARIMA obtidos no processamento da

base de dados de treino, em seguida utilizados para validação, desdobrando em tópicos cada hiperparâmetro destes modelos.

#### 4.2.1.1 ARIMA (AR/p)

Este hiperparâmetro no modelo ARIMA determina a regressão dos valores com os seus respectivos dados históricos. Os gráficos da [Figura 11](#), exibem a componente autorregressiva escolhida em cada unidade em cada cenário. Observa-se que os Cenários 2, 3 e 8 concentraram os valores acima de  $AR=5$ , enquanto o Cenário 6 obteve característica diversificada. Além disso, os cenários que não tiveram remoção de *outliers* (2, 3 e 8) tiveram suas características semelhantes: índices autorregressivos cresceram em frequência com o aumento deste índice. Alinhado com esta inferência, a [Tabela 3](#), mostra os valores do hiperparâmetro autorregressivo em cada unidade por cenário, e percebe-se que houve um comportamento predominante nas unidades nos Cenários 2, 3 e 8, com valores equivalentes ou com diferença de uma unidade. Portanto, compreende-se que para esta pesquisa, o tamanho do conjunto de dados foi um quesito determinante na determinação do índice autorregressivo, além de que este índice é sensibilizado pela característica do conjunto de dados, independente do tratamento dos mesmos.

Excluído: Fig


Excluído: Ta


Tabela 3 - Componente AR(p) do modelo ARIMA selecionada em cada unidade/cenário

	Cenários															
	C2	C3	C6	C8	C2	C3	C6	C8	C2	C3	C6	C8				
<b>U01</b>	8	8	6	4	<b>U19</b>	8	7	5	7	<b>U37</b>	6	6	4	4		
<b>U02</b>	6	6	4	6	<b>U20</b>	7	7	3	5	<b>U38</b>	4	8	2	6		
<b>U03</b>	6	7	6	6	<b>U21</b>	3	1	0	1	<b>U39</b>	3	6	6	8		
<b>U04</b>	1	7	3	5	<b>U22</b>	5	8	2	6	<b>U40</b>	7	7	2	7		
<b>U05</b>	6	6	2	6	<b>U23</b>	6	6	4	7	<b>U41</b>	7	5	5	5		
<b>U06</b>	7	6	4	6	<b>U24</b>	8	8	7	8	<b>U42</b>	4	7	2	6		
<b>U07</b>	6	6	5	7	<b>U25</b>	8	7	3	7	<b>U43</b>	8	8	3	7		
<b>U08</b>	6	6	8	7	<b>U26</b>	8	6	7	7	<b>U44</b>	7	5	0	4		
<b>U09</b>	8	7	3	7	<b>U27</b>	7	7	3	5	<b>U45</b>	8	5	7	6		
<b>U10</b>	7	8	4	8	<b>U28</b>	5	7	4	5	<b>U46</b>	4	7	7	6		
<b>U11</b>	7	7	8	7	<b>U29</b>	7	6	2	6	<b>U47</b>	8	5	8	8		
<b>U12</b>	8	8	0	8	<b>U30</b>	6	7	1	7	<b>U48</b>	8	8	6	6		
<b>U13</b>	7	7	4	7	<b>U31</b>	8	0	0	0	<b>U49</b>	7	8	3	7		
<b>U14</b>	7	8	3	6	<b>U32</b>	0	0	6	0	<b>U50</b>	8	6	4	6		
<b>U15</b>	6	6	4	6	<b>U33</b>	8	8	5	8	<b>U51</b>	6	6	1	6		
<b>U16</b>	8	7	8	7	<b>U34</b>	5	6	2	6	<b>U52</b>	7	7	6	7		
<b>U17</b>	7	6	7	6	<b>U35</b>	8	7	7	8	<b>U53</b>	6	6	3	6		
<b>U18</b>	6	7	4	6	<b>U36</b>	6	7	6	7	<b>U54</b>	7	6	8	6		

Fonte: o autor.


Figura 11 - Valores selecionados da componente AR em cada unidade, por cenário





Fonte: o autor.

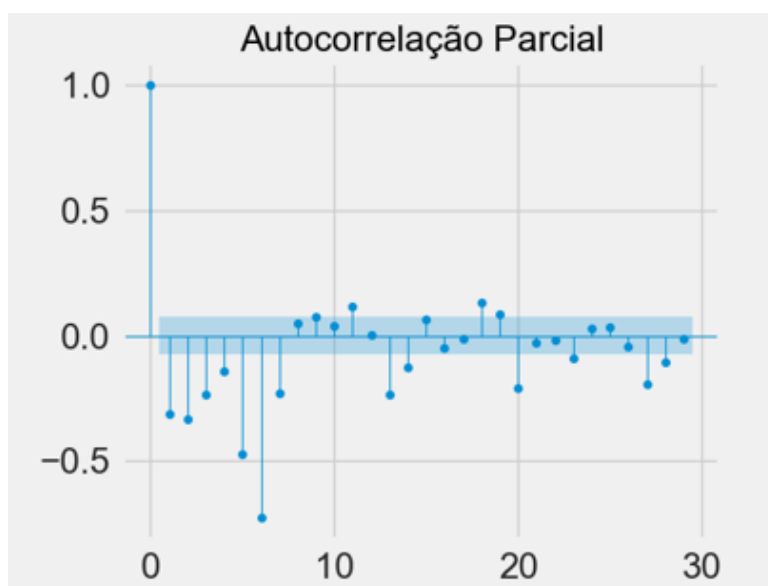
Figura 12 - (a) Distribuição dos valores AR nos cenários. (b) Contagem dos possíveis valores AR em cada cenário



Fonte: o autor.

A [Figura 12](#), (a) mostra um resumo da contagem de cada índice autorregressivo nos cenários em questão, confirmando as informações analisadas anteriormente. Um destaque é que o índice AR=2 foi selecionado apenas no Cenário 6. Em complemento, a [Figura 12](#), (b) exibe a concentração dos cenários em cada valor do hiperparâmetro. É possível identificar que houve uma crescente das frequências à medida que o índice aumentou, o que também mostra que os dados apresentam correlação a intervalos superiores a 5 nas séries-temporais. Os gráficos de autocorrelação parcial mostram a relação deste hiperparâmetro com os dados do conjunto de dados, como mostra a [Figura 13](#), que apresenta a autocorrelação parcial dos dados da unidade U03 diferenciada, posicionando o índice mais intenso no valor 6.

Figura 13 - Autocorrelação parcial diferenciada da unidade U03



Fonte: o autor.

#### 4.2.1.2 ARIMA (I/d)

Das unidades avaliadas, 47 das 54 apresentaram pelo menos um cenário com o índice diferenciado no valor 1, ou seja, uma característica não-estacionária e que será correlacionada esta característica com as métricas obtidas.

Tabela 4 - Componente I(d) do modelo ARIMA selecionada em cada unidade/cenário

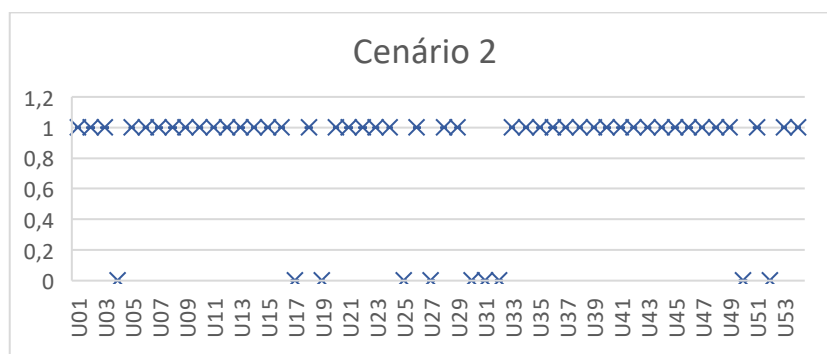
	Cenários															
	C2	C3	C6	C8	C2	C3	C6	C8	C2	C3	C6	C8	C2	C3	C6	C8
<b>U01</b>	1	1	1	1	<b>U19</b>	0	0	0	0	<b>U37</b>	1	1	1	1		
<b>U02</b>	1	1	1	1	<b>U20</b>	1	1	1	1	<b>U38</b>	1	1	1	0		
<b>U03</b>	1	1	1	1	<b>U21</b>	1	1	0	0	<b>U39</b>	1	1	1	1		
<b>U04</b>	0	0	0	0	<b>U22</b>	1	0	1	1	<b>U40</b>	1	1	1	1		
<b>U05</b>	1	1	1	1	<b>U23</b>	1	1	1	1	<b>U41</b>	1	1	0	0		
<b>U06</b>	1	1	1	1	<b>U24</b>	1	0	0	0	<b>U42</b>	1	1	1	1		
<b>U07</b>	1	1	1	1	<b>U25</b>	0	0	0	0	<b>U43</b>	1	1	0	1		
<b>U08</b>	1	1	0	0	<b>U26</b>	1	1	0	0	<b>U44</b>	1	1	1	1		
<b>U09</b>	1	0	0	0	<b>U27</b>	0	0	0	0	<b>U45</b>	1	1	1	1		
<b>U10</b>	1	1	1	1	<b>U28</b>	1	1	1	1	<b>U46</b>	1	0	0	0		
<b>U11</b>	1	1	0	1	<b>U29</b>	1	1	1	1	<b>U47</b>	1	1	0	1		
<b>U12</b>	1	1	1	1	<b>U30</b>	0	0	0	0	<b>U48</b>	1	1	0	1		
<b>U13</b>	1	1	1	1	<b>U31</b>	0	0	0	1	<b>U49</b>	1	0	1	1		
<b>U14</b>	1	1	1	1	<b>U32</b>	0	0	0	0	<b>U50</b>	0	1	0	1		
<b>U15</b>	1	1	1	1	<b>U33</b>	1	1	0	1	<b>U51</b>	1	1	1	1		
<b>U16</b>	1	1	0	0	<b>U34</b>	1	1	1	1	<b>U52</b>	0	0	0	0		
<b>U17</b>	0	1	0	1	<b>U35</b>	1	1	0	1	<b>U53</b>	1	1	1	1		
<b>U18</b>	1	1	1	1	<b>U36</b>	1	1	0	0	<b>U54</b>	1	1	0	1		

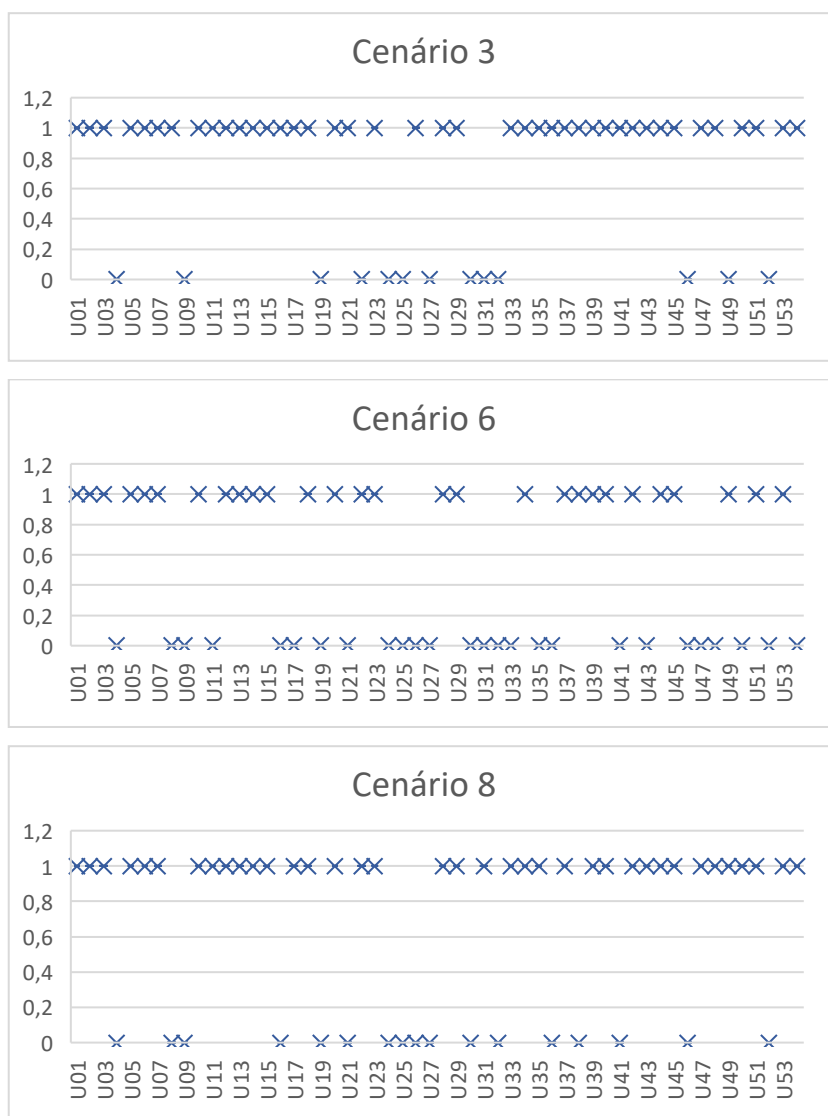
Fonte: o autor.

Os gráficos da [Figura 14](#), possuem os dados referentes aos valores selecionados da componente integral selecionada no modelo ARIMA em cada unidade, em todos os cenários avaliados. Os índices selecionados configuraram os valores 0 e 1, o que simplifica a análise. É possível identificar que nos Cenários 2, 3 e 8 concentraram as configurações na diferenciação em uma unidade, enquanto que no cenário 6 a distribuição foi equilibrada, entre 0 e 1.

Excluído: Fi

Figura 14 - Valores selecionados da componente I(d) em cada unidade, por cenário





Fonte: o autor.


Este hiperparâmetro está atribuído à estacionaridade da série-temporal. Portanto, os resultados sugerem que o tratamento de dados não alterou a característica da série, com exceção do cenário que foram removidos os *outliers*, modificando as características originais da série. A comparação entre os cenários pode ser interpretada de forma consolidada na [Figura 15](#). A [Tabela 4](#), apresenta os valores selecionados em cada unidade em todos os cenários, e dentre as unidades, acima de 60% apresentaram o mesmo valor diferenciado nos Cenários 2, 3 e 8.

Excluído: Fi

Excluído: Ta



Figura 15 - Distribuição dos valores I(d) nos cenários




Fonte: o autor.

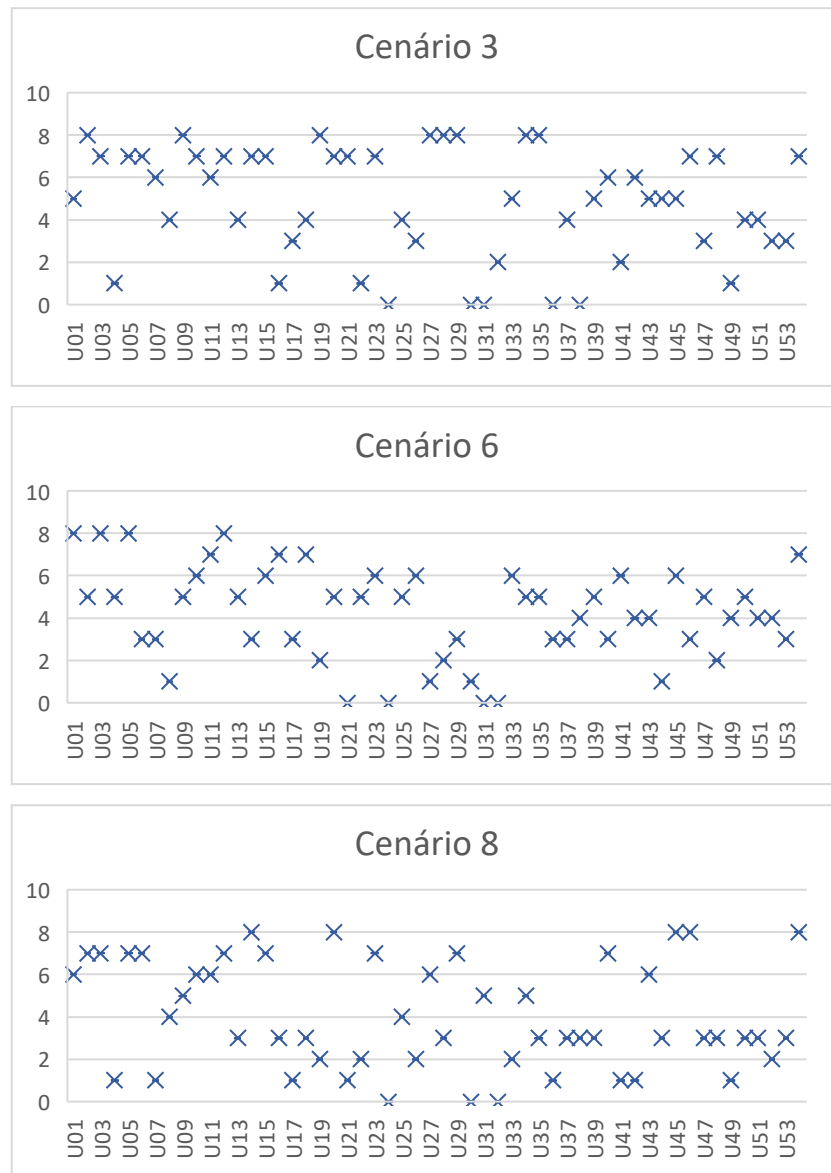
#### 4.2.1.3 ARIMA (MA/q)

Assim como o índice autorregressivo e o diferencial, o componente MA (ou q) pode obter sua característica baseada na autocorreção dos valores em termos de médias móveis. Os gráficos da [Figura 16](#), mostram a variação de valores (entre 0 e 9) em cada cenário em termos das unidades em questão. Observa-se que em todos os cenários este hiperparâmetro apresentou uma heterogeneidade, não obtendo valores predominantes.

Excluído: Fi

Figura 16 - Valores selecionados da componente MA em cada unidade, por cenário






Fonte: o autor.

Outra perspectiva desta observação é a [Figura 17](#), que descreve as contagens das variações de valores MA em cada cenário, que apresentou diferentes características em cada cenário, podendo-se afirmar que não tiveram resultados comuns. A [Tabela 5](#), apresenta os valores selecionados da componente MA em cada unidade em todos os cenários e é possível identificar ocorreram variações de hiperparâmetros dentre os cenários analisando as unidades individualmente, com exceção de duas unidades que apresentaram o mesmo valor em todos os cenários. Portanto, pode-se identificar que este hiperparâmetro é influenciado pelo tratamento dos dados e que os valores selecionados estão relacionados aos dados e características da série-temporal.

Excluído: Fi

Excluído: Ta

Figura 17 - Distribuição dos valores MA(q) nos cenários



Fonte: o autor.

Tabela 5 - Componente MA(q) do modelo ARIMA selecionada em cada unidade/cenário

	Cenários															
	C2	C3	C6	C8	C2	C3	C6	C8	C2	C3	C6	C8	C2	C3	C6	C8
<b>U01</b>	6	5	8	6	<b>U19</b>	7	8	2	2	<b>U37</b>	5	4	3	3		
<b>U02</b>	6	8	5	7	<b>U20</b>	7	7	5	8	<b>U38</b>	6	0	4	3		
<b>U03</b>	8	7	8	7	<b>U21</b>	5	7	0	1	<b>U39</b>	4	5	5	3		
<b>U04</b>	8	1	5	1	<b>U22</b>	7	1	5	2	<b>U40</b>	6	6	3	7		
<b>U05</b>	6	7	8	7	<b>U23</b>	8	7	6	7	<b>U41</b>	4	2	6	1		
<b>U06</b>	7	7	3	7	<b>U24</b>	0	0	0	0	<b>U42</b>	6	6	4	1		
<b>U07</b>	7	6	3	1	<b>U25</b>	4	4	5	4	<b>U43</b>	5	5	4	6		
<b>U08</b>	4	4	1	4	<b>U26</b>	1	3	6	2	<b>U44</b>	6	5	1	3		
<b>U09</b>	6	8	5	5	<b>U27</b>	8	8	1	6	<b>U45</b>	0	5	6	8		
<b>U10</b>	8	7	6	6	<b>U28</b>	5	8	2	3	<b>U46</b>	6	7	3	8		
<b>U11</b>	8	6	7	6	<b>U29</b>	8	8	3	7	<b>U47</b>	1	3	5	3		
<b>U12</b>	7	7	8	7	<b>U30</b>	1	0	1	0	<b>U48</b>	5	7	2	3		
<b>U13</b>	4	4	5	3	<b>U31</b>	0	0	0	5	<b>U49</b>	3	1	4	1		
<b>U14</b>	5	7	3	8	<b>U32</b>	2	2	0	0	<b>U50</b>	0	4	5	3		
<b>U15</b>	8	7	6	7	<b>U33</b>	5	5	6	2	<b>U51</b>	3	4	4	3		
<b>U16</b>	3	1	7	3	<b>U34</b>	6	8	5	5	<b>U52</b>	6	3	4	2		
<b>U17</b>	4	3	3	1	<b>U35</b>	7	8	5	3	<b>U53</b>	3	3	3	3		
<b>U18</b>	3	4	7	3	<b>U36</b>	3	0	3	1	<b>U54</b>	8	7	7	8		

Fonte: o autor.

#### 4.2.1.4 SARIMA (S-AR)


O modelo SARIMA decompõe a série entre os valores e as componentes sazonais. Para o índice autorregressivo sazonal, os valores variam entre 0 e 2,

sendo que observando a contagem de autorregressivos sazonais, os cenários não obtiveram correlação, como pode-se observar no gráfico da [Figura 18](#). Outra observação com este fator, é que as unidades apresentaram comportamentos variados, de acordo com o cenário avaliado, como demonstra o gráfico da [Figura 19](#), que mostra o hiperparâmetro em cada unidade em todos os cenários.

Excluído: Fi


Excluído: Fi

Figura 18 - Distribuição dos valores SAR nos cenários



Fonte: o autor.

Figura 19 - Proporções de valores SAR entre os cenários em cada unidades no modelo SARIMA




Fonte: o autor.

Na perspectiva da componente dos valores, ou seja, da base sem os termos sazonais, a [Figura 20](#), mostra a variação dos valores dos termos selecionados

Excluído: Fi


em cada cenário. Observa-se que os Cenários 2, 3 e 8 apresentaram curvas com tendências em comum, como os termos decrescem até atingirem valores mínimos e depois crescem à medida que os termos aumentam.

Figura 20 - Distribuição dos valores AR nos cenários para o modelo SARIMA



Fonte: o autor.

Figura 21 - Proporções de valores AR entre os cenários em cada unidades no modelo SARIMA



Fonte: o autor.


O Cenário 6 apresentou características distintas, devido à descaracterização dos dados. Em complemento, a [Figura 21](#), mostra os valores da componente autorregressiva não-sazonal em cada unidade, o que mostra que as unidades também tiveram variações de acordo com os cenários validados.

#### 4.2.1.5 SARIMA (S-I)

A característica sazonal que marca os conjuntos de dados, torna estes conjuntos habilitados para serem decompostos, tornando as componentes independentes de influências em suas características ocasionado por diferentes componentes. O gráfico da [Figura 22](#) mostra a contagem do total de unidades em cada cenário e os valores selecionados para o hiperparâmetro integrado. Os valores desta componente são os mesmos encontrados no modelo ARIMA, o que reforça que a componente sazonal é linearmente independente.

Excluído: Fi

Figura 22 - Distribuição dos valores I nos cenários para o modelo SARIMA




Fonte: o autor.

A parte sazonal apresentou apenas 1 unidade no Cenário 8 ([Figura 23](#)) com a necessidade de diferenciar os seus dados, os demais mantiveram seus dados originais. Isso decorre pelo fato que as componentes sazonais já possuem uma característica estacionária.

Excluído: Fi

Figura 23 - Distribuição dos valores S-I nos cenários para o modelo SARIMA



Fonte: o autor.


#### 4.2.1.5 SARIMA (S-MA)

O último índice avaliado do modelo SARIMA são os componentes temporais e sazonais das médias móveis. O gráfico da [Figura 25](#), mostra a contagem de unidades que obtiveram cada um dos valores selecionados da componente temporal das médias móveis em cada cenário. O que se pode observar é que os valores variaram não apresentando uma característica em comum aos cenários e também entra as unidades, como mostra a [Figura 24](#), que exhibe os valores desta componente em cada unidade, nos diferentes cenários.

Excluído: Fi


Excluído: Fi

Figura 24 - Proporções de valores MA entre os cenários em cada unidades no modelo SARIMA



Fonte: o autor.

Figura 25 - Distribuição dos valores MA nos cenários para o modelo SARIMA




Fonte: o autor.

Observando a componente sazonal, o gráfico ([Figura 27](#)) mostra que a contagem dos valores também foi heterogênea, mostrando que o tratamento dos conjuntos de dados pode influenciar as componentes sazonais das médias móveis, que também pode ser visto na [Figura 26](#), que exibe as variações dos valores entre as unidades e cenários.

Excluído: Fi


Excluído: Fi

Figura 26 - Proporções de valores S-MA entre os cenários em cada unidades no modelo SARIMA



Fonte: o autor.

Figura 27 - Distribuição dos valores S-MA nos cenários para o modelo SARIMA



Fonte: o autor.

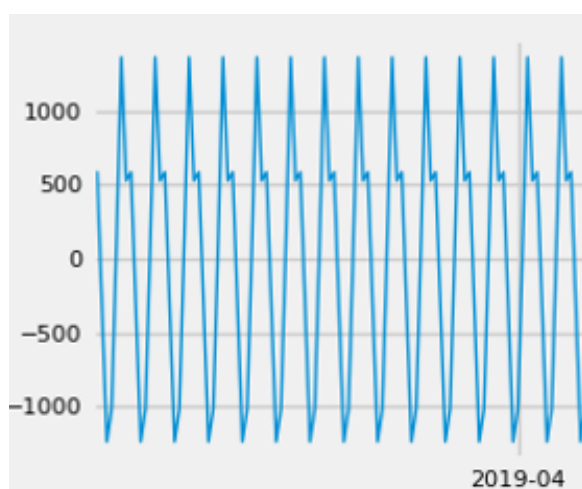


#### 4.2.1.6 SARIMA (Sazonalidade)

Devido às características sazonais que foram encontradas em todas as unidades, com recorrência de 7 dias, ou seja, semanal. Portanto, o índice sazonal do modelo SARIMA utilizado é o 7. O gráfico da [Figura 28](#), mostra a componente sazonal da unidade U05 que mostra que no intervalo de janeiro ao fim de março (3 meses) ocorreram 12 ciclos completos. Este comportamento pode ser identificado em todas as unidades.

Excluído: Fi

Figura 28 - Componente sazonal de um período da unidade U05



Fonte: o autor.

#### 4.2.2 TREINO LSTM

Esta subseção apresenta os resultados obtidos sob a perspectiva dos hiperparâmetros do modelo LSTM obtidos no processamento da base de treino, em seguida utilizados para validação, desdobrando em tópicos cada hiperparâmetro destes modelos.

##### 4.2.2.1 *Batch*

O hiperparâmetro *batch* das redes neurais LSTM se configura em apenas três valores (ou tamanhos): 32, 64 e 128. Os gráficos da [Figura 29](#), exibem as unidades e seus respectivos tamanho de *batch*. Em nenhum dos cenários se constatou um padrão, ou seja, a predominância de um único valor, o que indica

Excluído: Fi

que este hiperparâmetro pode variar de acordo com o conjunto de dados e suas características.

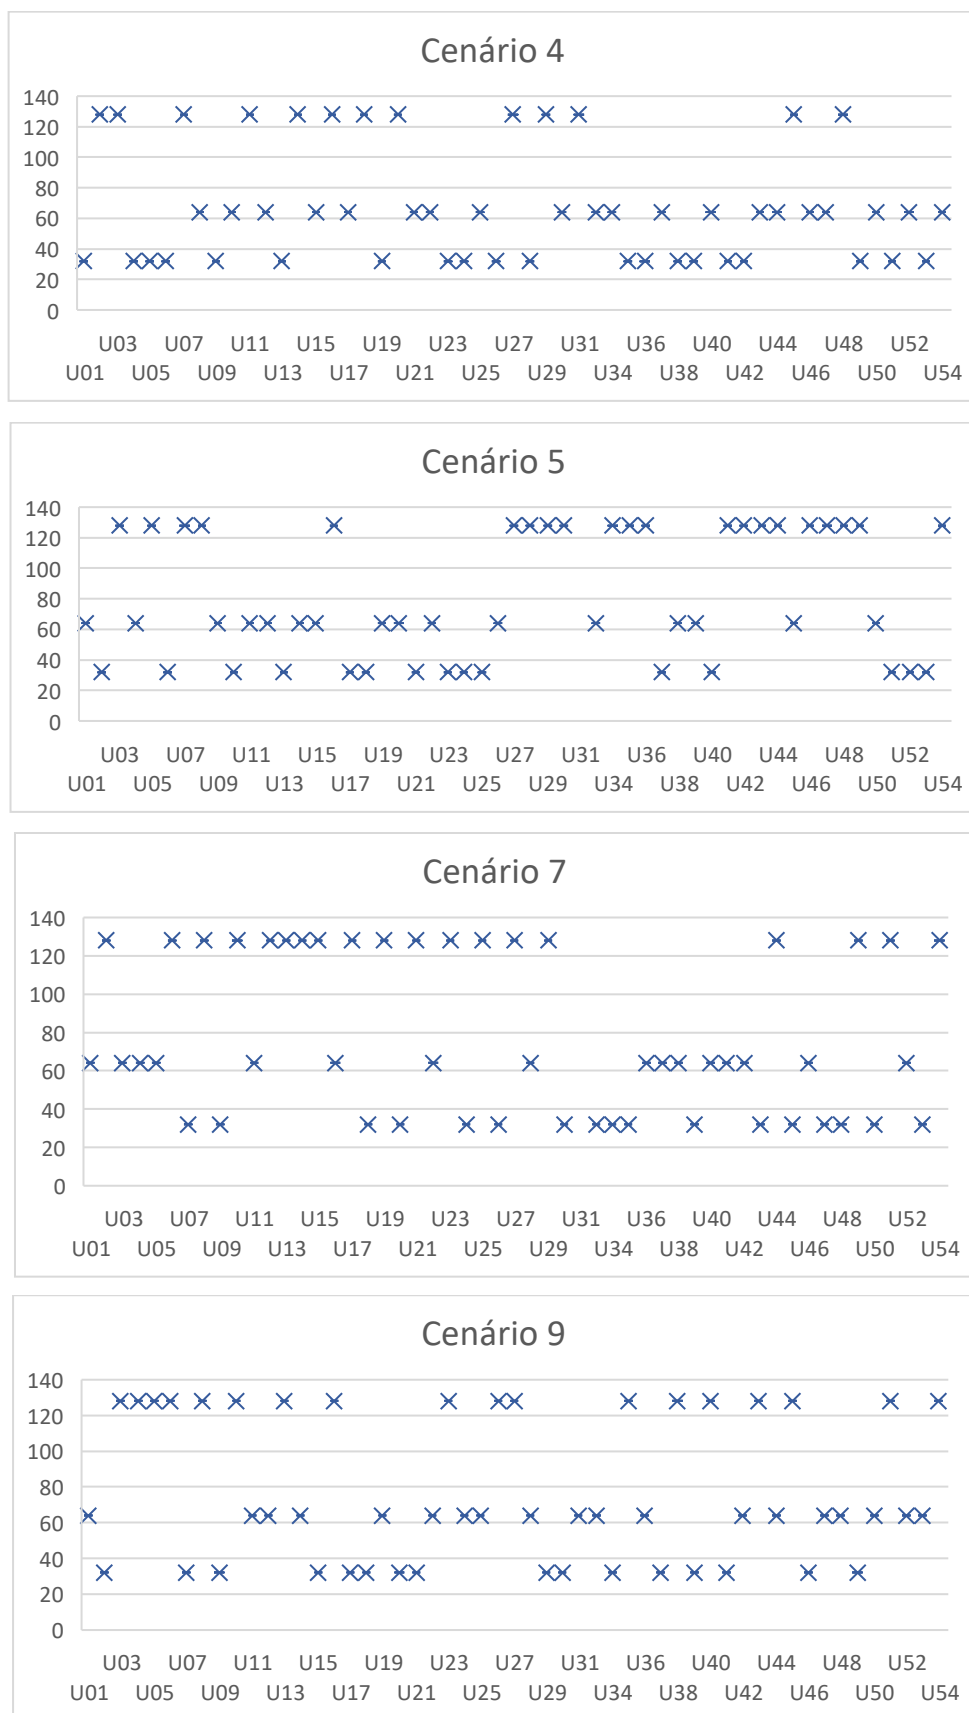
Tabela 6 – Valores *batch* do modelo LSTM selecionados em cada unidade/cenário e contagem por variações

	Cenário				Contagem				Cenário				Contagem		
	C4	C5	C7	C9	32	64	128		C4	C5	C7	C9	32	64	128
<b>U01</b>	32	64	64	64	1	3	0	<b>U28</b>	32	128	64	64	1	2	1
<b>U02</b>	128	32	128	32	2	0	2	<b>U29</b>	128	128	128	32	1	0	3
<b>U03</b>	128	128	64	128	0	1	3	<b>U30</b>	64	128	32	32	2	1	1
<b>U04</b>	32	64	64	128	1	2	1	<b>U31</b>	128			64	0	1	1
<b>U05</b>	32	128	64	128	1	1	2	<b>U33</b>	64	64	32	64	1	3	0
<b>U06</b>	32	32	128	128	2	0	2	<b>U34</b>	64	128	32	32	2	1	1
<b>U07</b>	128	128	32	32	2	0	2	<b>U35</b>	32	128	32	128	2	0	2
<b>U08</b>	64	128	128	128	0	1	3	<b>U36</b>	32	128	64	64	1	2	1
<b>U09</b>	32	64	32	32	3	1	0	<b>U37</b>	64	32	64	32	2	2	0
<b>U10</b>	64	32	128	128	1	1	2	<b>U38</b>	32	64	64	128	1	2	1
<b>U11</b>	128	64	64	64	0	3	1	<b>U39</b>	32	64	32	32	3	1	0
<b>U12</b>	64	64	128	64	0	3	1	<b>U40</b>	64	32	64	128	1	2	1
<b>U13</b>	32	32	128	128	2	0	2	<b>U41</b>	32	128	64	32	2	1	1
<b>U14</b>	128	64	128	64	0	2	2	<b>U42</b>	32	128	64	64	1	2	1
<b>U15</b>	64	64	128	32	1	2	1	<b>U43</b>	64	128	32	128	1	1	2
<b>U16</b>	128	128	64	128	0	1	3	<b>U44</b>	64	128	128	64	0	2	2
<b>U17</b>	64	32	128	32	2	1	1	<b>U45</b>	128	64	32	128	1	1	2
<b>U18</b>	128	32	32	32	3	0	1	<b>U46</b>	64	128	64	32	1	2	1
<b>U19</b>	32	64	128	64	1	2	1	<b>U47</b>	64	128	32	64	1	2	1
<b>U20</b>	128	64	32	32	2	1	1	<b>U48</b>	128	128	32	64	1	1	2
<b>U21</b>	64	32	128	32	2	1	1	<b>U49</b>	32	128	128	32	2	0	2
<b>U22</b>	64	64	64	64	0	4	0	<b>U50</b>	64	64	32	64	1	3	0
<b>U23</b>	32	32	128	128	2	0	2	<b>U51</b>	32	32	128	128	2	0	2
<b>U24</b>	32	32	32	64	3	1	0	<b>U52</b>	64	32	64	64	1	3	0
<b>U25</b>	64	32	128	64	1	2	1	<b>U53</b>	32	32	32	64	3	1	0
<b>U26</b>	32	64	32	128	2	1	1	<b>U54</b>	64	128	128	128	0	1	3
<b>U27</b>	128	128	128	128	0	0	4								


Fonte: o autor.

A [Tabela 6](#), relata que as unidades tiveram variações em torno dos cenários, o que sugere que além das características dos conjuntos de dados, o método de tratamento de *outlier* pode influenciar este hiperparâmetro.

Excluído: Ta

Figura 29 - Valores selecionados de *batch* em cada unidade, por cenário

Fonte: o autor.

Figura 30 - Distribuição valores *batch* nos cenários para o modelo LSTM

Fonte: o autor.

O gráfico da [Figura 30](#), apresenta resumida a contagem da quantidade de unidades por cenário que foram configuradas com cada tamanho de *batch*, que permite identificar a característica dos cenários e o reflexo neste hiperparâmetro. Em todos os cenários, obteve-se um equilíbrio entre as variações, não havendo um preeminente, salvo exceção no Cenário 4, que não teve nenhum tratamento dos dados, obteve uma quantidade menor de *batch* de tamanho 128 comparada aos outros cenários, e no Cenário 9, ocorreu o oposto, prevalecendo o *batch* de 128, onde ocorreu tratamento dos dados. Mesmo havendo algumas discrepâncias, elas são discretas e não é possível determinar um comportamento característico, nem mesmo de que forma os cenários e os diferentes conjuntos de dados podem influenciar no hiperparâmetro *batch*.


Excluído: Fi

#### 4.2.2.2 Epoch


O hiperparâmetro da rede neural LSTM, *Epoch*, referencia-se à quantidade de vezes que o conjunto de dados é validado, variando, neste caso, em 25, 100 e 200. Os gráficos da [Figura 31](#), exibem a distribuição dos valores associados ao hiperparâmetro escolhido para cada unidade, em cada cenário, o que indica que existem variações entre os cenários e também a não predominância de um determinado valor.

Excluído: Fi

Figura 31 - Valores selecionados de *epoch* em cada unidade, por cenário



Fonte: o autor.

Figura 32 - Distribuição valores *epoch* nos cenários para o modelo LSTM

Fonte: o autor.

A [Tabela 7](#), mostra os valores separados por unidade e os respectivos cenários, com a sumarização dos valores do *epoch* por unidade. É possível identificar que o comportamento obteve variações com relação ao tratamento do conjunto de dados, ou seja, o tratamento de *outliers*, sugerindo que a configuração pode influenciar na determinação do *epoch*. Em complemento, a [Figura 32](#), mostra a distribuição da contagem de *epochs* por cenários, entre as unidades. Em todos eles, os *epoch* 25 e 100 foram predominantes, ao contrário do *epoch* 200 que não se destacou em nenhum cenário em relação aos demais valores. Esta informação leva a entender que o *epoch* não teve influência direta com relação às variações de cenários.

Excluído: Ta

Excluído: Fi

Tabela 7 - Valores *epoch* do modelo LSTM selecionados em cada unidade/cenário e contagem por variações

	Cenário				Contagem				Cenário				Contagem		
	C4	C5	C7	C9	25	100	200		C4	C5	C7	C9	25	100	200
<b>U01</b>	25	25	25	200	3	0	1	<b>U28</b>	25	100	100	100	1	3	0
<b>U02</b>	25	25	25	25	4	0	0	<b>U29</b>	100	100	25	25	2	2	0
<b>U03</b>	200	200	25	100	1	1	2	<b>U30</b>	25	200	200	200	1	0	3
<b>U04</b>	100	200	200	100	0	2	2	<b>U31</b>	200			200	0	0	2
<b>U05</b>	25	100	25	25	3	1	0	<b>U33</b>	200	25	100	25	2	1	1
<b>U06</b>	25	25	100	100	2	2	0	<b>U34</b>	25	25	100	100	2	2	0
<b>U07</b>	200	200	25	25	2	0	2	<b>U35</b>	25	100	25	25	3	1	0
<b>U08</b>	25	100	200	100	1	2	1	<b>U36</b>	200	100	100	100	0	3	1
<b>U09</b>	25	25	200	25	3	0	1	<b>U37</b>	25	25	25	25	4	0	0
<b>U10</b>	25	25	100	200	2	1	1	<b>U38</b>	100	100	100	200	0	3	1
<b>U11</b>	100	200	100	100	0	3	1	<b>U39</b>	25	25	100	100	2	2	0
<b>U12</b>	100	100	100	100	0	4	0	<b>U40</b>	100	25	25	100	2	2	0
<b>U13</b>	100	25	100	100	1	3	0	<b>U41</b>	25	100	200	25	2	1	1
<b>U14</b>	25	25	100	100	2	2	0	<b>U42</b>	100	100	200	200	0	2	2
<b>U15</b>	25	100	200	25	2	1	1	<b>U43</b>	25	100	25	200	2	1	1
<b>U16</b>	100	100	100	200	0	3	1	<b>U44</b>	200	100	25	200	1	1	2
<b>U17</b>	100	25	100	25	2	2	0	<b>U45</b>	100	100	25	100	1	3	0
<b>U18</b>	25	25	25	25	4	0	0	<b>U46</b>	25	200	100	100	1	2	1
<b>U19</b>	100	200	200	200	0	1	3	<b>U47</b>	200	100	25	100	1	2	1
<b>U20</b>	100	25	25	25	3	1	0	<b>U48</b>	100	100	25	100	1	3	0
<b>U21</b>	25	200	25	100	2	1	1	<b>U49</b>	25	25	200	100	2	1	1
<b>U22</b>	100	100	100	200	0	3	1	<b>U50</b>	100	25	100	25	2	2	0
<b>U23</b>	100	100	200	200	0	2	2	<b>U51</b>	25	25	25	100	3	1	0
<b>U24</b>	200	200	100	100	0	2	2	<b>U52</b>	25	25	25	25	4	0	0
<b>U25</b>	200	25	100	25	2	1	1	<b>U53</b>	100	100	25	200	1	2	1
<b>U26</b>	100	25	100	25	2	2	0	<b>U54</b>	25	100	25	100	2	2	0
<b>U27</b>	100	100	100	200	0	3	1								

Fonte: o autor.


Os gráficos de curva de perda com a variação dos *epochs* até o valor selecionado são plotados em cada unidade e cada cenário. Alguns valores apresentados na [Tabela 7](#), podem ser identificados ou confirmados nestes gráficos. Alguns exemplos podem ser visualizados nos gráficos da [Figura 33](#): U37/Cenário 4 – *Epoch* 25; U03/Cenário 5 – *Epoch* 200; U51/Cenário 7 – *Epoch* 25 e U43/Cenário 9 – *Epoch* 200.

Excluído: Ta


Excluído: Fi

Figura 33 - Gráficos curva de aprendizado variando o *epoch* na (a) unidade U37/Cenário 4; (b) unidade U03/Cenário 5; (c) unidade U51/Cenário 7; (d) unidade U43/Cenário 9

(a)




(b)






(c)



(d)



Fonte: o autor.


#### 4.2.2.3 Lag Size


O *Lag size* é um hiperparâmetro que pode ser configurado de maneira analítica, ao contrário dos demais hiperparâmetros de uma rede neural LSTM, pois este correlaciona como os dados se comportam, relacionam e o tamanho do vetor que é inserido para processamento em uma rede neural profunda. Os conjuntos de dados possuem informações com frequência diária, e as características dos dados pode ser extraída através das decomposições da série-temporal em

quatro componentes: frequência, valores, tendência e resíduos, exemplificada na [Figura 8](#). As unidades em sua totalidade apresentaram as componentes sazonais com uma frequência semanal, o que faz sentido quando observa-se o contexto de negócio que envolve uma operação de uma unidade de consolidação e desconsolidação de um transportadora, em que as atividades possuem uma certa rotina, mesmo que ocorram variações. Este fato, descreve o motivo pela qual foram utilizadas as variações 7 e 14 neste hiperparâmetro, em que 7 indica que os últimos 7 valores terão uma influência diferenciada em relação aos demais dados anteriores. Por outro lado, o valor 14 verificaria se um período de 2 semanas teria um destaque com relação à apenas o período semanal.

Excluído: Fi

Figura 34 - Valores selecionados de *lag size* em cada unidade, por cenário





Fonte: o autor.

Os gráficos da [Figura 34](#), descrevem os cenários validados, relacionando o hiperparâmetro *lag size* escolhido. Em todos os cenários os *lag size* de valor 7 foram predominantes, o que era um resultado esperado, confirmando que as análises de decomposições são válidas para este processo, confirmado pela [Figura 35](#), que sumariza os cenários e as contagens de hiperparâmetros dentre as unidades.

Excluído: Fi

Excluído: Fi

Tabela 8 - Valores *lag size* do modelo LSTM selecionados em cada unidade/cenário

	Cenários															
	C4	C5	C7	C9	C4	C5	C7	C9	C4	C5	C7	C9	C4	C5	C7	C9
<b>U01</b>	7	7	14	7	<b>U19</b>	7	7	7	7	<b>U38</b>	7	7	7	7		
<b>U02</b>	7	7	7	7	<b>U20</b>	7	7	7	7	<b>U39</b>	14	14	14	7		
<b>U03</b>	7	7	7	7	<b>U21</b>	14	7	7	7	<b>U40</b>	7	7	7	7		
<b>U04</b>	7	7	7	7	<b>U22</b>	7	7	7	7	<b>U41</b>	7	7	7	14		
<b>U05</b>	7	7	7	7	<b>U23</b>	7	7	7	7	<b>U42</b>	7	7	7	7		
<b>U06</b>	7	7	7	7	<b>U24</b>	7	7	14	7	<b>U43</b>	7	7	7	7		
<b>U07</b>	7	7	7	7	<b>U25</b>	7	7	7	7	<b>U44</b>	7	7	14	7		
<b>U08</b>	7	7	7	7	<b>U26</b>	7	7	7	7	<b>U45</b>	7	7	7	7		
<b>U09</b>	7	7	7	7	<b>U27</b>	14	14	7	7	<b>U46</b>	7	7	7	7		
<b>U10</b>	7	7	7	7	<b>U28</b>	7	7	7	7	<b>U47</b>	7	7	7	7		
<b>U11</b>	7	7	7	7	<b>U29</b>	7	7	7	7	<b>U48</b>	7	7	7	7		
<b>U12</b>	7	7	7	7	<b>U30</b>	7	7	7	7	<b>U49</b>	14	14	7	14		
<b>U13</b>	7	7	7	7	<b>U31</b>	14			14	<b>U50</b>	7	7	7	7		
<b>U14</b>	7	7	7	7	<b>U33</b>	7	7	7	7	<b>U51</b>	7	7	7	7		
<b>U15</b>	7	7	7	7	<b>U34</b>	7	7	7	7	<b>U52</b>	7	7	7	7		
<b>U16</b>	7	7	7	14	<b>U35</b>	7	7	7	7	<b>U53</b>	7	7	7	7		
<b>U17</b>	7	7	7	7	<b>U36</b>	7	7	7	7	<b>U54</b>	7	7	7	7		
<b>U18</b>	7	7	7	7	<b>U37</b>	7	7	7	7							

Fonte: o autor.


A [Tabela 8](#), mostra a classificação do *lag size* em cada cenário em cada unidade.

Excluído: Ta

Em destaque, observa-se que apenas 2 unidades obtiveram a superação dos cenários com o tamanho do *lag size* 14, mesmo tendo características marcantes semanais em suas decomposições (Figura 8), o que não invalida as características em 2 ciclos.

Excluído: Fig

Figura 35 - Distribuição valores *lag size* nos cenários para o modelo LSTM



Fonte: o autor.

Outra inferência sobre a análise do *lag size*, é que os cenários apresentaram comportamentos semelhantes, ou seja, o método de tratamento de dados não foi um fator decisivo na determinação deste hiperparâmetro.

#### 4.2.2.4 Hidden Layers

O hiperparâmetro *hidden layer* determina a quantidade de camadas intermediárias de neurônios de uma rede neural profunda. A classificação da lista de valores deste hiperparâmetro é determinada de maneira que a arquitetura da rede neural atenda os critérios e objetivos aplicados à rede neural.

Tabela 9 - Valores *hidden layers* do modelo LSTM selecionados em cada unidade/cenário

	Cenários													
	C4	C5	C7	C9	C4	C5	C7	C9	C4	C5	C7	C9		
<b>U01</b>	1	1	1	2	<b>U19</b>	1	2	1	2	<b>U38</b>	1	1	2	1
<b>U02</b>	2	1	1	2	<b>U20</b>	1	1	1	1	<b>U39</b>	1	1	1	1
<b>U03</b>	1	1	2	1	<b>U21</b>	2	1	2	2	<b>U40</b>	1	1	1	1
<b>U04</b>	2	1	2	2	<b>U22</b>	2	2	2	2	<b>U41</b>	2	2	2	2
<b>U05</b>	1	1	1	2	<b>U23</b>	2	1	1	1	<b>U42</b>	1	1	1	1
<b>U06</b>	1	1	1	1	<b>U24</b>	2	1	2	2	<b>U43</b>	1	1	1	1
<b>U07</b>	1	1	2	1	<b>U25</b>	1	1	1	1	<b>U44</b>	2	1	2	1
<b>U08</b>	1	1	2	1	<b>U26</b>	2	2	2	2	<b>U45</b>	1	1	1	1
<b>U09</b>	1	1	1	2	<b>U27</b>	1	1	1	1	<b>U46</b>	1	1	1	1
<b>U10</b>	1	1	1	1	<b>U28</b>	1	1	2	2	<b>U47</b>	1	1	2	1
<b>U11</b>	1	1	1	1	<b>U29</b>	2	1	1	1	<b>U48</b>	1	2	1	1
<b>U12</b>	1	2	1	1	<b>U30</b>	2	1	2	2	<b>U49</b>	1	1	1	1
<b>U13</b>	1	2	2	1	<b>U31</b>	2			2	<b>U50</b>	1	2	1	2
<b>U14</b>	2	1	1	1	<b>U33</b>	1	1	1	1	<b>U51</b>	1	1	1	1
<b>U15</b>	2	1	1	1	<b>U34</b>	1	2	1	1	<b>U52</b>	1	1	1	1
<b>U16</b>	1	1	2	1	<b>U35</b>	2	1	1	2	<b>U53</b>	2	1	1	2
<b>U17</b>	1	1	1	1	<b>U36</b>	1	1	1	1	<b>U54</b>	2	2	1	1
<b>U18</b>	2	1	1	1	<b>U37</b>	1	1	1	1					


Fonte: o autor.

Os valores aplicados variam apenas entre 1 e 2, e podem ser vistos na [Tabela 9](#), que contém a quantidade de camadas ocultas por cada unidade nos diferentes cenários. Em complemento a esta tabela, os gráficos da [Figura 36](#), mostram os hiperparâmetros *hidden layers* selecionados em cada cenário, em cada unidade. É possível constatar que em cada cenário ambos os valores foram selecionados, porém com destaque para a camada única que superou as arquiteturas em duas camadas ocultas em todos os cenários, como pode ser visto na [Figura 37](#), que agrupa a contagem das unidades que possuem as opções de valores no hiperparâmetro em questão, em perspectivas dos cenários. Este gráfico também contribui para descrever que os Cenários 4, 7 e 9 apresentaram-se equivalentes, enquanto o Cenário 5 superou os demais em termos de camadas únicas. Apesar disso, os resultados descrevem que os diferentes cenários, que envolvem as tratativas exploratória de dados, não influenciaram a arquitetura de camadas da rede neural.


Excluído: Ta

Excluído: Fi

Excluído: Fi

Figura 36 - Valores selecionados *hidden layers* em cada unidade, por cenário

Fonte: o autor.

Figura 37 - Distribuição valores *hidden layers* nos cenários para o modelo LSTM


Fonte: o autor.


Outra análise que pode ser extraída destes resultados é que observando cada uma das unidades, mediante os cenários validados, 10 obtiveram a quantidade dos diferentes hiperparâmetros com 1 camada equivalente a quantidade de cenários com 2 camadas [Tabela 9](#). Isso sugere que acima de 80% das unidades tiveram uma polarização das camadas ocultas em um determinado valor, e que isto pode indicar que a variação deste hiperparâmetro está vinculado ao conjunto de dados e suas características do que a forma que os *outliers* são tratados.

Excluído: Ta

#### 4.2.2.5 Neurons


Este hiperparâmetro é um dos que determinam a arquitetura da rede neural profunda, ele define a quantidade de neurônios em cada camada da rede.

Figura 38 - Valores selecionados *neurons* em cada unidade, por cenário



Fonte: o autor.

Figura 39 - Distribuição valores *neurons* nos cenários para o modelo LSTM



Fonte: o autor.



Os gráficos da [Figura 38](#), relatam os cenários validados e os valores do hiperparâmetro selecionado. Os cenários obtiveram características distintas, sendo possível identificar polarizações de valores nos cenários, como por exemplo no Cenário 7. Em complemento a esta inferência, a [Figura 39](#), descreve a composição de cada cenário e suas respectivas contagens de cada hiperparâmetro. Os Cenários 4, 5 e 9 concentraram a seleção de 1024 neurônios na arquitetura. Estes três cenários possuem um conjunto de dados maior do que o Cenário 7, que removeu do conjunto de dados os *outliers*, o que pode indicar que a quantidade de neurônios pode variar de acordo com o tamanho do conjunto de dados. Por outro lado, as arquiteturas com 16 e 32 neurônios também tiveram representatividade nestes cenários, o que reforça que o tamanho do conjunto de dados polariza a quantidade de neurônios a extremos. Outro fato observado é que a arquitetura com 64 neurônios obteve a menor representatividade em todos cenários.

Tabela 10 - Valores *neurons* do modelo LSTM selecionados em cada unidade/cenário

	Cenários												
	C4	C5	C7	C9	C4	C5	C7	C9	C4	C5	C7	C9	
<b>U01</b>	1024	1024	64	16	<b>U19</b>	16	16	64	16	<b>U38</b>	32	32	16
<b>U02</b>	1024	1024	256	256	<b>U20</b>	16	1024	32	128	<b>U39</b>	128	1024	16
<b>U03</b>	16	32	1024	256	<b>U21</b>	1024	256	32	128	<b>U40</b>	32	1024	16
<b>U04</b>	32	16	16	256	<b>U22</b>	32	32	32	16	<b>U41</b>	1024	128	16
<b>U05</b>	1024	1024	16	1024	<b>U23</b>	16	16	32	32	<b>U42</b>	32	256	32
<b>U06</b>	1024	1024	16	256	<b>U24</b>	1024	128	16	32	<b>U43</b>	1024	64	16
<b>U07</b>	32	32	256	1024	<b>U25</b>	16	256	32	1024	<b>U44</b>	16	128	1024
<b>U08</b>	32	128	16	128	<b>U26</b>	16	256	16	1024	<b>U45</b>	1024	128	32
<b>U09</b>	256	1024	16	256	<b>U27</b>	256	128	32	128	<b>U46</b>	1024	16	32
<b>U10</b>	1024	1024	32	32	<b>U28</b>	256	128	16	64	<b>U47</b>	16	128	256
<b>U11</b>	256	16	32	128	<b>U29</b>	32	256	256	1024	<b>U48</b>	256	128	32
<b>U12</b>	64	64	32	64	<b>U30</b>	1024	64	32	32	<b>U49</b>	128	1024	16
<b>U13</b>	16	256	256	1024	<b>U31</b>	256			1024	<b>U50</b>	128	1024	16
<b>U14</b>	1024	1024	16	64	<b>U33</b>	16	1024	32	1024	<b>U51</b>	1024	256	256
<b>U15</b>	256	64	32	1024	<b>U34</b>	1024	1024	32	16	<b>U52</b>	1024	256	1024
<b>U16</b>	64	64	16	32	<b>U35</b>	256	128	16	1024	<b>U53</b>	32	32	128
<b>U17</b>	256	1024	16	1024	<b>U36</b>	16	1024	16	128	<b>U54</b>	1024	128	256
<b>U18</b>	1024	1024	128	1024	<b>U37</b>	1024	1024	256	256				

Fonte: o autor.

Observando os dados na [Tabela 10](#), é possível identificar que a característica

dos resultados nos cenários avaliados, foi de variações de neurônios e não um único absoluto, característica que mostra que a relação entre tratamento do conjunto de dados pode configurar arquiteturas de neurônios na rede neural.

### 4.3. ANÁLISE DOS MODELOS NO CONJUNTO DE VALIDAÇÃO

Esta subseção apresenta os resultados dos modelos ARIMA/SARIMA e LSTM, utilizando os hiperparâmetros encontrados no conjunto de dados de treinamento e aplicados no conjunto de dados de teste/validação.

As métricas obtidas na validação (testes) dos conjuntos de dados para avaliar e comparar os modelos e cenários pela métrica MAE ([Tabela 11](#)) e MSE. Ambas obtidas em todos os cenários, em todas unidades. Apesar de serem calculadas em relação aos erros obtidos, pode-se obter informações distintas de cada uma delas, dependendo da característica dos conjuntos de dados e também podem servir para efeito comparativo de uma com a outra, não em termos absolutos, mas como se distribuíram os erros em cada validação feito por elas. Apesar de as unidades possuírem propriedades que caracterizam séries não-estacionárias, predominando *outliers*, que pode penalizar o MSE, mesmo assim, ambas métricas se distribuíram e concentraram de maneira semelhante. Sabendo-se que os conjuntos de dados foram normalizados, entre 0 e 1, a análise da métrica MAE é possível identificar o quanto próximo ou distante do valor 0 (métrica ideal) os resultados atingiram.

Excluído: Ta

Tabela 11 - Métricas dos testes MAE de todas unidades e cenários

	MAE							
	C2	C3	C4	C5	C6	C7	C8	C9
U01	0.098	0.293	<b>0.031</b>	0.082	0.262	0.216	0.204	0.093
U02	0.139	0.160	0.072	<b>0.060</b>	0.153	0.132	0.181	0.072
U03	0.121	0.121	0.055	<b>0.037</b>	0.184	0.136	0.128	0.047
U04	0.122	0.123	0.139	0.112	0.126	0.123	0.123	<b>0.104</b>
U05	0.243	0.178	0.067	<b>0.055</b>	0.224	0.201	0.183	0.097
U06	0.186	0.174	0.046	0.049	0.175	0.161	0.255	<b>0.032</b>
U07	0.176	0.199	0.126	<b>0.102</b>	0.239	0.140	0.228	0.194
U08	0.177	0.205	<b>0.066</b>	0.081	0.220	0.158	0.142	0.070
U09	0.204	0.169	<b>0.076</b>	0.085	0.281	0.181	0.208	0.121
U10	0.205	0.186	0.091	<b>0.081</b>	0.217	0.185	0.224	0.112
U11	0.092	0.108	0.046	<b>0.042</b>	0.195	0.116	0.115	0.058
U12	0.200	0.127	0.067	<b>0.047</b>	0.123	0.111	0.158	0.097
U13	0.101	0.103	0.051	<b>0.048</b>	0.112	0.077	0.103	0.056
U14	0.195	0.201	0.115	<b>0.072</b>	0.238	0.163	0.188	0.127
U15	0.101	0.148	<b>0.045</b>	0.049	0.190	0.157	0.157	0.092
U16	0.152	0.152	0.107	<b>0.100</b>	0.147	0.127	0.172	0.127
U17	0.034	0.156	<b>0.020</b>	0.077	0.183	0.120	0.153	0.121
U18	0.256	0.207	<b>0.052</b>	0.066	0.220	0.075	0.172	0.097
U19	0.199	0.205	<b>0.105</b>	0.113	0.280	0.149	0.221	0.134
U20	0.117	0.130	0.077	<b>0.073</b>	0.220	0.149	0.169	0.103
U21	0.025	0.028	<b>0.016</b>	0.037	0.027	0.029	0.026	0.027
U22	0.115	0.139	<b>0.092</b>	0.111	0.134	0.111	0.136	0.132
U23	0.274	0.190	0.064	<b>0.055</b>	0.191	0.147	0.164	0.077
U24	0.136	0.126	<b>0.107</b>	0.125	0.128	0.154	0.121	0.123
U25	0.052	0.111	<b>0.042</b>	0.056	0.357	0.134	0.175	0.063
U26	0.157	0.168	0.110	0.116	0.175	<b>0.098</b>	0.172	0.152
U27	0.195	0.207	0.221	0.238	0.337	0.159	0.183	<b>0.158</b>
U28	0.128	0.130	0.093	<b>0.077</b>	0.136	0.128	0.132	0.108
U29	0.093	0.166	<b>0.039</b>	0.080	0.194	0.153	0.156	0.093
U30	<b>0.070</b>	0.178	0.092	0.154	0.182	0.279	0.129	0.085
U31	0.012		<b>0.010</b>				0.038	0.034
U32	0.143	0.143			0.167		<b>0.017</b>	
U33	0.271	0.280	0.128	<b>0.093</b>	0.349	0.129	0.226	0.108
U34	0.148	0.153	0.091	<b>0.081</b>	0.175	0.116	0.175	0.111
U35	0.066	0.182	<b>0.034</b>	0.097	0.287	0.238	0.212	0.114
U36	0.108	0.181	<b>0.064</b>	0.126	0.200	0.176	0.217	0.152
U37	0.084	0.138	<b>0.043</b>	0.076	0.233	0.145	0.199	0.068
U38	0.118	0.167	<b>0.082</b>	0.140	0.167	0.158	0.155	0.148
U39	0.109	0.111	0.070	<b>0.067</b>	0.151	0.133	0.140	0.108
U40	0.083	0.139	<b>0.048</b>	0.059	0.203	0.188	0.324	0.094
U41	<b>0.096</b>	0.141	0.104	0.161	0.156	0.206	0.160	0.134
U42	0.142	0.158	0.101	<b>0.085</b>	0.161	0.188	0.161	0.114
U43	0.283	0.363	<b>0.051</b>	0.067	0.450	0.219	0.135	0.066

<b>U44</b>	0.043	0.067	<b>0.039</b>	0.076	0.076	0.074	0.078	0.067
<b>U45</b>	0.158	0.164	0.095	<b>0.064</b>	0.222	0.177	0.165	0.079
<b>U46</b>	0.117	0.142	<b>0.043</b>	0.088	0.303	0.138	0.155	0.111
<b>U47</b>	0.134	0.133	0.091	<b>0.065</b>	0.168	0.130	0.153	0.095
<b>U48</b>	0.166	0.229	<b>0.121</b>	0.129	0.377	0.208	0.210	0.129
<b>U49</b>	0.086	0.176	<b>0.064</b>	0.133	0.181	0.168	0.178	0.137
<b>U50</b>	0.148	0.144	0.111	0.115	0.148	0.140	0.142	<b>0.109</b>
<b>U51</b>	0.109	0.142	<b>0.105</b>	0.114	0.222	0.198	0.217	0.127
<b>U52</b>	0.109	0.216	<b>0.102</b>	0.140	0.304	0.184	0.217	0.148
<b>U53</b>	0.053	0.153	<b>0.035</b>	0.108	0.162	0.152	0.152	0.145
<b>U54</b>	0.119	0.099	0.051	<b>0.037</b>	0.294	0.124	0.086	0.048
<b>DP</b>	0.062	0.053	0.037	0.038	0.077	0.044	0.054	0.035
<b>Méd.</b>	0.135	0.162	0.076	0.088	0.208	0.151	0.163	0.102


Fonte: o autor.

Iniciando a análise dos cenários que envolvem os modelos ARIMA/SARIMA, com exceção do Cenário 1, que já possui um tópico individual, o Cenário 2, que aplicou os modelos ARIMA/SARIMA sem nenhum tratamento de dados, apresentou uma média MAE de 0.13 (menor média entre os cenários dos modelos ARIMA/SARIMA) e um desvio padrão 0.06 (2º maior desvio padrão entre todos os cenários). Este resultado mostra que entre os cenários dos modelos da família ARIMA, os erros foram em média menores, porém com variações que indicam que a ausência de tratamento de dados pode reduzir erros em determinados cenários ou penalizar os resultados. Este cenário também obteve acima de 63% das unidades com as menores métricas entre os Cenários 2, 3, 6 e 8, indicando que prevaleceu em resultados com menores erros. Já o Cenário 3, que também aplica os modelos ARIMA/SARIMA com tratamento de *outliers*, a média da métrica MAE é de 0,16, com desvio padrão 0,05, destacando 11% das unidades pelo modelo SARIMA e 26% do modelo ARIMA. O Cenário 6, que é caracterizado pela eliminação de *outliers*, as métricas foram penalizadas, apresentando a maior média de erros e o maior desvio padrão entre todos os cenários. O mesmo ocorreu para o Cenário 7 que implementa o mesmo tratamento de dados, porém através de redes neurais profundas LSTM, resultando nos maiores índices de erros entre os cenários que implementam LSTM. Isto indica que a remoção dos pontos fora da curva prejudica as previsões e não se mostrou como um método aderente. Finalizando a última análise dos cenários de modelos ARIMA/SARIMA, o Cenário 8, assim como o 3, utiliza-se

tratamento de dados, porém sofisticados, como a detecção de anomalias antes de realizar o tratamento de dados. As métricas deste cenário se aproximam das métricas do Cenário 3 que também obteve tratamento de dados, resultando numa média de erros MAE de 0,16 e desvio padrão de 0,05.

Avaliando o desempenho entre os modelos ARIMA e SARIMA ao longo dos cenários, verifica-se que entre os cenários ambos foram implementados e obtiveram proporções de 50% entre os dois modelos com menores erros, ou seja, nos Cenários 2, 3, 6 e 7, os modelos intercalaram entre os modelos com os índices de erros menores entre os cenários e unidades.

Figura 40 - Acúmulo de unidades com os menores erros em cada cenário



Fonte: o autor.

Observando as métricas de todos os cenários em todos os modelos implementados na pesquisa, os modelos LSTM se destacam, como pode ser visto na [Figura 40](#), em que os Cenários 4 e 5 representam 85% das métricas entre as unidades com os menores erros, comparando todos os cenários, enquanto os cenários que representam os modelos ARIMA/SARIMA somaram 6% do total, juntas. Além disso, o tratamento de dados não contribuiu como esperado para redução dos erros, sendo que o Cenário 4 e 2 representaram os cenários com os menores erros nos modelos ARIMA/SARIMA e LSTM, respectivamente. Os métodos de detecção de anomalias também não mostraram favoráveis a reduções de erros, resultando em métricas que indicam erros maiores que o tratamento de *outliers* convencional.

Apesar que os Cenários 4 e 5 destacaram-se no quesito métricas, cada cenário obteve seus destaques em alguma(s) unidade(s), como pode ser visto nos gráficos da [Figura 41](#),

Excluído: Fig

Excluído: Fig

Figura 41 - Previsão x Real, Cenários 2, 3(U54), 4, 5, 7, 8, 9



Fonte: o autor.


As métricas dos resultados de validação da rede neural LSTM também podem descrever e associar as características de cada cenário, assim como os hiperparâmetro correlacionados. A [Tabela 11](#), apresenta as métricas MAE em

Excluído: Ta

todos os cenários para cada unidade. Os resultados em negrito representam o cenário que obteve a menor métrica, ou seja, que as previsões alcançaram a precisão próxima no valor real. Os gráficos da [Figura 42](#), resumem as métricas com a contagem dos cenários que obtiveram as menores métricas nas unidades. Pode-se observar que os Cenários 7 e 9 tiveram uma representatividade inferior a 12% do total de unidades avaliadas, o que indica que a remoção de *outliers* do conjunto de dados não contribuiu na evolução da assertividade das previsões. Além disso, o tratamento de *outliers* através de métodos sofisticados como a detecção de anomalias também não apresentou redução nos erros. Por outro lado, os Cenários 4 e 5 obtiveram acima de 88% das métricas destacadas, sugerindo que a manipulação dos dados pode ser vantajosa em determinados conjuntos de dados, enquanto para outros o tratamento de *outliers* pode impactar na característica e na forma que a rede neural irá interpretar os dados e os resultados.

Excluído: Fig

Figura 42 - Acúmulo de unidades com os menores erros em cada cenário LSTM



Fonte: o autor.

Os valores do hiperparâmetro *batch*: 32, 64 e 128 obtiveram proporções equivalentes em termos de cenários/unidades com as métricas destacadas, obtendo 32%, 38% e 30%, respectivamente. Este resultado leva a interpretar que este hiperparâmetro não possui um valor predominante e que pode variar de acordo com o conjunto de dados, podendo em cada caso, ser utilizado em diferentes valores para que se obtenha métricas refinadas.

Os valores do hiperparâmetro *epoch* 25, 100 e 200 representaram 43%, 38% e 19%, respectivamente, o total de unidades nos cenários que representam os menores erros, o que sugere que o aumento deste hiperparâmetro reduz a

chance que este aumento contribua para a redução do erro em previsões.

O *Lag size*, que obteve destaque para o valor 7 (devido à característica semanal de sazonalidade dos conjuntos), representou 92% dos casos de unidades com destaque nas métricas nos cenários, enquanto o restante (8%) foi atribuído ao outro valor 14. Apesar deste hiperparâmetro concentrar os casos em um valor, pode-se afirmar que o mesmo contribui com as métricas de acordo com a característica de sazonalidade da série temporal, caso exista.

A quantidade de camadas da arquitetura da rede neural se divide em 2 valores (1 e 2), representando 64% do total de unidades nos cenários que obtiveram as métricas destacadas com apenas 1 camada e o restante com 2. Portanto, a densidade da arquitetura, não proporciona refinamento dos resultados.

A [Tabela 12](#) apresenta a quantidade de unidades em cenários que obtiveram as métricas com menor erro para o hiperparâmetro *Neuron*, e pode-se observar que os extremos (menores e maiores valores) concentraram 85% dos casos avaliados. Esta informação pode levar ao entendimento que a quantidade de neurônios de uma rede neural artificial LSTM polariza a extremos os valores que podem apresentar resultados atrativos.

Excluído: Ta

Tabela 12 - Relação entre quantidade de neurônios, cenários e total de unidades selecionadas com o hiperparâmetro

	C4	C5	C7	C9	Total
<b>16</b>	4	2	1	0	7
<b>32</b>	6	2	0	1	9
<b>64</b>	0	2	0	0	2
<b>128</b>	1	4	0	1	6
<b>256</b>	6	2	0	2	10
<b>1024</b>	10	8	0	1	19

Fonte: o autor.

#### 4.4. IMPACTO DE VARIÁVEIS EXÓGENAS

A [Tabela 13](#) contém as métricas MSE/MAE obtidas das validações dos modelos e os conjuntos de hiperparâmetros selecionados, utilizando-se as categorias como variáveis adicionais para o modelo. Ao contrário dos Cenários 2 a 9, que não consideraram variáveis exógenas, o Cenário 1 obteve destaque para os modelos ARIMAX e SARIMAX, em que ambas as métricas avaliadas apontaram

Excluído: Ta



para mais de 93% dos casos com os menores índices de erros. Estes resultados podem ser avaliados sob duas hipóteses: (i) variáveis exógenas contribuíram para redução de erros em modelos ARIMAX/SARIMAX; (ii) variáveis exógenas prejudicaram o modelo LSTM. Para verificar qual das hipóteses justifica os resultados, verifica-se a [Tabela 14](#), que contém as métricas de erros (MSE e MAE) da unidade U45 nos Cenários (2 a 9). O menor valor de MAE, por exemplo, referencia-se no Cenário 5, enquanto o maior valor no Cenário 6, variando ambos de 0.06 a 0.22, aproximadamente, e com uma média entre as métricas em todos os cenários de 0.16 que aplicam os modelos ARIMAX/SARIMAX e 0.12 dos cenários que aplicam o modelo LSTM. Utilizando-se as métricas descritas na [Tabela 13](#), encontra-se a média dos valores MAE de ARIMAX e SARIMAX em 0.18, aproximadamente, e 0.27 no modelo LSTM, aproximadamente. Portanto, a hipótese (i) pode ser interpretada de forma que as métricas apresentaram, em média, erros 2% maiores, ou seja, não contribuíram para redução dos erros. A hipótese (ii) foi confirmada, penalizando os modelos LSTM com a inclusão de variáveis exógenas, aumentando, em média, 15% os índices de erros.

Excluído: Ta

Excluído: Ta

Tabela 13 - Métricas MSE e MAE para a unidade U45, considerando as variáveis exógenas, destacando em negrito os menores índices de cada categoria

	MSE			MAE		
	ARIMA	LSTM	SARIMA	ARIMA	LSTM	SARIMA
Agropecuária	0.0556	<b>0.0505</b>	0.0509	0.1961	0.1879	<b>0.1853</b>
Autopeças	<b>0.0409</b>	0.1968	0.0600	<b>0.1686</b>	0.3641	0.1999
Bebidas	0.0554	0.0659	<b>0.0393</b>	0.1957	0.2170	<b>0.1578</b>
Bolsas	0.0542	0.1555	<b>0.0398</b>	0.1935	0.3252	<b>0.1589</b>
Brinquedos em Geral	0.0511	0.0937	<b>0.0417</b>	0.1913	0.2593	<b>0.1664</b>
Calçados	<b>0.0515</b>	0.0847	0.0558	<b>0.1891</b>	0.2404	0.1953
Construção Civil	<b>0.0550</b>	0.1018	0.0648	<b>0.1984</b>	0.2618	0.2087
Cosméticos	<b>0.0332</b>	0.1371	0.0459	<b>0.1522</b>	0.3164	0.1735
Diversos	<b>0.0060</b>	0.1177	0.1060	<b>0.0592</b>	0.2837	0.2544
Eletrrodomésticos em Geral	<b>0.0491</b>	0.0507	0.0569	<b>0.1837</b>	0.1899	0.1983
Eletrônicos diversos	<b>0.0457</b>	0.1593	0.0583	<b>0.1796</b>	0.3381	0.1968
Embalagens	<b>0.0437</b>	0.1334	0.0551	<b>0.1732</b>	0.3035	0.1902
Equipamento de Segurança	0.0529	0.0662	<b>0.0379</b>	0.1925	0.1942	<b>0.1562</b>
Equipamentos para indústria	0.0527	0.1502	<b>0.0436</b>	0.1926	0.3244	<b>0.1655</b>
Fabricação de colchões	0.0554	0.0590	<b>0.0383</b>	0.1957	0.1888	<b>0.1560</b>
Ferramentas	<b>0.0561</b>	0.1062	0.0562	0.1981	0.2726	<b>0.1937</b>
Fiação Fibras Artificiais e Sintéticas	0.0557	0.0887	<b>0.0392</b>	0.1970	0.2441	<b>0.1597</b>
Informática	<b>0.0393</b>	0.1070	0.0628	<b>0.1650</b>	0.2592	0.2077
Itens infantis	0.0521	0.1113	<b>0.0467</b>	0.1904	0.2797	<b>0.1715</b>
Laboratórios e Medicamentos	<b>0.0480</b>	0.1704	0.0550	<b>0.1838</b>	0.3165	0.1949
Maquinas	<b>0.0538</b>	0.2008	0.0613	<b>0.1950</b>	0.3711	0.2074
Material de Construção	0.0497	0.0603	<b>0.0466</b>	0.1860	0.2138	<b>0.1769</b>
Material elétrico	<b>0.0474</b>	0.1725	0.0519	<b>0.1824</b>	0.3262	0.1901
Material Esportivo	<b>0.0441</b>	0.1457	0.1031	<b>0.1751</b>	0.3258	0.2649
Material Hospitalar	<b>0.0499</b>	0.1487	0.0562	<b>0.1843</b>	0.3234	0.1960
Moveis	0.0556	0.1842	<b>0.0527</b>	0.1964	0.2913	<b>0.1904</b>
Papelaria/Livraria	0.0537	<b>0.0361</b>	0.0557	0.1919	<b>0.1610</b>	0.1928
Produtos alimentícios	<b>0.0548</b>	0.0741	0.0560	<b>0.1945</b>	0.2300	0.1969
Produtos gráficos	0.0551	0.0963	<b>0.0461</b>	0.1951	0.2414	<b>0.1741</b>
Tecidos e Confecções	<b>0.0459</b>	0.1453	0.0619	<b>0.1786</b>	0.3254	0.2061
Transp. rod. cargas em geral	0.0557	0.0988	<b>0.0389</b>	0.1967	0.2475	<b>0.1571</b>
Utilidades Domesticas	<b>0.0331</b>	0.0856	0.0605	<b>0.1478</b>	0.2384	0.2006

Fonte: o autor.

Outra observação para os resultados da [Tabela 13](#), é a categoria Diversos no modelo ARIMAX, que obteve métricas que reduziram o erro, comparado com todos os outros cenários que não consideram variáveis exógenas. Isto indica que determinadas variáveis exógenas podem contribuir para o modelo ARIMAX, permitindo que os dados introduzam informações que agreguem precisão para o modelo.

Excluído: Ta

Tabela 14 - Métricas para unidade U45, desconsiderando variáveis exógenas

	C2	C3	C4	C5	C6	C7	C8	C9
<b>MSE</b>	0.0392	0.0413	0.0147	0.0068	0.0684	0.0453	0.0416	0.0098
<b>MAE</b>	0.1577	0.1644	0.0949	0.0639	0.2216	0.1774	0.1650	0.0792

Fonte: o autor.

## 4.5. ANÁLISE TEMPORAL

Esta subseção relata os resultados em termos de desempenho computacional, utilizando a referência os tempos de processamento de cada modelo em cada cenário, analisando os modelos e no final comparando todos. O processo de treinamento e validação de todos os modelos e cenários nesta pesquisa, incluindo ajustes e correções, ultrapassaram 1500 horas de processamento.

### 4.5.1 ARIMA

A [Tabela 15](#), mostra os tempos de processamento de cada unidade em cada cenário, destacando em cada unidade o menor (**negrito**) e o maior (*itálico*) tempo de processamento em cada cenário.

Excluído: Ta

Tabela 15 - Tempo de processamento de treino e validação das unidades em cada cenário no modelo ARIMA

UN	U01	U02	U03	U04	U05	U06	U07	U08	U09	U10	U11
<b>C2</b>	348.35	405.89	382.88	256.71	<u>465.9</u>	291.9	370.4	336.49	<u>403.76</u>	361.12	346.51
<b>C3</b>	<u>563.24</u>	<u>439.36</u>	<u>441.4</u>	<u>345.63</u>	440.3	<u>316.36</u>	<u>474.47</u>	<u>470.66</u>	268.48	<u>469.98</u>	309.18
<b>C6</b>	349.88	334.81	<b>275.6</b>	251.27	<b>291.46</b>	<b>253.98</b>	402.03	<b>217.98</b>	261.96	<b>358.35</b>	<b>238.24</b>
<b>C8</b>	<b>318.34</b>	<b>327.37</b>	343.94	<b>224.17</b>	388.49	266.53	<b>328.11</b>	261.37	<b>244.72</b>	399.54	<u>357.76</u>
	<b>U12</b>	<b>U13</b>	<b>U14</b>	<b>U15</b>	<b>U16</b>	<b>U17</b>	<b>U18</b>	<b>U19</b>	<b>U20</b>	<b>U21</b>	<b>U22</b>
<b>C2</b>	349.48	<b>324.21</b>	390.98	337.67	367.58	264.18	364.8	265.79	313.99	203.19	<u>409.12</u>
<b>C3</b>	<u>393.41</u>	360.9	<u>588.39</u>	<u>628.09</u>	<u>542.3</u>	<u>397.97</u>	<u>506.16</u>	<u>428.64</u>	<u>457.29</u>	<u>518.56</u>	<b>275.25</b>
<b>C6</b>	363.89	342.06	320.46	<b>282.07</b>	291.49	<b>163.81</b>	<b>268.38</b>	245.74	<b>279.25</b>	<b>201.26</b>	325.09
<b>C8</b>	<b>329.79</b>	<u>389.3</u>	<b>317.46</b>	339.64	<b>252.37</b>	387.08	363.61	<b>242.34</b>	387.03	210.31	358.31
	<b>U23</b>	<b>U24</b>	<b>U25</b>	<b>U26</b>	<b>U27</b>	<b>U28</b>	<b>U29</b>	<b>U30</b>	<b>U31</b>	<b>U32</b>	<b>U33</b>
<b>C2</b>	427.58	<u>422.45</u>	255.3	397.97	118.64	331.25	419.81	<b>108.11</b>	257.99	72.45	<u>384.43</u>
<b>C3</b>	<u>673.19</u>	381.99	<u>386.37</u>	<u>501.15</u>	<u>193.28</u>	<u>435.19</u>	<u>521.36</u>	<u>196.6</u>	1.46	78.31	378.85
<b>C6</b>	<b>284.99</b>	<b>132.91</b>	<b>201.95</b>	<b>224.86</b>	115.9	<b>304.75</b>	<b>368.82</b>	111.02	<b>0.37</b>	<u>80.54</u>	<b>234.6</b>
<b>C8</b>	401.66	230.91	240.87	230.77	<b>112.9</b>	333.32	408.92	113.1	<u>375.19</u>	<b>60.34</b>	381.78
	<b>U34</b>	<b>U35</b>	<b>U36</b>	<b>U37</b>	<b>U38</b>	<b>U39</b>	<b>U40</b>	<b>U41</b>	<b>U42</b>	<b>U43</b>	<b>U44</b>
<b>C2</b>	415.86	420.34	376.75	<u>416.8</u>	317.41	<u>419.13</u>	381.22	383.73	<u>441.43</u>	357.09	<b>306.11</b>
<b>C3</b>	<u>499.72</u>	<u>665.19</u>	<u>426.59</u>	414.35	<u>480.67</u>	417.04	<u>425.64</u>	<u>483.51</u>	404.98	<u>410.23</u>	<u>432.81</u>
<b>C6</b>	<b>331.67</b>	<b>160.05</b>	<b>252.61</b>	<b>318.55</b>	434.96	<b>261.67</b>	<b>254.44</b>	<b>250.27</b>	357.24	<b>234.3</b>	376.56
<b>C8</b>	423.52	356.77	288.55	370.75	<b>262.87</b>	333.95	340.09	257.74	<b>335.99</b>	368.73	333.79
	<b>U45</b>	<b>U46</b>	<b>U47</b>	<b>U48</b>	<b>U49</b>	<b>U50</b>	<b>U51</b>	<b>U52</b>	<b>U53</b>	<b>U54</b>	
<b>C2</b>	325.57	360.84	392.56	<u>336.77</u>	390.71	<b>256.69</b>	404.2	288.4	390.41	431.34	
<b>C3</b>	<u>338.02</u>	<u>452.61</u>	<u>438.53</u>	314.36	336.88	<u>632.35</u>	388.9	296.38	<u>532.38</u>	<u>617.43</u>	
<b>C6</b>	<b>240.02</b>	<b>182.88</b>	<b>242.05</b>	<b>154.57</b>	<b>306.81</b>	257.38	<u>440.38</u>	<u>314.37</u>	<b>375.65</b>	<b>218.68</b>	
<b>C8</b>	267.35	249.28	371.16	287.13	<u>424.7</u>	325.82	<b>377.96</b>	<b>251.41</b>	389.16	332.58	

Fonte: o autor.


O modelo ARIMA apresentou uma característica regular, com tempos de processamento semelhantes entre unidades em cada cenário, conforme observado na [Figura 43](#), (a). A análise deste gráfico mostra que o Cenário 6 apresentou os menores tempos de processamento, justificado pelo conjunto de dados reduzido, enquanto o Cenário 3 os maiores tempos de processamento. Apesar disso, o gráfico [Figura 43](#), (b) mostra que a média e mediana foram próximas, com desvios padrões que demonstram uma dispersão dos dados em uma amplitude inferior à média, que reforça a regularidade descrita na [Figura 43](#), (a).

Excluído: Fi

Excluído: Fi

Excluído: Fi

Figura 43 - (a) Proporções de tempo de processamento entre os cenários em cada unidades no modelo ARIMA. (b) Média, mediana e desvio padrão mínimos em cada unidade no modelo ARIMA



Fonte: o autor.


Os tempos mínimos e máximos por cenário entre as unidades, apresentados na [Tabela 15](#), mostra que os Cenários 3 e 6 foram opostos em suas características, em que o 3 apresentou o maior tempo de processamento em 38 das 54 unidades, enquanto o Cenário 6 apresentou 34 dos menores tempos. Os demais cenários se distribuíram, destacando que o Cenário 8 apresentou a segunda parcela dos menores tempos e apenas 4 unidades destes cenários com os maiores tempos de processamento. Estas informações demonstram que o tamanho do conjunto de dados é o fator que apresentou maior influência no

Excluído: Ta

tempo de processamento, e que o modelo de tratamento de *outlier* pode influenciar no tempo de processamento, no qual os Cenários 3 e 8 que possuem tratamento, apresentaram características divergentes. Entretanto não houve variações significativas entre os cenários.

Com relação a amplitude entre os tempos de processamento, a [Figura 44](#), exhibe os tempos mínimos e máximos entre os cenários de cada unidade, confirmando a interpretação que os demais gráficos e tabelas que descrevem regularidade entre os cenários e os tempos mínimos e máximos, sendo estes próximos e curvas semelhantes.

Figura 44 - Tempos mínimos e máximos entre todos os cenários em cada unidade no modelo ARIMA



Fonte: o autor.

#### 4.5.2 SARIMA

A [Tabela 16](#), mostra os tempos de processamento de cada unidade em cada cenário, destacando em cada unidade o menor (**negrito**) e o maior (*itálico*) tempo de processamento em cada cenário.

Excluído: Fi

Excluído: Ta

Tabela 16 - Tempo de processamento de treino e validação das unidades em cada cenário no modelo SARIMA

UN	U01	U02	U03	U04	U05	U06	U07	U08	U09	U10	U11
C2	99.87	<u>171.96</u>	<b>56.52</b>	40.01	<b>35.79</b>	67.02	167.29	58.83	<u>69.89</u>	43.96	<u>222.44</u>
C3	<u>112.35</u>		69.53	21.81	71.58	<u>184.91</u>	<u>301.01</u>	<u>78.12</u>	56.67	<u>81.23</u>	124.82
C6	90.4	<b>95.25</b>	105.92	<u>74.68</u>	<u>198.9</u>	100.21	<b>112.27</b>	75.55	<b>5.11</b>	<b>25.11</b>	<b>27.78</b>
C8	<b>40.25</b>	97.25	<u>174.47</u>	<b>16.75</b>	122.09	<b>40.33</b>	196.43	<b>39.58</b>	29.88	34.25	206.3
	<b>U12</b>	<b>U13</b>	<b>U14</b>	<b>U15</b>	<b>U16</b>	<b>U17</b>	<b>U18</b>	<b>U19</b>	<b>U20</b>	<b>U21</b>	<b>U22</b>
C2	<b>32.66</b>	52.29	78.99	<u>170.21</u>	32.49	<b>18.69</b>	<b>38.13</b>	259.27	<b>88.04</b>	<u>174.48</u>	116.72
C3	42.37	31.98	<u>127.91</u>	139.18	<u>49.08</u>	<u>199.37</u>	<u>289.18</u>	<u>300.44</u>	<u>396.95</u>	70.6	<u>232.71</u>
C6	42.16	<u>117.74</u>	<b>24.73</b>	<b>38.05</b>	18.62	143.63	100.78	<b>9.69</b>	129.88	<b>1.15</b>	<b>17.64</b>
C8	<u>143.77</u>	<b>18.06</b>	65	92.8	<b>14.01</b>	37.67	111.39	160.82	328.79	1.4	101.96
	<b>U23</b>	<b>U24</b>	<b>U25</b>	<b>U26</b>	<b>U27</b>	<b>U28</b>	<b>U29</b>	<b>U30</b>	<b>U31</b>	<b>U32</b>	<b>U33</b>
C2	46.21	<u>53.56</u>	24.18	121.89	5.85	<u>115.9</u>	<u>134.61</u>	3.51	<b>4.48</b>	0.53	<u>126.41</u>
C3	<b>19.92</b>	10.45	<u>72.24</u>	<u>171.66</u>	<u>14.16</u>	84.08	120.16	<u>23.39</u>		0.64	<b>20.22</b>
C6	<u>166.22</u>	5.95	24.94	<b>7.7</b>	<b>2.32</b>	<b>10.53</b>	<b>11.09</b>	<b>0.67</b>		<b>0.48</b>	33.1
C8	127.99	<b>1.66</b>	<b>21.45</b>	28.18	6.72	18.64	31.72	2.18	<u>135.19</u>	<u>0.69</u>	106.53
	<b>U34</b>	<b>U35</b>	<b>U36</b>	<b>U37</b>	<b>U38</b>	<b>U39</b>	<b>U40</b>	<b>U41</b>	<b>U42</b>	<b>U43</b>	<b>U44</b>
C2	171.7	<b>45.78</b>	108.71	<b>55.18</b>	58.12	231.81	<b>105.33</b>	<u>294.32</u>	<u>358.7</u>	78.17	<u>270.24</u>
C3	178.84	55.83	<u>164.2</u>	<u>141.35</u>	<u>130.79</u>	<u>309.51</u>	<u>152.68</u>	176.94	123	87.81	172.57
C6	<u>179.34</u>	<u>192.88</u>	103.9	61.47	90.29	22.72	149.86	<b>7.15</b>	22.17	<b>4.92</b>	<b>9.15</b>
C8	<b>71.73</b>	107.69	<b>26.26</b>	104.19	<b>15.16</b>	<b>8.77</b>	119.48	12.46	<b>19.72</b>	<u>182.81</u>	40.32
	<b>U45</b>	<b>U46</b>	<b>U47</b>	<b>U48</b>	<b>U49</b>	<b>U50</b>	<b>U51</b>	<b>U52</b>	<b>U53</b>	<b>U54</b>	
C2	<u>252.52</u>	<b>22.77</b>	194.52	<u>130.96</u>	<u>156.4</u>	17.55	<u>227.49</u>	101.98	30.78	165.07	
C3	99.72	58.35	<u>206.81</u>	71.13	133.58	<u>220.8</u>	210.59	60.8	59.37	216.92	
C6	60.94	<u>143.4</u>	<b>18.98</b>	<b>5.36</b>	<b>33.74</b>	<b>6.06</b>	124	<b>4.88</b>	<u>91.44</u>	<b>3.58</b>	
C8	<b>31.29</b>	33.72	112.25	102.42	65.45	119.55	<b>89.63</b>	<u>102.27</u>	<b>16.42</b>	<u>253.63</u>	


Fonte: o autor.

O quesito tempo para o modelo SARIMA obteve uma irregularidade considerável em relação ao modelo ARIMA, tornando a análise menos intuitiva como observado no gráfico com os tempos de cada cenário. Segundo o gráfico da [Figura 45](#), (a) e a [Tabela 16](#), o Cenário 6 obteve o menor tempo de processamento em quase metade das unidades validadas. Isso é justificável devido à preparação dos dados, que reduz o tamanho do conjunto. Em seguida, o Cenário 8 e Cenário 2 obtiveram a outra metade dos tempos mínimos de processamento, apenas em duas das unidades foram mais rápidas no Cenário 3. Por outro lado, os tempos máximos se concentraram no Cenário 3, seguido do Cenário 2, o que demonstra que o modelo SARIMA foi beneficiado em situações de remoção de *outliers* e métodos sofisticados para o tratamento do mesmo.

Excluído: Fi

Excluído: Ta

Figura 45 - (a) Proporções de tempo de processamento entre os cenários em cada unidades no modelo SARIMA. (b) Média, mediana e desvio padrão mínimos em cada unidade no modelo SARIMA




Fonte: o autor.

O gráfico da [Figura 45](#), (b) exibe as médias, medianas e desvio padrão de cada unidade de acordo com os tempos de cada cenário. O desvio padrão foi acima da média e mediana, demonstrando uma irregularidade em torno dos tempos em cada cenário/unidade, ou seja, não ocorreu um padrão regular de tempo de processamento.

Excluído: Fi



Figura 46 - Tempos mínimos e máximos entre todos os cenários em cada unidade no modelo SARIMA



Fonte: o autor.

Os tempos mínimos e máximos entre todos os cenários em cada unidade está descrito na [Figura 46](#), que permite perceber que os tempos mínimos percorrem uma faixa por volta de 0 e 100 segundos. Os máximos apresentaram uma amplitude maior, mostrando que em determinadas unidades, certos cenários influenciaram de forma significativa. Outra observação é que as curvas de mínimo e máximo apresentam tendências semelhantes, ou seja, o tempo de processamento é caracterizado não apenas pelo método de tratamento de *outlier*, mas também pelo conjunto de dados.

A partir destas observações, pode-se constatar que para o modelo SARIMA, a influência dos métodos de tratamento de *outlier* não apresentou um padrão, ou seja, enquanto que nos Cenários 3 e 8 foram tratados *outliers*, as características foram divergentes, o primeiro sendo responsável por quase metade dos casos de maior tempo e apenas dois casos com o menor tempo, enquanto que o Cenário 8 obteve a menor quantidade de tempos máximos.

#### 4.5.3 LSTM

A [Tabela 17](#), mostra os tempos de processamento de cada unidade em cada cenário, destacando em cada unidade o menor (**negrito**) e o maior (*itálico*) tempo de processamento em cada cenário.

Excluído: Fi

Excluído: Ta


Tabela 17 - Tempo de processamento de treino e validação das unidades em cada cenário no modelo LSTM

UN	U01	U02	U03	U04	U05	U06	U07	U08	U09	U10	U11
C4	<b>7866.57</b>	17383.32	26600.99	14344.92	19411.19	17308.1	23291.53	16631.55	16489.26	22339.12	17161.21
C5	19890.49	<b>9623.26</b>	<b>12703.03</b>	<b>11259.63</b>	<b>7331.33</b>	<b>9276.06</b>	<b>11842.24</b>	<b>14103.02</b>	<b>13061.76</b>	<b>15123.26</b>	<b>8863.82</b>
C7	30050.11	19150.64	23536.69	<u>41689.83</u>	19421.46	19851.27	<u>54323</u>	23977.21	22484.74	22603.63	22044.87
C9	<u>47155.68</u>	<u>31064.32</u>	<u>35459.43</u>	32331.92	<u>28359.66</u>	<u>30545.94</u>	34879.63	<u>36955.21</u>	<u>35699.67</u>	<u>38575.18</u>	<u>29910.42</u>
	<b>U12</b>	<b>U13</b>	<b>U14</b>	<b>U15</b>	<b>U16</b>	<b>U17</b>	<b>U18</b>	<b>U19</b>	<b>U20</b>	<b>U21</b>	<b>U22</b>
C4	16897	29801.56	18260.06	10664.63	17425.03	<b>7159.7</b>	10237.85	22817.46	17391.16	11308.98	14111.92
C5	<b>13716.58</b>	<b>16582.26</b>	<b>10992.53</b>	<b>8521.69</b>	<b>10739.13</b>	19689.93	<b>8216.39</b>	<b>14635.89</b>	<b>9912.09</b>	<b>8870.96</b>	<b>10885.53</b>
C7	20830.55	27972.88	22002.96	36331.48	23584.71	33171.63	33039.48	21828.76	17987.19	<u>44192.73</u>	<u>41884.28</u>
C9	<u>36425.31</u>	<u>41070.69</u>	<u>33295.5</u>	<u>51541.41</u>	<u>32712.92</u>	<u>45320.78</u>	<u>50947.16</u>	<u>38044.09</u>	<u>31548.2</u>	25405.77	31466.24
	<b>U23</b>	<b>U24</b>	<b>U25</b>	<b>U26</b>	<b>U27</b>	<b>U28</b>	<b>U29</b>	<b>U30</b>	<b>U31</b>	<b>U33</b>	<b>U34</b>
C4	17483.3	13881.39	8515.28	11880.12	9664.25	<b>7358.74</b>	30778.72	4311.56	<b>14442.31</b>	15593.87	<b>8254.69</b>
C5	<b>10212.93</b>	<b>10585.34</b>	<b>7134.4</b>	<b>9350.99</b>	<b>3698.6</b>	20152.06	<b>16798.54</b>	<b>3657.74</b>		<b>7488.34</b>	19408.58
C7	25196.83	<u>48123.33</u>	31193.49	<u>40508.73</u>	9631.4	33177.9	<u>48924.95</u>	<u>12534.96</u>		19998.72	29682.02
C9	<u>32179.35</u>	30857.67	<u>47560.22</u>	28841.89	<u>10623.8</u>	<u>45881.85</u>	41285.84	10249.95	<u>32768.88</u>	<u>28676.19</u>	<u>44382.69</u>
	<b>U35</b>	<b>U36</b>	<b>U37</b>	<b>U38</b>	<b>U39</b>	<b>U40</b>	<b>U41</b>	<b>U42</b>	<b>U43</b>	<b>U44</b>	<b>U45</b>
C4	9385.08	22882.59	21319.72	12138.41	12590.41	22774.83	18754.11	19914.44	20824.45	13126.13	16466.51
C5	<b>7478.38</b>	<b>15498.28</b>	<b>17945.33</b>	<b>9674.38</b>	<b>10018.42</b>	<b>16010.59</b>	<b>18539.8</b>	<b>12255.35</b>	<b>17555.02</b>	<b>10354.4</b>	<b>8528.26</b>
C7	31454.48	27755.09	30798.35	<u>36554.75</u>	<u>43715.2</u>	29240.89	34602.23	21745.3	26773.89	<u>35529.35</u>	17513.71
C9	<u>49767.73</u>	<u>39439.17</u>	<u>43213.66</u>	29169.46	29684.01	<u>40004.69</u>	<u>43789.33</u>	<u>35151.05</u>	<u>42674.92</u>	30243.9	<u>29560.02</u>
	<b>U46</b>	<b>U47</b>	<b>U48</b>	<b>U49</b>	<b>U50</b>	<b>U51</b>	<b>U52</b>	<b>U53</b>	<b>U54</b>		
C4	9011.74	23383.73	16251.75	11388.08	11129.75	17652.08	17019.93	9796.06	<u>57017.75</u>		
C5	<b>7260.56</b>	<b>17231.99</b>	<b>8020.11</b>	<b>9007.32</b>	<b>8752.8</b>	<b>7232.32</b>	<b>14353.68</b>	<b>7863.97</b>	<b>11263.48</b>		
C7	32623.16	<u>78366.42</u>	17200.34	<u>42800.52</u>	<u>41139.87</u>	18852.18	24014.95	32922.16	21832.68		
C9	<u>49100.27</u>	41895.62	<u>28844.64</u>	28299.84	28270.26	<u>28696.95</u>	<u>37498.72</u>	<u>49917.8</u>	33788.25		

Fonte: o autor.

Os dados indicam que as redes neurais LSTM obtiveram extremos em dois cenários: o cenário com 48 menores tempos de processamento de um total de 53, e o Cenário 9 com os 38 maiores tempos de processamento, ambos obtiveram tratamento de *outliers*. Isso pode sugerir que o método de tratamento de *outlier* pode ser um critério relevante no quesito desempenho computacional, mostrando que a escolha de métodos de tratamento de *outliers* para redes neurais LSTM, pode ser um critério decisivo, pois o tempo de treino de redes neurais em determinados casos pode inviabilizar a utilização. Outra característica não esperada, diferente dos modelos ARIMA/SARIMA, é que os conjuntos de dados que tiveram seus *outliers* eliminados (Cenário 7), não apresentaram menor tempo de processamento e, pelo contrário, em 14 dos 53 conjuntos de dados, obteve o maior tempo.

Figura 47 - (a) Proporções de tempo de processamento entre os cenários em cada unidades no modelo LSTM. (b) Média, mediana e desvio padrão mínimos em cada unidade no modelo LSTM



Fonte: o autor.


O gráfico da [Figura 47](#), (a) exibe algumas características da forma que as diferentes unidades em cada cenário se compõem, apresentando uma característica uniforme, com o Cenário 5 com os menores tempos, seguido do Cenário 4, em seguida os Cenários 7 e 9. Em complemento as estas informações, o gráfico da [Figura 47](#), (b) descreve as características das unidades em torno dos cenários, obtendo-se médias e medianas próximas, um desvio padrão inferior, porém próximo às outras curvas, o que confirma a distribuição

Excluído: Fi

Excluído: Fi

uniforme entre as unidades com diferentes proporções em cada cenário. O fato de o Cenário 4 apresentar tempos de processamento menores que o Cenário 9, por exemplo, também indica que as redes neurais LSTM podem ser sensíveis ao conjunto de dados, e que o tratamento de *outliers*, mudando ou não sua característica elementar, conseqüentemente o desempenho de processamento pode ser influenciado.

Figura 48 - Tempos mínimos e máximos entre todos os cenários em cada unidade no modelo LSTM



Fonte: o autor.

Analisando-se os tempos mínimos e máximos de cada unidade, [Figura 48](#), cada curva obteve variações na amplitude que tiveram uma variação regular, ou seja, o fator unidade não teve influência significativa ao longo do processamento.

#### 4.5.4 COMPARAÇÃO DE DESEMPENHO

Analisando-se os três modelos em conjunto, verifica-se que as redes neurais LSTM necessitam de um tempo de processamento superior aos modelos ARIMA/SARIMA, como descrevem os gráficos da [Figura 49](#), (a/b), em que os mínimos e máximos são referenciados. Os mínimos do modelo LSTM ([Tabela 17](#)) variam a partir de 5.000 segundos, enquanto os modelos ARIMA/SARIMA em torno de 300 segundos. Os tempos máximos seguem a mesma característica, com ARIMA e SARIMA não ultrapassando os 700 segundos,


Excluído: Fi


Excluído: Fi

Excluído: Ta

enquanto que o LSTM atingindo próximo aos 80.000 segundos. Estes resultados são esperados, uma vez que o processo de treinamento de determinação de hiperparâmetros de redes neurais exigem esforço computacional e complexidade para processamento que supera modelos regressivos, como ARIMA e SARIMA, que possuem métodos e processos simplificados para análise de hiperparâmetros e treinamento/validação dos dados.

Figura 49 - Tempos mínimos (a) e máximos (b) entre as unidades em todos os cenários em todos os modelos. (c) Tempos mínimos (c) e máximos (d) entre as unidades em todos os cenários nos modelos ARIMA





Fonte: o autor.

Observando de forma isolada os mínimos [Figura 49, \(c\)](#) e os máximos (d) dos modelos ARIMA/SARIMA, é possível verificar que as curvas do modelo SARIMA estão abaixo do ARIMA, isso se justifica devido ao método de determinação dos hiperparâmetros do modelo SARIMA utiliza heurísticas com desempenho que superam o método do modelo ARIMA.

Excluído: Fig

## 5. DISCUSSÕES

A presente pesquisa realizou uma análise de modelos preditivos aplicados em diversos conjuntos de dados em diferentes cenários que contemplam abordagens particulares de pré-processamento de dados. A partir dos resultados obtidos, este capítulo apresenta as principais discussões e observações alcançadas.

### 5.1 ANÁLISE EXPLORATÓRIA DE DADOS

Os 54 conjuntos de dados referentes às unidades apresentam características independentes e únicas. Entretanto, alguns aspectos são predominantes e justificam resultados e discussões.

Em todos os conjuntos de dados também é possível identificar a uma amplitude de ruídos na mesma escala dos conjuntos, o que leva a interpretação da existência de *outliers* distribuídos ao longo dos mesmos. Este fator é endereçado pelos cenários, mas também contribui para a aderência de modelos de aprendizado de máquina que implementam redes neurais (ABBASIMEHR; SHABANI; YOUSEFI, 2020; ABURTO; WEBER, 2007; KANTASA-ARD et al., 2021; MAHBUB; PAUL; AZEEM, 2013; ZHANG, 2003), devido às características dos conjuntos de dados.

Com relação à sazonalidade, todas as unidades apresentaram sazonalidades semanais, extraídos dos gráficos de decomposições sazonais, o que permitiria que o modelo SARIMA tivesse mais recursos que o ARIMA para resultar em previsões mais assertivas. Isso ocorreu em metade das unidades, comparando-se os modelos estatísticos, divergindo da expectativa de uma preponderância de resultados para o SARIMA. A sazonalidade semanal também confirmou que o hiperparâmetro *lag size* da rede neural LSTM poderia ser restrito a apenas o valor 7, sendo dispensável o outro valor (14), que representou menos de 10% das unidades que selecionaram o valor 14, o que reduziria pela metade as combinações de hiperparâmetros, reduzindo o tempo de processamento.

## 5.2 PRÉ-PROCESSAMENTO

No âmbito de processamento dos dados, a etapa de treinamento dos modelos, o método de seleção de hiperparâmetros adotado foi o *Grid Search*, que por sua vez, seleciona a combinação dos hiperparâmetros baseada ou em testes estatísticos ou métricas de erros. A principal vantagem deste método é a implementação simples e também reduz a necessidade de intervenções analíticas. Por outro lado, existe a penalidade deste método com relação ao desempenho computacional, que será relatado posteriormente. Em complemento, identificou-se que ocorrem casos em que os métodos analíticos apontam valores de hiperparâmetros diferentes dos selecionados pelo *Grid Search*, com destaque para os modelos ARIMA e SARIMA, que através dos gráficos de autocorrelação e autocorrelação parcial, podem indicar parte de suas componentes; porém, as variações entre valores analisados e selecionados foram frequentes. Isso pode ser devido a subjetividades ou ambiguidades que podem ocorrer em métodos analíticos.

## 5.3 RESULTADOS OBTIDOS

Sob a perspectiva de modelos implementados, os Cenários 4, 5, 7 e 9 utilizaram a rede neural LSTM, enquanto os Cenários 2, 3, 6 e 8 os modelos ARIMA/SARIMA. 94% das unidades avaliadas obtiveram as menores métricas de erros MAE e 91% da métrica MSE nos cenários que aplicaram LSTM na base de testes. A média das métricas MAE nos cenários que aplicaram a rede neural em todas as unidades foi 62,5% menor que dos modelos ARIMA/SARIMA e 48% menor segundo a métrica MSE. Estes resultados estão de acordo com os trabalhos no estado da arte da literatura, como as pesquisas de Ren et al.(2020), Abbasimehr et al. (2020), Kantasa-ard et al. (2020) e Fu et al. (2018).

Os resultados apontam que o modelo LSTM obteve as previsões nas unidades com os mínimos erros, com uma vantagem de redução de métrica superior a 60%, trazendo previsões assertivas. A literatura apresenta pesquisas que destacam o desempenho dos resultados com modelos ARIMA (VARGAS; ELIZONDO CORTÉS, 2017; YAMAK; YUJIAN; GADOSEY, 2019) do que com redes neurais e vice-versa (ABBASIMEHR; SHABANI; YOUSEFI, 2020;



ABURTO; WEBER, 2007; REN et al., 2020). Uma hipótese possível justificada na literatura é que redes neurais possuem capacidade de interpretar os padrões e se adaptam a séries não-lineares, situações que como descrito na literatura (HU et al., 2021; MIAO; XI, 2008; ÖMER FARUK, 2010; SEYEDAN; MAFAKHERI, 2020; ZHANG; QI, 2005), permitam que redes neurais desempenhem resultados com vantagem em relação a outros métodos, confirmando que as redes neurais LSTM são capazes de se adaptarem em situações diferentes (conjuntos de dados), flutuações de dados e possíveis irregularidades.

As redes neurais LSTM, considerando todos cenários e unidades, tiveram, em média, a métrica MAE de 0,104, considerando cenários que tiveram métricas inferiores a 0,01. Considerando que os dados de todas as unidades estão normalizados, entre 0 e 1, este erro representa em média 10%, com casos inferiores a 1%, o que pode ser considerado um resultado assertivo, comparado ao ARIMA/SARIMA, que apresentou médias superiores a 16% de erro médio.

Considerando-se uma margem de 10% de erro médio em um período de 72 dias, pode-se concluir que são satisfatórios para possíveis tomadas de decisões operacionais provenientes das previsões de demandas de transporte. Estes dados sugerem que a pesquisa gerou uma contribuição para a literatura, implementando modelos, cenários em previsões não exploradas na literatura com o mesmo intuito.

#### **5.4 TEMPO DE PROCESSAMENTO**

Na perspectiva de desempenho computacional, a LSTM demanda recursos computacionais maiores, sendo o seu tempo médio de processamento de 167 a 88.000 vezes maior que dos modelos ARIMA/SARIMA, dependendo do cenário e da unidade em questão. A média de tempo de treinamento dos modelos estatísticos foi de 3,5 minutos. No caso da LSTM, este tempo foi de 6,5 horas. Esta diferença é relevante para a escolha de modelos em cenários reais de aplicação. Esta decisão deve partir da avaliação de qual o panorama e a recorrência em que as previsões devem ser realizadas.

Caso seja necessário um treinamento intradiário do modelo, a LSTM pode impactar nos objetivos da organização se for utilizado um conjunto de dados

extenso para o seu treinamento. Nesta situação, deve-se avaliar o uso de modelos ARIMA e variações. Porém, em casos em que o treinamento possa ser realizado no período de um dia ou mais, o tempo de treinamento da LSTM não impactará no caso específico. Entretanto, é necessário avaliar os modelos utilizados e o hardware utilizado para o treinamento.

## 5.5 TRATAMENTO DE OUTLIERS

Outra observação relevante relacionada aos resultados obtidos é que o processamento de dados removendo os *outliers* não trouxe redução dos erros nas previsões. Este resultado surpreendeu, pois era esperado que o tratamento de dados contribuísse para redução de métricas de erros e permitisse que os modelos implementados interpretassem os dados de forma consistente. Alguns fatos podem justificar estes resultados: (I) os tratamentos de dados não identificaram devidamente os *outliers*, desprezando dados relevantes, neste caso, métodos não utilizados neste pesquisa poderiam contribuir para identificar dados que representam de fato *outliers*; (II) a característica dos conjuntos de dados não-lineares e não estacionários com resíduos predominando as séries, os modelos podem ter uma dependência dos *outliers* para interpretação dos dados e características da série temporal; (III) os supostos *outliers* podem ser interpretados como dados fundamentais e não podem ser desconsiderados ou substituídos.

Os Cenários 2 e 4, que não aplicaram nenhum tratamento de dados, apresentaram os menores índices de erros em relação aos demais cenários avaliados. A remoção dos *outliers* dos conjuntos de dados dos cenários obteve os maiores índices de erros, o que leva a compreender que não é uma técnica vantajosa.

Os Cenários 3, 5, 6 e 7 tiveram seus devidos tratamento de dados, com diferença na técnica de detecção. Entretanto, os indicadores de erros tiveram médias iguais (0,162) para ARIMA/SARIMA, e o LSTM apresentou uma média MAE de 0,088 para a detecção de *outliers* utilizando percentual quantil, enquanto 0,102 para a detecção utilizando *Isolation Forest*, o que leva a interpretar que métodos estatísticos contribuem para o pré-processamento de dados, do que modelos computacionais, para este problema em questão.

## 5.6 AVALIAÇÕES DE ASPECTOS SECUNDÁRIOS

Com relação às variáveis exógenas (Cenário 1), que levaram em conta as categorias de produtos operadas em uma determinada unidade, as métricas não mostraram contribuição para a acurácia dos resultados, com exceção da categoria Diversos no modelo ARIMAX, que alcançou o índice MAE de 0.059, menor até mesmo os índices dos cenários LSTM para a mesma unidade, o que indica que determinadas variáveis exógenas contribuem para que previsões assertivas sejam alcançadas.

Os efeitos da pandemia foram perceptíveis por volta de metade dos conjuntos de dados, porém, dentre os conjuntos que se identificaram variações atípicas com o restante do conjunto, concentraram-se em um período entre fevereiro e abril de 2020, com os resultados sugerindo que as métricas que foram afetadas foram as dos modelos ARIMA/SARIMA, que apresentam menor capacidade de adaptação a contextos de flutuações, diferente das redes neurais LSTM.

## 5.7 DISCUSSÕES FINAIS

Os modelos foram implementados de forma replicável a outros cenários que envolvam séries temporais. Desta forma, é possível avaliá-los utilizando diferentes conjuntos de dados, variáveis de avaliação, proporções entre os conjuntos de treino, validação e teste, métricas para a seleção dos modelos e conjuntos de hiperparâmetros a serem avaliados, ou seja, replicável a outras cadeias de suprimentos ou até mesmo problemas de outros contextos.

O capítulo seguinte conclui esta pesquisa, recomendando trabalhos futuros a serem realizados.

## **6. CONCLUSÕES**

Neste capítulo são apresentadas as conclusões da pesquisa. Os objetivos principais e secundários da pesquisa foram endereçados e tratados sem exceção, com conclusões e respostas determinadas segundo os resultados obtidos.

### **6.1 PRINCIPAIS CONTRIBUIÇÕES**

Esta pesquisa alcançou seu objetivo, implementando os modelos da família ARIMA e as redes neurais LSTM em demandas agregadas de transportes em unidades expedidoras de transportadoras, concluindo que ambos modelos podem ser aplicados para previsões em transportadoras, com destaque para o LSTM que apresentou as previsões mais assertivas.

Esta avaliação permite concluir que a pesquisa contribui para o estado da arte na ciência de dados em previsões nas cadeias de suprimentos, produzindo resultados que estendem a aplicação de modelos para previsões e conjuntos de dados para outras pesquisas e possíveis validações.

Os resultados mostraram que a assertividade (abaixo de 10% de erro no valor absoluto) da rede neural LSTM com um tempo de processamento superior a uma hora, enquanto os modelos da família ARIMA podem ser processados a partir de cinco minutos com assertividade inferior ao LSTM.

Além disso, também se contribui para a aplicação prática dos modelos em transportadoras, que necessitem de realizar previsões de demandas de transporte, através dos modelos estatísticos (em séries lineares) ou através das redes neurais LSTM (atendendo ambas séries temporais: lineares e não-lineares), que se mostraram aderentes e capazes de prever demandas de transporte em períodos superiores a dois meses.

### **6.2 OUTRAS CONTRIBUIÇÕES**

Como parte dos objetivos específicos, os requisitos para a pesquisa foram explorados. Dentre os funcionais, destaca-se as previsões de demandas

agregadas de transporte a partir de dados históricos que compõem a série-temporal. Dos requisitos não-funcionais destaca-se o uso de Python para implementação do processamento de dado, determinação dos modelos ARIMA/SARIMA e LSTM, métodos para pré-processamento de dados (detectando *outliers* e realizando diferentes tratativas para avaliação), recursos técnicos de hardware que tenham o máximo de capacidade de processamento e outros, identificados e detalhados ao longo da pesquisa.

A etapa de análise exploratória identificou as características dos dados, predominando séries não-estacionárias e não lineares em pelo menos 50% dos conjuntos, com sazonalidades de frequências semanais em todos os conjuntos de dados. Os conjuntos de dados possuem características heterogêneas, devido a fatores como localização da unidade, o que contribuiu para que fossem avaliados uma variedade de diferentes conjuntos de dados, o que contribui para a pesquisa, apontando o comportamento do modelo em características e variações de conjuntos.

Os resultados mostraram que o tratamento de *outliers* não contribuíram para que houvesse redução das métricas de erros tanto no modelo LSTM quanto nos modelos ARIMA/SARIMA, para este problema em questão. Além disso, as diferentes técnicas de tratamento e detecção de *outliers* resultaram em métricas que não favoreceram um cenário ou outro. Entretanto, os Cenários 8 e 9 que aplicaram o algoritmo *Isolation Forest* para detecção de *outliers*, obteve métricas inferiores (erros maiores) do que os demais cenários que realizaram análises estatísticas para detecção. Estes fatos levam a interpretar que os conjuntos de dados originais conduziram a resultados mais assertivos.

O modelo LSTM alcançou os melhores resultados (em termos de métricas de erros), em 94% dos conjuntos de dados nos cenários avaliados, com uma assertividade que corresponde pelo menos metade do erro do modelo ARIMA e suas variações.

O LSTM mostrou-se uma opção viável para o problema em questão, sendo vantajoso em relação aos demais avaliados, entretanto exige um tempo de processamento de seis horas, em média, enquanto o ARIMA/SARIMA pode ser treinado abaixo de 5 minutos. Neste caso, apesar dos modelos apresentarem uma variação significativa, levando em consideração que a previsão alcançada nas validações foi em torno de dois meses, um prazo de seis horas, em média,

para determinar as previsões, não se torna uma restrição para aplicar este modelo, podendo ser até reduzido, dependendo da capacidade de processamento.

O Cenário 1 que avaliou a variável exógena categoria de produtos, indicou que na unidade avaliada apenas uma das 32 variáveis contribuiu para redução dos erros nos modelos ARIMAX/SARIMAX. Para o LSTM nenhuma variável exógena reduziu a métrica com relação ao processamento sem a influências destes dados.

Metade dos conjuntos apresentaram indícios de flutuações nos períodos em que a pandemia de COVID-19 emergiu, entre os meses de janeiro de 2020 até abril de 2020. Apesar disso, pelas características dos conjuntos de dados, não estacionários e frequência de *outliers*, toram os conjuntos de dados caracterizados por flutuações em todo o período do conjunto. Portanto, apesar de influenciar na característica de um período, a pandemia pode ser interpretada pelos modelos como uma das demais flutuações. Além disso, o LSTM mostrou que possui maior capacidade de interpretação dos dados, identificando mudanças, características e ponderando os dados o que também reduziu o impacto da pandemia nas previsões.

Os objetivos alcançados viabilizam a realização de previsões de demandas de transporte acima de dois meses, com precisão suficiente para que sejam utilizados em finalidades práticas, prevendo demandas de transporte em locais específicos, suprimindo diversas atividades operacionais e estratégicas, como (i) programação da quantidade de veículos que devam ter disponibilidade em determinados dias e locais, reposicionando os mesmos de forma assertiva; (ii) programação de mão-de-obra para carregamento das demandas e motoristas; (iii) planejamento de aquisição ou venda de veículos; (iv) dimensionamento de locais de expedição; (v) previsão de faturamento; (vi) indicadores e relatórios; entre outros.

### **6.3 PRINCIPAIS DIFICULDADES E LIMITAÇÕES DA PESQUISA**

As principais dificuldades encontradas na realização da pesquisa foram: (i) obtenção de dados reais de demandas de transportes, superado pela concessão de dados de uma transportadora brasileira representativa no mercado; (ii) o

aumento exponencial dos tempos de processamento da LSTM ao se avaliar outros hiperparâmetros, o que limitou o conjunto de hiperparâmetros avaliados; (iii) obtenção de dados de demanda de transportes em longos períodos de tempo. (iv) a interpretação e manipulação de uma massa de uma quantidade de 86 conjuntos de dados, sendo necessário organização e estruturar os resultados de forma que sejam acessíveis para análise e comparação; (v) os trabalhos correlacionados, o que leva a buscar referências de outras cadeias ou aplicações e (vi) recursos computacionais para processamento dos dados e treinamento dos modelos, que exige capacidade computacional, que possui um custo elevado, sendo necessário utilizar computadores com recursos que tornam o processo longo.

Em complemento aos demais pontos mencionados, destaca-se a implementação dos modelos, especificamente o LSTM, que é um modelo que possui múltiplas arquiteturas, bibliotecas de implementação e variações. É um modelo que não é de entendimento trivial e exige dedicação em pesquisas, exercícios e técnicas de programação, que podem ser barreiras para alguns pesquisadores que não possuem familiaridade com o tema e/ou tecnologia. Além disso, para o uso de LSTM em Python, é necessário que sejam criadas estruturas de dados multidimensionais que são de difícil interpretação.

O cenário que avaliou as variáveis exógenas também exigiu diversas modificações no código-fonte que implementa os modelos, como inclusão de nova variável no modelo, mudanças no cálculo de métricas, transformação e normalização de dados.

Dentre as limitações encontradas na pesquisa, podem-se destacar: (i) os valores utilizados em cada hiperparâmetro, definindo uma faixa e validando um conjunto de valores, devido ao tempo de processamento; (ii) os hiperparâmetros avaliados, apesar de serem validados os que são destacados na literatura, existem outros hiperparâmetros que podem trazer alguma influência nos resultados; (iii) utilização de bibliotecas que auxiliam na implementação dos modelos, reduzindo a capacidade em personalizar os modelos; (iv) tamanho dos conjuntos de dados, limitados a dois anos e (v) conjunto de dados referente a uma única empresa do setor de transportes.

## 6.4 TRABALHOS FUTUROS

Trabalhos futuros que complementam a presente pesquisa recomendados são relacionados: (i) a implementação de heurísticas, como algoritmos genéticos, para treinamento e seleção dos hiperparâmetros; (ii) a implementação de outros modelos de, como GRU e SVM;(iii) aos tipos de redes LSTM, como *Stacked LSTM*, *Bidirectional LSTM*, *CNN LSTM*; (iv) à exploração de outros tratamentos para os *outliers*, como *autoencoder*, buscando reduzir o seu impacto nos resultados finais e na identificação de tendências pelos modelos; e (v) a exploração de outras formas de validação cruzada, como *Block Cross-Validation* e distribuições entre os conjuntos de treinamento, validação e testes.

Além disso, algumas das limitações poderão ser exploradas a fim de verificar o impacto e de que maneira poderiam influenciar nos resultados, como a avaliação de outros hiperparâmetros, conjuntos de dados maiores e também provenientes de outras fontes.

## 6.5 CONSIDERAÇÕES FINAIS

Este trabalho contribui para o ampliar o estado da arte em previsões de demandas em cadeias de suprimentos, no qual foram identificadas lacunas e poucas publicações, estendendo o conhecimento e a prática para pesquisas nesse segmento.

O aprendizado de máquina possibilitou que verificasse que podem ser aplicados no âmbito de transportes e que os resultados podem auxiliar em tomadas de decisões.

Espera-se que esta pesquisa contribua não somente para a academia, mas que também seja implementado, provendo informações, dados e conteúdos que auxiliem a evolução do tema em questão, através de novas pesquisas, evolução de modelos, arquiteturas e tecnologias.



## REFERÊNCIAS

ABBASIMEHR, Hossein; SHABANI, Mostafa; YOUSEFI, Mohsen. An optimized model using LSTM network for demand forecasting. **Computers and Industrial Engineering**, [S. l.], v. 143, 2020. DOI: 10.1016/j.cie.2020.106435. Disponível em: <https://doi.org/10.1016/j.cie.2020.106435>. Acesso em: 26 abr. 2021.

ABURTO, Luis; WEBER, Richard. Improved supply chain management based on hybrid demand forecasts. **Applied Soft Computing Journal**, [S. l.], v. 7, n. 1, p. 136–144, 2007. DOI: 10.1016/j.asoc.2005.06.001.

AHMED, Nesreen K.; ATIYA, Amir F.; EL GAYAR, Neamat; EL-SHISHINY, Hisham. An empirical comparison of machine learning models for time series forecasting. **Econometric Reviews**, [S. l.], v. 29, n. 5, p. 594–621, 2010. DOI: 10.1080/07474938.2010.481556.

AIASSI, Rouzbeh; SAJADI, Seyed Mojtaba; HADJI-MOLANA, Seyed Mohammad; ZAMANI-BABGOHARI, Ali. Designing a stochastic multi-objective simulation-based optimization model for sales and operations planning in built-to-order environment with uncertain distant outsourcing. **Simulation Modelling Practice and Theory**, [S. l.], v. 104, n. May, p. 102103, 2020. DOI: 10.1016/j.simpat.2020.102103. Disponível em: <https://doi.org/10.1016/j.simpat.2020.102103>. Acesso em: 20 out. 2020.

ASSOC ANASTASIA STEFANOVA KONDUKTOROVA, Bulgaria et al. ECONOMICS AND COMPUTER SCIENCE Научно списание A scientific journal. **ВАРНА, БЪЛГАРИЯ ELECTRONIC JOURNAL**, [S. l.], n. 2, 2021.

BABU, C. Narendra; REDDY, B. Eswara. A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data. **Applied Soft Computing Journal**, [S. l.], v. 23, p. 27–38, 2014. DOI: 10.1016/j.asoc.2014.05.028. Disponível em: <http://dx.doi.org/10.1016/j.asoc.2014.05.028>.

BALLOU, Ronald H. Necessidade de Previsão da Cadeia de Suprimentos. *In: Gerenciamento de Cadeia de Suprimentos/Logística Empresarial*. 5ª edição ed. [s.l: s.n.]. p. 241–269.

CARBONNEAU, Real; LAFRAMBOISE, Kevin; VAHIDOV, Rustam. **Application of machine learning techniques for supply chain demand forecasting**. 2008.

DOI: 10.1016/j.ejor.2006.12.004. Disponível em:  
[https://pdf.sciencedirectassets.com/271700/1-s2.0-S0377221707X05769/1-s2.0-S0377221706012057/main.pdf?X-Amz-Security-Token=IQoJb3JpZ2luX2VjEMn%2F%2F%2F%2F%2F%2F%2F%2F%2F%2FwEaCXVzLWVhc3QtMSJGMEQCIDmQla0lZyDXWbhHExGC%2FrYSkjiX3thvtsTkAbY31fJ8AiB0GPtHQSDkm2](https://pdf.sciencedirectassets.com/271700/1-s2.0-S0377221707X05769/1-s2.0-S0377221706012057/main.pdf?X-Amz-Security-Token=IQoJb3JpZ2luX2VjEMn%2F%2F%2F%2F%2F%2F%2F%2F%2F%2F%2FwEaCXVzLWVhc3QtMSJGMEQCIDmQla0lZyDXWbhHExGC%2FrYSkjiX3thvtsTkAbY31fJ8AiB0GPtHQSDkm2). Acesso em: 24 ago. 2020.

DOUGHERTY, Mark. A review of neural networks applied to transport. **Transportation Research Part C**, [S. l.], v. 3, n. 4, p. 247–260, 1995. DOI: 10.1016/0968-090X(95)00009-8.

EARLEY, Susan.; HENDERSON, Deborah. **DAMA-DMBOK: data management body of knowledge**. Second edition. ed. Basking Ridge, New Jersey: Technics Publications, 2017.

FANG-MEI, Tseng; HSIAO-CHENG, Yu; GWO-HSIUNG, Tzeng. Combining Neural Network Model with Seasonal Time Series ARIMA model. **Technological Forecasting and Social Change**, [S. l.], v. 69, n. 2002, p. 71–87, 2002.

FU, Wenhan; CHIEN, Chen Fu; LIN, Zih Hao. A hybrid forecasting framework with neural network and time-series method for intermittent demand in semiconductor supply chain. *In*: IFIP ADVANCES IN INFORMATION AND COMMUNICATION TECHNOLOGY 2018, **Anais [...]**. : Springer New York LLC, 2018. p. 65–72. DOI: 10.1007/978-3-319-99707-0\_9. Disponível em: [http://link.springer.com/10.1007/978-3-319-99707-0\\_9](http://link.springer.com/10.1007/978-3-319-99707-0_9). Acesso em: 22 fev. 2021.

GORGOLIS, Nikolaos; HATZILYGEROUDIS, Ioannis; ISTENES, Zoltan; GYENNE, Lazlo N. Gra. Hyperparameter Optimization of LSTM Network Models through Genetic Algorithm. *In*: 10TH INTERNATIONAL CONFERENCE ON INFORMATION, INTELLIGENCE, SYSTEMS AND APPLICATIONS, IISA 2019 2019, **Anais [...]**. : Institute of Electrical and Electronics Engineers Inc., 2019. DOI: 10.1109/IISA.2019.8900675.

HOCHREITER, Sepp; SCHMIDHUBER, Jürgen. Long Short-Term Memory. **Neural Computation**, [S. l.], v. 9, n. 8, p. 1735–1780, 1997. DOI: 10.1162/neco.1997.9.8.1735.

HOFMANN, Erik; RUTSCHMANN, Emanuel. Big data analytics and demand forecasting in supply chains: a conceptual analysis. **International Journal of**

**Logistics Management**, [S. l.], v. 29, n. 2, p. 739–766, 2018. DOI: 10.1108/IJLM-04-2017-0088. Disponível em: [www.emeraldinsight.com/0957-4093.htm](http://www.emeraldinsight.com/0957-4093.htm).

HU, Shiyuan; GAO, Jinliang; ZHONG, Dan; DENG, Liqun; OU, Chenhao; XIN, Ping. An Innovative Hourly Water Demand Forecasting Preprocessing Framework with Local Outlier Correction and Adaptive Decomposition Techniques. **Water** 2021, Vol. 13, Page 582, [S. l.], v. 13, n. 5, p. 582, 2021. DOI: 10.3390/W13050582. Disponível em: <https://www.mdpi.com/2073-4441/13/5/582/htm>. Acesso em: 2 abr. 2022.

JEENANUNTA, Chawalit; ABEYRATHNA, K. Darshana; DILHANI, M. H. M. R. Shyamali; HNIN, Su Wutyi; PHYO, Pyae Pyae. Time Series Outlier Detection for Short-Term Electricity Load Demand Forecasting. **INTERNATIONAL SCIENTIFIC JOURNAL OF ENGINEERING AND TECHNOLOGY (ISJET)**, [S. l.], v. 2, n. 1, p. 37–50, 2018. Disponível em: <https://ph02.tci-thaijo.org/index.php/isjet/article/view/175908>. Acesso em: 29 set. 2022.

KANTASA-ARD, Anirut; NOUIRI, Maroua; BEKRAR, Abdelghani; AIT EL CADI, Abdessamad; SALLEZ, Yves. Machine learning for demand forecasting in the physical internet: a case study of agricultural products in Thailand. **International Journal of Production Research**, [S. l.], v. 59, n. 24, p. 7491–7515, 2021. DOI: 10.1080/00207543.2020.1844332. Disponível em: <https://doi.org/00207543.2020.1844332>. Acesso em: 26 jan. 2021.

KARA, Yakup; ACAR BOYACIOGLU, Melek; BAYKAN, Ömer Kaan. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. **Expert Systems with Applications**, [S. l.], v. 38, n. 5, p. 5311–5319, 2011. DOI: 10.1016/J.ESWA.2010.10.027.

KOCHAK, Ashvin; SUMAN, Sharma. **Demand forecasting using neural network for supply chain management** *International Journal of Mechanical Engineering and Robotics Research*. [s.l.: s.n.]. Disponível em: [www.ijmerr.com](http://www.ijmerr.com). Acesso em: 24 ago. 2020.

LI, Wendi; WING, Wing W.; WANG, Ting; PELILLO, Marcello; KWONG, Sam. HELP: An LSTM-based approach to hyperparameter exploration in neural network learning. **Neurocomputing**, [S. l.], v. 442, p. 161–172, 2021. DOI:

10.1016/j.neucom.2020.12.133.

MAHBUB, Nafisa; PAUL, Sanjoy Kumar; AZEEM, Abdullahil. A neural approach to product demand forecasting. **International Journal of Industrial and Systems Engineering**, [S. l.], v. 15, n. 1, p. 1–18, 2013. DOI: 10.1504/IJISE.2013.055508.

MAMEDE, Fabio. Transportation demands of brazilian carrier in 2020 and 2021. [S. l.], 2022. DOI: 10.5281/ZENODO.7296555. Disponível em: <https://zenodo.org/record/7296555>. Acesso em: 6 nov. 2022.

MEMARZADEH, Gholamreza; KEYNIA, Farshid. A new short-term wind speed forecasting method based on fine-tuned LSTM neural network and optimal input sets. [S. l.], 2020. DOI: 10.1016/j.enconman.2020.112824. Disponível em: <https://doi.org/10.1016/j.enconman.2020.112824>.

MIAO, Xin; XI, Bao. Agile forecasting of dynamic logistics demand. **Transport**, [S. l.], v. 23, n. 1, p. 26–30, 2008. DOI: 10.3846/1648-4142.2008.23.26-30.

MIRCETIC, Dejan; NIKOLICIC, Svetlana; MASLARIC, Marinko; RALEVIC, Nebojsa; DEBELIC, Borna. Development of S-ARIMA Model for Forecasting Demand in a Beverage Supply Chain. **Open Engineering**, [S. l.], v. 6, n. 1, p. 407–411, 2016. DOI: 10.1515/eng-2016-0056. Disponível em: <https://www.degruyter.com/view/journals/eng/open-issue/article-10.1515-eng-2016-0056/article-10.1515-eng-2016-0056.xml>. Acesso em: 26 jan. 2021.

NEGAHBAN, A.; YILMAZ, L. Agent-based simulation applications in marketing research: An integrated review. **Journal of Simulation**, [S. l.], v. 8, n. 2, p. 129–142, 2014. DOI: 10.1057/JOS.2013.21.

NESPOLI, Alfredo; OGLIARI, Emanuele; PRETTO, Silvia; GAVAZZENI, Michele; VIGANI, Sonia; PACCANELLI, Franco. Electrical Load Forecast by Means of LSTM: The Impact of Data Quality. **Forecasting**, [S. l.], v. 3, n. 1, p. 91–101, 2021. DOI: 10.3390/forecast3010006.

NETO, J. T. C.; DE ANDRADE, P. H. M.; VILANUEVA, J. M.; SANTOS, F. A. O. Big data analytics of smart grids using artificial intelligence for the outliers correction at demand measurements. *In*: INSCIT 2018 - 3RD INTERNATIONAL SYMPOSIUM ON INSTRUMENTATION SYSTEMS, CIRCUITS AND

TRANSDUCERS: CHIP IN THE PAMPA 2018, **Anais [...]**. : Institute of Electrical and Electronics Engineers Inc., 2018. DOI: 10.1109/INSCIT.2018.8546718.

ÖMER FARUK, Durdu. A hybrid neural network and ARIMA model for water quality time series prediction. **Engineering Applications of Artificial Intelligence**, [S. l.], v. 23, n. 4, p. 586–594, 2010. DOI: 10.1016/j.engappai.2009.09.015.

POLOLA MAMEDE, Fabio. Transportation Demand Forecast. [S. l.], 2022. DOI: 10.5281/ZENODO.7296604. Disponível em: <https://zenodo.org/record/7296604>. Acesso em: 6 nov. 2022.

REN, Shuyun; CHOI, Tsan-Ming Ming; LEE, Ka-Man Man; LIN, Lei. Intelligent service capacity allocation for cross-border-E-commerce related third-party-forwarding logistics operations: A deep learning approach. **Transportation Research Part E: Logistics and Transportation Review**, [S. l.], v. 134, n. November 2019, p. 101834, 2020. DOI: 10.1016/j.tre.2019.101834. Disponível em: <https://doi.org/10.1016/j.tre.2019.101834>. Acesso em: 10 out. 2020.

SEYEDAN, Mahya; MAFAKHERI, Fereshteh. Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities. **Journal of Big Data**, [S. l.], v. 7, n. 1, 2020. DOI: 10.1186/s40537-020-00329-2. Disponível em: <https://doi.org/10.1186/s40537-020-00329-2>. Acesso em: 26 jan. 2021.

SEZER, Omer Berat; GUDELEK, Mehmet Ugur; OZBAYOGLU, Ahmet Murat. Financial time series forecasting with deep learning : A systematic literature review: 2005–2019. **Applied Soft Computing**, [S. l.], v. 90, p. 106181, 2020. DOI: 10.1016/J.ASOC.2020.106181.

SHIN, Dong Hoon; CHUNG, Kyungyong; PARK, Roy C. Prediction of Traffic Congestion Based on LSTM through Correction of Missing Temporal and Spatial Data. **IEEE Access**, [S. l.], v. 8, p. 150784–150796, 2020. DOI: 10.1109/ACCESS.2020.3016469.

TELLIS, Winston. Application of a Case Study Methodology. **The Qualitative Report**, [S. l.], v. 3, n. 3, p. 1–19, 1997. DOI: 10.46743/2160-3715/1997.2015. Disponível em: <https://doi.org/10.46743/2160-3715/1997.2015>. Acesso em: 26 jan. 2021.

VARGAS, C. A. González; ELIZONDO CORTÉS, M. Automobile spare-parts forecasting: A comparative study of time series methods. **International Journal of Automotive and Mechanical Engineering**, [S. l.], v. 14, n. 1, p. 3898–3912, 2017. DOI: 10.15282/ijame.14.1.2017.7.0317. Disponível em: <https://doi.org/10.15282/ijame.14.1.2017.7.0317>. Acesso em: 26 jan. 2021.

YAMAK, Peter T.; YUJIAN, Li; GADOSEY, Pius K. A Comparison between ARIMA, LSTM, and GRU for Time Series Forecasting. [S. l.], v. 7, 2019. DOI: 10.1145/3377713.3377722. Disponível em: <https://doi.org/10.1145/3377713.3377722>. Acesso em: 23 fev. 2021.

YUAN, Wen Jing; CHEN, Jian Hua; CAO, Jing Jing; JIN, Ze Yi. Forecast of Logistics Demand Based on Grey Deep Neural Network Model. **Proceedings - International Conference on Machine Learning and Cybernetics**, [S. l.], v. 1, p. 251–256, 2018. DOI: 10.1109/ICMLC.2018.8527006.

ZHANG, G. Peter; PATUWO, B. Eddy; HU, Michael Y. A simulation study of artificial neural networks for nonlinear time-series forecasting. **Computers and Operations Research**, [S. l.], v. 28, n. 4, p. 381–396, 2001. DOI: 10.1016/S0305-0548(99)00123-9.

ZHANG, G. Peter; QI, Min. Neural network forecasting for seasonal and trend time series. **European Journal of Operational Research**, [S. l.], v. 160, n. 2, p. 501–514, 2005. DOI: 10.1016/j.ejor.2003.08.037.

ZHANG, Peter G. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, [S. l.], v. 50, p. 159–175, 2003. DOI: 10.1016/S0925-2312(01)00702-0.

ZHU, Yangyong; XIONG, Yun. Defining Data Science. [S. l.], 2015. Disponível em: <http://arxiv.org/abs/1501.05039>. Acesso em: 22 out. 2022.