



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Mineração de Dados para Predição da Dispensação de Medicamentos do Componente Especializado da Assistência Farmacêutica no Sistema Único de Saúde

Renan Martins de Sousa

Dissertação apresentada como requisito parcial para conclusão do
Mestrado Profissional em Computação Aplicada

Orientador

Prof. Dr. Guilherme Novaes Ramos

Brasília
2019

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

MM386m Martins de Sousa, Renan
Mineração de Dados para Predição da Dispensação de Medicamentos do Componente Especializado da Assistência Farmacêutica no Sistema Único de Saúde / Renan Martins de Sousa; orientador Guilherme Novaes Ramos. -- Brasília, 2019. 191 p.

Dissertação (Mestrado - Mestrado Profissional em Computação Aplicada) -- Universidade de Brasília, 2019.

1. Assistência Farmacêutica. 2. Dispensação. 3. Mineração de Dados. 4. Séries Temporais. 5. Aprendizagem de Máquina. I. Novaes Ramos, Guilherme, orient. II. Título.



Universidade de Brasília

Instituto de Ciências Exatas
Departamento de Ciência da Computação

Mineração de Dados para Predição da Dispensação de Medicamentos do Componente Especializado da Assistência Farmacêutica no Sistema Único de Saúde

Renan Martins de Sousa

Dissertação apresentada como requisito parcial para conclusão do
Mestrado Profissional em Computação Aplicada

Prof. Dr. Guilherme Novaes Ramos (Orientador)
CIC/UnB

Prof. Dr. Donald Matthew Pianto Prof. Dr. Jhames Matos Sampaio
Universidade de Brasília Universidade de Brasília

Prof. Dr. Remis Balaniuk
Universidade Católica de Brasília

Prof.a Dr.a Aletéia Patrícia Favacho de Araújo
Coordenadora do Programa de Pós-graduação em Computação Aplicada

Brasília, 04 de julho de 2019

Dedicatória

Dedico este trabalho à minha família e a todos aqueles que dependem de uma gestão eficiente da Política Nacional de Assistência Farmacêutica.

Agradecimentos

A Deus, criador de todas as coisas e detentor de todo o saber.

Aos meus pais, que sempre fizeram um grande esforço para me proporcionar a melhor educação possível.

À minha esposa Roberta e à minha filha Laís, por suportarem os momentos de ausência.

Aos profissionais do Ministério da Saúde Jessé Azevedo, Heber Bernarde, Evandro Lupattini e Felipe Ferre, pela disponibilização dos dados da pesquisa e troca de informações a respeito da distribuição de medicamentos do Componente Especializado da Assistência Farmacêutica.

Ao Prof. Dr. Guilherme Novaes Ramos, pela diligente orientação, contribuindo de forma significativa para melhorar a qualidade desta pesquisa.

Ao Skander Hannachi, da Nordstrom Technology, pelas discussões e dicas a respeito da abordagem e métodos utilizados nesta pesquisa.

Aos colegas da turma do Programa de Pós-Graduação em Computação Aplicada (PPCA) do ano de 2017, pelo apoio e troca de experiências.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES), pela disponibilização do Acesso ao Portal de Periódicos.

Agradecimento Especial

Ao Ministro do Tribunal de Contas da União, Aroldo Cedraz de Oliveira, pelo permanente entusiasmo e encorajamento em relação ao uso da inteligência computacional aplicada ao controle externo, e, em especial, pelo incondicional e pronto apoio para a realização desta pesquisa.

Resumo

A Política Nacional de Assistência Farmacêutica é uma ação de saúde pública de extrema relevância e materialidade. Esta pesquisa propõe a utilização de algoritmos de mineração de dados para previsão de séries temporais dos medicamentos do subgrupo 1A do Componente Especializado da Assistência Farmacêutica (CEAF), de modo a estimar as quantidades que devem ser distribuídas trimestralmente às Secretarias Estaduais de Saúde. Comparados diversos métodos de previsão, entre modelos estatísticos tradicionais e um modelo de rede neural recorrente do estado da arte, os resultados demonstraram que a substituição do atual método de previsão utilizado pelo Ministério da Saúde por outros métodos apresentados nesta pesquisa, cujas implementações estão disponíveis na forma de uma contribuição tecnológica, teria gerado uma economia potencial de mais de R\$ 26 milhões e evitado o desabastecimento de mais de 4 milhões de unidades dos mais variados medicamentos, em um exame agregado para nove Estados da Federação nos três primeiros trimestres do ano de 2018. A comparação com outros modelos de previsão, o aperfeiçoamento do modelo de rede neural proposto, assim como a utilização desses modelos para outros medicamentos e Estados, têm o potencial de afetar de forma relevante a gestão dessa política pública de saúde, contribuindo, entre outros resultados, para uma melhor alocação de recursos públicos federais.

Palavras-chave: assistência farmacêutica, mineração de dados, previsão, dispensação, séries temporais

Abstract

The National Policy on Pharmaceutical Assistance is a public health action of extreme relevance. This research proposes the use of data mining for forecasting drugs' time series of the Specialized Component of Pharmaceutical Assistance (CEAF), in order to forecast quarterly drug distribution across the different states in Brazil. The comparison of various prediction methods – among traditional statistical ones and a state-of-art recurrent neural network model – demonstrated that replacing the current Ministry of Health forecasting method could have generated potential savings of more than R\$ 26 million and avoided the shortage of more than 4 million units of several drugs in an aggregated analysis for nine selected states. The comparison with other models, improvements on the proposed neural network model, as well as the use of such models for other medicines and states could help to maintain the right inventory levels and significantly reduce the amount of resources allocated to drug distribution, improving the management of this public health policy.

Keywords: pharmaceutical care, data mining, forecasting, dispensing, time-series

Sumário

1	Introdução	1
1.1	Problema de Pesquisa	1
1.2	Justificativa	6
1.3	Objetivo Geral	7
1.4	Objetivos Específicos	8
2	Fundamentação Teórica	9
2.1	A previsão de demanda de medicamentos	9
2.2	Revisão do estado da arte	11
2.3	Previsão de séries temporais	16
2.3.1	Conceitos fundamentais	16
2.3.2	Perspectiva estatística da previsão	19
2.3.3	Diagnóstico do ajuste dos modelos	21
2.4	Métodos e Modelos de previsão de séries temporais	22
2.4.1	<i>Naïve</i> e <i>Seasonal Naïve</i>	22
2.4.2	Suavização exponencial	22
2.4.3	Método <i>Theta</i>	26
2.4.4	Modelo de suavização exponencial em espaço de estados	28
2.4.5	Modelo autoregressivo integrado de médias móveis	31
2.4.6	Redes Neurais <i>Long Short Term Memory</i> (LSTM)	37
3	Metodologia de Pesquisa e Análise dos Resultados	45
3.1	Modelo de referência CRISP-DM	45
3.2	Entendimento do negócio	47
3.3	Entendimento dos dados	49
3.4	Preparação dos dados	56
3.5	Modelagem	59
3.5.1	Ferramentas e Recursos Utilizados	60
3.5.2	Implementação dos modelos estatísticos tradicionais	60

3.5.3	Implementação da rede neural LSTM proposta	62
3.5.4	Modelos Vencedores e Programações Automatizadas	66
3.5.5	Resultados	68
3.6	Avaliação	121
3.7	Implantação	122
4	Conclusões e Trabalhos Futuros	123
4.1	Conclusões	123
4.2	Trabalhos Futuros	125
	Referências	127
	Apêndice	133
A	Resultados das Programações Automatizadas	134
A.1	Distrito Federal	134
A.2	Ceará	137
A.3	Pernambuco	140
A.4	Alagoas	143
A.5	Amapá	146
A.6	Tocantins	147
A.7	Pará	149
A.8	Rio Grande do Norte	153
A.9	Paraíba	155
B	Código R (modelos estatísticos tradicionais)	159
C	Código Python (Rede LSTM)	166

Lista de Figuras

1.1	Desperdício dos medicamentos do CEAF no Brasil. Fonte: BBC Brasil, disponível em http://www.bbc.com/portuguese/brasil-41007650	4
2.1	Arquitetura básica de uma rede neural recorrente.	38
2.2	Diagrama de blocos de uma célula LSTM.	40
2.3	Arquitetura codificador-decodificador para mapeamento de entre sequências de tamanho diferentes. Fonte: [1].	42
3.1	Ciclo de vida de projetos de mineração de dados segundo o CRISP-DM.	46
3.2	Base Nacional de Dados de Ações e Serviços da Assistência Farmacêutica.	47
3.3	Cálculo da programação trimestral dos medicamentos do CEAF pelo Ministério da Saúde para o primeiro trimestre (T1/2018).	49
3.4	Quantidade de medicamentos do CEAF na base de dados por UF.	53
3.5	Quantidade de séries por número de observações por UF.	54
3.6	Valores faltantes (em vermelho) das séries de 4 medicamentos distribuídos no Distrito Federal.	55
3.7	Quantidade de medicamentos selecionados para a fase de modelagem, por UF.	57
3.8	Séries temporais de quantidades dispensadas de 4 medicamentos selecionados para a fase de modelagem.	58
3.9	Arquitetura Codificador-Decodificador da rede neural LSTM.	62
3.10	Formatação dos dados para treinamento e teste do modelo LSTM para os 3 medicamentos do Estado do Amapá.	64
3.11	Abordagem de previsão com rede LSTM (codificador-decodificador) multivariada de múltiplas entradas.	65
3.12	Contagem dos modelos vencedores em cada trimestre de 2018 para o DF, desconsiderando os empates.	69
3.13	Contagem dos modelos vencedores em cada trimestre de 2018 para o CE, desconsiderando os empates.	73

3.14	Contagem dos modelos vencedores em cada trimestre de 2018 para PE, desconsiderando os empates.	77
3.15	Contagem dos modelos vencedores em cada trimestre de 2018 para AL, desconsiderando os empates.	80
3.16	Contagem dos modelos vencedores em cada trimestre de 2018 para AP, desconsiderando os empates.	85
3.17	Contagem dos modelos vencedores em cada trimestre de 2018 para TO, desconsiderando os empates.	87
3.18	Contagem dos modelos vencedores em cada trimestre de 2018 para o PA, desconsiderando os empates.	90
3.19	Contagem dos modelos vencedores em cada trimestre de 2018 para o RN, desconsiderando os empates.	95
3.20	Contagem dos modelos vencedores em cada trimestre de 2018 para a PB, desconsiderando os empates.	99

Lista de Tabelas

2.1	Classificação dos métodos de suavização exponencial segundo a a configuração das componentes de tendência e sazonalidade	25
3.1	Exemplos de medicamentos do CEAF	54
3.2	Estratégia de <i>holdout</i> para validação por trimestre de 2018	59
3.3	Funções do pacote <i>forecast</i> para ajuste dos modelos	60
3.4	Características do modelo LSTM multivariado implementado na pesquisa .	65
3.5	Erro absoluto médio do modelo vencedor para os medicamentos do DF, por trimestre	70
3.6	Comparação entre os erros do modelo LSTM e do segundo colocado para o DF - T1 (2018)	71
3.7	Comparação entre os erros do modelo LSTM e do segundo colocado para o DF - T2 (2018)	71
3.8	Comparação entre os erros do modelo LSTM e do segundo colocado para o DF - T3 (2018)	72
3.9	Erro absoluto médio do modelo vencedor para os medicamentos do CE, por trimestre	74
3.10	Comparação entre os erros do modelo LSTM e do segundo colocado para o CE - T1 (2018)	75
3.11	Comparação entre os erros do modelo LSTM e do segundo colocado para o CE - T2 (2018)	76
3.12	Comparação entre os erros do modelo LSTM e do segundo colocado para o CE - T3 (2018)	76
3.13	Erro absoluto médio do modelo vencedor para os medicamentos de PE, por trimestre	78
3.14	Comparação entre os erros do modelo LSTM e do segundo colocado para PE - T1 (2018)	79
3.15	Comparação entre os erros do modelo LSTM e do segundo colocado para o PE - T2 (2018)	79

3.16	Comparação entre os erros do modelo LSTM e do segundo colocado para PE - T3 (2018)	80
3.17	Erro absoluto médio do modelo vencedor para os medicamentos de AL, por trimestre	82
3.18	Comparação entre os erros do modelo LSTM e do segundo colocado para AL - T1 (2018)	83
3.19	Comparação entre os erros do modelo LSTM e do segundo colocado para AL - T2 (2018)	83
3.20	Comparação entre os erros do modelo LSTM e do segundo colocado para AL - T3 (2018)	84
3.21	Erro absoluto médio do modelo vencedor para os medicamentos do AP, por trimestre	85
3.22	Comparação entre os erros do modelo LSTM e do segundo colocado para o AP - T1 (2018)	86
3.23	Comparação entre os erros do modelo LSTM e do segundo colocado para o AP - T2 (2018)	86
3.24	Comparação entre os erros do modelo LSTM e do segundo colocado para o AP - T3 (2018)	86
3.25	Erro absoluto médio do modelo vencedor para os medicamentos de TO, por trimestre	88
3.26	Comparação entre os erros do modelo LSTM e do segundo colocado para o TO - T1 (2018)	88
3.27	Comparação entre os erros do modelo LSTM e do segundo colocado para o TO - T2 (2018)	89
3.28	Comparação entre os erros do modelo LSTM e do segundo colocado para o TO - T3 (2018)	89
3.29	Erro absoluto médio do modelo vencedor para os medicamentos do PA, por trimestre	91
3.30	Comparação entre os erros do modelo LSTM e do segundo colocado para o PA - T1 (2018)	92
3.31	Comparação entre os erros do modelo LSTM e do segundo colocado para o PA - T2 (2018)	93
3.32	Comparação entre os erros do modelo LSTM e do segundo colocado para o PA - T3 (2018)	94
3.33	Erro absoluto médio do modelo vencedor para os medicamentos do RN, por trimestre	96

3.34	Comparação entre os erros do modelo LSTM e do segundo colocado para o RN - T1 (2018)	97
3.35	Comparação entre os erros do modelo LSTM e do segundo colocado para o RN - T2 (2018)	97
3.36	Comparação entre os erros do modelo LSTM e do segundo colocado para o RN - T3 (2018)	98
3.37	Erro absoluto médio do modelo vencedor para os medicamentos da PB, por trimestre	100
3.38	Comparação entre os erros do modelo LSTM e do segundo colocado para a PB - T1 (2018)	101
3.39	Comparação entre os erros do modelo LSTM e do segundo colocado para a PB - T2 (2018)	101
3.40	Comparação entre os erros do modelo LSTM e do segundo colocado para a PB - T3 (2018)	102
3.41	Comparação entre os modelos para programações acima da demanda no Distrito Federal - T1 (2018)	104
3.42	Comparação entre os modelos para programações acima da demanda no Distrito Federal - T2 (2018)	104
3.43	Comparação entre os modelos para programações acima da demanda no Distrito Federal - T3 (2018)	105
3.44	Medicamentos para os quais se evitaria o desabastecimento no Distrito Federal, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)	105
3.45	Comparação entre os modelos para programações acima da demanda no CE - T3 (2018)	106
3.46	Comparação entre os modelos para programações acima da demanda no CE - T3 (2018)	106
3.47	Comparação entre os modelos para programações acima da demanda no CE - T3 (2018)	107
3.48	Medicamentos para os quais se evitaria o desabastecimento no Ceará, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018) 107	107
3.49	Comparação entre os modelos para programações acima da demanda em PE - T1 (2018)	108
3.50	Comparação entre os modelos para programações acima da demanda em PE - T2 (2018)	108
3.51	Comparação entre os modelos para programações acima da demanda em PE - T3 (2018)	109

3.52	Medicamentos para os quais se evitaria o desabastecimento em Pernambuco, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)	109
3.53	Comparação entre os modelos para programações acima da demanda em AL - T1 (2018)	110
3.54	Comparação entre os modelos para programações acima da demanda em AL - T2 (2018)	111
3.55	Comparação entre os modelos para programações acima da demanda em AL - T3 (2018)	111
3.56	Medicamentos para os quais se evitaria o desabastecimento em Alagoas, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)	112
3.57	Comparação entre os modelos para programações acima da demanda no AP - T3 (2018)	112
3.58	Comparação entre os modelos para programações acima da demanda em TO - T2 (2018)	113
3.59	Comparação entre os modelos para programações acima da demanda em TO - T3 (2018)	113
3.60	Medicamentos para os quais se evitaria o desabastecimento em Tocantins, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)	114
3.61	Comparação entre os modelos para programações acima da demanda no PA - T2 (2018)	114
3.62	Comparação entre os modelos para programações acima da demanda no PA - T3 (2018)	115
3.63	Medicamentos para os quais se evitaria o desabastecimento no Pará, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)	115
3.64	Comparação entre os modelos para programações acima da demanda no Rio Grande do Norte - T2 (2018)	116
3.65	Comparação entre os modelos para programações acima da demanda no Rio Grande do Norte - T3 (2018)	116
3.66	Medicamentos para os quais se evitaria o desabastecimento no Rio Grande do Norte, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)	117
3.67	Comparação entre os modelos para programações acima da demanda na Paraíba - T2 (2018)	117

3.68	Comparação entre os modelos para programações acima da demanda na Paraíba - T3 (2018)	118
3.69	Medicamentos para os quais se evitaria o desabastecimento na Paraíba, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)	118
3.70	Percentual dos modelos LSTM e ARIMA, quando considerados vencedores, por trimestre de 2018 e por Estado	119
3.71	Estatísticas da distribuição da redução percentual dos erros de previsão da rede LSTM, em relação ao segundo melhor modelo (T3/2018)	119
3.72	Quantidade de medicamentos além da necessidade real cuja distribuição poderia ter sido evitada (e respectiva economia potencial), caso tivesse sido utilizado o modelo da pesquisa	120
3.73	Desabastecimento que seria potencialmente evitado pelo uso do modelo da pesquisa	121
A.1	Programações automatizadas (DF) - T1/2018	134
A.2	Programações automatizadas (DF) - T2/2018	135
A.3	Programações automatizadas (DF) - T3/2018	136
A.4	Programações automatizadas (CE) - T1/2018	137
A.5	Programações automatizadas (CE) - T2/2018	138
A.6	Programações automatizadas (CE) - T3/2018	139
A.7	Programações automatizadas (PE) - T1/2018	140
A.8	Programações automatizadas (PE) - T2/2018	141
A.9	Programações automatizadas (PE) - T3/2018	142
A.10	Programações automatizadas (AL) - T1/2018	143
A.11	Programações automatizadas (AL) - T2/2018	144
A.12	Programações automatizadas (AL) - T3/2018	145
A.13	Programações automatizadas (AP) - T1/2018	147
A.14	Programações automatizadas (AP) - T2/2018	147
A.15	Programações automatizadas (AP) - T3/2018	147
A.16	Programações automatizadas (TO) - T1/2018	147
A.17	Programações automatizadas (TO) - T2/2018	148
A.18	Programações automatizadas (TO) - T3/2018	149
A.19	Programações automatizadas (PA) - T1/2018	149
A.20	Programações automatizadas (PA) - T2/2018	151
A.21	Programações automatizadas (PA) - T3/2018	152
A.22	Programações automatizadas (RN) - T1/2018	153
A.23	Programações automatizadas (RN) - T2/2018	154

A.24	Programações automatizadas (RN) - T3/2018	155
A.25	Programações automatizadas (PB) - T1/2018	156
A.26	Programações automatizadas (PB) - T2/2018	157
A.27	Programações automatizadas (PB) - T3/2018	158

Lista de Abreviaturas e Siglas

ANN Artificial Neural Networks.

APAC Autorizações de Procedimentos de Alta Complexidade/Custo.

ARIMA Autoregressive Integrated Moving Average.

ARIMA-MS Modelo ARIMA utilizado atualmente pelo Ministério da Saúde.

BNAFAR Base Nacional de Dados de Ações e Serviços da Assistência Farmacêutica.

BNN Bayesian Neural Network.

BPTT Backpropagation Through Time.

CART CART Regression Trees.

CATMAT Catálogo de Materiais e Serviços.

CEAF Componente Especializado da Assistência Farmacêutica.

CGU Controladoria Geral da União.

CID-10 Classificação Estatística Internacional de Doenças e Problemas à Saúde.

CRISP-DM Cross Industry Standard Process for Data Mining.

CRM Conselho Regional de Medicina.

DNN Deep Neural Networks.

EA Evolutionary Algorithms.

EAKF Ensembled Adjustment Kalman Filter.

ESN Echo State Networks.

ETS State Space Exponential Smoothing.

FFORMA Feature-based Forecast Model Averaging.

GARCH Autoregressive Conditional Heterocedasticity.

GP Gaussian Processes.

GRNN Generalized Regression Neural Networks.

KNN K-Nearest Neighbor Regression.

LSTM Long Short Term Memory.

MLP Multi-Layer Perceptron.

MPF Ministério Público Federal.

OMS Organização Mundial de Saúde.

PATMM Programação Automatizada do Melhor Modelo da Pesquisa.

PATMS Programação Automatizada do Modelo ARIMA-MS.

PCDT Protocolos Clínicos e Diretrizes Teraupêticas.

QRDM Quantidade Realmente Dispensada do Medicamento.

RAF Random Forest.

RBF Radial Basis Functions.

RENAME Relação Nacional de Medicamentos Essenciais.

RNN Recurrent Neural Networks.

SARIMA Seasonal Autoregressive Integrated Moving Average.

SCTIE Secretaria de Ciência, Tecnologia e Insumos Estratégicos.

SEATS Seasonal Extraction in ARIMA Time Series.

SES Simple Exponential Smoothing.

SGD Stochastic Gradient Descent.

SIA/SUS Sistema de Informações Ambulatoriais.

SMBO Sequential Model-Based Optimization.

STLM STL Method.

SUS Sistema Único de Saúde.

SVM Supporting Vector Machines.

SVR Support Vector Regression.

TCU Tribunal de Contas da União.

TDNN Time Delay Neural Networks.

Capítulo 1

Introdução

Este capítulo apresenta o problema proposto como tema da pesquisa de mestrado, abordando sua definição e justificativa. Em seguida, são detalhados os objetivos e as contribuições esperadas.

1.1 Problema de Pesquisa

O acesso aos medicamentos essenciais constitui um dos eixos norteadores da Política Nacional de Medicamentos [2] e da Política Nacional de Assistência Farmacêutica [3]. Os medicamentos são a intervenção terapêutica mais utilizada e constituem uma tecnologia que exerce alto impacto sobre os gastos em saúde. Portanto, é fundamental para o Sistema Único de Saúde (SUS) que o processo de sua incorporação esteja baseado em critérios que possibilitem à população o acesso a medicamentos mais seguros, eficazes e equilibrados em termos de custo-efetividade, para atendimento aos principais problemas de saúde dos cidadãos brasileiros [4]. Por essa razão é que o Ministério da Saúde reafirma a relevância da Relação Nacional de Medicamentos Essenciais (RENAME), um elemento técnico-científico que orienta a oferta, a prescrição e a dispensação de medicamentos nos serviços do SUS.

Entre as diversas ações constantes do Orçamento da União, destaca-se a *Ação 4705 – Apoio Financeiro para Aquisição e Distribuição dos Medicamentos do Componente Especializado da Assistência Farmacêutica*. O Componente Especializado da Assistência Farmacêutica (CEAF) é uma das estratégias de acesso aos medicamentos no âmbito do SUS que busca garantir a integralidade do tratamento medicamentoso, em nível ambulatorial, para algumas situações clínicas, principalmente agravos crônicos, com custos de tratamento mais elevados ou de maior complexidade. Nesse componente, o acesso aos medicamentos ocorre de acordo com critérios definidos em protocolos clínicos e diretrizes terapêuticas (PCDTs) publicados pelo Ministério da Saúde. Os PCDTs definem as linhas de cuidado

para cada condição clínica, indicando a melhor abordagem terapêutica em cada situação, com base nas melhores evidências disponíveis [4].

A Portaria GM/MS nº 1.554, de 30 de julho de 2013, dispõe sobre as regras de financiamento e execução do CEAF no âmbito do SUS, e divide os medicamentos desse componente em três grupos, definindo as responsabilidades de financiamento entre os entes federados [5]:

- Grupo 1: medicamentos sob responsabilidade de financiamento do Ministério da Saúde, subdividido em:

Grupo 1A: medicamentos de aquisição centralizada pelo Ministério da Saúde e fornecidos às Secretarias de Saúde dos Estados e do Distrito Federal;

Grupo 1B: medicamentos financiados pelo Ministério da Saúde mediante transferência de recursos para aquisição pelas Secretarias de Saúde dos Estados e do Distrito Federal;

- Grupo 2: medicamentos financiados e adquiridos pelas Secretarias de Saúde dos estados e do Distrito Federal;
- Grupo 3: medicamentos financiados de acordo com as normativas do Componente Básico da Assistência Farmacêutica e indicados pelos PCDTs como a primeira linha de cuidado para o tratamento das doenças contempladas no CEAF.

Nos últimos anos, o Tribunal de Contas da União (TCU) já vem realizando vários trabalhos onde a sistemática de distribuição dos medicamentos custeados com recursos federais foi criticada, em virtude de impropriedades e oportunidades de melhoria detectadas, sobretudo no que diz respeito à estimativa de demanda, de modo a definir o quantitativo a ser enviado às unidades estaduais de saúde.

O Relatório Sistêmico de Fiscalização da Saúde consolidou diversos trabalhos realizados pela Corte de Contas na área da Saúde Pública [6]. No que concerne ao fornecimento de insumos e medicamentos, foram feitos vários apontamentos, por exemplo: (i) inadequação do quantitativo de diversos medicamentos; (ii) identificação intempestiva dos baixos volumes de estoques até a perda de validade por falhas de distribuição; (iii) dificuldade para prever o consumo e (iv) deficiências no que diz respeito à elaboração de estimativas dos medicamentos com base no consumo efetivo. Apontou ainda como fundamental que o gestor conhecesse a demanda das unidades a serem abastecidas.

Dentre os trabalhos consolidados, alguns fizeram menção a perdas de medicamentos, compras desnecessárias e ausência de planejamento das aquisições de medicamentos do CEAF [7, 8]. Em auditoria realizada na execução de convênios firmados com o Ministério da Saúde para adquirir medicamentos em municípios no Estado de São Paulo, O

TCU expediu recomendação para que fosse elaborada uma metodologia para programar a aquisição dos medicamentos, em que fossem considerados o perfil epidemiológico local, doenças prevalentes, consumo da população, sazonalidades, estoques mínimos e máximo, tempo de reposição e demandas não atendidas [9].

Em outra fiscalização, o TCU determinou ao Ministério da Saúde que apurasse perdas de medicamentos adquiridos com recursos federais pelo Estado de Mato Grosso e pelo próprio Ministério da Saúde, bem como as respectivas responsabilidades, caso a caso, providenciando os ressarcimentos devidos e instaurando, se necessário, os respectivos processos de busca de reparação dos danos causados aos cofres públicos [10].

A Controladoria Geral da União (CGU), em 2017, publicou relatório¹ abrangente sobre o tema. O objetivo foi analisar a confiabilidade dos sistemas de informação utilizados, a conformidade na programação (demanda) e entrega de remédios, o monitoramento de controles de armazenamento, validade e distribuição dos insumos, entre outras questões.

O relatório da CGU consolidou dados obtidos em nível federal, na Secretaria de Ciência, Tecnologia e Insumos Estratégicos (SCTIE), do Ministério da Saúde, e em 25 Secretarias Estaduais de Saúde. Foi constatado que o monitoramento e o controle realizados pelo Ministério da Saúde junto às Secretarias Estaduais de Saúde eram incipientes ou ausentes. Foram apontadas diversas oportunidades de melhoria na distribuição desses medicamentos, a exemplo da necessidade de ajustar divergências nos quantitativos de medicamentos distribuídos, a fim de evitar aquisições mal dimensionadas e inconsistências nas programações anuais que contribuem para a perda de medicamentos [11].

Em 28/8/2017, a BBC Brasil publicou matéria² sintetizando a referida auditoria da CGU, na qual revelou que 11 Estados e o Distrito Federal desperdiçaram, entre 2014 e 2015, R\$ 16 milhões em remédios, por validade vencida e armazenagem incorreta. A Figura 1.1 apresenta um mapa do desperdício dos medicamentos do CEAF por estado da federação, onde a cor mais escura denota maior desperdício, segundo a referida matéria.

Além de diversas notícias veiculadas em meios de comunicação escritos e televisivos, o Ministério Público Federal (MPF) tem apontado a falta e o desperdício de medicamentos do CEAF, situações que têm sido objeto de diversas denúncias e investigações por parte daquele órgão, a exemplo das seguintes apurações, obtidas por meio da ferramenta de busca do sítio do MPF³ usando o termo de busca “CEAF”:

- SAÚDE. MEDICAMENTO BEZAFIBRATO. NÃO FORNECIMENTO PELO CR/DST/AIDS DE SANTO AMARO, VINCULADO À SECRETARIA MUNICIPAL DE SAÚDE DE SÃO PAULO (SMS/SP). MEDICAMENTO DISPONIBILI-

¹<https://tinyurl.com/ybo8jgg5>

²<http://www.bbc.com/portuguese/brasil-41007650>

³<http://www.mpf.br/@search?path=&SearchableText=CEAF>



Figura 1.1: Desperdício dos medicamentos do CEAF no Brasil. Fonte: BBC Brasil, disponível em <http://www.bbc.com/portuguese/brasil-41007650>.

ZADO PELO COMPONENTE ESPECIALIZADO DA ASSISTÊNCIA FARMACÊUTICA (CEAF), A CARGO DO ESTADO DE SÃO PAULO. DISPONIBILIZAÇÃO NO PAM- VÁRZEA DO CARMO (POSTO ESTADUAL). AUSÊNCIA DE IRREGULARIDADES. ARQUIVAMENTO. VOTO PELA HOMOLOGAÇÃO. INQUÉRITO CIVIL n° 1.34.001.004894/2014-77⁴.

- SAÚDE. FALTA DE MEDICAMENTOS DE ALTO CUSTO NA REDE PÚBLICA: LEFLUNOMIDA (20 MG) E METOTREXATO (25 MG). DESABASTECIMENTO PONTUAL E TEMPORÁRIO. ESTOQUE NORMALIZADO NA SECRETARIA DE ESTADO DA SAÚDE DE SÃO PAULO. ARQUIVAMENTO. VOTO PELA HOMOLOGAÇÃO. INQUÉRITO CIVIL n° 1.34.001.000392/2016-39⁵.
- DENÚNCIA. FALTA DE MEDICAMENTOS PARA O MAL DE ALZHEIMER NA FARMÁCIA DE MEDICAÇÃO DE ALTO CUSTO DE JUNDIAÍ. DISPENSAÇÃO NORMALIZADA. VOTO PELA HOMOLOGAÇÃO DO ARQUIVAMENTO. POR UNANIMIDADE, FOI HOMOLOGADO O ARQUIVAMENTO. PROCEDIMENTO PREPARATÓRIO n° 1.34.021.000202/2015-64⁶.
- SAÚDE. FORNECIMENTO DE ENOXAPARINA SÓDICA NA REDE PÚBLICA DE SAÚDE. NOTA TÉCNICA CONTRÁRIA DO CONITEC. ARQUIVAMENTO. FATOS JÁ DEBATIDOS EM AÇÕES PROMOVIDAS PELO MINISTÉRIO PÚBLICO FEDERAL E PELA DEFENSORIA PÚBLICA DO ESTADO DE MATO GROSSO DO SUL. VOTO PELA HOMOLOGAÇÃO DO ARQUIVAMENTO. POR

⁴<https://tinyurl.com/y84tbh8mr>

⁵<https://tinyurl.com/y885eza4>

⁶<https://tinyurl.com/ya6kecne>

UNANIMIDADE, FOI HOMOLOGADO O ARQUIVAMENTO. INQUÉRITO CIVIL nº 1.21.005.000112/2013-68⁷.

- PROCURADORIA DA REPÚBLICA EM SANTA MARIA/RS. RESOLVE INSTAURAR INQUÉRITO CIVIL, COM ARRIMO NO ART. 4º, § 4º, DA RESOLUÇÃO CSMPF nº 87/2010 E NO ART. 2º, § 7º, DA RESOLUÇÃO CNMP nº 23/2007, VINCULADO À PROCURADORIA FEDERAL DOS DIREITOS DO CIDADÃO DO MINISTÉRIO PÚBLICO FEDERAL–PFDC/MPF, TENDO POR OBJETO APURAR A NOTÍCIA DE POSSÍVEL FALTA DE MEDICAMENTOS PARA TRATAMENTO DE PORTADORES DE HEPATITE C. PORTARIA DE INSTAURAÇÃO nº 104/2016/BP⁸.

O Ministério Público do Distrito Federal, em 2017, deflagrou uma operação denominada Custo Alto⁹, tendo como um de seus objetivos o de vistoriar o fluxo de fornecimento de remédios, como armazenamento, estoque, programação, aquisição e dispensação. A ação faz parte das investigações de inquérito civil público aberto para apurar irregularidades nas farmácias de alto custo do Distrito Federal. A primeira fase foi realizada em uma Farmácia de Alto Custo da Asa Sul, em Brasília, e, durante a vistoria, foram encontrados medicamentos com validade expirada, o que denota o desperdício de medicamentos que compõe o CEAF.

Além do desperdício, a falta de medicamentos também é um problema muito relevante. As doenças contempladas nas linhas de tratamento dos medicamentos do CEAF são aquelas importantes do ponto de vista clínico-epidemiológico, envolvendo algumas doenças raras e de baixa prevalência ou que demandam medicamentos de uso prolongado, alguns destes com alto custo unitário, a exemplo da Asma, Doença de Alzheimer, Esclerose Múltipla, Esquizofrenia, Dor Crônica, Dislipidemia, Transplante de órgãos, Glaucoma e Insuficiência Renal Crônica.

Em março de 2018¹⁰ foi noticiada a morte de um paciente acometido da doença rara HPN (Hemoglobinúria Paroxística Noturna), que deixou de receber o medicamento de alto custo cujo recebimento lhe havia sido garantido por decisão judicial prolatada na Ação Ordinária nº 25060-67.2015.4.01.3400, em trâmite na Justiça Federal da 1ª Região. Embora não se trate de um medicamento que oficialmente componha a lista de protocolos clínicos do CEAF, esse fato demonstra que a interrupção do tratamento de doenças da mesma natureza daquelas tratadas por medicamentos desse componente especializado,

⁷<https://tinyurl.com/y8gzuv2q>

⁸<https://tinyurl.com/yazh2afr>

⁹<https://tinyurl.com/mpdft>

¹⁰<https://tinyurl.com/y7ec9d4o>

como a Síndrome de Hunter (Mucopolissacaridose II–MPSII) e a Mucopolissacaridose tipo I (MPS I), pode levar ao óbito dos pacientes.

Feitas essas considerações, fica patente o problema de distribuição dos medicamentos do CEAF, que ora leva a desabastecimentos, ora ao excesso de medicamentos, que por vezes são descartados por diversas causas, entre elas a expiração da validade. Nesse sentido, a pesquisa busca endereçar a fragilidade apontada, propondo algoritmos de aprendizagem de máquina que possam melhorar as estimativas das quantidades de medicamentos a serem distribuídas, com base nos dados reais de dispensação.

Cumpra salientar que, embora o problema de pesquisa a ser enfrentado envolva a possível perda de vidas humanas, em virtude do desabastecimento dos fármacos, o escopo da pesquisa não envolverá a quantificação de ganhos advindos da manutenção de vidas decorrentes de uma possível melhor distribuição dos medicamentos às Secretarias de Saúde, uma vez que essa mensuração é muito complexa, pois envolve diversas outras variáveis e aspectos, muitas vezes de natureza subjetiva. Portanto, quanto a esse aspecto, a pesquisa pretende tão somente contribuir para uma distribuição mais eficiente dos medicamentos.

1.2 Justificativa

O orçamento federal ligado à Função Saúde, nos últimos 3 anos, atingiu uma média de R\$ 116 bilhões, ficando atrás somente das despesas relacionadas à dívida pública, aos encargos especiais e à previdência social. Para o ano de 2018, a dotação inicial do orçamento autorizado para a Saúde atingiu a cifra de R\$ 121 bilhões. Em especial, a *Ação 4705 – Apoio Financeiro para Aquisição e Distribuição dos Medicamentos do Componente Especializado da Assistência Farmacêutica*, que visa distribuir medicamentos de alto custo às Secretarias de Saúde dos Estados e do Distrito Federal, teve orçamento autorizado, nos três últimos anos, de R\$ 7 bilhões (em 2016), R\$ 7,2 bilhões (em 2017) e R\$ 7,32 bilhões (em 2018), indicando ser uma ação de expressiva materialidade¹¹.

Considerando o problema de pesquisa descrito na seção anterior, e um ambiente de desequilíbrio fiscal do país, levando à diminuição de recursos para o atendimento de áreas básicas da atuação governamental, como saúde, educação, segurança pública e outros investimentos, medidas tendentes a qualificar o gasto público são urgentes e extremamente necessárias.

A previsão mais precisa da demanda por medicamentos do CEAF pode ser encarada como uma dessas medidas, a qual, sendo utilizada pelo Ministério da Saúde como ferramenta para confrontar as quantidades requeridas pelas Secretarias Saúde Estaduais, pode contribuir para evitar a perda de medicamentos, apontando, por exemplo, possíveis rema-

¹¹<https://www.siop.planejamento.gov.br/siop/?pp=siop>

nejamentos entre as unidades de saúde, o que tornaria essa política pública mais eficiente e efetiva.

O TCU, como órgão auxiliar do Congresso Nacional para o exercício do controle externo, detém competências que lhe foram dadas pela Constituição Federal e realiza auditorias cujo objetivo é avaliar a qualidade da atuação governamental, expedindo, quando necessário, recomendações e determinações que possam melhorar a entrega de bens e serviços à sociedade. Nesse sentido, a missão institucional do TCU é aprimorar a Administração Pública em benefício da sociedade por meio do controle externo [12].

Assim, levando em conta a competência do TCU para fiscalizar os recursos federais aplicados na política de medicamentos e da assistência farmacêutica, bem como o alto custo dos medicamentos, é foco dessa pesquisa apenas o Grupo 1, composto por medicamentos cuja responsabilidade do financiamento é do Ministério da Saúde, órgão que é alcançado pela jurisdição do TCU.

A aplicabilidade da pesquisa aos outros grupos poderia ser avaliada, mas os entes federativos subnacionais não teriam a obrigação de fornecer informações sobre a dispensação dos medicamentos adquiridos com recursos dos orçamentos locais. Dentro do Grupo 1, decidiu-se selecionar apenas os medicamentos do Grupo 1A, já que esses medicamentos, além de serem custeados com recursos federais, têm sua distribuição realizada pelo Ministério da Saúde, facilitando a troca de informações a respeito da gestão dessa política, o que se tornaria inviável caso tivesse que ser realizada com vários Estados.

Além disso, a solução do problema de pesquisa está em consonância com os seguintes objetivos estratégicos do vigente Plano de Gestão do TCU [13]:

- Fomentar o aperfeiçoamento da gestão dos órgãos e entidades da área da saúde com foco na eficiência e qualidade dos serviços prestados;
- Contribuir para a sustentabilidade financeira do Sistema Único de Saúde (SUS);
- Contribuir para melhorar a capacidade de contratação das organizações públicas;
- Intensificar o uso da inteligência artificial como instrumento de suporte ao controle externo e funcionamento institucional.

1.3 Objetivo Geral

Este estudo visa investigar a aplicação de algoritmos de aprendizagem de máquina com séries temporais para prever a dispensação dos medicamentos do Componente Especializado da Assistência Farmacêutica do Sistema Único de Saúde, servindo de insumo tanto para o aperfeiçoamento da política de distribuição de medicamentos no país, de responsa-

bilidade do Ministério da Saúde, como para o seu controle externo, realizado pelo Tribunal de Contas da União.

1.4 Objetivos Específicos

- Comparar algoritmos preditivos da programação trimestral de medicamentos do subgrupo 1A do Componente Especializado da Assistência Farmacêutica;
- Comparar os resultados do atual modelo de programação do Ministério da Saúde com as previsões dos algoritmos avaliados;
- Disponibilizar, ao Ministério da Saúde, um documento técnico com aspectos teóricos a respeito dos diversos métodos/modelos comparados na pesquisa e *scripts* contendo as implementações dos modelos.

Capítulo 2

Fundamentação Teórica

Este capítulo apresenta o referencial teórico e a pesquisa do estado da arte atinente à solução problema de pesquisa, que busca, essencialmente, prever a demanda por medicamentos do Componente Especializado da Assistência Farmacêutica do Sistema Único de Saúde a serem dispensados pelas unidades de saúde dos Estados e do DF.

2.1 A previsão de demanda de medicamentos

A previsão de demanda por medicamentos é um tema bastante explorado pela Organização Mundial de Saúde (OMS) e outros organismos internacionais. Considerando que a efetividade das políticas de saúde requer um equilíbrio entre medidas preventivas e curativas, é essencial a boa gestão do suprimento de medicamentos. O acesso inadequado a esse tipo de política, incluindo a falta desses medicamentos, bem como o seu uso de modo irracional, influenciam significativamente o desempenho dos sistemas de saúde [14].

A gestão do suprimento de medicamentos envolve as etapas de seleção, quantificação, aquisição, distribuição e uso. A seleção decide que medicamentos são necessários. A quantificação estima quanto de cada droga é necessário, ao passo que a aquisição envolve a seleção de fornecedores, gerenciamento de pedidos, avaliação da qualidade e quantidade fornecida e pagamento. A distribuição envolve o recebimento, armazenamento, controle de estoques, transporte e registro de informações de controle. Por fim, a utilização refere-se à prescrição, dispensação e uso dos medicamentos pelos pacientes [15, 16].

A quantificação é o processo de estimar o consumo esperado de *commodities* baseado no consumo histórico, em estatísticas, em dados demográficos e de morbidades ou em outras premissas, quando não há dados disponíveis, de modo a atender a demanda em um determinado período [16]. Há dois métodos de quantificação [15]: (i) baseado em dados de morbidade e (ii) baseado em consumo.

O processo de quantificação envolve a estimação da quantidade de medicamentos a ser adquirida e pode ser realizado por meio de um dos quatro métodos usuais ou pela combinação deles [17]. Importante destacar que o contexto em que são apresentados esses métodos é aquele em que estão sendo planejadas compras centralizadas semestrais ou anuais, não se prestando para o cálculo de quantidades de pedidos de compra de rotina. Os métodos usuais de quantificação da demanda são:

- Baseado em consumo: utiliza dados reais de consumo de medicamentos para prever as necessidades futuras;
- Baseado em dados de morbidade: estima a necessidade de um determinado medicamento com base no valor esperado de atendimentos, na incidência de doenças comuns e tratamentos padronizados para essas doenças;
- Consumo *proxy*: utiliza dados de incidência de doenças, consumo do medicamento, demanda e gastos farmacêuticos de um sistema modelo de fornecimento, extrapolando o consumo ou taxas de uso baseado na cobertura da população ou nível de serviço a ser provido;
- Projeção de nível de serviço: utiliza o custo médio de atendimento em diferentes unidades de saúde em um sistema modelo, para então projetar o custo em unidades de saúde similares. Esse método não estima quantidades individuais de medicamentos.

Em muitos casos, o método baseado em consumo é o mais preciso, considerando que as fontes de dados são confiáveis e completas [15, 16, 17, 18, 19]. Aquele baseado em morbidade é o mais complexo e demorado, uma vez que não há disponibilidade de dados dessa natureza para todos os tipos de doenças. O método baseado em consumo *proxy* só é utilizado quando não é possível utilizar os métodos anteriores. A estimativa por nível de serviço encontra suas limitações nas premissas adotadas, pois o sistema modelo com o qual é comparado deve ser compatível com o sistema sendo estimado tanto em termos de atendimento aos pacientes como na similaridade dos medicamentos ofertados em ambos os sistemas comparados. De qualquer forma, usando informações de consumo ou de morbidade, dados faltantes ou de baixa qualidade diminuem a precisão da estimativa e impactam os planos de suprimento [16].

Quando aplicada à indústria farmacêutica, a previsão da demanda é influenciada pelo ciclo de vida da produção dos medicamentos, o que requer diferentes métodos de previsão para produtos ainda em desenvolvimento e para produtos já lançados no mercado. O algoritmo para previsão baseia-se em elementos para modelar o mercado, para prever a quantidade do produto e para converter pacientes e produtos em receita [20].

Para produtos em desenvolvimento, os métodos mais comuns são aqueles centrados nos dados dos pacientes (população, prevalência de doenças, sintomatologia, diagnóstico) e nos dados de prescrição. O primeiro identifica o número de pacientes potenciais com um determinado estado de doença, e então reduz esse universo por meio de filtros para chegar ao número de pacientes que estão recebendo a terapia medicamentosa naquele momento. O segundo começa com o número de pacientes atualmente recebendo a terapia medicamentosa e expande esse número para atingir o máximo teórico.

Para produtos já lançados no mercado, quando já existem séries temporais sobre o consumo, uma previsão adequada deve levar em conta dados que capturem, de formas alternativas, dinâmicas dos mercado que permitam a quem está fazendo a previsão realizar a triangulação da atividade histórica, a exemplo do uso de dados do total de prescrições e de novas prescrições, quantidades do medicamento dispensadas, número de dias da terapia e quantidade de pacientes [20].

Diferentemente de uma previsão aplicada à indústria farmacêutica, que considera diversas variáveis na modelagem, o escopo desta pesquisa é diverso, na medida em que objetiva quantificar, de forma mais precisa possível, não a produção de um determinado medicamento, mas quantidades que devem ser distribuídas a cada uma das unidades de destino, buscando atender de forma satisfatória a demanda de dispensação dos medicamentos, utilizando os próprios dados históricos de consumo.

2.2 Revisão do estado da arte

A previsão da demanda de produtos em cadeias de suprimento, como é o caso da cadeia de medicamentos, é um tema de grande interesse para a pesquisa operacional. A previsão associada ao gerenciamento de estoques, contratações, fornecimento e planejamento de demanda são temas presentes nos livros mais populares associados à gestão de cadeias de suprimento. Além disso, ferramentas quantitativas associadas à predição estão entre as cinco mais utilizadas, tendo por base os artigos em jornais associados ao gerenciamento de cadeias de suprimento [21].

Hu *et al.* [22], ao fazer uma revisão sobre o gerenciamento de estoques de reserva, apontaram três técnicas de predição, entre elas a técnica de previsão de séries temporais, comumente utilizadas para itens de demanda não intermitente. Exemplos de modelos de séries temporais utilizados nesse domínio são: amortecimento exponencial, incluindo os métodos de *Holt* para dados com tendência e o de *Holt-Winters* para dados com tendência e sazonalidade, além do *Autoregressive Integrated Moving Averages* (ARIMA). Para itens com demanda intermitente, os autores apontam estudos que se utilizam de outras abor-

dagens, como métodos *bootstrapping*, Bayesianos, máquinas de vetores de suporte (SVM) e redes neurais.

Em um estudo de revisão sobre a predição na área de saúde, Soyiri e Reidpath [23] descreveram conceitos-chave dessa tarefa, incluindo definições, princípios e propriedades dos dados que influenciam as escolhas dos métodos de previsão. Segundo os autores, não há uma abordagem que se aplique a todas as situações, de modo que vários métodos têm sido adaptados para essa finalidade. Destacaram ainda que o padrão de distribuição de dados em determinados períodos de tempo, ou seja, em forma de séries temporais, é importante na escolha do método a ser utilizado. Após explicar importantes componentes das séries temporais em saúde (tendência, sazonalidade, ciclos e aleatoriedades), os autores mostraram que os modelos estatísticos de predição que envolvem séries temporais mais comumente utilizados na área de saúde são os modelos de médias móveis, ARIMA, e técnicas de amortecimento exponencial, a exemplo do modelo de *Holt-Winters*.

Ainda na área de saúde, Talaei-Khoei *et al.* [24], em um estudo para identificar o menor período de observações sem prejudicar o desempenho da previsão de séries temporais para contagem da incidência de doenças, afirmaram que diferentes métodos estatísticos têm sido utilizados para prever a quantidade de casos de uma determinada doença com base em dados de vigilância em saúde, tendo a literatura recomendado a utilização do ARIMA e de modelos estruturais, embora um crescente número de pesquisas apontem para o uso de redes neurais artificiais nesse domínio.

Especificamente na área de medicamentos, Nikolopoulos *et al.* [25] publicaram um estudo onde previram o consumo de medicamentos da indústria farmacêutica no Reino Unido, antes e depois da expiração do prazo da patente, considerando o alto custo imposto aos sistemas de saúde nacionais, em especial ao sistema de saúde do Reino Unido. Após testar onze métodos, dentre os quais o ARIMA, suavização exponencial (simples e Holt), Naïve e métodos de regressão, os métodos ARIMA e Holt foram superiores na previsão de curto prazo (anual) para medicamentos não genéricos e genéricos, respectivamente, ao passo que, para horizontes mais estratégicos (dois a cinco anos), o método Naïve com *drift* fez as previsões com menor erro.

Pratyaks *et al.* [26], a fim de contribuir para assegurar a disponibilidade do antisséptico Iodopovidona, utilizado no Hospital Veterinário Professor Soeparwi, na Indonésia, analisaram e especificaram um modelo ARIMA(1,0,1) como o melhor modelo para prever a demanda desse insumo hospitalar.

Em 2018, Makridakis *et al.* [27] publicaram um estudo comparativo da capacidade de previsão de oito métodos estatísticos tradicionais (Naïve 2, SES, Holt, Holt-Damped, combinação dos últimos 3 métodos, Theta, ETS e ARIMA) e de dez métodos baseados em aprendizagem de máquina (MLP, BNN, RBF, GRNN, KNN, CART, SVR, GP, RNN

e LSTM), concluindo pela superioridade dos métodos tradicionais tanto em termos das duas medidas de erro utilizadas, quanto do custo computacional, em todos os horizontes de previsão que foram testados. Os métodos foram aplicados em 1045 séries temporais mensais utilizadas na competição M3. O método ETS é um modelo de espaço de estados de suavização exponencial, desenvolvido e automatizado por Hyndman [28], escolhido pelos autores em virtude de seus bons resultados, além do método Theta, que foi o melhor em termos da métrica de erro utilizada na competição M3 [29, 30].

Zadeh *et al.* [31] destacaram a grande capacidade das redes neurais em tratar relacionamentos não-lineares entre os valores da série, o que as tornam muito atrativas em problemas de predição de séries temporais e concluíram que há uma recente tendência de combinar métodos para atingir uma melhor acurácia. Ao comparar um modelo neural híbrido com o ARIMA para prever a demanda de compra de medicamentos de uma empresa do ramo da indústria farmacêutica, em todos os cenários o modelo neural obteve melhores resultados em termos de acurácia.

Para prever a quantidade de pacientes em atendimentos que não exigem internação, Luo *et al.* [32] combinaram um modelo ARIMA com sazonalidade (SARIMA), para uma série temporal das horas de um dia, e um modelo de amortecimento exponencial para os dias da semana. Aplicando essa combinação aos dados de um ano de visitas diárias de pacientes em dois departamentos de um hospital em Chengdu, na China, o modelo combinado resultou em uma menor variância dos resíduos e menor erro residual quando comparado aos modelos implementados isoladamente.

Em uma revisão da literatura, Mahalakshmi *et al.* [33] afirmaram que a análise e a previsão de séries temporais têm sido, há bastante tempo, um foco importante da pesquisa científica, sendo utilizadas em diversas aplicações na área de vendas, mercados de capitais, previsão do tempo, demanda de energia elétrica, custo e utilização de combustíveis e em vários outros domínios nos quais há tendências e sazonalidades nos dados de interesse. Além dos modelos tradicionais de previsão em séries temporais, outros têm sido utilizados nessa tarefa, já que a modelagem convencional baseia-se na combinação linear dos dados históricos da série, de modo que não são adequados quando precisam capturar padrões não lineares da série temporal. Nesse cenário, modelos como Redes Neurais (ANN), Algoritmos Evolucionários (EA), Máquinas de Vetores de Suporte (SVM) e Lógica Fuzzy têm sido explorados em diversas aplicações, às vezes combinados com métodos convencionais para criar modelos híbridos.

Navarro *et al.* [34] apresentaram as redes neurais artificiais como uma ferramenta de aprendizagem de máquina muito utilizada em previsão de séries temporais, sendo mais comum o uso de redes do tipo *feedforward* cujas entradas são alimentadas com dados históricos da série temporal, conhecidas como *Time Delay Neural Networks* (TDNN).

Segundo esses autores, as redes neurais recorrentes têm arquitetura diferente das redes neurais convencionais, pois a informação pode ser armazenada, constituindo uma memória que pode ser útil em previsão de séries temporais, pois a relação entre valores históricos e valores futuros da série pode influenciar o comportamento das observações da série. Após comentar sobre as redes neurais recorrentes do tipo LSTM, afirmam que as redes recorrentes *Echo State Networks* (ESN) também são capazes de memorizar informação e têm sido aplicadas com capacidade de generalização competitivas frente a outras redes, embora com complexidades associadas ao processo de otimização dos parâmetros da rede.

Segundo Fischer e Krauss [35], as redes recorrentes LSTM são o estado da arte no aprendizado de sequências. Elas ainda são pouco exploradas à predição de séries temporais na área financeira, embora possuam características que as tornam adequadas para esse domínio. Utilizando uma rede LSTM para prever movimentos direcionais das ações do índice S&P 500, ela foi superior a outros métodos sem memória, como *Random Forest* (RAF), uma rede neural profunda (DNN) e um classificador de regressão logística.

Cortez *et al.* [36] observaram que a maioria dos sistemas de previsão de eventos de emergência em tempo-real são baseados em métodos tradicionais de séries temporais, como médias móveis ou ARIMA. Assim, propuseram alguns modelos de previsão de eventos emergenciais usando redes neurais recorrentes, em especial as redes LSTM, utilizando dados históricos da polícia nacional da Guatemala. O ajuste dos modelos baseados em redes LSTM superou outros modelos de aprendizagem de máquina e também métodos convencionais de previsão de séries temporais em termos de acurácia na previsão desses eventos.

Kim e Won [37] propuseram um novo modelo híbrido para prever a volatilidade do preço de ações, o qual combina uma rede LSTM com três modelos auto-regressivos generalizados heterocedásticos condicionais GARCH (*Autoregressive Conditional Heterocedasticity*). Esses modelos híbridos tiveram o seu desempenho comparado com modelos não combinados (GARCH, GARCH exponencial, amortecimento exponencial de médias móveis, rede neural *feedforward* profunda e uma rede neural LSTM). Os resultados mostraram que o modelo híbrido proposto obteve os menores erros de predição em termos das métricas de avaliação utilizadas.

Na área de vigilância em saúde, Venna *et al.* [38] propuseram um modelo de previsão para casos de influenza utilizando um modelo LSTM multivariado, de modo a capturar a influência de variáveis externas como humidade, temperatura, precipitação e exposição solar. Comparado a dois métodos do estado-da-arte para previsão de influenza, ARIMA e EAKF (*Ensembled Adjustment Kalman Filter*), o método proposto foi superior, indicando uma aplicação promissora de modelos de aprendizado de máquina que consideram a influência de fatores ambientais e espaço-temporais nesse domínio.

A pesquisa na área de séries temporais é bastante dinâmica, de modo que é bastante comum o surgimento de novos métodos e modelos de previsão. Em fevereiro de 2017, o Facebook anunciou um método de previsão de séries temporais chamado *Prophet*¹, motivados pelas dificuldades de previsão em larga escala, que estão associadas à ideia da necessidade de aproveitar muitas pessoas sem capacitação em séries temporais, da variedade de problemas de previsão – e suas particularidades – e da grande quantidade de previsões sendo feitas simultaneamente. Esse modelo busca tratar algumas características de séries temporais associadas a dados empresariais de venda, como múltiplas e marcantes sazonalidades, mudanças de tendência, *outliers* e efeitos associados a feriados [39].

Em 2019, Montero-Manso et al.², apresentaram um modelo de previsão de séries temporais denominado FFORMA, acrônimo, em tradução livre, para modelo ponderado de previsão baseado em características. Trata-se de um modelo cuja abordagem envolve duas fases. Na primeira, um meta-modelo, cujos atributos são características obtidas da séries temporais de interesse, produz pesos, que, na segunda fase, são utilizados para ponderar as previsões de nove métodos individuais de previsão (Naïve, Naïve sazonalizado, passeio aleatório com *drift*, Theta, ARIMA, ETS, TBATS, STLM e TDNN), com o objetivo de minimizar o erro das previsões ponderadas, obtidas da combinação dos diversos métodos. O FFORMA obteve a segunda colocação na competição M4 e foi superior à combinação simples entre os métodos individuais e à maioria dos métodos da literatura na área de previsão de séries temporais [40].

É extremamente difícil tirar conclusões teóricas definitivas a respeito do mérito dos vários modelos de previsão em séries temporais. A melhor decisão sobre qual método utilizar é escolher aquele com menor erro de previsão quando aplicados a dados já observados [41].

A par dos modelos já mencionados, há que se destacar que há vários outros aplicáveis à análise e previsão de séries temporais, a depender da natureza da série e de suas características, o que torna extremamente diverso o cenário de modelos que podem ser avaliados. São exemplos dessa diversidade os modelos para tratamento de sazonalidades múltiplas (decomposição com múltiplas sazonalidades, regressão dinâmica harmônica com múltiplas sazonalidades e TBATS), modelos vetoriais autoregressivos (séries multivariadas), séries temporais *bootstrapping*, modelos de decomposição (STL), modelos de espaço de estados e modelos ARCH para séries com variância condicional evoluindo no tempo [42] e a combinação de modelos como o ES-RNN e o FFORMA, os quais ficaram ranqueados nos dois primeiros lugares da recente competição M4 [43].

¹<https://research.fb.com/prophet-forecasting-at-scale/>

²FFORMA: Feature-based Forecast Model Averaging. Disponível em <https://robjhyndman.com/publications/>

Além dos métodos e modelos estatísticos tradicionais de previsão, que em estudo recente foram superiores a diversos métodos de aprendizagem de máquina [27], a escolha das redes neurais recorrentes para compor o conjunto de modelos a ser avaliado nesta pesquisa, se justifica na medida em que elas têm sido apontadas como o estado da arte para o aprendizado de sequências [1], sendo utilizadas em diversos domínios, como revelam recentes pesquisas publicadas, como aplicações de previsão de séries temporais nas áreas de finanças [44], mercado de ações [45], petróleo [46], energia eólica [47], hidrologia [48], agricultura [49], tráfego urbano [50] e tráfego em redes móveis [51], para citar apenas algumas.

Considerando os resultados promissores das redes LSTM na previsão em outros domínios e que a sua utilização em séries temporais de consumo de medicamentos não foi encontrada na pesquisa bibliográfica, abre-se uma possibilidade de investigação de sua aplicação nessa área. Assim, foram escolhidos métodos estatísticos tradicionais já aplicados ao domínio do problema, a exemplo dos métodos de suavização exponencial (simples, Holt, Holt-Winters, espaço de estados) e ARIMA, além do método Theta e de um modelo de rede neural recorrente do tipo LSTM.

2.3 Previsão de séries temporais

Terminada a revisão bibliográfica, são apresentados nesta Seção conceitos importantes para a previsão de séries temporais, além dos métodos e modelos a serem utilizados na etapa de modelagem. Antes, porém, é fundamental diferenciar os conceitos de análise e de previsão de séries temporais. A análise envolve, fundamentalmente, investigar o mecanismo gerador da série e descrever o seu comportamento por meio da verificação de tendências, ciclos e variações sazonais [52], embora a análise também possa ser encarada como uma etapa anterior ou preparatória da previsão [34]. Já a previsão, objeto desta pesquisa, consiste em fazer previsões a respeito de valores futuros da série, podendo ser consideradas de curto ou de longo prazo.

2.3.1 Conceitos fundamentais

Dados observados de forma sequencial no domínio do tempo podem ser considerados uma série temporal, podendo ser entendidos como uma lista de valores registrados juntamente com a informação do momento em que foram coletados [42]. Uma série temporal também pode ser definida como uma coleção de variáveis aleatórias indexadas de acordo com a ordem temporal em que elas são obtidas. Em geral, uma coleção de variáveis aleatórias x , indexada por t , é conhecida como um processo estocástico. O conjunto de valores

observados de um processo estocástico, por sua vez, são conhecidos como uma realização daquele processo estocástico [52, 53].

Introduzindo uma notação mais formal, seja T um conjunto arbitrário. Um processo estocástico é uma família $Z = Z(t), t \in T$, tal que, para cada $t \in T$, $Z(t)$ é uma variável aleatória. Sejam t_1, t_2, \dots, t_n elementos quaisquer de T e consideremos

$$F(z_1, \dots, z_n) = P[Z(t_1) \leq z_1, \dots, Z(t_n) \leq z_n] \quad (2.1)$$

Então, o processo estocástico $Z = Z(t), t \in T$ estará especificado se forem conhecidas as distribuições finito-dimensionais (Equação 2.1), para todo $n \geq 1$. Quando se pretende utilizar modelos para descrever séries temporais, é necessário introduzir suposições simplificadoras, a fim de permitir analisar determinadas classes de processos estocásticos, a exemplo dos processos estacionários [52], que, em sua acepção estrita, assim se caracterizam quando todas as distribuições finito-dimensionais permanecem as mesmas sob translações do tempo, ou seja, para quaisquer $t_1, t_2, \dots, t_n, \tau$ de T :

$$F(z_1, \dots, z_n; t_1 + \tau, \dots, t_n + \tau) = F(z_1, \dots, z_n; t_1, \dots, t_n) \quad (2.2)$$

As séries temporais, algumas vezes, apresentam padrões cuja descrição é bastante importante no contexto da análise e da previsão de séries temporais: tendência, sazonalidade e ciclos. A tendência é uma direção que tomam as observações da série no longo prazo ao passo que a sazonalidade é um padrão que se repete com uma periodicidade conhecida [54]. A sazonalidade é sempre fixa e tem uma frequência conhecida, como, por exemplo, a venda mensal de um item que pode apresentar sazonalidade devido à mudança de custo daquele item no fim do ano. Já um ciclo ocorre quando os dados exibem uma alta ou queda que não tem uma periodicidade fixa. Em geral, os ciclos, em média, são mais longos do que os padrões sazonais e as suas magnitudes dos ciclos tendem a variar mais. As séries temporais podem ter tendências, ciclos e sazonalidades, de modo que a escolha de um método de previsão deve levar isso em conta, em razão da habilidade do método para capturar esses padrões de forma adequada [42].

Geralmente o ciclo e a tendência são combinados para formar uma componente ciclo-tendência (chamada comumente de tendência), de modo que uma série temporal pode ser descrita como uma composição de três componentes [54]:

$$y_t = S_t + T_t + R_t \quad (2.3)$$

Na Equação 2.3, S_t é a componente sazonal, T_t a tendência e R_t a componente remanescente, assim chamada porque representa tudo o mais na série que não é explicado

pelas demais componentes. A Equação 2.3 é chamada de decomposição aditiva, embora haja a decomposição multiplicativa:

$$y_t = S_t \times T_t \times R_t \quad (2.4)$$

A forma aditiva é mais apropriada se a magnitude das flutuações sazonais ou a variação em torno da componente ciclo-tendência não se altera com o nível da série, ao passo que a decomposição multiplicativa é mais apropriada quando a mudança em um desses padrões parece ser proporcional ao nível da série [42].

Há diversos métodos para decompor a série temporal, a exemplo da decomposição clássica, que se utiliza de médias móveis, além de métodos como X11, SEATS e STL [55, 56]. De posse dessas componentes, é possível gerar a série sazonalmente ajustada e sem tendência, bastando, para tanto, remover da série essas componentes, subtraindo-as da série original, no caso de um modelo aditivo. Como exemplo, a série sazonalmente ajustada y_{tSA} é aquela resultante da extração da componente sazonal, ou seja:

$$y_{tSA} = y_t - S_t \quad (2.5)$$

Outra ferramenta importante na previsão de séries temporais é a possibilidade de transformação dos dados. O propósito desses ajustes é simplificar os padrões nos dados históricos da série removendo fontes de variação ou tornando os padrões mais consistentes em todo o conjunto de observações, de forma a tornar as previsões mais precisas [42].

Uma transformação clássica aplicada às séries temporais é a aplicação do operador diferença [52], que consiste na seguinte manipulação da série original y_t :

$$\Delta^d y_t = y_t - y_{t-d}, \quad (2.6)$$

onde $d \geq 1$ é o número de diferenças aplicadas para tornar a série estacionária.

Embora haja diferentes tipos de transformação, as transformações matemáticas também são bastantes comuns. Nem todas as séries temporais podem ser tornadas estacionárias por meio da aplicação do operador diferença, pois as séries podem ser estacionárias na média e não em sua variância [57]. Nesse caso, as transformações matemáticas são muito adequadas, como transformações logarítmicas, de raízes quadradas ou cúbicas, chamadas de transformações de potência, pois elas podem ser escritas na forma $w_t = y_t^p$. Uma família de transformações que abrange tanto as logarítmicas com as de potência é a transformação Box-Cox [42].

O gráfico de autocorrelação é outra ferramenta importante na análise e previsão de séries temporais. Assim como a correlação mede a relação linear entre duas variáveis, a autocorrelação mede a correlação de uma série temporal com versões da mesma série

deslocadas no tempo (*lagged values*) [42]. Utilizando a expressão a seguir, podem ser calculados diversos coeficientes de autocorrelação r_k :

$$r_k = \frac{\sum_{t=k+1}^T (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2}, \quad (2.7)$$

onde T é o tamanho da série temporal. O coeficiente r_1 é a autocorrelação entre y_t e y_{t-1} , r_2 é a autocorrelação entre y_t e y_{t-2} e assim por diante. Uma hipótese comumente utilizada é a de que a série é considerada uma sequência de variáveis aleatórias não autocorrelacionadas, com média zero e variância finita, modelo conhecido como ruído branco, que é gaussiano se a distribuição dos valores da autocorrelação for considerada normal. Nesse caso, os coeficientes de correlação r_k são nulos ou próximos de zero.

Essa informação é relevante, pois, a partir dela, é possível medir o grau de dependência contido nos dados e selecionar um modelo para os dados que reflitam essa característica. A estimativa dessa medida, por meio da autocorrelação, pode sugerir qual dos diversos modelos estacionários é adequado para representar a dependência presente nos dados [41]. Por exemplo, quando os coeficientes de autocorrelação (ou 95% deles) são próximos de zero ou estejam dentro do intervalo $\pm\sqrt{2}/T$, onde T é o tamanho da série, é apropriado dizer que aquela série é um ruído branco, indicando que não há correlação presente naqueles dados. Essa informação, aplicada aos resíduos dos modelos, é utilizada para atestar se o modelo está bem ajustado ou precisa de melhoramentos. Além disso, valores dos coeficientes de autocorrelação acima daqueles limites podem indicar a presença de tendência e sazonalidade na série e servir para a definição da ordem dos modelos de previsão do tipo autoregressivos e de médias móveis [42, 52].

2.3.2 Perspectiva estatística da previsão

Por fim, a perspectiva estatística a respeito da previsão é outra questão relevante. Considerando que a variável que se quer prever pode assumir valores não determinísticos, ela é considerada uma variável aleatória. No caso em questão, a quantidade de cada medicamento que será dispensada pelas Secretarias Estaduais de Saúde poderá assumir qualquer valor em um determinado intervalo e, na maioria das situações de previsão, quanto maior o horizonte de previsão, mais incerteza está associada aos valores que podem assumir a variável sendo prevista [42].

Quando obtida uma previsão, estima-se o valor central de uma faixa de possíveis valores que a variável aleatória pode assumir, de modo que é comum que a previsão pontual seja acompanhada por um intervalo de previsão com determinado nível de confiança. Um intervalo de 80%, por exemplo, contém uma faixa de valores que devem incluir o futuro valor real da variável sendo prevista com probabilidade de 80%. Caso seja apresentada

apenas a previsão pontual, na verdade, não é fornecido um meio para informar a real acurácia da previsão, ao passo que os intervalos mostram a incerteza associada à previsão.

Utilizando a notação já descrita anteriormente, y_t é a observação da série no momento t . Considerando todas as observações anteriores como I , então $y_t|I$ é a variável aleatória y_t dada a informação I , e o conjunto de valores que essa variável pode assumir, com as suas respectivas probabilidades, é justamente a distribuição de probabilidades de $y_t|I$, ou seja, a distribuição das previsões. A previsão \hat{y}_t é geralmente considerada a média da distribuição das previsões [42]. Dito isso, $\hat{y}_{t|t-1}$ é a previsão de y_t levando em conta as observações (y_1, \dots, y_{t-1}) e $\hat{y}_{T+h|T}$ é a previsão h passos à frente (previsões para o futuro), considerando todas as observações até o tempo T (y_1, \dots, y_T) .

Assumindo normalidade dos erros de previsão (resíduos), o intervalo de previsão para h passos é igual a:

$$\hat{y}_{T+h|T} \pm c \cdot \hat{\sigma}_h, \quad (2.8)$$

onde c é a probabilidade de cobertura pelo intervalo e $\hat{\sigma}_h$ uma estimativa do desvio padrão da distribuição das previsões h passos à frente. Para uma probabilidade de 95%, o intervalo seria $\hat{y}_{T+h|T} \pm 1,96 \cdot \hat{\sigma}_h$, onde o valor de c é obtido da tabela da distribuição Normal padrão.

Quanto maior o horizonte de previsão, maior a incerteza e, portanto, maior o intervalo de previsão. Para $h = 1$, o desvio padrão dos erros de previsão é uma boa estimativa do desvio padrão da distribuição das previsões σ_1 . Para previsões com $h > 1$, entretanto, o método de cálculo é mais complicado, pois assume que os resíduos são não correlacionados. Uma alternativa para esses casos é lançar mão da técnica de *bootstrapping*, por meio da qual é obtida uma distribuição de previsões, usando amostras dos erros de previsão, e, assim, podem ser calculados intervalos de previsão com base em percentis para cada horizonte de previsão [42].

Para alguns métodos de previsão mais simples, como *Naïve*, *Seasonal Naïve*, *Drift* e a média dos valores passados, é matematicamente possível derivar uma expressão para o desvio padrão, mesmo diante da premissa de resíduos não correlacionados [42].

Quando se trata de modelos de redes neurais, a estimação da incerteza, ou seja, a possibilidade de produzir previsões com intervalos de previsão associados, como aquele apresentado na Equação 2.8, permanece em aberto na pesquisa. Recentemente, as redes neurais bayesianas têm atraído a atenção como uma alternativa para tratar a incerteza de modelos de redes neurais profundas. Essas redes neurais introduzem incerteza partindo de uma perspectiva bayesiana, ou seja, associando distribuições *a priori* para os pesos W da rede, de modo a encontrar uma distribuição de probabilidade *a posteriori* desses parâmetros, ao invés de uma previsão pontual [58].

Em 2016, Gal e Ghahramani [59] propuseram uma abordagem para inferência em redes neurais chamada de *Monte Carlo Dropout*, que não requer mudanças na arquitetura da rede e facilita do cálculo da incerteza associada às previsões desses modelos. Especificamente, a abordagem consiste em tornar inoperantes, de forma aleatória, uma determinada quantidade de neurônios das camadas escondidas da rede neural (*dropout*), o que faz com que a saída do modelo seja uma aproximação de uma amostra aleatória gerada de uma distribuição *a posteriori* da previsão [60]. Assim, os intervalos de previsão podem ser estimados pela variância amostral das previsões do modelo, obtidas a partir de uma determinada quantidade de repetições.

2.3.3 Diagnóstico do ajuste dos modelos

Qualquer que seja o modelo ajustado para a previsão de séries temporais, o diagnóstico do modelo visa observar o quanto o modelo foi capaz de capturar toda a informação contida nas observações. Isso, em geral, é feito por meio do diagnóstico dos resíduos do modelo, calculados da seguinte maneira:

$$e_t = y_t - \hat{y}_t \quad (2.9)$$

A fim de se determinar se um determinado modelo é adequado para fazer previsões, são usualmente consideradas as seguintes premissas a respeito dos resíduos [42]:

- São não correlacionados;
- Têm média zero, caso contrário, as previsões são viesadas;
- Têm variância constante;
- Têm distribuição normal.

Apesar desse diagnóstico poder ser feito pela observação dos gráficos de autocorrelação dos resíduos dos modelos, é comum aplicar testes formais de autocorrelação considerando todo o conjunto de coeficientes de correlação r_k (vide Equação 2.7) como um grupo, ao invés de tratá-los separadamente.

Esses testes são chamados de testes de *portmanteau*, sendo comumente utilizado o teste de Ljung-Box, baseado na seguinte estatística:

$$Q^* = T(T+2) \sum_{k=1}^h (T-k)^{-1} r_k^2, \quad (2.10)$$

onde h é o número máximo considerado de *lags* e T o número de observações. Se cada r_k é próximo de zero, então Q^* será pequeno e se alguns r_k são grandes (positivos ou negativos),

então Q^* será grande, sugerindo que as autocorrelações não se originam de um processo de ruído branco. Nesse último caso, $Q^* \sim \chi^2_{(h-K)}$, ou seja, uma distribuição qui-quadrado com $h - K$ graus de liberdade, onde K é o número de parâmetros do modelo [42].

2.4 Métodos e Modelos de previsão de séries temporais

Feita uma introdução sobre conceitos importantes para a previsão de séries temporais, são apresentados, a seguir, conceitos teóricos a respeito dos métodos/modelos que serão comparados nesta pesquisa.

2.4.1 *Naïve e Seasonal Naïve*

Em problemas de previsão de séries temporais, é comum estabelecer métodos do tipo “baseline”, ou seja, métodos simples que servem como ponto de partida para avaliação de outros de maior complexidade. Foram escolhidos para esta pesquisa os métodos naïve e naïve sazonal, a exemplo do que fizeram Makridakis *et al.* [27].

O método naïve consiste em utilizar como previsão de valores futuros o último valor da série temporal, ou seja, $\hat{y}_{T+h|T} = y_T$, onde h é o tamanho do horizonte de previsão e $\hat{y}_{T+h|T}$ é a estimativa de y_{T+h} feita com base nos dados y_1, y_2, \dots, y_T .

Um método similar é o naïve sazonal, onde cada previsão é igual ao último valor observado no período sazonal. O valor da previsão para \hat{y}_{T+h} é igual a:

$$\hat{y}_{T+h|T} = y_{T+h-m(k+1)}, \quad (2.11)$$

onde h é o tamanho do horizonte de previsão, m é o período sazonal e k é a parte inteira de $(h - 1)/m$, ou seja, o número de anos completos no horizonte de previsão antes de $T + h$. Para dados com registro mensal, as previsões para todos os meses de Abril no futuro, apenas a título de exemplo, seriam iguais ao último valor observado da série em Abril.

2.4.2 *Suavização exponencial*

Os métodos de suavização exponencial foram propostos no final dos anos 1950, por Brown [61], Holt [62] e Winters [63]. As previsões realizadas por esses métodos podem ser entendidas como médias ponderadas das observações passadas, com os pesos diminuindo de forma exponencial para os valores mais antigos da série. Esses métodos geram previ-

sões confiáveis e de forma rápida para uma gama variada de séries temporais, tendo sido utilizado em importantes aplicações na indústria [42].

Suavização exponencial simples

O método mais simples daqueles que compõe a suavização exponencial é chamado de suavização exponencial simples (SES), e é adequado para a previsão de séries temporais sem tendência ou sazonalidade [42]. Escrevendo o modelo em forma de componentes, a única existente é o nível da série (l_t), já que nesse caso não são modeladas a tendência e a sazonalidade:

$$\hat{y}_{t+h|t} = l_t \quad (2.12a)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1}) \quad (2.12b)$$

Na Equação 2.12a, o valor previsto no instante $t + 1$ é o nível da série no instante t . A Equação 2.12b calcula o nível estimado da série (valor suavizado) em cada período t . A constante $0 \leq \alpha \leq 1$ é o parâmetro de suavização e a previsão para o horizonte $T+h$ é uma média ponderada de todas as observações da série y_1, y_2, \dots, y_T . A taxa de decréscimo dos pesos é controlada pelo parâmetro α . Assim, esse método consiste em produzir previsões que são médias ponderadas por pesos que diminuem exponencialmente para observações mais antigas da série temporal.

Holt

O método Holt é uma extensão da suavização exponencial simples para séries com tendência [62]. Assim, o método é modelado por uma equação de previsão e duas equações de suavização, uma para o nível da série e outra para a tendência:

$$\hat{y}_{t+h|t} = l_t + hb_t \quad (2.13a)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2.13b)$$

$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1} \quad (2.13c)$$

Na Equação 2.13b, l_t é a estimativa do nível da série no instante t , b_t a estimativa da tendência da série no instante t , que representa a inclinação de uma reta, $0 \leq \alpha \leq 1$ e $0 \leq \beta^* \leq 1$ os parâmetros de suavização do nível e da tendência da série, respectivamente.

Assim como para a suavização exponencial simples, a equação do nível mostra que l_t é uma média ponderada da observação y_t e da previsão de treinamento um passo à frente ($h = 1$) para o instante t . Já b_t , como mostra a Equação 2.13c, é uma média ponderada

da tendência estimada no instante t , baseada em $(l_t - l_{t-1})$ e da estimativa da tendência no instante anterior (b_{t-1}) [42]. Como pode ser observado, a função de previsão não é mais constante e sim, uma função linear de h (horizonte de previsão), ou seja, a previsão h passos à frente é igual ao valor da estimativa anterior de nível mais h vezes o valor da última estimativa de tendência.

Partindo de evidências empíricas de que as previsões de tendência constante do método Holt levavam a tendências superestimadas, principalmente para horizontes de previsão mais longos, Gardner e McKenzie [42], em 1985, introduziram ao método Holt um parâmetro que modifica a tendência para um valor constante a partir de um determinado momento no futuro. Essa alteração se mostrou muito bem sucedida e comprovadamente é um dos métodos mais populares quando são necessárias previsões automatizadas para muitas séries temporais.

Assim, essa alteração inclui o parâmetro $0 \leq \phi \leq 1$, levando à seguinte modelagem:

$$\hat{y}_{t+h|t} = l_t + (\phi + \phi^2 + \dots + \phi^h)b_t \quad (2.14a)$$

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1}) \quad (2.14b)$$

$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)\phi b_{t-1} \quad (2.14c)$$

Quando $\phi = 1$, o método torna-se idêntico ao método Holt com tendência linear. Para valores entre 0 e 1, o método aproxima a tendência a uma constante em algum momento no futuro. Os valores de previsão convergem para $l_T + \phi b_T / (1 - \phi)$, para qualquer valor $0 \leq \phi \leq 1$, à medida que $h \rightarrow \infty$ [42].

Holt-Winters

O método Holt foi alterado por Winters [63] para capturar a sazonalidade presente na série temporal, nascendo o método Holt-Winters, que consiste em uma equação de previsão e outras três equações de suavização, uma para cada componente da série (nível, tendência e sazonalidade), cada qual com sua constante de suavização (α , β^* e γ).

A natureza da componente sazonal da série (aditiva ou multiplicativa) dá origem a duas variações do método. O método aditivo é indicado quando as variações sazonais são praticamente constantes para toda a série, ao passo que o método multiplicativo é preferido quando as variações sazonais mudam proporcionalmente com o nível da série [42].

O método Holt-Winters, na forma aditiva, pode ser expresso da seguinte forma:

$$\hat{y}_{t+h|t} = l_t + hb_t + s_{t+h-m(k+1)} \quad (2.15a)$$

$$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2.15b)$$

$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1} \quad (2.15c)$$

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m} \quad (2.15d)$$

Na Equação 2.15a, k é a parte inteira da divisão $(h - 1)/m$, de modo que os índices sazonais estimados usados para a previsão vêm do último ano da amostra. O nível da série (2.15b) é dado pela média ponderada da observação desazonalizada $y_t - s_{t-m}$ e da previsão não sazonal para o instante t ($l_{t-1} + b_{t-1}$). A equação de tendência é a mesma do método Holt (2.15c). Já a componente sazonal é modelada por uma média entre o índice sazonal atual e aquele da última estação sazonal, ou seja m períodos antes (2.15d) [42].

Já o método que considera a componente sazonal multiplicativa é descrito da seguinte maneira:

$$\hat{y}_{t+h|t} = (l_t + hb_t)s_{t+h-m(k+1)} \quad (2.16a)$$

$$l_t = \alpha \frac{y_t}{s_{t-m}} + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2.16b)$$

$$b_t = \beta^*(l_t - l_{t-1}) + (1 - \beta^*)b_{t-1} \quad (2.16c)$$

$$s_t = \gamma \frac{y_t}{(l_{t-1} + b_{t-1})} + (1 - \gamma)s_{t-m} \quad (2.16d)$$

Classificação dos métodos de suavização exponencial

A depender da combinação das possíveis configurações das componentes de tendência (inexistente, aditiva, aditiva suavizada, multiplicativa ou multiplicativa suavizada) e de sazonalidade (aditiva ou multiplicativa), os métodos podem ser classificados de acordo com a Tabela 2.1 [64]:

Tabela 2.1: Classificação dos métodos de suavização exponencial segundo a a configuração das componentes de tendência e sazonalidade

Tendência	Sazonalidade		
	N (inexistente)	A (aditiva)	M (multiplicativa)
N (inexistente)	N,N	N,A	N,M
A (aditiva)	A,N	A,A	A,M
A_d (aditiva suavizada)	A_d,N	A_d,A	A_d,M
M (multiplicativa)	M,N	M,A	M,M
M_d (multiplicativa suavizada)	M_d,N	M_d,A	M_d,M

Essa classificação é resultante de uma proposta inicial de Pegels [65], estendida por Gardner [66], modificada por Hyndman [64] e, finalmente, alterada novamente por Taylor [67], onde cada método é descrito por um par de letras (T, S) , onde a letra T define o tipo de tendência e a letra S define o tipo de sazonalidade [54]. Embora tenham sido

apresentados os métodos com tendência multiplicativa, eles tendem a produzir previsões ruins [42]. De todo modo, cada um desses métodos tem, como apresentados para os métodos anteriormente descritos, equações recursivas para previsão h passos à frente, além de equações das componentes de tendência e sazonalidade para aplicação do método.

Otimização nos métodos de suavização exponencial

A otimização dos métodos de suavização exponencial consiste na escolha dos valores iniciais de alguns parâmetros (l_0 e b_0) e dos valores das constantes de suavização apresentadas anteriormente (α , β , γ e ϕ). De posse desses valores, todas as previsões podem ser calculadas. Esses parâmetros são estimados utilizando os próprios dados disponíveis, por meio da minimização da soma dos erros quadráticos, conhecida como estimação dos mínimos quadrados.

Os resíduos (erros de treinamento) dos métodos são calculados pela equação

$$e_t = y_t - \hat{y}_{t|t-1}, \quad (2.17)$$

para $t = 1, 2, \dots, T$. Assim, são obtidos os valores dos parâmetros desconhecidos, e seus valores iniciais, minimizando a Equação 2.18. O procedimento, neste caso, é encarado como um problema de otimização não-linear, sujeito a restrições dos valores dos parâmetros [42].

$$SSE = \sum_{t=1}^T (y_t - \hat{y}_{t|t-1})^2 = \sum_{t=1}^T e_t^2 \quad (2.18)$$

2.4.3 Método *Theta*

O método *Theta* foi o vencedor da competição de previsão de séries temporais M3, que contou com 3003 séries das áreas financeira, empresarial, demográficas e econômicas. O método foi desenvolvido por Assimakopoulos e Nikolopoulos [68] e consiste em alterar a curvatura local da série temporal por meio de um coeficiente θ , aplicado diretamente à série resultante da aplicação de duas operações de diferença na série original. As séries resultantes, denominadas linhas-*theta*, mantêm a média e a inclinação da série original mas não a sua curvatura. O método proposto decompõe a série original em duas linhas-*theta*, $\theta=0$ (reta) e $\theta=2$, que são ajustadas separadamente e as suas previsões combinadas.

Hyndman e Billah [29] apresentaram o modelo Theta de forma simplificada quando comparada à apresentação original. Seja X_1, \dots, X_n uma série temporal e desta série é construída uma nova série $Y_{1,\theta}, \dots, Y_{n,\theta}$, tal que, para $t = 3, \dots, n$

$$\Delta^2 Y_{t,\theta} = \theta \Delta^2 X_t, \quad (2.19)$$

onde $\Delta^d X_t$ é a aplicação da operação de diferença na série X_t e $\Delta^d Y_{t,\theta}$ a aplicação da operação de diferença na série $Y_{t,\theta}$, com $d = 2$. A Equação 2.19 tem como solução

$$Y_{t,\theta} = a_\theta + b_\theta(t - 1) + \theta X_t, \quad (2.20)$$

onde a_θ e b_θ são constantes e $t = 1, \dots, n$. A Equação 2.20 é equivalente a uma função linear de X_t com adição de uma tendência linear, chamada de linha-theta [68]. Para um valor fixo de θ , os autores do método encontram os valores que minimizam a soma dos erros quadráticos

$$\sum_{i=1}^t [X_i - Y_{i,\theta}]^2 = \sum_{i=1}^t [(1 - \theta)X_t - a_\theta - b_\theta(i - 1)]^2, \quad (2.21)$$

o que equivale a minimizar a soma dos quadrados com respeito a a_θ e b_θ . Assim, é uma regressão simples de $(1 - \theta)X_t$ em função de $t-1$, cuja solução é dada por

$$\begin{aligned} \hat{b}_\theta &= \frac{6(1 - \theta)}{n^2 - 1} \left(\frac{2}{n} \sum_{t=1}^n tX_t - (n + 1)\bar{X} \right) \\ \hat{a}_\theta &= (1 - \theta)\bar{X} - b_\theta(n - 1)/2 \end{aligned} \quad (2.22)$$

As previsões do método são, a partir daí, obtidas por uma média ponderada das previsões para diferentes valores de θ . Na versão original do método foram escolhidos os valores de $\theta = 0$ e $\theta = 2$, o que leva as previsões h passos adiante, a partir das observações X_1, \dots, X_n , a serem calculadas por

$$\hat{X}_n(h) = \frac{1}{2} \left[\hat{Y}_{n,0}(h) + \hat{Y}_{n,2}(h) \right], \quad (2.23)$$

onde $\hat{Y}_{n,0}(h)$ é obtido pela projeção da parte linear da Equação 2.20 e $\hat{Y}_{n,2}(h)$ obtido utilizando a suavização exponencial simples na série $Y_{t,2}$, ou seja

$$\hat{Y}_{n,0}(h) = \hat{a}_0 + \hat{b}_0(n + h - 1), \quad (2.24)$$

e

$$\hat{Y}_{n,2}(h) = \alpha \sum_{i=0}^{n-1} (1 - \alpha)^i Y_{n-i,2} + (1 - \alpha)^n Y_{1,2}, \quad (2.25)$$

onde α é o parâmetro de suavização do modelo de suavização exponencial simples. Combinando a Equação 2.24 e a Equação 2.25,

$$\hat{X}_n(h) = \hat{X}_n(h) + \frac{1}{2} \hat{b}_0 \left(h - 1 + \frac{1}{\alpha} - \frac{(1 - \alpha)^n}{\alpha} \right) \quad (2.26)$$

Para valores grandes de n , a Equação 2.26 pode ser escrita como:

$$\hat{X}_n(h) = \hat{X}_n(h) + \frac{1}{2}\hat{b}_0 \left(h - 1 + \frac{1}{\alpha} \right) \quad (2.27)$$

Segundo Hyndman e Billah [29], ao dar uma representação em espaço de estados ao método Theta, o seu intervalo de previsão de 95% de probabilidade, para h passos à frente, é dado por

$$\hat{X}_n(h) \pm 1,96 \cdot \sigma \sqrt{(h-1)\alpha^2 + 1}, \quad (2.28)$$

2.4.4 Modelo de suavização exponencial em espaço de estados

A representação de séries temporais no domínio do tempo pode ser dividida em dois diferentes modos: o tradicional e um Markoviano, isto é, a representação em espaço de estados. No segundo, as séries temporais são descritas com o auxílio de variáveis auxiliares, chamadas de variáveis de estado [69]. A natureza determinística das componentes de nível, tendência e sazonalidade dos modelos de decomposição clássica limita a sua aplicabilidade, e uma maneira de contornar esse problema é permitir uma variação aleatória dessas componentes, ou seja, descrevendo a série por meio de um modelo de espaço de estados [41, 52]. A formulação estatística da tendência e da sazonalidade em modelos estruturais precisa ser flexível o suficiente para responder a mudanças gerais na direção da série [70].

A representação básica de um modelo linear q -dimensional em espaço de estados relaciona o vetor de observações \mathbf{Y}_t e o vetor de ruídos \mathbf{v}_t , por intermédio de um processo de Markov \mathbf{X}_t , p -dimensional, chamado de vetor de estados não observáveis [52]. O modelo de espaço de estados é assim definido:

$$\mathbf{Y}_t = \mathbf{A}_t \mathbf{X}_t + \mathbf{v}_t, \quad (2.29)$$

$$\mathbf{X}_t = \mathbf{G}_t \mathbf{X}_{t-1} + \mathbf{w}_t, \quad t = 1, 2, \dots, N, \quad (2.30)$$

em que \mathbf{A}_t é a matriz do sistema, de ordem $(q \times p)$, \mathbf{v}_t é o vetor ruído da observação, de ordem $(q \times 1)$, não correlacionado, com média zero e matriz de covariância \mathbf{R} , \mathbf{G}_t é a matriz de transição, de ordem $(p \times p)$ e \mathbf{w}_t é um vetor de ruídos não correlacionados, representando a perturbação do sistema, de ordem $(p \times 1)$, com média zero e matriz de covariância \mathbf{Q} . A Equação 2.29 é chamada de equação de observação, enquanto que a Equação 2.30 é a equação de estado. Ainda, são suposições no modelo de espaço de estados:

- o estado inicial \mathbf{X}_0 tem média μ_0 e matriz de covariância Σ_0 .
- os vetores de ruídos \mathbf{v}_t e \mathbf{w}_t são não correlacionados entre si e não correlacionados com o estado inicial, isto é, $E(\mathbf{v}_t \mathbf{w}_s') = 0, \forall t, s = 1, \dots, N$ e $E(\mathbf{v}_t \mathbf{X}_0') = E(\mathbf{w}_t \mathbf{X}_0') = 0, t = 1, \dots, N$.

Quando os vetores de ruído forem normalmente distribuídos o modelo de espaço de estados é gaussiano. No modelo univariado ($q=1$), \mathbf{A}_t é um vetor e \mathbf{v}_t é um ruído com média zero e variância σ_v^2 [52].

Descrição na forma de modelos de espaço de estados de inovações

Para cada método de suavização exponencial apresentado na Tabela 2.1, há dois modelos de espaço de estados: um para a modelagem com erros na forma aditiva e com erros na forma multiplicativa. Os modelos são representados de acordo com a natureza dos erros, da tendência e da sazonalidade, tal como descrito na Tabela 2.1. As previsões pontuais dos dois modelos são as mesmas, embora os intervalos de previsão sejam diferentes. Especificado o modelo, pode-se estudar a distribuição de probabilidade dos valores futuros da série e encontrar a média condicional de uma observação futura dado o conhecimento das observações passadas, $\mu_{t+h} = E(y_{t+h} | \mathbf{x}_t)$, onde \mathbf{x}_t contém as componentes não observáveis (estados) como l_t, b_t e s_t [54].

A título de exemplo, um modelo Holt com tendência linear, na forma aditiva, pode ser expresso pelas seguintes equações:

$$y_t = l_{t-1} + b_{t-1} + \varepsilon_t \quad (2.31a)$$

$$l_t = l_{t-1} + b_{t-1} + \alpha \varepsilon_t \quad (2.31b)$$

$$b_t = b_{t-1} + \beta^* (l_t - l_{t-1} - b_{t-1}) = b_{t-1} + \alpha \beta^* \varepsilon_t \quad (2.31c)$$

com $\beta = \alpha \beta^*$. Esse modelo é escrito em forma de espaço de estados fazendo $\mathbf{x}_t = (l_t, b_t)'$ e expressando as Equações 2.31a a 2.31c como

$$y_t = \begin{bmatrix} 1 & 1 \end{bmatrix} \mathbf{x}_{t-1} + \varepsilon_t \quad (2.32)$$

$$\mathbf{x}_t = \begin{bmatrix} l_t \\ b_t \end{bmatrix} = \begin{bmatrix} 1 & 1 \\ 0 & 1 \end{bmatrix} \mathbf{x}_{t-1} + \begin{bmatrix} \alpha \\ \beta \end{bmatrix} \varepsilon_t \quad (2.33)$$

O modelo é especificado inteiramente uma vez definida a distribuição do termo de erro ε_t . Considerando a premissa de erros independentes e uniformemente distribuídos e seguindo uma distribuição normal com média zero e variância σ^2 , tem-se que $\varepsilon_t \sim \mathcal{N}(0, \sigma^2)$.

Dito isso, é possível derivar equações dos modelos de espaço de estados para todos os trinta possíveis métodos de suavização exponencial. O modelo geral envolve um vetor de estados $\mathbf{x}_t = (l_t, b_t, s_t, s_{t-1}, \dots, s_{t-m+1})'$ e equações de espaço de estados na forma

$$y_t = w(\mathbf{x}_{t-1}) + r(\mathbf{x}_{t-1})\varepsilon_t \quad (2.34)$$

$$\mathbf{x}_t = \mathbf{f}(\mathbf{x}_{t-1}) + \mathbf{g}(\mathbf{x}_{t-1})\varepsilon_t, \quad (2.35)$$

onde ε_t é um ruído branco com variância σ^2 e $\mu_t = w(\mathbf{x}_{t-1})$. O modelo com erros aditivos tem $r(\mathbf{x}_{t-1}) = 1$, de modo que $y_t = \mu_t + \varepsilon_t$. Já no modelo com erros multiplicativos $r(\mathbf{x}_{t-1}) = \mu_t$ e $y_t = \mu_t(1 + \varepsilon_t)$. Algumas combinações de tendência, sazonalidade e erros podem levar a modelos que ocasionem dificuldades numéricas, a exemplo da necessidade de divisão por um valor de estado que seja próximo de zero. Isso acontece com modelos de erros aditivos e sazonalidade multiplicativa ou tendência multiplicativa, assim como com modelos de erros multiplicativos, tendência multiplicativa e sazonalidade aditiva [54]. Essa abordagem, que leva o nome inovações em espaço de estados, vêm do fato de que todas as equações utilizam o mesmo processo aleatório de erro ε_t , razão pela qual é conhecido como modelo de única fonte de erro [42].

As previsões pontuais desses modelos podem ser obtidas pela iteração das equações Equações 2.34 a 2.35 para $t = n + 1, n + 2, \dots, n + h$ e fazendo $\varepsilon_{n+j} = 0, j = 1, \dots, h$. Os modelos também permitem obter intervalos de previsão, que no caso de modelos lineares, onde as distribuições são Gaussianas, são calculados com base na variância condicional $v_{t+h|t} = V(y_{t+h}|\mathbf{x}_t)$, procedimento que vale também para a maioria dos modelos não-lineares [54].

Estimação e seleção de modelos

Embora haja outros métodos de estimação, o mais comumente utilizado para modelos de inovação em espaço de estados é aquele baseado na maximização da verossimilhança. Para um modelo de erros aditivos, essa maximização, assumindo erros normalmente distribuídos, equivale a minimizar a soma dos erros quadráticos [42].

Considerando a distribuição conjunta $p(\mathbf{y}|\theta, \mathbf{x}_0, \sigma^2)$, e o modelo geral das Equações 2.34 a 2.35, a verossimilhança é dada por

$$-2 \ln \mathcal{L}(\theta, \mathbf{x}_0 | \mathbf{y}) = \mathcal{L}^*(\theta, \mathbf{x}_0) = n \ln \left(\sum_{t=1}^n \varepsilon_t^2 \right) + 2 \sum_{t=1}^n \ln |r(\mathbf{x}_{t-1})|, \quad (2.36)$$

onde $\theta = (\alpha, \beta, \gamma, \phi)'$ é o vetor de parâmetros, $\mathbf{x}_0 = (l_0, b_0, s_0, s_{-1}, \dots, s_{-m+1})'$ o vetor de estados iniciais e n o número de observações da série. Esse cálculo é feito recursivamente

por meio das equações do modelo de espaço de estados. Assim, os parâmetros θ e os estados iniciais \mathbf{x}_0 podem ser estimados minimizando \mathcal{L}^* [54].

A otimização, entretanto, se inicia com \mathbf{x}_0 obtido por uma heurística que define os valores iniciais dos estados e $\theta_0 = (0, 1, 0, 01, 0, 01, 0, 99)'$. Embora haja diversas propostas de restrição do espaço de parâmetros, a estratégia mais comum é garantir que as várias equações possam ser interpretadas como médias móveis e, portanto, impondo que os parâmetros α , $\beta_* = \beta/\alpha$, $\gamma_* = \gamma/(1 - \alpha)$ e ϕ estejam no intervalo $(0, 1)$ [42, 54]. Isso leva a que $0 < \alpha < 1$, $0 < \beta < \alpha$, $0 < \gamma < 1 - \alpha$ e $0 < \phi < 1$.

A seleção do modelo que melhor se ajusta aos dados usa um critério de função penalizadora, cuja penalização depende da complexidade do modelo, ou seja, do seu número de parâmetros. Para modelos ETS, podem ser utilizados o critério de informação de Akaike [71] e variações dele [54]. O critério de Akaike é definido por:

$$AIC = \mathcal{L}^*(\hat{\theta}, \hat{\mathbf{x}}_0) + 2q, \quad (2.37)$$

onde q é o número de parâmetros do vetor θ mais o número de graus de liberdade no vetor de estados \mathbf{x}_0 , sendo $\hat{\theta}$ e $\hat{\mathbf{x}}_0$ estimativas de θ e de \mathbf{x}_0 , respectivamente. De uma forma mais geral:

$$AIC = -2 \ln(L) + 2q, \quad (2.38)$$

onde L é a verossimilhança do modelo. A partir do AIC , foram desenvolvidos outros critérios, como o AIC corrigido, dado por

$$AIC_c = AIC + \frac{q(q+1)}{n-q-1}, \quad (2.39)$$

e também o critério de informação bayesiano, dado por

$$BIC = AIC + q[\ln(n) - 2], \quad (2.40)$$

onde n é o número de observações da série. Utilizando qualquer um desses critérios, é escolhido o modelo com menor valor do critério dentre os modelos que são apropriados para os dados.

2.4.5 Modelo autoregressivo integrado de médias móveis

Uma metodologia bastante utilizada na análise de modelos paramétricos e previsão de séries temporais é conhecida como abordagem de Box e Jenkins (1970), que consiste em ajustar modelos autoregressivos integrados de médias móveis, ARIMA (p, d, q) , a um conjunto de observações de uma série. A estratégia de construção do modelo é baseada em

um ciclo iterativo que envolve a consideração de uma classe geral de modelos (especificação), a escolha dos parâmetros p , d e q por meio da análise de correlações, autocorrelações e outros critérios (identificação), a estimação dos parâmetros (estimação) e a verificação do modelo por meio da análise de resíduos (diagnóstico) [52]. Enquanto os métodos e modelos de suavização exponencial são baseados na descrição dos padrões da tendência e sazonalidade da série, o modelo ARIMA objetiva descrever a autocorrelação presente nas observações da série.

O modelo ARIMA faz parte da classe dos modelos lineares de séries temporais, e pode ser considerado um caso particular de um modelo de filtro linear, que pressupõe que uma série temporal Z_t é gerada por meio de um sistema linear cuja entrada é um ruído branco a_t [52]. Utilizando uma notação formal

$$Z_t = \mu + a_t + \psi a_{t-1} + \psi a_{t-2} + \dots = \mu + \psi(B)a_t, \quad (2.41)$$

em que

$$\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 \dots \quad (2.42)$$

é denominada função de transferência do sistema linear e μ é um parâmetro determinando o nível da série. O operador B é o operador de translação para o passado e definido por $BZ_t = Z_{t-1}$, $B^m Z_t = Z_{t-m}$. Feitas essas considerações, Z_t então é um processo linear discreto. Considerando que $a_t \sim N(0, \sigma^2)$, então $E(a_t) = 0$ e $Var(a_t) = \sigma^2, \forall t$ e $E(a_t a_s) = 0, s \neq t$. Chamando $\tilde{Z}_t = Z_t - \mu$, tem-se que

$$\tilde{Z}_t = \psi(B)a_t \quad (2.43)$$

Se a sequência de pesos $\psi_j, j \geq 1$ for finita ou infinita e convergente, o filtro é estável e Z_t é estacionária, com μ sendo a média do processo. Caso contrário, Z_t é não estacionária e μ não tem um significado específico, a não ser como um ponto de referência para o nível da série [52].

É possível escrever \tilde{Z}_t em uma forma alternativa, como uma soma ponderada de valores passados $\tilde{Z}_{t-1}, \tilde{Z}_{t-2}, \dots$ mais um ruído a_t :

$$\tilde{Z}_t = \pi_1 \tilde{Z}_{t-1} + \pi_2 \tilde{Z}_{t-2} + \dots + a_t = \sum_{j=1}^{\infty} \pi_j \tilde{Z}_{t-j} + a_t \quad (2.44)$$

De onde se segue que

$$\pi(B)\tilde{Z}_t = a_t, \quad (2.45)$$

onde $\pi(B)$ é o operador $\pi(B) = 1 - \pi_1 B - \pi_2 B^2 - \dots$

Propriedades importantes do sistema linear, como a estacionariedade e invertibilidade serão obtidas caso as séries $\psi(B)$ e $\pi(B)$ convirjam para $|B| < 1$, o que leva a restrições de valores que podem assumir os parâmetros do modelo [41]. Introduzidos os processos lineares, são definidos, a seguir, os modelos autoregressivos (AR) e de médias móveis (MA), que formam a base do modelo ARIMA.

Modelo autoregressivo

Partindo da Equação 2.44, se $\pi_j = 0, j > p$, obtém-se um modelo autoregressivo de ordem p , conhecido como AR(p) [52]:

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t, \quad (2.46)$$

a partir da renomeação dos pesos para a notação mais usual e do ruído de a_t para ε_t . Definindo o operador autoregressivo estacionário de ordem p como

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p, \quad (2.47)$$

pode-se escrever

$$\phi(B) \tilde{Z}_t = \varepsilon_t \quad (2.48)$$

A partir da Equação 2.46, percebe-se que a variável de interesse é prevista utilizando uma combinação linear de observações anteriores dessa mesma variável, daí o nome autorregressivo. Trata-se de uma regressão múltipla que utiliza os valores passados da variável em diferentes instantes como preditores.

Modelo de médias móveis

De modo semelhante, considerando o processo linear da Equação 2.41, com $\psi_j = 0, j > q$, obtém-se um modelo de médias móveis de ordem q , conhecido como MA(q) [52]:

$$Z_t = \mu + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.49)$$

a partir da renomeação dos pesos para a notação mais usual e do ruído de a_t para ε_t . Sendo $\tilde{Z}_t = Z_t - \mu$ e o operador de médias móveis

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q, \quad (2.50)$$

pode-se escrever

$$\tilde{Z}_t = (1 - \theta_1 B - \dots - \theta_q B^q) \varepsilon_t = \theta(B) \varepsilon_t \quad (2.51)$$

A partir da Equação 2.49, percebe-se que a variável de interesse é prevista utilizando valores de erros passados como em um modelo de regressão, que não é assim considerada, em sentido estrito, já que os valores de ε_t não são observáveis. Os valores da série podem ser encarados como uma média móvel de erros de previsão em instantes passados [42].

Modelo autoregressivo integrado de médias móveis (ARIMA)

Os modelos autoregressivos (AR) e de médias móveis (MA) e autoregressivos de médias móveis (ARMA) são apropriados para descrever séries estacionárias, embora muitas séries não possuam essa característica. Todavia, ao utilizar uma operação de diferença na série, tal que $\Delta^d Z_t = Z_t - Z_{t-d} = (1 - B)^d Z_t$, obtém-se, se for o caso, uma série W_t estacionária. Assim, se $W_t = \Delta_d Z_t$ for estacionária, podemos representá-la por um modelo ARMA(p, q)

$$\phi(B)W_t = \theta(B)\varepsilon_t \quad (2.52)$$

Como W_t é uma diferença de Z_t , então Z_t é uma integral de W_t , razão pela qual dizemos que Z_t , nesse caso, segue um modelo autoregressivo integrado de médias móveis (ARIMA) não sazonal

$$\phi(B)\Delta^d Z_t = \theta(B)\varepsilon_t, \quad (2.53)$$

de ordem (p, d, q) , ou ARIMA(p, d, q), se p e q são as ordens de $\phi(B)$ e $\theta(B)$, respectivamente, e $\varepsilon_t \sim \mathcal{N}(0, \sigma^2)$.

Portanto, um modelo ARIMA não sazonal é uma combinação de uma operação de diferença d aplicada à série, de um modelo autoregressivos de ordem p e de um modelo de médias móveis de ordem q . Ou seja, o modelo pode ser considerado uma regressão onde a variável de interesse tem como preditores tanto observações como erros de previsão passados.

O modelo ARIMA também é capaz de modelar uma vasta gama de séries sazonais. Um modelo ARIMA sazonal é formado pela inclusão de termos sazonais ao modelo ARIMA não sazonal [42]. Para simplificar a apresentação do modelo, a fórmula geral para um modelo ARIMA sazonal $(p, d, q)(P, D, Q)_m$, para uma série de frequência m [52]:

$$\phi(B)\Phi(B^m)\Delta^d\Delta_m^D Z_t = \theta(B)\Theta(B^m)\varepsilon_t \quad (2.54)$$

Na Equação 2.54:

- $\Phi(B^m) = 1 - \Phi_1(B^m) - \Phi_2(B^{2m}) - \dots - \Phi_P(B^{Pm})$, é operador autoregressivo sazonal de ordem P , estacionário;
- $\Theta(B^m) = 1 - \Theta_1(B^m) - \Theta_2(B^{2m}) - \dots - \Theta_Q(B^{Qm})$, é o operador de médias móveis sazonal de ordem Q , invertível;
- $\Delta_m = (1 - B^m)$ é o operador de diferença sazonal;
- $\Delta_m^D = (1 - B^m)^D$, D indicando o número de diferenças sazonais;

Nesse modelo devem ser realizadas d diferenças simples e D diferenças sazonais de Z_t , de modo que o processo $W_t = \Delta_d \Delta_m^D Z_t$ seja estacionário. Os termos sazonais são simplesmente multiplicados pelos termos não sazonais. A título de exemplo, um modelo ARIMA $(1, 1, 1)(1, 1, 1)_{m=4}$, ou seja, para dados com frequência de observação trimestral, pode ser escrito da seguinte forma:

$$(1 - \phi_1 B)(1 - \Phi_1 B^4)(1 - B)(1 - B^4)Z_t = (1 + \theta_1 B)(1 + \Theta_1 B^4)\varepsilon_t \quad (2.55)$$

Identificação de modelos ARIMA

A identificação envolve a escolha das ordens p , d e q do modelo ARIMA que será ajustado aos dados. A seleção de modelos é uma parte crítica da análise de dados, uma atividade que têm se tornado mais importante à medida que a capacidade computacional disponível permite o ajuste de modelos mais realistas, flexíveis e complexos [72].

Embora essa escolha, para o modelo ARIMA, possa ser realizada por meio das autocorrelações e autocorrelações parciais estimadas, esse método leva à identificação de modelos diferentes, utilizando a mesma série, razão pela qual diversas outras abordagens têm sido apresentadas na literatura especializada [52]. Em geral, essas abordagens buscam equilibrar o compromisso entre a complexidade do modelo, representada pela quantidade de parâmetros e a sua capacidade de ajuste aos dados disponíveis [72]. Para modelos ARIMA, uma forma de melhorar a identificação consiste em utilizar os critérios apresentados na Seção 2.4.4, como AIC , AIC_c e BIC .

Estimação de modelos ARIMA

A estimação dos modelos ARIMA consiste no cálculo de seus parâmetros. Um modelo ARIMA(p, d, q), tem o seu vetor de parâmetros $\xi = (\phi, \theta, \sigma_\varepsilon^2)$, onde $\phi = (\phi_1, \dots, \phi_p)$, $\theta = (\theta_1, \dots, \theta_q)$, sendo ainda o vetor $\eta = (\phi, \theta)$. Para $d > 0$, supõe-se $\mu_w = 0$. Caso contrário, μ_w é incluído como mais um parâmetro a ser estimado, aumentando o número de parâmetros de $p + q + 1$ para $p + q + 2$ [52].

Para estimar ξ , o método comumente empregado é o da máxima verossimilhança condicional (EMV). Levando em conta as N observações Z_1, \dots, Z_N , $L(\xi|Z_1, \dots, Z_N)$ é a função de verossimilhança, e os estimadores de máxima verossimilhança de η serão os valores que maximizam L ou $l = \log(L)$. Para calcular esses estimadores, é possível supor que o processo ε é normal, ou seja, para cada t , $\varepsilon_t \sim \mathcal{N}(0, \sigma_\varepsilon^2)$, de modo que os estimadores serão, nesse caso, equivalentes aos estimadores de mínimos quadrados condicionais [52].

Previsão nos modelos ARIMA

Identificado o modelo e feitos sua estimação e diagnóstico, são calculadas as previsões para h passos à frente, Z_{t+h} , $h \geq 1$, dadas as observações da série $\dots, Z_{t-2}, Z_{t-1}, Z_t$, até instante t (origem das previsões). Considerando o modelo ARIMA (p, d, q) escrito como na Equação 2.53, obtém-se a equação de previsão substituindo t por $t + h$:

$$Z_{t+h} = \phi_1 Z_{t+h-1} + \dots + \phi_{p+d} Z_{t+h-p-d} - \theta_1 \varepsilon_{t+h-1} - \theta_2 \varepsilon_{t+h-2} - \dots - \theta_q \varepsilon_{t+h-q} + \varepsilon_{t+h} \quad (2.56)$$

Usando a minimização do erro quadrático médio (EQM) e a representação de Z_{t+h} na forma de médias móveis, $e_t(h) = Z_{t+h} - \hat{Z}_t(h) = \sum_{j=0}^{h-1} \psi_j \varepsilon_{t+h-j}$, $h \geq 1$, $[Z_{t+h}] = E[Z_{t+h}|Z_t, Z_{t-1}, \dots]$. Assim, a previsão de EQM mínimo é a esperança condicional de Z_t , dadas as observações passadas da série, ou seja, $\hat{Z}_t(h) = [Z_{t+h}]$ [52]. Além disso, $[e(t)] = 0$ e a variância do erro de previsão é dada por

$$V(h) = (1 + \psi_1^2 + \psi_1^2 + \dots + \psi_{h-1}^2) \sigma_\varepsilon^2 \quad (2.57)$$

Os erros de previsão a um passo são não-correlacionados, o que não acontece para $h \geq 1$ [52]. Assim, a equação de previsão é aquela resultante da aplicação da esperança condicional na Equação 2.56, obtendo-se

$$\hat{Z}_t(h) = \phi_1 [Z_{t+h-1}] + \dots + \phi_{p+d} [Z_{t+h-p-d}] - \theta_1 [\varepsilon_{t+h-1}] - \dots - \theta_q [\varepsilon_{t+h-q}] + [\varepsilon_{t+h}], \quad (2.58)$$

para $h \geq 1$, devendo-se utilizar os seguintes resultados [52]:

$$[Z_{t+k}] = \hat{Z}_t(k), \quad k > 0 \quad (2.59)$$

$$[Z_{t+k}] = Z_{t+k}, \quad k \leq 0 \quad (2.60)$$

$$[\varepsilon_{t+k}] = 0, k > 0 \quad (2.61)$$

$$[\varepsilon_{t+k}] = \varepsilon_{t+k}, k \leq 0 \quad (2.62)$$

De posse da variância dos erros de previsão (Equação 2.57), faz-se uma suposição a mais a respeito dos erros para calcular os intervalos de previsão de Z_{t+h} . Além de supor que $E(\varepsilon_t) = 0$, $Var(\varepsilon_t) = \sigma_\varepsilon^2$, $\forall t$ e $E(\varepsilon_t \varepsilon_s) = 0$, $t \neq s$, supõe-se que $\varepsilon_t \sim \mathcal{N}(0, \sigma_\varepsilon^2)$, para cada t . Dadas as observações passadas da série, a distribuição condicional de $Z_{t+h} \sim \mathcal{N}(\hat{Z}_t(h), V(h))$. Portanto,

$$U = \frac{Z_{t+h} - \hat{Z}_t(h)}{[V(h)]^{1/2}} \sim \mathcal{N}(0, 1) \quad (2.63)$$

Fixado o nível de confiança γ , recorre-se à tabela da distribuição normal para encontrar o valor de u_γ tal que $P(-u_\gamma < U < u_\gamma) = \gamma$. Ou seja, o intervalo da previsão com probabilidade γ é dado por:

$$\hat{Z}_t(h) \pm u_\gamma [V(h)]^{1/2} \quad (2.64)$$

2.4.6 Redes Neurais *Long Short Term Memory* (LSTM)

As redes neurais recorrentes (RNN) são uma família de redes neurais para o processamento de dados sequenciais, que, diferentemente das redes neurais convencionais do tipo *feedforward*, se aproveitam da idéia de compartilhar parâmetros entre diferentes partes do modelo. As RNN compartilham os parâmetros fazendo com que cada elemento de saída seja produzido utilizando a mesma regra de atualização aplicada ao elemento anterior da saída [1].

Esse compartilhamento se dá por meio de conexões que formam ciclos, tal como a conexão apresentada na Figura 2.1, dotando essas redes de uma capacidade de mapear qualquer valor histórico sequencial para a saída (capacidade de memória), ou seja, permitem que determinadas entradas persistam no estado interno da rede, podendo ser utilizadas para influenciar a saída da rede, dando às redes neurais recorrentes, com um número suficiente de unidades internas ou nós, a capacidade de aproximar qualquer mapeamento de uma sequência de entrada para uma sequência de saída [73].

As redes recorrentes utilizam a Equação 2.65 para definir o valor de seus estados internos (*hidden states*).

$$\mathbf{h}^{(t)} = f(\mathbf{h}^{(t-1)}, \mathbf{x}^{(t)}; \theta), \quad (2.65)$$

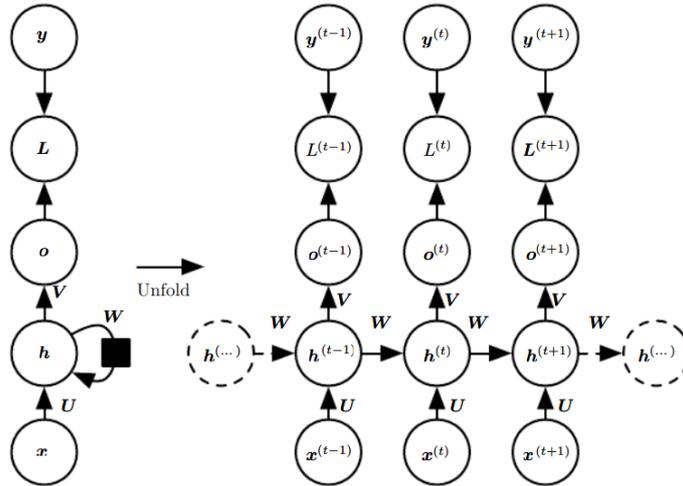


Figura 2.1: Arquitetura básica de uma rede neural recorrente. (Fonte: [1]).

onde θ é o conjunto de parâmetros da rede.

Tendo como referência a arquitetura apresentada na Figura 2.1, parametrizada pelo conjunto de parâmetros $\theta = [W, U, V, b, c, h_0]$, e uma sequência de entrada x_1, \dots, x_T , o algoritmo a seguir faz o processamento dos estados internos e das saídas a partir das entradas da rede [1, 73]:

Algoritmo 1: Processamento dos estados internos e das saídas a partir das entradas de uma RNN

Entrada: W, U, V, b, c, h_0

Saída: $h^{(t)}, \hat{y}^{(t)}$

para t **de** 1 **até** T **faça**

- 1: $a^{(t)} \leftarrow Wh^{(t-1)} + Ux^{(t)} + b$;
- 2: $h^{(t)} \leftarrow e(a^{(t)})$;
- 3: $o^{(t)} \leftarrow Vh^{(t)} + c$;
- 4: $\hat{y}^{(t)} \leftarrow g(o^{(t)})$

fim

Nesse algoritmo, h_0 é um vetor de parâmetros que armazena o estado inicial do modelo, $e(\cdot)$ e $g(\cdot)$ são não-linearidades representadas por funções de ativação, b e c os vieses (*bias*) e U , V e W as matrizes de pesos, respectivamente, das entradas para os estados internos, dos estados internos para a saída e das conexões entre os estados internos. A depender da tarefa executada pela rede, como classificação ou regressão, a função de ativação da saída $g(\cdot)$ pode ser do tipo *softmax*, sigmóide logística ou qualquer outra função diferenciável [74].

A função de perda (loss function) de uma RNN é a soma das perdas em cada instante t e dada por

$$L(\hat{y}, y) = \sum_{t=1}^T L(\hat{y}^{(t)}, y^{(t)}) \quad (2.66)$$

onde $L(\hat{y}^{(t)}, y^{(t)})$ pode ser uma medida de erro como o erro absoluto ou quadrático médio, por exemplo. De posse dessa função, os parâmetros são atualizados por meio de derivações parciais calculadas no sentido inverso, por meio do algoritmo de retropropagação do erro no tempo (BPTT) [73]:

Algoritmo 2: Algoritmo de retropropagação do erro no tempo (BPTT)

Entrada: W, U, V, b, c, h_0

Saída: $d\theta = [dW, dU, dV, db, dc, dh_0]$

para t **de** T **até** 1 **faça**

- 1: $do^{(t)} \leftarrow g'(o^{(t)}) \cdot dL(\hat{y}^{(t)}, y^{(t)}) / dy^{(t)}$;
- 2: $dc \leftarrow dc + do^{(t)}$;
- 3: $dV \leftarrow dV + do^{(t)} h^{(t)\top}$;
- 4: $dh^{(t)} \leftarrow dh^{(t)} + dW^\top do^{(t)}$;
- 5: $dy^{(t)} \leftarrow e'(y^{(t)}) \cdot dh^{(t)}$;
- 6: $dU \leftarrow dU + dy^{(t)} dx^{(t)\top}$;
- 7: $db \leftarrow db + dy^{(t)}$;
- 8: $dW \leftarrow dW + dy^{(t)} dh^{(t-1)\top}$;
- 9: $dh^{(t-1)} \leftarrow W^\top dy^{(t)}$

fim

Embora o cálculo dos gradientes de uma RNN seja simples, o treinamento da rede é difícil, especialmente com dependências temporais de longo prazo, devido à sua natureza não linear [73]. Isso faz com que gradientes que se propagam através de muitos estágios diminuam consideravelmente ou cresçam significativamente, problema conhecido como gradiente diminuído ou explosivo [1, 74]. Com isso, a influência de uma dada entrada na saída da rede no longo prazo pode ser insignificante, fazendo com que a RNN perca a sua característica de carregar, ao longo do tempo, informações do contexto, para influenciar a sua saída [74].

LSTM

Embora diversas alternativas tenham sido desenvolvidas para o tratamento do problema do gradiente diminuído ou explosivo, a mais efetiva foi o desenvolvimento da arquitetura *Long Short Term Memory (LSTM)* [74]. Essa arquitetura introduz autociclos por meio dos quais os gradientes seguem sem serem diminuídos ou aumentados drasticamente, mesmo

no longo prazo, permitindo que a rede acumule informação, ou seja, tenha capacidade de memória. O diagrama de blocos de uma célula LSTM é apresentada na Figura 2.2.

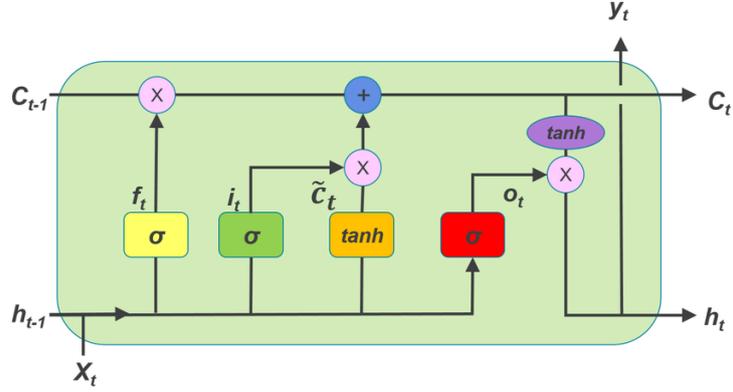


Figura 2.2: Diagrama de blocos de uma célula LSTM.

Cada célula tem as mesmas entradas e saídas, como as redes RNN, porém possui mais parâmetros e um sistema de unidades que controlam o fluxo de informação [1]. Essas unidades são conhecidas como *forget gate*, *input gate* e *output gate*. As Equações 2.67 a 2.72 apresentam o cálculo da saída $h^{(t)}$ de uma célula LSTM com base em suas entradas $\mathbf{x}^{(t)}$.

$$f^{(t)} = \sigma(\mathbf{U}_f \mathbf{x}^{(t)} + \mathbf{W}_f \mathbf{h}^{(t-1)} + b_f) \quad (2.67)$$

$$i^{(t)} = \sigma(\mathbf{U}_i \mathbf{x}^{(t)} + \mathbf{W}_i \mathbf{h}^{(t-1)} + b_i) \quad (2.68)$$

$$\tilde{C}^{(t)} = \tanh(\mathbf{U}_c \mathbf{x}^{(t)} + \mathbf{W}_c \mathbf{h}^{(t-1)} + b_c) \quad (2.69)$$

$$C^{(t)} = f^{(t)} * C^{(t-1)} + i^{(t)} * \tilde{C}^{(t)} \quad (2.70)$$

$$o^{(t)} = \sigma(\mathbf{U}_o \mathbf{x}^{(t)} + \mathbf{W}_o \mathbf{h}^{(t-1)} + b_o) \quad (2.71)$$

$$h^{(t)} = o^{(t)} * \tanh(C^{(t)}) \quad (2.72)$$

Nessas equações, \mathbf{b}_f , \mathbf{W}_f , \mathbf{U}_f são os vieses (bias), pesos de entrada e os pesos aplicados à unidade *forget gate* $f^{(t)}$. Os elementos \mathbf{b}_i , \mathbf{W}_i , \mathbf{U}_i são os vieses (bias), pesos de entrada e os pesos aplicados à unidade *input gate* $i^{(t)}$ e \mathbf{b}_c , \mathbf{W}_c , \mathbf{U}_c são os vieses (bias), pesos

de entrada e os pesos aplicados à entrada da célula LSTM. $C^{(t)}$ é o estado da célula no instante t .

O mecanismo de memorização da rede LSTM pode ser entendida da seguinte forma. No primeiro passo decide-se qual informação será descartada do estado de célula, o que é feito pela saída da unidade *forget gate* (Equação 2.67). Se a saída for 1 isso significa manter a informação, ao passo que 0 significa descartá-la. No segundo passo decide-se o que vai ser armazenado no estado da célula. Inicialmente a função sigmóide da unidade *input gate* decide que valores serão atualizados (Equação 2.68) e, em seguida, a camada $\tanh()$ cria um vetor de novos candidatos $\tilde{C}^{(t)}$ que serão adicionados ao estado (Equação 2.69). De posse do que será descartado e adicionado ao estado da célula, atualiza-se o estado (Equação 2.70). Finalmente, decide-se qual será a saída da célula, que será o resultado da função sigmóide aplicada ao estado da célula, definindo, assim, que partes do estado farão parte da saída (Equação 2.71). Então, esse resultado é aplicado a uma função $\tanh()$, que muda a escala dos valores para $[-1,1]$ e multiplicado pela saída da unidade *output gate*, definindo o que será produzido na saída da célula (Equação 2.72).

Arquitetura LSTM Codificador-Decodificador

As redes recorrentes podem ser ter várias arquiteturas, mas uma, em especial, é adequada para o mapeamento de uma sequência de entrada cujo tamanho seja diferente da tamanho da sequência de saída: arquitetura codificador-decodificador (*encoder-decoder*) ou sequência para sequência (*sequence2sequence*). É o caso de aplicações de reconhecimento de voz, máquinas de tradução e resposta a perguntas [1], assim como aplicações de previsão de séries temporais [75].

A idéia desta arquitetura, apresentada na Figura 2.3, é a seguinte: o codificador (ou RNN de entrada) processa a sequência de entrada $\mathbf{x}^{(t)}$, de tamanho n_x , e produz o contexto C , que é um vetor de tamanho fixo que define uma representação da entrada, sendo uma função do estado interno final da rede. O decodificador (ou RNN de saída), condicionada ao tamanho do contexto C , produz a sequência de saída $Y = (y^{(1)}, \dots, y^{n_y})$, de tamanho n_y .

Otimização para redes LSTM

A otimização dos parâmetros de uma rede LSTM, como é comum a outros modelos e arquiteturas, consiste em encontrar parâmetros θ que reduzam significativamente uma função de custo $J(\theta)$, que, tipicamente, inclui uma medida de desempenho avaliada no conjunto de dados de treinamento e termos de regularização. Embora haja diversos algoritmos de otimização, escolhas razoáveis são o gradiente descendente estocástico (SGD) com momento e o algoritmo com taxa de aprendizagem adaptativa Adam [1].

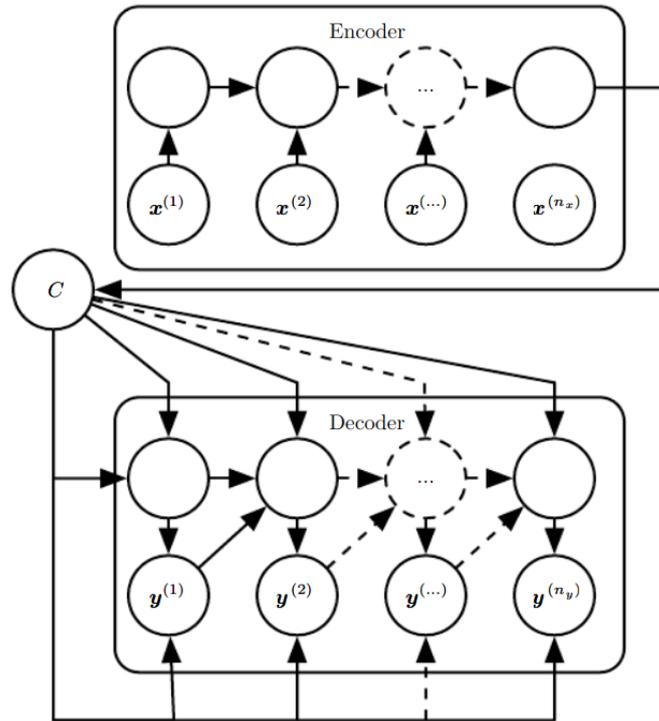


Figura 2.3: Arquitetura codificador-decodificador para mapeamento de entre seqüências de tamanho diferentes. Fonte: [1].

Seleção de Hiperparâmetros

Os algoritmos de aprendizagem de máquina também possuem parâmetros que controlam aspectos de seu comportamento, conhecidos como hiperparâmetros. Alguns desses parâmetros afetam o custo computacional em termos de tempo e memória, ao passo que outros afetam a qualidade de generalização do modelo. De um modo geral, as técnicas para seleção de parâmetros podem ser divididas em manuais e automatizadas, sendo as últimas mais custosas em termos computacionais [1]. Em qualquer das técnicas, o problema consiste em buscar um máximo (ou mínimo) de uma função $f : \mathcal{X} \rightarrow \mathbb{R}$,

$$\mathbf{x}_{\text{ótimo}} = \arg \max_{\mathbf{x} \in \mathcal{X}} f(\mathbf{x}), \quad (2.73)$$

com o domínio $\mathcal{X} \subset \mathbb{R}^d$.

A técnica de seleção manual pressupõe o entendimento da relação entre os hiperparâmetros, o erro de treinamento, o erro de generalização e o custo computacional. O objetivo é encontrar o menor erro de generalização dada uma restrição computacional em termos de memória e poder de processamento. A seleção manual pode funcionar bem quando o projetista tem um conjunto de valores iniciais a partir do qual ele possa

trabalhar, geralmente pela aplicação de modelos com a mesma arquitetura em outras aplicações semelhantes, mas geralmente não é esse o caso, razão porque as técnicas de seleção automatizadas são muito utilizadas [1].

Em geral, as técnicas de otimização automatizada de hiperparâmetros mais comumente utilizadas são a busca em grid (*grid search*), busca aleatória (*random search*) e busca baseada em modelos probabilísticos.

Na primeira, define-se um conjunto finito e pequeno de valores para cada hiperparâmetro e o algoritmo treina o modelo para cada combinação do produto cartesiano entre os valores dos parâmetros, selecionando aquela combinação com o menor erro de validação. A busca em grid tem custo exponencial $O(n^m)$, que é elevado, onde m é o número de parâmetros e n o número máximo de valores que eles podem assumir [1].

O método de busca aleatória consiste em definir uma distribuição marginal para cada hiperparâmetro, geralmente uniforme ou log-uniforme e isso cria uma distribuição de probabilidade conjunta da configuração dos parâmetros. O algoritmo aleatoriamente amostra a distribuição conjunta e treina o modelo com essa amostra de parâmetros e retorna aquele conjunto de parâmetros com o menor erro de validação. Esse método é simples e conveniente, além de convergir mais rápido para bons valores dos hiperparâmetros [1].

Otimização baseada em modelos bayesianos

A otimização bayesiana dos hiperparâmetros consiste em construir um modelo de probabilidade da função objetivo e utilizá-la para selecionar os hiperparâmetros mais promissores, a fim de avaliá-los na função objetivo real. Ela guarda resultados anteriores da avaliação, os quais são utilizados para formar um mapeamento probabilístico dos hiperparâmetros para a probabilidade da avaliação na função objetivo, ou seja, $P(\text{avaliação} \mid \text{hiperparâmetros})$.

A função que substitui a real função objetivo é chamada de substituta (*surrogate*), sendo representada por $p(y|x)$. Essa função é mais fácil de otimizar e os métodos bayesianos procuram o próximo conjunto de parâmetros para avaliar na função objetivo real, selecionando aquele conjunto com melhor resultado na função *surrogate*. Como a escolha dos hiperparâmetros leva em consideração regiões mais promissoras do espaço de parâmetros, isso elimina avaliações custosas da função objetivo, levando à escolha dos hiperparâmetros de forma mais rápida quando comparada com outras técnicas [76].

O algoritmo de otimização sequencial baseada em modelo (SMBO) é uma formalização da otimização bayesiana, onde o termo sequencial se refere às tentativas, uma após a outra, de obter melhores valores dos hiperparâmetros por meio da inferência bayesiana e atualização do modelo de probabilidade da função objetivo (*surrogate*). Embora haja algumas modelagens para a função (*surrogate*), a pesquisa se utilizou do modelo *Tree Parzen Estimator (TPE)*, descrito por Bergstra et al. [76], e implementado pela biblioteca

Python Hyperopt, facilitando a incorporação desse tipo de otimização no modelo LSTM desenvolvido na pesquisa.

Capítulo 3

Metodologia de Pesquisa e Análise dos Resultados

Definido o problema de pesquisa e seus objetivos, este capítulo apresenta a metodologia de pesquisa utilizada neste trabalho, a fim de que fossem atingidos os objetivos propostos. Tratando-se de uma pesquisa experimental de mineração de dados, ela foi dividida em etapas, as quais foram organizadas, sempre que aplicável, em conformidade com as fases propostas pelo *Cross Industry Standard Process for Data Mining* (CRISP-DM) [77]. Depois de uma breve introdução a respeito do CRISP-DM, as demais seções descrevem a aplicação dos conceitos de cada fase do modelo de referência ao problema de pesquisa, de forma a facilitar a identificação das atividades realizadas com as fases do modelo utilizado como referência.

3.1 Modelo de referência CRISP-DM

O CRISP-DM é um modelo de referência que nasceu no final do século XX, pela iniciativa de especialistas, sendo depois apropriado por um consórcio de empresas para se tornar um padrão de fato no desenvolvimento de projetos de mineração de dados. Segundo esse modelo, os projetos de mineração de dados têm um ciclo de vida composto por seis fases descritas na Figura 3.1.

O círculo mais externo do ciclo de vida mostra a natureza cíclica dos projetos de mineração de dados. As setas do ciclo de vida indicam as mais frequentes e importantes dependências entre as fases, embora a sequência das fases não seja rígida, de modo que avançar e retornar para diferentes fases é comum [77]. As seis fases do CRISP-DM podem ser assim descritas, de forma sucinta:



Figura 3.1: Ciclo de vida de projetos de mineração de dados segundo o CRISP-DM. (Fonte: [77]).

- **Entendimento do negócio** - Nessa fase o foco é o entendimento dos objetivos do projeto de uma perspectiva do negócio, convertendo esse entendimento na definição do problema de mineração e de um plano preliminar para alcançar os objetivos pretendidos.
- **Entendimento dos dados** - Essa fase se inicia com a coleta inicial dos dados e segue com atividades para promover a familiaridade com os dados, para identificar problemas em relação à qualidade, para fazer inferências iniciais e detectar subconjuntos de dados para formar hipóteses a respeito de informações presentes nos dados.
- **Preparação dos dados** - Essa fase engloba as atividades necessárias para construir o conjunto de dados que servirá de entrada para os modelos da fase de modelagem. Tarefas comuns nessa etapa são a seleção de tabelas, registros e atributos, além de transformações nos dados.
- **Modelagem** - Nessa fase, várias técnicas de modelagem são aplicadas e os seus parâmetros são otimizados. Sendo bastante comum haver várias técnicas diferentes para a solução do problema de mineração, pode-se voltar à fase de preparação dos dados a fim de adequá-los às diferentes técnicas, caso seja necessário.
- **Avaliação** - Nesse estágio o(s) modelo(s) ajustados, mesmo parecendo ter uma alta qualidade do ponto de vista da análise de dados, devem ser avaliados do ponto de vista do alcance dos objetivos de negócio, a fim de saber se há alguma consideração

que não tenha sido suficientemente considerada, antes de partir para a implantação. Ao fim dessa fase, a decisão a respeito do uso dos resultados é tomada.

- **Implantação** - Nessa fase o(s) modelo(s) escolhido(s) devem ser organizados, incorporados aos processos organizacionais e apresentados aos usuários de modo que eles possam utilizá-lo(s) em suas atividades.

3.2 Entendimento do negócio

O registro da distribuição, armazenamento e dispensação dos medicamentos do CEAF é feito por intermédio da Base Nacional de Dados de Ações e Serviços da Assistência Farmacêutica (BNAFAR), a qual foi instituída pela Portaria nº 957/2016/GM/MS [78] e complementada posteriormente pela Portaria nº 938/2017/GM/MS [79], sendo hoje regulamentada pela Portaria de Consolidação nº 1/MS [80], alterada, recentemente, pela Portaria nº 1.737, de 14 de junho de 2018 [81]. O referido repositório é constituído por dados do Sistema Nacional de Gestão da Assistência Farmacêutica (Hórus), serviço de envio de dados (*web service*) e Sistema Autorizador do Programa Farmácia Popular. A Figura 3.2¹ ilustra a BNAFAR:

Base Nacional de Dados de Ações e Serviços da Assistência Farmacêutica no SUS

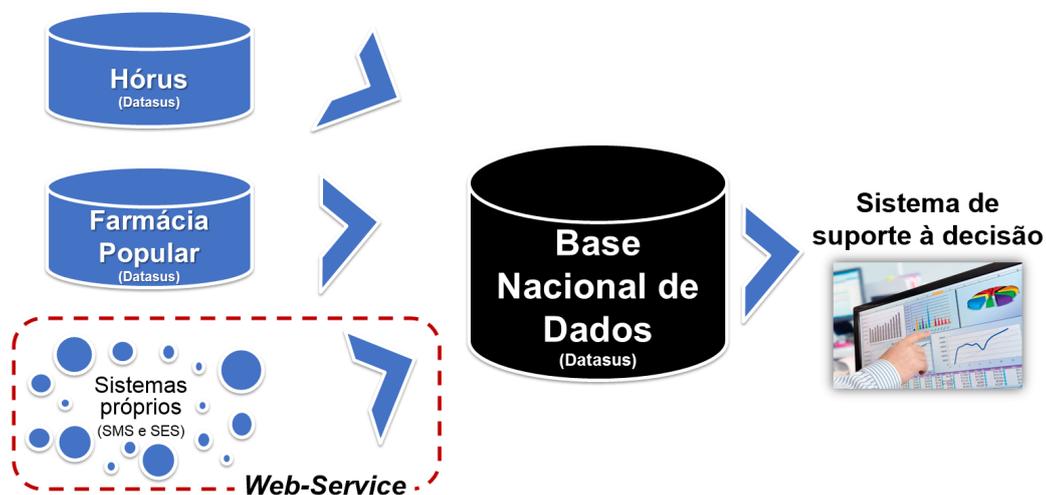


Figura 3.2: Base Nacional de Dados de Ações e Serviços da Assistência Farmacêutica.

A BNAFAR consolida os dados nacionais de posição de estoque, entradas, saídas, avaliações e dispensações realizadas pelos estabelecimentos de saúde dos Municípios, Estados

¹<http://portalms.saude.gov.br/assistencia-farmacutica/base-nacional-de-dados>

e Distrito Federal para os medicamentos padronizados na Relação Nacional de Medicamentos Essenciais (RENAME), e do Programa Farmácia Popular do Brasil, contendo dados dos Componentes Básico, Especializado e Estratégico da Assistência Farmacêutica.

A distribuição de medicamentos do Grupo 1A do CEAF é feita, para algumas unidades da federação, com base em solicitação de programação trimestral das Secretarias de Saúde, a qual é avaliada pelo Ministério da Saúde. De acordo com auditoria realizada pela CGU em 2017 [11], verificou-se que os Estados e o DF enviam planilha eletrônica devidamente preenchida, informando o número de pacientes para cada um dos medicamentos, consumo médio mensal, previsão de estoque até o fim do trimestre anterior e necessidade para atendimento do próximo trimestre a ser programado.

A partir dessas informações, o DAF realiza uma análise crítica e comparativa da necessidade informada com base nas Autorizações de Procedimentos de Alta Complexidade/Custo (APAC) aprovadas nos últimos três meses, disponíveis no Sistema de Informações Ambulatoriais (SIA/SUS). Não havendo divergências, a quantidade solicitada pelo Estado é aprovada.

Entretanto, para diversos estados, a quantidade de medicamentos a ser enviada (programação automatizada trimestral) é calculada, atualmente, por meio de um modelo do tipo ARIMA que utiliza as séries temporais de dispensação de cada medicamento. Por questões operacionais e de logística para entrega desses medicamentos, o cálculo dessas previsões é realizado um mês antes do início do trimestre.

A Figura 3.3 ilustra esse procedimento para o primeiro trimestre de 2018, a título de exemplo. Nesse caso, são realizadas previsões pontuais de dispensação para os meses de dezembro ($h = 1$), janeiro ($h = 2$), fevereiro ($h = 3$) e março ($h = 4$). Importante destacar a informação dada pelo Ministério da Saúde de que as previsões pontuais não são as previsões médias, mas os limites superiores dos intervalos de previsão de 60%, que é o intervalo de confiança escolhido pelo Ministério, segundo técnicos do órgão.

Calculadas as quatro previsões, elas são somadas e dessa soma subtrai-se a quantidade do medicamento no estoque ao fim do mês de novembro ($h = 0$), utilizando-se da premissa de que aquela quantidade será consumida até a entrega da quantidade de medicamentos sendo prevista. Esse resultado é a previsão automatizada de distribuição do medicamento para o trimestre (PA).

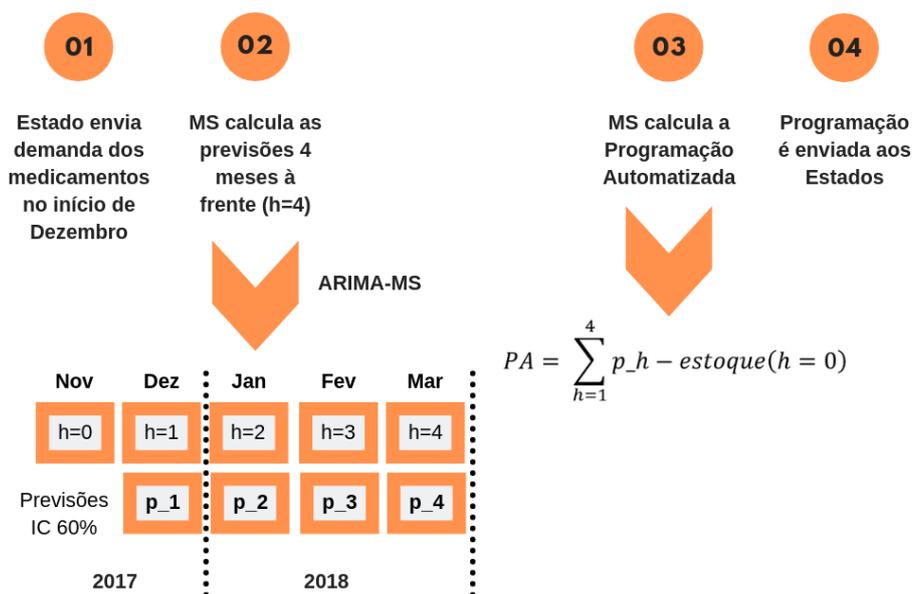


Figura 3.3: Cálculo da programação trimestral dos medicamentos do CEAF pelo Ministério da Saúde para o primeiro trimestre (T1/2018).

Portanto, é essa a abordagem de previsão da distribuição de medicamentos do subgrupo 1A do CEAF às Secretarias Estaduais de Saúde, a qual serviu de base para a etapa de modelagem, ou seja, os algoritmos de previsão propostos nesta pesquisa se utilizaram dessa formatação para fazer suas previsões, a partir das quais foram calculadas as programações automatizadas. Calculadas as programações automatizadas, elas foram comparadas com as programações automatizadas do modelo ARIMA implementado no Ministério da Saúde e também com a dispensação real dos medicamentos.

3.3 Entendimento dos dados

Como destacado na Seção 3.2, fazem parte da BNAFAR o conjunto de dados referentes aos registros de estoque, entrada, saída, dispensação dos medicamentos e insumos referentes à RENAME e aos registros das avaliações das solicitações no âmbito do Componente Especializado da Assistência Farmacêutica. Esses dados estão elencados a seguir:

Posição de Estoque:

- Código do Cadastro Nacional de Estabelecimentos de Saúde (CNES)
- Código de identificação do produto

- Quantidade do produto em estoque do último dia do mês
- Lote
- Data de validade do produto
- Programa de saúde vinculado ao produto
- IUM (Identificador Único de Medicamento) do produto

Entradas:

- Código do CNES do estabelecimento que registrou a entrada
- Código de identificação do tipo de estabelecimento
- Código de identificação do produto
- Número do CNPJ do fabricante
- Número do documento fiscal ou simples remessa
- Lote
- Valor monetário unitário do produto adquirido
- Data de validade do produto
- Programa de saúde vinculado ao produto
- Quantidade do produto recebida
- Data recebimento do produto
- IUM (Identificador Único de Medicamento) do produto
- Número do CNPJ do distribuidor
- Tipo de entrada do produto no estoque

Saídas:

- Código do CNES do estabelecimento que registrou a saída
- Código de identificação do tipo de estabelecimento
- Código de identificação do produto
- Número do CNPJ do fabricante
- Lote

- Data de validade do produto
- Programa de saúde vinculado ao produto
- Quantidade da saída do produto
- Data de saída do produto
- IUM (Identificador Único de Medicamento) do produto
- Código do CNES do estabelecimento destino
- Tipo de saída do produto no estoque

Dispensações:

- Código do CNES ou CNPJ do estabelecimento que registrou a dispensação
- Número do Cartão Nacional de Saúde (CNS) do usuário SUS
- Peso e altura do usuário SUS
- CID-10
- Código de identificação do produto
- Programa de saúde vinculado ao produto
- Lote
- Data de validade do produto
- IUM (Identificados Único de Medicamentos) do produto
- Quantidade dispensada do produto
- Data de dispensação do produto
- Competência da dispensação
- Código do CNES do profissional solicitante
- Número do registro no CRM do prescriptor
- UF do CRM do prescriptor

Avaliações Deferidas:

- Quantidade avaliada por competência do LME
- Código do Procedimento da Tabela de Procedimentos, Medicamentos, Órteses, Próteses e Materiais Especiais do Sistema Único de Saúde

- Data da avaliação
- Código do CNES do estabelecimento avaliador
- Número do Cartão Nacional de Saúde (CNS)
- Avaliação de Adequação

Apesar da grande quantidade de atributos que compõe a BNAFAR, foi realizada uma extração de dados pelo Ministério da Saúde focada na solução do problema de pesquisa proposto, que engloba os seguintes campos: (i) Unidade da Federação (UF); (ii) Identificador Único do Medicamento (CATMAT); (iii) Descrição do medicamento; (iv) Mês/Ano; (v) Quantidade do medicamento no estoque no último dia do mês; (vi) Quantidade de entrada do medicamento no estoque; (vii) Quantidade de saída do medicamento no estoque; e (viii) Quantidade do medicamento dispensada.

Considerando que os medicamentos que compõe o CEAF tratam as mais diversas doenças e, segundo especialistas consultados, não há bancos de dados epidemiológicos e/ou de morbidade relativos a todas as doenças, a estratégia de previsão a ser utilizada será a de séries temporais univariadas, com base no consumo histórico dos medicamentos, não sendo utilizados outros atributos ou variáveis explicativas. Portanto, a variável de interesse nessa pesquisa é a quantidade de medicamento dispensada.

A dificuldade de se obter dados de outras variáveis e de medir as relações assumidas que governariam a variável de interesse são justificativas para a escolha dos métodos de séries temporais, além de que estes podem gerar previsões mais precisas do que os modelos exploratórios [42]. Entretanto, uma análise pontual a respeito de alguns medicamentos poderia utilizar um modelo exploratório, onde a variável de interesse pode ser representada como uma função de outras variáveis, obtidas em publicações ou sítios especializados.

Os dados têm periodicidade mensal e foram extraídos desde maio de 2012 até setembro de 2018, perfazendo um total de 79 meses. Uma análise exploratória dos dados resultou em algumas constatações, a saber:

- Existem 23 Estados na base de dados, o que indica que 4 Estados ainda não informam os dados à BNAFAR;
- Existem 109 diferentes medicamentos na base de dados;
- Há muitos dados faltantes de dispensação no ano de 2012, ficando mais regular a partir do ano de 2013;
- Nem todos os Estados recebem todos os 109 medicamentos ou informam os dados à BNAFAR;

- A quantidade de medicamentos que os Estados recebem (ou informam) varia de 9 (BA/SP) a 109 (AL); e
- Apenas 9 Estados (AL, AP, CE, DF, PA, PB, PE, RN e TO) têm medicamentos com todos os registros mensais de dispensação informados;

A Figura 3.4 ilustra a quantidade de medicamentos do CEAF com registros na base de dados por Estado. A Tabela 3.1 lista alguns desses medicamentos, apenas a título de ilustração. Percebe-se que os fármacos se repetem, pois podem ser distribuídos em diferentes composições e/ou formas de administração. Assim, os 109 medicamentos não são necessariamente distribuídos para o tratamento de igual número de doenças.

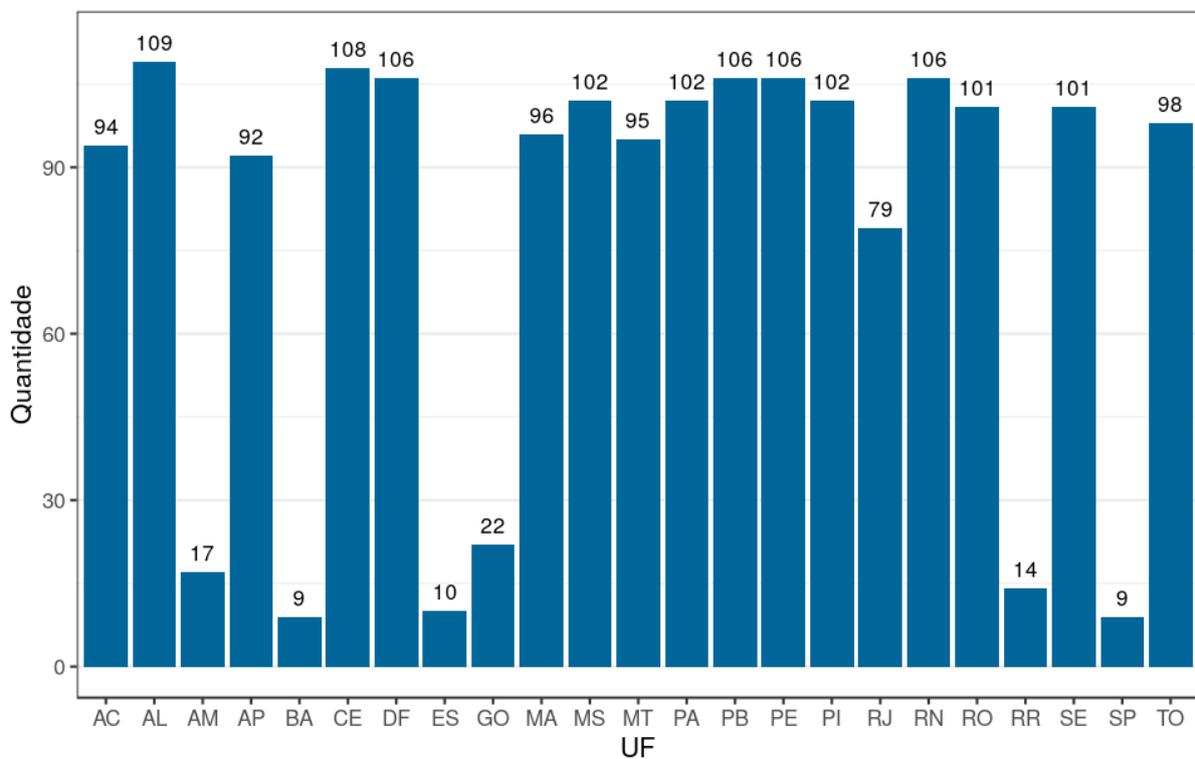


Figura 3.4: Quantidade de medicamentos do CEAF na base de dados por UF.

A Figura 3.5, por sua vez, apresenta um panorama da quantidade de séries temporais por faixas de quantidade de valores históricos registrados, para cada UF. Dos 23 estados, apenas 14 contém medicamentos cujas séries têm mais de 60 valores históricos (AC, AL, AP, CE, DF, GO, PA, PB, PE, PI, RN, RO, SE e TO). Para o Estado do Rio de Janeiro, por exemplo, cerca de 83% das séries temporais têm menos de 12 meses registrados de dispensação.

Tabela 3.1: Exemplos de medicamentos do CEAf

Medicamento	Tratamento
ALFAEPOETINA 2.000 UI SOL INJ (FR-AMP)	Anemia associada ao câncer não mielóide
ALFAEPOETINA 4.000 UI SOL INJ (FR-AMP)	
ALFAEPOETINA 10.000 UI SOL INJ (FR-AMP)	
RIVASTIGMINA 3 MG CAP	Doença de Alzheimer e de Parkinson
RIVASTIGMINA 6 MG CAP	
RIVASTIGMINA 1,5 MG CAP	
RIVASTIGMINA 4,5 MG CAP	
EVEROLIMO 0,5 MG COMP	Rejeição de órgãos em transplantes
EVEROLIMO 0,75 MG COMP	
EVEROLIMO 1 MG COMP	

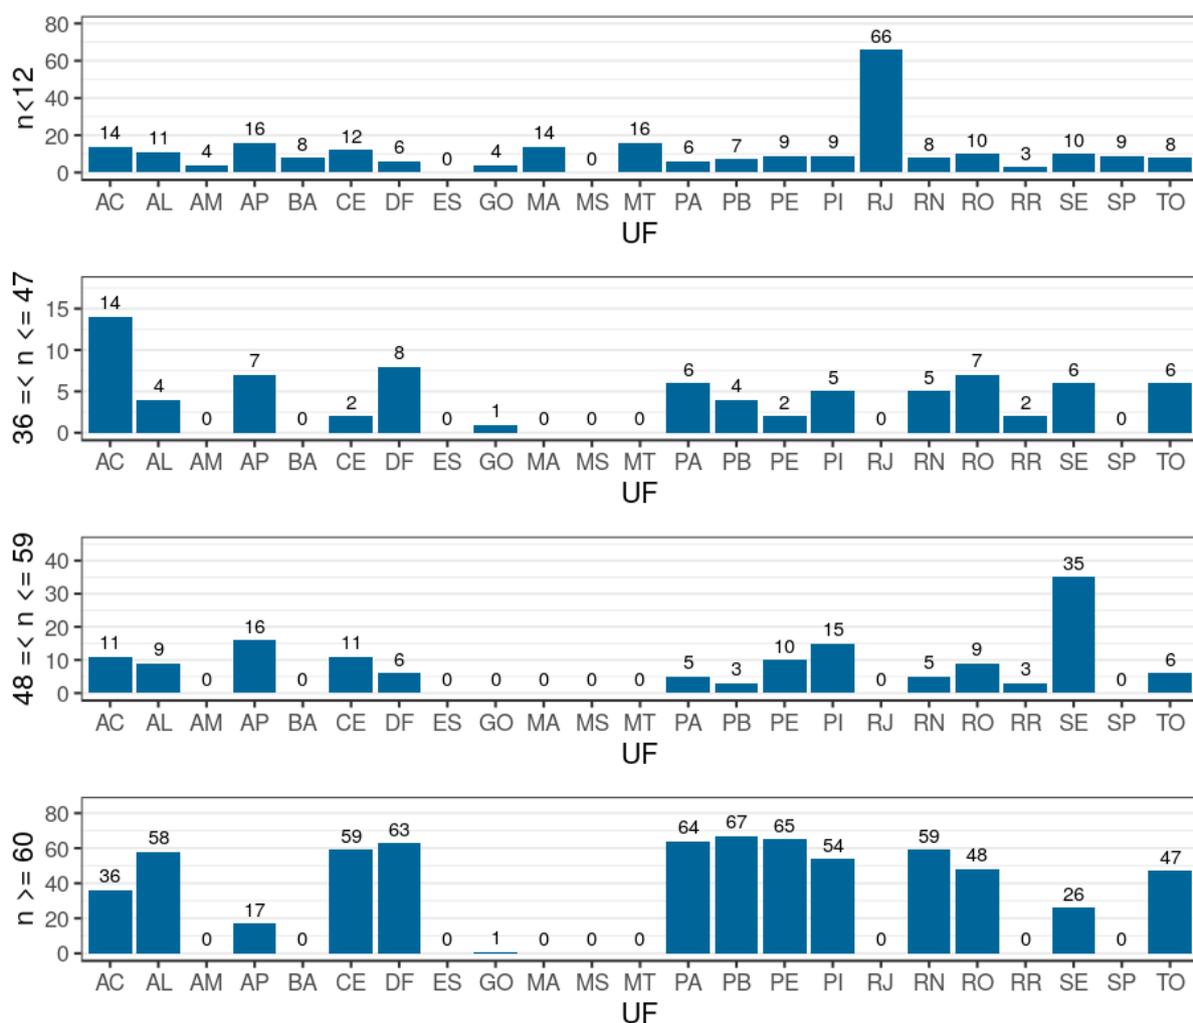


Figura 3.5: Quantidade de séries por número de observações por UF.

Além disso, percebeu-se muitos dados faltantes na variável de interesse (quantidade de

medicamento dispensada), em todas as unidades da federação, como ilustra a Figura 3.6 para alguns medicamentos distribuídos no Distrito Federal. Como é possível observar, a variabilidade de dados faltantes é grande.

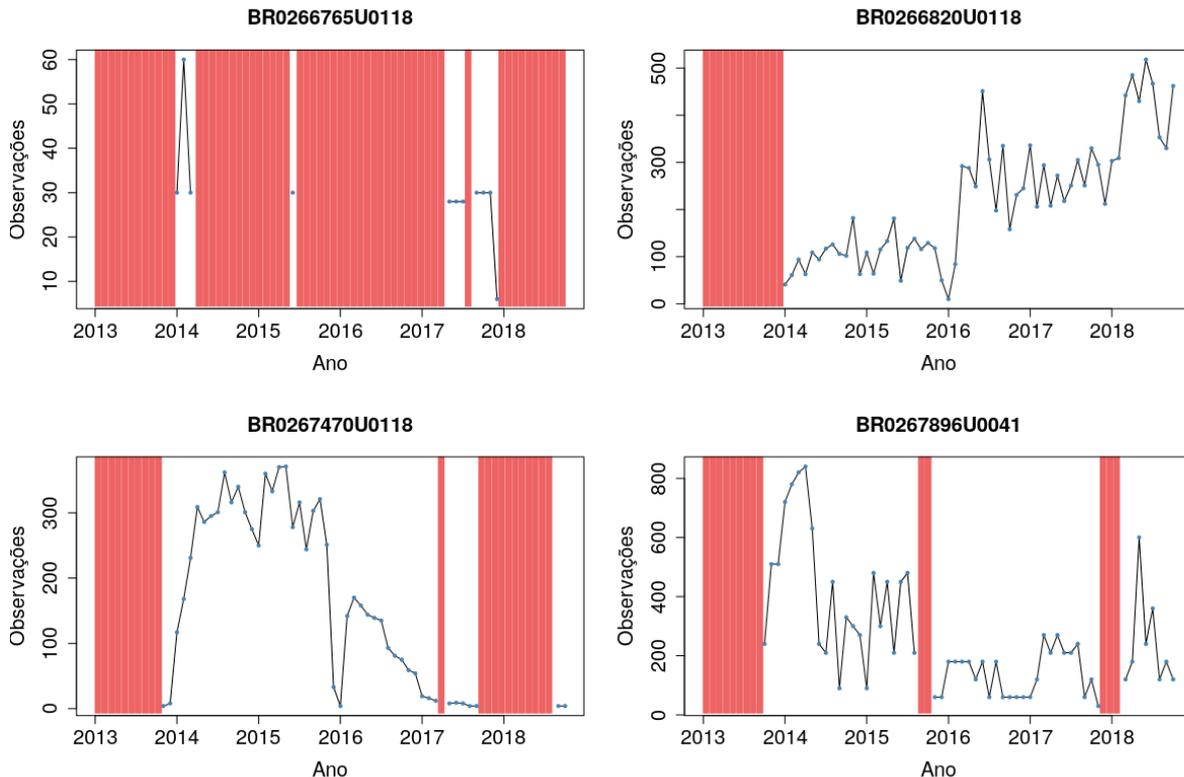


Figura 3.6: Valores faltantes (em vermelho) das séries de 4 medicamentos distribuídos no Distrito Federal.

Com relação a dados faltantes, o Ministério da Saúde informou que não é possível identificar, a priori, se não houve consumo daquele medicamento ou se o dado não foi alimentado na base de dados pelas Secretarias de Saúde Estaduais, considerando que a BNAFAR é uma base de dados transacional, podendo apresentar valores diferentes ao longo do tempo. Tal afirmação inviabiliza uma estratégia de imputação de dados, pois imputar um valor de dispensação quando, na verdade, não houve dispensação do medicamento, pode levar a erros grosseiros acerca da realidade do consumo dos medicamentos e, assim, a erros igualmente grosseiros de previsão. Isso levou, portanto, à definição de um critério de qualidade para selecionar os medicamentos, de modo que foram escolhidos somente aqueles com registros de dispensação ininterruptos desde Janeiro de 2013 até Setembro de 2018.

Além dos dados de dispensação e estoque de cada medicamento, o Ministério da Saúde forneceu os valores da programação automatizada do modelo ARIMA que está hoje em

utilização no Ministério, para os três primeiros trimestres de 2018. Importante destacar que esses valores não são as previsões pontuais (médias) do horizonte de previsão (4 meses à frente), e sim o valor das previsões do intervalo de confiança de 60%, que são utilizadas para calcular a programação automatizada, conforme a descrição feita na Figura 3.3. As previsões pontuais (médias) do horizonte de previsão (4 meses à frente), segundo agentes do Ministério da Saúde, não são armazenadas.

3.4 Preparação dos dados

Levando em consideração o que foi descrito na Seção 3.3, a fase de preparação dos dados selecionou quais unidades da Federação e que medicamentos de cada uma delas foram utilizados na fase de modelagem, buscando atender critérios de qualidade e disponibilidade da informação na base de dados.

Embora o Ministério da Saúde tenha apontado alguns Estados que informariam os dados de dispensação com maior cuidado, foram incluídas todos aqueles que iniciaram os registros de dispensação ainda no ano de 2012, a fim de abarcar um maior número de Estados. De certa maneira, isso privilegiou a escolha daquelas unidades com maior experiência no fornecimento de dados para a BNAFAR. De todo modo, considerando que os Estados passaram a alimentar a base de dados de forma recorrente somente a partir de 2013, foram descartados os registros de dispensação dos medicamentos do ano de 2012.

A partir daí, como informado na Seção 3.3, foram selecionados somente aqueles medicamentos com registros de dispensação ininterruptos desde Janeiro de 2013 até Setembro de 2018, perfazendo um total de 69 registros (meses) válidos de dispensação, já que a periodicidade de registro é mensal. A avaliação das previsões foi realizada apenas para os três primeiros trimestres de 2018 (T1, T2 e T3), já que os dados extraídos, até Setembro de 2018, não permitiram a avaliação do último trimestre do ano.

Além disso, as informações repassadas pelo Ministério da Saúde a respeito das programações automatizadas do modelo ARIMA que está hoje em uso no Ministério, mostraram que, para a mesma unidade da Federação, não havia programações válidas para a mesma quantidade de medicamentos em todos os trimestres que estão sendo avaliados, exceção feita para o Estado de Alagoas e para o Distrito Federal, cujos medicamentos possuíam previsões para todos os três trimestres (T1, T2 e T3), o que levou à necessidade de filtrar apenas os medicamentos com previsões válidas para todos os três trimestres de 2018. A aplicação desses critérios levou à seleção de diferentes quantidades de medicamentos para a fase de modelagem, por unidade da Federação, como se observa na Figura 3.7.

Selecionados os medicamentos objeto da pesquisa, foram visualizadas as séries temporais de cada um deles, a fim de que fossem identificadas características importantes, como

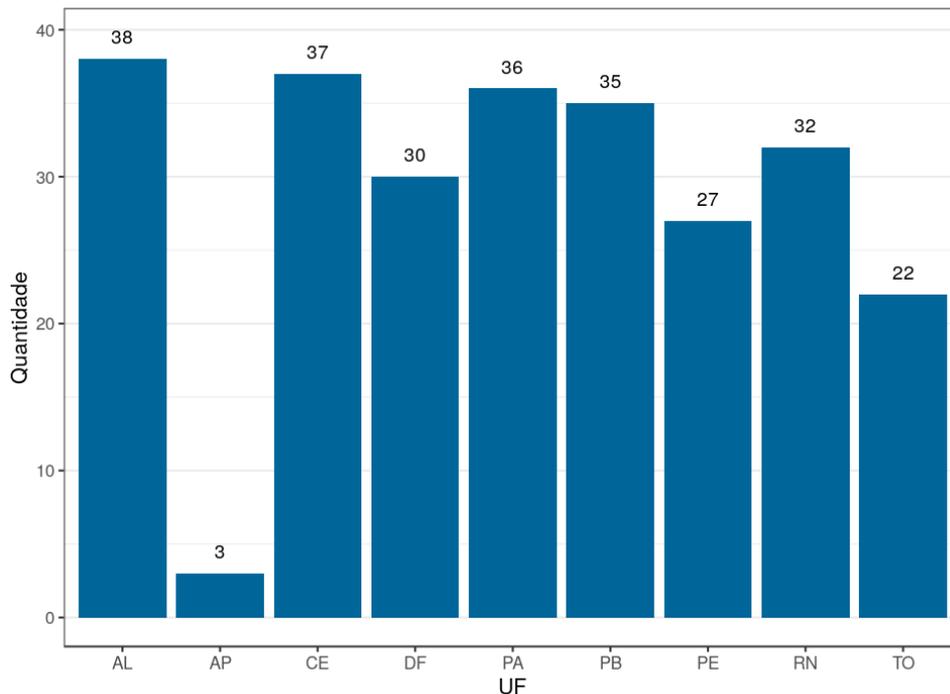


Figura 3.7: Quantidade de medicamentos selecionados para a fase de modelagem, por UF.

tendências, sazonalidade e autocorrelação. Para decomposição das séries temporais, foi utilizado o método STL.

A Figura 3.8 apresenta, para 4 medicamentos aleatoriamente selecionados, gráficos que permitem a visualização das séries temporais de dispensação, onde é possível identificar, por exemplo, uma clara tendência nas séries dos medicamentos BR0272083U0042 (PE) e BR0272083U0042 (DF). Em virtude da grande quantidade de séries temporais e da necessidade de interação com os gestores do Ministério da Saúde para a avaliação de cada uma delas, não foi realizado nenhum tratamento relacionado à detecção de *outliers* ou de valores iniciais próximos de zero, o que pode ter algum impacto na qualidade das previsões realizadas.

A implementação dos algoritmos de previsão automatizou a detecção de características das séries temporais dos medicamentos, a exemplo da estacionariedade e presença de tendência e sazonalidade.

Considerando a quantidade de séries selecionadas, foi utilizado um teste objetivo para a identificação da estacionariedade das séries. Embora haja alguns testes disponíveis, foi utilizado o teste estatístico Kwiatkowski-Phillips-Schmidt-Shin (KPSS) [82]. Nesse teste a hipótese nula é a de que os dados são estacionários e procura-se evidência de que essa hipótese é falsa. Conseqüentemente, valores pequenos do *p-valor* (por exemplo, menores do que 0,05) sugerem que uma operação é necessária para tornar a série estacionária,

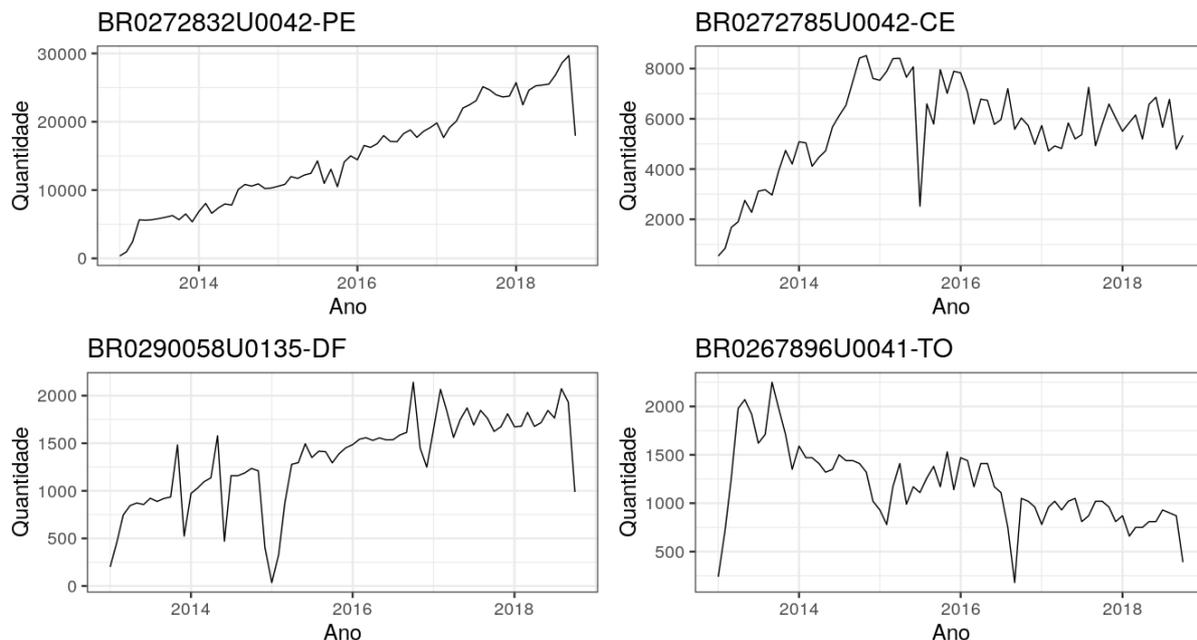


Figura 3.8: Séries temporais de quantidades dispensadas de 4 medicamentos selecionados para a fase de modelagem.

resultado que foi obtido, neste trabalho, por intermédio da operação de diferença aplicada à série original [42].

A presença de sazonalidade das séries foi avaliada por meio da observação do gráfico de autocorrelação, percebendo se o valor absoluto da correlação no *lag* 12 é superior ao limiar que indica se a correlação é ou não, significativamente, diferente de zero [27]. Quando os dados são sazonais, as medidas de autocorrelação para os *lags* sazonais (múltiplos de 12 para séries mensais) são maiores do que a correlação para os outros *lags* [42]. Detectando-se a presença de sazonalidade, faz-se um ajuste da série para remoção da sazonalidade, gerando a série sem sazonalidade e os índices sazonais, os quais são reincorporados às previsões dos modelos, ajustando-as.

Quanto à presença de tendência, foi utilizado o teste estatístico de Cox-Stuart, e, uma vez confirmada a tendência, ela foi modelada como uma reta, subtraindo-se, da série sazonalmente ajustada, a tendência estimada [27].

A respeito da validação e da comparação dos modelos, foi escolhida a estratégia clássica de *holdout*, observando, também, o procedimento adotado para previsão no Ministério da Saúde, apresentado na Figura 3.3. Essa estratégia divide a série em dados de treinamento e de teste, segundo cada um dos trimestres do ano de 2018. Usando essa modelagem, foi possível comparar os modelos para cada medicamento, e por trimestre do ano. A Tabela 3.2 apresenta a divisão que foi adotada.

Tabela 3.2: Estratégia de *holdout* para validação por trimestre de 2018

Trimestre	Dados de Treinamento	Dados de Teste
T1	Jan/2013 a Nov/2017	Dez/17 a Mar/2018
T2	Jan/2013 a Fev/2018	Mar/2018 a Jun/2018
T3	Jan/2013 a Maio/2018	Jun/2018 a Set/2018

Os conjuntos de dados de treinamento vão aumentando de tamanho, partindo de 59 meses para o 1º trimestre, e aumentado três meses a cada trimestre, alcançando 65 meses para o 3º trimestre. Os conjuntos de teste se mantêm com o tamanho de 4 meses, atendendo à abordagem de previsão realizada pelo do Ministério da Saúde. O erro de previsão, nesse contexto, representa a parte do valor real que não consegue ser prevista pelos algoritmos de previsão e é dado por:

$$e_{T+h} = y_{T+h} - \hat{y}_{T+h|T} \quad (3.1)$$

Na Equação 3.1, os dados de treinamento são y_1, y_2, \dots, y_T e os dados de teste são $y_{T+1}, y_{T+2}, \dots, y_{T+h}$, e $h = 4$ é o horizonte de previsão. Como métrica do cálculo do erro de previsão, foi utilizado o erro absoluto médio (EAM), que é baseado no erro definido pela Equação 3.1:

$$EAM = \frac{1}{f_h} \sum_{h=1}^4 |e_{T+h}| = \frac{1}{f_h} \sum_{h=1}^4 |y_{T+h} - \hat{y}_{T+h|T}|, \quad (3.2)$$

onde $f_h = 4$, ou seja, o tamanho do horizonte de previsão. Utilizando o EAM, a medida de erro fica na mesma escala dos dados, métrica adequada quando são comparados métodos aplicados a uma única série ou a várias séries com as mesmas unidades, além de ser uma métrica simples de calcular e interpretar [42, 83].

3.5 Modelagem

Considerando o que foi exposto nas etapas anteriores, foram ajustados nove modelos estatísticos tradicionais de previsão de séries temporais e um modelo de rede neural do estado da arte para aprendizagem de sequências (rede neural recorrente LSTM), descritos na Seção 2.4, perfazendo um total de dez modelos. Feitas as previsões de cada um desses modelos, para cada medicamento, elas foram comparadas com as previsões feitas atualmente pelo Ministério da Saúde, buscando identificar os modelos mais precisos em prever a quantidade de cada medicamento a ser distribuída.

3.5.1 Ferramentas e Recursos Utilizados

A implementação dos métodos e modelos estatísticos tradicionais (NAIVE, SNAIVE, SES, HOLT e variações, THETA, ETS e ARIMA) foi feita em linguagem R, utilizando-se de funções dos pacotes *forecast*, *tseries*, *urca*, *pracma* e *xts*. O ajuste dos modelos, especificamente, utilizou as funções do pacote *forecast* listadas na Tabela 3.3. Para a rede neural recorrente LSTM, a modelagem foi feita em Python, utilizando a biblioteca Keras com suporte para Tensorflow em GPU Nvidia® Geforce GTX 1060. A implementação dos modelos foi realizada utilizando um computador com processador Intel®, Core i7, 8ª Geração, 16 GB de RAM, sistema operacional linux, distribuição Ubuntu 18.04.1 LTS.

Tabela 3.3: Funções do pacote *forecast* para ajuste dos modelos

Método (ou modelo)	Função
Naïve	<code>naive()</code>
Seasonal Naïve	<code>snaive()</code>
Theta	<code>thetaf()</code>
Suavização exponencial simples (SES)	<code>ses()</code>
Holt-Linear	<code>holt()</code>
Holt-Damped	<code>holt()</code>
Holt-Winters	<code>hw()</code>
Arima	<code>auto.arima()</code>
Modelo de espaço de estados (ETS)	<code>ets()</code>

3.5.2 Implementação dos modelos estatísticos tradicionais

A modelagem da solução do problema de pesquisa partiu do cenário apresentado nas seções anteriores e, para cada trimestre, unidade da federação e medicamento selecionados, executou os seguintes passos:

1. dividiu as séries temporais de dispensação de cada medicamento em dados de treinamento e de teste;
2. investigou as características da série temporal (estacionariedade, tendência e sazonalidade) assim como calcula medidas dessas características;
3. ajustou a série original, gerando novas séries (série sem tendência e série sazonalmente ajustada e sem tendência)
4. ajustou os modelos, que recebem como entrada, segundo as suas características, uma das séries do passo anterior;

5. calculou as previsões e as ajustou, reincorporando a componente sazonal, a depender do modelo, como explicado na Seção 3.4;
6. calculou o EAM para cada um dos modelos, sendo considerado o vencedor aquele com menor erro;
7. calculou a previsão automatizada para o melhor modelo.

As funções que ajustaram os modelos receberam, como entrada, a série original ou a série ajustada sazonalmente. Os modelos Naïve, Seasonal Naïve, Holt-Winters, Arima e ETS receberam a série original, já que eles tratam padrões de tendência e sazonalidade presentes nas séries temporais. Para os demais modelos lineares tradicionais, ou seja, Theta, SES, Holt-Linear e Holt-Damped, foi utilizada, como entrada, a série ajustada sazonalmente.

A função `auto.arima()` automatiza a busca do melhor modelo utilizando uma variação do algoritmo de Hyndman e Khandakar [28], que combina testes de raiz unitária, minimização do critério *AICc* e minimização da função de verossimilhança. A função `ets()`, de forma análoga, ajusta os parâmetros dos modelos e os seleciona por meio dos procedimentos descritos na Seção 2.4.4, principalmente da minimização de critério de informação. Os demais métodos que exigem a seleção de parâmetros utilizam a minimização do erro quadrático médio apresentada na Seção 2.4.2.

Ao final, um objeto do tipo lista guardou, para todos os trimestres, unidades da federação e, para cada medicamento, diversas informações, como:

- nome;
- se a série tem tendência ou não;
- se a série é estacionária ou não;
- estruturas de dados dos modelos ajustados, contendo os valores de seus parâmetros e outras características;
- tabela contendo o erro de previsão para cada mês dentro do horizonte de previsão e o valor médio (EAM), de todos os modelos;
- qual o modelo vencedor (aquele com menor EAM);
- previsões médias (pontuais) de todos os modelos;
- previsões agregadas (trimestrais) de todos os modelos;
- previsões do intervalo de confiança de 60% do modelo ARIMA em uso no Ministério da Saúde (ARIMA-MS);

- estoque do medicamento no mês anterior ao início da trimestre;
- quantidade real consumida no trimestre.

3.5.3 Implementação da rede neural LSTM proposta

Para a rede LSTM foi escolhida a arquitetura codificador-decodificador, cada qual com uma camada, ilustrada na Figura 3.9. Para a utilização da rede neural, as séries originais foram colocadas na escala $(-1,1)$ [27] e formatadas de modo a se adequarem a um modelo de treinamento supervisionado, que mapeia diversas sequências de entrada (X) para diversas sequências de saída (y), podendo as sequências de entrada e saída terem tamanhos diferentes.

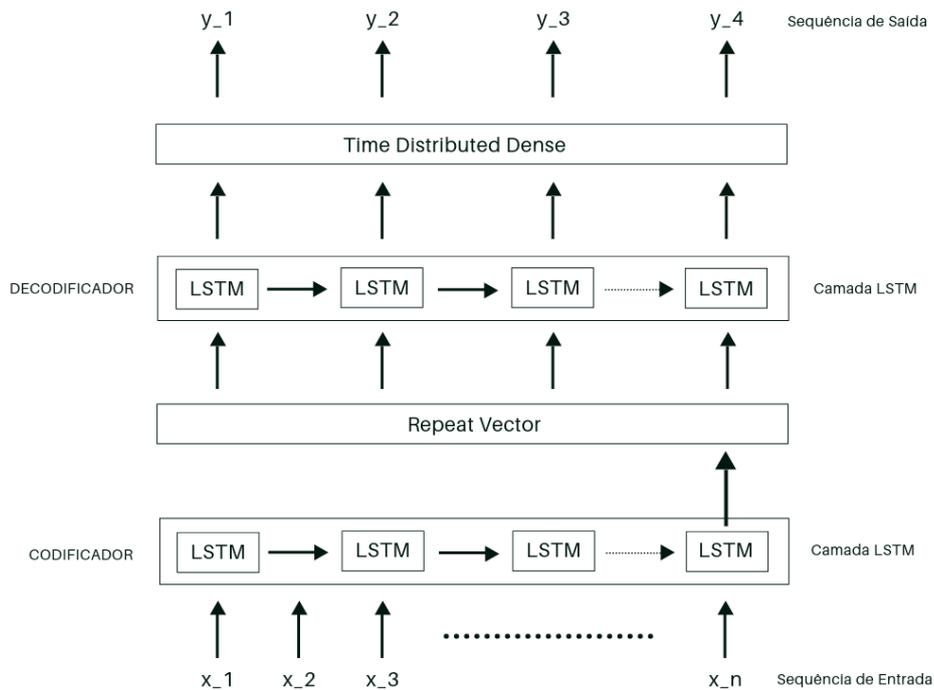


Figura 3.9: Arquitetura Codificador-Decoder da rede neural LSTM.

Na pesquisa em questão, as sequências de saída foram sempre de tamanho $h = 4$, que é o horizonte de previsão utilizado. Já o tamanho das sequências de entrada foi modelado como um parâmetro do modelo implementado, podendo variar dentro do conjunto discreto de valores $[1,3,6,12]$. Esse tamanho de sequência pode ser interpretado com uma janela que define quantas observações passadas da série são levadas em consideração para prever as observações futuras. O tamanho dessa janela define o número de amostras (sequências) disponíveis para o treinamento do modelo, ou seja, um conjunto de mapeamentos de entradas e saídas.

Utilizando a biblioteca Python Keras, a implementação da rede LSTM requer uma entrada tridimensional com dimensões (amostras, observações, atributos), onde:

- amostras - número de sequências de mapeamentos de entradas para saídas;
- observações - uma observação é um ponto observado dentro da amostra, de modo que uma amostra contém múltiplas observações. É o tamanho das sequências de entradas;
- atributos - número de variáveis sendo previstas (igual a 1 para séries univariadas ou maior que 1 para séries multivariadas ou múltiplas séries de entrada).

A Figura 3.10 apresenta os dados das séries dos 3 medicamentos do Estado do Amapá, onde é possível entender a formatação dos dados para treinamento e teste da rede LSTM com múltiplas entradas, considerando os dados de treinamento e teste para o primeiro trimestre de 2018. O quadro no canto superior esquerdo mostra as observações das séries dos três medicamentos na forma de uma matriz de 3 colunas (*tsdata*). O quadro do meio, por sua vez, apresenta algumas amostras dos dados de treinamento (*X_train*), para a configuração de 3 observações de entrada, de um total de 52 amostras.

Esse conjunto de amostras, como explicado anteriormente, tem o formato tridimensional (52,3,3). Esse formato significa que, para essa configuração, resultaram 52 amostras de 3 observações (*timesteps*) para 3 medicamentos (total de medicamentos do Amapá). No canto superior direito, é apresentado o conjunto de saídas (*y_train*) no formato (52,4,3), o que significa que há 52 amostras de 4 observações (horizonte de previsão) para os três medicamentos. Já na parte inferior são apresentados os dados de teste (*X_test* e *y_test*), no formato (1,3,3) e (1,4,3), respectivamente.

Além do tamanho das sequências de entrada, variando dentro do conjunto discreto de valores [1,3,6,12], foram definidas faixas de variação de hiperparâmetros do modelo, como número de unidades LSTM na camada do codificador, número de unidades LSTM na camada do decodificador, ambos variando dentro do conjunto de valores [12,32,64,128], o número de épocas de treinamento, no conjunto de valores [50,100,300,500,1000] e o percentual de *dropout*, no conjunto de valores [0,5%,1%,5%,10%]. No caso de hiperparâmetros numéricos, o menor e o maior valor da faixa de valores foi escolhida de forma empírica, baseado na experiência anterior com experimentos similares [1]. A única exceção foi a taxa de *dropout*, que utilizou valores sugeridos em experimentos realizado por Gal [60].

A fim de diminuir o custo computacional em termos de tempo de execução, foi adotada uma abordagem por meio da qual foi implementado um modelo para todos os medicamentos de cada Estado, ou seja, um modelo com múltiplas entradas e múltiplas saídas (várias previsões para os próximos 4 meses), como pode ser vista na Figura 3.11. Dessa forma,



Figura 3.10: Formatação dos dados para treinamento e teste do modelo LSTM para os 3 medicamentos do Estado do Amapá.

para cada Estado foram implementados 12 modelos, valor resultante da combinação de 1 agrupamento de medicamentos (cujo tamanho depende de cada Estado) \times 3 trimestres \times 4 tamanhos de seqüências de entradas.

Com relação à otimização dos hiperparâmetros (número de unidades LSTM na camada do codificador, número de unidades LSTM na camada do decodificador, épocas de treinamento e percentual de *dropout*), foi escolhida a otimização Bayesiana com o algoritmo TPE, implementada pela biblioteca Python Hyperopt², utilizado também por Bergstra *et al.* [76]. A escolha desse algoritmo se deu principalmente pela necessidade de acelerar o processo de busca dos hiperparâmetros, em virtude da necessidade de treinar diversos modelos e a considerável quantidade de combinações dos hiperparâmetros.

A otimização dos parâmetros dos modelos foi realizada com o algoritmo Adam, considerada uma boa escolha por Goodfellow *et al.* [1], utilizando os valores *default* da biblioteca Keras ($lr = 0.001$, $\rho_1 = 0.9$, $\rho_2 = 0.999$, $\delta = 1e-08$), também sugeridos por [1]. Além disso, foram utilizadas funções de ativação do tipo *Rectified Linear Units* (ReLU), em virtude de sua marcante característica de acelerar várias vezes o treinamento de redes profundas, dada a sua computação simples, que não envolve exponenciações, em comparação com as funções de ativação do tipo tangente hiperbólica [84]. Por fim, foi utilizado o erro absoluto médio como função de perda (*loss function*) na saída da rede. Um resumo

²<http://hyperopt.github.io/hyperopt/>

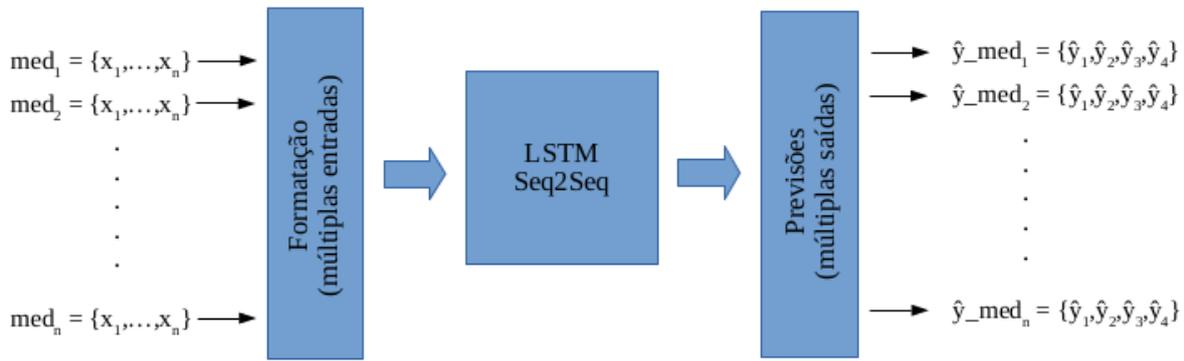


Figura 3.11: Abordagem de previsão com rede LSTM (codificador-decodificador) multivariada de múltiplas entradas.

de todas as características do modelo LSTM implementado é apresentado na Tabela 3.4.

Tabela 3.4: Características do modelo LSTM multivariado implementado na pesquisa

Características	Descrição/Valores
Arquitetura	Codificador-Decoder
Número de camadas (Codificador)	1
Número de camadas (Decoder)	1
Número de células LSTM no Codificador	[12,32,64,128]
Número de células LSTM no Decoder	[12,32,64,128]
Tamanho das sequências de entrada	[1,3,6,12]
Tamanho das sequências de saída (previsões)	4
Épocas de treinamento	[100,200,500,1000,1500]
Percentuais de <i>Dropout</i>	[0,5%,1%,5%,10%]
Função de ativação	ReLU
Otimização dos pesos	Adam
Otimização dos hiperparâmetros	Bayesiana (TPE)
<i>Loss function</i>	Erro absoluto médio

Incerteza da previsão para redes neurais

A técnica de *dropout*, considerada um método de regularização robusto e de baixo custo computacional [85], consiste, basicamente, em treinar uma combinação de subredes neurais construídas a partir da remoção de neurônios da entrada ou das camadas escondidas de uma rede neural considerada base. A quantidade de unidades a ser removida é feita

de forma aleatória, com um percentual p fixo, podendo ser modelado também como um hiperparâmetro a ser otimizado [1].

Em 2015, Gal e Ghahramani [59] mostraram que o uso da técnica de *dropout* em redes neurais pode ser interpretada como uma aproximação bayesiana do conhecido modelo probabilístico de processos gaussianos. Em outras palavras, esses autores demonstraram que uma rede neural de profundidade arbitrária e *dropout* aplicado antes de cada camada com pesos associados, é matematicamente equivalente a uma aproximação de um processo gaussiano, permitindo, assim, a representação da incerteza do modelo neural. Ou seja, a saída do modelo pode ser considerada uma amostra aleatória gerada de uma distribuição de probabilidade *a posteriori* das previsões.

Assim, a incerteza do modelo pode ser estimada por meio do conhecimento da distribuição *a posteriori* $P(W|X, Y)$, onde $X = x_1, \dots, x_N$ é o conjunto de dados de entrada, $Y = y_1, \dots, y_N$ o conjunto de dados de saída e W o conjunto de parâmetros do modelo. Os resultados de Gal e Ghahramani [59] permitem aproximar a incerteza do modelo neural utilizando um algoritmo denominado por esses autores como Monte Carlo *dropout*.

De acordo com esse algoritmo, dada uma nova entrada x^* , calcula-se a saída da rede com *dropout* aleatório em cada camada da rede. Esse procedimento é repetido T vezes, obtendo-se um conjunto de saídas $\hat{y}_{(1)}, \dots, \hat{y}_{(T)}$ e a incerteza da previsão pode ser aproximada pela variância dessa amostra, ou seja:

$$\widehat{Var}(f^W(x^*)) = \frac{1}{T} \sum_{t=1}^T (\hat{y}_{(t)}^* - \overline{\hat{y}^{(*)}})^2, \quad (3.3)$$

onde $\overline{\hat{y}^{(*)}} = \frac{1}{T} \sum_{t=1}^T \hat{y}_{(t)}^*$. Utilizando a distribuição de valores $\hat{y}_{(1)}, \dots, \hat{y}_{(T)}$, podem ser calculados os quantis associados à probabilidade do intervalo de previsão que se deseja obter.

Esse resultado foi incorporado ao modelo LSTM implementado na pesquisa de modo a encontrar as previsões no intervalo de confiança de 60% e possibilitar a comparação direta entre a rede LSTM e os outros modelos implementados na pesquisa. As previsões da rede LSTM foram salvas e carregadas no *script* em R que implementou os demais modelos.

3.5.4 Modelos Vencedores e Programações Automatizadas

Feitas as previsões, o modelo considerado vencedor foi aquele com menor erro absoluto médio (EAM). O EAM é calculado para cada mês do horizonte de previsão (4 meses), assim como o seu valor médio, considerando todo o horizonte de previsão (ver Equação 3.1). O erro de previsão é calculado utilizando as previsões médias (pontuais) e o melhor modelo será aquele com menor EAM, calculado da seguinte forma, onde $f_h = 4$, ou seja, o tamanho do horizonte de previsão:

$$EAM = \frac{1}{f_h} \sum_{h=1}^4 |e_{T+h}| = \frac{1}{f_h} \sum_{h=1}^4 |y_{T+h} - \hat{y}_{T+h|T}| \quad (3.4)$$

Como destacado na Seção 3.3, o Ministério da Saúde não disponibilizou as previsões médias (pontuais) $\hat{y}_{T+h|T}$, $h = 1, 2, 3, 4$, do seu atual modelo de previsão (ARIMA-MS), informando que eles não ficam armazenados. Esse fato impediu uma comparação direta entre os erros dos modelos implementados na pesquisa e o modelo atualmente em uso pelo órgão. Todavia, essa limitação foi mitigada, uma vez que foi ajustado um modelo ARIMA utilizando as mesmas entradas e a mesma implementação hoje utilizada pelo Ministério (função `auto.arima()` do pacote *forecast* do R).

Para cada um dos modelos implementados na pesquisa foi calculado o intervalo de previsão de 60%, já que é esse o intervalo utilizado pelo Ministério da Saúde para o cálculo de suas programações automatizadas (quantidades a serem enviadas aos Estados). Como já informado anteriormente, esse foi o intervalo utilizado para permitir uma comparação das programações dos modelos da pesquisa com as programações do modelo atualmente utilizado pelo Ministério da Saúde.

Diferentemente das previsões pontuais (médias), foram disponibilizadas as previsões superiores do intervalo de previsão de 60%, as quais foram utilizadas para o cálculo das programações automatizadas do Ministério (PATMS) de cada um dos medicamentos, calculadas na forma da Equação 3.6, permitindo a comparação direta das programações com a demanda real dos medicamentos.

Considerando que o objetivo da modelagem é obter uma previsão de programação trimestral, foi necessário agregar as previsões feitas para o horizonte de 4 meses, utilizando um modelo que foi ajustado para dados não agregados, ou seja, dados com frequência mensal. Somar as previsões pontuais é uma boa estimativa da previsão pontual agregada, mas os intervalos de previsão agregados não podem ser calculados de forma trivial, devido à correlação entre os erros de previsão [42].

Esse problema foi resolvido por meio de simulações de previsões do modelo ajustado. Foram simuladas N previsões pontuais do modelo ajustado para os dados desagregados (N suficientemente grande), formando-se uma distribuição desses valores, cujos quantis foram utilizados para o cálculo dos limites superiores e inferiores dos intervalos de previsão para qualquer nível de confiança. Na modelagem da pesquisa, definiu-se $N = 10.000$, seguindo a orientação de Hyndman [54] e experimentos conduzidos por Gal [59].

Dessa forma, após definido o modelo vencedor, foi calculada a a programação automatizada trimestral do melhor modelo (PATMM), dada pela Equação 3.5:

$$PATMM = PAggMM_{ic_60_sup} - EMMAT \quad (3.5)$$

Na Equação 3.5, o valor de $PATMM$ é dado pela subtração do estoque do medicamento no mês anterior ao trimestre ($EMMAT$) do valor da previsão agregada do modelo vencedor ($P\text{Agg}MM_{sup}$), simulando o que faz o Ministério da Saúde quando calcula a sua previsão automatizada. Como destacado anteriormente, $P\text{Agg}MM_{ic_60_sup}$ é o limite superior do intervalo de previsão com nível de confiança de 60%, de modo a possibilitar a exata comparação com o valor que é utilizado nas previsões atuais do Ministério da Saúde.

De modo semelhante, foi calculada a programação automatizada do modelo ARIMA em operação no Ministério da Saúde (ARIMA-MS), da seguinte maneira:

$$PATMS = PAMS_{ic_60_sup} - EMMAT \quad (3.6)$$

Calculada ambas as previsões automatizadas ($PATMM$ e $PATMS$), elas foram comparadas com a quantidade real dispensada do medicamento (QRDM) no trimestre sendo avaliado.

3.5.5 Resultados

Os resultados serão apresentados em duas etapas. Na primeira, será destacado, entre os modelos implementados na pesquisa, aquele considerado vencedor, ou seja, com menor erro de previsão utilizando a métrica do erro absoluto médio, calculado segundo a Equação 3.4. Como destacado na Seção 3.5.4, esse erro é calculado com base nas previsões médias (pontuais) para o horizonte de previsão, ou seja, quatro meses à frente.

Na segunda etapa, serão comparados os valores de programação automatizada do modelo vencedor e do modelo ARIMA-MS (modelo em operação no Ministério da Saúde) com a demanda real dos medicamentos. Os valores de programação automatizada, ou seja, as quantidades de cada medicamento que serão distribuídas aos Estados, são calculadas de acordo com as Equações 3.5 a 3.6, levando em conta a previsão agregada e o estoque do medicamento.

Primeira Etapa - Modelos Vencedores

A seguir são apresentados os modelos vencedores em cada um dos Estados escolhidos para a fase de modelagem.

DISTRITO FEDERAL

Com relação ao Distrito Federal, a Figura 3.12 apresenta a contagem de quantas vezes cada modelo foi o vencedor, por trimestre avaliado. Esse resultado não leva em conta empates que tenham ocorrido entre os métodos alternativos, tendo sido escolhido o primeiro

modelo com o menor valor de EAM da lista de modelos, nessa ordem: NAIVE, SNAIVE, SES, HOLT_LINEAR, HOLT_DAMPED, THETA, HOLT_WINTERS, ARIMA, ETS e LSTM.

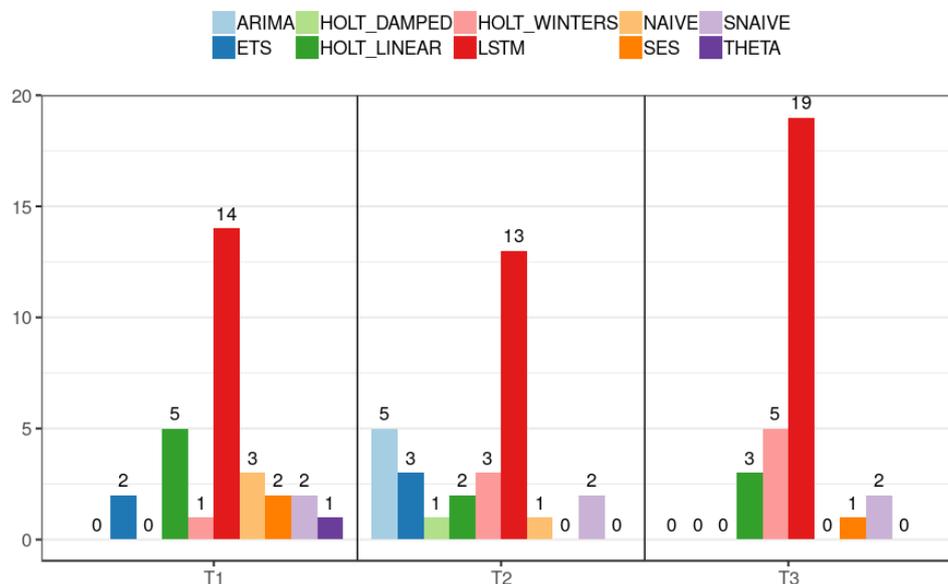


Figura 3.12: Contagem dos modelos vencedores em cada trimestre de 2018 para o DF, desconsiderando os empates.

Em qualquer dos trimestres observados, o modelo LSTM foi superior, tendo sido o modelo vencedor para 14, 13 e 19 dos medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 46,7%, 43,3% e 63,3% do total de medicamentos do Distrito Federal. No agregado dos três trimestres, o LSTM foi o melhor modelo para 53 medicamentos, o que representa 51,1% de todas as previsões realizadas.

A Tabela 3.5 apresenta a lista de modelos vencedores por medicamento e por trimestre no Distrito Federal, e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.6 a 3.8 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0343608U0118 no primeiro trimestre (0,8%), BR0369176U0042 no segundo trimestre (1,59%) e BR0272833U0042 no terceiro trimestre (0,89%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0272833U0042 no primeiro trimestre (118,67%), BR0272825U0042 no segundo trimestre (111,24%) e BR0271620U0042 no terceiro trimes-

tre (95,02%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 28,2% (primeiro trimestre), em 25,7% (segundo trimestre) e em 22,6% (terceiro trimestre).

Tabela 3.5: Erro absoluto médio do modelo vencedor para os medicamentos do DF, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266820U0118	LSTM	87,93	ETS	118,671	LSTM	26,51
BR0268084U0042	SES	118	LSTM	253,83	LSTM	340,39
BR0268098U0041	NAIVE	1717,5	HOLT_LINEAR	3465,084	LSTM	5316,38
BR0268118U0135	LSTM	8,85	LSTM	4,82	SES	25,536
BR0268143U0042	NAIVE	272,5	LSTM	251,45	HOLT_LINEAR	389,502
BR0268825U0042	HOLT_LINEAR	447,33	LSTM	531,83	LSTM	817,03
BR0271620U0042	LSTM	396,6	LSTM	371,54	LSTM	204,88
BR0271621U0042	NAIVE	1295	LSTM	1521,34	LSTM	2138,62
BR0272083U0042	HOLT_LINEAR	8596,143	ARIMA	2616,237	HOLT_WINTERS	2251,103
BR0272786U0042	HOLT_WINTERS	304,015	LSTM	89,82	HOLT_WINTERS	295,056
BR0272824U0042	HOLT_LINEAR	391,236	ETS	45	LSTM	135,17
BR0272825U0042	LSTM	1310,58	LSTM	439,07	LSTM	1980,6
BR0272833U0042	LSTM	539,8	NAIVE	510	LSTM	4658,38
BR0272835U0041	SNAIVE	1064,5	LSTM	868,72	HOLT_LINEAR	150,431
BR0277434U0135	LSTM	125,1	ARIMA	60,286	HOLT_WINTERS	53,79
BR0277438U0118	ETS	14,75	HOLT_DAMPED	18,747	LSTM	28,8
BR0277743U0118	LSTM	11,29	LSTM	27,98	LSTM	22,45
BR0285817U0046	LSTM	146,16	HOLT_WINTERS	362,577	LSTM	312,94
BR0285818U0046	LSTM	159,5	HOLT_WINTERS	233,899	HOLT_WINTERS	153,405
BR0288640U0042	SES	285	LSTM	228,23	LSTM	162,83
BR0288641U0042	HOLT_LINEAR	1528,367	HOLT_LINEAR	2097,798	SNAIVE	2245
BR0290058U0135	LSTM	53,1	SNAIVE	48,25	HOLT_LINEAR	112,465
BR0292372U0118	SNAIVE	72,75	ARIMA	63,84	SNAIVE	61
BR0315088U0042	THETA	923,219	ARIMA	274,602	LSTM	582,52
BR0325836U0042	ETS	164,53	ARIMA	139,199	LSTM	72,42
BR0342320U0041	LSTM	334,7	HOLT_WINTERS	219,549	HOLT_WINTERS	438,913
BR0342746U0118	HOLT_LINEAR	47,693	ETS	91,283	LSTM	28,93
BR0343607U0118	LSTM	39,75	LSTM	175,1	LSTM	20,12
BR0343608U0118	LSTM	237,6	SNAIVE	578	LSTM	169,54
BR0369176U0042	LSTM	295,34	LSTM	155,04	LSTM	142,37

Tabela 3.6: Comparação entre os erros do modelo LSTM e do segundo colocado para o DF - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266820U0118	87,93	HOLT_LINEAR	134,68	53,17
BR0268118U0135	8,85	SES	9,21	4,07
BR0271620U0042	396,60	HOLT_LINEAR	462,26	16,56
BR0272825U0042	1310,58	NAIVE	1375	4,92
BR0272833U0042	539,80	HOLT_LINEAR	1180,39	118,67
BR0277434U0135	125,10	ARIMA	153,32	22,56
BR0277743U0118	11,29	ETS	17,98	59,26
BR0285817U0046	146,16	NAIVE	202,5	38,55
BR0285818U0046	159,50	HOLT_DAMPED	167,49	5,01
BR0290058U0135	53,10	SES	70,25	32,3
BR0342320U0041	334,7	THETA	380,7	13,74
BR0343607U0118	39,75	HOLT_LINEAR	44,09	10,92
BR0343608U0118	237,60	SES	239,5	0,80
BR0369176U0042	295,34	ARIMA	337,13	14,15

Tabela 3.7: Comparação entre os erros do modelo LSTM e do segundo colocado para o DF - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0268084U0042	253,83	NAIVE	258,00	1,64
BR0268118U0135	4,82	ETS	5,00	3,73
BR0268143U0042	251,45	NAIVE	335,00	33,23
BR0268825U0042	531,83	THETA	621,50	16,86
BR0271620U0042	371,54	SNAIVE	572,50	54,09
BR0271621U0042	1521,34	HOLT_LINEAR	1743,08	14,58
BR0272786U0042	89,82	HOLT_LINEAR	135,61	50,98
BR0272825U0042	439,07	SNAIVE	927,50	111,24
BR0272835U0041	868,72	HOLT_LINEAR	1046,93	20,51
BR0277743U0118	27,98	ETS	30,08	7,51
BR0288640U0042	228,23	SES	238,46	4,48
BR0343607U0118	175,10	HOLT_WINTERS	199,03	13,67
BR0369176U0042	155,04	HOLT_LINEAR	157,50	1,59

Tabela 3.8: Comparação entre os erros do modelo LSTM e do segundo colocado para o DF - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266820U0118	26,51	SES	33,88	27,80
BR0268084U0042	340,39	HOLT_DAMPED	365,00	7,23
BR0268098U0041	5316,38	SES	5637,50	6,04
BR0268825U0042	817,03	ETS	848,62	3,87
BR0271620U0042	204,88	HOLT_DAMPED	399,55	95,02
BR0271621U0042	2138,62	ETS	2412,50	12,81
BR0272824U0042	135,17	ETS	183,12	35,47
BR0272825U0042	1980,60	NAIVE	2015,00	1,74
BR0272833U0042	4658,38	HOLT_LINEAR	4700,00	0,89
BR0277438U0118	28,80	THETA	32,16	11,67
BR0277743U0118	22,45	HOLT_DAMPED	32,56	45,03
BR0285817U0046	312,94	HOLT_WINTERS	315,56	0,84
BR0288640U0042	162,83	NAIVE	187,50	15,15
BR0315088U0042	582,52	NAIVE	607,50	4,29
BR0325836U0042	72,42	HOLT_WINTERS	90,38	24,80
BR0342746U0118	28,93	ETS	37,69	30,28
BR0343607U0118	20,12	SNAIVE	27,00	34,19
BR0343608U0118	169,54	NAIVE	172,00	1,45
BR0369176U0042	142,37	SES	243,90	71,31

CEARÁ

Com relação ao Estado do Ceará, a Figura 3.13 mostra que o modelo LSTM foi superior para 24, 19 e 18 dos medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 64,8%, 51,4% e 48,6% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 61 medicamentos, o que representa 54,9% de todas as previsões realizadas.

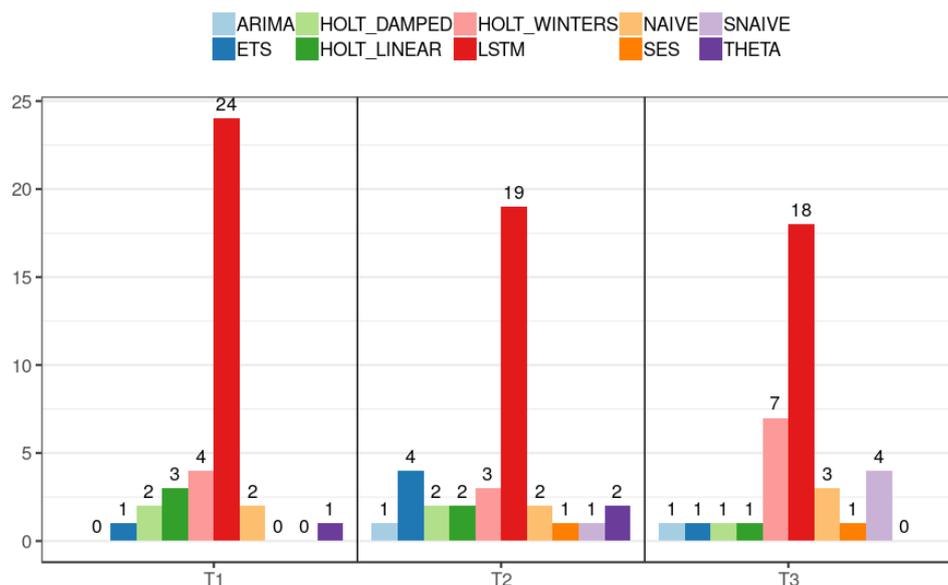


Figura 3.13: Contagem dos modelos vencedores em cada trimestre de 2018 para o CE, desconsiderando os empates.

A Tabela 3.9 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado do Ceará, e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.10 a 3.12 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0268097U0041 no primeiro trimestre (0,18%), BR0268097U0041 no segundo trimestre (0,89%) e BR0271620U0042 no terceiro trimestre (0,20%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0268825U0042 no primeiro trimestre (1912,4%), BR0267897U0041 no segundo trimestre (77,58%) e BR0343607U0118 no terceiro trimestre (266,80%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 127,9% (primeiro trimestre), em 24,7% (segundo trimestre) e em 48,7% (terceiro trimestre).

Tabela 3.9: Erro absoluto médio do modelo vencedor para os medicamentos do CE, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266629U0118	LSTM	801,68	LSTM	2806,94	LSTM	6477,1
BR0266820U0118	ETS	60,564	LSTM	96,08	HOLT_WINTERS	38,101
BR0267894U0041	LSTM	436,71	LSTM	396,65	HOLT_WINTERS	326,603
BR0267895U0041	LSTM	285,69	NAIVE	307,5	HOLT_WINTERS	595,22
BR0267896U0041	LSTM	80,85	HOLT_WINTERS	133,878	HOLT_WINTERS	150,334
BR0267897U0041	LSTM	294,16	LSTM	221,38	NAIVE	339
BR0268084U0042	HOLT_WINTERS	159,662	LSTM	299,65	LSTM	173,68
BR0268097U0041	LSTM	326,42	LSTM	479,05	LSTM	727,32
BR0268098U0041	HOLT_LINEAR	5179,181	THETA	1815,572	NAIVE	6521,25
BR0268114U0042	LSTM	692,99	SES	1619,75	LSTM	10333,66
BR0268143U0042	LSTM	461,53	ETS	335,178	SES	267,662
BR0268345U0042	HOLT_DAMPED	37,656	HOLT_DAMPED	46,929	LSTM	43,7
BR0268825U0042	LSTM	13,68	HOLT_DAMPED	135,645	LSTM	99,75
BR0271620U0042	HOLT_LINEAR	1081,48	LSTM	1939,01	LSTM	4673,36
BR0271621U0042	LSTM	1776,66	LSTM	1552,94	LSTM	4336,11
BR0272431U0042	LSTM	840,87	LSTM	1881,13	HOLT_LINEAR	1754,5
BR0272785U0042	LSTM	205,84	LSTM	366,61	HOLT_WINTERS	599,337
BR0272786U0042	HOLT_WINTERS	1698,875	THETA	1292,948	LSTM	524,94
BR0272826U0042	HOLT_WINTERS	1467,574	LSTM	3335,02	ARIMA	3042,362
BR0272831U0042	LSTM	554,03	HOLT_WINTERS	1150,509	HOLT_WINTERS	2060,738
BR0272832U0042	LSTM	2079,44	LSTM	14441,4	SNAIVE	12895,5
BR0272833U0042	LSTM	2678,42	LSTM	9653,62	SNAIVE	5141,75
BR0272835U0041	LSTM	317,01	ETS	225,773	LSTM	220,56
BR0277434U0135	THETA	22,539	HOLT_LINEAR	21,893	LSTM	19,4
BR0277438U0118	LSTM	18,46	HOLT_WINTERS	23,38	LSTM	18,42
BR0277743U0118	LSTM	8,58	HOLT_LINEAR	4,859	LSTM	3,09
BR0285817U0046	HOLT_LINEAR	659,908	LSTM	488,27	LSTM	168,91
BR0288640U0042	LSTM	13961,09	SNAIVE	9391,75	ETS	11445,435
BR0288641U0042	LSTM	4917,2	ARIMA	12474,35	SNAIVE	8348,5
BR0290058U0135	HOLT_WINTERS	38,826	ETS	91,581	HOLT_WINTERS	99,942
BR0315088U0042	LSTM	105,77	LSTM	430,56	HOLT_DAMPED	382,889
BR0333447U0118	LSTM	78,22	LSTM	45,12	LSTM	35,71
BR0342746U0118	NAIVE	69	NAIVE	110,25	LSTM	107,36
BR0343607U0118	NAIVE	25,5	LSTM	188,28	LSTM	25,21
BR0343608U0118	LSTM	220,62	LSTM	513,44	NAIVE	44
BR0367664U0075	LSTM	0,53	ETS	3,482	LSTM	3,93
BR0369176U0042	HOLT_DAMPED	323,352	LSTM	985,56	SNAIVE	1073,5

Tabela 3.10: Comparação entre os erros do modelo LSTM e do segundo colocado para o CE - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	801,68	SES	1808,85	125,63
BR0267894U0041	436,71	HOLT_LINEAR	468,80	7,35
BR0267895U0041	285,69	HOLT_WINTERS	571,69	100,11
BR0267896U0041	80,85	NAIVE	153,75	90,17
BR0267897U0041	294,16	HOLT_LINEAR	536,89	82,52
BR0268097U0041	326,42	HOLT_LINEAR	327,01	0,18
BR0268114U0042	692,99	HOLT_WINTERS	1286,17	85,60
BR0268143U0042	461,53	ARIMA	484,19	4,91
BR0268825U0042	13,68	SES	275,30	1912,43
BR0271621U0042	1776,66	ETS	2130,73	19,93
BR0272431U0042	840,87	NAIVE	1324,00	57,46
BR0272785U0042	205,84	ETS	223,65	8,65
BR0272831U0042	554,03	NAIVE	556,25	0,40
BR0272832U0042	2079,44	SNAIVE	3522,25	69,38
BR0272833U0042	2678,42	HOLT_DAMPED	6089,62	127,36
BR0272835U0041	317,01	THETA	362,79	14,44
BR0277438U0118	18,46	HOLT_WINTERS	18,76	1,63
BR0277743U0118	8,58	HOLT_WINTERS	24,25	182,63
BR0288640U0042	13961,09	HOLT_LINEAR	16159,30	15,75
BR0288641U0042	4917,20	SNAIVE	5513,00	12,12
BR0315088U0042	105,77	NAIVE	138,50	30,94
BR0333447U0118	78,22	HOLT_WINTERS	94,49	20,80
BR0343608U0118	220,62	ARIMA	246,10	11,55
BR0367664U0075	0,53	NAIVE	1,00	88,68

Tabela 3.11: Comparação entre os erros do modelo LSTM e do segundo colocado para o CE - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	2806,94	HOLT_WINTERS	4718,91	68,12
BR0266820U0118	96,08	HOLT_LINEAR	96,10	0,02
BR0267894U0041	396,65	HOLT_WINTERS	473,48	19,37
BR0267897U0041	221,38	HOLT_LINEAR	393,12	77,58
BR0268084U0042	299,65	THETA	310,49	3,62
BR0268097U0041	479,05	HOLT_WINTERS	483,33	0,89
BR0271620U0042	1939,01	ARIMA	1988,10	2,53
BR0271621U0042	1552,94	HOLT_DAMPED	1919,79	23,62
BR0272431U0042	1881,13	SNAIVE	2141,75	13,85
BR0272785U0042	366,61	THETA	643,81	75,61
BR0272826U0042	3335,02	HOLT_WINTERS	3808,75	14,20
BR0272832U0042	14441,40	SNAIVE	15703,50	8,74
BR0272833U0042	9653,62	SNAIVE	9940,25	2,97
BR0285817U0046	488,27	SES	713,63	46,15
BR0315088U0042	430,56	ETS	458,91	6,58
BR0333447U0118	45,12	HOLT_WINTERS	57,95	28,44
BR0343607U0118	188,28	ARIMA	206,16	9,50
BR0343608U0118	513,44	THETA	576,52	12,29
BR0369176U0042	985,56	HOLT_WINTERS	1536,63	55,91

Tabela 3.12: Comparação entre os erros do modelo LSTM e do segundo colocado para o CE - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	6477,10	ETS	6896,96	6,48
BR0268084U0042	173,68	HOLT_DAMPED	187,28	7,83
BR0268097U0041	727,32	HOLT_WINTERS	987,43	35,76
BR0268114U0042	10333,66	ETS	17221,44	66,65
BR0268345U0042	43,70	HOLT_LINEAR	54,97	25,79
BR0268825U0042	99,75	NAIVE	138,00	38,35
BR0271620U0042	4673,36	THETA	4682,70	0,20
BR0271621U0042	4336,11	HOLT_LINEAR	5026,16	15,91
BR0272786U0042	524,94	SES	666,75	27,01
BR0272835U0041	220,56	HOLT_DAMPED	257,89	16,93
BR0277434U0135	19,40	NAIVE	21,50	10,82
BR0277438U0118	18,42	HOLT_LINEAR	28,43	54,34
BR0277743U0118	3,09	HOLT_DAMPED	5,62	81,88
BR0285817U0046	168,91	NAIVE	288,50	70,80
BR0333447U0118	35,71	SNAIVE	46,25	29,52
BR0342746U0118	107,36	NAIVE	237,00	120,75
BR0343607U0118	25,21	HOLT_DAMPED	92,47	266,80
BR0367664U0075	3,93	SNAIVE	4,00	1,78

PERNAMBUCO

Com relação ao Estado de Pernambuco, a Figura 3.14 mostra que o modelo LSTM foi superior para 14, 15 e 13 dos medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 51,8%, 55,6% e 48,1% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 42 medicamentos, o que representa 51,8% de todas as previsões realizadas.

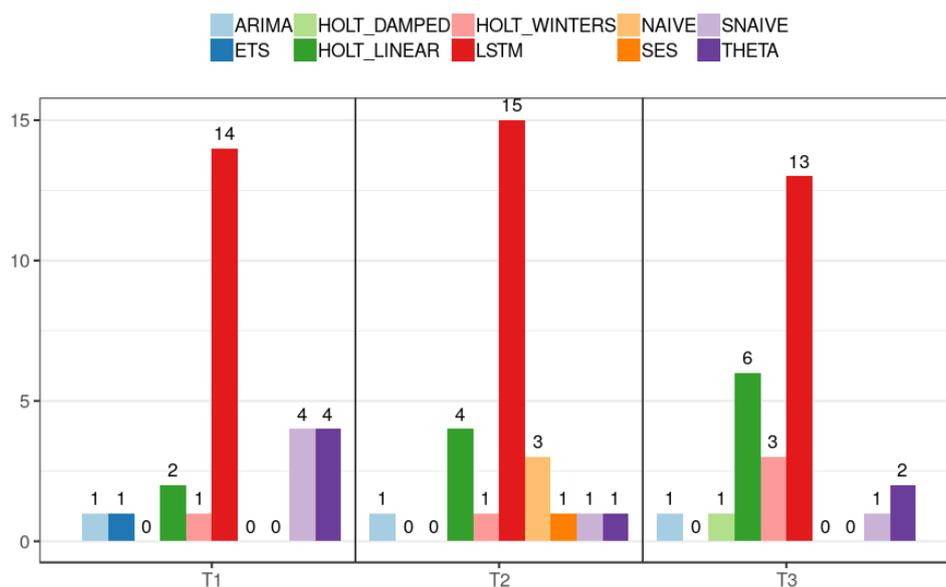


Figura 3.14: Contagem dos modelos vencedores em cada trimestre de 2018 para PE, desconsiderando os empates.

A Tabela 3.13 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado de Pernambuco, e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.14 a 3.16 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0268097U0041 no primeiro trimestre (2,21%), BR0271620U0042 no segundo trimestre (0,09%) e BR0267894U0041 no terceiro trimestre (2,94%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0266628U0118 no primeiro trimestre (106,69%), BR0266628U0118 no segundo trimestre (142,65%) e BR0288640U0042 no terceiro trimestre (222,38%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 36,6% (primeiro trimestre), em 38% (segundo trimestre) e em 72,4% (terceiro trimestre).

Tabela 3.13: Erro absoluto médio do modelo vencedor para os medicamentos de PE, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266628U0118	LSTM	8,37	LSTM	6,94	HOLT_WINTERS	10,387
BR0267894U0041	HOLT_LINEAR	232,916	LSTM	118,7	LSTM	178,26
BR0267895U0041	LSTM	816,49	NAIVE	692	THETA	372,305
BR0267896U0041	SNAIVE	521,25	NAIVE	397,5	HOLT_LINEAR	180
BR0267897U0041	LSTM	140,34	HOLT_LINEAR	202,5	LSTM	46,99
BR0268084U0042	THETA	172,684	HOLT_LINEAR	209,5	HOLT_LINEAR	139,059
BR0268097U0041	LSTM	587,04	HOLT_LINEAR	775,012	LSTM	2389,26
BR0268114U0042	SNAIVE	863	LSTM	487,96	HOLT_DAMPED	3329,953
BR0268143U0042	LSTM	1076,75	LSTM	619,63	LSTM	405,48
BR0271620U0042	ETS	1213,019	LSTM	1416,97	HOLT_WINTERS	991,921
BR0271621U0042	THETA	1273,383	HOLT_LINEAR	1897,903	ARIMA	834,092
BR0272083U0042	LSTM	14379,54	SNAIVE	43792,5	LSTM	8418,32
BR0272785U0042	LSTM	298,9	LSTM	1911,12	LSTM	480,86
BR0272786U0042	LSTM	737,44	LSTM	2029,44	LSTM	688,08
BR0272825U0042	SNAIVE	1270,25	LSTM	1326,03	SNAIVE	1078
BR0272826U0042	LSTM	984,22	THETA	1217,341	HOLT_LINEAR	7049,001
BR0272832U0042	THETA	938,67	HOLT_WINTERS	341,617	HOLT_WINTERS	1014,816
BR0277434U0135	HOLT_LINEAR	34,919	SES	52	THETA	43,949
BR0277743U0118	ARIMA	23,5	NAIVE	15	LSTM	10,33
BR0285817U0046	LSTM	266,45	LSTM	437,77	LSTM	250,67
BR0288640U0042	LSTM	1327,05	LSTM	531,8	LSTM	106,9
BR0288641U0042	LSTM	8143,26	ARIMA	8553,949	LSTM	4163,48
BR0290058U0135	HOLT_WINTERS	61,242	LSTM	31,9	HOLT_LINEAR	29,716
BR0333447U0118	SNAIVE	17,75	LSTM	36,16	LSTM	34,53
BR0343608U0118	LSTM	129,49	LSTM	502,33	LSTM	100,54
BR0369176U0042	LSTM	221,97	LSTM	167,2	HOLT_LINEAR	860,938
BR0369179U0042	THETA	220,106	LSTM	306,23	HOLT_LINEAR	356,664

Tabela 3.14: Comparação entre os erros do modelo LSTM e do segundo colocado para PE - T1 (2018)

CATMAT	EAM _{lstm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266628U0118	8,37	HOLT_LINEAR	17,30	106,69
BR0267895U0041	816,49	THETA	1242,76	52,21
BR0267897U0041	140,34	HOLT_WINTERS	235,57	67,86
BR0268097U0041	587,04	NAIVE	600,00	2,21
BR0268143U0042	1076,75	HOLT_LINEAR	1401,87	30,19
BR0272083U0042	14379,54	HOLT_WINTERS	19260,51	33,94
BR0272785U0042	298,90	NAIVE	360,50	20,61
BR0272786U0042	737,44	SNAIVE	759,50	2,99
BR0272826U0042	984,22	NAIVE	1226,75	24,64
BR0285817U0046	266,45	NAIVE	414,75	55,66
BR0288640U0042	1327,05	SNAIVE	1412,00	6,40
BR0288641U0042	8143,26	ARIMA	13067,71	60,47
BR0343608U0118	129,49	SNAIVE	150,25	16,03
BR0369176U0042	221,97	ETS	296,01	33,36

Tabela 3.15: Comparação entre os erros do modelo LSTM e do segundo colocado para o PE - T2 (2018)

CATMAT	EAM _{lstm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266628U0118	6,94	SES	16,84	142,65
BR0267894U0041	118,70	SES	147,50	24,26
BR0268114U0042	487,96	HOLT_LINEAR	636,00	30,34
BR0268143U0042	619,63	HOLT_LINEAR	1742,44	181,21
BR0271620U0042	1416,97	NAIVE	1418,25	0,09
BR0272785U0042	1911,12	THETA	1965,78	2,86
BR0272786U0042	2029,44	HOLT_WINTERS	2106,87	3,82
BR0272825U0042	1326,03	NAIVE	1613,00	21,64
BR0285817U0046	437,77	HOLT_DAMPED	654,99	49,62
BR0288640U0042	531,80	SES	583,99	9,81
BR0290058U0135	31,90	HOLT_LINEAR	43,34	35,86
BR0333447U0118	36,16	ARIMA	37,51	3,73
BR0343608U0118	502,33	NAIVE	549,25	9,34
BR0369176U0042	167,20	NAIVE	217,50	30,08
BR0369179U0042	306,23	NAIVE	383,75	25,31

Tabela 3.16: Comparação entre os erros do modelo LSTM e do segundo colocado para PE - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0267894U0041	178,26	NAIVE	183,50	2,94
BR0267897U0041	46,99	HOLT_WINTERS	93,64	99,28
BR0268097U0041	2389,26	HOLT_WINTERS	2796,01	17,02
BR0268143U0042	405,48	HOLT_DAMPED	1293,38	218,98
BR0272083U0042	8418,32	SNAIVE	19162,50	127,63
BR0272785U0042	480,86	SNAIVE	531,50	10,53
BR0272786U0042	688,08	SNAIVE	1205,00	75,12
BR0277743U0118	10,33	ETS	20,53	98,74
BR0285817U0046	250,67	NAIVE	260,00	3,72
BR0288640U0042	106,90	HOLT_LINEAR	344,62	222,38
BR0288641U0042	4163,48	ARIMA	5606,48	34,66
BR0333447U0118	34,53	HOLT_WINTERS	41,12	19,08
BR0343608U0118	100,54	SNAIVE	112,25	11,65

ALAGOAS

Com relação ao Estado de Alagoas, a Figura 3.15 mostra que o modelo LSTM foi superior para 19, 18 e 21 dos medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 50%, 47,4% e 55,2% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 58 medicamentos, o que representa 37,2% de todas as previsões realizadas.

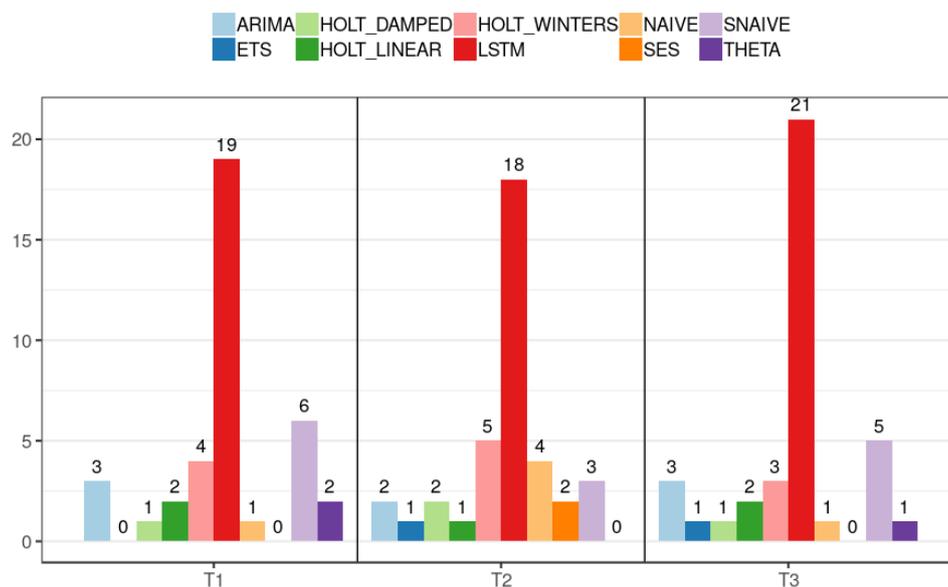


Figura 3.15: Contagem dos modelos vencedores em cada trimestre de 2018 para AL, desconsiderando os empates.

A Tabela 3.17 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado de Pernambuco, e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.18 a 3.20 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0272825U0042 no primeiro trimestre (1,55%), BR0268074U0081 no segundo trimestre (3,66%) e BR0271621U0042 no terceiro trimestre (1,02%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0268098U0041 no primeiro trimestre (163,21%), BR0267894U0041 no segundo trimestre (89,35%) e BR0267897U0041 no terceiro trimestre (238,97%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 42,1% (primeiro trimestre), em 24,1% (segundo trimestre) e em 41,2% (terceiro trimestre).

Tabela 3.17: Erro absoluto médio do modelo vencedor para os medicamentos de AL, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266629U0118	LSTM	316,51	LSTM	455,33	SNAIVE	259,75
BR0266820U0118	THETA	60,958	LSTM	110,08	LSTM	47,35
BR0267894U0041	ARIMA	125,9	LSTM	180,09	LSTM	175,39
BR0267895U0041	LSTM	160,96	LSTM	152,11	HOLT_LINEAR	56,25
BR0267896U0041	LSTM	81,36	ARIMA	121,069	SNAIVE	120
BR0267897U0041	SNAIVE	83	ETS	109,072	LSTM	28,38
BR0268074U0081	HOLT_LINEAR	2,566	LSTM	4,1	HOLT_WINTERS	10,408
BR0268084U0042	HOLT_WINTERS	77,337	LSTM	65,59	LSTM	84,31
BR0268097U0041	LSTM	280,95	LSTM	106,42	LSTM	144,86
BR0268098U0041	LSTM	973,16	LSTM	1251,32	LSTM	1061,39
BR0268114U0042	LSTM	112,71	SNAIVE	195	LSTM	1478,56
BR0268143U0042	HOLT_WINTERS	223,609	HOLT_WINTERS	105,98	LSTM	110,9
BR0268345U0042	HOLT_WINTERS	48,903	HOLT_DAMPED	40,23	LSTM	69,75
BR0268825U0042	LSTM	247,73	NAIVE	60	HOLT_LINEAR	53,746
BR0271620U0042	NAIVE	1206,5	HOLT_LINEAR	569,189	LSTM	301,66
BR0271621U0042	THETA	788	HOLT_WINTERS	1827,125	LSTM	1663,7
BR0272083U0042	LSTM	9920,98	HOLT_WINTERS	8599,136	LSTM	8112,3
BR0272431U0042	LSTM	430,55	SNAIVE	3143,75	SNAIVE	3184
BR0272785U0042	SNAIVE	1890	NAIVE	263,75	HOLT_DAMPED	286,737
BR0272786U0042	LSTM	1026,3	LSTM	575,02	ARIMA	459,671
BR0272825U0042	LSTM	725,35	LSTM	486,06	LSTM	519,18
BR0272826U0042	SNAIVE	1262,5	LSTM	477,72	SNAIVE	160,25
BR0272831U0042	SNAIVE	504,5	LSTM	4603,15	SNAIVE	3156,75
BR0272833U0042	LSTM	478,49	LSTM	2205,22	LSTM	6207,46
BR0272835U0041	LSTM	160,39	SES	191,494	HOLT_WINTERS	87,054
BR0277438U0118	SNAIVE	11	NAIVE	0,75	NAIVE	4,5
BR0277743U0118	LSTM	27,61	NAIVE	10,75	ETS	8,2
BR0285817U0046	HOLT_LINEAR	93,25	LSTM	43,01	LSTM	55,02
BR0285818U0046	ARIMA	61,406	SNAIVE	40	LSTM	49,1
BR0288641U0042	LSTM	983,2	LSTM	615,06	ARIMA	405,65
BR0290058U0135	HOLT_DAMPED	8,927	HOLT_WINTERS	27,834	HOLT_WINTERS	30,324
BR0292372U0118	LSTM	25,99	SES	34,25	LSTM	18,83
BR0315088U0042	LSTM	670,85	LSTM	630,52	LSTM	604,63
BR0333447U0118	ARIMA	10,24	HOLT_WINTERS	15,532	THETA	12,5
BR0342746U0118	LSTM	27,86	LSTM	32,15	LSTM	23,44
BR0343607U0118	LSTM	2,42	LSTM	3,6	ARIMA	2,682
BR0343608U0118	SNAIVE	113	HOLT_DAMPED	75,311	LSTM	13,52
BR0369178U0042	HOLT_WINTERS	47,636	ARIMA	101,795	LSTM	53,34

Tabela 3.18: Comparação entre os erros do modelo LSTM e do segundo colocado para AL - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	316,51	NAIVE	387,25	22,35
BR0267895U0041	160,96	ARIMA	223,63	38,94
BR0267896U0041	81,36	SNAIVE	150,00	84,37
BR0268097U0041	280,95	HOLT_LINEAR	321,79	14,54
BR0268098U0041	973,16	SNAIVE	2561,50	163,21
BR0268114U0042	112,71	SNAIVE	116,25	3,14
BR0268825U0042	247,73	HOLT_LINEAR	321,56	29,80
BR0272083U0042	9920,98	SNAIVE	12739,50	28,41
BR0272431U0042	430,55	ETS	651,34	51,28
BR0272786U0042	1026,30	ETS	1070,15	4,27
BR0272825U0042	725,35	ARIMA	736,58	1,55
BR0272833U0042	478,49	HOLT_LINEAR	885,77	85,12
BR0272835U0041	160,39	HOLT_WINTERS	171,24	6,76
BR0277743U0118	27,61	SNAIVE	46,50	68,42
BR0288641U0042	983,20	SNAIVE	1835,50	86,69
BR0292372U0118	25,99	NAIVE	44,50	71,22
BR0315088U0042	670,85	NAIVE	690,00	2,85
BR0342746U0118	27,86	ETS	37,45	34,42
BR0343607U0118	2,42	ARIMA	2,46	1,65

Tabela 3.19: Comparação entre os erros do modelo LSTM e do segundo colocado para AL - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	455,33	HOLT_DAMPED	541,46	18,92
BR0266820U0118	110,08	ARIMA	133,17	20,98
BR0267894U0041	180,09	HOLT_DAMPED	341,00	89,35
BR0267895U0041	152,11	HOLT_WINTERS	203,96	34,09
BR0268074U0081	4,10	NAIVE	4,25	3,66
BR0268084U0042	65,59	HOLT_LINEAR	77,02	17,43
BR0268097U0041	106,42	SNAIVE	112,50	5,71
BR0268098U0041	1251,32	HOLT_LINEAR	1375,25	9,90
BR0272786U0042	575,02	SNAIVE	760,00	32,17
BR0272825U0042	486,06	ARIMA	567,19	16,69
BR0272826U0042	477,72	SNAIVE	663,75	38,94
BR0272831U0042	4603,15	SNAIVE	5146,75	11,81
BR0272833U0042	2205,22	NAIVE	2556,75	15,94
BR0285817U0046	43,01	HOLT_WINTERS	59,27	37,81
BR0288641U0042	615,06	HOLT_LINEAR	782,24	27,18
BR0315088U0042	630,52	SNAIVE	855,00	35,60
BR0342746U0118	32,15	HOLT_DAMPED	34,22	6,44
BR0343607U0118	3,60	NAIVE	4,00	11,11

Tabela 3.20: Comparação entre os erros do modelo LSTM e do segundo colocado para AL - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266820U0118	47,35	HOLT_DAMPED	50,46	6,57
BR0267894U0041	175,39	ARIMA	253,32	44,43
BR0267897U0041	28,38	ARIMA	96,20	238,97
BR0268084U0042	84,31	HOLT_DAMPED	90,05	6,81
BR0268097U0041	144,86	HOLT_LINEAR	219,02	51,19
BR0268098U0041	1061,39	ETS	1191,71	12,28
BR0268114U0042	1478,56	SNAIVE	1769,75	19,69
BR0268143U0042	110,90	HOLT_WINTERS	255,87	130,72
BR0268345U0042	69,75	NAIVE	75,00	7,53
BR0271620U0042	301,66	ARIMA	405,50	34,42
BR0271621U0042	1663,70	HOLT_WINTERS	1680,60	1,02
BR0272083U0042	8112,30	NAIVE	9358,25	15,36
BR0272825U0042	519,18	NAIVE	659,50	27,03
BR0272833U0042	6207,46	HOLT_DAMPED	7130,18	14,86
BR0285817U0046	55,02	THETA	79,90	45,22
BR0285818U0046	49,10	SNAIVE	92,50	88,39
BR0292372U0118	18,83	THETA	21,25	12,85
BR0315088U0042	604,63	THETA	674,91	11,62
BR0342746U0118	23,44	NAIVE	30,00	27,99
BR0343608U0118	13,52	NAIVE	21,00	55,33
BR0369178U0042	53,34	NAIVE	60,00	12,49

AMAPÁ

Com relação ao Estado do Amapá, a Figura 3.16 mostra que o modelo LSTM foi superior para 2, 1 e 2 dos medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 66,7%, 33,3% e 66,7% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 5 medicamentos, o que representa 55,6% de todas as previsões realizadas.

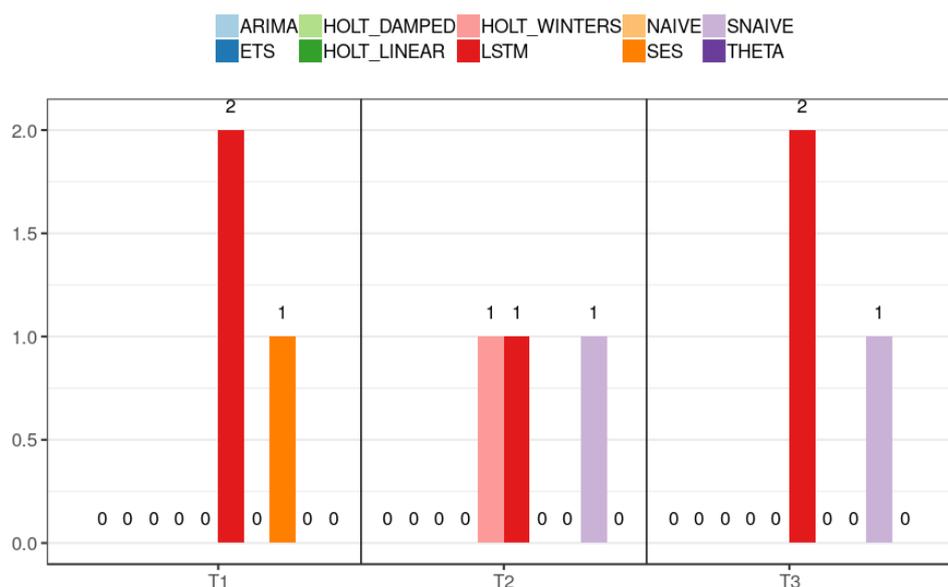


Figura 3.16: Contagem dos modelos vencedores em cada trimestre de 2018 para AP, desconsiderando os empates.

A Tabela 3.21 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado de Pernambuco, e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.22 a 3.24 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados. O destaque para esse Estado é a diminuição percentual de cerca de 1.000% do erro absoluto médio para a previsão do medicamento BR0268098U0041 no primeiro trimestre, quando utilizado o modelo LSTM.

Tabela 3.21: Erro absoluto médio do modelo vencedor para os medicamentos do AP, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0268098U0041	LSTM	37,09	SNAIVE	202,50	SNAIVE	675,00
BR0288641U0042	LSTM	64,21	HOLT_WINTERS	268,18	LSTM	276,27
BR0290058U0135	SES	10,80	LSTM	18,74	LSTM	13,82

Tabela 3.22: Comparação entre os erros do modelo LSTM e do segundo colocado para o AP - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0268098U0041	37,09	HOLT_WINTERS	407,69	999,19
BR0288641U0042	64,21	THETA	254,40	296,20

Tabela 3.23: Comparação entre os erros do modelo LSTM e do segundo colocado para o AP - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0290058U0135	18,74	HOLT_DAMPED	19,38	3,42

Tabela 3.24: Comparação entre os erros do modelo LSTM e do segundo colocado para o AP - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0288641U0042	276,27	ARIMA	297,78	7,79
BR0290058U0135	13,82	HOLT_DAMPED	17,15	24,10

TOCANTINS

Com relação ao Estado de Tocantins, a Figura 3.17 mostra que o modelo LSTM foi superior para 13, 17 e 9 dos medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 59,1%, 77,3% e 40,1% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 39 medicamentos, o que representa 59,1% de todas as previsões realizadas.

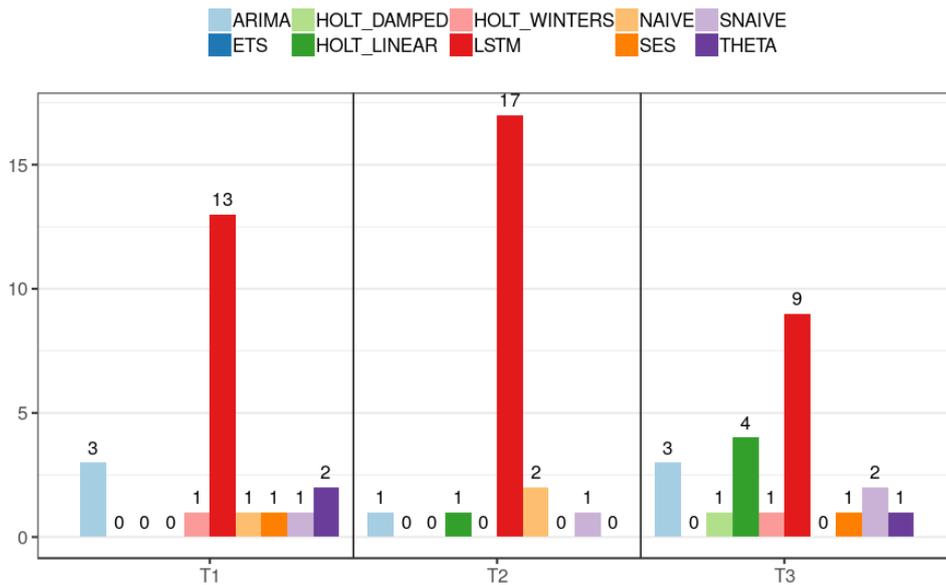


Figura 3.17: Contagem dos modelos vencedores em cada trimestre de 2018 para TO, desconsiderando os empates.

A Tabela 3.25 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado de Tocantins, e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.26 a 3.28 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0272431U0042 no segundo trimestre (0,14%) e BR0272833U0042 no terceiro trimestre (5%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0288640U0042 no primeiro trimestre (466,33%), BR0268143U0042 no segundo trimestre (142,77%) e BR0343608U0118 no terceiro trimestre (323,84%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 134,7% (primeiro trimestre), em 42,2% (segundo trimestre) e em 84,5% (terceiro trimestre).

Tabela 3.25: Erro absoluto médio do modelo vencedor para os medicamentos de TO, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266629U0118	SNAIVE	123,75	LSTM	130,44	LSTM	171,77
BR0267894U0041	LSTM	117,03	HOLT_LINEAR	84,88	HOLT_LINEAR	42,87
BR0267895U0041	LSTM	200,90	LSTM	167,96	LSTM	26,66
BR0267896U0041	LSTM	83,98	LSTM	48,94	LSTM	29,74
BR0268098U0041	LSTM	325,95	LSTM	578,60	ARIMA	526,70
BR0268114U0042	LSTM	77,56	LSTM	80,48	LSTM	578,93
BR0268143U0042	LSTM	42,67	LSTM	46,78	SNAIVE	27,50
BR0268825U0042	LSTM	53,40	ARIMA	76,60	SES	50,97
BR0271620U0042	HOLT_WINTERS	112,90	SNAIVE	780,00	ARIMA	350,69
BR0271621U0042	THETA	324,30	LSTM	226,09	LSTM	147,80
BR0272083U0042	ARIMA	398,87	NAIVE	630,00	HOLT_LINEAR	471,56
BR0272431U0042	THETA	278,62	LSTM	337,85	HOLT_WINTERS	678,17
BR0272825U0042	ARIMA	154,47	LSTM	220,26	LSTM	127,45
BR0272826U0042	LSTM	341,89	LSTM	124,98	LSTM	142,95
BR0272832U0042	LSTM	138,13	LSTM	212,78	SNAIVE	757,50
BR0272833U0042	NAIVE	442,50	LSTM	341,80	LSTM	999,96
BR0288640U0042	LSTM	9,83	LSTM	98,83	HOLT_DAMPED	59,98
BR0288641U0042	LSTM	136,15	LSTM	113,35	ARIMA	158,28
BR0315088U0042	LSTM	107,04	LSTM	196,47	HOLT_LINEAR	169,29
BR0333447U0118	ARIMA	10,20	LSTM	10,28	THETA	10,05
BR0343607U0118	SES	5,00	NAIVE	4,00	HOLT_LINEAR	4,77
BR0343608U0118	LSTM	10,75	LSTM	79,60	LSTM	4,95

Tabela 3.26: Comparação entre os erros do modelo LSTM e do segundo colocado para o TO - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0267894U0041	117,03	HOLT_WINTERS	190,93	63,15
BR0267895U0041	200,90	ETS	363,21	80,79
BR0267896U0041	83,98	HOLT_WINTERS	124,02	47,68
BR0268098U0041	325,95	HOLT_LINEAR	418,36	28,35
BR0268114U0042	77,56	SNAIVE	97,50	25,71
BR0268143U0042	42,67	HOLT_DAMPED	93,19	118,40
BR0268825U0042	53,40	ETS	104,46	95,62
BR0272826U0042	341,89	SNAIVE	900,00	163,24
BR0272832U0042	138,13	NAIVE	255,00	84,61
BR0288640U0042	9,83	HOLT_LINEAR	55,67	466,33
BR0288641U0042	136,15	HOLT_LINEAR	241,81	77,61
BR0315088U0042	107,04	SNAIVE	217,50	103,20
BR0343608U0118	10,75	HOLT_LINEAR	53,39	396,65

Tabela 3.27: Comparação entre os erros do modelo LSTM e do segundo colocado para o TO - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	130,44	HOLT_WINTERS	237,06	81,74
BR0267895U0041	167,96	SNAIVE	240,00	42,89
BR0267896U0041	48,94	HOLT_DAMPED	68,55	40,07
BR0268098U0041	578,60	HOLT_WINTERS	639,88	10,59
BR0268114U0042	80,48	HOLT_LINEAR	95,22	18,32
BR0268143U0042	46,78	ETS	113,57	142,77
BR0271621U0042	226,09	HOLT_WINTERS	267,88	18,48
BR0272431U0042	337,85	HOLT_LINEAR	338,31	0,14
BR0272825U0042	220,26	HOLT_WINTERS	353,77	60,61
BR0272826U0042	124,98	SNAIVE	285,00	128,04
BR0272832U0042	212,78	SES	240,00	12,79
BR0272833U0042	341,80	HOLT_WINTERS	489,21	43,13
BR0288640U0042	98,83	HOLT_WINTERS	155,23	57,07
BR0288641U0042	113,35	HOLT_DAMPED	144,99	27,91
BR0315088U0042	196,47	NAIVE	225,00	14,52
BR0333447U0118	10,28	HOLT_WINTERS	10,53	2,43
BR0343608U0118	79,60	NAIVE	93,00	16,83

Tabela 3.28: Comparação entre os erros do modelo LSTM e do segundo colocado para o TO - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	171,77	ARIMA	226,62	31,93
BR0267895U0041	26,66	SNAIVE	30,00	12,53
BR0267896U0041	29,74	HOLT_LINEAR	64,40	116,54
BR0268114U0042	578,93	SNAIVE	892,50	54,16
BR0271621U0042	147,80	SES	165,00	11,64
BR0272825U0042	127,45	HOLT_DAMPED	375,06	194,28
BR0272826U0042	142,95	NAIVE	157,50	10,18
BR0272833U0042	999,96	NAIVE	1050,00	5,00
BR0343608U0118	4,95	ETS	20,98	323,84

PARÁ

Com relação ao Estado do Pará, a Figura 3.18 mostra que o modelo LSTM foi superior para 25, 23 e 23 dos medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 69,4%, 63,9% e 63,9% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 39 medicamentos, o que representa 65,7% de todas as previsões realizadas.

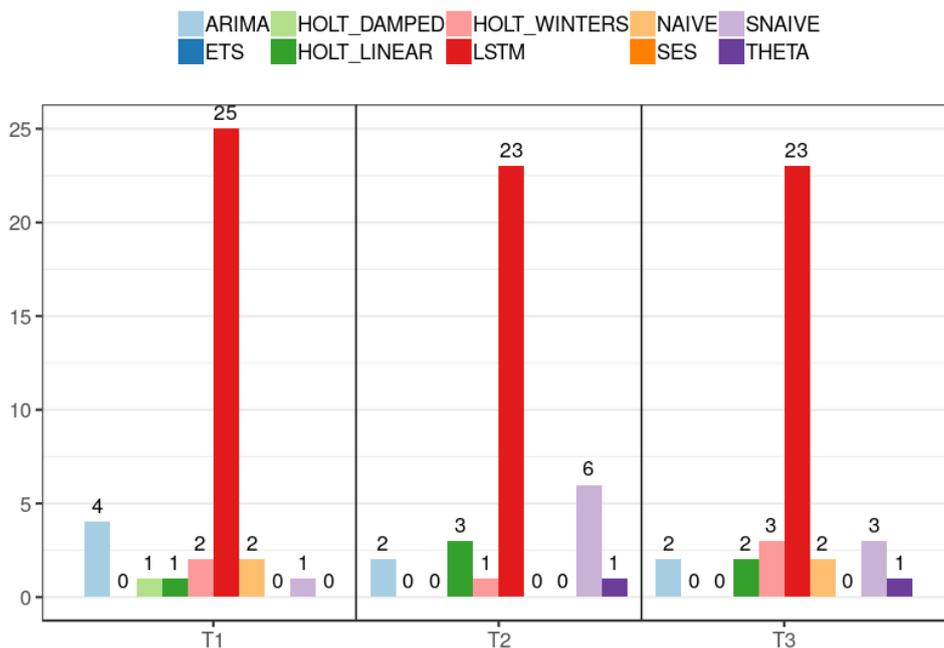


Figura 3.18: Contagem dos modelos vencedores em cada trimestre de 2018 para o PA, desconsiderando os empates.

A Tabela 3.29 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado do Pará, e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.30 a 3.32 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0268097U0041 no primeiro trimestre (6,89%), BR0266820U0118 no segundo trimestre (0,66%) e BR0277438U0118 no terceiro trimestre (1,87%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0369176U0042 no primeiro trimestre (934,48%), BR0267895U0041 no segundo trimestre (347,62%) e BR0277435U0135 no terceiro trimestre (287,38%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 182% (primeiro trimestre), em 56,6% (segundo trimestre) e em 43,2% (terceiro trimestre).

Tabela 3.29: Erro absoluto médio do modelo vencedor para os medicamentos do PA, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266629U0118	LSTM	519,98	LSTM	407,54	LSTM	735,79
BR0266820U0118	ARIMA	32,083	LSTM	36,26	LSTM	31,6
BR0267894U0041	ARIMA	19,762	LSTM	59,6	LSTM	41,96
BR0267895U0041	HOLT_LINEAR	75	LSTM	25,2	LSTM	42,8
BR0267897U0041	ARIMA	27,26	LSTM	45,82	THETA	43,13
BR0268084U0042	LSTM	38,75	HOLT_WINTERS	146,796	SNAIVE	271,5
BR0268097U0041	LSTM	394,01	LSTM	254,98	HOLT_WINTERS	193,06
BR0268098U0041	LSTM	1453,78	SNAIVE	4612,5	SNAIVE	5998,5
BR0268114U0042	LSTM	201,89	LSTM	2096,39	LSTM	3434,47
BR0268143U0042	LSTM	150,95	SNAIVE	107,5	LSTM	147,18
BR0268825U0042	LSTM	135,05	HOLT_LINEAR	356,218	LSTM	324,73
BR0272083U0042	LSTM	2570,08	LSTM	14940,3	LSTM	2244,82
BR0272431U0042	LSTM	389,81	LSTM	775,73	NAIVE	443,5
BR0272785U0042	LSTM	198,22	LSTM	92,62	LSTM	111,88
BR0272786U0042	LSTM	85,72	THETA	56,822	LSTM	46,49
BR0272825U0042	LSTM	410,83	LSTM	436,8	HOLT_LINEAR	455,701
BR0272826U0042	LSTM	382,61	LSTM	553,87	LSTM	852,69
BR0272831U0042	HOLT_WINTERS	164,451	ARIMA	359,543	SNAIVE	735
BR0272832U0042	HOLT_DAMPED	69,555	LSTM	705,96	LSTM	1900,48
BR0272833U0042	NAIVE	429,5	LSTM	316,86	LSTM	912,49
BR0272835U0041	LSTM	496,15	SNAIVE	667,5	ARIMA	820,128
BR0277434U0135	LSTM	10,68	SNAIVE	23,5	HOLT_WINTERS	21,783
BR0277435U0135	LSTM	10,49	LSTM	10,96	LSTM	10,38
BR0277438U0118	LSTM	10,98	LSTM	10,48	LSTM	18,71
BR0277743U0118	LSTM	4,76	LSTM	6,35	HOLT_WINTERS	3,931
BR0285817U0046	HOLT_WINTERS	43,059	LSTM	49,09	LSTM	51,49
BR0285818U0046	ARIMA	12,905	SNAIVE	15	LSTM	16,18
BR0288640U0042	LSTM	369,16	HOLT_LINEAR	594,07	HOLT_LINEAR	314,843
BR0290058U0135	NAIVE	24	HOLT_LINEAR	27,629	LSTM	25,08
BR0292372U0118	SNAIVE	6	LSTM	19,75	LSTM	4,27
BR0315088U0042	LSTM	180,71	LSTM	479,02	LSTM	274,13
BR0333447U0118	LSTM	8,87	ARIMA	3,665	LSTM	2,65
BR0342746U0118	LSTM	23,39	LSTM	45,32	LSTM	45,49
BR0343607U0118	LSTM	7,74	LSTM	70,87	ARIMA	41,499
BR0343608U0118	LSTM	29,83	LSTM	289,62	LSTM	41,67
BR0369176U0042	LSTM	46,4	SNAIVE	97,5	NAIVE	322,5

Tabela 3.30: Comparação entre os erros do modelo LSTM e do segundo colocado para o PA - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	519,98	HOLT_WINTERS	742,77	42,85
BR0268084U0042	38,75	HOLT_DAMPED	71,45	84,39
BR0268097U0041	394,01	ETS	421,17	6,89
BR0268098U0041	1453,78	ETS	1599,15	10,00
BR0268114U0042	201,89	ARIMA	364,39	80,49
BR0268143U0042	150,95	NAIVE	167,50	10,96
BR0268825U0042	135,05	SNAIVE	672,50	397,96
BR0272083U0042	2570,08	ARIMA	16350,43	536,18
BR0272431U0042	389,81	SES	796,50	104,33
BR0272785U0042	198,22	ETS	406,01	104,83
BR0272786U0042	85,72	HOLT_WINTERS	305,79	256,73
BR0272825U0042	410,83	ETS	584,96	42,38
BR0272826U0042	382,61	HOLT_WINTERS	1776,59	364,33
BR0272835U0041	496,15	SES	1470,47	196,38
BR0277434U0135	10,68	NAIVE	26,50	148,13
BR0277435U0135	10,49	NAIVE	18,00	71,59
BR0277438U0118	10,98	HOLT_LINEAR	17,54	59,74
BR0277743U0118	4,76	NAIVE	8,75	83,82
BR0288640U0042	369,16	SES	730,00	97,75
BR0315088U0042	180,71	SNAIVE	947,25	424,18
BR0333447U0118	8,87	NAIVE	13,00	46,56
BR0342746U0118	23,39	HOLT_WINTERS	54,61	133,48
BR0343607U0118	7,74	ETS	10,15	31,14
BR0343608U0118	29,83	HOLT_WINTERS	114,03	282,27
BR0369176U0042	46,40	NAIVE	480,00	934,48

Tabela 3.31: Comparação entre os erros do modelo LSTM e do segundo colocado para o PA - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	407,54	HOLT_WINTERS	1043,02	155,93
BR0266820U0118	36,26	NAIVE	36,50	0,66
BR0267894U0041	59,60	THETA	84,72	42,15
BR0267895U0041	25,20	HOLT_DAMPED	112,80	347,62
BR0267897U0041	45,82	SNAIVE	135,00	194,63
BR0268097U0041	254,98	ARIMA	509,81	99,94
BR0268114U0042	2096,39	HOLT_DAMPED	2273,56	8,45
BR0272083U0042	14940,30	HOLT_DAMPED	15808,34	5,81
BR0272431U0042	775,73	THETA	809,53	4,36
BR0272785U0042	92,62	SES	115,50	24,70
BR0272825U0042	436,80	SNAIVE	602,50	37,93
BR0272826U0042	553,87	SNAIVE	1184,75	113,90
BR0272832U0042	705,96	HOLT_LINEAR	725,00	2,70
BR0272833U0042	316,86	HOLT_DAMPED	593,58	87,33
BR0277435U0135	10,96	NAIVE	11,00	0,36
BR0277438U0118	10,48	HOLT_DAMPED	15,78	50,57
BR0277743U0118	6,35	HOLT_LINEAR	7,12	12,13
BR0285817U0046	49,09	ARIMA	57,29	16,70
BR0292372U0118	19,75	HOLT_LINEAR	22,17	12,25
BR0315088U0042	479,02	NAIVE	517,50	8,03
BR0342746U0118	45,32	ARIMA	46,31	2,18
BR0343607U0118	70,87	HOLT_WINTERS	105,88	49,40
BR0343608U0118	289,62	SNAIVE	361,50	24,82

Tabela 3.32: Comparação entre os erros do modelo LSTM e do segundo colocado para o PA - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	735,79	HOLT_DAMPED	981,39	33,38
BR0266820U0118	31,60	HOLT_WINTERS	39,55	25,16
BR0267894U0041	41,96	ETS	46,63	11,13
BR0267895U0041	42,80	ETS	44,44	3,83
BR0268114U0042	3434,47	SNAIVE	3737,50	8,82
BR0268143U0042	147,18	THETA	186,54	26,74
BR0268825U0042	324,73	HOLT_LINEAR	333,15	2,59
BR0272083U0042	2244,82	SES	3172,50	41,33
BR0272785U0042	111,88	ETS	121,96	9,01
BR0272786U0042	46,49	THETA	52,50	12,93
BR0272826U0042	852,69	HOLT_LINEAR	1026,51	20,38
BR0272832U0042	1900,48	SNAIVE	2509,00	32,02
BR0272833U0042	912,49	ETS	1228,65	34,65
BR0277435U0135	10,38	ETS	40,21	287,38
BR0277438U0118	18,71	ETS	19,06	1,87
BR0285817U0046	51,49	HOLT_LINEAR	71,03	37,95
BR0285818U0046	16,18	SNAIVE	21,25	31,33
BR0290058U0135	25,08	SNAIVE	59,00	135,25
BR0292372U0118	4,27	NAIVE	7,00	63,93
BR0315088U0042	274,13	NAIVE	335,50	22,39
BR0333447U0118	2,65	SES	5,20	96,23
BR0342746U0118	45,49	NAIVE	51,50	13,21
BR0343608U0118	41,67	SNAIVE	59,25	42,19

RIO GRANDE DO NORTE

Com relação ao Estado do Rio Grande do Norte, a Figura 3.19 mostra que o modelo LSTM foi superior para 19, 11 e 22 medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 59,4%, 34,4% e 68,8% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 52 medicamentos, o que representa 54,2% de todas as previsões realizadas.

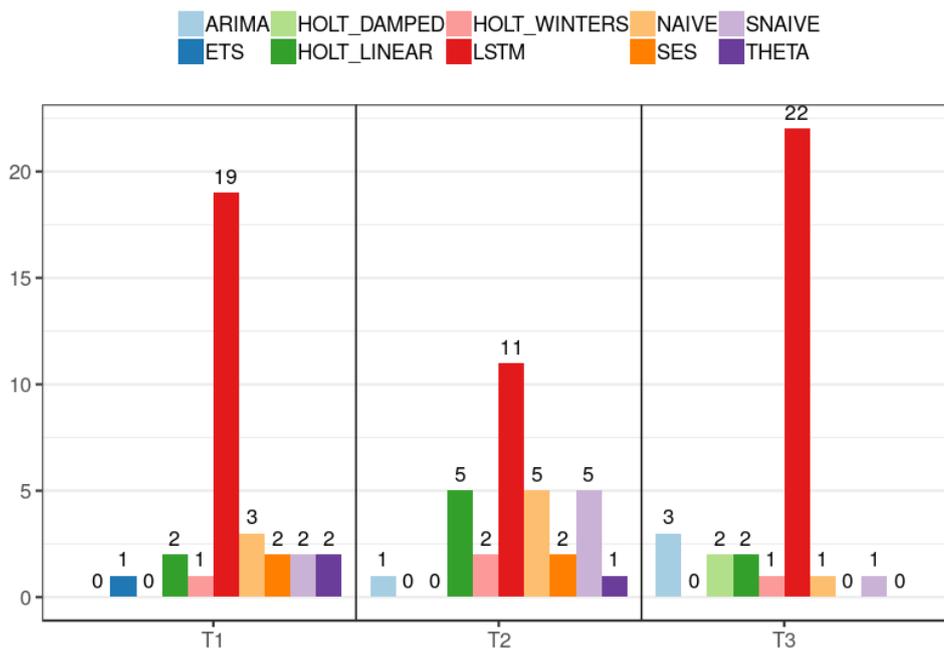


Figura 3.19: Contagem dos modelos vencedores em cada trimestre de 2018 para o RN, desconsiderando os empates.

A Tabela 3.33 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado do Rio Grande do Norte e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.34 a 3.36 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0272786U0042 no primeiro trimestre (1,85%), BR0343607U0118 no segundo trimestre (0,72%) e BR0369176U0042 no terceiro trimestre (1,81%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0285817U0046 no primeiro trimestre (253,55%), BR0268118U0135 no segundo trimestre (129%) e BR0288640U0042 no terceiro trimestre (162,24%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 67,1% (primeiro trimestre), em 23,9% (segundo trimestre) e em 30,8% (terceiro trimestre).

Tabela 3.33: Erro absoluto médio do modelo vencedor para os medicamentos do RN, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266629U0118	LSTM	1716,61	SNAIVE	2965	LSTM	1113,25
BR0266820U0118	LSTM	69,07	HOLT_LINEAR	47,713	LSTM	46,85
BR0267894U0041	LSTM	1103,2	SNAIVE	2059,5	SNAIVE	364
BR0267895U0041	LSTM	2262,4	LSTM	1344,4	LSTM	200,34
BR0267896U0041	LSTM	109,91	NAIVE	112,5	LSTM	178,57
BR0267897U0041	LSTM	174,44	THETA	200,089	LSTM	208,36
BR0268084U0042	SES	75,5	HOLT_LINEAR	102	LSTM	93,09
BR0268097U0041	LSTM	93,95	NAIVE	52,5	LSTM	77,62
BR0268098U0041	NAIVE	997,5	HOLT_LINEAR	937,108	HOLT_DAMPED	3755,395
BR0268118U0135	HOLT_WINTERS	38,499	LSTM	21,07	HOLT_LINEAR	6,39
BR0268143U0042	LSTM	435,09	NAIVE	2995	LSTM	1947,58
BR0271620U0042	NAIVE	2572,5	HOLT_WINTERS	1603,065	LSTM	20354,53
BR0271621U0042	THETA	3695,477	HOLT_LINEAR	4711,884	NAIVE	13310
BR0272083U0042	SNAIVE	17910,75	LSTM	29576,04	ARIMA	18207,549
BR0272785U0042	LSTM	623,11	SNAIVE	1594,5	LSTM	1369,09
BR0272786U0042	LSTM	1114,43	LSTM	1869,05	LSTM	809,28
BR0272831U0042	SNAIVE	1366,25	SES	5737,5	LSTM	9977,66
BR0272833U0042	NAIVE	2558,75	ARIMA	7996,033	HOLT_WINTERS	19943,481
BR0277434U0135	LSTM	15,88	LSTM	31,56	LSTM	24,7
BR0277438U0118	LSTM	20,79	SES	7	LSTM	10,04
BR0277743U0118	ETS	8,191	LSTM	6,27	LSTM	15,25
BR0285817U0046	LSTM	167,2	SNAIVE	367,5	ARIMA	403,06
BR0285818U0046	LSTM	58,52	LSTM	43,85	LSTM	30,64
BR0288640U0042	LSTM	250,72	LSTM	141,17	LSTM	28,6
BR0288641U0042	THETA	907,5	HOLT_LINEAR	1170	HOLT_LINEAR	1132,329
BR0315088U0042	LSTM	94,25	LSTM	301,13	LSTM	79,31
BR0333447U0118	HOLT_LINEAR	24,71	HOLT_WINTERS	88,174	ARIMA	170,211
BR0342746U0118	LSTM	26,25	NAIVE	23,75	LSTM	14,49
BR0343607U0118	LSTM	30,23	LSTM	216,63	LSTM	264,98
BR0343608U0118	LSTM	124,9	NAIVE	554	LSTM	268,95
BR0369176U0042	SES	127,5	LSTM	194,73	LSTM	237,61
BR0369179U0042	HOLT_LINEAR	244,503	SNAIVE	322,5	HOLT_DAMPED	607,255

Tabela 3.34: Comparação entre os erros do modelo LSTM e do segundo colocado para o RN - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	1716,61	ETS	2136,79	24,48
BR0266820U0118	69,07	SES	82,13	18,91
BR0267894U0041	1103,20	SNAIVE	2250,00	103,95
BR0267895U0041	2262,40	HOLT_LINEAR	3008,13	32,96
BR0267896U0041	109,91	HOLT_LINEAR	112,35	2,22
BR0267897U0041	174,44	ARIMA	192,18	10,17
BR0268097U0041	93,95	ETS	195,78	108,39
BR0268143U0042	435,09	ARIMA	1266,28	191,04
BR0272785U0042	623,11	HOLT_DAMPED	1382,09	121,81
BR0272786U0042	1114,43	NAIVE	1135,00	1,85
BR0277434U0135	15,88	HOLT_LINEAR	18,65	17,44
BR0277438U0118	20,79	ETS	22,67	9,04
BR0285817U0046	167,20	HOLT_DAMPED	591,13	253,55
BR0285818U0046	58,52	SNAIVE	127,50	117,87
BR0288640U0042	250,72	ETS	346,73	38,29
BR0315088U0042	94,25	HOLT_WINTERS	102,69	8,95
BR0342746U0118	26,25	HOLT_WINTERS	47,58	81,26
BR0343607U0118	30,23	HOLT_LINEAR	56,50	86,90
BR0343608U0118	124,90	SES	182,00	45,72

Tabela 3.35: Comparação entre os erros do modelo LSTM e do segundo colocado para o RN - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0267895U0041	1344,40	HOLT_WINTERS	2338,52	73,95
BR0268118U0135	21,07	SNAIVE	48,25	129,00
BR0272083U0042	29576,04	NAIVE	31619,25	6,91
BR0272786U0042	1869,05	HOLT_DAMPED	1889,94	1,12
BR0277434U0135	31,56	HOLT_WINTERS	33,38	5,77
BR0277743U0118	6,27	NAIVE	6,50	3,67
BR0285818U0046	43,85	NAIVE	52,50	19,73
BR0288640U0042	141,17	NAIVE	157,50	11,57
BR0315088U0042	301,13	HOLT_LINEAR	322,06	6,95
BR0343607U0118	216,63	HOLT_LINEAR	218,20	0,72
BR0369176U0042	194,73	SNAIVE	202,50	3,99

Tabela 3.36: Comparação entre os erros do modelo LSTM e do segundo colocado para o RN - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266629U0118	1113,25	ARIMA	1332,80	19,72
BR0266820U0118	46,85	HOLT_LINEAR	50,12	6,98
BR0267895U0041	200,34	ARIMA	455,91	127,57
BR0267896U0041	178,57	HOLT_LINEAR	192,62	7,87
BR0267897U0041	208,36	SES	215,00	3,19
BR0268084U0042	93,09	THETA	103,12	10,77
BR0268097U0041	77,62	NAIVE	105,00	35,27
BR0268143U0042	1947,58	HOLT_WINTERS	2767,26	42,09
BR0271620U0042	20354,53	HOLT_WINTERS	25050,10	23,07
BR0272785U0042	1369,09	HOLT_DAMPED	1452,47	6,09
BR0272786U0042	809,28	ARIMA	905,18	11,85
BR0272831U0042	9977,66	NAIVE	10197,50	2,20
BR0277434U0135	24,70	HOLT_LINEAR	25,41	2,87
BR0277438U0118	10,04	SES	18,80	87,25
BR0277743U0118	15,25	HOLT_DAMPED	15,98	4,79
BR0285818U0046	30,64	NAIVE	60,00	95,82
BR0288640U0042	28,60	NAIVE	75,00	162,24
BR0315088U0042	79,31	NAIVE	82,50	4,02
BR0342746U0118	14,49	NAIVE	15,00	3,52
BR0343607U0118	264,98	HOLT_WINTERS	281,41	6,20
BR0343608U0118	268,95	SES	305,00	13,40
BR0369176U0042	237,61	ETS	241,91	1,81

PARAÍBA

Com relação ao Estado da Paraíba, a Figura 3.20 mostra que o modelo LSTM foi superior para 19, 18 e 17 medicamentos no primeiro, segundo e terceiros trimestres, respectivamente, quantidades que equivalem a 54,3%, 51,4% e 48,6% do total de medicamentos desse Estado. No agregado dos três trimestres, o LSTM foi o melhor modelo para 54 medicamentos, o que representa 51,4% de todas as previsões realizadas.

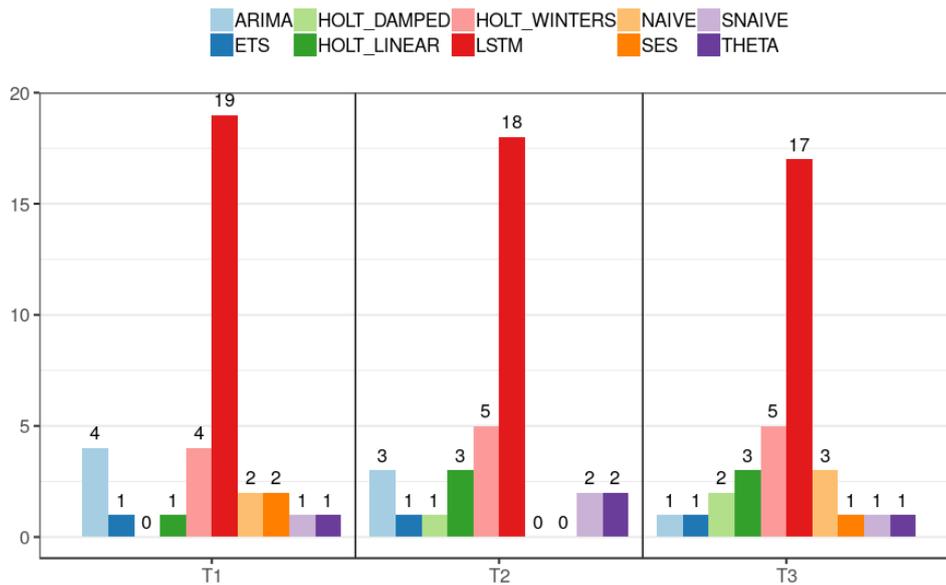


Figura 3.20: Contagem dos modelos vencedores em cada trimestre de 2018 para a PB, desconsiderando os empates.

A Tabela 3.37 apresenta a lista de modelos vencedores por medicamento e por trimestre no Estado da Paraíba e seus erros absolutos médios. Para que se tenha uma ideia da superioridade do modelo LSTM, quando este foi considerado o vencedor, em relação ao segundo melhor modelo, as Tabelas 3.38 a 3.40 apresentam as diferenças percentuais entre os erros absolutos médios nos trimestres avaliados.

Como se pode observar, há casos onde a diferença entre os erros dos dois melhores modelos é pequena, a exemplo dos medicamentos BR0268097U0041 no primeiro trimestre (0,86%), BR0268084U0042 no segundo trimestre (1,29%) e BR0268084U0042 no terceiro trimestre (1,23%), assim como, de maneira diversa, casos onde a diferença é bastante considerável, a exemplo dos medicamentos BR0288641U0042 no primeiro trimestre (1078,15%), BR0272824U0042 no segundo trimestre (106,85%) e BR0267894U0041 no terceiro trimestre (87,54%). Em média, quando considerado vencedor, o modelo LSTM foi superior ao segundo melhor modelo, em 175% (primeiro trimestre), em 32,8% (segundo trimestre) e em 23,3% (terceiro trimestre).

Tabela 3.37: Erro absoluto médio do modelo vencedor para os medicamentos da PB, por trimestre

CATMAT	T1		T2		T3	
	Modelo	EAM	Modelo	EAM	Modelo	EAM
BR0266820U0118	LSTM	29,12	HOLT_LINEAR	117,75	ETS	68,85
BR0267894U0041	HOLT_WINTERS	320,049	LSTM	1782,67	LSTM	538,54
BR0267895U0041	LSTM	812,98	LSTM	763,08	HOLT_DAMPED	208,427
BR0267896U0041	LSTM	218,44	LSTM	363,49	HOLT_LINEAR	387,5
BR0268084U0042	HOLT_WINTERS	115,713	LSTM	184,38	LSTM	124,06
BR0268097U0041	LSTM	190,45	LSTM	74,93	LSTM	344,36
BR0268098U0041	NAIVE	2237	ETS	1800,71	HOLT_WINTERS	1389,422
BR0268114U0042	LSTM	954,43	HOLT_WINTERS	1452,231	ARIMA	11655,204
BR0271620U0042	HOLT_WINTERS	1028,091	HOLT_WINTERS	1929,066	LSTM	1925,74
BR0271621U0042	THETA	2691,107	HOLT_WINTERS	4423,46	LSTM	5099,84
BR0272083U0042	ARIMA	5623,04	HOLT_LINEAR	5617,5	LSTM	7321,58
BR0272431U0042	NAIVE	513,75	LSTM	225,58	HOLT_LINEAR	775,184
BR0272785U0042	LSTM	410,36	LSTM	3463,98	LSTM	890,54
BR0272786U0042	LSTM	470,52	THETA	643,608	SNAIVE	913,75
BR0272824U0042	ARIMA	303,123	LSTM	90,16	LSTM	204,93
BR0272825U0042	ARIMA	694,762	SNAIVE	671,25	THETA	757,278
BR0272826U0042	LSTM	452,3	LSTM	428,33	HOLT_DAMPED	456,757
BR0272831U0042	LSTM	1011,87	HOLT_DAMPED	6339,423	LSTM	4599,03
BR0272832U0042	LSTM	394,52	HOLT_WINTERS	9966,369	LSTM	9526,04
BR0272833U0042	HOLT_WINTERS	458,094	LSTM	2305,65	LSTM	6875,73
BR0272835U0041	SNAIVE	287,5	THETA	74,261	NAIVE	130,25
BR0277434U0135	LSTM	33,21	LSTM	22,95	HOLT_WINTERS	22,859
BR0277435U0135	LSTM	6,47	ARIMA	2,926	NAIVE	8,75
BR0277438U0118	ARIMA	10,802	LSTM	10,21	LSTM	5,81
BR0277743U0118	LSTM	7,85	LSTM	7,48	HOLT_WINTERS	5,844
BR0285817U0046	LSTM	62,56	HOLT_LINEAR	74,676	LSTM	75,67
BR0288640U0042	LSTM	671,97	LSTM	497,69	LSTM	248,37
BR0288641U0042	LSTM	430,78	HOLT_WINTERS	283,701	HOLT_LINEAR	547,64
BR0290058U0135	SES	24,423	LSTM	31,38	LSTM	30,44
BR0292372U0118	HOLT_LINEAR	15,5	SNAIVE	18,75	HOLT_WINTERS	38,874
BR0333447U0118	SES	32,769	ARIMA	32,534	LSTM	52,09
BR0342746U0118	ETS	38,591	LSTM	54,83	HOLT_WINTERS	43,178
BR0343607U0118	LSTM	5,95	LSTM	15,57	SES	18,727
BR0343608U0118	LSTM	24,08	ARIMA	244,901	NAIVE	34,5
BR0367664U0075	LSTM	2,33	LSTM	4,73	LSTM	1,91

Tabela 3.38: Comparação entre os erros do modelo LSTM e do segundo colocado para a PB - T1 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0266820U0118	29,12	HOLT_WINTERS	62,24	113,74
BR0267895U0041	812,98	NAIVE	832,50	2,40
BR0267896U0041	218,44	HOLT_WINTERS	656,85	200,70
BR0268097U0041	190,45	ARIMA	192,08	0,86
BR0268114U0042	954,43	NAIVE	1201,50	25,89
BR0272785U0042	410,36	ARIMA	1635,38	298,52
BR0272786U0042	470,52	SNAIVE	930,00	97,65
BR0272826U0042	452,30	SNAIVE	581,25	28,51
BR0272831U0042	1011,87	SES	1872,43	85,05
BR0272832U0042	394,52	NAIVE	2572,50	552,06
BR0277434U0135	33,21	ARIMA	35,67	7,41
BR0277435U0135	6,47	ETS	18,83	191,04
BR0277743U0118	7,85	SNAIVE	11,00	40,13
BR0285817U0046	62,56	ARIMA	126,99	102,99
BR0288640U0042	671,97	HOLT_LINEAR	701,89	4,45
BR0288641U0042	430,78	SNAIVE	5075,25	1078,15
BR0343607U0118	5,95	SNAIVE	6,25	5,04
BR0343608U0118	24,08	NAIVE	117,50	387,96
BR0367664U0075	2,33	SES	4,75	103,86

Tabela 3.39: Comparação entre os erros do modelo LSTM e do segundo colocado para a PB - T2 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0267894U0041	1782,67	NAIVE	1986,50	11,43
BR0267895U0041	763,08	HOLT_DAMPED	1288,25	68,82
BR0267896U0041	363,49	SNAIVE	685,50	88,59
BR0268084U0042	184,38	HOLT_LINEAR	186,75	1,29
BR0268097U0041	74,93	SNAIVE	100,50	34,13
BR0272431U0042	225,58	THETA	315,01	39,64
BR0272785U0042	3463,98	HOLT_WINTERS	3782,22	9,19
BR0272824U0042	90,16	ETS	186,50	106,85
BR0272826U0042	428,33	HOLT_WINTERS	630,60	47,22
BR0272833U0042	2305,65	HOLT_WINTERS	2534,68	9,93
BR0277434U0135	22,95	HOLT_LINEAR	31,78	38,47
BR0277438U0118	10,21	SES	18,01	76,40
BR0277743U0118	7,48	SNAIVE	7,75	3,61
BR0288640U0042	497,69	HOLT_LINEAR	584,48	17,44
BR0290058U0135	31,38	HOLT_DAMPED	32,88	4,78
BR0342746U0118	54,83	NAIVE	56,25	2,59
BR0343607U0118	15,57	SNAIVE	16,75	7,58
BR0367664U0075	4,73	SNAIVE	5,75	21,56

Tabela 3.40: Comparação entre os erros do modelo LSTM e do segundo colocado para a PB - T3 (2018)

CATMAT	EAM _{1stm}	MOD _{2nd}	EAM _{2nd}	DIF(%)
BR0267894U0041	538,54	SNAIVE	1010,00	87,54
BR0268084U0042	124,06	THETA	125,59	1,23
BR0268097U0041	344,36	HOLT_DAMPED	383,41	11,34
BR0271620U0042	1925,74	HOLT_WINTERS	2284,57	18,63
BR0271621U0042	5099,84	ARIMA	5435,10	6,57
BR0272083U0042	7321,58	HOLT_LINEAR	13029,57	77,96
BR0272785U0042	890,54	SNAIVE	1026,25	15,24
BR0272824U0042	204,93	ARIMA	209,68	2,32
BR0272831U0042	4599,03	NAIVE	5136,50	11,69
BR0272832U0042	9526,04	SES	9992,33	4,89
BR0272833U0042	6875,73	HOLT_DAMPED	7059,01	2,67
BR0277438U0118	5,81	NAIVE	7,50	29,09
BR0285817U0046	75,67	NAIVE	91,25	20,59
BR0288640U0042	248,37	HOLT_LINEAR	276,09	11,16
BR0290058U0135	30,44	ETS	39,65	30,26
BR0333447U0118	52,09	SES	56,50	8,47
BR0367664U0075	1,91	SNAIVE	3,00	57,07

Segunda Etapa - Comparação das programações automatizadas com a demanda real

As comparações entre as programações automatizadas e a demanda real dos medicamentos foram feitas a partir de tabelas montadas com base nas previsões obtidas. Elas apresentam, para todos os medicamentos, o seu código identificador (CATMAT), a programação automatizada do melhor modelo entre os modelos ajustados na pesquisa (PATMM), a programação automatizada do modelo ARIMA-MS (PATMS) e a quantidade realmente dispensada (QRDM). Essas tabelas, para todos os Estados, trimestres avaliados e medicamentos, estão listadas no Apêndice A (Tabelas Tabelas A.1 a A.27).

Os valores das programações PATMM e PATMS foram calculados utilizando a abordagem de previsão utilizada pelo Ministério da Saúde (ver Figura 3.3), expressa na forma das Equações 3.5 a 3.6. Essas quantidades podem assumir valores positivos ou negativos, a depender do valor da previsão agregada em relação ao estoque do medicamento. Caso o valor da previsão agregada seja inferior ao valor do estoque do medicamento, o valor da programação será negativo. Caso contrário, o valor será positivo. Caso ambos os valores de programação (PATMM e PATMS) sejam negativos, eles serão descartados na análise, já que, nesse caso, não há remessa de medicamentos aos Estados.

Feita essa seleção inicial, subtrai-se dos valores das programações PATMM e PATMS a quantidade realmente consumida dos medicamentos (QRDM), gerando, respectivamente,

as métricas MMvQRDM e MSvQRDM, as quais medem o quanto as programações dos dois modelos se afastam da demanda real. Os valores de MMvQRDM e MSvQRDM são calculadas da seguinte maneira:

$$MMvQRDM = PATMM - QRDM \quad (3.7)$$

$$MSvQRDM = PATMS - QRDM \quad (3.8)$$

Caso os valores de MMvQRDM e MSvQRDM sejam positivos, o menor valor (e o modelo associado) será considerado o melhor, já que, quanto mais próximo da demanda real estiver a programação, melhor o modelo. Tendo os valores de MMvQRDM e MSvQRDM sinais opostos, ou seja, um positivo e outro negativo, foi considerado como melhor o valor positivo (e o respectivo modelo), já que, do ponto de vista do negócio, o desabastecimento, ou seja, o envio abaixo da demanda, é uma situação que deve ser evitada.

Esta Seção compara, portanto, o modelo vencedor para cada um dos medicamentos e o modelo atualmente utilizado pelo Ministério da Saúde. Como são avaliados tanto o modelo atualmente em uso pelo Ministério, assim como outros modelos, é importante destacar que qualquer resultado obtido é, no pior caso, tão bom quanto o que há hoje disponível, ou seja, qualquer variação encontrada em termos da diminuição dos erros entre as programações automatizadas e a demanda real já pode ser considerada um benefício.

Quando utilizados, os preços dos medicamentos foram, de forma conservadora, aqueles obtidos do menor valor de média ponderada de compras realizadas por órgãos públicos entre 1/1/2015 e 9/5/2019, obtida em consulta ao Banco de Preços em Saúde (BPS), disponibilizado pelo Ministério da Saúde³. Quando não disponível no BPS, utilizou-se o Preço Máximo de Venda ao Governo (PMVG) sem imposto, disponibilizado pela Câmara de Regulação do Mercado de Medicamentos (CMED) no sítio da Agência Nacional de Vigilância Sanitária⁴.

A seguir, são apresentados os resultados das comparações entre as programações dos modelos e a demanda real dos medicamentos, para todos os Estados selecionados.

DISTRITO FEDERAL

Avaliando os casos onde ambas as programações superaram a demanda, o modelo da pesquisa foi melhor, no DF, para 5 medicamentos no primeiro trimestre, 5 medicamentos no segundo e 6 medicamentos no terceiro, o que levaria a uma distribuição, pelo modelo atualmente utilizado no Ministério da Saúde, de 30.377 unidades acima da demanda real,

³<http://portalms.saude.gov.br/gestao-do-sus/economia-da-saude/banco-de-precos-em-saude>

⁴<http://portal.anvisa.gov.br/cmed>

considerando o agregado dos três trimestres. Esses casos são apresentados nas Tabelas 3.41 a 3.43.

Para monetizar essa distribuição acima da real necessidade, multiplicou-se o preço de cada um desses medicamentos pela diferença entre valores de MMvQRDM e MSvQRDM, obtendo-se uma economia potencial de um montante em torno de R\$ 3.708.876,79 (soma dos totais das Tabelas 3.41 a 3.43). É fundamental deixar claro que esse montante representa uma economia potencial, já que nem sempre uma distribuição acima da demanda resultará, necessariamente, em desperdício de recursos financeiros, por exemplo, pela perda de validade daqueles medicamentos.

Tabela 3.41: Comparação entre os modelos para programações acima da demanda no Distrito Federal - T1 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0272786U0042	2.301	2.397	0,41	39,52
BR0277743U0118	145	254	510,54	55.648,86
BR0288640U0042	2.477	3.255	3,49	2.715,22
BR0315088U0042	11.224	11.975	21,23	15.942,38
BR0325836U0042	220	967	34,84	26.023,31
			TOTAL	100.369,30

Tabela 3.42: Comparação entre os modelos para programações acima da demanda no Distrito Federal - T2 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0266820U0118	420	874	744,43	337.971,22
BR0268098U0041	17.673	22.745	2,26	11.444,968
BR0272824U0042	151	1.381	0,37	460,88
BR0315088U0042	4.749	9.890	21,23	109.134,18
BR0325836U0042	439	1.170	34,84	25.465,92
			TOTAL	484.477,17

Tabela 3.43: Comparação entre os modelos para programações acima da demanda no Distrito Federal - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0268118U0135	281	292	313,99	3.453,89
BR0268143U0042	1451	4162	2,90	7.861,90
BR0272833U0042	9020	19187	0,75	7.633,38
BR0285817U0046	552	1535	20,11	19.767,44
BR0285818U0046	275	1167	39,92	35.604,72
BR0343607U0118	110	1345	2.469,40	3.049.709,00
			TOTAL	3.124.030,33

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para 3 medicamentos no segundo trimestre. Havendo casos em mais de um trimestre, essa análise agrupou os dados, de modo a facilitar a visualização agregada dos resultados. Desse modo, caso o medicamento tenha se repetido em mais de um trimestre, as quantidades foram somadas. Para o Distrito Federal, a utilização do modelo da pesquisa evitaria um desabastecimento de 5.672 unidades durante os três primeiros trimestres de 2018, como se percebe a partir do exame da Tabela 3.44.

Tabela 3.44: Medicamentos para os quais se evitaria o desabastecimento no Distrito Federal, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

Medicamento	MMvQRDM	MSvQRDM
QUETIAPINA 200 MG COMP	3.924	-4.934
ADALIMUMABE 40 MG/ML SOL INJ (SER PREENC)	440	-2
ZIPRASIDONA 80 MG CAP	458	-736
	TOTAL	-5.672

Esse é um resultado relevante, pois, do ponto de vista do negócio, o Ministério da Saúde informou que o desabastecimento é muito mais grave do que a distribuição acima da demanda. Isso porque a falta de algum desses medicamentos pode ser fatal para o paciente. O medicamento QUETIAPINA, por exemplo, é indicado para o tratamento da esquizofrenia, como monoterapia ou adjuvante no tratamento dos episódios de mania associados ao transtorno afetivo bipolar, dos episódios de depressão associados ao transtorno afetivo bipolar, no tratamento de manutenção do transtorno afetivo bipolar I (episódios maníaco, misto ou depressivo) em combinação com os estabilizadores de humor lítio ou valproato, e como monoterapia no tratamento de manutenção no transtorno afetivo bipolar (episódios

de mania, mistos e depressivos)⁵. Outros medicamentos que não atenderiam a demanda são indicados para a esquizofrenia, transtornos esquizoafetivo e esquizofreniforme⁶ (ZIPRASIDONA) e artrite reumatóide grave, ativa e progressiva⁷(ADALIMUMABE).

CEARÁ

Comparando as programações acima da demanda no Estado do Ceará, o modelo da pesquisa foi melhor para um total de 13 medicamentos, considerando o agregado dos três trimestres. Nesse período, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 828.096 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 8.172.309,03 ao se utilizar o modelo da pesquisa. Esses casos estão listados nas Tabelas 3.45 a 3.47.

Tabela 3.45: Comparação entre os modelos para programações acima da demanda no CE - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL(R\$)
BR0343608U0118	559	2.705	1.206,18	2.588.471,08
			TOTAL	2.588.471,08

Tabela 3.46: Comparação entre os modelos para programações acima da demanda no CE - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL(R\$)
BR0268098U0041	49.722	123.052	2,26	165.725,80
BR0272786U0042	8.213	37.323	0,41	11.984,59
BR0272833U0042	15.722	161.090	0,75	109.142,29
BR0315088U0042	885	1.194	21,23	6.559,51
BR0343608U0118	1.705	5.258	1.206,18	4.285.572,11
			TOTAL	4.578.984,30

⁵<https://consultaremedios.com.br/hemifumarato-de-quetiapina>

⁶<https://consultaremedios.com.br/hemifumarato-de-quetiapina/bula>

⁷<https://consultaremedios.com.br/adalimumabe/bula/para-que-serve>

Tabela 3.47: Comparação entre os modelos para programações acima da demanda no CE - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL(R\$)
BR0266820U0118	224	254	744,43	22.332,90
BR0267894U0041	1.211	15.056	3,27	45.302,22
BR0268098U0041	29.977	107.888	2,26	175.806,17
BR0268114U0042	19.663	146.746	4,32	548.769,81
BR0272826U0042	1.213	32.607	0,98	30.766,12
BR0272832U0042	72.925	395.599	0,48	153.366,95
BR0315088U0042	1.328	2.671	21,23	28.509,47
			TOTAL	1.004.853,65

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para apenas 1 medicamento no agregado dos três trimestres (ver Tabela 3.48). Apesar disso, isso significa que a utilização do modelo da pesquisa evitaria um desabastecimento de 181.749 unidades do medicamento TACROLIMO, considerado um medicamento de extrema relevância para pacientes submetidos à transplantes alogênicos de fígado e rins, sendo indicado para a profilaxia da rejeição dos órgãos⁸.

Tabela 3.48: Medicamentos para os quais se evitaria o desabastecimento no Ceará, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

Medicamento	MMvQRDM	MSvQRDM
TACROLIMO 1 MG CAP	5.852	-181.749
	TOTAL	-181.749

PERNAMBUCO

Comparando as programações acima da demanda no Estado de Pernambuco, o modelo da pesquisa foi melhor para 35 medicamentos, considerando o agregado dos três trimestres. Nesse período, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 797.290 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 7.780.991,03 ao se utilizar o modelo da pesquisa. Esses casos estão listados nas Tabelas 3.49 a 3.51.

⁸<https://consultaremedios.com.br/tacrolimo/bula>

Tabela 3.49: Comparação entre os modelos para programações acima da demanda em PE
- T1 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0333447U0118	393	619	1.976,04	446.585,04
			TOTAL	446.585,04

Tabela 3.50: Comparação entre os modelos para programações acima da demanda em PE
- T2 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0266628U0118	20	146	66,16	8.336,16
BR0267895U0041	12.759	14.115	2,09	2.834,04
BR0267896U0041	2.214	3.565	1,69	2.283,19
BR0267897U0041	1.433	2.051	2,80	1.730,40
BR0268084U0042	4.215	5.335	5,19	5.812,80
BR0268097U0041	13.759	15.041	11,68	14.973,76
BR0268114U0042	8.985	35.022	4,32	112.479,84
BR0268143U0042	1.869	17.808	2,90	46.223,10
BR0271620U0042	23.456	62.045	0,90	34.730,10
BR0271621U0042	64.413	73.341	0,53	4.731,84
BR0272083U0042	437.748	987.008	2,99	1.642.287,40
BR0272786U0042	3.024	22.523	0,41	7.994,59
BR0272825U0042	2.964	36.832	0,57	19.304,76
BR0272826U0042	37.489	40.018	0,98	2.478,42
BR0277434U0135	818	1.028	580,83	121.974,30
BR0288640U0042	4.190	28.838	3,49	86.021,52
BR0288641U0042	126.458	129.307	5,00	14.245,00
BR0290058U0135	456	1.024	2.359,94	1.340.445,92
BR0333447U0118	240	406	1.976,04	328.022,64
BR0343608U0118	2.063	4.118	1.206,18	2.478.699,90
BR0369176U0042	3.585	18.667	11,22	169.220,04
BR0369179U0042	1.385	14.368	24,46	317.564,18
			TOTAL	6.762.393,90

Tabela 3.51: Comparação entre os modelos para programações acima da demanda em PE
- T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0267895U0041	7.101	8.921	2,09	3.803,80
BR0268084U0042	4.671	6.457	5,19	9.269,34
BR0268097U0041	15.420	20.944	11,68	64.520,32
BR0268114U0042	37.360	50.454	4,32	56.566,08
BR0271621U0042	73.377	74.503	0,53	596,78
BR0272826U0042	44.834	49.794	0,98	4.860,80
BR0277434U0135	951	1.116	580,83	95.836,95
BR0277743U0118	226	509	510,54	144.482,82
BR0288641U0042	58.019	61.196	5,00	15.885,00
BR0290058U0135	1.040	1.065	2.359,94	58.998,50
BR0369176U0042	12.372	14.681	11,22	25.906,98
BR0369179U0042	8.817	12.549	24,46	91.284,72
			TOTAL	572.012,09

Tabela 3.52: Medicamentos para os quais se evitaria o desabastecimento em Pernambuco,
caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

Medicamento	MMvQRDM	MSvQRDM
RIVASTIGMINA 6 MG CAP	1.266	-30.810
RIVASTIGMINA 1,5 MG CAP	1.106	-12.196
CABERGOLINA 0,5 MG COMP	6.125	-6.953
TACROLIMO 5 MG CAP	5.489	-59.422
LEFLUNOMIDA 20 MG COMP	31.835	-48.700
OLANZAPINA 5 MG COMP	28.683	-191.828
OLANZAPINA 10 MG COMP	78.408	-241.807
SEVELAMER 800 MG COMP	253.075	-1.425.110
DONEPEZILA 10 MG COMP	4.968	-34.972
PRAMIPEXOL 0,25 MG COMP	39.022	-113.781
PRAMIPEXOL 1 MG COMP	4.493	-118.299
BETAINTERFERONA 1A 12.000.000UI (44MCG)	837	-1.872
BETAINTERFERONA 1A 6.000.000 UI (30MCG) PÓ LIOF INJ	352	-803
SIROLIMO 1 MG DRÁGEA	3.571	-4.999
MICOFENOLATO DE SÓDIO 180 MG COMP	13.487	-6.443
MICOFENOLATO DE SÓDIO 360 MG COMP	102.988	-313.515
ADALIMUMABE 40 MG/ML SOL INJ	1.208	-3.707
ETANERCEPTE 50 MG PÓ LIOF INJ	1.340	-7.263
EVEROLIMO 0,5 MG COMP	3.062	-13.327
EVEROLIMO 1 MG COMP	6.729	-54.820
TOTAL		-2.690.627

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para 20 medicamentos no agregado dos três trimestres, conforme apresenta a Tabela 3.52. Isso significa que a utilização do modelo da pesquisa evitaria um desabastecimento de 2.690.627 unidades de diversos medicamentos, a exemplo da BETAINTERFERONA 1A, indicada para o tratamento da esclerose múltipla caracterizada pela presença de surtos, cujo efeito tem eficácia na redução do número e gravidade destes casos, assim como na estabilização da progressão da doença⁹, além de outros medicamentos importantes, como o MICOFENOLATO DE SÓDIO, TACROLIMO e EVEROLIMO, utilizados para o tratamento da rejeição em transplantes de órgãos. Merece destaque, entre os medicamentos que não atenderiam a demanda o medicamento SEVELAMER, utilizado no tratamento da Hiperfosfatemia na Insuficiência Renal Crônica¹⁰, cuja indisponibilidade ultrapassou a quantidade de 1 milhão de unidades.

ALAGOAS

Comparando as programações acima da demanda no Estado de Alagoas, o modelo da pesquisa foi melhor para 25 medicamentos, considerando o agregado dos três trimestres. Nesse período, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 94.549 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 1.164.894,16 ao se utilizar o modelo da pesquisa. Esses casos estão listados nas Tabelas 3.53 a 3.55.

Tabela 3.53: Comparação entre os modelos para programações acima da demanda em AL - T1 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0266820U0118	175	282	744,43	79.654,01
BR0267894U0041	86	192	3,27	346,84
BR0272786U0042	147	4.566	0,41	1.819,30
BR0272826U0042	3.743	9.082	0,98	5.232,22
BR0272835U0041	1.019	2.190	5,88	6.885,48
BR0288641U0042	10.248	36.154	5,00	129.530,00
BR0315088U0042	3.703	6.378	21,23	56.790,25
BR0342746U0118	46	360	89,84	28.209,76
			TOTAL	308.467,86

⁹<https://consultaremedios.com.br/betainterferona-1a/bula>

¹⁰<http://portalarquivos2.saude.gov.br/images/pdf/2016/janeiro/07/sevel--mer.pdf>

Tabela 3.54: Comparação entre os modelos para programações acima da demanda em AL - T2 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0268097U0041	82	2.216	11,68	24.925,12
BR0268098U0041	4.305	18.702	2,26	32.486,83
BR0268825U0042	1.850	1.919	17,45	1.203,75
BR0271620U0042	6.599	7.097	0,90	448,20
BR0272785U0042	4.721	10.546	0,21	1.223,25
BR0272831U0042	14.714	28.676	0,20	2.742,14
BR0272835U0041	2.602	3.931	5,88	7.814,52
BR0277743U0118	194	446	510,54	128.656,08
BR0288641U0042	282	6.408	5,00	30.630,00
BR0292372U0118	124	185	454,59	27.730,16
BR0333447U0118	14	28	1.976,04	27.664,56
BR0343608U0118	766	1.174	1.206,18	492.121,44
			TOTAL	777.646,04

Tabela 3.55: Comparação entre os modelos para programações acima da demanda em AL - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0268114U0042	2.959	9.216	4,32	27.030,24
BR0272786U0042	3.679	5.135	0,41	596,96
BR0272826U0042	7.554	7.836	0,98	276,36
BR0272835U0041	3.247	4.656	5,88	8.284,92
BR0277438U0118	8	41	1.290,66	42.591,78
			TOTAL	78.780,26

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para 7 medicamentos, no agregado dos três trimestres de 2018 (ver Tabela 3.56). Os dados mostram que a utilização do modelo da pesquisa evitaria um desabastecimento de 4.195 unidades desses medicamentos, a exemplo da BETAINTERFERONA 1A, cuja importância no tratamento da esclerose múltipla já foi comentado anteriormente e da LEFLUNOMIDA, indicada para o tratamento da artrite reumatóide ativa (inflamação crônica das articulações), reduzindo os sinais e sintomas, inibindo a destruição das articulações e melhorando as funções físicas e de saúde relacionadas à qualidade devida e também da artrite psoriática ativa (doença inflamatória que afeta uma parte dos pacientes que sofrem de psoríase crônica na pele)¹¹.

¹¹<https://consultaremedios.com.br/leflunomida/bula>

Tabela 3.56: Medicamentos para os quais se evitaria o desabastecimento em Alagoas, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

Medicamento	MMvQRDM	MSvQRDM
BETAINTERFERONA 1B 9.600.000UI (300MG) PÓ LIOF INJ	138	-98
BETAINTERFERONA 1A 6.000.000 UI (30MCG) PÓ LIOF INJ	6	-194
LEFLUNOMIDA 20 MG COMP	302	-1.448
DONEPEZILA 10 MG COMP	784	-346
ADALIMUMABE 40 MG/ML SOL INJ	15	-38
ENTECAVIR 0,5 MG COMP	396	-1.814
RIVASTIGMINA 1,5 MG CAP	252	-257
TOTAL		-4.195

AMAPÁ

Em relação às programações acima da demanda, só houve 1 caso onde o modelo da pesquisa foi superior ao atual modelo do Ministério da Saúde, que aconteceu no terceiro trimestre de 2018. Nesse caso, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 560 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 1.263,64 ao se utilizar o modelo da pesquisa (ver Tabela 3.57). Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa não superou o atual modelo do Ministério da Saúde para nenhum medicamento.

Tabela 3.57: Comparação entre os modelos para programações acima da demanda no AP - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0268098U0041	2.084	2.644	2,26	1.263,64
			TOTAL	1.263,64

TOCANTINS

Comparando as programações acima da demanda no Estado de Tocantins, o modelo da pesquisa foi melhor para 11 medicamentos, considerando o agregado dos três trimestres. Nesse período, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 11.489 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 417.410,71 ao se utilizar o modelo da pesquisa. Esses casos estão listados nas Tabelas 3.58 a 3.59.

Tabela 3.58: Comparação entre os modelos para programações acima da demanda em TO - T2 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0271620U0042	1.772	3.239	0,9	1.320,30
BR0272833U0042	2.186	2.477	0,75	218,48
BR0343607U0118	40	44	2.469,40	9.877,60
BR0343608U0118	79	397	1.206,18	383.566,54
			TOTAL	394.982,93

Tabela 3.59: Comparação entre os modelos para programações acima da demanda em TO - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0267894U0041	3.001	3.106	3,27	343,57
BR0268114U0042	2.975	5.965	4,32	12.911,42
BR0271620U0042	3.688	4.586	0,90	808,20
BR0272431U0042	5.998	6.678	1,98	1.348,44
BR0272825U0042	471	3.191	0,57	1.550,40
BR0272833U0042	4.903	6.726	0,75	1.368,71
BR0315088U0042	13	206	21,23	4.097,04
			TOTAL	22.427,78

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para 11 medicamentos no agregado dos três trimestres, como mostra a Tabela 3.60. A utilização do modelo da pesquisa evitaria um desabastecimento de 64.068 unidades desses medicamentos, a exemplo do ETANERCEPTE, indicado para redução dos sinais e sintomas e inibição da progressão do dano estrutural em pacientes com artrite reumatoide ativa moderada a grave¹², do TENOFOVIR, para o tratamento de pessoas com infecção pelo HIV-1¹³ e da OLANZAPINA, indicada para o tratamento agudo e de manutenção da esquizofrenia e outros transtornos mentais (psicoses), nos quais sintomas positivos (exemplo: delírios, alucinações, alterações de pensamento, hostilidade e desconfiança) e/ou sintomas negativos (exemplo: afeto diminuído, isolamento emocional/social e pobreza de linguagem) são proeminentes¹⁴.

¹²<https://consultaremedios.com.br/etanercepte/pa>

¹³<http://portalarquivos2.saude.gov.br/images/pdf/2014/setembro/17/Tenofovir.pdf>

¹⁴<https://consultaremedios.com.br/olanzapina/bula>

Tabela 3.60: Medicamentos para os quais se evitaria o desabastecimento em Tocantins, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

Medicamento	MMvQRDM	MSvQRDM
RIVASTIGMINA 3 MG CAP	2.554	-3.535
RIVASTIGMINA 6 MG CAP	1.664	-26
MICOFENOLATO DE MOFETILA 500 MG COMP	118	-3.333
TENOFOVIR 300 MG COMP	140	-6.546
OLANZAPINA 5 MG COMP	1.089	-16.296
OLANZAPINA 10 MG COMP	2.795	-13.645
PRAMIPEXOL 1 MG COMP	3.346	-9.732
ENTECAVIR 0,5 MG COMP	617	-2.665
ETANERCEPTE 50 MG PÓ LIOF INJ	100	-757
SEVELAMER 800 MG COMP	388	-7.216
TACROLIMO 1 MG CAP	579	-317
TOTAL		-64.068

PARÁ

Comparando as programações acima da demanda no Estado do Pará, o modelo da pesquisa foi melhor para 15 medicamentos, considerando o agregado dos três trimestres. Nesse período, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 63.257 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 3.376.659,91 ao se utilizar o modelo da pesquisa. Esses casos estão listados nas Tabelas 3.61 a 3.62.

Tabela 3.61: Comparação entre os modelos para programações acima da demanda no PA - T2 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0268825U0042	2.943	3.947	17,45	17.515,38
BR0288640U0042	11.830	12.762	3,49	3.252,68
BR0343608U0118	668	2.074	1.206,18	1.695.894,84
BR0369176U0042	1.379	3.652	11,22	25.503,06
TOTAL				1.742.165,97

Tabela 3.62: Comparação entre os modelos para programações acima da demanda no PA - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0268084U0042	832	1.853	5,19	5.298,99
BR0268098U0041	1.816	18.480	2,26	37.660,64
BR0268114U0042	15.033	35.387	4,32	87.929,28
BR0272826U0042	6.481	8.493	0,98	1.971,76
BR0272832U0042	7.868	17.393	0,48	4.527,23
BR0272833U0042	5.606	12.003	0,75	4.802,87
BR0277438U0118	92	245	1.290,66	197.470,98
BR0285818U0046	55	306	39,92	10.019,92
BR0290058U0135	221	672	2.359,94	1.064.332,94
BR0315088U0042	649	1.380	21,23	15.519,13
BR0343607U0118	389	472	2.469,40	204.960,20
			TOTAL	1.634.493,94

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para 3 medicamentos no agregado dos três trimestres, como mostra a Tabela 3.63. A utilização do modelo da pesquisa evitaria um desabastecimento de 18.817 unidades desses medicamentos, a exemplo do ENTECAVIR, utilizado para o tratamento de adultos com infecção crônica pelo vírus da hepatite B (VHB)¹⁵.

Tabela 3.63: Medicamentos para os quais se evitaria o desabastecimento no Pará, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

Medicamento	MMvQRDM	MSvQRDM
TENOFOVIR 300 MG COMP	4.332	-6.010
ENTECAVIR 0,5 MG COMP	455	-12.412
QUETIAPINA 25 MG COMP	124	-395
TOTAL		-18.817

RIO GRANDE DO NORTE

Comparando as programações acima da demanda no Estado do Rio Grande do Norte, o modelo da pesquisa foi melhor para 12 medicamentos, considerando o agregado dos três trimestres. Nesse período, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 69.636 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 1.550.278,47 ao se utilizar o modelo da pesquisa. Esses casos estão listados nas Tabelas 3.64 a 3.65.

¹⁵<https://consultaremedios.com.br/entecavir/pa>

Tabela 3.64: Comparação entre os modelos para programações acima da demanda no Rio Grande do Norte - T2 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0266629U0118	10.301	17.509	134,18	967.169,44
BR0267895U0041	2.006	11.158	2,09	19.127,68
BR0271621U0042	11.329	14.319	0,53	1.584,70
BR0272786U0042	1.250	13.761	0,41	5.129,51
BR0272833U0042	9.914	20.292	0,75	7.791,80
BR0315088U0042	579	1.197	21,23	13.119,03
BR0333447U0118	131	253	1.976,04	241.076,88
BR0343608U0118	2.726	2.849	1.206,18	148.360,64
			TOTAL	1.403.359,68

Tabela 3.65: Comparação entre os modelos para programações acima da demanda no Rio Grande do Norte - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0267894U0041	1.474	11.281	3,27	32.089,48
BR0267897U0041	996	2.194	2,80	3.354,40
BR0272833U0042	6.112	17.431	0,75	8.498,31
BR0369179U0042	221	4.431	24,46	102.976,60
			TOTAL	146.918,79

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para 11 medicamentos no agregado dos três trimestres, como mostra a Tabela 3.66. A utilização do modelo da pesquisa, portanto, evitaria um desabastecimento de 956.647 unidades desses medicamentos.

Tabela 3.66: Medicamentos para os quais se evitaria o desabastecimento no Rio Grande do Norte, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

	Medicamento	MMvQRDM	MSvQRDM
	IMUNOGLOBULINA HUMANA 5 G INJ (FR)	235	-591
	RIVASTIGMINA 6 MG CAP	8.133	-14.773
	TACROLIMO 5 MG CAP	619	-3.668
	TACROLIMO 1 MG CAP	13.756	-207.097
	OLANZAPINA 10 MG COMP	7.462	-407.214
	SEVELAMER 800 MG COMP	341.482	-317.561
	BETAINTERFERONA 1B 9.600.000UI (300MG) PÓ LIOF INJ	33	-590
	BETAINTERFERONA 1A 6.000.000 UI (30MCG) PÓ LIOF INJ	214	-78
	SIROLIMO 2 MG DRÁGEA	281	-978
	ENTECAVIR 0,5 MG COMP	1.043	-2.943
	EVEROLIMO 1 MG COMP	856	-1.154
	TOTAL		-956.647

PARAÍBA

Comparando as programações acima da demanda no Estado da Paraíba, o modelo da pesquisa foi melhor para 19 medicamentos, considerando o agregado dos três trimestres. Nesse período, a utilização do atual modelo do Ministério da Saúde levaria a uma distribuição de 79.258 unidades acima da demanda real, quando comparado com o modelo da pesquisa. A economia potencial, nesse caso, seria de R\$ 593.174,23 ao se utilizar o modelo da pesquisa. Esses casos estão listados nas Tabelas 3.67 a 3.65.

Tabela 3.67: Comparação entre os modelos para programações acima da demanda na Paraíba - T2 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0267895U0041	1.585	7.656	2,09	12.688,39
BR0268097U0041	91	3.231	11,68	36.675,20
BR0271621U0042	27.986	31.183	0,53	1.694,41
BR0272083U0042	6.112	13.533	2,99	22.188,79
BR0272431U0042	1.736	9.517	1,98	15.406,38
BR0272825U0042	6.504	7.100	0,57	339,72
BR0288641U0042	4.234	5.811	5,00	7.885,00
BR0333447U0118	153	170	1.976,04	33.592,68
BR0343608U0118	911	1.016	1.206,18	126.648,90
BR0367664U0075	12	51	3.351,95	130.726,05
			TOTAL	387.845,52

Tabela 3.68: Comparação entre os modelos para programações acima da demanda na Paraíba - T3 (2018)

CATMAT	MMvQRDM	MSvQRDM	PREÇO (R\$)	ECONOMIA POTENCIAL (R\$)
BR0268098U0041	23.615	28.752	2,26	11.609,62
BR0268114U0042	42.398	49.818	4,32	32.054,40
BR0272832U0042	1.751	19.696	0,48	8.613,60
BR0272833U0042	8.173	26.701	0,75	13.896,00
BR0277434U0135	92	195	580,83	59.825,49
BR0277743U0118	61	84	510,54	11.742,42
BR0292372U0118	19	61	454,59	19.092,78
BR0342746U0118	126	226	89,84	8.984,00
BR0343607U0118	37	53	2.469,40	39.510,40
			TOTAL	205.328,71

Quando avaliados os casos onde as programações ficam abaixo da demanda, o modelo da pesquisa foi melhor para 8 medicamentos no agregado dos três trimestres, como mostra a Tabela 3.69. A utilização do modelo da pesquisa evitaria um desabastecimento de 225.389 unidades desses medicamentos, a exemplo do NATALIZUMABE, utilizado para o tratamento da esclerose múltipla (EM), que é uma doença autoimune, desmielinizante, crônica do sistema nervoso central, comum em adultos jovens, predominantemente mulheres, com evolução progressiva e imprevisível¹⁶.

Tabela 3.69: Medicamentos para os quais se evitaria o desabastecimento na Paraíba, caso utilizado o modelo da pesquisa (agregando os 3 primeiros trimestres de 2018)

Medicamento	MMvQRDM	MSvQRDM
TACROLIMO 1 MG CAP	12.383	-163.989
DONEPEZILA 10 MG COMP	1.106	-52.710
RIBAVIRINA 250 MG CAP	1.828	-6.401
BETAINTERFERONA 1A 6.000.000 UI (22MCG) SOL INJ	67	-239
BETAINTERFERONA 1A 6.000.000 UI (30MCG) PÓ LIOF INJ	70	-66
MICOFENOLATO DE SÓDIO 180 MG COMP	783	-1.451
NATALIZUMABE 300 MG SOL INJ (FR-AMP)	1	-119
SIROLIMO 1 MG DRÁGEA	233	-414
TOTAL		-225.389

Exame agregado para todas as Unidades da Federação

Como se depreende dos resultados apresentados na Seção 3.5.5, a rede neural LSTM foi considerada o modelo vencedor (menor erro absoluto médio) para um percentual conside-

¹⁶<http://portalarquivos2.saude.gov.br/images/pdf/2014/fevereiro/03/Relatorio-Natalizumabe-CP19.pdf>

rável de medicamentos, conforme se observa pelo conteúdo da Tabela 3.70, ao passo que o ARIMA, que é o modelo atualmente utilizado pelo Ministério da Saúde, foi considerado o vencedor para percentuais significativamente menores, o que denota a necessidade de que seja avaliada a revisão do modelo ARIMA como o único modelo de previsão da programação de medicamentos do CEAF.

Tabela 3.70: Percentual dos modelos LSTM e ARIMA, quando considerados vencedores, por trimestre de 2018 e por Estado

UF	T1		T2		T3	
	LSTM	ARIMA	LSTM	ARIMA	LSTM	ARIMA
DF	46,7	0,0	43,3	16,7	63,3	0,0
CE	64,8	0,0	51,4	2,7	48,6	2,7
PE	51,8	3,7	55,6	3,7	48,1	3,7
AL	50,0	7,9	47,4	5,3	55,2	7,9
AP	66,7	0,0	33,3	0,0	33,3	0,0
TO	59,1	13,6	77,3	4,5	40,1	13,6
PA	69,4	11,1	63,9	5,6	63,9	5,6
RN	59,4	0,0	34,4	3,1	68,8	9,4
PB	54,3	11,4	51,4	8,6	48,6	2,9

Quando a rede LSTM foi considerada o modelo vencedor, o ganho, em termos de redução do erro de previsão, pode ser considerado bastante significativo, conforme se observa na Tabela 3.71, que apresenta, apenas para o último trimestre avaliado (terceiro trimestre de 2018), algumas estatísticas a respeito da distribuição desse ganho, para cada um dos Estados que fizeram parte da modelagem.

Tabela 3.71: Estatísticas da distribuição da redução percentual dos erros de previsão da rede LSTM, em relação ao segundo melhor modelo (T3/2018)

UF/Estatística	Min	1 Quartil	Mediana	Média	3 Quartil	Max
DF	0,84	4,08	12,81	22,63	32,23	95,02
CE	0,20	12,09	28,27	48,76	63,57	266,80
PE	2,94	11,65	34,66	72,44	99,28	222,38
AL	1,02	12,28	19,69	41,18	45,22	238,97
AP	7,79	11,87	15,95	15,95	20,02	24,10
TO	5,00	11,64	31,93	84,46	116,54	323,84
PA	1,87	12,03	26,74	43,20	39,64	287,38
RN	1,81	4,21	9,32	30,84	32,22	162,24
PB	1,23	6,57	11,69	23,34	29,09	87,54

As reduções médias foram significativas, variando de 15,95% para os medicamentos no Estado do Amapá até 84,46% para os medicamentos no Estado de Tocantins. Quando se

observa o 1º Quartil, por exemplo, percebe-se que 75% dos ganhos, qualquer que seja o Estado avaliado, foram superiores a 4%.

Passando para a comparação entre as programações automatizadas, ou seja, entre as quantidades distribuídas com as quantidades efetivamente dispensadas, que representa a demanda dos medicamentos, os resultados demonstraram-se promissores.

Quando comparadas as programações acima da demanda real dos medicamentos, descritas na Seção 3.5.5, o modelo da pesquisa levaria a uma distribuição mais próxima da demanda real, evitando o envio desnecessário de quase 2 milhões de unidades (somados diversos medicamentos), considerando todos os Estados e os trimestres avaliados (3 primeiros trimestres de 2018). Traduzindo essa distribuição acima da real necessidade em termos monetários (economia potencial), o montante atingiu algo em torno de R\$ 26 milhões, como mostra a Tabela 3.72.

Tabela 3.72: Quantidade de medicamentos além da necessidade real cuja distribuição poderia ter sido evitada (e respectiva economia potencial), caso tivesse sido utilizado o modelo da pesquisa

UF	Unidades acima da demanda	Economia Potencial (R\$)
DF	30.377	3.708.876,79
CE	828.096	8.172.309,03
PE	797.290	7.780.991,03
AL	94.549	1.164.894,16
AP	560	1.263,64
TO	11.489	417.410,71
PA	63.257	3.376.659,91
RN	69.636	1.550.278,47
PB	79.258	593.174,23
TOTAL	1.974.512	26.765.857,97

Quando comparadas as programações abaixo da demanda, os resultados da pesquisa são bastante interessantes do ponto de vista do negócio. Segundo o Ministério da Saúde, a distribuição abaixo da demanda é crítica, já que pode levar ao desabastecimento de medicamentos. Como foi mostrado ao longo da pesquisa, os medicamentos que compõe o CEAF, em especial o subgrupo 1A, servem para o tratamento de doenças crônicas, podendo a interrupção de tratamentos com tais medicamentos levar, inclusive, à morte de pacientes. Como foi mostrado na Seção 3.5.5, a utilização dos modelos implementados nesta pesquisa evitaria o desabastecimento de mais de 4 milhões de unidades dos mais variados medicamentos, como apresenta a Tabela 3.73, por Estado, quando são agregados os três trimestres avaliados.

Tabela 3.73: Desabastecimento que seria potencialmente evitado pelo uso do modelo da pesquisa

UF	Desabastecimento
DF	5.672
CE	181.749
PE	2.690.627
AL	4.195
AP	-
TO	64.068
PA	18.817
RN	956.647
PB	225.389
TOTAL	4.147.164

Embora também tenham sido identificados casos onde o modelo atualmente utilizado pelo Ministério da Saúde é superior ao modelo implementado nesta pesquisa, ou seja, evitaria desabastecimentos e/ou minimizaria a distribuição de medicamentos acima da demanda real, foram destacados apenas os casos onde o modelo de pesquisa obteve melhores resultados, a fim de mostrar que a possibilidade de treinar diferentes modelos com dados de cada medicamento, inclusive aquele atualmente em uso (ARIMA-MS), só traz ganhos de eficiência à política pública de distribuição de medicamentos do CEAF, pois possibilita ao gestor escolher o melhor modelo para cada um dos medicamentos em cada um dos Estados.

3.6 Avaliação

Nessa fase os modelos implementados devem ser avaliados do ponto de vista dos objetivos do negócio que foram definidos a priori. Aqui importa se o desenvolvimento dos modelos levou em consideração todos os objetivos do negócio que serviram de motivação para o projeto de mineração de dados.

Como foi apresentado até aqui, a pesquisa logrou êxito em atingir os objetivos propostos, já que implementou diversos modelos de previsão das séries temporais de dispensação de medicamentos do subgrupo 1A do CEAF, cujos resultados foram comparados aos resultados alcançados pelo modelo ARIMA hoje em uso pelo Ministério da Saúde.

Considerando a característica da modelagem, que se utilizou apenas dos próprios dados de dispensação dos medicamentos, não há qualquer óbice para que esses modelos possam ser utilizados também para a previsão das programações dos medicamentos do subgrupo 1B do CEAF, que, apesar de distribuídos pelas Secretarias Estaduais de Saúde, são custeados mediante a transferência de recursos federais. A apropriação desse conhecimento

por esses órgãos estaduais pode fazer parte de iniciativas de capacitação já desenvolvidas pelo Ministério da Saúde e tem o potencial de qualificar de maneira significativa a gestão da política de distribuição de medicamentos em nível local, aumentando a eficiência na alocação de recursos públicos federais.

3.7 Implantação

Nessa etapa o modelo criado e o conhecimento que ele gerou sobre os dados deve ser tornado acessível para o usuário final do projeto. No contexto específico da pesquisa apresentada, não é objetivo implantar modelos de previsão de programação dos medicamentos no ambiente do Ministério da Saúde, pois essa decisão depende de atuação do próprio Ministério.

Entretanto, o texto desta pesquisa serve como documento técnico, podendo ser utilizado como fonte de consulta para o estudo, aprofundamento, avaliação e aperfeiçoamento dos modelos apresentados. Além disso, como outra forma de contribuição tecnológica, o desenvolvimento dos modelos, na forma de *scripts* R e Python, estão disponíveis em repositório¹⁷ na Internet, caso seja de interesse do Ministério da Saúde adaptá-lo e incorporá-lo aos seus procedimentos de trabalho.

¹⁷<https://gitlab.com/renanms/sus-drugs-forecasting>

Capítulo 4

Conclusões e Trabalhos Futuros

Este capítulo apresenta as conclusões e os trabalhos futuros que se vislumbram a partir da realização desta pesquisa.

4.1 Conclusões

A comparação de algoritmos de previsão de séries temporais aplicado ao problema de pesquisa revelou que modelos alternativos podem ser utilizados com sucesso pelo Ministério da Saúde em relação aos medicamentos do Componente Especializado da Assistência Farmacêutica, em especial o subgrupo 1A, que foi objeto desta pesquisa. Como pode se perceber dos resultados apresentados na Seção 3.5.5, diversos modelos, diferentes do modelo atualmente utilizado pelo Ministério da Saúde, obtiveram melhores resultados (menor erro absoluto médio) nas previsões pontuais no horizonte de previsão utilizado.

O número de vezes em que o modelo ARIMA foi considerado vencedor foi bastante inferior quando comparados todos os modelos, com destaque para a rede neural recorrente LSTM, um modelo do estado da arte no aprendizado de sequências e cuja utilização tem obtido bons resultados na previsão de séries temporais em diversos domínios. Além disso, quando a rede LSTM foi considerada vencedora, ela obteve reduções significativas do erro absoluto médio. Esses resultados indicam a necessidade de que o Ministério reveja o modelo que atualmente utiliza para o cálculo das programações dos medicamentos.

Quando confrontadas as programações automatizadas do melhor modelo implementado nesta pesquisa, ou seja, aquele com menor erro absoluto médio de previsão, com aquelas do modelo ARIMA atualmente em uso no Ministério da Saúde, os resultados demonstraram que a utilização do modelo da pesquisa foi superior em diversos casos.

A utilização de outros modelos, como mostraram os resultados obtidos, levaria a uma economia potencial de cerca de R\$ 26 milhões. Embora esse valor possa ser considerado uma economia, ela é dita potencial, já que a distribuição a maior nem sempre representa

um desperdício – por conta, por exemplo, do vencimento do prazo de validade daqueles medicamentos –, uma vez que é possível o remanejamento de medicamentos de uma unidade da Federação para outra. Além disso, a alteração do comportamento das séries de dispensação ao longo do tempo pode resultar na obtenção de diferentes modelos de previsão considerados vencedores, de modo que as diferenças podem ser menores ou maiores, com reflexos diretos no montante da economia que foi estimada.

Por outro lado, é preciso levar em conta que o remanejamento tem custos, a exemplo de custos logísticos e até políticos, que envolvem negociações entre diferentes unidades da Federação. Caso os modelos de previsão sejam aplicados para a estimar as quantidades de medicamentos a serem adquiridas de forma centralizada, para a formação de estoques, essa economia potencial certamente se converteria em economia efetiva, já que poderia evitar a compra desnecessária de medicamentos. De qualquer maneira, os vultosos valores apresentados, que podem ser ainda maiores quando aplicados a mais Estados e a outros medicamentos, indicam uma grande oportunidade de aumento da eficiência e da economicidade da política de distribuição de medicamentos no Sistema Único de Saúde.

Também foi demonstrado que o uso de modelos alternativos evitaria, potencialmente, o desabastecimento de mais de 4 milhões de unidades dos mais variados medicamentos em todo o período examinado. Do ponto de vista do negócio, esse é um resultado bastante relevante, pois, segundo o Ministério da Saúde, a falta de medicamentos nos estoques estaduais é altamente indesejável, pois pode ter consequências graves para os pacientes em tratamento. Há que se reconhecer que os efeitos danosos decorrentes da distribuição abaixo da demanda também podem ser mitigados por meio de remanejamentos ou por solicitações de complementação realizadas pelas Secretarias Estaduais de Saúde. Todavia, há custos associados com esses trâmites adicionais, inclusive a demora para que uma nova remessa de medicamentos chegue ao Estado, que pode ter consequências indesejáveis para os pacientes e para a imagem do Governo Federal, que é o principal gestor dessa política. Além do mais, compras emergenciais que precisem ser feitas por conta de aquisições ou distribuições mal dimensionadas são, geralmente, muito mais custosas aos cofres públicos, em virtude de que os preços cobrados pelos medicamentos, nesses casos, são, via de regra, bem superiores aos preços das compras ordinárias.

Outras constatações obtidas pela pesquisa dizem respeito à qualidade dos dados, como apresentado na Seção 3.3. Como se percebe, há um enorme espaço para melhorias, a exemplo da necessidade de diminuir o número de dados faltantes, o que contribuirá com previsões mais confiáveis para um número ainda maior de medicamentos constantes da BNAFAR. A intensificação de iniciativas para qualificação e conscientização dos gestores da saúde pública nos Estados, como já têm feito o Ministério da Saúde, a exemplo da necessidade de fornecer dados com qualidade para a BNAFAR, contribuiria sobremaneira

com a qualidade das previsões e outras análises possíveis para qualificar a assistência farmacêutica no Brasil.

Considerando a modelagem proposta, que se utiliza unicamente dos dados de dispensação, os modelos implementados podem, do ponto de vista meramente técnico, ser facilmente utilizados para previsão da programação de outros medicamentos do subgrupo 1A e para os medicamentos do subgrupo 1B do CEAFF, estes últimos adquiridos e distribuídos pelas Secretarias de Saúde, mediante a transferência de recursos federais.

O uso da mineração de dados para o desenvolvimento de novos modelos de previsão, seja para outros medicamentos do subgrupo 1A, seja para medicamentos do subgrupo 1B, tem, portanto, o potencial de gerar grandes economias e assim, melhorar a eficiência da Política Nacional de Assistência Farmacêutica. Em momentos de restrição fiscal, é ainda mais premente a busca da eficiência na alocação de recursos públicos, já que esses ganhos podem se traduzir em recursos que podem ser realocados para outras prioridades dentro da Função Orçamentária Saúde ou mesmo para financiar outras políticas públicas.

4.2 Trabalhos Futuros

A partir do trabalho realizado, percebeu-se que a pesquisa científica em relação à previsão de séries temporais é muito dinâmica, de modo que novos métodos de previsão são propostos com frequência. Portanto, uma extensão natural desta pesquisa é a implementação de novos métodos, a exemplo dos métodos considerados os mais bem sucedidos na recente competição de séries temporais M4¹, cujos resultados demonstraram que a utilização de modelos híbridos e combinados é promissora na tarefa de previsão [43].

Em relação aos modelos neurais, as redes recorrentes LSTM são consideradas o estado da arte para o aprendizado de sequências e têm sido bastante utilizadas na previsão de séries temporais, de modo que a investigação de outras arquiteturas dessas redes, assim como a utilização de mais camadas na arquitetura codificador-decodificador que foi proposta e o uso de outras técnicas de regularização podem melhorar o desempenho do modelo proposto, quando aplicado nos dados desta pesquisa.

Além disso, a possibilidade de realizar uma busca exaustiva dos hiperparâmetros, com o uso da busca em grid, em ambiente computacional com mais recursos, pode levar a configurações com melhores resultados em termos de previsão. Pode-se buscar, além disso, avaliar as previsões em relação às quantidades de medicamentos para outros intervalos de previsão, dando ao gestor da política de distribuição de medicamentos ainda mais informações, possibilitando uma melhor tomada de decisão.

¹<https://www.mcompetitions.unic.ac.cy/>

Em relação à qualidade dos dados, não foi realizado nenhum tratamento relacionado à detecção de *outliers* ou de valores iniciais de dispensação próximos de zero, em virtude da grande quantidade de séries temporais selecionadas. Dessa forma, realizar avaliações dessa natureza, para cada série temporal, pode levar a uma melhoria nas previsões dos modelos.

Para auxiliar os gestores do Ministério da Saúde na escolha de que modelo devem utilizar em fase de produção, a fim de fazer previsões futuras com base no histórico de dispensações, poderia ser modelada uma função de custo que penalizasse de forma mais significativa os casos de previsões abaixo da demanda (desabastecimento) em relação aos casos acima da demanda. Outra medida possível seria o cálculo de um índice, para alguns modelos que obtiveram melhor desempenho, que levasse em conta uma avaliação agregada, ou seja, dos casos onde os modelos implementados na pesquisa foram superiores ao modelo atualmente em uso, assim como os casos onde o contrário foi observado. Outra possibilidade seria a utilização de máquinas de comitê para seleção ou combinação das previsões dos diversos métodos avaliados. Melhoramentos como esses dariam ao Ministério da Saúde mais segurança para decidir qual modelo ou combinação de modelos utilizar.

Por fim, a utilização de séries temporais para a previsão de compras centralizadas dos medicamentos e a utilização de previsões hierárquicas podem ser uma ferramenta muito importante para que se tenha uma visão nacional a respeito da demanda dos medicamentos, contribuindo, portanto, para um melhor planejamento das aquisições de medicamentos, já que isso redundaria em uma mensuração mais precisa das quantidades a serem adquiridas e auxiliaria o Ministério da Saúde na tarefa de controlar os estoques centralizados.

Referências

- [1] Goodfellow, Ian, Yoshua Bengio e Aaron Courville: *Deep Learning*. MIT Press, 2016. x, 16, 37, 38, 39, 40, 41, 42, 43, 63, 64, 66
- [2] Ministério da Saúde: *Portaria GM nº 3.916, de 30 de outubro de 1998. Política Nacional de Medicamentos*, 1988. 1
- [3] Ministério da Saúde: *Resolução CNS nº 338, de 6 de maio de 2004. Política Nacional de Assistência Farmacêutica.*, 2004. 1
- [4] Ministério da Saúde: *Relação Nacional de Medicamentos Essenciais : RENAME 2018*, 2018. 1, 2
- [5] Ministério da Saúde: *Portaria GM/MS nº 1.554, de 30 de julho de 2013. Dispõe sobre as regras de financiamento e execução do Componente Especializado da Assistência Farmacêutica no âmbito do Sistema Único de Saúde (SUS).*, 2013. 2
- [6] Tribunal de Contas da União.: *Relatório Sistemático de Fiscalização da Saúde - Fisc-Saúde. Acórdão 693/2014-TCU-Plenário*, 2014. 2
- [7] Tribunal de Contas da União: *Auditoria de conformidade realizada na Secretaria de Saúde do Estado da Paraíba (SES/PB), com o objetivo de verificar a regularidade da aplicação dos recursos federais repassados ao ente federativo no Programa de Medicamentos Excepcionais, entre 2007 e 2011. Acórdão 1.154/2013-TCU-Plenário*, 2013. 2
- [8] Tribunal de Contas da União: *Tribunal de Contas da União. Auditoria realizada em municípios do Estado do Paraná para verificar a regularidade das aquisições de medicamentos efetuadas com recursos de convênios. Acórdão 1.267/2011-TCU-Plenário*, 2011. 2
- [9] Tribunal de Contas da União: *Auditoria de conformidade da execução de convênios firmados com o Ministério da Saúde para aquisição de medicamentos da assistência farmacêutica básica nos municípios de Balsamo/SP, Cândido Rodrigues/SP, Monte Alegre Sul/SP e Tuiuti/SP. Acórdão 1.874/2013-TCU-Segunda Câmara*, 2013. 3
- [10] Tribunal de Contas da União: *Representação versando sobre o vencimento do prazo de validade de medicamentos de alto custo estocados no âmbito da Secretaria de Estado de Saúde em Mato Grosso (SES/MT).Acórdão 2.917/2013-TCU-Plenário*, 2013. 3

- [11] Ministério da Transparência, Fiscalização e Controladoria Geral da União: *Relatório de Avaliação da Execução de Programa de Governo Nº 71: Apoio financeiro para aquisição e distribuição de medicamentos do componente especializado da assistência farmacêutica - CEAF*, 2017. 3, 48
- [12] Tribunal de Contas da União: *Portaria-TCU nº 141, DE 1º DE ABRIL DE 2015. Aprova o Plano Estratégico do Tribunal de Contas da União para o período 2015-2021*, 2015. 7
- [13] Tribunal de Contas da União: *Portaria-TCU Nº 181, de 23 de Maio de 2019. Aprova o Plano de Gestão do Tribunal de Contas da União para o período de abril de 2019 a março de 2021 e a distribuição, nos períodos avaliativos, dos valores das metas que compõem o resultado institucional.*, 2019. 7
- [14] Strengthening Pharmaceutical Systems: *Pharmaceuticals and the Public Interest: The Importance of Good Governance*, 2011. 9
- [15] World Health Organization: *Estimating Drug Requirements: A Practical Manual. Action programme on essential drugs and vaccines*, 1988. 9, 10
- [16] Management Sciences for Health: *Systems for Improved Access to Pharmaceuticals and Services (SIAPS) Program. Promising Practices: Quantification: Forecasting and Supply Planning.*, 2014. 9, 10
- [17] Management Sciences for Health: *MDS-3: Managing Access to Medicines and Health Technologies*, 2012. 10
- [18] United Nations High Commissioner for Refugees: *UNHCR's Essential Medicines and Medical Supplies. Policy and Guidance*, 2011. 10
- [19] Inc, John Snow: *Quantification of Health Commodities: A Guide to Forecasting and Supply Planning for Procurement.*, 2017. 10
- [20] Cook, Arthur G.: *Forecasting for the pharmaceutical industry: models for new product and in-market forecasting and how to use them.* Gower, Aldershot, 2006, ISBN 978-0-566-08675-5. OCLC: 836293442. 10, 11
- [21] Asgari, Nasrin, Ehsan Nikbakhsh, Alex Hill e Reza Zanjirani Farahani: *Supply chain management 1982–2015: a review.* IMA Journal of Management Mathematics, 27(3):353–379, julho 2016, ISSN 1471-678X, 1471-6798. 11
- [22] Hu, Qiwei, John E. Boylan, Huijing Chen e Ashraf Labib: *OR in spare parts management: A review.* European Journal of Operational Research, 266(2):395–414, abril 2018, ISSN 03772217. 11
- [23] Soyiri, Ireneous N. e Daniel D. Reidpath: *An overview of health forecasting.* Environmental Health and Preventive Medicine, 18(1):1–9, janeiro 2013, ISSN 1342-078X, 1347-4715. 12

- [24] Talaei-Khoei, Amir, James M Wilson e Seyed Farzan Kazemi: *Period of Measurement in Time-Series Predictions of Disease Counts from 2007 to 2017 in Northern Nevada: Analytics Experiment*. JMIR Public Health Surveill, 5(1):e11357, janeiro 2019, ISSN 2369-2960. 12
- [25] Nikolopoulos, Konstantinos, Samantha Buxton, Marwan Khammash e Philip Stern: *Forecasting branded and generic pharmaceuticals*. International Journal of Forecasting, 32(2):344–357, abril 2016, ISSN 01692070. 12
- [26] Pratyaksa, Hans, Adhistya Erna Permanasari, Silmi Fauziati e Ida Fitriana: *ARIMA implementation to predict the amount of antiseptic medicine usage in veterinary hospital*. Em *2016 1st International Conference on Biomedical Engineering (IBIOMED)*, páginas 1–4, Yogyakarta, Indonesia, outubro 2016. IEEE, ISBN 978-1-5090-4142-8. 12
- [27] Makridakis, Spyros, Evangelos Spiliotis e Vassilios Assimakopoulos: *Statistical and Machine Learning forecasting methods: Concerns and ways forward*. PLOS ONE, 13(3):e0194889, março 2018, ISSN 1932-6203. 12, 16, 22, 58, 62
- [28] Hyndman, Rob J. e Yeasmin Khandakar: *Automatic Time Series Forecasting: The **forecast** Package for R*. Journal of Statistical Software, 27(3), 2008, ISSN 1548-7660. 13, 61
- [29] Hyndman, Rob J. e Baki Billah: *Unmasking the Theta method*. International Journal of Forecasting, 19(2):287–290, abril 2003, ISSN 01692070. 13, 26, 28
- [30] Nikolopoulos, Konstantinos, Vassilios Assimakopoulos, Nikolaos Bougioukos, Akrivi Litsa e Fotios Petropoulos: *The Theta Model: An Essential Forecasting Tool for Supply Chain Planning*. Em Lee, Gary (editor): *Advances in Automation and Robotics, Vol. 2*, volume 123, páginas 431–437. Springer Berlin Heidelberg, Berlin, Heidelberg, 2011, ISBN 978-3-642-25645-5 978-3-642-25646-2. 13
- [31] Khalil Zadeh, Neda, Mohammad Mehdi Sepehri e Hamid Farvaresh: *Intelligent Sales Prediction for Pharmaceutical Distribution Companies: A Data Mining Based Approach*. Mathematical Problems in Engineering, 2014:15, 2014. 13
- [32] Luo, Li, Le Luo, Xinli Zhang e Xiaoli He: *Hospital daily outpatient visits forecasting using a combinatorial model based on ARIMA and SES models*. BMC Health Services Research, 17(1), dezembro 2017, ISSN 1472-6963. 13
- [33] Mahalakshmi, G., S. Sridevi e S. Rajaram: *A survey on forecasting of time series data*. Em *Proceedings of the International Conference on Computing Technologies and Intelligent Data Engeneering*, páginas 1–8, India, janeiro 2016. IEEE, ISBN 978-1-4673-8437-7. 13
- [34] Fernández-Navarro, F., Maria Angeles de la Cruz, P. A. Gutiérrez, A. Castaño e C. Hervás-Martínez: *Time series forecasting by recurrent product unit neural networks*. Neural Computing and Applications, 29(3):779–791, fevereiro 2018, ISSN 0941-0643, 1433-3058. 13, 16

- [35] Fischer, Thomas e Christopher Krauss: *Deep learning with long short-term memory networks for financial market predictions*. European Journal of Operational Research, dezembro 2017, ISSN 03772217. 14
- [36] Cortez, Bitzel, Berny Carrera, Young Jin Kim e Jae Yoon Jung: *An architecture for emergency event prediction using LSTM recurrent neural networks*. Expert Systems with Applications, 97:315–324, maio 2018, ISSN 09574174. 14
- [37] Kim, Ha Young e Won, Chang Hyun: *Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models*. Expert Systems with Applications, 103:25–37, agosto 2018, ISSN 09574174. 14
- [38] Venna, S. R., A. Tavanaei, R. N. Gottumukkala, V. V. Raghavan, A. S. Maida e S. Nichols: *A Novel Data-Driven Model for Real-Time Influenza Forecasting*. IEEE Access, 7:7691–7701, 2019, ISSN 2169-3536. 14
- [39] Taylor, Sean J e Benjamin Letham: *Forecasting at scale*. PeerJ Preprints, 5:e3190v2, setembro 2017, ISSN 2167-9843. 15
- [40] Montero-Manso, Pablo, George Athanasopoulos, Rob J Hyndman e Thiyanga S Tagala: *FFORMA: Feature-based Forecast Model Averaging*. International Journal of Forecasting, página 12, 2019. 15
- [41] Brockwell, Peter J. e Richard A. Davis: *Introduction to Time Series and Forecasting*. Springer, 2002, ISBN 0-387-95351-5. 15, 19, 28, 33
- [42] Hyndman, Rob J. e George Athanasopoulos: *Forecasting: principles and practice*. OTexts, 2nd edição, 2018, ISBN 978-0-9875071-1-2. 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 30, 31, 34, 52, 58, 59, 67
- [43] Makridakis, Spyros, Evangelos Spiliotis e Vassilios Assimakopoulos: *The M4 Competition: Results, findings, conclusion and way forward*. International Journal of Forecasting, 34(4):802–808, outubro 2018, ISSN 01692070. 15, 125
- [44] Cao, Jian, Zhi Li e Jian Li: *Financial time series forecasting model based on CEEM-DAN and LSTM*. Physica A: Statistical Mechanics and its Applications, 519:127–139, abril 2019, ISSN 0378-4371. 16
- [45] Kim, Taewook e Ha Young Kim: *Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data*. PLOS ONE, 14(2):e0212320, fevereiro 2019, ISSN 1932-6203. 16
- [46] Sagheer, Alaa e Mostafa Kotb: *Time series forecasting of petroleum production using deep LSTM recurrent networks*. Neurocomputing, 323:203–213, janeiro 2019, ISSN 0925-2312. 16
- [47] Yu, Ruiguo, Jie Gao, Mei Yu, Wenhuan Lu, Tianyi Xu, Mankun Zhao, Jie Zhang, Ruixuan Zhang e Zhuo Zhang: *LSTM-EFG for wind power forecasting based on sequential correlation features*. Future Generation Computer Systems, 93:33–42, abril 2019, ISSN 0167739X. 16

- [48] Qin, Jinbo, Ji Liang, Tao Chen, Xiaohui Lei e Aiqing Kang: *Simulating and Predicting of Hydrological Time Series Based on TensorFlow Deep Learning*. Polish Journal of Environmental Studies, 28(2):795–802, dezembro 2018, ISSN 1230-1485, 2083-5906. 16
- [49] Haider, Sajjad Ali, Syed Rameez Naqvi, Tallha Akram, Gulfam Ahmad Umar, Aamir Shahzad, Muhammad Rafiq Sial, Shoaib Khaliq e Muhammad Kamran: *LSTM Neural Network Based Forecasting Model for Wheat Production in Pakistan*. Agronomy, 9(2):72, fevereiro 2019. 16
- [50] Yang, Bailin, Shulin Sun, Jianyuan Li, Xianxuan Lin e Yan Tian: *Traffic flow prediction using LSTM with feature enhancement*. Neurocomputing, 332:320–327, março 2019, ISSN 09252312. 16
- [51] Zhang, Kaisa, Gang Chuai, Weidong Gao, Xuewen Liu, Saidiwaerdi Maimaiti e Zhiwei Si: *A new method for traffic forecasting in urban wireless communication network*. EURASIP Journal on Wireless Communications and Networking, 2019(1):66, março 2019, ISSN 1687-1499. 16
- [52] Morettin, P.A e Clélia M. C. Toloi: *Análise de séries temporais*. Edgar Blucher, São Paulo, 2ª edição, 2006, ISBN 978-85-212-0389-6. 16, 17, 18, 19, 28, 29, 32, 33, 34, 35, 36
- [53] Shumway, Robert H e David S Stoffer: *Time Series Analysis and Its Applications*. Springer Texts in Statistics. Springer, fourth edição, 2016. 17
- [54] Hyndman, Rob J., Anne B. Koehler, J.K. Ord e R.D. Snyder: *Forecasting with Exponential Smoothing The State Space Approach*. Springer Series in Statistics. Springer, agosto 2008, ISBN 978-3-540-71916-8. 17, 25, 29, 30, 31, 67
- [55] Dagum, E.B. e S. Bianconcini: *Seasonal adjustment methods and real time trend-cycle estimation*. Springer, 2016. 18
- [56] Cleveland, R. B., W. S. Cleveland, J. E. McRae e I. J. Terpenning: *STL: A seasonal-trend decomposition procedure based on loess*. Journal of Official Statistics, 6(1):3–73, 1990. 18
- [57] Wei, William: *Time Series Analysis: Univariate and Multivariate Methods*. Pearson, 2nd edição, 2005, ISBN 0-321-32216-9. 18
- [58] Zhu, Lingxue e Nikolay Laptev: *Deep and Confident Prediction for Time Series at Uber*. Em *2017 IEEE International Conference on Data Mining Workshops (ICDMW)*, páginas 103–110, novembro 2017. arXiv: 1709.01907. 20
- [59] Gal, Yarin e Zoubin Ghahramani: *Dropout As a Bayesian Approximation: Representing Model Uncertainty in Deep Learning*. Em *Proceedings of the 33rd International Conference on International Conference on Machine Learning - Volume 48, ICML'16*, páginas 1050–1059. JMLR.org, 2016. event-place: New York, NY, USA. 21, 66, 67
- [60] Gal, Yarin: *Uncertainty in Deep Learning*. PhD Thesis, University of Cambridge, 2016. 21, 63

- [61] Brown, Robert Goodell: *Statistical forecasting for inventory control*, 1959. 22
- [62] Holt, Charles C.: *Forecasting seasonals and trends by exponentially weighted moving averages*. *International Journal of Forecasting*, 20(1):5–10, janeiro 2004, ISSN 01692070. 22, 23
- [63] Winters, Peter R.: *Forecasting Sales by Exponentially Weighted Moving Averages*. Em Funke, Ursula H. (editor): *Mathematical Models in Marketing: A Collection of Abstracts*, Lecture Notes in Economics and Mathematical Systems, páginas 384–386. Springer Berlin Heidelberg, Berlin, Heidelberg, 1976, ISBN 978-3-642-51565-1. 22, 24
- [64] Hyndman, Rob J, Anne B Koehler, Ralph D Snyder e Simone Grose: *A state space framework for automatic forecasting using exponential smoothing methods*. *International Journal of Forecasting*, 18(3):439–454, julho 2002, ISSN 0169-2070. 25
- [65] Garth P. McCormick: *Exponential Forecasting: Some New Variations*. *Management Science*, 15(5):311–320, janeiro 1969, ISSN 0025-1909, 1526-5501. 25
- [66] Gardner, Everette S.: *Exponential smoothing: The state of the art*. *Journal of Forecasting*, 4(1):1–28, janeiro 1985, ISSN 1099-131X. 25
- [67] Taylor, James W.: *Exponential smoothing with a damped multiplicative trend*. *International Journal of Forecasting*, 19(4):715–725, outubro 2003, ISSN 0169-2070. 25
- [68] Assimakopoulos, V. e K. Nikolopoulos: *The theta model: a decomposition approach to forecasting*. *International Journal of Forecasting*, 16(4):521–530, outubro 2000, ISSN 01692070. 26, 27
- [69] Aoki, Masanao: *State Space Modeling of Time Series*. Universitext. Springer-Verlag Berlin Heidelberg, 1ª edição, 1987, ISBN 0-387-172256-4. 28
- [70] Harvey, Andrew C.: *Forecasting, Structural Time Series Models and the Kalman Filter*. Cambridge University Press, fevereiro 1990, ISBN 0-521-32196-4. 28
- [71] Akaike, H.: *A new look at the statistical model identification*. *IEEE Transactions on Automatic Control*, 19(6):716–723, dezembro 1974, ISSN 0018-9286. 31
- [72] Gentle, James E., Wolfgang K. Hardle e Yuichi Mori: *Handbook of Computational Statistics: Concepts and Methods*, volume 2 de *Springer Handbooks of Computational Statistics*. Springer-Verlag Berlin Heidelberg, 2ª edição, 2012, ISBN 978-3-642-21550-6. 35
- [73] Sutskever, Ilya: *Training Recurrent Neural Networks*. Tese de Doutorado, University of Toronto, 2013. 37, 38, 39
- [74] Graves, Alex: *Supervised Sequence Labelling with Recurrent Neural Networks*. Tese de Doutorado, Technische Universität München, 2008. 38, 39

- [75] Rahman, Aowabin, Vivek Srikumar e Amanda D. Smith: *Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks*. Applied Energy, 212:372 – 385, 2018, ISSN 0306-2619. 41
- [76] Bergstra, James, Rémi Bardenet, Yoshua Bengio e Balázs Kégl: *Algorithms for Hyperparameter Optimization*. Em *Proceedings of the 24th International Conference on Neural Information Processing Systems*, NIPS'11, páginas 2546–2554, USA, 2011. Curran Associates Inc., ISBN 978-1-61839-599-3. event-place: Granada, Spain. 43, 64
- [77] Chapman, Pete, Thomas Khabaza e Colin Shearer: *Step-by-step data mining guide. Technical Report, The CRISP-DM Consortium*, 2000. 45, 46
- [78] Ministério da Saúde: *Portaria nº 957/GM/MS, de 10 de maio de 2016. Estabelece o conjunto de dados e eventos referentes aos medicamentos e insumos da Relação Nacional de Medicamentos Essenciais (RENAME) e do Programa Farmácia Popular do Brasil para composição da Base Nacional de Dados de Ações e Serviços da Assistência Farmacêutica no âmbito do Sistema Único de Saúde (SUS)*, 2016. 47
- [79] Ministério da Saúde: *Altera a Portaria nº 957/GM/MS, de 10 de maio de 2016. Portaria nº 938/GM/MS, de 07 de abril de 2017*, 2017. 47
- [80] Ministério da Saúde: *Consolidação das normas sobre os direitos e deveres dos usuários da saúde, a organização e o funcionamento do Sistema Único de Saúde. Portaria de Consolidação nº 1, de 28 de setembro de 2017*, 2017. 47
- [81] Ministério da Saúde: *Altera a Portaria de Consolidação nº 1/GM/MS, de 28 de setembro de 2017, para regulamentar os prazos máximos para transmissão dos dados compositores da Base Nacional de Dados de Ações e Serviços da Assistência Farmacêutica.*, junho 2018. 47
- [82] Kwiatkowski, Denis, Peter C. B. Phillips, Peter Schmidt e Yongcheol Shin: *Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?* Journal of Econometrics, 54(1):159–178, outubro 1992, ISSN 0304-4076. 57
- [83] Hyndman, Rob J. e Anne B. Koehler: *Another look at measures of forecast accuracy*. International Journal of Forecasting, 22(4):679–688, outubro 2006, ISSN 01692070. 59
- [84] Krizhevsky, Alex, Ilya Sutskever e Geoffrey E. Hinton: *ImageNet Classification with Deep Convolutional Neural Networks*. Em *Proceedings of the 25th International Conference on Neural Information Processing Systems - Volume 1*, NIPS'12, páginas 1097–1105, USA, 2012. Curran Associates Inc. event-place: Lake Tahoe, Nevada. 64
- [85] Srivastava, Nitish, Geoffrey E. Hinton, Alex Krizhevsky, Ilya Sutskever e Ruslan Salakhutdinov: *Dropout: A Simple Way to Prevent Neural Networks from Overfitting*. The Journal of Machine Learning Research, página 30, 2014. 65

Apêndice A

Resultados das Programações Automatizadas

A.1 Distrito Federal

Tabela A.1: Programações automatizadas (DF) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266820U0118	1575	1441	1256	319	185
BR0268084U0042	11777	10305	13680	-1903	-3375
BR0268098U0041	442145	383263	379170	62975	4093
BR0268118U0135	53	466	300	-247	166
BR0268143U0042	38468	29496	20370	18098	9126
BR0268825U0042	21040	22476	25620	-4580	-3144
BR0271620U0042	18746	22680	22990	-4244	-310
BR0271621U0042	100914	101337	111260	-10346	-9923
BR0272083U0042	195681	168906	251190	-55509	-82284
BR0272786U0042	7401	7497	5100	2301	2397
BR0272824U0042	3418	3714	4860	-1442	-1146
BR0272825U0042	40214	60155	64640	-24426	-4485
BR0272833U0042	24943	33868	44850	-19907	-10982
BR0272835U0041	-5646	-27293	8320	-13966	-35613
BR0277434U0135	2379	3193	3237	-858	-44
BR0277438U0118	576	887	991	-415	-104
BR0277743U0118	662	771	517	145	254
BR0285817U0046	8331	9984	11190	-2859	-1206
BR0285818U0046	4280	6706	7340	-3060	-634

Table A.1 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0288640U0042	9367	10145	6890	2477	3255
BR0288641U0042	281822	272557	198320	83502	74237
BR0290058U0135	3299	5057	5176	-1877	-119
BR0292372U0118	931	790	942	-11	-152
BR0315088U0042	42394	43145	31170	11224	11975
BR0325836U0042	2565	3312	2345	220	967
BR0342320U0041	8321	11595	11340	-3019	255
BR0342746U0118	6133	5775	6772	-639	-997
BR0343607U0118	351	754	486	-135	268
BR0343608U0118	4148	5397	5008	-860	389
BR0369176U0042	7743	14232	13710	-5967	522

Tabela A.2: Programações automatizadas (DF) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266820U0118	1683	2137	1263	420	874
BR0268084U0042	9344	13473	12976	-3632	497
BR0268098U0041	412323	417395	394650	17673	22745
BR0268118U0135	116	312	279	-163	33
BR0268143U0042	5059	12384	21770	-16711	-9386
BR0268825U0042	21219	27240	23670	-2451	3570
BR0271620U0042	17475	22027	23050	-5575	-1023
BR0271621U0042	84665	107838	112720	-28055	-4882
BR0272083U0042	200409	229910	239760	-39351	-9850
BR0272786U0042	4876	7005	5040	-164	1965
BR0272824U0042	5311	6541	5160	151	1381
BR0272825U0042	45357	54989	70550	-25193	-15561
BR0272833U0042	49104	40246	45180	3924	-4934
BR0272835U0041	-25194	-11595	4430	-29624	-16025
BR0277434U0135	2916	3808	3492	-576	316
BR0277438U0118	-31	199	932	-963	-733
BR0277743U0118	-314	-5	443	-757	-448
BR0285817U0046	13272	12691	11180	2092	1511
BR0285818U0046	6302	6308	7320	-1018	-1012
BR0288640U0042	-2607	3338	6920	-9527	-3582
BR0288641U0042	82424	106399	199910	-117486	-93511

Table A.2 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0290058U0135	5677	5235	5237	440	-2
BR0292372U0118	466	536	999	-533	-463
BR0315088U0042	36369	41510	31620	4749	9890
BR0325836U0042	2924	3655	2485	439	1170
BR0342320U0041	12548	11354	12090	458	-736
BR0342746U0118	5185	6795	6886	-1701	-91
BR0343607U0118	500	403	1092	-592	-689
BR0343608U0118	8566	8328	4638	3928	3690
BR0369176U0042	8858	13995	15420	-6562	-1425

Tabela A.3: Programações automatizadas (DF) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266820U0118	404	842	1143	-739	-301
BR0268084U0042	9558	14084	13468	-3910	616
BR0268098U0041	324538	427594	368290	-43752	59304
BR0268118U0135	580	591	299	281	292
BR0268143U0042	21091	23802	19640	1451	4162
BR0268825U0042	20101	27245	23700	-3599	3545
BR0271620U0042	20317	28277	22940	-2623	5337
BR0271621U0042	91160	122067	105620	-14460	16447
BR0272083U0042	222711	248411	255540	-32829	-7129
BR0272786U0042	5531	5552	6330	-799	-778
BR0272824U0042	2434	5732	4650	-2216	1082
BR0272825U0042	58710	77725	65010	-6300	12715
BR0272833U0042	42180	52347	33160	9020	19187
BR0272835U0041	-20372	-18902	3420	-23792	-22322
BR0277434U0135	3258	3802	3796	-538	6
BR0277438U0118	118	1056	857	-739	199
BR0277743U0118	79	526	463	-384	63
BR0285817U0046	12462	13445	11910	552	1535
BR0285818U0046	7715	8607	7440	275	1167
BR0288640U0042	368	4005	6380	-6012	-2375
BR0288641U0042	188068	181832	188300	-232	-6468
BR0290058U0135	5151	5451	5770	-619	-319
BR0292372U0118	1406	1366	1057	349	309

Table A.3 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0315088U0042	26883	36133	29610	-2727	6523
BR0325836U0042	1150	1709	2961	-1811	-1252
BR0342320U0041	17447	16464	11850	5597	4614
BR0342746U0118	4440	7512	6769	-2329	743
BR0343607U0118	462	1697	352	110	1345
BR0343608U0118	2204	2031	6064	-3860	-4033
BR0369176U0042	11364	17029	14460	-3096	2569

A.2 Ceará

Tabela A.4: Programações automatizadas (CE) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	4845	59354	47831	-42986	11523
BR0266820U0118	-693	-414	1359	-2052	-1773
BR0267894U0041	-6252	-2610	8955	-15207	-11565
BR0267895U0041	-10762	-20241	31020	-41782	-51261
BR0267896U0041	556	9853	2295	-1739	7558
BR0267897U0041	-9550	-14458	14884	-24434	-29342
BR0268084U0042	-18700	-10338	10883	-29583	-21221
BR0268097U0041	-11205	-12842	29225	-40430	-42067
BR0268098U0041	872541	684940	866689	5852	-181749
BR0268114U0042	-69809	-88558	95495	-165304	-184053
BR0268143U0042	-131723	-129663	40428	-172151	-170091
BR0268345U0042	-5652	-7325	2040	-7692	-9365
BR0268825U0042	6892	5809	13590	-6698	-7781
BR0271620U0042	-171404	-228263	148385	-319789	-376648
BR0271621U0042	-154554	157876	152883	-307437	4993
BR0272431U0042	-99195	13242	231983	-331178	-218741
BR0272785U0042	-72949	-59899	17508	-90457	-77407
BR0272786U0042	-9573	10579	88156	-97729	-77577
BR0272826U0042	39495	14059	64531	-25036	-50472
BR0272831U0042	-32815	165432	35245	-68060	130187
BR0272832U0042	-174550	-83242	106544	-281094	-189786
BR0272833U0042	-24526	70759	75830	-100356	-5071
BR0272835U0041	-41060	-45684	6382	-47442	-52066

Table A.4 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0277434U0135	-1554	-3089	1969	-3523	-5058
BR0277438U0118	-2116	-2032	462	-2578	-2494
BR0277743U0118	-871	-1027	470	-1341	-1497
BR0285817U0046	8628	3971	25115	-16487	-21144
BR0288640U0042	-46397	-3573	61126	-107523	-64699
BR0288641U0042	554823	483347	442977	111846	40370
BR0290058U0135	711	2430	4104	-3393	-1674
BR0315088U0042	8597	10245	11803	-3206	-1558
BR0333447U0118	-5559	-5660	1916	-7475	-7576
BR0342746U0118	-1033	-6372	8055	-9088	-14427
BR0343607U0118	298	370	304	-6	66
BR0343608U0118	4436	6582	3877	559	2705
BR0367664U0075	5	25	136	-131	-111
BR0369176U0042	-123556	-145916	56585	-180141	-202501

Tabela A.5: Programações automatizadas (CE) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	10738	73972	70906	-60168	3066
BR0266820U0118	456	694	1486	-1030	-792
BR0267894U0041	-11536	11987	6690	-18226	5297
BR0267895U0041	24948	30812	31950	-7002	-1138
BR0267896U0041	-12493	-884	1935	-14428	-2819
BR0267897U0041	-9332	1943	13740	-23072	-11797
BR0268084U0042	-2342	7359	12121	-14463	-4762
BR0268097U0041	19591	25259	29609	-10018	-4350
BR0268098U0041	931415	1004745	881693	49722	123052
BR0268114U0042	78186	152960	95770	-17584	57190
BR0268143U0042	-48670	-25421	38554	-87224	-63975
BR0268345U0042	378	407	1862	-1484	-1455
BR0268825U0042	11840	13851	14370	-2530	-519
BR0271620U0042	76052	384098	140818	-64766	243280
BR0271621U0042	100566	407195	144342	-43776	262853
BR0272431U0042	142969	357944	242863	-99894	115081
BR0272785U0042	-43691	-18105	18634	-62325	-36739
BR0272786U0042	99343	128453	91130	8213	37323

Table A.5 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0272826U0042	29924	59931	59683	-29759	248
BR0272831U0042	19915	166340	40679	-20764	125661
BR0272832U0042	50539	323129	114525	-63986	208604
BR0272833U0042	76449	221817	60727	15722	161090
BR0272835U0041	-29708	-26942	3752	-33460	-30694
BR0277434U0135	620	1515	2103	-1483	-588
BR0277438U0118	-1080	-848	461	-1541	-1309
BR0277743U0118	-298	-169	487	-785	-656
BR0285817U0046	25799	36068	27021	-1222	9047
BR0288640U0042	54659	118934	62654	-7995	56280
BR0288641U0042	192907	196601	437725	-244818	-241124
BR0290058U0135	3857	6871	3923	-66	2948
BR0315088U0042	12624	12933	11739	885	1194
BR0333447U0118	-3588	-3477	1976	-5564	-5453
BR0342746U0118	7017	7874	7764	-747	110
BR0343607U0118	-372	357	1087	-1459	-730
BR0343608U0118	5067	8620	3362	1705	5258
BR0367664U0075	32	90	134	-102	-44
BR0369176U0042	-68486	-62904	63417	-131903	-126321

Tabela A.6: Programações automatizadas (CE) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	6922	17662	98555	-91633	-80893
BR0266820U0118	1852	1882	1628	224	254
BR0267894U0041	8231	22076	7020	1211	15056
BR0267895U0041	1286	7934	30720	-29434	-22786
BR0267896U0041	-15528	-1521	2490	-18018	-4011
BR0267897U0041	13790	17923	14048	-258	3875
BR0268084U0042	9913	20027	12032	-2119	7995
BR0268097U0041	27181	28176	29270	-2089	-1094
BR0268098U0041	900463	978374	870486	29977	107888
BR0268114U0042	59117	186200	39454	19663	146746
BR0268143U0042	28296	43383	39589	-11293	3794
BR0268345U0042	-5172	-4489	1713	-6885	-6202
BR0268825U0042	13967	18315	14126	-159	4189

Table A.6 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0271620U0042	113890	444915	164442	-50552	280473
BR0271621U0042	116886	419428	171324	-54438	248104
BR0272431U0042	221146	403735	257210	-36064	146525
BR0272785U0042	-471	31596	17224	-17695	14372
BR0272786U0042	69989	122569	89263	-19274	33306
BR0272826U0042	79573	110967	78360	1213	32607
BR0272831U0042	35599	214231	40544	-4945	173687
BR0272832U0042	149389	472063	76464	72925	395599
BR0272833U0042	-12761	37118	107734	-120495	-70616
BR0272835U0041	-35330	-27578	1838	-37168	-29416
BR0277434U0135	1521	2308	2063	-542	245
BR0277438U0118	-204	-107	480	-684	-587
BR0277743U0118	290	567	459	-169	108
BR0285817U0046	21382	27127	27540	-6158	-413
BR0288640U0042	-14848	-32595	54915	-69763	-87510
BR0288641U0042	568331	554431	453471	114860	100960
BR0290058U0135	4069	7649	4567	-498	3082
BR0315088U0042	14460	15803	13132	1328	2671
BR0333447U0118	-1368	-906	1975	-3343	-2881
BR0342746U0118	6749	9033	7358	-609	1675
BR0343607U0118	-285	1213	210	-495	1003
BR0343608U0118	1737	3590	4785	-3048	-1195
BR0367664U0075	110	157	142	-32	15
BR0369176U0042	21952	4048	64981	-43029	-60933

A.3 Pernambuco

Tabela A.7: Programações automatizadas (PE) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266628U0118	302	162	380	-78	-218
BR0267894U0041	10260	-5172	12706	-2446	-17878
BR0267895U0041	31108	-968	29842	1266	-30810
BR0267896U0041	8846	-4456	7740	1106	-12196
BR0267897U0041	6305	-2454	6330	-25	-8784
BR0268084U0042	21177	8099	15052	6125	-6953

Table A.7 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0268097U0041	59819	-5092	54330	5489	-59422
BR0268114U0042	114995	34460	83160	31835	-48700
BR0268143U0042	39957	-14289	49938	-9981	-64227
BR0271620U0042	198907	-21604	170224	28683	-191828
BR0271621U0042	326718	6503	248310	78408	-241807
BR0272083U0042	1724575	46390	1471500	253075	-1425110
BR0272785U0042	16344	465	19348	-3004	-18883
BR0272786U0042	49509	11468	44620	4889	-33152
BR0272825U0042	145778	-7025	106756	39022	-113781
BR0272826U0042	93756	-29036	89263	4493	-118299
BR0272832U0042	71590	-11553	72807	-1217	-84360
BR0277434U0135	4028	1319	3191	837	-1872
BR0277743U0118	1282	127	930	352	-803
BR0285817U0046	14014	6637	11491	2523	-4854
BR0288640U0042	56512	36582	43025	13487	-6443
BR0288641U0042	501618	85115	398630	102988	-313515
BR0290058U0135	4972	57	3764	1208	-3707
BR0333447U0118	1535	1761	1142	393	619
BR0343608U0118	8751	2221	7998	753	-5777
BR0369176U0042	33200	16811	30138	3062	-13327
BR0369179U0042	46649	-14900	39920	6729	-54820

Tabela A.8: Programações automatizadas (PE) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266628U0118	444	570	424	20	146
BR0267894U0041	9515	12043	12034	-2519	9
BR0267895U0041	40509	41865	27750	12759	14115
BR0267896U0041	10494	11845	8280	2214	3565
BR0267897U0041	6143	6761	4710	1433	2051
BR0268084U0042	19347	20467	15132	4215	5335
BR0268097U0041	69216	70498	55457	13759	15041
BR0268114U0042	94020	120057	85035	8985	35022
BR0268143U0042	51424	67363	49555	1869	17808
BR0271620U0042	188116	226705	164660	23456	62045
BR0271621U0042	315018	323946	250605	64413	73341

Table A.8 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0272083U0042	1515918	2065178	1078170	437748	987008
BR0272785U0042	6646	10751	27210	-20564	-16459
BR0272786U0042	40036	59535	37012	3024	22523
BR0272825U0042	102669	136537	99705	2964	36832
BR0272826U0042	130594	133123	93105	37489	40018
BR0272832U0042	73005	71472	76116	-3111	-4644
BR0277434U0135	3865	4075	3047	818	1028
BR0277743U0118	1366	1307	967	399	340
BR0285817U0046	12169	11864	10620	1549	1244
BR0288640U0042	45840	70488	41650	4190	28838
BR0288641U0042	504283	507132	377825	126458	129307
BR0290058U0135	4604	5172	4148	456	1024
BR0333447U0118	1359	1525	1119	240	406
BR0343608U0118	7719	9774	5656	2063	4118
BR0369176U0042	32055	47137	28470	3585	18667
BR0369179U0042	39300	52283	37915	1385	14368

Tabela A.9: Programações automatizadas (PE) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266628U0118	466	420	484	-18	-64
BR0267894U0041	11720	13817	13036	-1316	781
BR0267895U0041	36021	37841	28920	7101	8921
BR0267896U0041	993	2822	8760	-7767	-5938
BR0267897U0041	3695	5420	5788	-2093	-368
BR0268084U0042	20487	22273	15816	4671	6457
BR0268097U0041	65572	71096	50152	15420	20944
BR0268114U0042	116770	129864	79410	37360	50454
BR0268143U0042	36600	59579	52785	-16185	6794
BR0271620U0042	212272	208466	174892	37380	33574
BR0271621U0042	340499	341625	267122	73377	74503
BR0272083U0042	1588061	1328501	1275090	312971	53411
BR0272785U0042	13398	29201	19731	-6333	9470
BR0272786U0042	47119	45220	47040	79	-1820
BR0272825U0042	148573	126570	110779	37794	15791
BR0272826U0042	110844	115804	66010	44834	49794

Table A.9 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0272832U0042	78787	78334	85130	-6343	-6796
BR0277434U0135	4327	4492	3376	951	1116
BR0277743U0118	1129	1412	903	226	509
BR0285817U0046	12528	11335	11480	1048	-145
BR0288640U0042	44627	57034	44910	-283	12124
BR0288641U0042	487964	491141	429945	58019	61196
BR0290058U0135	5506	5531	4466	1040	1065
BR0333447U0118	1614	1491	1285	329	206
BR0343608U0118	8679	6606	8092	587	-1486
BR0369176U0042	42662	44971	30290	12372	14681
BR0369179U0042	50022	53754	41205	8817	12549

A.4 Alagoas

Tabela A.10: Programações automatizadas (AL) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	30746	40013	45906	-15160	-5893
BR0266820U0118	814	921	639	175	282
BR0267894U0041	3776	3882	3690	86	192
BR0267895U0041	-793	270	6630	-7423	-6360
BR0267896U0041	1935	2118	2520	-585	-402
BR0267897U0041	730	281	3270	-2540	-2989
BR0268074U0081	-884	-831	235	-1119	-1066
BR0268084U0042	3826	4680	4493	-667	187
BR0268097U0041	2703	3806	3860	-1157	-54
BR0268098U0041	74964	115248	87966	-13002	27282
BR0268114U0042	9355	13177	13110	-3755	67
BR0268143U0042	7262	3145	8010	-748	-4865
BR0268345U0042	-66	323	900	-966	-577
BR0268825U0042	8092	10700	10080	-1988	620
BR0271620U0042	25096	24041	29732	-4636	-5691
BR0271621U0042	65137	73231	68347	-3210	4884
BR0272083U0042	357918	460848	418968	-61050	41880
BR0272431U0042	54552	51048	68630	-14078	-17582
BR0272785U0042	4382	6350	10980	-6598	-4630

Table A.10 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0272786U0042	16232	20651	16085	147	4566
BR0272825U0042	20300	26828	32445	-12145	-5617
BR0272826U0042	23743	29082	20000	3743	9082
BR0272831U0042	40703	43142	45083	-4380	-1941
BR0272833U0042	48680	59200	76774	-28094	-17574
BR0272835U0041	2339	3510	1320	1019	2190
BR0277438U0118	522	286	384	138	-98
BR0277743U0118	751	551	745	6	-194
BR0285817U0046	2823	2246	2100	723	146
BR0285818U0046	1881	1864	1170	711	694
BR0288641U0042	55396	81302	45148	10248	36154
BR0290058U0135	1278	1621	1290	-12	331
BR0292372U0118	279	418	385	-106	33
BR0315088U0042	8683	11358	4980	3703	6378
BR0333447U0118	547	655	610	-63	45
BR0342746U0118	1160	1474	1114	46	360
BR0343607U0118	30	125	96	-66	29
BR0343608U0118	3309	3050	2915	394	135
BR0369178U0042	2400	3764	2870	-470	894

Tabela A.11: Programações automatizadas (AL) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	32694	40831	47383	-14689	-6552
BR0266820U0118	720	593	977	-257	-384
BR0267894U0041	1012	3740	3015	-2003	725
BR0267895U0041	2579	2806	7200	-4621	-4394
BR0267896U0041	2335	2456	2580	-245	-124
BR0267897U0041	-459	195	2638	-3097	-2443
BR0268074U0081	-684	-628	241	-925	-869
BR0268084U0042	3636	4157	4850	-1214	-693
BR0268097U0041	3382	5516	3300	82	2216
BR0268098U0041	98646	113043	94341	4305	18702
BR0268114U0042	14012	12262	13710	302	-1448
BR0268143U0042	6631	5061	7660	-1029	-2599
BR0268345U0042	866	1249	900	-34	349

Table A.11 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0268825U0042	12050	12119	10200	1850	1919
BR0271620U0042	39884	40382	33285	6599	7097
BR0271621U0042	61701	64350	66381	-4680	-2031
BR0272083U0042	337897	333168	418308	-80411	-85140
BR0272431U0042	59187	56927	56274	2913	653
BR0272785U0042	9316	15141	4595	4721	10546
BR0272786U0042	19638	18508	18854	784	-346
BR0272825U0042	24257	32201	32573	-8316	-372
BR0272826U0042	14399	10344	26040	-11641	-15696
BR0272831U0042	36757	50719	22043	14714	28676
BR0272833U0042	54544	57433	66165	-11621	-8732
BR0272835U0041	3850	5179	1248	2602	3931
BR0277438U0118	233	254	372	-139	-118
BR0277743U0118	833	1085	639	194	446
BR0285817U0046	2211	2187	2175	36	12
BR0285818U0046	56	-289	1230	-1174	-1519
BR0288641U0042	49808	55934	49526	282	6408
BR0290058U0135	1312	1259	1297	15	-38
BR0292372U0118	414	475	290	124	185
BR0315088U0042	6186	3976	5790	396	-1814
BR0333447U0118	593	607	579	14	28
BR0342746U0118	912	1021	1258	-346	-237
BR0343607U0118	8	103	108	-100	-5
BR0343608U0118	3962	4370	3196	766	1174
BR0369178U0042	3175	3205	3345	-170	-140

Tabela A.12: Programações automatizadas (AL) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	44808	47216	47086	-2278	130
BR0266820U0118	957	1201	1003	-46	198
BR0267894U0041	4624	4572	4010	614	562
BR0267895U0041	1849	3082	7575	-5726	-4493
BR0267896U0041	2832	2323	2580	252	-257
BR0267897U0041	1688	2059	2718	-1030	-659
BR0268074U0081	-402	-399	284	-686	-683

Table A.12 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0268084U0042	4115	5490	4793	-678	697
BR0268097U0041	1508	1864	4390	-2882	-2526
BR0268098U0041	83107	105660	99504	-16397	6156
BR0268114U0042	10130	16387	7171	2959	9216
BR0268143U0042	6656	10108	7170	-514	2938
BR0268345U0042	879	1564	900	-21	664
BR0268825U0042	9385	9600	10770	-1385	-1170
BR0271620U0042	30451	34130	33119	-2668	1011
BR0271621U0042	77946	77516	76553	1393	963
BR0272083U0042	397344	488125	440803	-43459	47322
BR0272431U0042	80080	73485	63474	16606	10011
BR0272785U0042	-6378	-5682	4995	-11373	-10677
BR0272786U0042	24849	26305	21170	3679	5135
BR0272825U0042	21788	31018	31004	-9216	14
BR0272826U0042	33128	33410	25574	7554	7836
BR0272831U0042	62587	55932	47382	15205	8550
BR0272833U0042	55515	83727	59602	-4087	24125
BR0272835U0041	4297	5706	1050	3247	4656
BR0277438U0118	359	392	351	8	41
BR0277743U0118	478	481	613	-135	-132
BR0285817U0046	1720	2455	1770	-50	685
BR0285818U0046	271	980	930	-659	50
BR0288641U0042	48608	49946	52336	-3728	-2390
BR0290058U0135	1630	1627	1505	125	122
BR0292372U0118	285	348	384	-99	-36
BR0315088U0042	10333	9752	8370	1963	1382
BR0333447U0118	713	712	639	74	73
BR0342746U0118	1030	1378	1217	-187	161
BR0343607U0118	68	91	87	-19	4
BR0343608U0118	2356	2033	3170	-814	-1137
BR0369178U0042	2999	3395	3600	-601	-205

A.5 Amapá

Tabela A.13: Programações automatizadas (AP) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0268098U0041	6799	-5580	12600	-5801	-18180
BR0288641U0042	-7967	-15243	7110	-15077	-22353
BR0290058U0135	-327	-989	564	-891	-1553

Tabela A.14: Programações automatizadas (AP) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0268098U0041	10478	9802	11280	-802	-1478
BR0288641U0042	-4290	-3317	6720	-11010	-10037
BR0290058U0135	-262	-102	508	-770	-610

Tabela A.15: Programações automatizadas (AP) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0268098U0041	11654	12214	9570	2084	2644
BR0288641U0042	2226	4944	7200	-4974	-2256
BR0290058U0135	312	447	534	-222	-87

A.6 Tocantins

Tabela A.16: Programações automatizadas (TO) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	3887	-5456	6662	-2775	-12118
BR0267894U0041	6568	919	4020	2548	-3101
BR0267895U0041	2324	634	660	1664	-26
BR0267896U0041	1698	-1002	2280	-582	-3282
BR0268098U0041	16282	-5501	19050	-2768	-24551
BR0268114U0042	6804	-2376	7980	-1176	-10356
BR0268143U0042	2308	-1143	2190	118	-3333
BR0268825U0042	7010	324	6870	140	-6546
BR0271620U0042	15249	-2136	14160	1089	-16296
BR0271621U0042	21485	5045	18690	2795	-13645

Table A.16 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0272083U0042	136	-19639	17460	-17324	-37099
BR0272431U0042	29276	-14268	40980	-11704	-55248
BR0272825U0042	5583	-4342	7770	-2187	-12112
BR0272826U0042	11866	-1212	8520	3346	-9732
BR0272832U0042	3771	-749	8430	-4659	-9179
BR0272833U0042	15441	-1011	15810	-369	-16821
BR0288640U0042	1083	462	1900	-817	-1438
BR0288641U0042	7233	2216	8620	-1387	-6404
BR0315088U0042	3557	275	2940	617	-2665
BR0333447U0118	-16	-191	160	-176	-351
BR0343607U0118	129	-76	168	-39	-244
BR0343608U0118	660	-197	560	100	-757

Tabela A.17: Programações automatizadas (TO) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	-2882	-2692	7557	-10439	-10249
BR0267894U0041	3714	4242	4094	-380	148
BR0267895U0041	1866	1426	1860	6	-434
BR0267896U0041	-18	798	2370	-2388	-1572
BR0268098U0041	23259	22363	22680	579	-317
BR0268114U0042	5781	7753	8430	-2649	-677
BR0268143U0042	1834	2667	2010	-176	657
BR0268825U0042	6726	6827	7140	-414	-313
BR0271620U0042	12482	13949	10710	1772	3239
BR0271621U0042	17396	19273	20160	-2764	-887
BR0272083U0042	21628	14024	21240	388	-7216
BR0272431U0042	26068	30350	42810	-16742	-12460
BR0272825U0042	5289	6293	9450	-4161	-3157
BR0272826U0042	6835	3120	12540	-5705	-9420
BR0272832U0042	8524	8414	8250	274	164
BR0272833U0042	20336	20627	18150	2186	2477
BR0288640U0042	1659	1556	2610	-951	-1054
BR0288641U0042	4710	6375	8680	-3970	-2305
BR0315088U0042	4667	4531	4500	167	31
BR0333447U0118	75	112	222	-147	-110

Table A.17 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0343607U0118	212	216	172	40	44
BR0343608U0118	539	857	460	79	397

Tabela A.18: Programações automatizadas (TO) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	-345	542	5993	-6338	-5451
BR0267894U0041	6613	6718	3612	3001	3106
BR0267895U0041	129	1114	1860	-1731	-746
BR0267896U0041	1751	2780	2700	-949	80
BR0268098U0041	26669	24543	23630	3039	913
BR0268114U0042	7325	10315	4350	2975	5965
BR0268143U0042	1504	849	2080	-576	-1231
BR0268825U0042	5940	6342	6810	-870	-468
BR0271620U0042	16378	17276	12690	3688	4586
BR0271621U0042	17396	21108	19560	-2164	1548
BR0272083U0042	9138	10902	20160	-11022	-9258
BR0272431U0042	47758	48438	41760	5998	6678
BR0272825U0042	8241	10961	7770	471	3191
BR0272826U0042	11640	13151	12330	-690	821
BR0272832U0042	9102	9027	4080	5022	4947
BR0272833U0042	18523	20346	13620	4903	6726
BR0288640U0042	2448	2562	2490	-42	72
BR0288641U0042	9210	9294	9630	-420	-336
BR0315088U0042	4873	5066	4860	13	206
BR0333447U0118	245	211	207	38	4
BR0343607U0118	31	60	172	-141	-112
BR0343608U0118	390	951	628	-238	323

A.7 Pará

Tabela A.19: Programações automatizadas (PA) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	-4069	-55345	46776	-50845	-102121

Table A.19 continuação da página anterior

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266820U0118	-285	-1228	800	-1085	-2028
BR0267894U0041	-521	-1412	870	-1391	-2282
BR0267895U0041	1531	-1862	2220	-689	-4082
BR0267897U0041	4	-820	420	-416	-1240
BR0268084U0042	-784	-3823	4074	-4858	-7897
BR0268097U0041	-21887	-29718	9070	-30957	-38788
BR0268098U0041	54644	-82113	145224	-90580	-227337
BR0268114U0042	-12965	-26793	27360	-40325	-54153
BR0268143U0042	9773	-2063	12360	-2587	-14423
BR0268825U0042	15355	5013	11023	4332	-6010
BR0272083U0042	-130306	-256214	219252	-349558	-475466
BR0272431U0042	60462	-900	65276	-4814	-66176
BR0272785U0042	-43600	-49376	3398	-46998	-52774
BR0272786U0042	-5444	-19335	7830	-13274	-27165
BR0272825U0042	-38269	-38134	16020	-54289	-54154
BR0272826U0042	24820	-10945	26340	-1520	-37285
BR0272831U0042	-20474	-24483	4940	-25414	-29423
BR0272832U0042	-6365	-11461	17420	-23785	-28881
BR0272833U0042	3408	-21210	17358	-13950	-38568
BR0272835U0041	-42813	-51045	8986	-51799	-60031
BR0277434U0135	534	-221	853	-319	-1074
BR0277435U0135	-513	-947	440	-953	-1387
BR0277438U0118	347	-307	421	-74	-728
BR0277743U0118	156	-140	228	-72	-368
BR0285817U0046	559	-1850	2559	-2000	-4409
BR0285818U0046	301	-609	765	-464	-1374
BR0288640U0042	23395	-4868	34270	-10875	-39138
BR0290058U0135	2494	-1257	3030	-536	-4287
BR0292372U0118	-11	-114	41	-52	-155
BR0315088U0042	9242	-2285	8813	429	-11098
BR0333447U0118	-115	-477	286	-401	-763
BR0342746U0118	-683	-1511	730	-1413	-2241
BR0343607U0118	-404	53	232	-636	-179
BR0343608U0118	2613	-1353	3432	-819	-4785
BR0369176U0042	-2223	-5389	5940	-8163	-11329

Tabela A.20: Programações automatizadas (PA) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	-17829	-17179	47680	-65509	-64859
BR0266820U0118	267	421	843	-576	-422
BR0267894U0041	-465	862	510	-975	352
BR0267895U0041	-795	97	2460	-3255	-2363
BR0267897U0041	-2449	-2600	1020	-3469	-3620
BR0268084U0042	3595	3396	4282	-687	-886
BR0268097U0041	-13608	-9956	6150	-19758	-16106
BR0268098U0041	146010	143978	160820	-14810	-16842
BR0268114U0042	23036	19899	27120	-4084	-7221
BR0268143U0042	4166	3665	11700	-7534	-8035
BR0268825U0042	16155	17159	13212	2943	3947
BR0272083U0042	261771	335799	271890	-10119	63909
BR0272431U0042	40683	54483	68690	-28007	-14207
BR0272785U0042	-34562	-31303	4520	-39082	-35823
BR0272786U0042	-409	-59	8513	-8922	-8572
BR0272825U0042	-18332	-15804	16930	-35262	-32734
BR0272826U0042	5591	-104	31861	-26270	-31965
BR0272831U0042	-2496	-2392	6180	-8676	-8572
BR0272832U0042	7196	10376	18810	-11614	-8434
BR0272833U0042	7993	8235	17502	-9509	-9267
BR0272835U0041	-28660	-41549	6584	-35244	-48133
BR0277434U0135	836	853	853	-17	0
BR0277435U0135	-27	134	396	-423	-262
BR0277438U0118	229	197	429	-200	-232
BR0277743U0118	164	200	224	-60	-24
BR0285817U0046	2161	2754	2415	-254	339
BR0285818U0046	783	736	795	-12	-59
BR0288640U0042	48070	49002	36240	11830	12762
BR0290058U0135	2623	2576	3182	-559	-606
BR0292372U0118	-107	0	131	-238	-131
BR0315088U0042	13358	12018	13332	26	-1314
BR0333447U0118	210	250	303	-93	-53
BR0342746U0118	-2	48	952	-954	-904
BR0343607U0118	228	153	804	-576	-651
BR0343608U0118	3231	4637	2563	668	2074
BR0369176U0042	4949	7222	3570	1379	3652

Tabela A.21: Programações automatizadas (PA) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	31661	41868	48248	-16587	-6380
BR0266820U0118	518	918	726	-208	192
BR0267894U0041	-302	686	505	-807	181
BR0267895U0041	-3905	-2438	2580	-6485	-5018
BR0267897U0041	-1334	-875	780	-2114	-1655
BR0268084U0042	5144	6165	4312	832	1853
BR0268097U0041	-4834	-3849	7320	-12154	-11169
BR0268098U0041	154721	171385	152905	1816	18480
BR0268114U0042	27083	47437	12050	15033	35387
BR0268143U0042	7461	10458	11130	-3669	-672
BR0268825U0042	9992	11896	12081	-2089	-185
BR0272083U0042	164386	186320	257220	-92834	-70900
BR0272431U0042	83594	78300	70799	12795	7501
BR0272785U0042	-30495	-26897	4180	-34675	-31077
BR0272786U0042	7461	9892	8490	-1029	1402
BR0272825U0042	6071	-1613	17180	-11109	-18793
BR0272826U0042	44898	46910	38417	6481	8493
BR0272831U0042	3094	2575	2970	124	-395
BR0272832U0042	16612	26137	8744	7868	17393
BR0272833U0042	18861	25258	13255	5606	12003
BR0272835U0041	-40445	-39838	2456	-42901	-42294
BR0277434U0135	765	747	960	-195	-213
BR0277435U0135	189	395	306	-117	89
BR0277438U0118	467	620	375	92	245
BR0277743U0118	235	244	244	-9	0
BR0285817U0046	2281	2619	2820	-539	-201
BR0285818U0046	750	1001	695	55	306
BR0288640U0042	12252	22894	38900	-26648	-16006
BR0290058U0135	3383	3834	3162	221	672
BR0292372U0118	47	117	82	-35	35
BR0315088U0042	14783	15514	14134	649	1380
BR0333447U0118	272	355	281	-9	74
BR0342746U0118	953	946	1012	-59	-66
BR0343607U0118	545	628	156	389	472
BR0343608U0118	1574	2109	3732	-2158	-1623
BR0369176U0042	450	818	4740	-4290	-3922

A.8 Rio Grande do Norte

Tabela A.22: Programações automatizadas (RN) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	51366	14884	65992	-14626	-51108
BR0266820U0118	1579	753	1344	235	-591
BR0267894U0041	-4226	-24627	28140	-32366	-52767
BR0267895U0041	23163	257	15030	8133	-14773
BR0267896U0041	760	-6386	10770	-10010	-17156
BR0267897U0041	4335	-8515	9120	-4785	-17635
BR0268084U0042	7246	-2261	8362	-1116	-10623
BR0268097U0041	2809	-1478	2190	619	-3668
BR0268098U0041	186196	-34657	172440	13756	-207097
BR0268118U0135	-1779	-2242	606	-2385	-2848
BR0268143U0042	41239	-14926	44110	-2871	-59036
BR0271620U0042	87648	-102076	134125	-46477	-236201
BR0271621U0042	316212	-98464	308750	7462	-407214
BR0272083U0042	765610	106567	424128	341482	-317561
BR0272785U0042	-22824	-30064	25930	-48754	-55994
BR0272786U0042	33705	14434	43470	-9765	-29036
BR0272831U0042	67415	-44884	82320	-14905	-127204
BR0272833U0042	200841	-98661	208855	-8014	-307516
BR0277434U0135	365	-150	392	-27	-542
BR0277438U0118	408	-215	375	33	-590
BR0277743U0118	690	398	476	214	-78
BR0285817U0046	3627	-248	3780	-153	-4028
BR0285818U0046	1181	-78	900	281	-978
BR0288640U0042	-246395	-245060	3780	-250175	-248840
BR0288641U0042	100347	-30426	104040	-3693	-134466
BR0315088U0042	4601	615	3558	1043	-2943
BR0333447U0118	704	193	779	-75	-586
BR0342746U0118	500	-341	1076	-576	-1417
BR0343607U0118	-1185	-695	709	-1894	-1404
BR0343608U0118	4000	-2378	4313	-313	-6691
BR0369176U0042	-8832	-11861	6210	-15042	-18071
BR0369179U0042	14288	-978	16500	-2212	-17478

Tabela A.23: Programações automatizadas (RN) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	76456	83664	66155	10301	17509
BR0266820U0118	978	1287	1604	-626	-317
BR0267894U0041	-7572	-6937	21892	-29464	-28829
BR0267895U0041	22616	31768	20610	2006	11158
BR0267896U0041	587	-1602	10860	-10273	-12462
BR0267897U0041	4367	2725	7928	-3561	-5203
BR0268084U0042	8012	8820	9048	-1036	-228
BR0268097U0041	737	2081	2190	-1453	-109
BR0268098U0041	160940	186721	172420	-11480	14301
BR0268118U0135	-1659	-1551	862	-2521	-2413
BR0268143U0042	51995	49206	42500	9495	6706
BR0271620U0042	96792	120461	127190	-30398	-6729
BR0271621U0042	342429	345419	331100	11329	14319
BR0272083U0042	81507	344384	313128	-231621	31256
BR0272785U0042	-27778	-28337	19370	-47148	-47707
BR0272786U0042	50540	63051	49290	1250	13761
BR0272831U0042	73942	84813	78020	-4078	6793
BR0272833U0042	188819	199197	178905	9914	20292
BR0277434U0135	237	309	409	-172	-100
BR0277438U0118	224	233	375	-151	-142
BR0277743U0118	108	206	486	-378	-280
BR0285817U0046	4430	3754	3510	920	244
BR0285818U0046	-1331	-2062	1050	-2381	-3112
BR0288640U0042	-245362	-239511	3930	-249292	-243441
BR0288641U0042	67318	70288	105630	-38312	-35342
BR0315088U0042	4239	4857	3660	579	1197
BR0333447U0118	855	977	724	131	253
BR0342746U0118	1680	1351	1260	420	91
BR0343607U0118	-554	61	1204	-1758	-1143
BR0343608U0118	6440	6563	3714	2726	2849
BR0369176U0042	-4498	-789	6000	-10498	-6789
BR0369179U0042	16936	14926	16080	856	-1154

Tabela A.24: Programações automatizadas (RN) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266629U0118	51079	75359	70168	-19089	5191
BR0266820U0118	1075	1867	1298	-223	569
BR0267894U0041	21774	31581	20300	1474	11281
BR0267895U0041	-9537	-11743	23370	-32907	-35113
BR0267896U0041	-1654	-698	11756	-13410	-12454
BR0267897U0041	9368	10566	8372	996	2194
BR0268084U0042	8126	10751	9242	-1116	1509
BR0268097U0041	-24364	-20652	2460	-26824	-23112
BR0268098U0041	141766	161945	162000	-20234	-55
BR0268118U0135	-360	-502	902	-1262	-1404
BR0268143U0042	23257	39152	38990	-15733	162
BR0271620U0042	99043	126967	236110	-137067	-109143
BR0271621U0042	379817	368491	301380	78437	67111
BR0272083U0042	259980	326327	498117	-238137	-171790
BR0272785U0042	-13366	-7779	19510	-32876	-27289
BR0272786U0042	30543	46460	45490	-14947	970
BR0272831U0042	54704	92242	69330	-14626	22912
BR0272833U0042	204797	216116	198685	6112	17431
BR0277434U0135	343	406	443	-100	-37
BR0277438U0118	269	394	430	-161	-36
BR0277743U0118	286	376	461	-175	-85
BR0285817U0046	2897	2870	3010	-113	-140
BR0285818U0046	-143	57	1410	-1553	-1353
BR0288640U0042	-9193	-3178	3870	-13063	-7048
BR0288641U0042	104319	107541	108840	-4521	-1299
BR0315088U0042	4008	4029	4290	-282	-261
BR0333447U0118	882	978	916	-34	62
BR0342746U0118	1132	1242	1318	-186	-76
BR0343607U0118	539	1124	1742	-1203	-618
BR0343608U0118	2041	-461	4250	-2209	-4711
BR0369176U0042	1263	5994	5730	-4467	264
BR0369179U0042	13901	18111	13680	221	4431

A.9 Paraíba

Tabela A.25: Programações automatizadas (PB) - T1/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266820U0118	-1376	-2663	1832	-3208	-4495
BR0267894U0041	30286	2539	43290	-13004	-40751
BR0267895U0041	5690	-8657	13740	-8050	-22397
BR0267896U0041	17948	2828	29010	-11062	-26182
BR0268084U0042	4968	-5558	8237	-3269	-13795
BR0268097U0041	504	-2081	7400	-6896	-9481
BR0268098U0041	149839	-26533	137456	12383	-163989
BR0268114U0042	32757	-42477	71912	-39155	-114389
BR0271620U0042	25849	-58421	74160	-48311	-132581
BR0271621U0042	123122	-117288	211045	-87923	-328333
BR0272083U0042	31525	-364727	340452	-308927	-705179
BR0272431U0042	35891	-38165	57893	-22002	-96058
BR0272785U0042	9522	-1911	29900	-20378	-31811
BR0272786U0042	39314	-5707	38540	774	-44247
BR0272824U0042	3825	1347	10800	-6975	-9453
BR0272825U0042	-7126	-66314	65770	-72896	-132084
BR0272826U0042	358	-49418	41580	-41222	-90998
BR0272831U0042	-30591	-51238	58740	-89331	-109978
BR0272832U0042	-35050	-77726	76755	-111805	-154481
BR0272833U0042	-25544	-111853	67880	-93424	-179733
BR0272835U0041	4764	-3465	2936	1828	-6401
BR0277434U0135	1374	520	1995	-621	-1475
BR0277435U0135	320	14	253	67	-239
BR0277438U0118	-293	-758	523	-816	-1281
BR0277743U0118	382	246	312	70	-66
BR0285817U0046	-119	-239	1810	-1929	-2049
BR0288640U0042	21143	18909	20360	783	-1451
BR0288641U0042	77658	8864	79370	-1712	-70506
BR0290058U0135	1593	-1669	2798	-1205	-4467
BR0292372U0118	27	-146	320	-293	-466
BR0333447U0118	-71	-1792	1365	-1436	-3157
BR0342746U0118	1046	-1173	1776	-730	-2949
BR0343607U0118	-123	-350	214	-337	-564
BR0343608U0118	818	-392	2290	-1472	-2682
BR0367664U0075	129	9	128	1	-119

Tabela A.26: Programações automatizadas (PB) - T2/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266820U0118	937	1029	1799	-862	-770
BR0267894U0041	18129	25807	34444	-16315	-8637
BR0267895U0041	15715	21786	14130	1585	7656
BR0267896U0041	13753	15399	32790	-19037	-17391
BR0268084U0042	8019	9017	9098	-1079	-81
BR0268097U0041	6231	9371	6140	91	3231
BR0268098U0041	196987	187558	152488	44499	35070
BR0268114U0042	80229	78857	74970	5259	3887
BR0271620U0042	85469	82549	76020	9449	6529
BR0271621U0042	249436	252633	221450	27986	31183
BR0272083U0042	366977	374398	360865	6112	13533
BR0272431U0042	60884	68665	59148	1736	9517
BR0272785U0042	-8049	-8906	30910	-38959	-39816
BR0272786U0042	36475	39911	39660	-3185	251
BR0272824U0042	8289	13418	11100	-2811	2318
BR0272825U0042	70119	70715	63615	6504	7100
BR0272826U0042	33982	40707	38195	-4213	2512
BR0272831U0042	81263	79481	51934	29329	27547
BR0272832U0042	90105	89873	68475	21630	21398
BR0272833U0042	50653	52879	66645	-15992	-13766
BR0272835U0041	-2100	-1909	1870	-3970	-3779
BR0277434U0135	1595	1781	2006	-411	-225
BR0277435U0135	108	212	243	-135	-31
BR0277438U0118	184	247	555	-371	-308
BR0277743U0118	325	340	327	-2	13
BR0285817U0046	2238	1591	2005	233	-414
BR0288640U0042	16448	19633	22522	-6074	-2889
BR0288641U0042	87993	89570	83759	4234	5811
BR0290058U0135	2876	3078	2944	-68	134
BR0292372U0118	225	214	271	-46	-57
BR0333447U0118	1436	1453	1283	153	170
BR0342746U0118	1640	2143	1801	-161	342
BR0343607U0118	116	132	302	-186	-170
BR0343608U0118	3201	3306	2290	911	1016
BR0367664U0075	135	174	123	12	51

Tabela A.27: Programações automatizadas (PB) - T3/2018

CATMAT	PATMM	PATMS	QRDM	MMvQRDM	MSvQRDM
BR0266820U0118	2720	2311	1985	735	326
BR0267894U0041	52715	42661	41068	11647	1593
BR0267895U0041	595	2159	13860	-13265	-11701
BR0267896U0041	25624	26133	34610	-8986	-8477
BR0268084U0042	8568	9708	9511	-943	197
BR0268097U0041	7272	7561	7545	-273	16
BR0268098U0041	176094	181231	152479	23615	28752
BR0268114U0042	75838	83258	33440	42398	49818
BR0271620U0042	78019	88078	82696	-4677	5382
BR0271621U0042	233848	255666	245785	-11937	9881
BR0272083U0042	271697	328088	405102	-133405	-77014
BR0272431U0042	59544	60932	64737	-5193	-3805
BR0272785U0042	26701	34942	27940	-1239	7002
BR0272786U0042	44402	35607	44070	332	-8463
BR0272824U0042	5338	10133	12060	-6722	-1927
BR0272825U0042	65857	68746	69620	-3763	-874
BR0272826U0042	37887	40325	39435	-1548	890
BR0272831U0042	32686	20426	53100	-20414	-32674
BR0272832U0042	40031	57976	38280	1751	19696
BR0272833U0042	52543	71071	44370	8173	26701
BR0272835U0041	447	360	2036	-1589	-1676
BR0277434U0135	2275	2378	2183	92	195
BR0277435U0135	314	242	222	92	20
BR0277438U0118	557	644	600	-43	44
BR0277743U0118	399	422	338	61	84
BR0285817U0046	2654	2464	2445	209	19
BR0288640U0042	12868	16108	22562	-9694	-6454
BR0288641U0042	72103	70888	89212	-17109	-18324
BR0290058U0135	2837	3270	3120	-283	150
BR0292372U0118	412	454	393	19	61
BR0333447U0118	1368	1559	1391	-23	168
BR0342746U0118	1829	1929	1703	126	226
BR0343607U0118	313	329	276	37	53
BR0343608U0118	-2727	-2675	2984	-5711	-5659
BR0367664U0075	79	105	109	-30	-4

Apêndice B

Código R (modelos estatísticos tradicionais)

```

library(forecast)
library(tseries)
library(urca)
library(pracma)
library(xts)
library(dplyr)
library(tidyr)

# Cox-Stuart Test
o.Cox.Stuart.test <- function(x, alternative=c("two.sided" ,"left.sided", "right.sided")){

  dname <- deparse(substitute(x))

  alternative <- match.arg(alternative)

  stopifnot(is.numeric(x))

  n0 <- length(x)

  if (n0 < 2){
    stop("sample size must be greater than 1")
  }

  n0 <- round(length(x)) %% 2

  if (n0 == 1) {
    remove <- (length(x)+1)/2
    x <- x[ -remove ]
  }

  half <- length(x)/2
  x1 <- x[1:half]
  x2 <- x[(half+1):(length(x))]
  n <- sum((x2-x1)!=0)
  t <- sum(x1<x2)

  if (alternative == "left.sided") {
    p.value <- pbinom(t, n, 0.5)
    alternative <- "decreasing trend"
  }

  if (alternative == "right.sided"){
    p.value <- 1-pbinom(t-1, n, 0.5)
    alternative <- "increasing trend"
  }

  if (alternative == "two.sided"){
    alternative <- "any type of trend, either decreasing or increasing"
    if (1-pbinom(t-1, n, 0.5) == pbinom(t, n, 0.5)) {
      pdist <- dbinom(0:n, n, 0.5)
      p.value <- sum(pdist[pdist <= t+1])
    }
    else {
      p.value <- 2*min( 1-pbinom(t-1, n, 0.5), pbinom(t, n, 0.5))
    }
  }

  rval <- list(statistic=c("Test Statistic"=t),
              alternative=alternative,
              p.value=p.value,
              method="Cox & Stuart Test for Trend Analysis",
              parameter=c("Number of Untied Pairs"=n),
              data.name=dname)

  class(rval) <- "htest"
  return(rval)
}

# Mean Absolute Error
mae_cal <- function(outsample, forecasts){
  #Used to estimate MAE
  outsample <- as.numeric(outsample) ; forecasts<-as.numeric(forecasts)
  mae <- as.matrix(abs(outsample-forecasts))
  #add a column average MAE
  mae <- as.numeric(round(rbind(mae,mean(mae)),3))
  return(mae)
}
# end of mae_cal() function

# Test series seasonality (M3 competition)
seasonalityTest <- function(input, ppy){
  #Used to determine whether a time series is seasonal
  tcrit <- 1.645
  if (length(input)<3*ppy){
    test_seasonal <- FALSE
  } else{
    xacf <- acf(input, plot = FALSE)$acf[-1, 1, 1]
    clim <- tcrit/sqrt(length(input)) * sqrt(cumsum(c(1, 2 * xacf^2)))
    test_seasonal <- ( abs(xacf[ppy]) > clim[ppy] )
    if (is.na(test_seasonal)==TRUE){ test_seasonal <- FALSE }
  }

  return(test_seasonal)
}
# end of seasonalityTest() function

```

```

# Function to train models. Return models forecast object and additional information
statModels <- function(input, des_input, des_det_input, fh) {
  # Naive, SNaive and Theta
  fcast.naive <- naive(input, h=fh, level=c(50,60,70,80,95))
  fcast.snaive <- snaive(input, h=fh, level=c(50,60,70,80,95))
  fcast.thetaf <- thetaf(des_input, h=fh, level=c(50,60,70,80,95))

  # Methods which requires a seasonally adjusted component
  fcast.ses <- ses(des_input, h=fh, level=c(50,60,70,80,95))
  fcast.holt.linear <- holt(des_input, h=fh, damped=FALSE, level=c(50,60,70,80,95))
  fcast.holt.damped <- holt(des_input, h=fh, damped=TRUE, level=c(50,60,70,80,95))

  # Methods which deals with trended and/or seasonal time series
  fcast.holt.winters <- hw(input, h=fh, level=c(50,60,70,80,95))
  fcast.arima <- forecast(auto.arima(input, ic='aicc', stepwise=FALSE), h=fh, level=c(50,60,70,80,95))
  fcast.ets <- forecast(ets(input, ic='aicc'), h=fh, level=c(50,60,70,80,95))

  # List containing all models forecast objects
  return(list(NAIVE=fcast.naive, SNAIVE=fcast.snaive, SES=fcast.ses,
             HOLT_LINEAR=fcast.holt.linear, HOLT_DAMPED=fcast.holt.damped,
             THETA=fcast.thetaf, HOLT_WINTERS = fcast.holt.winters,
             ARIMA=fcast.arima, ETS=fcast.ets))
}
# end of statModels() function

```

```

# Function to load LSTM results from CSV files
loadLSTMResults <- function(UF) {
  switch(UF,
    DF = {ic_60 <- read.csv('LSTM_BOpt_DF_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_DF_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    CE = {ic_60 <- read.csv('LSTM_BOpt_CE_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_CE_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    PE = {ic_60 <- read.csv('LSTM_BOpt_PE_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_PE_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    AL = {ic_60 <- read.csv('LSTM_BOpt_AL_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_AL_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    AP = {ic_60 <- read.csv('/LSTM_BOpt_AP_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_AP_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    TO = {ic_60 <- read.csv('LSTM_BOpt_TO_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_TO_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    PA = {ic_60 <- read.csv('/LSTM_BOpt_PA_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_PA_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    RN = {ic_60 <- read.csv('LSTM_BOpt_RN_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('LSTM_BOpt_RN_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    PB = {ic_60 <- read.csv('/LSTM_BOpt_PB_FCAST_IC60_INF_SUP.csv', stringsAsFactors = FALSE)
          mae <- read.csv('/LSTM_BOpt_PB_TOTAL_MAE.csv', stringsAsFactors = FALSE)
          },
    stop("Enter something that switches me!")
  )

  ic_60 <- ic_60 %>% select(-c(X)) %>% t()
  mae <- mae %>% select(-c(X)) %>% t()

  return(list("ic60" = ic_60, "mae" = mae))
}
# end of loadLSTMResults() function

```

```

#####
# LOAD DATA AND VARIABLES DEFINITION
#####

# read medicines Time Series from disk
xts_list_med <- readRDS("listMedicinesXTS_teste.rds")

# read vector of index of medicines with best information quality (no missing values)
idxListMedQual <- readRDS("indexOfQualityMedicines_teste.rds")

# UFs vector (Brazilian States)
UFs_vec <- c("DF", "CE", "PE", "AL", "AP", "TO", "PA", "RN", "PB")

# forecast horizon
fh <- 4

# frequency of the series
frq <- 12

```

```

# models' names
namesModels <- c("NAIVE", "SNAIVE", "SES", "HOLT_LINEAR", "HOLT_DAMPED",
                "THETA", "HOLT_WINTERS", "ARIMA", "ETS", "LSTM")

# list to store 2018 Quarter Results
quarterResults <- list()

# list to store UF results (MAE and forecasts)
ufResults <- list()

# array to store MAE for each model
totalMAE <- array(NA, dim = c(length(namesModels), fh+1)) # fh + 1 (4 points + mean)

# array to store Forecasts for each model
# 11 [= 5 IC (50,60,70,80,95) * 2 (High,Low) + 1 (point forecast)]
totalFCAST <- array(NA, dim = c(fh, 11, length(namesModels)))

# 5 aggregate forecasts (50,60,70,80,95) * 2 (high,low)
aggFCAST <- array(NA, dim = c(2, 5, length(namesModels)))

# list to store time series characteristics and results
tsMedResults <- list()

# number of states you want to evaluate
n_UFs = length(UFs_vec)

# decomposition method to be used (STL or CLASSICAL)
decompMethod = "STL"

# Save plots (TRUE) or not (FALSE)
savePlots = FALSE

# First Year
firstYear = 2013
firstMonth = 1

# Last Year
lastYear = 2018
lastMonth = 10

# number of quarters of 2018 to evaluate (1,2 or 3)
n_Qs = 3

#####
# MAIN LOOP
# System.time() used to estimate computational cost in terms of time
#####
system.time (
  # Loop to evaluate forecast error of "n_Qs" quarters of 2018 (Jan-Mar + Apr-Jun + Jul-Sep)
  for (quarter in 1:n_Qs) {

    print(paste0("Q",quarter))

    # Loop to run over all UFs
    for (uf in 1:n_UFs) { # ("DF", "CE", "PE", "AL", "AP", "TO", "PA", "RN", "PB")

      # print UF
      print(paste0("UF: ",UFs_vec[uf]))

      # load Python LSTM results from .csv files
      lstm_results <- loadLSTMResults(UFs_vec[uf])
      lstm_fcast_ic_60 <- lstm_results$ic60
      lstm_mae <- lstm_results$mae

      # number of drugs (time-series) of each UF
      nmed <- length(idxListMedQual[[uf]]$IDX_MED_QUAL)

      # ARIMA_MS aggregate IC 60 predictions for all drugs
      switch(quarter,
            arima_MS_pred <- xts_list_med[[uf]]$ARIMA_MS_PREV[idxListMedQual[[uf]]$IDX_MED_QUAL,"Q1"],
            arima_MS_pred <- xts_list_med[[uf]]$ARIMA_MS_PREV[idxListMedQual[[uf]]$IDX_MED_QUAL,"Q2"],
            arima_MS_pred <- xts_list_med[[uf]]$ARIMA_MS_PREV[idxListMedQual[[uf]]$IDX_MED_QUAL,"Q3"],
            arima_MS_pred <- xts_list_med[[uf]]$ARIMA_MS_PREV[idxListMedQual[[uf]]$IDX_MED_QUAL,"Q4"])

      # Stock information of drugs
      stockMed <- xts_list_med[[uf]]$STOCK[quarter,idxListMedQual[[uf]]$IDX_MED_QUAL]

      # Loop to run over all medicines
      for (med in 1:nmed) {

        # print Medicine
        print(paste0("Drug: ",toString(med)))

        # index of the medicine
        idx_MED <- idxListMedQual[[uf]]$IDX_MED_QUAL[med]

        # drug time series as a ts object
        ts_MED <- ts(coredata(xts_list_med[[uf]]$XTS_MED[,idx_MED]),[1], start=firstYear,
                    end=c(lastYear,lastMonth), frequency=frq)

```

```

#Train/Test Split
ts_MED_train <- ts_MED %>% head(n=(lastYear-firstYear)*12-1+(quarter-1)*3)
ts_MED_test <- ts_MED %>% head(n=(lastYear-firstYear)*12-1+(quarter-1)*3+fh) %>% tail(fh)

if (quarter == 1) #Q1
{
  # Forecast Jan-Mar
  str = c( paste0("dec/",toString(lastYear-1)),
           paste0("jan/",toString(lastYear)),
           paste0("fev/",toString(lastYear)),
           paste0("mar/",toString(lastYear)),
           "MAE-avg"
         )
} else if (quarter == 2) { #Q2
  # Forecast Apr-Jun
  str = c( paste0("mar/",toString(lastYear)),
           paste0("apr/",toString(lastYear)),
           paste0("may/",toString(lastYear)),
           paste0("jun/",toString(lastYear)),
           "MAE-avg"
         )
} else { #Q3
  # Forecast Jul-Sep
  str = c( paste0("jun/",toString(lastYear)),
           paste0("jul/",toString(lastYear)),
           paste0("aug/",toString(lastYear)),
           paste0("sep/",toString(lastYear)),
           "MAE-avg"
         )
}

# Save time series characteristics (Decomposition + ACF/PACF + Trend and seasonality strength)
# Explore time series characteristics (Stationarity, Trend, Seasonality)
if (decompMethod == "CLASSICAL") {
  ts_MED_train %>% decompose() -> ts_MED_decomp
} else { # STL decomposition
  ts_MED_train %>% stl(s.window=5, robust=TRUE) -> ts_MED_decomp
}

#Save decomposition plot to file
if (savePlots) {
  ggsave(
    plot = autoplot(ts_MED_decomp) +
      ggtitle(paste0(xts_list_med[[uf]]$UF, "-", xts_list_med[[uf]]$COD_MED[idx_MED,1])),
    filename = paste0(xts_list_med[[uf]]$UF, "-", xts_list_med[[uf]]$COD_MED[idx_MED,1], "-DECOMPOSE.png")
  )
}

# Unit Root Test (Stationarity)
# A number of unit root tests are available, which are based on different assumptions and may
# lead to conflicting answers. In our analysis, we use the
# Kwiatkowski-Phillips-Schmidt-Shin (KPSS) test (Kwiatkowski, Phillips, Schmidt, & Shin, 1992).
# In this test, the null hypothesis is that the data are stationary, and we look for evidence
# that the null hypothesis is false. Consequently, small p-values (e.g., less than 0.05)
# suggest that differencing is required.

# H0 = data are stationary
# HA = data are not stationary
# test statistic > 0.05 critical value => rejects H0

tsIsStationary <- TRUE
tsNdiffs <- 0
unitRootTest <- ur.kpss(ts_MED_train)
if ( unitRootTest@teststat > unitRootTest@cval[2]) { # not stationary
  tsNdiffs = ndiffs(ts_MED_train)
  print(paste0("no stationary -> ndiffs = ",toString(tsNdiffs)))
  tsIsStationary <- FALSE
  ts_MED_train %>% diff(differences=tsNdiffs) -> ts_MED_train_diff
} else {
  ts_MED_train_diff <- ts_MED_train
}

# Save ACF/PACF
if (savePlots) {
  #ACF
  ggsave(
    plot = ggAcf(ts_MED, lag=36) +
      ggtitle(paste0(xts_list_med[[uf]]$UF, "-", xts_list_med[[uf]]$COD_MED[idx_MED,1])),
    filename = paste0(xts_list_med[[uf]]$UF, "-", xts_list_med[[uf]]$COD_MED[idx_MED,1], "-ACF.png")
  )

  #PACF
  ggsave(
    plot = ggPacf(ts_MED, lag=36) +
      ggtitle(paste0(xts_list_med[[uf]]$UF, "-", xts_list_med[[uf]]$COD_MED[idx_MED,1])),
    filename = paste0(xts_list_med[[uf]]$UF, "-", xts_list_med[[uf]]$COD_MED[idx_MED,1], "-PACF.png")
  )
}

# Seasonality checking using ACF
# Steps in case seasonality is present

```

```

# 1. Series decomposition
# 2. Seasonally adjust series
# 3. Calculates seasonal index
# 4. Fit models and make forecasts using the adjusted series
# 6. Adjusts predictions using the seasonal index
tsHasSeasonality <- FALSE
tsFseasonality <- NULL
tsHasSeasonality <- seasonalityTest(ts_MED_train, frq)
if (tsHasSeasonality) {
  print("seasonality detected ...")
  # Seasonality strength (see Hyndman`s chapter 5)
  tsFseasonality = max(0, 1-var(remainder(ts_MED_decomp))/var(seasonal(ts_MED_decomp) + remainder(ts_MED_decomp)))
  tsNSdiffs = nsdiffs(ts_MED_train)
  ts_MED_train_deseason <- seasadj(ts_MED_decomp)
  SIout <- sindexf(ts_MED_decomp, fh)
}
else {
  ts_MED_train_deseason <- ts_MED_train
  tsNSdiffs <- 0
  SIout <- rep(1, fh)
}

# Trend
# Cox-Stuart statistical test to check trend
# H0 = no trend
# HA = trend
# p-value < 0.05 rejects H0
tsHasTrend <- FALSE
tsFtrend <- NULL
if (o.Cox.Stuart.test(ts_MED_train_deseason, alternative = "two.sided")$p.value < 0.05) {
  print("trend detected ...")
  tsHasTrend <- TRUE
  # Trend strength (see Hyndman`s chapter 5)
  tsFtrend = max(0, 1-var(remainder(ts_MED_decomp))/var(trendcycle(ts_MED_decomp) + remainder(ts_MED_decomp)))
  # Detrend the series
  coeff <- polyfit(c(1:length(ts_MED_train_deseason)), ts_MED_train_deseason, n=1)
  ts_MED_deseason_detrended <- ts_MED_train_deseason - (coeff[1]*c(1:length(ts_MED_train_deseason))) + coeff[2]
}
else {
  ts_MED_deseason_detrended <- ts_MED_train_deseason
}

# Fit models and forecasting
models <- statModels(input = ts_MED_train,
                    des_input = ts_MED_train_deseason,
                    des_det_input = ts_MED_deseason_detrended,
                    fh = fh)

# Adjust Forecasts and calculate MAE
for (nmodels in 1:length(namesModels)){
  # Add seasonality back to forecasts: point and IC(50,60,70,80,95)
  if (nmodels %in% c(3,4,5,6)) { # SES, Holt-Linear, Holt-Damped and Theta
    models[[nmodels]]$mean <- models[[nmodels]]$mean + SIout
    models[[nmodels]]$lower <- models[[nmodels]]$lower + cbind(SIout, SIout, SIout, SIout, SIout)
    models[[nmodels]]$upper <- models[[nmodels]]$upper + cbind(SIout, SIout, SIout, SIout, SIout)
    models[[nmodels]]$x <- ts_MED_train
  }

  # MAE
  if (nmodels != length(namesModels)) { # all models except LSTM
    # Update matrix of forecasts
    totalFCAST[, nmodels] <- apply(as.matrix(as.data.frame(models[[nmodels]])), 2, round)

    # Mean Absolute Error
    totalMAE[nmodels,] <- mae_cal(ts_MED_test, models[[nmodels]]$mean)
  }
  else {
    # LSTM MAE (from CSV files)
    switch(quarter,
          totalMAE[length(namesModels),] <- lstm_mae[med,],
          totalMAE[length(namesModels),] <- lstm_mae[med+nmed,],
          totalMAE[length(namesModels),] <- lstm_mae[med+2*nmed,]
        )
  }
}

# define row and column labels of totalMAE and totalFCAST
dimnames(totalMAE) <- list(namesModels, str)
dimnames(totalFCAST) <- list(str[1:fh],
                             c("Point", "Lo 50", "Hi 50", "Lo 60", "Hi 60", "Lo 70", "Hi 70",
                               "Lo 80", "Hi 80", "Lo 95", "Hi 95"),
                             namesModels)

# Identify the winner model(s)
winnerModel = which(totalMAE[,5] == min(totalMAE[,5]))

# Calculate aggregate forecasts (Hyndman 12.5 online book)
for (nmodels in 1:length(namesModels)){

```

```

if (!(nmodels %in% c(1,2,6,10))) { # all models except naive, snaive, theta and lstm
# Simulate 10000 future sample paths
fit <- models[[nmodels]]$model
nsim <- 10000
sim <- numeric(nsim)
for(i in seq_len(nsim))
  sim[i] <- sum(simulate(fit, future=TRUE, nsim=nsim))
temp <- cbind(quantile(sim, prob=c(0.25, 0.75)), # IC 50%
              quantile(sim, prob=c(0.2, 0.8)), # IC 60%
              quantile(sim, prob=c(0.15, 0.85)), # IC 70%
              quantile(sim, prob=c(0.1, 0.9)), # IC 80%
              quantile(sim, prob=c(0.025, 0.975))) # IC 95%
}
else if ((nmodels %in% c(1,2,6))) {
temp <- cbind(c(sum(totalFCAST[, ,nmodels][, "Lo 50"]), sum(totalFCAST[, ,nmodels][, "Hi 50"])),
              c(sum(totalFCAST[, ,nmodels][, "Lo 60"]), sum(totalFCAST[, ,nmodels][, "Hi 60"])),
              c(sum(totalFCAST[, ,nmodels][, "Lo 70"]), sum(totalFCAST[, ,nmodels][, "Hi 70"])),
              c(sum(totalFCAST[, ,nmodels][, "Lo 80"]), sum(totalFCAST[, ,nmodels][, "Hi 80"])),
              c(sum(totalFCAST[, ,nmodels][, "Lo 95"]), sum(totalFCAST[, ,nmodels][, "Hi 95"])))
}
else { # LSTM
# update aggFCAST with LSTM IC 60 aggregate forecasts (loaded above from .csv file)
temp <- cbind(c(NA,NA),
              lstm_fcst_ic_60[med, c(quarter*2-1,quarter*2)],
              c(NA,NA),
              c(NA,NA),
              c(NA,NA))
}
aggFCAST[, ,nmodels] <- round(temp)
dimnames(aggFCAST[, ,nmodels]) <- list(c("Low", "High"), c("IC 50", "IC 60", "IC 70", "IC 80", "IC 95"))
}

# Update drugs' attributes list
tsMedResults[[med]] = list(code = xts_list_med[[uf]]$COD_MED[idx_MED,1],
                           name = xts_list_med[[uf]]$COD_MED[idx_MED,2],
                           isTrendy = tsHasTrend,
                           FT = tsFtrend,
                           isSeasonal = tsHasSeasonality,
                           FS = tsFseasonality,
                           isStationary = tsIsStationary,
                           n_diffs = tsNdiffs,
                           ns_diffs = tsNSdiffs,
                           models = models,
                           nameModels = namesModels,
                           winnerModel = winnerModel,
                           agg_predictions = aggFCAST,
                           predictions = totalFCAST,
                           predictions_ARIMA_MS = arima_MS_pred[med],
                           real_demand = sum(ts_MED_test[2:4]),
                           stock = stockMed[med],
                           MAE = totalMAE)

} # end medicines loop

# update global results list
ufResults[[uf]] <- list(UF = UFs_vec[uf],
                       MED = tsMedResults)

# empty the medicines list before moving forward to the next UF
tsMedResults <- list()

} # end of UF loop

quarterResults[[quarter]] <- list(Q = quarter,
                                  UF = ufResults)

} # end of Quarter loop

) # end of system.time

# save results list on disk
saveRDS(quarterResults, "StatModelsResults.rds")

```

Apêndice C

Código Python (Rede LSTM)

```

from hyperopt import fmin, tpe, hp, STATUS_OK, Trials, space_eval
import numpy as np
from pandas import read_csv, to_datetime, DataFrame, concat
from sklearn.metrics import mean_absolute_error
from sklearn.preprocessing import MinMaxScaler
from keras.models import Model
from keras.layers import Input
from keras.layers import Dense
from keras.layers import RepeatVector
from keras.layers.wrappers import TimeDistributed
from keras.layers import Dropout
from keras.layers.recurrent import LSTM
import time

# difference dataset
def difference(data, order):
    return [data[i] - data[i - order] for i in range(order, len(data))]

# mean absolute error
def measure_mae(actual, predicted):
    return mean_absolute_error(actual, predicted)

# forecast with the best fit model
def model_predict(model, X_test, n_steps_in, n_features, n_diff):

    correction = 0.0
    if n_diff > 0:
        correction = X_test[-n_diff]
        X_test = difference(X_test, n_diff)
    # reshape sample into [samples, timesteps, features]
    # x_input = array(history[-n_input:]).reshape((1, n_input, 1))
    X_test = X_test.reshape((1, n_steps_in, n_features))
    # forecast
    yhat = model.predict(X_test, verbose=0)
    return correction + yhat[0]

def data(): #uf,quarters,scale,n_steps_in,n_steps_out,n_test,n_features

    file = None

    # load dataset
    if uf=='AL':
        file = 'tsAL.csv'
    elif uf=='AP':
        file = 'tsAP.csv'
    elif uf=='CE':
        file = 'tsCE.csv'
    elif uf=='DF':
        file = 'tsDF.csv'
    elif uf=='PA':
        file = 'tsPA.csv'
    elif uf=='PB':
        file = 'tsPB.csv'
    elif uf=='PE':
        file = 'tsPE.csv'
    elif uf=='RN':
        file = 'tsRN.csv'
    elif uf=='TO':
        file = 'tsTO.csv'

    ts_df = read_csv(file, sep=';')
    ts_df['Unnamed: 0'] = to_datetime(ts_df['Unnamed: 0'])
    ts_df.index = ts_df['Unnamed: 0']
    del ts_df['Unnamed: 0']

    # Retrieve data from all drugs
    if quarter==1:
        tsdata = ts_df['1/1/2013':'3/1/2018'].iloc[:,:].values.astype('float64')
    elif quarter==2:
        tsdata = ts_df['1/1/2013':'6/1/2018'].iloc[:,:].values.astype('float64')
    elif quarter==3:
        tsdata = ts_df['1/1/2013':'9/1/2018'].iloc[:,:].values.astype('float64')

    # Number of features (number of multiple inputs or drugs)
    n_features = tsdata.shape[1] # or

    # prepare data
    # rescale values to -1, 1
    if scale:
        scaler = MinMaxScaler(feature_range=(-1, 1))
        scaled_data = scaler.fit_transform(tsdata)
    else:
        scaled_data = tsdata

    # split into train and test samples
    X, y = list(), list()

    for i in range(len(scaled_data)):
        # find the end of this pattern
        end_ix = i + n_steps_in
        out_end_ix = end_ix + n_steps_out
        # check if we are beyond the sequence
        if out_end_ix > len(scaled_data):

```

```

        break
    # gather input and output parts of the pattern
    seq_x, seq_y = scaled_data[i:end_ix], scaled_data[end_ix:out_end_ix]
    X.append(seq_x)
    y.append(seq_y)

X = np.array(X)
y = np.array(y)

# train and test samples
X_train, y_train = X[0:-n_test, :, :], y[0:-n_test, :, :]
X_test, y_test = X[-n_test:, :, :], y[-n_test:, :, :]

return X_train, X_test, y_train, y_test, scaler, n_features, ts_df.columns #CATMAT

def objective(args):

    n_units_1 = args['n_units_1']
    n_units_2 = args['n_units_2']
    epochs = args['epochs']
    drop_rate = args['dropout']

    #define model
    #flag training='True' in Dropout layer allows for dropout at testing phase (MC Dropout)
    inputs = Input(shape=(n_steps_in, n_features))
    drop_1 = Dropout(drop_rate)(inputs, training=True)
    lstm_1 = LSTM(n_units_1, activation='relu')(drop_1)
    drop_2 = Dropout(drop_rate)(lstm_1, training=True)
    repeat_vector = RepeatVector(n_steps_out)(drop_2)
    lstm_2 = LSTM(n_units_2, activation='relu', return_sequences=True)(repeat_vector)
    drop_3 = Dropout(drop_rate)(lstm_2, training=True)
    outputs = TimeDistributed(Dense(n_features))(drop_3)
    model = Model(inputs=inputs, outputs=outputs)

    # compile model
    model.compile(optimizer='adam', loss='mae', metrics=['mae'])

    # fit model
    model.fit(X_train,
              y_train,
              #epochs={choice([50, 100, 200, 500, 1000])},
              epochs=epochs,
              #callbacks=callbacks, # Early stopping
              verbose=0)

    score, acc = model.evaluate(X_test, y_test, verbose=0)

    return {'loss': acc, 'status': STATUS_OK, 'model': model}

def unpack_hyperopt_vals(vals):
    """
    Unpack values from a hyperopt return dictionary where values are wrapped in a list.
    :param vals: dict
    :return: dict
        copy of the dictionary with unpacked values
    """
    assert isinstance(vals, dict), "Parameter must be given as dict."
    ret = {}
    for k, v in list(vals.items()):
        try:
            ret[k] = v[0]
        except (TypeError, IndexError):
            ret[k] = v
    return ret

def eval_hyperopt_space(space, vals):
    """
    Evaluate a set of parameter values within the hyperopt space.
    Optionally unpacks the values, if they are wrapped in lists.
    :param space: dict
        the hyperopt space dictionary
    :param vals: dict
        the values from a hyperopt trial
    :return: evaluated space
    """
    unpacked_vals = unpack_hyperopt_vals(vals)
    return space_eval(space, unpacked_vals)

#####
# MAIN LOOP
# Change ufs tuple accordingly before running
# Possible values: "DF", "CE", "PE", "AL", "AP", "PA", "TO", "RN" or "PB"
#
#####
if __name__ == "__main__":

    np.random.seed(28042019) # for reproducibility

    list_tsteps = list()

    df_MAE, df_totalMAE = DataFrame(), DataFrame()

```

```

df_FCAST, df_FCAST_IC_60_INF, df_FCAST_IC_60_SUP = DataFrame(), DataFrame(), DataFrame()

quarters = tuple([1,2,3])
ufs = tuple(['DF'])
tsteps_in = tuple([1,3,6,12])

n_steps_out = 4
n_test = 1
n_evals = 10
scale = True

# Parameter Space
space_params = {'n_units_1': hp.choice('n_units_1', [12,32,64,128]),
                'n_units_2': hp.choice('n_units_2', [12,32,64,128]),
                'epochs' : hp.choice('epochs', [100,200,500,1000,1500]),
                'dropout' : hp.choice('dropout', [0.005,0.01,0.05,0.1])}

# main loop
start = time.time()
for quarter in quarters:
    for uf in ufs:
        for n_steps_in in tsteps_in:

            X_train, X_test, y_train, y_test, scaler, n_features, catmat = data()

            trials=Trials()
            best_run = fmin(objective,
                           space=space_params,
                           algo=tpe.suggest,
                           max_evals=n_evals,
                           trials=trials)

            print('Optimizing ....')

            # get the best model
            # copied from https://github.com/maxpumperla/hyperas/blob/master/hyperas/optim.py
            best_model = None
            for trial in trials:
                vals = trial.get('misc').get('vals')
                # unpack the values from lists without overwriting the mutable dict within 'trial'
                unpacked_vals = unpack_hyperopt_vals(vals)
                # identify the best_run (comes with unpacked values from the hyperopt
                # function `base.Trials.argmin`)
                if unpacked_vals == best_run and 'model' in trial.get('result').keys():
                    best_model = trial.get('result').get('model')

            print('UF: ' + ufs[0] + ', ' + 'Quarter: ' + str(quarter) + ', ' + 'Time Steps: ' + str(n_steps_in))
            best_params = space_eval(space_params, trials.argmin)
            print(best_params)

            # Monte Carlo Dropout for measuring uncertainty (see Yarın Gal 2016 thesis)
            T = 10000
            y_hat = np.array([best_model.predict(X_test, verbose=0) for _ in range(T)])

            #reshape y_hat from 4D to 3D (10000 x 4 x med)
            y_hat = y_hat.reshape((y_hat.shape[0], y_hat.shape[2], y_hat.shape[3]))

            #reshape y_test from 3D to 2D
            y_test = y_test.reshape((y_test.shape[1], y_test.shape[2]))

            # invert scale
            if scale:
                y_hat_temp = np.array([scaler.inverse_transform(y_hat[i,:,:]) for i in range(T)])
                y_hat = y_hat_temp
                y_test = scaler.inverse_transform(y_test)

            # y_hat MEAN (4 x med)
            y_hat_mean = np.mean(y_hat, axis=0)

            # y_hat AGGREGATE (10000 x med)
            y_hat_agg = y_hat.sum(axis=1)

            # y_hat AGGREGATE mean (1 x med)
            y_hat_agg_mean = np.mean(y_hat_agg, axis=0)

            # y_hat AGGREGATE IC 60% (2 x med)
            y_hat_ic_60_agg = np.quantile(y_hat_agg, q=[0.2,0.8], axis=0)

            # Mean Absolute Error
            error_avg = mean_absolute_error(y_hat_mean, y_test, multioutput = 'raw_values')
            error_avg = error_avg.round(decimals=2)

            error_per_fcast = abs(y_hat_mean-y_test)
            error_per_fcast = error_per_fcast.round(decimals=2)

```

```

# concatenate forecast errors for each month in horizon and average error
error_total = np.concatenate([error_per_fcast, error_avg.reshape(1,n_features)], axis=0)

# save best hyperparameters
list_tsteps.append({'QUARTER':quarter,
                   'UF':uf,
                   'STEPS_IN':n_steps_in,
                   'EPOCHS':best_params['epochs'],
                   'N_UNITS_1':best_params['n_units_1'],
                   'N_UNITS_2':best_params['n_units_2'],
                   'DROPOUT':best_params['dropout']})

# update MAE and totalMAE
df_MAE = concat([df_MAE,DataFrame(error_avg)], axis=1)
df_totalMAE = concat([df_totalMAE,DataFrame(error_total)], axis=0)

# update FCAST_MEAN
df_FCAST = concat([df_FCAST,DataFrame(y_hat_mean)], axis=1)

# update FCAST_IC_60_SUP
df_FCAST_IC_60_SUP = concat([df_FCAST_IC_60_SUP, DataFrame(y_hat_ic_60_agg[1,:])], axis=1)

# update FCAST_IC_60_INF
df_FCAST_IC_60_INF = concat([df_FCAST_IC_60_INF, DataFrame(y_hat_ic_60_agg[0,:])], axis=1)

print('Total optimization time: %.2f seconds' %(time.time()-start))
print('End Main Loop')

#####
# SAVE DATA
# CSV files with MAE and IC 60 predictios will be loaded by R script
#####

#save list of hyperparameters to a Data Frame and *.csv file
df_results = DataFrame.from_records(list_tsteps)
df_results = df_results[['QUARTER', 'UF', 'STEPS_IN',
                        'EPOCHS', 'N_UNITS_1', 'N_UNITS_2', 'DROPOUT']]

df_results.to_csv('LSTM_BOpt_' + uf + '_CONFIGS.csv', header=True)

#save MAE DataFrame
df_MAE = df_MAE.T
df_MAE.columns = catmat.values
df_MAE.reset_index(drop=True, inplace=True)
df_MAE.to_csv('LSTM_BOpt_' + uf + '_MAE' + '.csv', header=True)

#save FCAST DataFrame
nmed = n_features

df_temp = concat([df_FCAST.iloc[:,0:nmed],df_FCAST.iloc[:,nmed:2*nmed],
                 df_FCAST.iloc[:,2*nmed:3*nmed],df_FCAST.iloc[:,3*nmed:4*nmed],
                 df_FCAST.iloc[:,4*nmed:5*nmed],df_FCAST.iloc[:,5*nmed:6*nmed],
                 df_FCAST.iloc[:,6*nmed:7*nmed],df_FCAST.iloc[:,7*nmed:8*nmed],
                 df_FCAST.iloc[:,8*nmed:9*nmed],df_FCAST.iloc[:,9*nmed:10*nmed],
                 df_FCAST.iloc[:,10*nmed:11*nmed],df_FCAST.iloc[:,11*nmed:12*nmed]])

df_temp.columns = catmat.values
df_FCAST = df_temp
df_FCAST.reset_index(drop=True, inplace=True)
df_FCAST.to_csv('LSTM_BOpt_' + uf + '_FCAST' + '.csv', header=True)

df_temp = concat([df_FCAST_IC_60_INF.iloc[:,0],df_FCAST_IC_60_SUP.iloc[:,0],
                 df_FCAST_IC_60_INF.iloc[:,1],df_FCAST_IC_60_SUP.iloc[:,1],
                 df_FCAST_IC_60_INF.iloc[:,2],df_FCAST_IC_60_SUP.iloc[:,2],
                 df_FCAST_IC_60_INF.iloc[:,3],df_FCAST_IC_60_SUP.iloc[:,3],
                 df_FCAST_IC_60_INF.iloc[:,4],df_FCAST_IC_60_SUP.iloc[:,4],
                 df_FCAST_IC_60_INF.iloc[:,5],df_FCAST_IC_60_SUP.iloc[:,5],
                 df_FCAST_IC_60_INF.iloc[:,6],df_FCAST_IC_60_SUP.iloc[:,6],
                 df_FCAST_IC_60_INF.iloc[:,7],df_FCAST_IC_60_SUP.iloc[:,7],
                 df_FCAST_IC_60_INF.iloc[:,8],df_FCAST_IC_60_SUP.iloc[:,8],
                 df_FCAST_IC_60_INF.iloc[:,9],df_FCAST_IC_60_SUP.iloc[:,9],
                 df_FCAST_IC_60_INF.iloc[:,10],df_FCAST_IC_60_SUP.iloc[:,10],
                 df_FCAST_IC_60_INF.iloc[:,11],df_FCAST_IC_60_SUP.iloc[:,11]],axis=1)

df_temp = df_temp.T

df_temp.columns = catmat.values
df_FCAST_IC_60_INF_SUP = df_temp
df_FCAST_IC_60_INF_SUP.reset_index(drop=True, inplace=True)
df_FCAST_IC_60_INF_SUP.to_csv('LSTM_BOpt_' + uf + '_FCAST_IC60' + '.csv', header=True)
del df_temp

# SAVE BEST FCAST IC 60 PER QUARTER
df_totalMAE.reset_index(drop=True, inplace=True)

```

```

df_MAE.reset_index(drop=True, inplace=True)

# FIRST QUARTER
idx_q = df_MAE.iloc[0:4,:].idxmin(axis=0).values * 2 # inf and sup
idx_q_mae = (df_totalMAE.iloc[[4,9,14,19],:].idxmin(axis=0).values // 5) * 5

df_inf_sup_q1 = DataFrame()
df_mae_q1 = DataFrame()

for med in range(nmed):
    # IC 60 INF + SUP
    df_temp = df_FCAST_IC_60_INF_SUP.iloc[idx_q[med]:idx_q[med]+2,med]
    df_temp.reset_index(drop=True,inplace=True)
    df_inf_sup_q1 = concat([df_inf_sup_q1,df_temp], axis=1)

    # POINT AND AVERAGE MAE
    df_temp = df_totalMAE.iloc[idx_q_mae[med]:idx_q_mae[med]+5,med]
    df_temp.reset_index(drop=True,inplace=True)
    df_mae_q1 = concat([df_mae_q1,df_temp], axis=1)
#end for
df_inf_sup_q1.reset_index(drop=True, inplace=True)

# SECOND QUARTER
idx_q = df_MAE.iloc[4:8,:].idxmin(axis=0).values*2
idx_q_mae = df_totalMAE.iloc[[24,29,34,39],:].idxmin(axis=0).values//5*5

df_inf_sup_q2 = DataFrame()
df_mae_q2 = DataFrame()

for med in range(nmed):
    # IC 60 INF + SUP
    df_temp = df_FCAST_IC_60_INF_SUP.iloc[idx_q[med]:idx_q[med]+2,med]
    df_temp.reset_index(drop=True,inplace=True)
    df_inf_sup_q2 = concat([df_inf_sup_q2,df_temp], axis=1)

    # POINT AND AVERAGE MAE
    df_temp = df_totalMAE.iloc[idx_q_mae[med]:idx_q_mae[med]+5,med]
    df_temp.reset_index(drop=True,inplace=True)
    df_mae_q2 = concat([df_mae_q2,df_temp], axis=1)
#end for
df_inf_sup_q2.reset_index(drop=True, inplace=True)

# THIRD QUARTER
idx_q = df_MAE.iloc[8:12,:].idxmin(axis=0).values*2
idx_q_mae = df_totalMAE.iloc[[44,49,54,59],:].idxmin(axis=0).values//5*5

df_inf_sup_q3 = DataFrame()
df_mae_q3 = DataFrame()

for med in range(nmed):
    # IC 60 INF + SUP
    df_temp = df_FCAST_IC_60_INF_SUP.iloc[idx_q[med]:idx_q[med]+2,med]
    df_temp.reset_index(drop=True,inplace=True)
    df_inf_sup_q3 = concat([df_inf_sup_q3,df_temp], axis=1)

    # POINT (fh=4) AND AVERAGE MAE
    df_temp = df_totalMAE.iloc[idx_q_mae[med]:idx_q_mae[med]+5,med]
    df_temp.reset_index(drop=True,inplace=True)
    df_mae_q3 = concat([df_mae_q3,df_temp], axis=1)
#end for

df_inf_sup_q3.reset_index(drop=True, inplace=True)

# Save IC 60 forecasts [2(inf,sup)*nquarters x nmed]
df_save_ic = concat([df_inf_sup_q1, df_inf_sup_q2, df_inf_sup_q3], axis=0)
df_save_ic.to_csv('LSTM_BOpt_' + uf + '_FCAST_IC60_INF_SUP.csv', header=True)

# Save point and average MAE [5 (fh + avg) x nmed*nquarters]
df_save_mae = concat([df_mae_q1, df_mae_q2, df_mae_q3], axis=1)
df_save_mae.to_csv('LSTM_BOpt_' + uf + '_TOTAL_MAE.csv', header=True)

```