

Modelagem da previsão do volume de chamadas recebidas por um *Call Center*

Pedro Henrique da Silva Roque* Rogério Martins Gomes*
Bruno André Santos* Marcela Richele Ferreira**

* *Departamento de Computação, Centro Federal de Educação
Tecnológica de Minas Gerais, Belo Horizonte, Minas Gerais, Brasil
(e-mail: pedrohsroque@gmail.com, rogerio@cefetmg.br,
bsantos@cefetmg.br).*

** *Departamento de Matemática, Centro Federal de Educação
Tecnológica de Minas Gerais, Belo Horizonte, Minas Gerais, Brasil
(e-mail: marcela.richele@cefetmg.br)*

Abstract: This work presents a comparison between several classical statistical models (Simple Exponential Smoothing (SES), Holt, Holt-Winters (HW), Autoregressive (AR), Moving Average (MA) and Moving Average Autoregressive (ARMA)) and the recurrent neural network model called Long Short Term Memory (LSTM), in the task of predicting the volume of calls received by a Call Center. The methodology used in classical statistical models consisted of obtaining data from a call center system and analyzing them in two different ways: dividing the dataset into two training and test partitions and using the cross-validation method Blocked Cross-Validation (CV-BI) with ten partitions. Two forecasting methods were developed for each classical statistical model, called static and dynamic, based on the partitioning methodology. The methodology applied in the LSTM, in turn, used a window of 24 samples of the time series to predict the next value. Finally, the models were evaluated by the metric normalized Root Mean Squared Error (RMSE). The best results were obtained by the dynamic AR CV-BI (RMSE = 14.7%), dynamic ARMA CV-BI (RMSE = 15.2%) and LSTM (RMSE = 15.4%) models.

Resumo: Este trabalho apresenta uma comparação entre diversos modelos estatísticos clássicos (Suavização Exponencial Simples (SES), Holt, Holt-Winters (HW), Autorregressivo (AR), Média Móvel (MA) e Média Móvel Autorregressiva (ARMA)) e o modelo de rede neural recorrente *Long Short Term Memory* (LSTM), na tarefa de prever o volume de chamadas recebidas por um *Call Center*. A metodologia utilizada nos modelos estatísticos clássicos consistiu em obter dados de um sistema de *call center* e analisa-los de duas formas distintas: dividindo o conjunto de dados em duas partições de treino e teste e utilizando o método de validação cruzada *Blocked Cross-Validation* (CV-BI) com dez partições. Com base na metodologia de particionamento, dois métodos de previsão foram desenvolvidos para cada modelo estatístico clássico, denominados estático e dinâmico. A metodologia aplicada na LSTM, por sua vez, utilizou uma janela de 24 amostras da série temporal na previsão do próximo valor. Por fim, os modelos foram avaliados pela métrica *Root Mean Squared Error* (RMSE) normalizado. Os melhores resultados foram obtidos pelos modelos AR CV-BI dinâmico (RMSE = 14,7%), ARMA CV-BI dinâmico (RMSE = 15,2%) e LSTM (RMSE = 15,4%).

Keywords: Time series; Call Center; Classical statistical models; LSTM.

Palavras-chaves: Séries temporais; *Call Center*; Modelos estatísticos clássicos; LSTM.

1. INTRODUÇÃO

Graças ao desenvolvimento tecnológico e impactadas pela pandemia de COVID-19, diversas empresas têm optado pelo atendimento por meio eletrônico, o qual é realizado via *web*, *apps* de celulares, *chats* ou por telefone. Sendo assim, as mais diversas empresas têm investido em campanhas que visam agregar valor a marca por meio da experiência do cliente, principalmente no que tange a melhoria na qualidade do atendimento. Para um *call center*, objeto deste trabalho, o volume de ligações recebidas é um dos principais indicadores que auxiliam os gestores na tomada

de decisão quanto ao dimensionamento da equipe a ser utilizada no atendimento dessas ligações. Dessa forma, é possível perceber que a previsão do volume de ligações recebidas possibilitaria um aumento direto nos lucros da companhia e também nos lucros indiretos advindos do aumento da satisfação do cliente, por meio da redução do tempo de espera.

Na literatura, é possível encontrar trabalhos sobre previsão do volume de ligações recebidas por um *call center* utilizando métodos estatísticos e de *machine learning*. Andrews and Cunningham (1995), por exemplo, desenvolveram dois modelos de previsão para a empresa L.L. Bean,

utilizando o modelo *Auto Regressive Integrated Moving Average* (ARIMA). A escolha do método ocorreu devido a influência dos padrões sazonais e a variáveis externas, como os anúncios da marca. Devido a precisão dos modelos desenvolvidos, o ganho estimado para a empresa foi de 300 mil dólares por ano.

Bianchi et al. (1998) analisaram métodos já existentes e aprimorados de previsão de chamadas recebidas por um *call center* com o propósito de planejar o orçamento. Os autores analisaram o uso de versões aditivas e multiplicativas dos modelos de média móvel exponencialmente ponderados de Holt-Winters (HW), comparando-os com o ARIMA com análise de intervenção. Apesar de existirem evidências na literatura que mostram que modelos simples, tais como HW, apresentam um desempenho semelhante ou melhor que modelos mais complexos, para esse caso, os autores mostraram que o modelo ARIMA, com análise de intervenção, apresentou um desempenho melhor para a série temporal estudada.

Ibrahim and L'Ecuyer (2013) avaliaram a precisão da previsão de diferentes modelos estatísticos, descrevendo os resultados de um estudo empírico, para o processo de previsão do recebimento de ligações de um *call center* real. Os modelos utilizados foram: (i) modelo de referência de efeitos fixos, o qual não explora qualquer dependência na estrutura dos dados; (ii) modelo de efeitos mistos, que leva em conta correlações intra-diárias e entre dias; (iii) modelo de efeitos bivariáveis, que explora correlações de dois tipos diferentes de ligações. O estudo que eles realizaram apresentou a importância de se considerar correlações diferentes na estrutura de dados.

Shen and Huang (2008) desenvolveram métodos para previsão intradiária e em dias subsequentes, considerando o volume de ligações como uma série temporal vetorial de alta dimensão. Os autores propuseram, primeiramente, a redução da dimensionalidade da série utilizando decomposição de valor singular da matriz histórica intradiária e depois aplicaram técnicas de regressão sobre o vetor resultante. Os métodos se mostraram robustos e competitivos durante as simulações e na previsão de dois *datasets*. Eles também foram computacionalmente rápidos, tornando possível a utilização em tempo real.

Taylor (2008) analisou métodos de séries temporais invariáveis para prever o recebimento de chamadas no intervalo de tempo de 1 hora até 2 semanas. Foram analisadas cinco séries de chamadas telefônicas recebidas por um Banco no Reino Unido, no qual foi possível perceber a característica sazonal entre as semanas e entre os dias. Os métodos considerados incluíram: 1) o método ARIMA; 2) uma extensão da suavização exponencial de Holt-Winters, para o caso de dois ciclos sazonais; 3) uma outra suavização exponencial, baseada no peso absoluto dos desvios das regressões; 4) uma regressão harmônica dinâmica. Os resultados desse estudo indicaram um forte potencial para o uso da modelagem utilizando ARIMA e a extensão de suavização exponencial de Holt-Winters para prever o volume de chamadas acima de 2 ou 3 dias a frente e também indicaram que, para intervalos maiores, uma média histórica apresenta um resultado difícil de ser batido. O autor também testou os métodos para um conjunto de dados extraídos

em um banco de Israel, obtendo resultados similares de desempenho.

Bianchi et al. (2015) abordaram o problema da previsão da carga de ligações recebidas por uma rede móvel utilizando *Echo State Network*. Nessa abordagem, foi considerada a adição dos registros telefônicos referentes a atividade na célula como variáveis exógenas, por meio da análise da sua utilidade na tarefa de previsão. As metodologias utilizadas para treinar a rede foram a *v-SVR* e uma "*elastic net penalty*". Posteriormente, foi empregado um algoritmo genético na tarefa de sintonização dos parâmetros do sistema, bem como na seleção de um subconjunto ótimo de informações adicionais das séries temporais a serem consideradas como entradas externas. O desempenho do sistema foi comparado com modelos preditivos padrões e os resultados foram avaliados de acordo com as propriedades específicas das séries temporais analisadas.

Jalal et al. (2016) propuseram um modelo de rede neural com três camadas que usa a combinação das redes neurais Elman e NARX na previsão dos volumes de chamadas em *call centers*. O modelo foi comparado com a rede neural *time-lagged feedforward* e os resultados mostraram que a rede proposta obteve um desempenho superior, alcançando um erro quadrático menor, em todas as configurações testadas.

Diante desse cenário, o presente trabalho propõe fazer uma comparação de desempenho entre diversos modelos preditivos estatísticos e o modelo de rede neural recorrente *Long Short Term Memory* (LSTM). Esses modelos podem ser utilizados na previsão do volume de ligações que serão recebidas por um *Call Center*, afim de otimizar a distribuição da equipe de atendimento e reduzir o tempo de espera do cliente. As redes LSTM são adequadas para o aprendizado de dependências de longo prazo, na detecção de sazonalidade e para previsões dentro do contexto de séries não estacionárias, no entanto, ainda não foram testadas nos trabalhos anteriores para este tipo de problema.

2. METODOLOGIA

As etapas da metodologia utilizada neste trabalho incluem a obtenção dos dados históricos da série temporal que será estudada, o processamento dos dados, a escolha e aplicação dos métodos de previsão utilizados, bem como a análise dos resultados obtidos.

2.1 Coleta de dados

Os dados foram coletados do sistema *Avaya CMS Supervisor*, responsável por fazer a gestão das ligações recebidas pelo *Call Center*, e possuem os dados referentes ao período de 01/05/2018 a 31/08/2019. Os dados coletados foram armazenados em um arquivo csv contendo os campos data e volume de ligações recebidas. A Figura 1 exibe, de forma gráfica, o volume de ligações recebidas pelo *call center* no intervalo analisado.

2.2 Processamento de dados

Para aplicar os métodos de previsão é necessário garantir que não existam valores iguais a zero no conjunto de dados. Sendo assim, esses valores foram removidos da base,

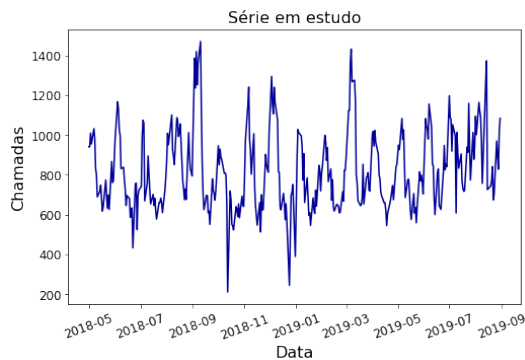


Figura 1. Série em estudo - Volume de ligações recebidas pelo call center

principalmente, devido ao fato de ocorrerem nos finais de semana e feriados.

2.3 Escolha dos métodos de previsão

Foram realizados experimentos com seis métodos tradicionais divididos em dois grupos (Suavização exponencial e ARMA) e um método de aprendizado de máquina, *i.e.*, uma rede neural *Long Short Term Memory* (LSTM) (Hochreiter and Schmidhuber, 1997). Os sete modelos testados foram:

1. Modelo Auto-Regressivo (AR)
2. Modelo de Médias Móveis/Moving Average (MA)
3. Modelo Auto-Regressivo Moving Average (ARMA)
4. Modelo Suavização Exponencial Simples (SES)
5. Modelo Suavização Exponencial de Holt
6. Modelo Suavização Exponencial de Holt-Winters (HW)
7. Rede neural do tipo *Long Short Term Memory* (LSTM)

A LSTM foi escolhida com o objetivo de avaliar o desempenho desse importante método de *machine learning*, usado em previsão de séries temporais, com os métodos tradicionais.

2.4 Métodos estático e dinâmico

Para cada um dos métodos de suavização exponencial e ARMA foram desenvolvidos dois modelos de previsão. O primeiro modelo foi o estático, no qual os dados históricos foram divididos em duas partes. Na primeira parte, constituída por 67% dos dados da série, tem-se os dados de treinamento, os quais serão utilizados para identificar os parâmetros dos modelos preditivos. Na segunda parte, constituída pelos restantes 33% da série de dados, estão contidos os valores de teste, os quais serão utilizados para comparar os resultados previstos com os que foram registrados no caso real.

No segundo método, foi desenvolvido um modelo dinâmico. Da mesma forma que no método estático, 67% dos dados históricos da série foram usados, na primeira iteração, como dados de treinamento, os quais serão utilizados para identificar os parâmetros dos modelos preditivos. No entanto, diferentemente do outro método, que fazia a

previsão dos 33% restantes da série, somente será prevista a primeira amostra desconhecida da série. Por exemplo, considerando os dados de treinamento, que vão de y_1 até y_t , o modelo tenta fazer a previsão do valor em $t+1$ (y_{t+1}). Em seguida, com os dados de y_1 até y_{t+1} , tenta-se estimar y_{t+2} , assim por diante. É importante observar que a cada iteração os dados de treinamento não ficam limitados a 67% da série, mas incorporam os dados dos dias subsequentes, à medida que a previsão avança sobre a sequência desconhecida.

Para facilitar a identificação desses métodos, eles serão chamados de métodos estático e dinâmico.

2.5 Blocked Cross-Validation (CV-BI)

Com intuito de verificar de maneira mais robusta o desempenho dos modelos implementados, foi utilizado o método de validação cruzada denominado *Blocked Cross-Validation* (CV-BI), apresentado em (Cerqueira et al., 2020). Esse método é semelhante ao método tradicional de validação cruzada denominado *K-fold*. No entanto, diferentemente do método padrão, no qual os dados são embaralhados aleatoriamente antes de serem divididos nas K partições, nesse trabalho os dados serão renderizados em $K=10$ partições de observações contíguas, por se tratar de séries temporais. Dessa forma, foram mantidas a ordem natural das observações dentro de cada partição.

Da mesma forma que na seção 2.4, o procedimento dos métodos estático e dinâmico, foi também aplicado ao método de validação cruzada *Blocked Cross-Validation* (CV-BI). Sendo assim, a validação cruzada estática manterá a proporção de 9 (nove) partições para treinamento e 1 (uma) para teste. Nesse caso, toda partição de teste será prevista logo após o treinamento. Na validação cruzada dinâmica, os dados de treinamento não ficam limitados às 9 (nove) partições da série, mas incorporam os dados dos dias subsequentes da partição de teste, à medida que a previsão avança sobre a sequência desconhecida.

Por fim, todos os modelos foram avaliados de forma gráfica e também por meio da métrica RMSE (*root mean squared error*) normalizado.

3. RESULTADOS

3.1 Métodos de suavização exponencial (SE) estático

A Figura 2 apresenta a comparação entre os métodos SES (Robert, 1956), Holt (Holt, 2004) e HW (Chatfield, 1978). Os resultados dos métodos SES e Holt aparecem sobrepostos na figura, devido ao fato do método Holt se diferenciar do método SES somente por uma componente capaz de captar tendências de crescimento ou decaimento dos valores da série. Como a série em estudo não apresenta nenhuma tendência, os resultados obtidos pelos dois métodos são praticamente idênticos. É possível perceber que os valores previstos pelos métodos SES e Holt não se aproximaram do comportamento da série, tornando os métodos inviáveis para aplicação prática. Por outro lado, o método HW capturou a sazonalidade da série e apresentou níveis parecidos com os dados do período de teste, ainda que com uma espécie de *offset* positivo, superestimando os valores.




Figura 2. Comparação dos métodos de suavização exponencial estática

O RMSE normalizado dos métodos SES, Holt e HW são apresentados na Tabela 1. Os resultados mostraram uma pequena diferença entre os erros encontrados pelos métodos SES e Holt, enquanto o método HW apresentou um valor de RMSE de 9,2%, menor que o obtido nos demais modelos.

Tabela 1. Modelos SE estáticos

Modelos	RMSE Normalizado
SES	30,7%
Holt	30,7%
HW	21,5%

3.2 Métodos de suavização exponencial (SE) dinâmicos

A comparação dos modelos dinâmicos SES, Holt e HW pode ser vista na Figura 3. É possível perceber que os métodos dinâmicos apresentaram resultados consideravelmente melhores que os métodos estáticos, conseguindo acompanhar a sazonalidade e os níveis dos dados de teste.




Figura 3. Comparação dos métodos de suavização exponencial dinâmicos

O RMSE normalizado dos métodos SES, Holt e HW são apresentados na Tabela 2. Os resultados mostraram uma pequena diferença entre os métodos, indicando que os modelos obtiveram resultados semelhantes.

3.3 Métodos Autoregressivos e de média móvel estáticos

Os resultados dos métodos AR (Yule, 1927), MA (Yule, 1909) e ARMA (Whittle, 1951) podem ser vistos na Figura

Tabela 2. Modelos SE dinâmicos

Modelos	RMSE Normalizado
SES	16,8%
Holt	16,8%
HW	16,9%

4. É possível perceber que o modelo AR apresentou um resultado relativamente bom nos primeiros ciclos da série, mas um comportamento convergente nos demais ciclos, o que inviabiliza sua utilização. Também é possível perceber que os métodos MA e ARMA apresentaram valores muito próximos entre si, mas muito diferentes em relação aos dados do período de testes. Sendo assim, tais modelos não foram capazes de acompanhar a sazonalidade da série.

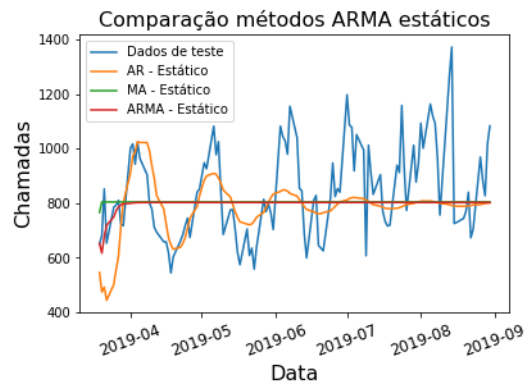


Figura 4. Comparação dos métodos ARMA estáticos

O RMSE normalizado dos métodos AR, MA e ARMA são apresentados na Tabela 3. Os resultados mostraram uma diferença de 1,0% entre o modelo com menor RMSE normalizado (AR) e o modelo com o maior RMSE normalizado (MA), indicando um desempenho superior do método AR.

Tabela 3. Modelos Auto regressivos estáticos

Modelos	RMSE Normalizado
AR	19,8%
MA	20,8%
ARMA	20,8%

3.4 Métodos Autoregressivos e de média móvel dinâmicos

Nesta seção são apresentados e discutidos os resultados obtidos pelos métodos AR, MA e ARMA dinâmicos.

É possível observar na Figura 5, que o modelo AR conseguiu capturar a sazonalidade e que os atrasos apresentados pelos métodos SES não foram evidenciados aqui. O método MA, por sua vez, apresentou uma melhora significativa em relação a sua versão estática e, apesar de ainda apresentar variações atenuadas em relação aos dados de teste, conseguiu capturar a sazonalidade da série. Por fim, é possível observar que o resultado do método ARMA apresentou bastante semelhança com o resultado obtido pelo modelo AR, sendo impossível determinar, visualmente, quais dos métodos alcançou um melhor desempenho.

O RMSE normalizado dos métodos AR, MA e ARMA são apresentados na Tabela 4. Os resultados mostraram




Figura 5. Comparação dos métodos ARMA dinâmicos uma diferença de 1,9% entre o modelo com menor RMSE normalizado (AR) e o modelo com o maior RMSE normalizado (MA), indicando um desempenho inferior do método MA. Já os métodos AR e ARMA apresentaram resultados similares, com uma ligeira vantagem para o método AR.

Tabela 4. Modelos auto regressivos dinâmicos

Modelos	RMSE Normalizado
AR	15,2%
MA	17,1%
ARMA	15,7%

O RMSE de todos os modelos avaliados (SES, Holt, HW, AR, MA e ARMA), utilizando os métodos estático e dinâmico, são sumarizados na Tabela 5. Diante dos resultados apresentados para a série original, é possível perceber um desempenho consideravelmente superior dos modelos utilizando o método dinâmico.

Tabela 5. Modelos estatísticos clássicos estáticos e dinâmicos

Modelos	RMSE Normalizado	
	Estático	Dinâmico
SES	30,7%	16,8%
Holt	30,7%	16,8%
HW	21,5%	16,9%
AR	19,8%	15,2%
MA	20,8%	17,1%
ARMA	20,8%	15,7%

3.5 Modelos estatísticos clássicos utilizando o método de validação cruzada Blocked Cross-Validation (CV-BI)

A Tabela 6 mostra os resultados obtidos pelos modelos estatísticos clássicos utilizando o método de validação cruzada *Blocked Cross-Validation* e considerando os métodos de treinamento estático e dinâmico. É possível observar, exatamente como nos resultados mostrados na Tabela 5, que os modelos autoregressivos apresentaram resultados superiores quando comparados com os métodos de suavização exponencial. Além disso, é possível perceber que o método AR utilizando o método dinâmico foi o modelo que apresentou o melhor resultado.

3.6 Rede neural LSTM

Nesta seção será apresentado o resultado da previsão utilizando a rede neural LSTM. Diversos modelos foram

Tabela 6. Modelos estatísticos clássicos - Validação Cruzada (CV-BI)

Modelos	RMSE Normalizado	
	Estático	Dinâmico
SES	28,5%	16,2%
Holt	29,0%	16,2%
HW	37,9%	16,3%
AR	20,4%	14,7%
MA	23,4%	18,0%
ARMA	22,9%	15,2%

treinados utilizando diferentes otimizadores, sendo que o RMPSPROP, o ADAM e o ADAMAX precisaram de uma quantidade de épocas consideravelmente menor que os demais (150, 200 e 350, respectivamente) para atingir erros de validação baixos. O modelo que apresentou menor erro de validação utilizou o otimizador Adam, com 200 épocas, considerando a utilização de uma janela de 24 amostras na previsão do próximo valor.




Figura 6. Previsão utilizando LSTM

Os resultados obtidos podem ser vistos na Figura 6. Na Tabela 7 é possível observar que a rede LSTM apresentou um desempenho superior em relação a todos os métodos estatísticos clássicos com exceção dos modelos AR e ARMA com validação cruzada e utilizando o método dinâmico.

Tabela 7. RMSE normalizados LSTM

Modelo	RMSE Normalizado
Long Short Term Memory (LSTM)	15,4%

4. CONCLUSÃO

Esse estudo propôs fazer uma comparação do desempenho entre diversos modelos preditivos estatísticos clássicos de previsão de séries temporais aplicados a dados reais de ligações telefônicas de um *call center* e um modelo de rede neural recorrente que fosse capaz de aprender dependências de longo prazo, detectar sazonalidade, bem como pudesse fazer previsões dentro desse contexto.

Para sintetizar os resultados obtidos nesse trabalho foi a construída a Tabela 8. É possível observar que os modelos que só utilizaram os métodos estático sem validação cruzada, de uma maneira geral, não apresentaram bons resultados, inviabilizando a sua utilização na tarefa de previsão. Da mesma forma, pode-se identificar que o método que apresentou o melhor desempenho foi o AR com validação

Tabela 8. Resultados mais relevantes encontrados em todos os experimentos realizados considerando os métodos utilizados

Modelo	Método	RMSE
AR	CV-BI dinâmico	14,7%
ARMA	CV-BI dinâmico	15,2%
Long	Short Term Memory	15,4%
SES	CV-BI dinâmico	16,2%
Holt	CV-BI dinâmico	16,2%
HW	CV-BI dinâmico	16,3%
MA	dinâmico	17,1%
AR	estático	19,8%
MA	estático	20,8%
ARMA	estático	20,8%
HW	estático	21,5%
SES	CV-BI estático	28,5%
Hol	CV-BI estático	29,0%

cruzada e método dinâmico, pois foi o modelo que apresentou o menor RMSE normalizado em todos os conjuntos de testes realizados. Quando comparados os métodos de suavização exponencial e os métodos autoregressivos, é possível observar também a superioridade de desempenho desse último. Essa diferença entre os resultados encontrados fica ainda mais evidenciada no momento em que se observa os resultados de *boxplot*, obtidos no processo de validação cruzada com o método dinâmico, mostrado Figura 7.

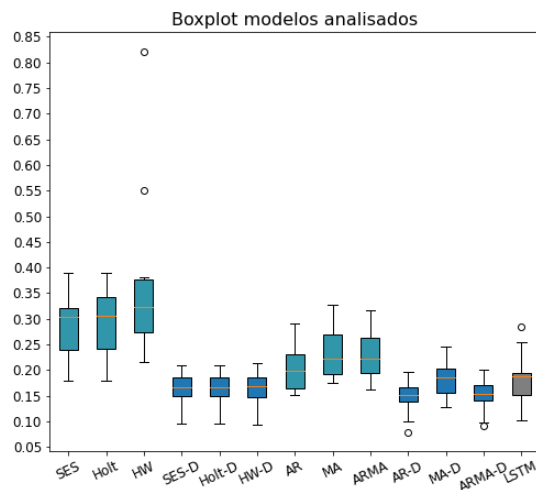


Figura 7. *Boxplot* dos experimentos realizados - método de Validação Cruzada (CV-BI) dinâmica.

Da mesma forma, é possível observar que os resultados indicam que a rede neural LSTM, escolhida nesse trabalho, é uma abordagem de inteligência computacional promissora para o problema de previsão de volumes de chamadas recebidas, uma vez que foi capaz de capturar a dinâmica da série temporal, bem como apresentou um RMSE normalizado muito próximo dos métodos estatísticos clássicos que apresentaram os melhores resultados.

AGRADECIMENTOS

Os autores gostariam de agradecer ao CEFET-MG pelo suporte financeiro, sem o qual esse trabalho não teria sido possível.

REFERÊNCIAS

Andrews, B.H. and Cunningham, S.M. (1995). LI bean improves call-center forecasting. *Interfaces*, 25(6), 1–13.

Bianchi, F.M., Scardapane, S., Uncini, A., Rizzi, A., and Sadeghian, A. (2015). Prediction of telephone calls load using echo state network with exogenous variables. *Neural Networks*, 71, 204–213.

Bianchi, L., Jarrett, J., and Hanumara, R.C. (1998). Improving forecasting for telemarketing centers by arima modeling with intervention. *International Journal of Forecasting*, 14(4), 497–504.

Cerqueira, V., Torgo, L., and Mozetič, I. (2020). Evaluating time series forecasting models: An empirical study on performance estimation methods. *Machine Learning*, 1–32.

Chatfield, C. (1978). The holt-winters forecasting procedure. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 27(3), 264–279.

Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735–1780.

Holt, C.C. (2004). Forecasting seasonals and trends by exponentially weighted moving averages. *International journal of forecasting*, 20(1), 5–10.

Ibrahim, R. and L'Ecuyer, P. (2013). Forecasting call center arrivals: Fixed-effects, mixed-effects, and bivariate models. *Manufacturing & Service Operations Management*, 15(1), 72–85.

Jalal, M.E., Hosseini, M., and Karlsson, S. (2016). Forecasting incoming call volumes in call centers with recurrent neural networks. *Journal of Business Research*, 69(11), 4811–4814.

Robert, B. (1956). Exponential smoothing for predicting demand, arthur d. *Little Inc., Cambridge, Massachusetts*, 97–116.

Shen, H. and Huang, J.Z. (2008). Interday forecasting and intraday updating of call center arrivals. *Manufacturing & Service Operations Management*, 10(3), 391–410.

Taylor, J.W. (2008). A comparison of univariate time series methods for forecasting intraday arrivals at a call center. *Management Science*, 54(2), 253–265.

Whittle, P. (1951). *Hypothesis testing in time series analysis*, volume 4. Almqvist & Wiksells boktr.

Yule, G.U. (1909). The applications of the method of correlation to social and economic statistics. *Journal of the Royal Statistical Society*, 72(4), 721–730.

Yule, G.U. (1927). Vii. on a method of investigating periodicities disturbed series, with special reference to wolfer's sunspot numbers. *Philosophical Transactions of the Royal Society of London. Series A, Containing Papers of a Mathematical or Physical Character*, 226(636-646), 267–298.