

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM SISTEMAS DE INFORMAÇÃO

**Modelos para Previsão da Arrecadação do
ICMS do Rio de Janeiro Utilizando *Deep
Learning***

Pedro Fernandes Freitas

JUIZ DE FORA
DEZEMBRO, 2023

Modelos para Previsão da Arrecadação do ICMS do Rio de Janeiro Utilizando *Deep Learning*

PEDRO FERNANDES FREITAS

Universidade Federal de Juiz de Fora
Instituto de Ciências Exatas
Departamento de Ciência da Computação
Bacharelado em Sistemas de Informação

Orientadora: Luciana Dias Campos Conceição

JUIZ DE FORA
DEZEMBRO, 2023

MODELOS PARA PREVISÃO DA ARRECADAÇÃO DO ICMS DO RIO DE JANEIRO UTILIZANDO *Deep Learning*

Pedro Fernandes Freitas

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE CIÊNCIAS EXATAS DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA, COMO PARTE INTEGRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE BACHAREL EM SISTEMAS DE INFORMAÇÃO.

Aprovada por:

Luciana Dias Campos Conceição
Doutora em Engenharia Elétrica UFJF

Stênio Sã Rosário Furtado Soares
Doutor em Computação UFF

Luciana Brugiolo Gonçalves
Doutora em Computação UFF

JUIZ DE FORA
15 DE DEZEMBRO, 2023

Aos meu pais, pelo encorajamento, apoio incondicional e por não me deixarem desistir.

Ao meu amigo João Paulo, que sempre esteve comigo nessa jornada.

A minha melhor amiga e companheira Bárbara, pode sempre estar do meu lado, mesmo nos momentos mais difíceis dessa caminhada.

A minha orientadora por me guiar e trazer clareza nesse momento crucial.

Resumo

Este trabalho estuda sobre como a Ciência da Computação pode auxiliar a gestão pública no planejamento e execução de recursos financeiros arrecadados através do Imposto sobre Circulação de Mercadorias e Prestação de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação (ICMS) do estado do Rio de Janeiro. A escolha do tema apoia-se no fato de que os impostos se configuram como importante fonte de renda para o governo, os quais geram recursos financeiros para subsidiarem programas governamentais para a sua população e para custearem bens e serviços públicos. Prever os futuros valores de arrecadação de ICMS torna-se tarefa indispensável para a Secretaria de Fazenda (SEFAZ), tendo em vista que os valores alcançados na previsão servem de base para o planejamento orçamentário do estado. Sendo assim, a previsão de ICMS precisa acontecer pelo menos doze meses antes de o dinheiro ser usado pelo estado, a fim de que o planejamento orçamentário possa apresentar maior eficiência. Desse modo, este trabalho buscou averiguar diferentes possibilidades de previsão para verificar até onde é possível ter um horizonte seguro de previsão, empregando modelos de Redes Neurais Recorrentes *Long Short-Term Memory* (LSTM).

Palavras-chave: Rede neural artificial; *Machine Learning*; *Deep Learning*; LSTM; ICMS.

Abstract

This work studies how Computer Science can help public management in the planning and execution of financial resources collected through the Tax on the Circulation of Merchandise and the Rendering of Interstate and Intercity Transportation and Communication Services (ICMS) in the state of Rio de Janeiro. The choice of theme is based on the fact that taxes are configured as an important source of income for the government, which generate financial resources to subsidize government programs for its population and to fund public goods and services. Forecasting future ICMS collection becomes an indispensable task for the State Treasury Department (SEFAZ), since the values reached in the forecast serve as a basis for the state's budget planning. Thus, the ICMS forecast must happen at least twelve months before the money is used by the state, so that the budget planning can be more efficient. Thus, this work sought to investigate different forecasting possibilities to verify how far it is possible to have a safe forecast horizon, using recurrent neural network models (LSTM).

Keywords: Artificial neural network; Machine Learning; Deep Learning; LSTM; ICMS.

Conteúdo

Lista de Figuras	6
Lista de Abreviações	7
1 Introdução	8
1.1 Apresentação do tema	8
1.2 Justificativa/Motivação	9
1.3 Objetivos	10
1.4 Organização do Trabalho	10
2 Fundamentação Teórica	11
2.1 Redes Neurais Artificiais	11
2.1.1 Neurônio Biológico	11
2.1.2 Neurônio Artificial	12
2.1.3 Treinamento de Redes Neurais	14
2.2 <i>Deep Learning</i>	15
2.2.1 Redes Neurais <i>Long Short-Term Memory</i> (LSTM)	16
2.3 Série temporal <i>Univariate</i> x <i>Multivariate</i>	17
2.4 Série temporal <i>Single-step</i> x <i>Multi-step</i>	18
2.5 Métricas de Avaliação	18
3 Trabalhos Relacionados	20
3.1 Aprendizado Profundo na Previsão do ICMS: utilização de variáveis endógenas	20
3.2 Modelos para previsão tributária: utilização de Redes Neurais LSTM	21
3.3 Gestão de riscos: a escolha de modelos preditivos	21
3.4 Previsão de receitas de ICMS: seleção de características em cascata e técnicas de Aprendizado de Máquina	22
3.5 Redes Neurais: Previsão de Curto Prazo de Receitas Tributárias em Séries Temporais	22
3.6 Evasão fiscal: dados abertos e Inteligência Artificial	23
3.7 Redes Neurais Aplicadas na Previsão de Receita de ICMS	24
3.8 Considerações Finais	24
4 Metodologia	26
4.1 Coleta de Dados	26
4.2 Pré-processamento dos Dados	27
4.3 Modelo de Previsão com a rede LSTM	28
4.3.1 Modelo 1: LSTM com saída de 12 meses	28
4.3.2 Modelos com abordagem M_x	29
5 Estudo de Caso	36
5.1 Modelo 1: LSTM <i>Univariate Multi-step</i> 12 meses	36
5.2 Modelos LSTM M_x , M_{6x} e M_{4x}	37
6 Conclusões e Trabalhos Futuros	39

Lista de Figuras

2.1	Neurônio Biológico	12
2.2	Neurônio Artificial esquematizado	13
2.3	Rede neural simples x aprendizagem profunda	15
2.4	Rede LSTM	16
4.1	Arrecadação do ICMS dos anos de 2002 até 2022	27
4.2	Janelamento de entrada e saída dos 12 modelos LSTM	31
4.3	Série temporal prevista na abordagem M_x	32
4.4	Janelamento de entrada e saída dos 2 modelos LSTM	33
4.5	Janelamento de entrada e saída dos 2 modelos LSTM	33
4.6	Janelamento de entrada e saída dos 3 modelos LSTM	35
4.7	Janelamento de entrada e saída dos 3 modelos LSTM	35
5.1	Comparação entre os modelos <i>univariate</i> com e sem KerasTuner	37
5.2	Comparação entre os modelos M_x	38

Lista de Abreviações

ICMS	Imposto sobre Circulação de Mercadorias e Serviços
LSTM	<i>Long Short-Term Memory</i>
PPA	Lei do Plano Plurianual
LDO	Lei de Diretrizes Orçamentárias
LOA	Lei Orçamentária Anual
PIB	Produto Interno Bruto
RN	Rede Neural
RNA	Rede Neural Artificial
MLP	Redes <i>Multilayer Perceptron</i>
RNR	Redes Neurais Recorrentes
RL	Regressão Linear
SEFAZ/RJ	Secretaria de Estado da Fazenda do Rio de Janeiro
MAPE	Média Percentual do Erro Absoluto
MSE	Erro Quadrático Médio
RMSE	Raiz do Erro Médio Quadrático
R^2	Coefficiente de determinação

1 Introdução

Neste capítulo apresentam-se o tema da pesquisa, bem como os objetivos e a motivação utilizada para a previsão de arrecadação de Imposto sobre Circulação de Mercadorias e Prestação de Serviços de Transporte Interestadual e Intermunicipal e de Comunicação (ICMS) no estado do Rio de Janeiro.

1.1 Apresentação do tema

A necessidade de previsão da arrecadação tributária estadual possui fundamentação jurídica na Lei Complementar nº 101, de 4 de maio de 2000 (BRASIL, 2000)¹, conhecida como a Lei de Responsabilidade Fiscal, em seu Artigo 12. Essa lei preconiza a previsão de receitas tributárias, por meio de métodos e premissas adequadas para os devidos cálculos (BRASIL,2000).

Para que os estados brasileiros mantenham seu funcionamento e evitem complicações financeiras, é necessário que se tenha o planejamento fiscal das receitas públicas. Esse planejamento acontece com um ano de antecedência e é preciso que sejam estimadas as receitas arrecadadas por impostos, contribuições e taxas, e também que se estimem as despesas como obras, compra de produtos e prestação de serviços. Esses valores são fixados, a fim de se ter uma base para o controle de gastos do estado (SACHSIDA, 2017).

Existem algumas etapas para que o planejamento seja aprovado, dentre elas estão as aprovações das seguintes leis: a Lei do Plano Plurianual (PPA), a Lei de Diretrizes Orçamentárias (LDO) e a Lei Orçamentária Anual (LOA). Sendo assim, o ICMS pode ser considerado como o mais importante tributo arrecadado, visto que incide na movimentação de serviços e produtos tributáveis nos estados e, por isso, é a principal fonte de financiamento dos estados brasileiros. Na última década, a arrecadação total do ICMS foi de aproximadamente 7% do produto interno bruto (PIB) brasileiro. Por ser um imposto de alta arrecadação, em que as alíquotas e demais aspectos da legislação referentes ao im-

¹Disponível em <https://tinyurl.com/civilleigov3>. Acesso em 05 de Dezembro 2023.

posto são definidos em nível dos estados, e não da União, cria uma série de características e peculiaridades ao ICMS (SACHSIDA, 2017).

Uma peculiaridade é a condição em que cada estado da Federação se encontra em termos de arrecadação, assim como a variação de alíquotas. No que se refere ao estado do Rio de Janeiro, que é o estado considerado nesta pesquisa, desde 2020 encontra-se em Regime de Recuperação Fiscal [Resolução CSRRF n^o33 2020]² (SEFAZ-RJ, 2020), a fim de possibilitar a este estado o ajuste de suas contas. Tal Regime exige uma constante atualização dos dados de receitas e despesas do estado, de maneira a permitir o acompanhamento da trajetória da Recuperação Fiscal do referido estado da Federação (DORNELAS, 2022)(SILVA, 2020).

Por conta do Regime de Recuperação Fiscal, faz-se necessário que o estado do Rio de Janeiro realize a previsão da arrecadação do ICMS, e tal situação tem instigado vários profissionais a buscarem soluções para o desafio de se propor modelos que atendam às demandas relacionadas ao uso das receitas fiscais (REZENDE, 2012).

1.2 Justificativa/Motivação

Os modelos tradicionalmente propostos para os problemas referentes à previsão de receitas tributárias apresentam características de linearidade e não têm conseguido produzir resultados satisfatórios de previsibilidade orçamentária para os estados. Isto porque existe uma não-linearidade nos dados coletados, devido às mudanças contínuas do ambiente externo e interno dos estados (DORNELAS, 2022). Por conseguinte, modelos não-lineares de *Machine Learning*, como *Deep Learning*, conseguem capturar as mudanças não lineares dos dados analisados, adquirindo resultados mais eficientes, e com isso, proporcionando informações mais precisas para as tomadas de decisões na gestão pública de recursos financeiros arrecadados através da tributação.

Neste trabalho, buscou-se aperfeiçoar o modelo proposto por Dornelas (2022), a fim de obter uma previsão anual do ICMS mais acurada

²Disponível em <https://www.gov.br/economia/pt-br/aceso-a-informacao/participacao-social/consultas-publicas/arquivos/2020/resolucao-ndeg-30-do-csrrf.pdf>. Acesso em 04 Dezembro 2023.

1.3 Objetivos

Com a intenção de contribuir com as formulações existentes acerca das receitas fiscais, este trabalho teve como objetivo geral aplicar um modelo *Deep Learning* com diferentes abordagens para a previsão anual de ICMS.

1.4 Organização do Trabalho

O trabalho se organiza em 6 capítulos, da seguinte forma: no primeiro teve-se a introdução que continha a apresentação do tema, justificativa e objetivos da pesquisa. No Capítulo 2 apresentam-se a fundamentação teórica acerca do tema, que consiste na revisão da literatura existente a fim de endossar a realização do trabalho. No Capítulo 3 são apresentados os trabalhos relacionados com tema desta pesquisa. No Capítulo 4 é apresentada a metodologia utilizada para a implementação dos modelos LSTM. No Capítulo 5, são abordadas todas as diferentes formas de testes e implementações que foram feitas. Por fim, no Capítulo 6 encontram-se as conclusões e as propostas para trabalhos futuros.

2 Fundamentação Teórica

Nesse capítulo apresentados conceitos fundamentais para o entendimento do trabalho, como: redes neurais, séries temporais e métricas de avaliação dos resultados.

2.1 Redes Neurais Artificiais

De acordo com Haykin (2001), uma Rede Neural Artificial (RNA) é um processador formado por unidades de processamento, que buscam armazenar conhecimento experimental, tornando-o disponível para uso. As RNAs, tomando por base o processamento do cérebro humano, são capazes de aprender e generalizar, fato que pode auxiliar na resolução de problemas complexos (HAYKIN, 2001).

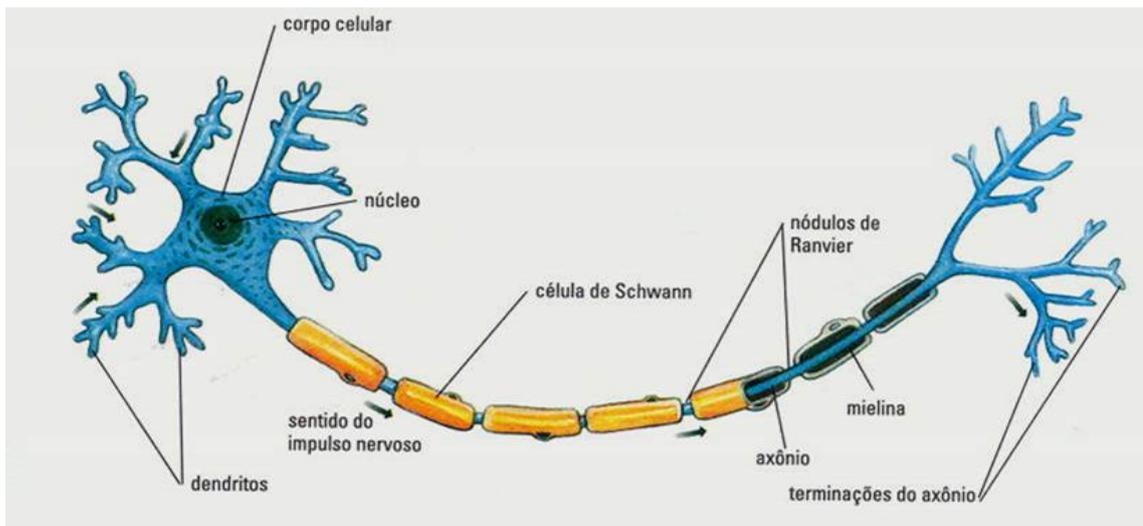
Segundo Silva (2020), as RNAs conseguem aprender, memorizar e generalizar em um processo parecido à aprendizagem realizada pelo cérebro humano, ou seja, através da experiência. A aprendizagem acontece através de um treinamento determinado por algoritmo de aprendizagem de máquina, que remodela, pelos dados recebidos do ambiente externo, os pesos sinápticos dos neurônios. A capacidade de generalizar, isto é, criar saídas para qualquer entrada, é relevante visto que podem ser enviadas à rede entradas que não foram usadas na fase de aprendizagem. (SILVA, 2020).

2.1.1 Neurônio Biológico

Os neurônios são as células responsáveis pela transmissão dos impulsos nervosos capazes de estabelecerem conexões entre si ao receberem estímulos do ambiente externo ou do próprio organismo (JUNQUEIRA; CARNEIRO, 2013).

Para que seja possível modelar a rede neural humana, é preciso entender um pouco melhor sobre como o neurônio biológico se comporta. Na Figura 2.1 é apresentado um esquema simplificado de um neurônio biológico.

Figura 2.1: Neurônio Biológico



Fonte: Adaptado de Histologia Interativa Universidade Federal de Alfenas ³

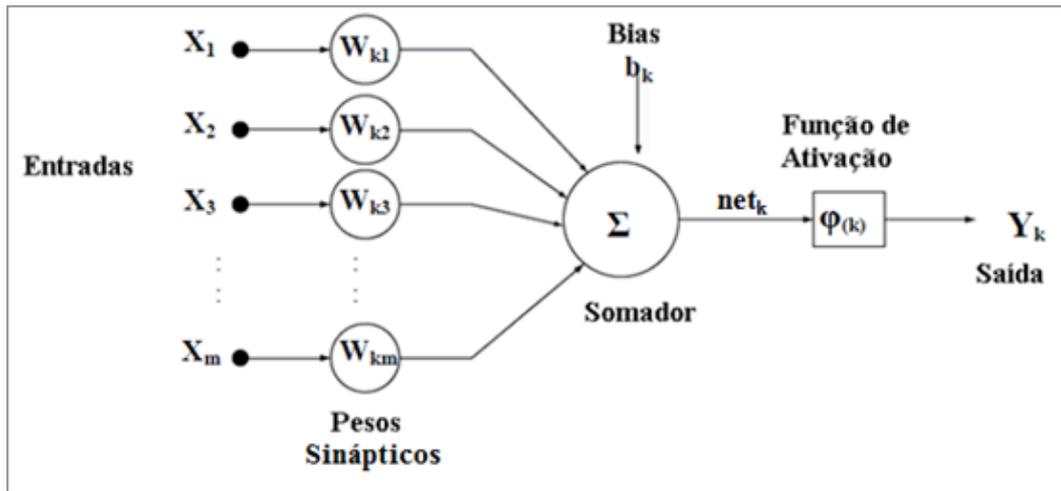
É possível observar na Figura 2.1 que os neurônios apresentam três partes básicas: os dendritos, o axônio e o corpo celular. Os dendritos são prolongamentos do neurônio que garantem a recepção dos estímulos, levando o impulso nervoso em direção ao corpo celular, ocorrendo a sinapse que é a comunicação entre os neurônios. O axônio é o prolongamento que garante a condução do impulso nervoso. Cada neurônio possui apenas um axônio, o qual é, geralmente, mais longo que os dendritos. O corpo celular é o local do neurônio onde está presente o núcleo, grande parte das organelas celulares e de onde partem os prolongamentos dessa célula (JUNQUEIRA; CARNEIRO, 2013).

2.1.2 Neurônio Artificial

Faz-se necessário traçar um paralelo entre o neurônio biológico e o neurônio artificial, para compreender as modelagens das RNAs, o que pode ser observado na Figura 2.2.

³Disponível em <https://www.unifal-mg.edu.br/histologiainterativa/tecido-nervoso/>. Acesso em 5 de Dezembro de 2023

Figura 2.2: Neurônio Artificial esquematizado



Fonte: Adaptado de Vellasco (2010)

Este modelo é formado por: entrada, pesos sinápticos, somador, função de ativação e saída. Essas cinco partes deste modelo funcionam da seguinte forma: são enviadas ao neurônio entradas, o qual faz o processamento gerando uma única saída como resultado. Os dendritos representam a combinação das entradas, que são $X_1, X_2, X_3 \dots X_m$. Estes alimentam a rede e se conectam ao corpo do neurônio artificial por meio dos pesos. Os pesos sinápticos, simbolizados por $W_{k,1}, W_{k,2}, W_{k,3} \dots, W_{k,m}$, representam a simulação das sinapses. Assim, cada peso sináptico associa-se a um canal de entrada, que juntos estabelecem o quanto o estímulo adquirido incitará o neurônio receptor, visto que quanto maior o valor do peso, mais incitação promove o estímulo (SILVA, 2020).

O somador, representado pelo Σ , desempenha o somatório das entradas ponderadas pelos pesos sinápticos e o bias b_k fornecendo como resultado o net_k . A função de ativação, representada por $\Phi(k)$, é aplicada ao net_k e define a resposta da rede que é a saída identificada por Y_k (SILVA, 2020).

O somador pode, ainda, receber um parâmetro externo - o bias - representado por b_k , que é capaz de aumentar (se for positivo) ou diminuir (se for negativo) a entrada líquida da função de ativação, com a intenção de ampliar a liberdade desta função e, em consequência, aumentar a capacidade da rede fazer as aproximações, permitindo que um neurônio não apresente saída nula mesmo que todas as suas entradas sejam nulas. (SILVA, 2020).

2.1.3 Treinamento de Redes Neurais

As RNAs precisam ser treinadas por um algoritmo de aprendizado de máquina, a fim de que atinjam o seu desígnio de identificar padrões em conjunto de dados através de adequações de parâmetros para modelar sistemas ou antever dados, adquirindo, assim, novas informações que partiram de conhecimentos de experiências anteriores. É na etapa de treinamento que acontece a aprendizagem da RNA (SILVA, 2020).

Segundo Kovács (2006), os tipos de algoritmos de aprendizado de máquina são: supervisionado e não supervisionado. O algoritmo de aprendizagem supervisionado utiliza conjuntos de dados de entrada e saída mapeados, modelando o sistema de maneira projetável e sabendo o resultado que se almeja alcançar. Para isso, o sistema necessita de um “supervisor” o qual é representado por mostras de saída almejada para uma específica entrada (KOVÁCS, 2006). O treinamento não supervisionado disponibiliza para a rede somente os dados de entrada, não sendo possibilitado calcular o erro entre a saída prevista e a almejada. Assim, o treinamento é feito por meio de análises estáticas dos padrões das entradas, possibilitando gerar agrupamentos de semelhanças, diferenças ou associações como saída do modelo (KOVÁCS, 2006).

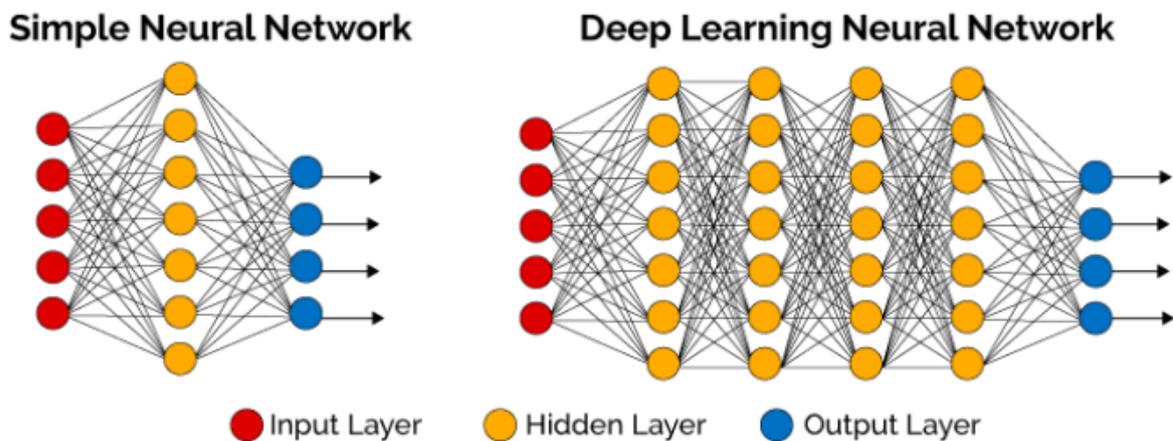
Existem três diferentes conjuntos de dados para o treino da RNA: o de treinamento, o de validação e o de teste. No caso de utilização do algoritmo de aprendizado supervisionado, o treinamento da rede incide na apresentação de uma amostra, que corresponde ao conjunto de entrada, e de uma resposta almejada, e a diferença entre a saída da rede e a saída almejada gera um sinal de erro. Durante o treinamento, os pesos sofrem uma adequação visando à correção desse sinal de erro. Para evitar o *overfitting*, que se dá quando o modelo aprende além do que se deveria sobre os dados o impossibilitando de gerar uma previsão assertiva para dados não conhecidos, é utilizado os dados do conjunto de validação, que são dados não vistos no conjunto de treinamento.

Depois de ocorrer a fase de treinamento da rede, o seu desempenho é examinado na fase de teste, na qual são analisados os resultados apresentados do conjunto de dados de teste, que não avistados durante a fase de treinamento. O desempenho reflete a qualidade da aprendizagem do modelo selecionado, bem como o seu potencial de generalizar o problema constituído (SILVA, 2020).

2.2 *Deep Learning*

É comum que Redes Neurais tradicionais e *Deep Learning* sejam relacionadas, porém existe uma diferença. Redes Neurais tradicionais podem existir com uma ou poucas camadas de neurônios, já o *Deep Learning* trabalha com a aprendizagem profunda e contém múltiplas camadas de neurônios para que o resultado seja processado de forma mais rápida e eficiente. A primeira camada da rede de aprendizagem profunda é chamada de entrada, a última camada é chamada de saída e todas as camadas entre elas são chamadas de camadas ocultas pelas quais passam as informações de camada a camada, sendo cada uma tipicamente um algoritmo simples e uniforme contendo um tipo de função de ativação, conforme pode ser observado na Figura 2.3.

Figura 2.3: Rede neural simples x aprendizagem profunda



Fonte: Data Science Academy (2023)

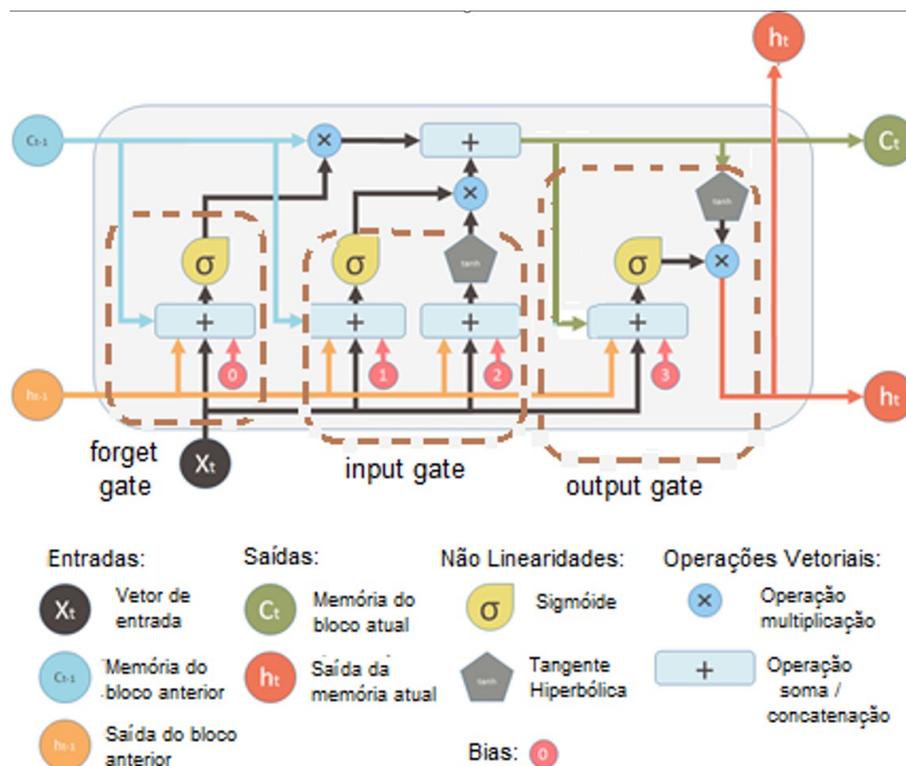
Redes Neurais Recorrentes são modelos de *Deep Learning* projetadas para o reconhecimento de padrões em sequência de dados em que os algoritmos consideram tempo e sequência, ou seja, os algoritmos têm uma dimensão temporal. As redes recorrentes possuem *loop* de *feedback* conectado com as decisões anteriores, alimentando-se de suas próprias saídas momento após momento como entrada, configurando uma memória. (HOSAKI; RIBEIRO, 2021).

2.2.1 Redes Neurais *Long Short-Term Memory* (LSTM)

A rede *Long Short-Term Memory* (LSTM) é um tipo de rede neural recorrente, e sua diferença é ser guiada pelo aprendizado a partir do gradiente, para que seja possível acessar memórias de longo prazo. (DORNELAS, 2022).

A rede LSTM foi proposta por Hochreiter e Schmidhuber (1997) e é composta por três portões (*forget gate*, *input gate* e *output gate*) e por células de memória (unidades LSTMs) que são capazes de transportar os dados até o final de uma sequência ou identificar os dados que devem ser esquecidos pela rede a partir de qualquer etapa de processamento, que podem ser observados na Figura 2.4.

Figura 2.4: Rede LSTM



Fonte: Silva (2020)

Na Figura 2.4, temos como parâmetros de entrada X_t , representando a entrada do passo corrente, h_{t-1} , referente à saída do passo anterior da célula LSTM e o C_{t-1} , como se fosse a “memória” da unidade anterior. Na saída temos os parâmetros h_t , correspondendo à saída proveniente do processamento corrente, e C_t , correspondendo ao estado corrente

de célula.

Quanto aos portões da estrutura interna da LSTM, ainda sobre a Figura 2.4, cabe destacar:

- O *forget gate* possui a função de eliminar as informações desnecessárias ao estado atual da célula, através da camada sigmoide que recebe as entradas h_{t-1} e X_t , avaliando a quantidade de informações que devem ser guardadas, produzindo uma saída entre zero e um, em que, zero simboliza “esquecer tudo” e um significa “lembrar tudo”.
- O *input gate* determina o tipo de ingerência que a memória nova terá sobre a memória antiga no sentido de atualização dos valores anteriores. Tal influência se dá através da camada tangente hiperbólica que cria um vetor C_t , podendo adicionar novos valores ao estado da célula.
- O *output gate* significa o último passo para gerar uma saída. Portanto, orienta quais as partes do estado da célula serão encaminhados à saída. Para tanto, indica quando as entradas h_{t-1} e X_t devem induzir na saída, na qual a célula C_{t-1} passa pela função tangente hiperbólica tendo seu resultado combinado com a definição oriunda do output gate, constituindo o C_t , que vai originar o novo estado da célula.

2.3 Série temporal *Univariate* x *Multivariate*

De acordo com Guillén-Navarro et al. (2020), existem duas possibilidades para a camada de entrada da Rede LSTM: *Univariate* e *Multivariate*.

Na LSTM *Univariate* é inserido na camada de entrada um único conjunto de dados sobre o mesmo tema, que configura um tipo de variável, como por exemplo, os dados de arrecadação do ICMS. Desse modo a aprendizagem e a análise dependem exclusivamente do comportamento desse conjunto de dados. Essa abordagem apresenta o benefício de não necessitar nenhuma validação no tocante a correlações com outros tipos de variáveis. (GUILLÉN-NAVARRO et al., 2020).

Na LSTM *Multivariate* são inseridos na camada de entrada dois ou mais tipos de variáveis, como por exemplo, a arrecadação do ICMS mais uma ou mais variáveis

que se relacionam com essa arrecadação. Para conseguir uma melhor aprendizagem, faz-se necessária a análise da correlação entre os tipos de variáveis que mais impactam no resultado que se deseja prever. (GUILLÉN-NAVARRO et al., 2020).

2.4 Série temporal *Single-step* x *Multi-step*

Segundo Chevillon (2007), ao se utilizar um modelo de previsão para séries temporais pode-se obter dois tipos de previsões: a *single-step* e a *multi-step*. A previsão *single-step* é quando o modelo gera apenas uma saída, que corresponde ao que seria o valor do próximo dado na sequência temporal. Na previsão *multi-step*, o modelo gera duas ou mais saídas, que seriam as sucessoras na sequência temporal e é válido ressaltar que quanto maior for o número de previsões, mais distante elas serão dos dados reais e, conseqüentemente, maior será a probabilidade erro de previsão desse modelo. (CHEVILLON, 2007).

2.5 Métricas de Avaliação

A fim de avaliar o desempenho do modelo de previsão e analisar os resultados obtidos, são utilizadas métrica de avaliação. As métricas muito utilizadas para avaliar modelos de previsão na literatura são: Erro Quadrático Médio (MSE), Raiz do Erro Médio Quadrático (RMSE), Média Percentual do Erro Absoluto (MAPE) e a R^2 que são representadas pelas equações:

$$MSE = \frac{1}{n} \times \sum_{t=1}^n (y_t - y'_t)^2 \quad (2.1)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \times \sum_{t=1}^n (y_t - y'_t)^2} \quad (2.2)$$

$$MAPE = \frac{1}{n} \times \sum_{t=1}^n \frac{(y_t - y'_t)}{y_t} \times 100 \quad (2.3)$$

$$R^2 = 1 - \frac{\sum_{t=1}^n (y_t - y'_t)^2}{\sum_{t=1}^n (y_t - \bar{y}_t)^2} \quad (2.4)$$

onde:

n = número de observações;

y_t = valor real;

y'_t = valor previsto;

\bar{y}_t = média dos valores reais;

3 Trabalhos Relacionados

Este capítulo discorre sobre sete trabalhos acadêmicos que dialogam diretamente com a temática central deste estudo, ou seja, que ajudem a mapear o que vem sendo discutido sobre Inteligência Artificial na relação com a previsão do ICMS.

3.1 Aprendizado Profundo na Previsão do ICMS: utilização de variáveis endógenas

Silva (2020) desenvolveu um modelo de rede neural, baseado em aprendizado profundo, para prever a arrecadação ICMS do estado do Rio de Janeiro, usando dois modelos de redes neurais: o *Long Short-Term Memory* (LSTM) e o *Multi Layer Perceptron* (MLP). Foram considerados dois diferentes conjuntos de entrada: um formado por valores originais da série e o outro por variáveis provenientes de cálculos matemáticos sobre valores originais da série.

Em relação à acuraria, a autora concluiu que os resultados obtidos, quando comparados com as previsões do estado do Rio de Janeiro, podem ser considerados promissores por contribuírem com a tarefa de previsão do ICMS. Os resultados do modelo LSTM foram comparados aos do modelo MLP visando a avaliação da eficácia das previsões de ambos os modelos de redes neurais e o modelo LSTM foi o que apresentou melhor acuraria nos resultados, sendo, portanto, considerado o modelo mais eficiente.

Diferentemente do trabalho de Silva (2020), a presente pesquisa realiza diferentes abordagens com o modelo de Rede Neural LSTM, a fim de se verificar se existem formas com que o LSTM possa ser mais preciso na previsão da arrecadação do ICMS.

3.2 Modelos para previsão tributária: utilização de Redes Neurais LSTM

Dornelas (2022) comparou modelos de Redes Neurais Recorrentes *Long ShortTerm Memory* (LSTM), com a abordagem *Multivariate Multi-step*, utilizando variáveis exógenas, tentando gerar uma previsão anual da arrecadação de ICMS do estado do Rio de Janeiro superior à de outras abordagens, o que, segundo o autor, pode servir de parâmetro para as decisões que as autoridades governamentais precisam tomar em relação ao emprego desse recurso tributário.

O referido autor concluiu que o modelo LSTM *Multivariate Multi-step* é mais eficiente na previsão das séries temporais anuais do ICMS no estado do Rio de Janeiro e que pode ser usado por outros órgãos públicos.

A partir da pesquisa de Dornelas (2022), este trabalho buscou averiguar diferentes possibilidades de previsão para verificar até onde foi possível ter uma melhora na previsão de arrecadação do ICMS utilizando o modelo LSTM Univariate.

3.3 Gestão de riscos: a escolha de modelos preditivos

Venturini (2021) discutiu o uso de modelos preditivos na gestão de riscos da Fiscalização Tributária do Distrito Federal com o objetivo de identificar “modelos preditivos aplicáveis ao processo de seleção de contribuintes a fiscalizar, bem como sua criação e avaliação, que levou em conta o resultado das ações fiscais já realizadas” (VENTURINI, 2021).

A autora concluiu que a proposição dos modelos, baseados no estudo da realidade pode trazer benefícios para a gestão, minimizando, assim, riscos, visto que, quanto mais ajustados forem os modelos de predição maior a chance de recolhimento de impostos que se voltam à melhoria da sociedade.

O trabalho de Venturini (2021) contribuiu para esta pesquisa, pois buscou-se aperfeiçoar o modelo LSTM com diferentes abordagens e melhorias nas ferramentas utilizadas até então para a previsão do ICMS.

3.4 Previsão de receitas de ICMS: seleção de características em cascata e técnicas de Aprendizado de Máquina

O trabalho de Carmo, Boldt e Komati (2019) versa sobre a comparação de dois modelos voltados à previsão de arrecadação de ICMS no estado do Espírito Santo. Trata-se de um modelo que usa rede neural artificial e outro que se pauta na combinação de métodos estatísticos. A pesquisa buscou validar qual dos dois modelos é o mais eficiente, trazendo estudos que destacam a relevância na definição de modelos de predição que considerem não só a série histórica de arrecadação de um estado, como a realidade do contexto atual que desafia a ter modelos de predição cada vez mais precisos, o que requer pesquisa constante.

Os autores concluíram que o modelo que funcionou para a proposição de predição para a arrecadação de ICMS do Espírito Santo pode ser usado para a previsão em outras séries econômicas correlacionadas às exportações e importações com poucas adaptações. Tal conclusão reforça a importância de novas pesquisas que possam validar modelos de predição em consonância com a realidade do lugar, mas considerando os percursos de pesquisas de funcionamento de modelos já existentes.

3.5 Redes Neurais: Previsão de Curto Prazo de Receitas Tributárias em Séries Temporais

Rosa (2020) pesquisou uma solução para melhorar a previsão para os cinco dias seguintes dos valores da arrecadação tributária do estado da Bahia, a fim de proporcionar agilidade e precisão na gestão do fluxo de caixa das finanças estaduais, de forma automatizada e com menor custo de mão de obra. Para tanto, construiu um modelo baseado em Inteligência Artificial que conseguisse realizar a previsão dos valores da arrecadação tributária diária, tomando por base o comportamento da série histórica de entrada de receitas tributárias e de outros importantes tributos.

O autor utilizou Redes *Multilayer Perceptron* (MLP) e Redes Neurais Recorren-

tes (RNR), mais especificamente as Redes de Memória de Longo Prazo (*Long Short-Term Memory* - LSTM). E para comparar o resultado usou a avaliação da viabilidade do modelo, por meio de uma Regressão Linear (RL) simples, buscando uma combinação que viabilizasse os melhores valores de predição, de acordo com as métricas consideradas. (ROSA, 2020).

Por fim, o autor concluiu que o Modelo MLP é o mais indicado para utilização prática da solução em foco, visto que houve pequena diferença na assertividade entre os modelos MLP e LSTM, e o modelo MLP possui menor custo computacional de treinamento. Portanto, segundo o autor, este trabalho pode proporcionar benefícios para a gestão das finanças pela Secretaria da Fazenda, ao permitir melhor controle de seu fluxo de caixa com menor custo de mão de obra envolvida nessa previsão.

3.6 Evasão fiscal: dados abertos e Inteligência Artificial

Xavier et al. (2022), trataram da evasão fiscal praticada pela sonegação de empresas, buscando identificar os perfis de potenciais sonegadores com o uso apenas de dados abertos, públicos, disponibilizados pela Receita Federal e pelo Conselho Administrativo Tributário do estado de Goiás.

Eles geraram três modelos utilizando os recursos *Random Forest*, Redes Neurais e Grafos. E conseguiram obter um nível de exatidão superior a 98% na predição do perfil inadimplente. Criaram, ainda, uma solução de software visual para uso e validação pelos auditores fiscais do estado de Goiás. Segundo os autores, esta pesquisa contribui ao utilizar redes neurais para grafos, no problema da evasão fiscal em comparação com abordagens clássicas de aprendizagem de máquina, como o algoritmo *Random Forest* e Redes Neurais Multicamadas. (XAVIER et al., 2022).

Os autores concluíram que a utilização de dados relacionais, representados em grafos, é equivalente aos dados tabulares utilizados em classificações, pois através dos experimentos realizados conseguiram representar as características relacionais através de dados tabulares e apontaram que o modelo clássico *Random Forest* foi o escolhido para a

solução final, pois obteve melhora de quase 8% de acurácia.

3.7 Redes Neurais Aplicadas na Previsão de Receita de ICMS

Dornelles, Schwartz e Braatz (2022) abordaram a importância da assertividade de previsões fiscais, ressaltando o aspecto da transparência para a eficiência do gasto público. Na fundamentação teórica eles explicaram o porquê da escolha das redes LSTM, trazendo exemplos de trabalhos exitosos neste assunto. Desse modo desenvolveram um modelo univariado de curto prazo utilizando Redes Neurais de Memória de Longo e Curto Prazo (LSTM) objetivando prever a arrecadação mensal do ICMS do Rio Grande do Sul.

Concluíram que o modelo utilizando redes neurais apresentou erro de previsão acumulado de -2,33% em seis previsões de um passo à frente, apresentando ganhos significativos frente a outros métodos preditivos já utilizados pela SEFAZ/RGS. Para eles, a tecnologia possivelmente incrementa soluções baseadas em pesquisas científicas que precisam avançar no sentido de adquirir maior precisão na previsão de arrecadação.

3.8 Considerações Finais

Por fim, o estudo de trabalhos relacionados com o tema deste Trabalho de Conclusão de Curso (Modelos para previsão de arrecadação do ICMS do Rio de Janeiro utilizando Deep Learning) consolidou a sua importância, visto que possui extremo significado para auxiliar a gestão pública a realizar de maneira responsável, eficiente e com transparência o seu orçamento, através da avaliação da utilização de ferramentas de aprendizado de máquina. A Inteligência Artificial aplicada para a previsão de ICMS, permite a previsão/projeção de receita dos Estados da Federação com base em dados históricos, considerando a informação acumulada. O cenário atual também precisa ser considerado, ou seja, se tem ou não inflação; quais os impactos nos preços; se a curva ascendente de inflação imprime uma resposta; se a deflação coloca uma resposta inversa. Isto porque o ICMS envolve diversos setores produtivos – indústria, comércio, transporte, combustível, serviços, entre outros –

constituindo uma significativa receita para os Estados da Federação.

4 Metodologia

Neste capítulo são apresentadas as metodologias utilizadas na implementação do modelo de *Deep Learning* para a previsão anual da arrecadação do ICMS do Rio de Janeiro com o uso de variável endógena.

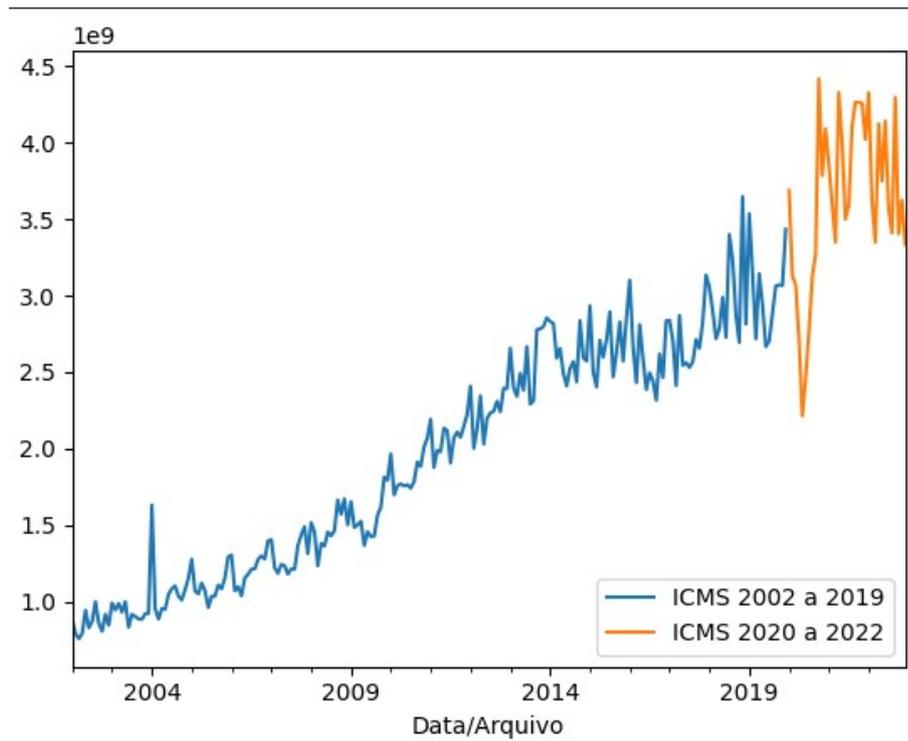
O modelo de *Deep Learning* escolhido foi o LSTM devido aos resultados satisfatórios encontrados por Dornelas (2022) e para avaliar os resultados, foram utilizadas as métricas de erros apresentadas no Capítulo 2.

4.1 Coleta de Dados

A coleta de dados de arrecadação do ICMS foi realizada no site da Secretaria de estado da Fazenda do Rio de Janeiro ⁴, no período entre 2002 e 2022. Porém devido à pandemia da COVID-19, ocorrida entre 2020 e 2022, foi observado que os dados de arrecadação do ICMS do Rio de Janeiro foram afetados, apresentando um comportamento inesperado, como é possível ver na Figura 4.1.

⁴Disponível em <http://www.fazenda.rj.gov.br/sefaz/>. Acesso em 05 de Dezembro de 2023.

Figura 4.1: Arrecadação do ICMS dos anos de 2002 até 2022



Fonte: Elaborado pelo autor

Por conta desse comportamento e também para que fosse possível a comparação com o trabalho de Dornelas (2022), o trabalho pautou-se nos dados do período de 2002 à 2019. Porém para trabalhos futuros é interessante que se busque alternativas que lidem com o comportamento inesperado.

4.2 Pré-processamento dos Dados

Nessa seção são descritos os procedimentos de pré-processamento dos dados coletados. Para que o modelo LSTM pudesse gerar previsões de forma assertiva, foi necessário retirar as casas decimais dos valores em reais(R\$) coletados da SEFAZ/RJ, respeitando a regra de arredondamento (NBR, 2014). O conjunto de dados já formatados foi dividido em três agrupamentos: treino, validação e teste, que se encontram-se descritos a seguir.

Primeiramente, o conjunto de treino foi definido pelo período de janeiro de 2002 até dezembro de 2015, que totalizou 168 meses, e esse conjunto foi utilizado para regular os pesos da rede na fase de treinamento. Em seguida, o conjunto de validação foi composto

pelo período entre janeiro de 2016 à dezembro de 2018, que gerou o somatório de 36 meses, o qual foi aproveitado para realizar a validação do modelo LSTM. Por fim, o conjunto de teste foi construído com dados de janeiro de 2019 até dezembro do mesmo ano e sua função o desempenho dos modelos analisados, além de comparar com outro modelo existente na literatura.

Após a divisão dos conjuntos, foi utilizada a função *MinMaxScaler*, da biblioteca Scikit-learn⁵, para realizar a normalização dos dados dentro do intervalo fixo de 0 a 1. Segundo Silva (2020), essa normalização facilita o processo de treinamento da rede a fim de que o modelo seja capaz de generalizar a aprendizagem realizada.

4.3 Modelo de Previsão com a rede LSTM

O modelo de Rede LSTM criado tomou por base as abordagens *univariate*, com a variável endógena sendo a arrecadação do ICMS do Rio de Janeiro, e saída *multi-step*. A abordagem de entrada *univariate* foi utilizada por apresentar um bom resultado na previsão de ICMS (SILVA, 2020). A codificação do modelo utilizou as seguintes bibliotecas: Keras⁶, TensorFlow⁷ e a linguagem Python⁸. Foram desenvolvidos 4 modelos nesse trabalho que são descritos nas seções seguintes.

4.3.1 Modelo 1: LSTM com saída de 12 meses

Tomou-se como referência o modelo LSTM *Univariate* utilizado no trabalho de Dornelas (2022), que possuía a seguinte topologia: apenas uma camada com 600 neurônios e tendo como função de ativação a *relu*, e a camada de densidade igual a 12. Este modelo foi refatorado para que fosse possível a implementação da ferramenta KerasTuner O'Malley et al. (2019) que, até encontrar a configuração desejada, realiza a busca pelos melhores hiperparâmetros possíveis para o modelo LSTM. A configuração definida para esse modelo foi o janelamento na camada de entrada que recebe 24 meses passados de ICMS e gera como saída 12 meses consecutivos, fazendo a previsão anual da arrecadação do ICMS.

⁵Disponível em <https://scikit-learn.org/stable/>. Acesso em 5 de Dezembro de 2023.

⁶Disponível em <https://keras.io/>. Acesso em 5 de Dezembro de 2023.

⁷Disponível em <https://www.tensorflow.org/?hl=pt-br>. Acesso em 5 de Dezembro de 2023.

⁸Disponível em <https://www.python.org/>. Acesso em 5 de Dezembro de 2023.

Os neurônios poderiam variar no intervalo entre 10 e 600, a função de ativação camada poderia variar entre a *relu* ou *sigmoid*, como pode ser visto na Tabela 4.1 e também foi adicionada uma camada de densidade no modelo com valor 12, que é a quantidade de meses que serão previstos.

Tabela 4.1: Hiperparâmetros possíveis para o KerasTuner

Hiperparâmetros	Número de Neurônios	Função de Ativação
Faixa de Valores	10-600	relu, sigmoid

Fonte: Elaborado pelo autor

Para a definição do *tuner* do KerasTuner foi estipulado que usaríamos a otimização bayesiana⁹, e que fossem feitos 15 *trials* com 2 execuções por *trial* e como objetivo do *tuner* definimos que a métrica utilizada seria o menor valor da Média Percentual do Erro Absoluto (MAPE). Cada *trial* testa uma combinação dos hiperparâmetros estabelecidos na configuração citada acima. Após, foram definidos os seguintes parâmetros para a função *search*, ela teve o número de 350 *epochs*, o *batch size* de tamanho 32 e o *early stop* que monitorou a *val_loss* com 100 de paciência.

Nesse modelo o KerasTuner definiu os seguintes hiperparâmetros que compuseram a configuração da rede LSTM:

Tabela 4.2: Hiperparâmetros definidos pelo KerasTuner

Número de neurônios	Função de ativação
470	relu

Fonte: Elaborado pelo autor

Com esses hiperparâmetros definidos, o modelo LSTM foi composto por apenas uma camada de 470 neurônios com a função de ativação nessa camada sendo a *relu* e uma camada de densidade sendo 12.

4.3.2 Modelos com abordagem M_x

Nesta abordagem o M_x representa o modelo LSTM onde x pode variar de 1 à 12 e ele indica a quantidade de saídas que o modelo possui. Com isso, o número de modelos

⁹Disponível em https://keras.io/api/keras_tuner/tuners/bayesian/. Acesso em 5 de Dezembro de 2023.

necessários para conseguir-se prever a arrecadação anual do ICMS varia de acordo com o valor do janelamento estipulado para o x . Estes modelos foram criados com a intenção de validarmos a ideia trazida por Chevillon (2007), que diz que previsões mais próximas da série temporal possuem uma menor probabilidade de erro.

4.3.2.1 Modelo 2: Junção de 12 modelos LSTM

Cada modelo LSTM que compõe essa junção é chamado de M_x , onde x varia de 1 a 12, por isso, precisou-se de 12 modelos LSTM para que tivéssemos a previsão do ICMS do próximo ano por completo, a Figura 4.3 representa a junção desses modelos. Quando $x = 1$, o modelo M_1 gera 1 saída representada por janeiro de 2019 em azul. Já no momento em que $x = 2$ o modelo M_2 gera 2 saídas, janeiro de 2019 em laranja e fevereiro de 2020 em azul. E assim sucessivamente até que o modelo M_{12} , que gera 12 meses na saída representadas na Figura 4.2 por janeiro de 2019 até dezembro de 2019, mas note que somente dezembro está em destaque azul.

A junção desses 12 modelos consiste em pegar as saídas, representadas na Figura 4.2, em azul de cada modelo M_x , $x = 1 \dots 12$, e conectar formando uma série anual de previsão de ICMS, como mostra a Figura 4.3.

Observa-se na Figura 4.2 que todos os modelos M_x , $x = 1$ até $x = 12$ recebem 24 meses como entrada, representados no janelamento sem cor, na cor laranja são os dados que a rede neural previu, porém não foram utilizados. Já os dados na cor azul são os dados que foram previstos pela rede, que compuseram a série temporal prevista, como pode-se ver na Figura 4.3, e que foi comparada com a série histórica no cálculo das métricas de erro que avaliam o desempenho do modelo.

Figura 4.2: Janelamento de entrada e saída dos 12 modelos LSTM

M1	M2	M3	M...	M12
jan/18	jan/18	jan/18	M...	jan/18
fev/18	fev/18	fev/18	M...	fev/18
mar/18	mar/18	mar/18	M...	mar/18
abr/18	abr/18	abr/18	M...	abr/18
mai/18	mai/18	mai/18	M...	mai/18
jun/18	jun/18	jun/18	M...	jun/18
jul/18	jul/18	jul/18	M...	jul/18
ago/18	ago/18	ago/18	M...	ago/18
set/18	set/18	set/18	M...	set/18
out/18	out/18	out/18	M...	out/18
nov/18	nov/18	nov/18	M...	nov/18
dez/18	dez/18	dez/18	M...	dez/18
jan/19	jan/19	jan/19	M...	jan/19
fev/19	fev/19	fev/19	M...	fev/19
mar/19	mar/19	mar/19	M...	mar/19
abr/19	abr/19	abr/19	M...	abr/19
mai/19	mai/19	mai/19	M...	mai/19
jun/19	jun/19	jun/19	M...	jun/19
jul/19	jul/19	jul/19	M...	jul/19
ago/19	ago/19	ago/19	M...	ago/19
set/19	set/19	set/19	M...	set/19
out/19	out/19	out/19	M...	out/19
nov/19	nov/19	nov/19	M...	nov/19
dez/19	dez/19	dez/19	M...	dez/19
jan/20	jan/20	jan/20	M...	jan/20
	fev/20	fev/20	M...	fev/20
		mar/20	M...	mar/20
				abr/20
				mai/20
				jun/20
				jul/20
				ago/20
				set/20
				out/20
				nov/20
				dez/20

Fonte: Elaborado pelo autor

Figura 4.3: Série temporal prevista na abordagem M_x

M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12
jan/20	fev/20	mar/20	abr/20	mai/20	jun/20	jul/20	ago/20	set/20	out/20	nov/20	dez/20

Fonte: Elaborado pelo autor

4.3.2.2 Modelo 3: Junção de 2 modelos LSTM

Nesta abordagem cada modelo LSTM é chamado de M_{6x} , onde $x = 1...2$. Dessa forma foi preciso de dois modelos para que a série anual prevista do ICMS fosse gerada.

É possível observar na Figura 4.4 que ambos modelos recebem 24 meses e que quando $x = 1$, foram geradas 6 saídas referentes aos meses de janeiro de 2020 à junho de 2020 e quando $x = 2$ foram gerados 12 saídas referentes aos meses de janeiro de 2020 à dezembro de 2020, note que somente os últimos 6 meses estão em azul. Como pode-se ver na Figura 4.5 os meses representados pela cor azul foram unidos para ter-se a série temporal completa e pronta para análise.

Figura 4.4: Janelamento de entrada e saída dos 2 modelos LSTM

M1	M2
jan/18	jan/18
fev/18	fev/18
mar/18	mar/18
abr/18	abr/18
mai/18	mai/18
jun/18	jun/18
jul/18	jul/18
ago/18	ago/18
set/18	set/18
out/18	out/18
nov/18	nov/18
dez/18	dez/18
jan/19	jan/19
fev/19	fev/19
mar/19	mar/19
abr/19	abr/19
mai/19	mai/19
jun/19	jun/19
jul/19	jul/19
ago/19	ago/19
set/19	set/19
out/19	out/19
nov/19	nov/19
dez/19	dez/19
jan/20	jan/20
fev/20	fev/20
mar/20	mar/20
abr/20	abr/20
mai/20	mai/20
jun/20	jun/20
	jul/20
	ago/20
	set/20
	out/20
	nov/20
	dez/20

Fonte: Elaborado pelo autor

Figura 4.5: Janelamento de entrada e saída dos 2 modelos LSTM

M1						M2					
jan/20	fev/20	mar/20	abr/20	mai/20	jun/20	jul/20	ago/20	set/20	out/20	nov/20	dez/20

Fonte: Elaborado pelo autor

4.3.2.3 Modelo 4: Junção de 3 modelos LSTM

Nessa abordagem, cada modelo LSTM é chamado de M_{4x} onde o x pode variar entre 3 possibilidades, $x = 1$, $x = 2$ e $x = 3$.

Como visto na Figura 4.6, para cada modelo M_{4x} é inserido 24 meses como entrada e quando $x = 1$ temos 4 meses de saída, quando $x = 2$ temos 8 meses de saída e que quando $x = 3$ temos 12 meses de saída, porém note que sempre os últimos 4 meses estão representados na cor azul. Esses meses são unificados para que possamos ter a série de previsão anual do ICMS, como pode-se ver na Figura 4.7.

Figura 4.6: Janelamento de entrada e saída dos 3 modelos LSTM

M1	M2	M3
jan/18	jan/18	jan/18
fev/18	fev/18	fev/18
mar/18	mar/18	mar/18
abr/18	abr/18	abr/18
mai/18	mai/18	mai/18
jun/18	jun/18	jun/18
jul/18	jul/18	jul/18
ago/18	ago/18	ago/18
set/18	set/18	set/18
out/18	out/18	out/18
nov/18	nov/18	nov/18
dez/18	dez/18	dez/18
jan/19	jan/19	jan/19
fev/19	fev/19	fev/19
mar/19	mar/19	mar/19
abr/19	abr/19	abr/19
mai/19	mai/19	mai/19
jun/19	jun/19	jun/19
jul/19	jul/19	jul/19
ago/19	ago/19	ago/19
set/19	set/19	set/19
out/19	out/19	out/19
nov/19	nov/19	nov/19
dez/19	dez/19	dez/19
jan/20	jan/20	jan/20
fev/20	fev/20	fev/20
mar/20	mar/20	mar/20
abr/20	abr/20	abr/20
	mai/20	mai/20
	jun/20	jun/20
	jul/20	jul/20
	ago/20	ago/20
		set/20
		out/20
		nov/20
		dez/20

Fonte: Elaborado pelo autor

Figura 4.7: Janelamento de entrada e saída dos 3 modelos LSTM

M1				M2				M3			
jan/20	fev/20	mar/20	abr/20	mai/20	jun/20	jul/20	ago/20	set/20	out/20	nov/20	dez/20

Fonte: Elaborado pelo autor

5 Estudo de Caso

Neste capítulo são apresentados todos os resultados obtidos nos modelos LSTM implementados.

5.1 Modelo 1: LSTM *Univariate Multi-step* 12 meses

No trabalho de Dornelas (2022), esse modelo foi implementado e ele buscou pela melhor configuração sem usar o mecanismo de busca pela configuração existente nas bibliotecas. A fim de comparar com nossos experimentos, foi implementado esse mesmo modelo, mas deixando a busca pela melhor configuração através do KerasTuner, conforme explicado no Capítulo 4.

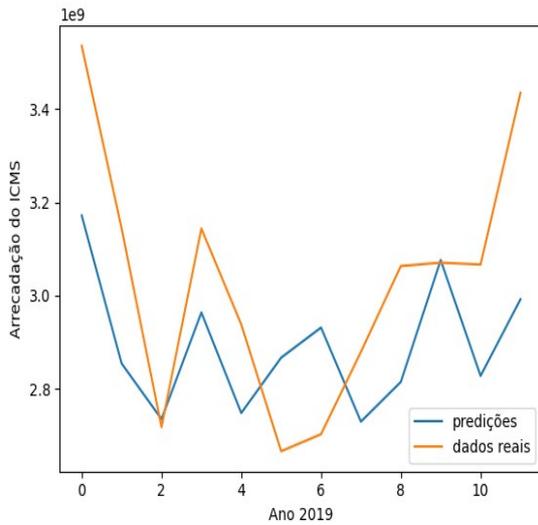
Segue que a implementação desse trabalho, com o uso do KerasTuner, apresentou melhores resultados comparados aos de Dornelas (2022) como pode-se ver na Tabela 5.1

Tabela 5.1: Métricas de erro para comparação entre modelos com e sem KerasTuner

	Modelo multi-step 12 meses sem KerasTuner	Modelo multi-step 12 meses com KerasTuner
RMSE(R\$):	263.604.312,0	165.045.413,1
MAPE (%):	6.88	4.22
MSE(R\$):	69.487.257.974.734.800	27.039.080.132.083.712

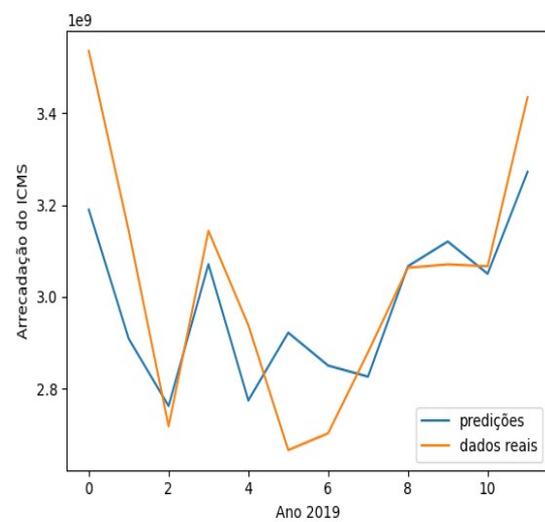
Fonte: Elaborado pelo autor

Na Tabela 5.1 pode-se verificar pelas métricas de erro obtidas pelos dois modelos, que o modelo com KerasTuner possuiu uma ssertividade maior.

Figura 5.1: Comparação entre os modelos *univariate* com e sem KerasTuner

(a) Previsão LSTM sem KerasTuner

Fonte: Dornelas (2022)



(b) Previsão LSTM com KerasTuner

Fonte: Elaborado pelo autor

Como é possível identificar na Figura 5.1, o modelo com KerasTuner conseguiu se aproximar mais da série temporal real.

5.2 Modelos LSTM M_x , M_{6x} e M_{4x}

A segunda abordagem de previsão escolhida também foi a *multi-step*, porém com saídas M_x . Abaixo encontra-se a Tabela 5.2 com os resultados obtidos.

Tabela 5.2: Métricas de avaliação dos modelos analisados

	Modelo <i>multi-step</i> 12 meses sem KerasTuner (DORNELAS, 2022)	Modelo <i>multi-step</i> 12 meses	Modelo M_{6x}	Modelo M_{4x}	Modelo M_x
RMSE (R\$):	263.604.312,0	165.045.413,1	146.065.692,8	138.730.245,7	115.329.212,0
MAPE (%):	6.88	4.22	4.06	3.12	2.54
MSE (R\$):	69.487.257.974.734.800	27.039.080.132.083.712	20.641.427.520.448.606	19.246.081.073.184.768	13.300.827.170.465.886
R-dois [0,1]:	Não aplicável	Não aplicável	0.72	0.75	0.79

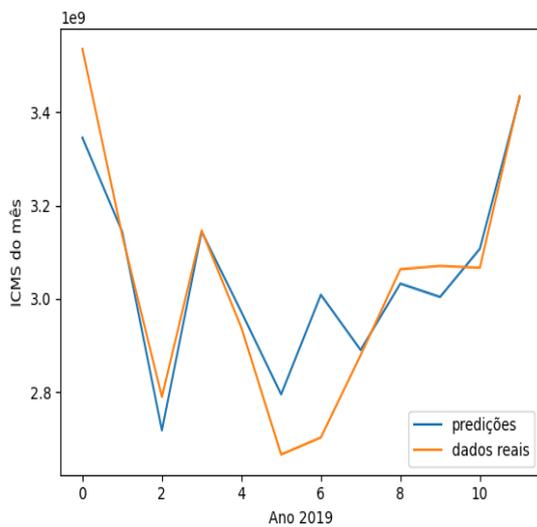
Fonte: Elaborada pelo autor.

De acordo com a Tabela 5.2, constata-se uma assertividade maior do modelo M_x na previsão dos valores de arrecadação do ICMS do Rio de Janeiro, pois durante o período de doze meses, existem vários pontos que convergem com os valores de fato arrecadados e,

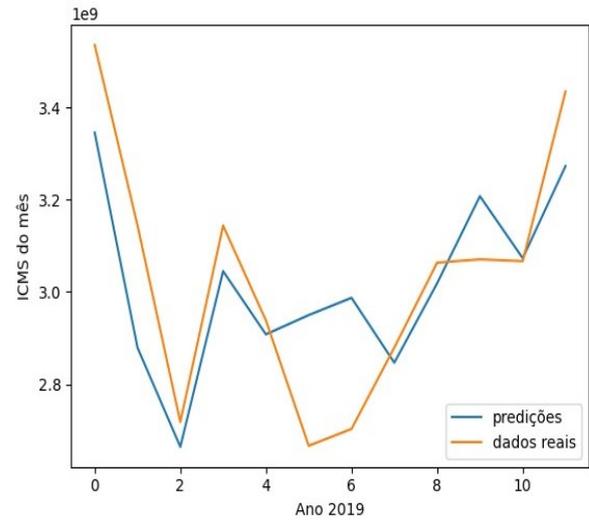
essa maior assertividade é demonstrada pelas métricas de erro obtidas quando comparadas com outros modelos.

Em seguida são apresentados os gráficos de comparação entre as predições dos modelos apresentados na Seção 4.3.2 e a série temporal real do ICMS.

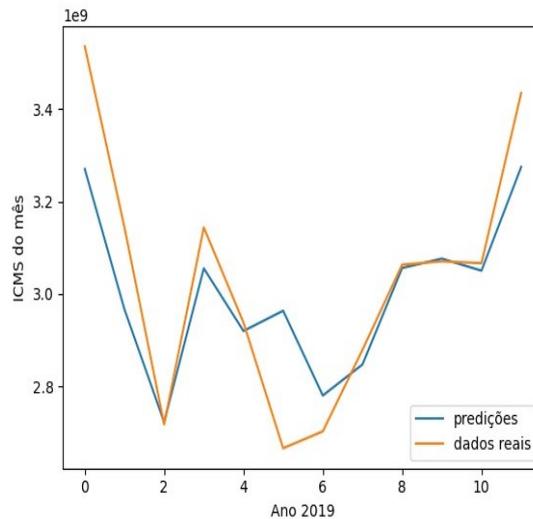
Figura 5.2: Comparação entre os modelos M_x



(a) M_x junção dos 12 modelos



(b) M_x intervalo 6 meses



(c) M_x intervalo 4 meses

Fonte: Elaborado pelo autor

Com a análise de todos os gráficos, pode-se perceber que quanto menor for o intervalo de meses, mais assertiva a previsão fica e isso reforça o que é dito por Chevillon (2007) que ter a previsão mais próxima da série temporal, possui uma menor probabilidade de erro.

6 Conclusões e Trabalhos Futuros

Esta pesquisa trabalhou com o pressuposto de que modelos de predição para qualificar a arrecadação de ICMS são necessários, uma vez que estimar, prever e controlar as receitas fiscais, tem se estabelecido como um elemento estruturante para a elaboração de ações fundamentais quanto ao planejamento e execução do dinheiro público.

Desse modo, o objetivo geral deste trabalho foi identificar as contribuições do modelo *Deep Learning* para a previsão de arrecadação do ICMS do estado do Rio de Janeiro. Para tanto, foi realizada uma análise sobre a eficiência do modelo *Long Short-Term Memory* (LSTM), com base nos dados retirados do site da SEFAZ/RJ, do período entre janeiro de 2002 e dezembro de 2019.

A partir dos resultados obtidos com o estudo de caso, foi possível concluir que o modelo LSTM *univariate* com a abordagem da junção de 12 modelos que foram chamados de $M_x, x = 1...12$, foi eficiente na predição anual do ICMS do estado do Rio de Janeiro e pode ser uma metodologia utilizada pelo estado na previsão da arrecadação desse imposto.

Quanto a trabalhos futuros, sugere-se que seja realizada a execução do modelo LSTM com KerasTuner e as abordagens *single-step* e M_x com a junção da entrada *multivariate*, pois dessa forma será possível analisar a arrecadação do ICMS do Rio de Janeiro utilizando variáveis exógenas, que no trabalho de Dornelas (2022) provou-se que influenciam a previsão do ICMS. Uma segunda possibilidade para o modelo LSTM, pode ser o aumento dos horizontes de entrada, caso a rede possua mais dados para treinamento.

Outra sugestão seria utilizar outro modelo de Rede Neural Artificial, como por exemplo, a *Gated Recurrent Unit* (GRU) que pode ser inclusive implementada em conjunto com as camadas LSTM.

Bibliografia

- CARMO, M. do; BOLDT, F.; KOMATI, K. Previsão de receitas de icms do estado do espírito santo através de seleção de características em cascata e técnicas de aprendizado de máquina. In: SBC. *Anais do XVI Encontro Nacional de Inteligência Artificial e Computacional*. [S.l.], 2019. p. 118–129.
- CHEVILLON, G. Direct multi-step estimation and forecasting. *Journal of Economic Surveys*, Wiley Online Library, v. 21, n. 4, p. 746–785, 2007.
- DORNELAS, A. d. F. *Modelos para Previsão Tributária Utilizando Redes Neurais LSTM*. Monografia (Graduação) — Universidade Federal de Juiz de Fora, 2022.
- DORNELLES, G. Z.; SCHWARTZER, F. R.; BRAATZ, J. Redes neurais aplicadas na previsão de receita de icms no rio grande do sul. 2022.
- GUILLÉN-NAVARRO, M. A.; MARTÍNEZ-ESPAÑA, R.; BUENO-CRESPO, A.; MORALES-GARCÍA, J.; AYUSO, B.; CECILIA, J. M. A decision support system for water optimization in anti-frost techniques by sprinklers. *Sensors*, MDPI, v. 20, n. 24, p. 7129, 2020.
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2001.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.
- HOSAKI, G. Y. G. Y.; RIBEIRO, D. F. Deep learning: ensinando a aprender. 275, 2021.
- JUNQUEIRA, L. C.; CARNEIRO, J. *Histologia Básica, Texto e Atlas*. [S.l.]: Guanabara Koogan, 2013.
- KOVÁCS, Z. L. *Redes neurais artificiais: Fundamentos e Aplicações*. [S.l.]: Editora Livraria da Física; 4ª edição, 2006.
- NBR, A. 5891: Regras de arredondamento na numeração decimal. *NBR 4: Norma Brasileira Probatória*, 2014.
- O'MALLEY, T.; BURSZTEIN, E.; LONG, J.; CHOLLET, F.; JIN, H.; INVERNIZZI, L. et al. *KerasTuner*. 2019. (<https://github.com/keras-team/keras-tuner>).
- REZENDE, F. Icms, gênese, mutações, atualidade e caminhos para a recuperação. FGV/-Projetos; IDP, 2012.
- ROSA, E. Previsão de curto prazo de receitas tributárias em séries temporais com uso de redes neurais. Centro Universitário SENAI CIMATEC, 2020.
- SACHSIDA, A. Tributação no brasil: estudos, ideias e propostas: Icms, seguridade social, carga tributária, impactos econômicos. Instituto de Pesquisa Econômica Aplicada (Ipea), 2017.

SILVA, P. M. F. d. *Aprendizado Profundo Aplicado na Previsão de Receita Tributária Utilizando Variáveis Endógenas*. Monografia (Graduação) — Universidade do Estado do Rio de Janeiro, 2020.

VELLASCO, M. M. *Modelo Estocástico Periódico baseado em Redes Neurais*. Tese (Doutorado) — PUC-Rio, 2010.

VENTURINI, F. C. *Uso de modelos preditivos na gestão de riscos da Fiscalização Tributária*. Dissertação (Mestrado) — Universidade de Brasília, 2021.

XAVIER, O. C.; PIRES, S. R.; MARQUES, T. C.; SOARES, A. d. S. Identificação de evasão fiscal utilizando dados abertos e inteligência artificial. *Revista de Administração Pública*, SciELO Brasil, v. 56, p. 426–440, 2022.