

Utilizando Algoritmos de Deep Learning para a Previsão da Taxa de Inflação

Using Deep Learning Algorithms for Prediction of the Inflation Rate

Uso de Algoritmos de Aprendizaje Profundo para la Predicción de la Tasa de Inflación

Como citar:

Santos, Gustavo O.; Lara, Hygor S. & Mesquita Junior, José E. (2025). Utilizando Algoritmos de Deep Learning para a Previsão da Taxa de Inflação. *Revista Gestão & Tecnologia*, vol. 25, nº 3, p: 314-326

Gustavo Oliveira Santos, Consultor independente em TI
<https://orcid.org/0009-0000-9358-3783>

Hygor Santiago Lara, Doutorando em Engenharia Mecânica pela Universidade de Campinas (UNICAMP). Professor (PED) no curso de graduação em Engenharia Mecânica na UNICAMP.
<https://orcid.org/0000-0002-4835-5498>

José Eduardo Mesquita Junior, Mestrado Profissional em Administração de Empresas pela Fundação Pedro Leopoldo. Coordenador de Engenharia de Suporte ao Cliente - IDV Latin America (IVECO Group)
<https://orcid.org/0009-0003-6577-8155>

"Os autores declaram não haver qualquer conflito de interesse de natureza pessoal ou corporativa, em relação ao tema, processo e resultado da pesquisa"

Editor Científico: José Edson Lara
Organização Comitê Científico
Double Blind Review pelo SEER/OJS
Recebido em 20/01/2025
Aprovado em 20/06/2025



This work is licensed under a Creative Commons Attribution – Non-Commercial 3.0 Brazil

Resumo

Objetivo: Este artigo demonstra as previsões de modelos de *machine learning* como as RNNs e LSTMs, sendo aplicadas na previsão da taxa de inflação.

Originalidade/Relevância: O uso de modelos de *machine learning* para previsões de mudanças de preços é bastante abordado na indústria. Esse artigo contribui para o avanço da área ao analisar parâmetros e seus resultados de forma individual e conjunta, mostrando novos resultados e servindo como guia para futuros projetos.

Metodologia/Abordagem: Foi utilizado dados dos Estados Unidos, sendo os parâmetros o IPC, a taxa de juros dos fundos federais, o crescimento do PIB Real e a velocidade do M2. Onde o banco de dados foi normalizado e dividido em 3 lotes menores, e em cada lote foi feito previsões, e essas previsões foram comparadas com os valores de teste.

Principais Resultados: Todos os parâmetros utilizados mostraram ser eficiência em auxiliar nas previsões além do banco de dados, gerando previsões com correlações acima de 0,65% e erros de MAE menores do que 3.

Contribuições teóricas/metodológicas: Demonstração do peso de cada parâmetro para os resultados, e explicações econômicas sobre mudanças nos parâmetros e como essas mudanças afeta as capacidades preditivas dos modelos.

Contribuições Sociais: Esse estudo contribui tanto para indústrias que necessitam de boas previsões sobre a inflação futura, e pesquisadores que desejam criar modelos mais precisos.

Palavras-chaves: Inflação, Previsões, *Machine Learning*.

Abstract

Objective: This article demonstrates the predictions of machine learning models such as RNNs and LSTMs, being applied to predict the inflation rate.

Originality/Relevance: The use of machine learning models to predict price changes is widely discussed in the industry. This article contributes to the advancement of the area by analyzing parameters and their results individually and jointly, showing new results and serving as a guide for future projects.

Methodology/Approach: Data from the United States were used, with the parameters being the CPI, the federal funds interest rate, the growth of Real GDP and the velocity of M2. Where the database was normalized and divided into 3 smaller batches, and in each batch predictions were made, and these predictions were compared with the test values.

Main Results: All parameters used were shown to be efficient in assisting in forecasts beyond the database, generating forecasts with correlations above 0.65% and MAE errors lower than 3.

Theoretical/methodological contributions: Demonstration of the weight of each parameter for the results, and economic explanations about changes in the parameters and how these changes affect the predictive capabilities of the models.

Social Contributions: This study contributes both to industries that need good forecasts about future inflation, and researchers who want to create more accurate models.

Keywords: Inflation, Forecasts, Machine Learning.

Resumen

Objetivo: Este artículo demuestra las predicciones de modelos de aprendizaje automático como RNN y LSTM, que se aplican para predecir la tasa de inflación.

Originalidad/Relevancia: El uso de modelos de aprendizaje automático para predecir cambios de precios es un tema ampliamente discutido en la industria. Este artículo contribuye al avance del campo analizando los parámetros y sus resultados de forma individual y conjunta, mostrando nuevos resultados y sirviendo como guía para proyectos futuros.

Metodología/Enfoque: Se utilizaron datos de Estados Unidos, cuyos parámetros fueron el IPC, la tasa de interés de los fondos federales, el crecimiento del PIB real y la velocidad del M2. Donde la base de datos fue normalizada y dividida en 3 lotes más pequeños, y en cada lote se realizaron predicciones, y estas predicciones se compararon con los valores de prueba.

Resultados principales: Todos los parámetros utilizados demostraron ser eficientes para ayudar en las predicciones más allá de la base de datos, generando predicciones con correlaciones superiores a 0,65% y errores MAE inferiores a 3.

Aportaciones teóricas/metodológicas: Demostración del peso de cada parámetro para los resultados, y explicaciones económicas sobre los cambios en los parámetros y cómo estos cambios afectan a las capacidades predictivas de los modelos.

Contribuciones sociales: Este estudio contribuye tanto a las industrias que necesitan buenas predicciones sobre la inflación futura como a los investigadores que desean crear modelos más precisos.

Palabras clave: Inflación, Pronósticos, Aprendizaje Automático.

Introdução

A inflação é um fenômeno reconhecido há muito tempo, e que se origina principalmente por fatores de políticas que podem desencadear grandes aumentos na quantidade de moeda, ou de causas naturais como choques de oferta que levam inevitavelmente a uma escassez. Tanto as autoridades e indivíduos se preocupam com o nível da inflação, buscando minimizar os danos causados por ela. Na história da economia é reconhecido vários episódios históricos de níveis elevados de inflação, como o estouro da Bolha do Mississippi, as descobertas de ouro nas Américas, e o caso da hiperinflação do Zimbábue (Knight, 2002 e Hanke, 2009). Que demonstram que descuidos por parte das autoridades podem causar severos danos para toda uma população.

O aumento na taxa de inflação traz consigo vários danos para os agentes econômicos, por exemplo, para os poupadores, que começam a notar uma desvalorização das suas poupanças; os tomadores de empréstimos que pagam juros mais altos por causa das expectativas de inflação; e os credores que

subestimam a taxa inflação sofrem percas com retornos desvalorizados (Bach, 1957). Já as autoridades tentam evitar inflações acima das metas para evitar desequilíbrios macroeconômicos e perdas de produtividade.

Os modelos de *machine learning* e *deep learning*, conseguem aliviar esses empecilhos graças as suas capacidades preditivas advinda de vários tipos de modelos. Como já reconhecido eles são extremamente úteis para previsões de mudanças nos níveis de preços, o que é bem demonstrado no uso da previsão de preços de automóveis (Chadak, 2019), e também na previsão de mudanças nos preços de ações e commodities.

No presente artigo serão utilizados algoritmos de *deep learning* para a previsão da taxa de inflação futura. Sendo os modelos as *recurrent neural network* (RNN) e *Long short-term memory* (LSTM). Essas redes neurais se estruturam em camadas, onde cada camada recebe uma entrada e gera uma saída. Esses modelos se diferenciam dos outros, pois cada saída é realimentada na célula do modelo auxiliando na previsão dos próximos valores, sendo muito úteis para atividades de séries temporais.

O objetivo do presente artigo é a criação de modelos de *machine learning* para a previsão da taxa de inflação futura. Os algoritmos que foram utilizados nesse trabalho, foram as RNNs e LSTMs, que terão uma maior explicação dos seus conceitos e funcionalidades na seção dos modelos preditivos e na metodologia. Já os objetivos específicos escolhidos para o artigo são os seguintes: validar as previsões em comparação com os valores reservados para teste, e averiguar os parâmetros que geram maior peso para as previsões dos modelos preditivos.

Elementos da literatura

Os preços de mercado surgem da relação entre as unidades monetárias e as unidades dos bens, conforme relata a vastíssima literatura sobre o tema. Um aumento na oferta de moeda nos estoques dos indivíduos fará eles gastarem esse aumento em bens, levando a um aumento dos preços (inflação). Já numa economia onde a quantidade de moeda é fixa, e acompanhada com um aumento na produção, os preços vão diminuir (deflação) (Bagus, 2009).

Esses mecanismos de preços podem ser mais aprofundados usando a equação da teoria quantitativa de moeda $MV = PY$. Onde M representa as unidades monetárias, V representa a velocidade de circulação

de um meio monetário, refere-se ao nível de preços, e Y a produção total da economia (Sakib-bin-Amin, 2011).

Um aumento na variável M sem ser correspondido por um crescimento no atributo Y , vai resultar num aumento de preços. Mas pode ocorrer que um aumento de M não tenha o mesmo efeito do que o esperado, por causa das variações na variável V , onde se têm uma redução da velocidade de circulação das unidades monetárias, sinalizando uma diminuição dos gastos dos agentes do mercado.

Tributos

Os atributos são referentes as variáveis de entrada que foram inseridas nos nossos modelos. No projeto foram utilizadas 4 variáveis de entrada: o IPC (CPI) que mede as variações nos níveis de preços de produtos padrões que as famílias americanas compram para consumo, a taxa de juros dos fundos federais, o PIB Real da economia, e a velocidade de circulação do agregado monetário $M2$.

Taxa de juros

A taxa de juros dos fundos federais é determinada pelos empréstimos de curtíssimo que os bancos fazem entre si. O banco central consegue influenciar essa taxa de juros utilizando as ferramentas monetárias. Ao utilizar as ferramentas monetárias para aumentar a oferta de liquidez, ele leva a taxa de juros para baixo – aumentando os gastos dos consumidores e das firmas; já quando ele utiliza os seus instrumentos para contrair a liquidez no mercado, ele aumenta a taxa de juros – diminuindo os gastos.

No entanto, isso não significa controle absoluto sobre os resultados, já que o banco central só controla o suprimento de moeda e crédito, mas não possui controle sobre a demanda. Bancos com ativos de baixa qualidade podem querer manter mais reservas, os bancos também podem ficar relutantes em fazer empréstimos para mutuários com garantias ruins; já as pessoas e firmas tendem licitar menos empréstimos quando os seus passivos superam muito os seus ativos, fazendo com que eles gastem menos. Esses empecilhos fazem que taxa de juros baixas não estimulem a demanda agregada e nem os preços.

PIB Real

O PIB Real mede a produção final de uma vasta gama de bens e serviços feitos num determinado território. Diferente do PIB Nominal, o PIB Real tenta capturar mudanças na produção econômica sem

levar em consideração mudanças nos níveis de preços como inflação e deflação, assim conseguindo distinguir crescimento econômico de aumentos de preços e salários. Ele também serve para saber se uma economia está em expansão ou recessão, já que ele pode ser utilizado para comparar as taxas de crescimentos entre os trimestres de um ano ou entres trimestres de outros anos.

Velocidade do M2

A velocidade do dinheiro reflete o número de vezes que uma unidade monetária circulou em um determina período de tempo. Geralmente as unidades monetárias circulam mais rapidamente quando a economia está em expansão, e tende a diminuir em cenários de recessão. Outros fatores como incerteza, nível da taxa de juros, e de endividamento podem altera a velocidade de circulação de um meio de troca.

Modelos preditivos

Os modelos de *machine learning* foram adquirindo importância e relevância com a grande quantidade massiva de dados e do grande avanço de processamento computacional que foram surgindo nas décadas recentes. Os modelos que mais se destacaram nesse sentido são as redes neurais.

As redes neurais são modelos estruturados em várias camadas, onde essas camadas são compostas de “neurônios”, que estão interconectados entre si. Os neurônios de uma camada processam as informações e passam para a próxima camada. Cada nó na primeira camada oculta recebe uma entrada e os processa com uma função de ativação e envia, então a saída da primeira é a entrada para a segunda camada, e onde se aplica outra função linear, e os resultados são passados para a última camada (Hao, 2016).

A RNN é um tipo de rede neural que lida com dados que contém relações de dependência com os valores dos vetores anteriores. Ela possui um estado oculto, que mantém a essência de tudo que foi anteriormente passado. Esse processo oculto é feito quando a célula emite a saída, e essa saída é reutilizada na célula para uso em um passo de tempo posterior (Koutnik, 2014).

Em cada camada da RNN, os parâmetros são compartilhados entre si. Diferente das redes neurais mais básicas como as redes feedforwards, onde cada nó possui diferentes pesos, as redes neurais recorrentes compartilham os mesmos parâmetros de pesos dentro de camada no modelo. E onde os pesos são ajustados utilizando um método de retropropagação com a descida de

gradiente. A retropropagação é onde as somas de todos os erros de cada série temporal é somada, e o modelo ajusta os parâmetros pro estado mais adequado (Ahmad, 2004).

Já na LSTM funciona de maneira semelhante, mas com mais camadas interagindo no processo. O portão de esquecimento define quanto do estado anterior você que deixar passar. O portão de entrada filtra quanto do estado recém-computado você vai transmitir, e o portão de saída determina a quantidade do estado interno deve passar para a próxima camada. E o estado oculto é computado com base na entrada atual e no estado oculto anterior (Pal, 2018).

Por esses modelos lidarem com vetores sequências, se tornou comum eles serem utilizados em tarefas relacionadas a séries temporais. Os dados de séries temporais possuem uma alta dependência entre as suas variáveis. Cada vetor nos parâmetros depende dos seus vizinhos passados e futuros, dessa forma gerando atributos onde os modelos buscam encontrar padrões não aleatórios, e usar as observações adquiridas para poderem fazer previsões futuras.

Metodologia

A correlação captura a tendência de subidas e quedas nas previsões em relação aos valores reais (quanto maior a correlação melhor), tendo como alvo uma correlação superior a 70% em todas as partições. Já o erro capta o nível de diferença das previsões para os dados de teste (quanto menor o erro melhor), tendo como alvo um erro menor que 3 em ambas partições.

Para a previsão do nível de inflação por parte dos modelos, se torna extremamente útil visar a tendência do que uma previsão totalmente precisa, já que o nível de preços é só uma média ponderada de alguns bens em um determinado período de tempo. Na economia real, os preços dos bens são heterogêneos, uns sobem mais rápido do que outros, preços variam de local, marcar, e tipo de bem. E para visualizar o erro das previsões para o valor real será utilizado a métrica de erro MAE.

E para evitar que problemas com o *overfitting* prejudique as previsões, foi utilizado um método de validação cruzada para dados de séries temporais. Onde o banco de dados é dividido em 3, e cada uma das partições irá retornar uma correlação e um erro. Os dados foram ajustados para um período de tempo mensal, e passaram por um processo de normalização, para facilitar a aprendizagem pros modelos de *machine learning*.

Resultados

A seguir são apresentados os resultados dos estudos, assim como suas análises, em função dos modelos adotados.

Modelo 1

Alimentado a rede neural com o nível de preços e a taxa de juros numa LSTM de 3 camadas, à primeira contendo um valor de 32 neurônios, a segunda 8, e a terceira camada 8 neurônios (LSTM 32x8x8x1). O modelo alcança uma correlação de 0,81% na primeira partição e um erro de 2,467; na segunda ele consegue uma correlação de 0,95% e um erro de 0,287; e na terceira uma correlação de 0,68% e erro de 1,851.

Modelo 2

Adicionando o PIB Real no banco de dados, e usando uma RNN de duas camadas, com a primeira camada tendo 16 neurônios, e a segunda 4 (RNN 16x4x1). O modelo alcança uma correlação de 0,76% e um erro de 3,833 na primeira partição; na segunda ele consegue uma correlação de 0,93% com erro de 0,099; e na última uma correlação de 0,81% e erro de 1,871.

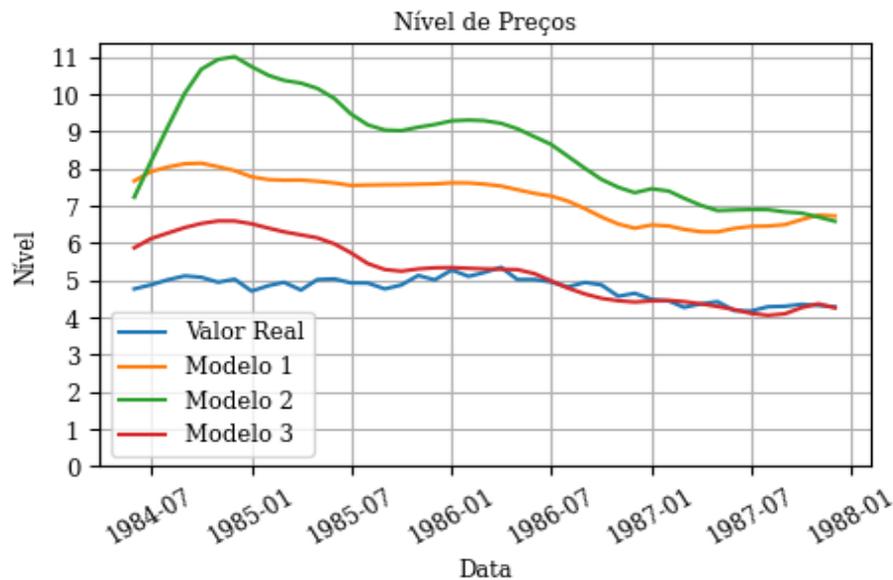
Modelo 3

Aplicando a velocidade do M2 aos lotes, e utilizando uma RNN com a primeira camada tendo 8 neurônios, a segunda camada tendo 4 neurônios. O modelo atinge uma correlação de 0,69% com um erro de 0,546; já na previsão do segundo lote o modelo alcança uma correlação de 0,80% e um erro de 0,801; no terceiro lote o modelo consegue uma correlação de 0,72% com o erro de 1,924.

Previsões dos níveis de preço para os períodos da pesquisa, em função dos modelos adotados

Previsões para o Período 1

Tabela 1
Previsões do primeiro período

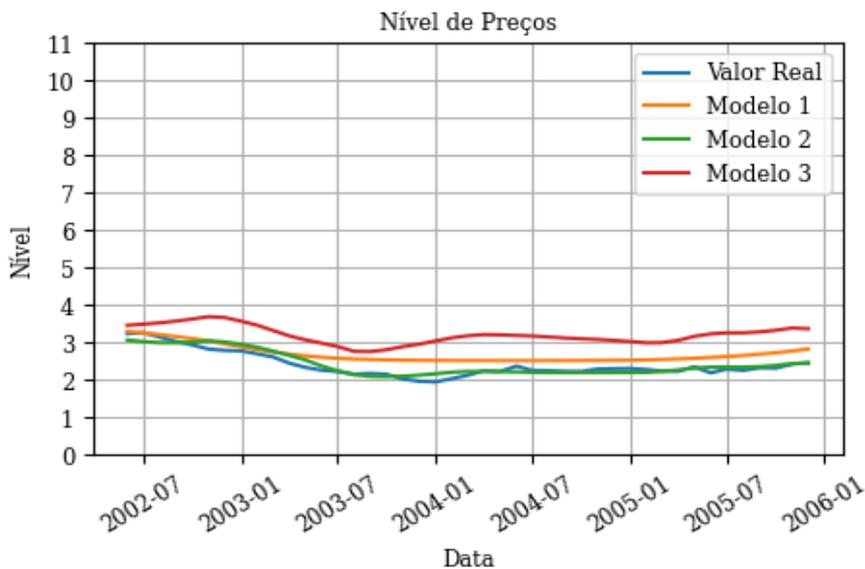


As previsões dos modelos vão do período de junho de 1984 até o final de 1987, ambos os modelos conseguem boas correlações. O modelo 1 conseguiu correlações superiores ao modelo 2 e um erro menor, já o modelo 3 superou os outros modelos na previsão, tendo uma correlação menor do que os outros, mas tendo um erro extremamente baixo de 0,546; e obtendo uma melhora acentuada na previsão a partir de Outubro de 1985.

Mesmo os dados de treino carregando variáveis de 1970 até 1984, onde o Estados Unidos enfrentou forte inflação e flutuações, e a recessão de 1982; o algoritmo conseguiu manter boas previsões. Já que os atributos de inflação, taxa de juros, e velocidade do M2 estavam seguindo tendências semelhantes, com o IPC tende uma correlação de 0,54% com a taxa de juros, a velocidade do M2 tendo uma correlação de 0,67% com o IPC, e a taxa de juros uma correlação de 0,85% com a velocidade do M2.

Previsões para o Período 2

Tabela 2
Previsões do segundo período.

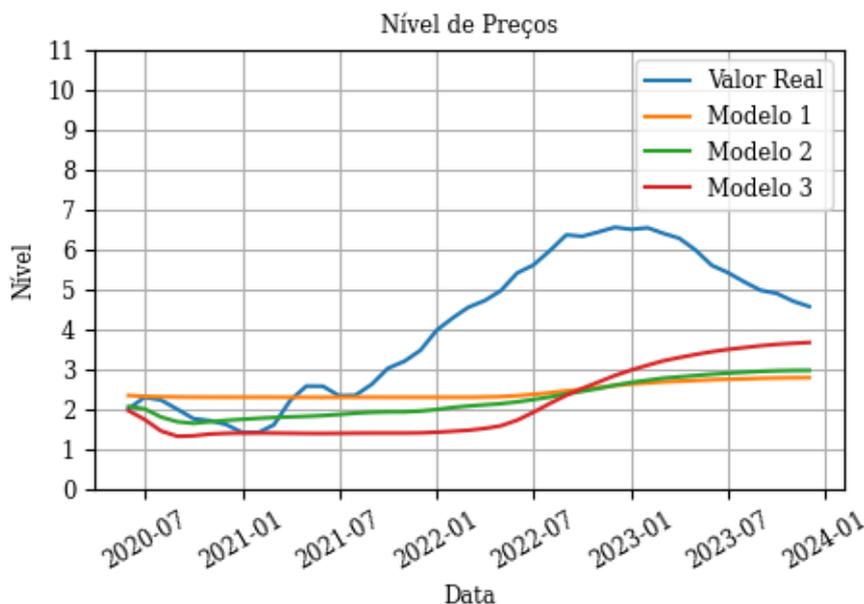


O período que abrange as previsões do modelo vai de junho de 2002 até Dezembro de 2006. Os modelos alcançaram boas correlações, sendo o modelo 3 o algoritmo com menor correlação entre elas, que é de 0,80%; e a maior correlação vem do modelo 1 que atinge uma correlação de 0,95%; já o modelo 2 uma correlação de 0,93%; e o menor erro entre os modelos, sendo esse de 0,099.

Ao analisar a figura se consegue notar baixo nível de ruído e sazonalidade nos dados de teste, contribuindo para que o algoritmo conseguisse de forma mais fácil alcançar boas previsões. Os níveis de preços se estabilizaram muito do período de 1988 até 2006, permitindo que os dados de treinamento também fossem limpos, e com baixa sazonalidade.

Previsões para o Período 3

Tabela 3
Previsões do terceiro período.



Já o terceiro lote foi usado para fazer previsões do período de junho de 2020 até dezembro de 2023. Ambos os modelos tiveram dificuldades de fazer boas previsões, só o modelo 2 que alcançou uma correlação de 0,81%; mas ainda teve um erro alto. Essa dificuldade dos modelos em atingir se deve a problemas econômicos que surgiram nesse período de tempo. A crise da pandemia resultou num choque de oferta e demanda onde notado de forma clara com o aumento no nível de preços a partir de agosto de 2021.

Não só esse choque de oferta nós dados não vistos, mas nos dados de treinamento também. Desde a crise de 2007-2009, as variáveis como a Velocidade do M2 sofreram de tendências mais aleatórias, e as taxas de juros baixas não levando aos efeitos no nível de preços esperados. Vários fatores influenciaram esses atributos, crises imobiliárias levando a alto nível de endividamento por causas das alavancagens, o alto endividamento afetando a velocidade do M2 e a eficácia da política monetária, deixando esses atributos com padrões menos claros para os algoritmos.

O modelo 1 só com a taxa de juros e o nível de preços não deu bons resultados, o modelo 2 que fez a previsão com o IPC, taxa de juros e o crescimento do PIB Real, obteve resultados melhores, e o modelo 3, que previu usando mais um atributo, foi a velocidade do M2, piorou os resultados. O crescimento do PIB Real se sobre saí perante a taxa de juros e a velocidade do M2 em períodos de choque de oferta e recessões graves, pois é uma variável ligada ao lado real da economia, e é mais correlacionado com o nível de preços do que os outros dois atributos.

Conclusão

Os algoritmos de *deep learning* como as RNNs e LSTMs mostraram resultados eficientes na previsão em comparação com os valores de teste, ultrapassando correlações de 70% em ambas partições, e partições com correlações superiores a 0,90% e erro menor que 1. Todos os atributos usados proporcionaram boas contribuições para as previsões, mas a taxa de juros e a velocidade do M2 apresentam resultados inferiores em períodos de recessões graves ou de choques de oferta.

Embora a literatura acadêmica e executiva no campo do conhecimento das estimativas de inflação em diversos contextos seja abundante em praticamente todos os países, a aplicabilidade da *deep learning* consiste em uma inovação metodológica. Os algoritmos proporcionados por este recurso tecnológico demonstram ser robustos para identificar e efetuar previsões. Esta é uma contribuição desta pesquisa aos estudos futuros, mediante o estabelecimento de hipóteses tais como:

- Os algoritmos de *deep learning* permitem efetuar previsões otimizando técnicas estatísticas com melhor depuração de dados do que outros métodos;
- Os algoritmos de *deep learning* possibilitam prever as flutuações de inflação com precisão tão apuradas, quanto outros métodos.

Como contribuição executiva é possível recomendar às organizações a aplicabilidade das técnicas de *deep learning* em processos de previsões em áreas diversificadas, tais como: previsão de vendas, verificações de impactos de publicidade, identificação quantitativa de reclamações de clientes, necessidades de horas trabalhadas em gestão de projetos, previsões de custos logísticos, previsões de custos de itens industriais, identificação de atrasos de entregas por agentes terceirizados, identificação de acessos a conteúdos de empresas na internet,

conversão de acessos em compras efetivas na internet, tempos de demora que um cliente investe no processo de compra na internet, verificação de reclamações e de soluções por compra na internet, etc.

Referências

- Ahmad, A. M; Ismail, S. & Samaon, D.F. (2004). Recurrent neural network with backpropagation through time for speech recognition. *IEEE International Symposium on Communications & Information Technology*, 1, 98-102.
- Bach G. L. & Albert A. (1957). The Redistributive Effects of Inflation. *The Review of Economics and Statistics* Vol. 39, No. 1 (Feb, 1957), pp. 1-13
- Bagus, Philipp. (2009). The Quality of Money *The Quarterly Journal of Austrian Economics* 12, No. 4 (2009): 22–45.
- Chandak A.; Prajwal G.; Shyam S.; Ayushi B. & Soumya T. (2019). Car Price Prediction Using Machine Learning. *International Journal of Computer Sciences and Engineering*.
- Hanke, S. H. & Alex K. F. Kwok. (2009) On the Measurement of Zimbabwe's Hyperinflation. *Cato Journal* Vol. 29, No.2 (Spring/Summer 2009).
- Hao X.; Guigang Z & Shang M. (2016). Deep Learning. *International Journal Of Semantic Computing* Vol. 10, No. 03, pp. 417-439(2016).
- Knight, Alex. (2002) A Bubble on the Mighty Mississippi: An Application of a General Model of Speculative Bubbles to the Mississippi Bubble of 1716-1720. *Major Themes in Economics*, 4, 71-94.
- Koutnik .J; Klaus G.; Faustino G. & Juergen S. (2014). A Clockwork RNN. *31st International Conference on Machine Learning*, PMLR 32(2):1863-1871.
- Pal S.; Soumadip G. & Amitava N. (2018). Sentiment Analysis in the Light of LSTM Recurrent Neural Networks. *International Journal of Synthetic Emotions, Volume 9, Issue*.
- Sakib-Bin-Amin. (2011). Quantity Theory of Money and its Applicability: The Case of Bangladesh. *World Review of Business Research* Vol. 1. No. 4. September 2011. Pp.33-4.