

ARTIGO ORIGINAL

## Previsão de inflação com o uso de Inteligência Artificial

### Inflation forecast with Artificial Intelligence

Cristina Zaniol <sup>1</sup>, Cássio Pazinato <sup>2</sup>, Ana Paula Sturbelle Schiller<sup>2</sup>,  
Jean Carlo Pech de Moraes<sup>4</sup>

<sup>1,2,3</sup>Instituto Federal de Educação, Ciência e Tecnologia Sul-rio-grandense, IFSUL, <sup>4</sup>Universidade Federal do Rio Grande do Sul, UFRGS

\*[cristinazaniol@ifsul.edu.br](mailto:cristinazaniol@ifsul.edu.br); [cassiopazinatto@pelotas.ifsul.edu.br](mailto:cassiopazinatto@pelotas.ifsul.edu.br); [eng.anapschiller@gmail.com](mailto:eng.anapschiller@gmail.com); [jean.moraes@ufrgs.br](mailto:jean.moraes@ufrgs.br)

Recebido: 16/05/2021. Revisado: 18/05/2021. Aceito: 14/06/2021.

#### Resumo

A inflação é um aumento generalizados dos preços em uma economia. Pequenas taxas de inflação são naturais; entretanto, a incerteza causada pela volatilidade da inflação dificulta o delineamento de políticas monetárias. No Brasil, adota-se o IPCA como meta de inflação; entretanto, o uso de núcleos de inflação como meta possibilitaria o delineamento de políticas monetárias menos rígidas e menos suscetíveis à choques externos. Neste trabalho, propõe-se a construção de núcleos de inflação baseados em *wavelets*, uma vez que em contextos inflacionários apresentam melhor desempenho na análise da tendência quando comparados com núcleos de inflação usuais. Para a previsão, adotam-se técnicas de inteligência artificial, como as redes neurais. O uso de redes neurais possibilita lidar com problemas altamente complexos, os quais nem sempre podem ser descritos por modelos analíticos. Delimitam-se as estimativas prováveis das previsões futuras através de intervalos de confiança. Dentre as principais conclusões do trabalho, salienta-se que os núcleos de inflação baseados em *wavelets* possuem menores intervalos de confiança, além de apresentarem menores erros na construção da rede neural. Verifica-se, ainda, que as previsões geradas pelos núcleos de inflação são suavizações da inflação, permitindo identificar a tendência da inflação para um horizonte de até doze meses.

**Palavras-Chave:** Núcleo de inflação; previsão; redes neurais.

#### Abstract

Inflation is a generalized increase in prices in an economy. Small rates of inflation are natural; however, the uncertainty related to inflation volatility brings issues in monetary policies design. In Brazil, the IPCA is adopted as an inflation target; however, the use of core inflation as a target would allow to design less rigid monetary policies. In this work, we propose the construction of a wavelet based core inflation, since in inflationary contexts they present a better performance in the trend analysis when compared to usual core inflation. For the forecast, artificial intelligence techniques are adopted, such as neural networks. We point out that neural network make it possible to deal with highly complex problems, which cannot always be described by analytical models. Additionally, we analyse confidence intervals to estimate bounds for inflation forecast probable values. Among the main conclusions, we emphasize that wavelet core inflation had smaller confidence intervals, in addition to presenting smaller errors in the construction of the neural network. In addition, inflation forecast generated smoothed signals, allowing to identify trends of inflation of up to twelve months.

**Keywords:** Core inflation; forecasting; neural network.

## 1 Introdução

A inflação é um aumento contínuo e generalizado dos preços em uma economia, acompanhado da perda do poder de compra. Demanda e oferta estão em constante mudança e, por isso, é natural uma variação no nível de preços e, em consequência, a existência de inflação. O problema surge quando há uma excessiva volatilidade da inflação, que geralmente culmina em crises inflacionárias descritas através da hiperinflação e da estagflação.

No Brasil, a partir da década de 60, houveram diversas estratégias traçadas para combater o descontrole inflacionário. Tal objetivo foi alcançado apenas com o Plano Real, lançado em 1994, no qual houve sucesso na estabilização da economia e no controle inflacionário. O Plano Real ganha como reforço nas políticas de controle inflacionário a adoção do Regime de Metas de Inflação, em julho de 1999, que tem o Índice de Preços ao Consumidor Amplo (IPCA) como referência (Carrara and Correa, 2012). O IPCA é calculado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) desde 1979 de forma a descrever a variação mensal de preços para 90% das famílias na área urbana.

No sistema de metas, o compromisso com a estabilidade de preços é o principal objetivo da política monetária, em que são estabelecidas metas de médio prazo para a inflação (Alem, 2018). O principal mecanismo para atingir as metas de inflação no Brasil é a taxa de juros, em que o Banco Central usualmente intervém com a elevação da taxa Selic quando há um aumento do nível de preços acima do esperado; tal medida incentiva a redução de gastos, o que reduz a velocidade do crescimento dos preços.

A adoção do IPCA como meta de inflação gera discussões, uma vez que o índice é afetado por choques econômicos não duradouros. Como meio de determinar a tendência da inflação, o Banco Central tem, adicionalmente ao IPCA, acompanhado algumas medidas de núcleos de inflação, sendo a primeira delas publicada em 2000 pelo próprio Banco Central. Os núcleos de inflação envolvem uma série de métodos para calcular a tendência da inflação a partir da exclusão de componentes tidos como temporários ou casuais. Defende-se que a utilização de núcleos de inflação como meta possibilitaria o delineamento de políticas monetárias menos rígidas e menos suscetíveis à choques externos (Carrara and Correa, 2012).

Neste trabalho, propõe-se a construção de núcleos de inflação através da teoria das *wavelets*. Sua principal vantagem é a de evitar a simples exclusão de componentes tidos como mais voláteis, frequentemente utilizada nos núcleos de inflação usuais, não sendo necessárias suposições adicionais em relação à tendência ou aos ruídos inerentes (Denardin et al., 2018, Dowd et al., 2011). É importante ressaltar que, mesmo em contextos inflacionários, os núcleos de inflação baseados em *wavelets* conseguem representar mais adequadamente descontinuidades e choques isolados, conseguindo um melhor desempenho em relação à análise da tendência quando comparados com núcleos de inflação usuais (Dowd et al., 2011).

Propõe-se, ainda, a utilização de inteligência artificial para a previsão da inflação futura. Assim, as redes neurais apresentam um avanço em relação às técnicas utilizadas para modelagem e previsão de séries temporais, permitindo lidar com problemas altamente complexos, os quais

nem sempre podem ser descritos por modelos analíticos (Haykin, 1999). A influência de diversos fatores, entre eles uma grande quantidade de indicadores macroeconômicos, além de tantos outros de ordem política, faz com que o problema de previsão da inflação seja de difícil modelagem; desta forma, justifica-se o uso de redes neurais.

Neste contexto, a incorporação de intervalos de confiança na previsão da inflação propicia uma avaliação da confiabilidade das previsões futuras a partir da modelagem proposta. Ressalta-se o caráter inovativo da abordagem conjunta de *wavelets* e de redes neurais na previsão da inflação, principalmente no contexto brasileiro (Zaniol and Moraes, 2020, Zaniol et al., 2021).

## 2 Núcleo de Inflação

Os índices de preços ao consumidor são medidas convencionais utilizadas para mensurar a dinâmica inflacionária de uma economia, incorporando fatores como a sazonalidade e os choques temporários de ofertas, entre outros. Esses fatores são tidos como perturbações que dificultam a visualização da tendência e a construção de uma previsão acurada da inflação, uma vez que afetam o nível de preços de forma e de recorrência desconhecidas, mas são revertidas rapidamente sem a necessidade de políticas monetárias. Então, desponta a necessidade de entender o comportamento persistente da inflação, sendo necessária para isso a exclusão da parte não persistente ou transitória do índice, de forma a obter como resultado apenas um núcleo mais informativo.

Para sanar essa dificuldade, surge o conceito de núcleo de inflação, cujo objetivo é capturar a tendência da inflação ao longo do tempo, verificando a persistência dos aumentos de preços. Bryan and Cecchetti (1994) definem o núcleo de inflação a partir de uma componente de longo prazo, persistente, e utilizam essa ideia na tentativa de desenvolver um modelo que possibilitasse descrever o comportamento dos preços e do dinheiro em uma economia. Na mesma linha de raciocínio, Roger (1998) concebeu dois conceitos de núcleo de inflação: o primeiro envolve a persistência dos componentes da inflação e, o segundo, a presença de um componente generalizado da inflação – ambos associados com expectativas e pressões da demanda. Apesar de não haver uma definição única, é comum a importância de um componente persistente, possibilitando a visualização do núcleo de inflação como uma medida de tendência e, por isso, um bom indicador da inflação futura.

O núcleo de inflação pode ser decomposto em dois componentes: um persistente e outro transitório. Assim, matematicamente, tem-se

$$\pi_t = \pi_t^* + \epsilon_t, \quad (1)$$

onde  $\pi_t$  é o índice de inflação e  $\pi_t^*$ , o núcleo de inflação, e  $\epsilon_t$  é o componente transitório de  $\pi_t$ , com  $\epsilon_t \sim N(0, \sigma^2)$  e  $\sigma^2$  limitado. É importante notar que, por definição, assume-se que  $\epsilon_t$  tem média zero; caso a média seja diferente de zero,  $\epsilon_t$  estaria incorporando parte dos componentes persistentes da inflação e o núcleo de inflação geraria uma falsa tendência da inflação persistente (Marques et al., 2003).

Segregar componentes persistentes e transitórios tem

sido desafiador e, até o momento, não apresenta consenso na literatura sobre o que constitui um núcleo de inflação ideal. Normalmente são utilizados um conjunto de critérios para avaliá-los, como a redução da volatilidade e capacidade preditiva da inflação (Baqaee, 2010). Percebe-se que esses critérios são vagos e carecem de maior detalhamento. Assim, a inexistência de um conjunto de critérios bem definidos ou de um conjunto de métricas para a avaliação dos núcleos de inflação é acrescida nessa série de dificuldades na formulação, na análise e na comparação de núcleos de inflação.

Os tipos de núcleo de inflação mais comumente utilizados são os que excluem determinados tipos de itens segundo a volatilidade e os que utilizam ferramentas matemáticas para realizar a exclusão (Andersson, 2008, da Silva, 2020). Por ser mais fácil de calcular, núcleos por exclusão tendem a ser vistos com maior credibilidade e transparência; exemplos de países que utilizam tais núcleos são a Nova Zelândia e os Estados Unidos, assim como o Brasil (Baqaee, 2010, Carrara and Correa, 2012, Figueiredo, 2001).

Com a implantação do Regime de Metas para a Inflação em 1999 no Brasil, o Banco Central passou a calcular alguns núcleos de inflação baseados no IPCA, entre eles os núcleos por exclusão (IPCA-EX), o de médias aparadas, com (IPCA-MS) ou sem suavização (IPCA-MA) e o de dupla ponderação (IPCA-DP); estes núcleos foram concebidos para serem ferramentas adicionais no suporte das decisões da política monetária (da Silva Filho and Figueiredo, 2014). A busca por outros núcleos de inflação que possam agregar mais informações e, ao mesmo tempo, reduzir a volatilidade tem propulsionado novos estudos nesta área.

### 3 Wavelets

O uso de *wavelets* na análise de séries temporais traz flexibilidade na construção de aproximações nas quais é possível manter os componentes ou as características que auxiliam na modelagem do problema. No contexto de núcleos de inflação, o uso de *wavelets* permite a reconstrução do IPCA de forma a manter apenas os componentes que caracterizam a tendência da inflação, evitando, ao mesmo tempo, a simples exclusão de certos grupos de preços.

Dada uma função *wavelet*  $\psi(t)$ , denominada *wavelet* mãe, é possível construir bases *wavelets* a partir da composição de  $\psi(t)$  com transformações de dilatação e de translação, isto é,

$$\psi_{m,n} = \frac{1}{2^{m/2}} \psi(2^{-m}t - n) \quad (2)$$

onde  $m$  e  $n$  referem-se à dilatação e à translação, respectivamente (Addison, 2016, Chan, 1994). Assim, uma série temporal  $f(t)$  pode ser reescrita através dos coeficientes de detalhes,

$$T_{m,n} = \int_{-\infty}^{\infty} f(t) \psi_{m,n}(t) dt \quad (3)$$

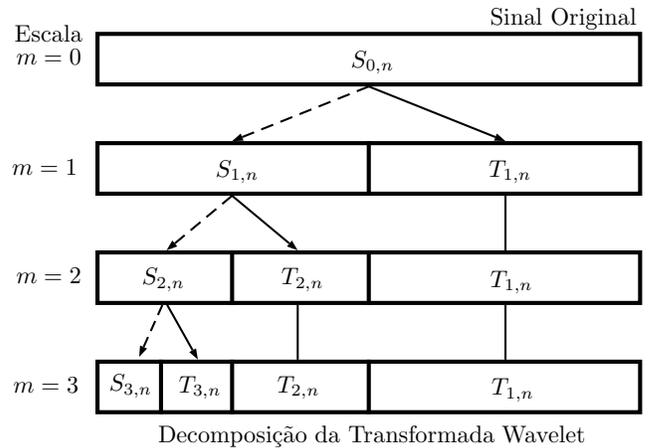


Figura 1: Coeficientes de uma decomposição *wavelet* em diversas escalas.

e de aproximação,

$$S_{m,n}(t) = \int_{-\infty}^{\infty} f(t) \phi_{m,n}(t) dt, \quad (4)$$

com

$$\phi_{m,n}(t) = \frac{1}{2^{m/2}} \phi(2^{-m}t - n), \quad (5)$$

onde  $\phi$  é a função escala associada com a suavidade do sinal. Em analogia a  $\psi(t)$ ,  $\phi(t)$  é denominada de *wavelet* pai. Para representar o sinal  $f(t)$ , então, é utilizada uma combinação de expansões em série de ambos os coeficientes de aproximação e de detalhes (Addison, 2016),

$$f(t) = \sum_{n=-\infty}^{\infty} S_{m_0,n} \phi_{m_0,n}(t) + \sum_{m=-\infty}^{m_0} \sum_{n=-\infty}^{\infty} T_{m,n} \psi_{m,n}(t) \quad (6)$$

em uma escala arbitrária  $m_0$ . Pela análise multirresolução, divide-se  $f(t)$  em intervalos de frequências, chamadas de escalas, conforme mostradas na Fig. 1. As escalas menores são caracterizadas por componentes de menor frequência, enquanto que as escalas maiores, maior frequência.

Normalmente, as frequências mais altas estão ligadas aos ruídos ou aos componentes transitórios de  $f(t)$ . Assim, essa divisão possibilita a reconstrução de  $f(t)$  com um número menor de escalas, permitindo desconsiderar os ruídos inerentes da série temporal.

### 4 Redes Neurais

A inteligência artificial tem sido cada vez mais utilizada para o aprendizado de padrões e para o delineamento de relações entre os dados de entrada e os de saída. Mais especificamente, quando utilizadas redes neurais artificiais, é possível lidar com problemas altamente complexos, os quais nem sempre podem ser descritos por modelos analíticos (Alexandridis and Zaprakis, 2014, Haykin, 1999). Além do desafio de estabelecer fatores inerentes que influ-

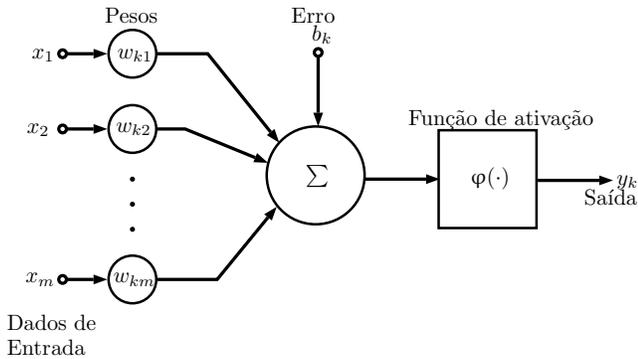


Figura 2: Modelo matemático de um neurônio  $k$

enciam a evolução da inflação, há dificuldades de estabelecer relações entre os diversos indicadores macroeconômicos no aumento dos preços; tal fato mostra a complexidade de modelagem do problema, o que justifica o uso das redes neurais (Zaniol and Moraes, 2020, Zaniol et al., 2021).

A capacidade do cérebro humano de adaptar-se e moldar-se às informações recebidas trazem inspiração e contribuem para a construção das redes neurais artificiais. Nessa estrutura, um neurônio é a unidade de processamento de informação com três elementos principais: um conjunto de sinapses, um acumulador ( $\Sigma$ ) e uma função de ativação ( $\varphi$ ). Assim, o neurônio pode ser matematicamente representado por (Haykin, 1999)

$$u_k = \sum_{j=1}^m w_{kj}x_j, \quad (7)$$

onde  $w_{kj}$  é o peso sináptico utilizado pelo neurônio  $k$  para ponderar a importância de uma entrada  $x_j$  na produção de uma determinada resposta  $y_k$ , dada por

$$y_k = \varphi(v_k), \quad (8)$$

onde

$$v_k = u_k + b_k \quad (9)$$

com  $b_k$  uma entrada caracterizada por um vetor unitário que permite aumentar os graus de liberdade, de forma a melhor adaptação às informações recebidas. A esquematização desse procedimento é visto na Fig. 2.

A função de ativação  $\varphi$ , por sua vez, é responsável pela propagação ou não das entradas  $x_j$  ponderadas. As funções de ativação *sigmóides*, na Fig. 3, apresentam um formato de “S”, tendo como principal vantagem a não linearidade, contribuindo, assim, para a inserção deste aspecto à saída  $y_k$  da rede neural (Haykin, 1999). De fato, uma função de ativação que seja não linear e diferenciável permite o aprendizado de comportamentos não lineares presente nos dados.

Em relação à rede neural, um aspecto importante a ser definido é a sua arquitetura, destacando-se as redes neurais de múltiplas camadas (Fig. 4) e as recorrentes (Fig. 5). A rede neural de múltiplas camadas é composta por uma

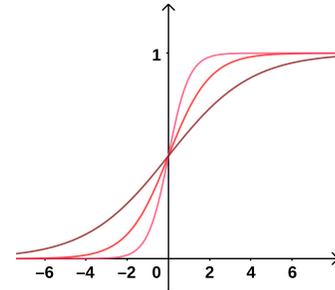


Figura 3: Funções de ativação sigmóides.

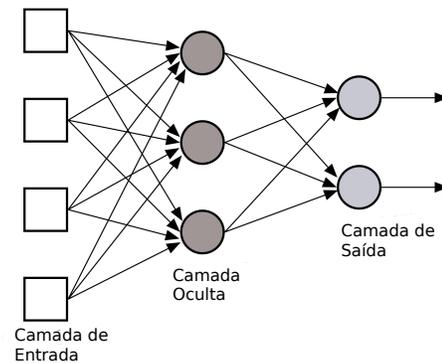


Figura 4: Rede neural com uma camada oculta.

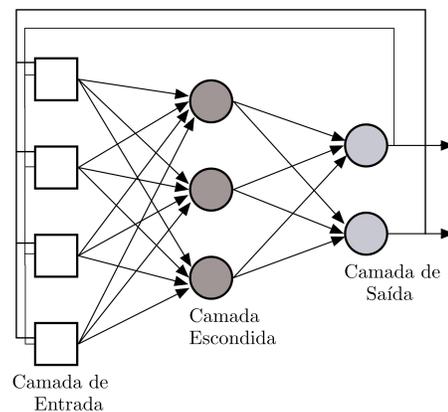


Figura 5: Rede neural recorrente com uma camada oculta.

ou mais camadas ocultas, além da camada de entrada e a de saída. A decisão sobre a quantidade de camadas ocultas depende do problema a ser modelado; ainda assim, grande parte dos problemas pode ser aproximados com uma única camada oculta (Haykin, 1999, Heaton, 2008).

Redes neurais recorrentes se distinguem da arquitetura anterior por ter um laço de retroalimentação, isto é, a saída de algum neurônio da  $i$ -ésima camada da rede neural é usada como entrada em alguma das camadas antecedentes. Quando há ciclos de retroalimentação, componentes temporais podem ser considerados: por exemplo, se a entrada é uma informação no tempo  $t$ , a saída que será produzida envolverá o tempo  $t + 1$  (Goodfellow et al., 2016). A prin-

principal vantagem, portanto, é a capacidade de memória das redes neurais recorrentes, uma vez que permite processar seqüências de informações, incluindo séries temporais.

Dada a natureza das redes neurais, muito do processamento dos dados não é visualizado, uma vez que a generalização ocorre principalmente nas camadas ocultas. Desta forma, é na camada oculta que ocorrem transformações não lineares e, por conseguinte, a determinação das complexidades inerentes dos dados de entradas (Da Costa Lewis, 2017). Para determinar a acurácia em relação aos dados originais, uma das medidas de performance é o erro quadrático médio (EQM). Para tanto, deseja-se minimizar o EQM, em que (Haykin, 1999)

$$EQM = \frac{1}{N} \sum_{n=1}^N e_k^{(n)}, \quad (10)$$

onde  $e_k^{(n)} = [y_k^{(n)} - \hat{y}_k^{(n)}]^2$  é o erro na saída referente ao neurônio  $k$  gerado a partir da entrada  $x^{(n)} = (x_1, \dots, x_m)$ , que é o conjunto de entradas  $x_j$ ,  $1 \leq j \leq m$ , no tempo  $n$ . Ainda,  $y_k^{(n)}$  é a resposta desejada e  $\hat{y}_k^{(n)}$  é a saída gerada pela rede neural. O processo dá-se pela atualização dos pesos sinápticos após percorrer completamente o conjunto de treinamento, de forma recorrente, até obter o mínimo da Equação (10). Quando o mínimo é observado, diz-se o algoritmo convergiu, isto é, o critério de parada é satisfeito. Tal convergência é garantida pelo Teorema da Aproximação Universal, que garante a existência de aproximações geradas por redes neurais (Cybenko, 1989).

Para a construção de intervalos de confiança, utiliza-se o método de *bootstrap*. Dado um conjunto de dados  $x = (x_1, x_2, \dots, x_n)$ , uma amostra obtida por *bootstrap* é definida como uma permutação de  $x$  tal que  $x^* = (x_1^*, x_2^*, \dots, x_n^*)$ , com  $x_i^*$  representando a permutação dos elementos de  $x$  (Efron and Tibshirani, 1994). Quando uma amostra  $x^*$  é utilizada para treinar uma rede neural, o algoritmo de aprendizagem é aplicado nas diversas configurações dos dados, de forma a gerar diversas saídas. Em outras palavras, os dados de entrada  $x$  são aleatoriamente reamostrados em  $B$  novas amostras e, por conseguinte, utilizados para treinar  $B$  redes neurais. Neste contexto, o parâmetro que deseja-se estimar é a média das previsões,

$$\hat{y}_{\text{médio}} = \frac{1}{B} \sum_{i=1}^B \hat{y}_i. \quad (11)$$

A variância do conjunto de previsões  $\hat{y}$  é dada por

$$\hat{\sigma}_m^2 = \frac{1}{B-1} \sum_{i=1}^B (\hat{y}_i - \hat{y}_{\text{médio}})^2, \quad (12)$$

que nada mais é que a variância amostral das previsões geradas. Assumindo que a média das previsões geradas pelas redes neurais é uma aproximação do valor real, tem-se que o intervalo de confiança pode ser descrito por

$$\hat{y}_{\text{médio}} - z_{\alpha} \hat{\sigma}_m \leq y \leq \hat{y}_{\text{médio}} + z_{\alpha} \hat{\sigma}_m, \quad (13)$$

onde  $(1 - 2\alpha)$  é o nível de confiança desejado.

## 5 Procedimentos e Dados

Os dados utilizados neste trabalho foram obtidos no Sistema Gerenciador de Séries Temporais, do Banco Central, referentes ao período de julho de 2006 a dezembro de 2020 (BANCO CENTRAL DO BRASIL, 2021).

Primeiramente, foi realizado o cálculo dos núcleos de inflação baseado em *wavelets*. O procedimento realizado foi conduzido da seguinte forma: a partir do IPCA, foram calculadas decomposições em cinco escalas e, na reconstrução, foram mantidos apenas três níveis de detalhes. A escolha de três níveis de detalhes refere-se à manutenção das frequências no período de até 16 meses (Denardin et al., 2018). Desta forma, o sinal torna-se mais suave e tende a representar a tendência da inflação. As *wavelets* utilizadas são da família das Daubechies, mais especificamente *db4*, *db6*, *db8* e *db10* (Daubechies et al., 1992). Estes núcleos de inflação, então, foram utilizados como parte dos dados de entrada para a rede neural. Para comparação, são utilizados núcleos de inflação adotados pelo Banco Central, entre eles: IPCA-EX2, IPCA-MS e IPCA-DP.

Para melhorar a previsão da inflação, isto é, do IPCA, incorporam-se à análise outros indicadores: o Índice de Custo de Vida, o Salário Mínimo, o Índice de Confiança do Consumidor e o Índice de Expectativas Futuras. Ressalta-se que os indicadores são referentes ao mesmo período acima explicitado. Para garantir a independência dos indicadores, realiza-se a Análise de Componentes Principais de forma a obter uma forma que melhor explica a variância dos dados.

Uma das limitações da análise da inflação é a escassez de dados em um mesmo contexto político e econômico. Embora o IPCA tenha valores disponíveis desde 1979, fatos como o Plano Real geraram grandes mudanças de paradigmas, principalmente no que tange ao controle inflacionário. Assim, utilizam-se métodos de perturbação para criação e incorporação de novos conjuntos de treinamento, mantendo a independência desses dados. São, então, replicados os dados utilizados para a construção da rede neural, acrescentando um ruído normal de 5% de perturbação.

Os dados são divididos em três conjuntos: os de construção da rede neural, divididos em treinamento, validação e teste; dados de entrada para a previsão; e os dados que devem ser previstos. Do total dos dados, 174 observações, apenas 150 são reservadas para a construção da rede neural. Ressalta-se que a perturbação é aplicada nestas 150 observações, que são agrupados aos dados sem perturbação e por fim utilizados para construir a rede neural.

São, portanto, dados de entrada para a rede neural: os núcleos de inflação, os dados resultantes da Análise de Componentes Principais e o próprio IPCA. A camada de processamento da rede neural possui uma camada oculta com  $n$  neurônios, com  $n$  variando de 1 a 50, e a função de ativação adotada é a função tangente hiperbólica. O algoritmo de aprendizagem adotado foi o *Scaled Conjugate Gradient* (SCG) e o EQM foi utilizado como critério de performance. Os dados foram divididos da seguinte forma: 60% para o treinamento, 10% para validação e 30% para teste. Por fim, da saída, resulta uma previsão para o IPCA

**Tabela 1:** EQM e Coeficiente de Determinação ( $R^2$ ) da previsão gerada pela rede neural com uma camada oculta.

Núcleo de inflação	Neurônios	EQM da Rede Neural			EQM da Previsão					$R^2$
		Treino	Validação	Teste	k+1	k+3	k+6	k+9	k+12	
IPCA-EX2	35	0,0513	0,0522	0,0512	0,0870	0,1760	0,2914	0,1888	0,3091	0,3813
IPCA-MS	37	0,0510	0,0520	0,0516	0,0888	0,1853	0,3091	0,1721	0,2873	0,3800
IPCA-DP	36	0,0522	0,0521	0,0525	0,0914	0,1721	0,2949	0,1873	0,3067	0,3730
db4	34	0,0540	0,0555	0,0543	0,0721	0,1592	0,2823	0,1718	0,2947	0,3381
db6	36	0,0470	0,0480	0,0468	0,0928	0,1693	0,2880	0,1828	0,3036	0,4248
db8	35	0,0526	0,0532	0,0511	0,0890	0,1563	0,2917	0,1808	0,2971	0,3623
db10	35	0,0521	0,0520	0,0520	0,0862	0,1636	0,2924	0,1730	0,2815	0,3641

para os determinados horizontes de tempo: um, três, seis, nove ou doze meses.

Para construção dos intervalos de confiança, utilizou-se a técnica de *bootstrap* para gerar diferentes amostras para o cálculo da previsão do IPCA. Para cada uma dos conjuntos de dados de entrada, foram estabelecidas 250 amostras com redes neurais distintas.

## 6 Resultados

Nesta seção são apresentados os resultados comparativos da previsão utilizando os núcleos de inflação oficiais, calculados pelo Banco Central, e os núcleos de inflação baseados em *wavelets* da família Daubechies. A primeira análise trata o valor médio do número de neurônios, do erro quadrático médio (EQM) e do coeficiente de determinação ( $R^2$ ) para as 250 amostras geradas, apresentados na Tabela 1.

Quanto ao número de neurônios, percebe-se que não há diferença significativa no número médio de neurônios necessários para gerar as redes neurais de menor EQM. Assim, para gerar esses resultados, em média, são necessários entre 34 (db4) e 37 (IPCA-MS) neurônios.

A próxima análise versa sobre a média do EQM para construção da rede neural. Observa-se que para o treino, validação e teste, não há diferença significativa entre os núcleos de inflação; ainda assim, o núcleo de inflação baseado na db6 é o que apresenta as menores médias.

A média do EQM da previsão calculada a partir das 250 amostras é apresentado a seguir, onde a rede neural de menor EQM recebe os dados de entrada para previsão até o mês  $k$  e gera previsões no horizonte de um ( $k+1$ ), três ( $k+3$ ), seis ( $k+6$ ), nove ( $k+9$ ) e doze meses ( $k+12$ ). Como o esperado, os menores erros ocorrem para os horizontes de tempo mais próximos, indicando uma maior acurácia para as previsões para horizontes até três meses.

Para a previsão de um mês, observa-se que a menor média resulta das previsões geradas pelos núcleos de inflação baseados na db4 (0,0721) e a maior, para o núcleo db6 (0,0928). Para a previsão no horizonte de três meses, a menor média e a maior são obtidas a partir dos núcleos, respectivamente, db8 (0,1563) e IPCA-MS (0,1853). Para a previsão no horizonte de nove meses, a menor e a maior média do EQM são obtidas para a db4 (0,1718) e IPCA-EX2 (0,1888).

Destaca-se que as maiores médias do EQM da previsão são observados para horizontes de tempo de seis e doze meses. Para a previsão no horizonte de seis meses, a menor e a maior média do EQM são obtidas, respectivamente, para db4 (0,2823) e IPCA-MS (0,3091). Quando observa-

se a previsão para um horizonte de doze meses, a menor e a maior média do EQM são obtidas pelos núcleos de inflação db10 (0,2815) e IPCA-EX2 (0,3091).

Da análise das médias do EQM, percebe-se que os núcleos de inflação oficiais apresentam maiores erros de previsão, em geral, que os núcleos de inflação baseados em *wavelets* da família Daubechies. Sendo assim, resta a análise do Coeficiente de Determinação.

O Coeficiente de Determinação ( $R^2$ ) é uma medida de ajuste que expressa a quantidade de variância do IPCA explicada pela previsão gerada pela rede neural. Para os núcleos de inflação oficiais, os valores variam entre 0,3730 (IPCA-DP) e 0,3813 (IPCA-EX2); para os núcleos de inflação baseados em *wavelets*, este valor varia entre 0,3381 (db4) e 0,4248 (db6). Pode-se inferir que, em média, os núcleos de inflação oficiais são capazes de explicar mais da variância do IPCA através da previsão quando comparados com os núcleos de inflação baseados em *wavelets*.

As previsões e os respectivos Intervalos de Confiança são apresentados na Fig. 6 para o período entre setembro de 2018 a dezembro 2020. A linha sólida em preto representa o IPCA. Na primeira coluna, em azul, tem-se mediana das 250 previsões geradas pelas redes neurais e, a área sombreada, representa o intervalo de confiança de 95% das previsões geradas a partir dos núcleos IPCA-EX2; na segunda coluna, em vermelho, a linha tracejada mostra a mediana das previsões e a área sombreada, o Intervalo de Confiança das previsões geradas com o núcleo db6.

Para as previsões para um horizonte de até seis meses, percebe-se que tanto o IPCA-EX2 (Figs. 6a e 6c), quanto o db6 (Figs. 6b e 6d) apresentam uma previsão de tendência de crescimento, observada no IPCA a partir do mês de maio de 2020. É importante ressaltar que, apesar de reconhecer a tendência de crescimento do índice de inflação, o intervalo de confiança gerado pela db6 é levemente mais delgado quando comparado com o intervalo de confiança gerado pelo IPCA-EX2.

Quando observa-se a previsão e o intervalo de confiança para horizontes maiores que nove meses, o comportamento esperado em relação à inflação é próximo da estabilidade, com uma previsão de crescimento para o final de dezembro de 2020. Mais uma vez, em relação ao intervalo de confiança, percebe-se que o gerado com o db6 apresenta-se mais delgado, sendo possível inferências mais precisas à inflação esperada. Ressalta-se, no intervalo de confiança do IPCA-EX2, no horizonte de 6 meses, em março de 2020, e no de nove meses, junho de 2020, há uma ampliação no intervalo de confiança.

Ainda que a mediana das duas previsões não se dife-

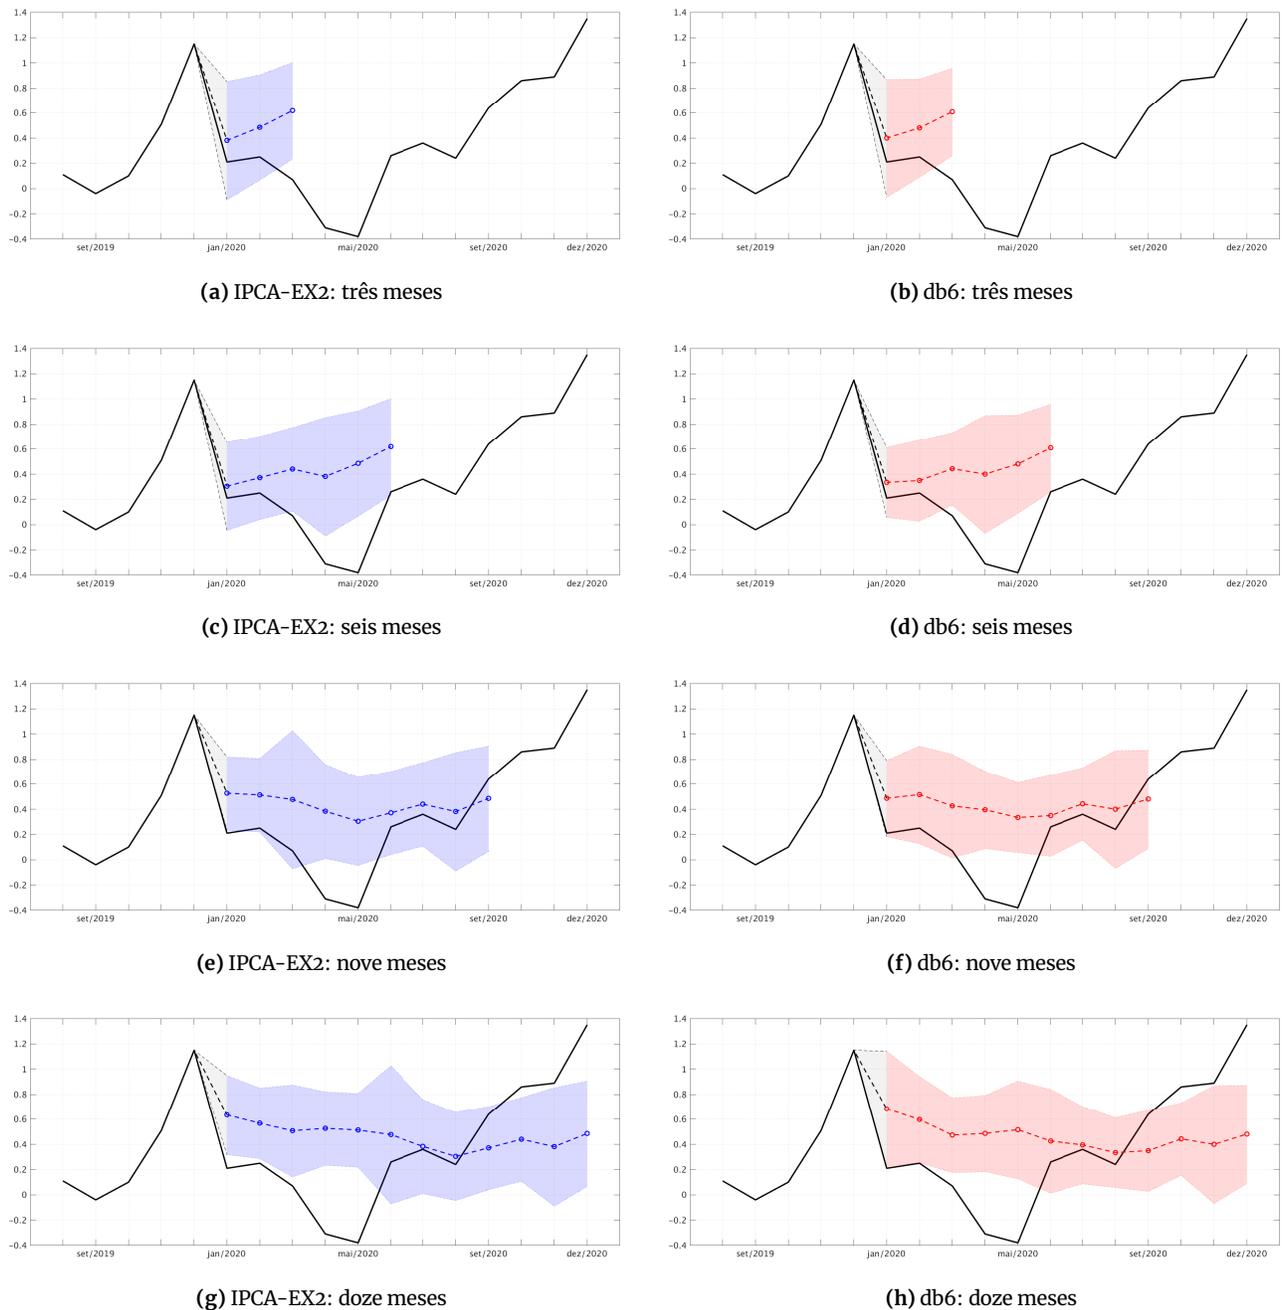


Figura 6: Intervalo de Confiança da previsão para três, seis, nove e doze meses.

rencie significativamente, o intervalo de confiança das previsões geradas a partir dos núcleos baseados em *wavelets* são mais estreitos que os gerados a partir dos núcleos de inflação oficiais.

Quando é analisada a previsão no horizonte de nove e doze meses, em 2020, e os respectivos intervalos de confiança, os núcleos de inflação tendem a gerar uma versão suavizada do IPCA. Desta forma, ainda que não consigam prever variações abruptas, como em maio ou em dezembro de 2020, conseguem prever a tendência da inflação.

Assim, é possível inferir que as previsões geradas pelas redes neurais tendem a se comportar em conformidade com os núcleos de inflação, não sendo capazes de identificar movimentos transitórios do IPCA.

## 7 Considerações Finais

O uso de redes neurais, associado com núcleos de inflação, é uma das possibilidades para a obtenção de previsões para a inflação. Ao crescer intervalos de confiança à análise,

é possível realizar uma comparação mais robusta dos resultados encontrados com núcleos de inflação oficiais e baseados em *wavelets*.

Quando analisadas as médias dos EQMs, percebe-se que os núcleos de inflação baseados em *wavelets* figuram entre os menores erros; ainda assim, são os núcleos de inflação oficiais que conseguem explicar a maior quantidade da variabilidade do IPCA a partir das previsões geradas.

Em relação aos intervalos de confiança dos dois núcleos de inflação analisados, IPCA-EX2 e db6, percebe-se que a mediana das previsões é similar nos dois casos; entretanto, em relação ao tamanho do intervalo, a db6 apresenta uma distância menor entre os intervalos quando comparado com o IPCA-EX2.

Destaca-se, ainda, que as previsões geradas são versões suavizadas do IPCA, não sendo capazes de identificar movimentos transitórios da inflação. Ainda assim, a identificação da tendência permite que tais previsões sejam utilizadas como suporte no delineamento de políticas monetárias.

Uma das limitações associadas à análise da inflação é a carência de dados, uma vez que o Brasil apresentou uma série de trocas de moedas e de políticas monetárias que limitam a obtenção de dados dentro de um mesmo contexto. Técnicas de replicação de dados, através de perturbações, mostram-se necessárias nesta conjuntura; entretanto, trazem uma série de inconsistências que podem gerar resultados menos confiáveis.

Outra dificuldade do trabalho é o grande tempo e esforço computacional. Assim, vê-se a necessidade de aumentar, não apenas o número máximo de neurônios utilizados para a construção das previsões, como também um maior número de observações, para a obtenção de resultados mais acurados.

Verifica-se que este trabalho traz contribuições à discussão de previsão da inflação, uma vez que, diferentemente de outros métodos de previsão, como os de regressão, traz consigo a possibilidade de incorporação de informações externas ao índice de inflação. De fato, indicadores macroeconômicos podem auxiliar na modelagem deste problema, e com isso, contribuir no delineamento de políticas monetárias.

Para trabalhos futuros, propõe-se o uso de outras arquiteturas de redes, além da incorporação de outros indicadores macroeconômicos para a previsão da inflação. Desta forma, espera-se obter um resultado mais acurado, além de verificar a influência dos dados macroeconômicos na previsão da inflação.

## Referências

- Addison, P. S. (2016). *The illustrated wavelet transform handbook: introductory theory and applications in science, engineering, medicine and finance*, 2 edn, CRC press, Edinburgh, UK.
- Alem, A. (2018). *Macroeconomia: Teoria e Prática no Brasil*, 1 edn, Elsevier Brasil, São Paulo, SP.
- Alexandridis, A. K. and Zaprani, A. D. (2014). *Wavelet neural networks: with applications in financial engineering, chaos, and classification*, John Wiley & Sons, New Jersey.
- Andersson, F. N. G. (2008). Core inflation - why the federal reserve got it wrong, *Technical Report Working Papers 2008:19*, Lund University, DEpartment of Economics. Disponível em [http://project.nek.lu.se/publications/workpap/Papers/WP08\\_19.pdf](http://project.nek.lu.se/publications/workpap/Papers/WP08_19.pdf).
- BANCO CENTRAL DO BRASIL (2021). SGS - Sistema Gerenciador de Séries Temporais - v2.1. Disponível em <https://bit.ly/1ivyjfd>.
- Baqee, D. (2010). Using wavelets to measure core inflation: The case of New Zealand, *The North American Journal of Economics and Finance* 21(3): 241–255. <https://doi.org/10.1016/j.najef.2010.03.003>.
- Bryan, M. F. and Cecchetti, S. G. (1994). Measuring core inflation, *Monetary policy*, The University of Chicago Press, Chicago, pp. 195–219. <http://dx.doi.org/10.3386/w4303>.
- Carrara, A. F. and Correa, A. L. (2012). O regime de metas de inflação no Brasil: uma análise empírica do IPCA, *Revista de Economia Contemporânea* 16(3): 441–462. <http://dx.doi.org/10.1590/S1415-98482012000300004>.
- Chan, Y. T. (1994). *Wavelet basics*, Springer, New York.
- Cybenko, G. (1989). Approximation by superpositions of a sigmoidal function, *Mathematics of control, signals and systems* 2(4): 303–314. <https://doi.org/10.1007/BF02551274>.
- Da Costa Lewis, N. (2017). *Neural Networks for Time Series Forecasting with R: An Intuitive Step by Step Blueprint for Beginners*, CreateSpace Independent Publishing Platform.
- da Silva Filho, T. N. T. and Figueiredo, F. M. R. (2014). Revisitando as medidas de núcleo de inflação do banco central do brasil, *Technical Report Working Papers Series 356*, Banc Central do Brasil. Disponível em <https://www.bcb.gov.br/pec/wps/port/TD356.pdf>.
- da Silva, N. (2020). Medida de núcleo de inflação para o brasil baseadas no método wavelet?, *Technical Report Working Papers Series 528*, Banco Central do Brasil. Disponível em <https://www.bcb.gov.br/pec/wps/port/wps528.pdf>.
- Daubechies, I. et al. (1992). *Ten lectures on wavelets*, Vol. 61, SIAM.
- Denardin, A. A., Kozakevicius, A. and Schmidt, A. A. (2018). Avaliação da medida de núcleo de inflação baseada no método wavelet para o Brasil, *Anais do XLIV Encontro Nacional de Economia [Proceedings of the 44th Brazilian Economics Meeting]*, ANPEC. Disponível em [https://www.anpec.org.br/encontro/2016/submissao/files\\_I/i4-fc77de3b0afb688099653e56d3f4f064.pdf](https://www.anpec.org.br/encontro/2016/submissao/files_I/i4-fc77de3b0afb688099653e56d3f4f064.pdf).
- Dowd, K., Cotter, J. and Loh, L. (2011). US core inflation: A wavelet analysis, *Macroeconomic Dynamics* 15(4): 513–536. <https://doi.org/10.1017/S1365100510000179>.
- Efron, B. and Tibshirani, R. J. (1994). *An introduction to the bootstrap*, CRC press.

- Figueiredo, F. M. R. (2001). Evaluating core inflation measures for Brazil, *Technical Report Working Papers Series 14*, Banco Central do Brasil. Disponível em <https://www.bcb.gov.br/pec/wps/ingl/wps14.pdf>.
- Goodfellow, I., Bengio, Y. and Courville, A. (2016). *Deep Learning*, MIT Press. Disponível em <http://www.deeplearningbook.org>.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, 2 edn, Prentice Hall, Ontario, Canada.
- Heaton, J. (2008). *Introduction to Neural Networks with Java*, 2 edn, Heaton Research, St. Louis.
- Marques, C. R., Neves, P. D. and Sarmento, L. M. (2003). Evaluating core inflation indicators, *Economic modelling* **20**(4): 765–775. [https://doi.org/10.1016/S0264-9993\(02\)00008-1](https://doi.org/10.1016/S0264-9993(02)00008-1).
- Roger, S. (1998). Core inflation: concepts, uses and measurement.
- Zaniol, C. and Moraes, J. C. (2020). Previsão e núcleo de inflação: uma abordagem baseada em wavelets e redes neurais, *Proceeding Series of the Brazilian Society of Computational and Applied Mathematics* **7**(1). <https://doi.org/10.5540/03.2020.007.01.0418>.
- Zaniol, C., Pazinato, C. B. and Moraes, J. C. (2021). Intervalos de confiança de núcleos de inflação utilizando wavelets e redes neurais, *Anais do X Encontro Regional de Matemática Aplicada e Computacional do Rio Grande do Sul – ERMAC-RS*. Disponível em <https://editora.pucrs.br/edipucrs/acessolivre/anais/1501/assets/edicoes/2020/arquivos/66.pdf>.