

APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL E CIÊNCIA DE DADOS

Julio C. Uzinski
Caio C. E. de Abreu
Bruno R. de **Oliveira**

organizadores



Pantanal Editora

2020

Julio Cezar Uzinski
Caio Cesar Enside de Abreu
Bruno Rodrigues de Oliveira
(Organizadores)

**Aplicações de
Inteligência Artificial e
Ciência de Dados**



Pantanal Editora

2020

Copyright© Pantanal Editora
Copyright do Texto© 2020 Os Autores
Copyright da Edição© 2020 Pantanal Editora
Editor Chefe: Prof. Dr. Alan Mario Zuffo
Editores Executivos: Prof. Dr. Jorge González Aguilera
Prof. Dr. Bruno Rodrigues de Oliveira

Diagramação: A editora
Edição de Arte: A editora
Revisão: Os autor(es), organizador(es) e a editora

Conselho Editorial

- Prof. Dr. Adailson Wagner Sousa de Vasconcelos – OAB/PB
- Profa. Msc. Adriana Flávia Neu – Mun. Faxinal Soturno e Tupanciretã
- Profa. Dra. Albys Ferrer Dubois – UO (Cuba)
- Prof. Dr. Antonio Gasparetto Júnior – IF SUDESTE MG
- Profa. Msc. Aris Verdecia Peña – Facultad de Medicina (Cuba)
- Profa. Arisleidis Chapman Verdecia – ISCM (Cuba)
- Prof. Dr. Bruno Gomes de Araújo - UEA
- Prof. Dr. Caio Cesar Enside de Abreu – UNEMAT
- Prof. Dr. Carlos Nick – UFV
- Prof. Dr. Claudio Silveira Maia – AJES
- Prof. Dr. Cleberton Correia Santos – UFGD
- Prof. Dr. Cristiano Pereira da Silva – UEMS
- Profa. Ma. Dayse Rodrigues dos Santos – IFPA
- Prof. Msc. David Chacon Alvarez – UNICENTRO
- Prof. Dr. Denis Silva Nogueira – IFMT
- Profa. Dra. Denise Silva Nogueira – UFMG
- Profa. Dra. Dennyura Oliveira Galvão – URCA
- Prof. Dr. Elias Rocha Gonçalves – ISEPAM-FAETEC
- Prof. Me. Ernane Rosa Martins – IFG
- Prof. Dr. Fábio Steiner – UEMS
- Prof. Dr. Gabriel Andres Tafur Gomez (Colômbia)
- Prof. Dr. Hebert Hernán Soto Gonzáles – UNAM (Peru)
- Prof. Dr. Hudson do Vale de Oliveira – IFRR
- Prof. Msc. Javier Revilla Armesto – UCG (México)
- Prof. Msc. João Camilo Sevilla – Mun. Rio de Janeiro
- Prof. Dr. José Luis Soto Gonzales – UNMSM (Peru)
- Prof. Dr. Julio Cezar Uzinski – UFMT
- Prof. Msc. Lucas R. Oliveira – Mun. de Chap. do Sul
- Prof. Dr. Leandro Argente-Martínez – ITSON (México)
- Profa. Msc. Lidiane Jaqueline de Souza Costa Marchesan – Consultório em Santa Maria
- Prof. Msc. Marcos Pisarski Júnior – UEG
- Prof. Dr. Mario Rodrigo Esparza Mantilla – UNAM (Peru)
- Profa. Msc. Mary Jose Almeida Pereira – SEDUC/PA
- Profa. Msc. Nila Luciana Vilhena Madureira – IFPA
- Profa. Dra. Patrícia Maurer
- Profa. Msc. Queila Pahim da Silva – IFB
- Prof. Dr. Rafael Chapman Auty – UO (Cuba)
- Prof. Dr. Rafael Felipe Ratke – UFMS
- Prof. Dr. Raphael Reis da Silva – UFPI

- Prof. Dr. Ricardo Alves de Araújo – UEMA
- Prof. Dr. Wéverson Lima Fonseca – UFPI
- Prof. Msc. Wesclen Vilar Nogueira – FURG
- Profa. Dra. Yilan Fung Boix – UO (Cuba)
- Prof. Dr. Willian Douglas Guilherme – UFT

Conselho Técnico Científico

- Esp. Joacir Mário Zuffo Júnior
- Esp. Maurício Amormino Júnior
- Esp. Tayronne de Almeida Rodrigues
- Esp. Camila Alves Pereira
- Lda. Rosalina Eufrausino Lustosa Zuffo

Ficha Catalográfica

Dados Internacionais de Catalogação na Publicação (CIP) (eDOC BRASIL, Belo Horizonte/MG)	
A642	<p>Aplicações de inteligência artificial e ciência de dados [recurso eletrônico] / Organizadores Julio Cezar Uzinski, Caio Cesar Enside de Abreu, Bruno Rodrigues de Oliveira. – Nova Xavantina, MT: Pantanal, 2020. 100p.</p> <p>Formato: PDF Requisitos de sistema: Adobe Acrobat Reader Modo de acesso: World Wide Web ISBN 978-65-88319-26-0 DOI https://doi.org/10.46420/9786588319260</p> <p>1. Inteligência artificial. 2. Automação. 3. Processamento de dados. I. Uzinski, Julio Cezar. II. Abreu, Caio Cesar Enside de. III. Oliveira, Bruno Rodrigues de.</p> <p style="text-align: right;">CDD 001.535</p>
Elaborado por Maurício Amormino Júnior – CRB6/2422	

O conteúdo dos livros e capítulos, seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva do(s) autor (es). O download da obra é permitido e o compartilhamento desde que sejam citadas as referências dos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000.
Nova Xavantina – Mato Grosso – Brasil.
Telefone (66) 99682-4165 (Whatsapp).
<https://www.editorapantanal.com.br>
contato@editorapantanal.com.br

APRESENTAÇÃO

Ciência de dados (*Data science*) e Inteligência artificial (*Artificial intelligence*) podem ser consideradas como algumas das áreas da ciência mais importantes de nosso tempo. Ademais, não estão apenas no mundo acadêmico ou no futuro como no filme *The terminator*, estão ao nosso redor nesse exato momento em situações simples, por exemplo, são empregadas para sugerir qual o próximo emoji que você enviará em uma conversa no seu aplicativo de bate papo favorito. Ciência de dados se refere a um campo de estudo muito amplo que se vale de métodos científicos para se obter informações e percepções de conjuntos de dados, enquanto que a inteligência artificial refere-se ao que chamamos de inteligência das máquinas. As aplicações dessas ferramentas estão relacionadas às tecnologias que nos envolvem em nosso cotidiano, e.g., as redes sociais ou comércio eletrônico, bem como aplicações que escapam ao senso comum, como em cibersegurança ou astrofísica.

Tais abordagens, às vezes, são utilizadas juntas, de forma intercalada ou separadas. Uma pesquisa poderá contar com ambas as ferramentas ou apenas com uma delas. Nesse livro, o leitor encontrará aplicações diversas dessas ferramentas em diferentes perspectivas. Em seis capítulos são apresentados resultados de pesquisas de dezesseis pesquisadores sobre temas diversos que dão uma demonstração do poder da Inteligência Artificial e da Ciência de Dados.

O primeiro capítulo traz uma comparação dos resultados da Transformada Wavelet (WT) e do Filtro Savitzky-Golay (SG) na estimação da tendência em séries temporais. Os resultados são obtidos a partir de uma série temporal artificial e uma série de dados reais, i.e, a cotação da moeda americana (Dólar US\$) frente à moeda brasileira (Real R\$).

Considerando que a principal abordagem em Aprendizado de Máquinas é a construção de algoritmos que, por meio das experiências e aprendizado, possam ser melhorados automaticamente, o segundo capítulo desse livro traz uma avaliação de um algoritmo usando Redes Neurais Artificiais LSTM. Essa abordagem é justificada pela necessidade de reconhecimento de padrões de comportamento de presença de elementos em um ambiente para realizar a predição de ações no local por meio dos dados coletados fornecendo uma base para o desenvolvimento de um sistema doméstico inteligente.

Já no terceiro capítulo, uma metodologia para descrição de Casos de Uso (Uc) no desenvolvimento de sistemas de informação é apresentada. A motivação para a criação desta metodologia é que muitos UC's são descritos com pouca riqueza de detalhes, o que prejudica a qualidade dos sistemas de informação.

O quarto capítulo traz uma aplicação bastante diversa de todas as outras: um estudo dos aspectos e causas da obesidade por meio do algoritmo de agrupamento Farthest First para agrupar

pessoas com informações demográficas, socioeconômicas, de biotipo e de conjunto de ações observáveis recorrentes.

No quinto capítulo é desenvolvida uma aplicação utilizando regressão logística como um mapeamento do espaço de atributos não-linearmente separável baseado em um tipo especial de funções denominadas de Golden Wavelets. Nesse texto, os autores buscam tratar a matemática envolvida no método de aprendizado de máquina denominado de Regressão Logística e propor a utilização de funções wavelets para mapeamento do espaço de atributos.

Para encerrar esse e-book com chave de ouro, o sexto capítulo, apresenta uma classificação de cenas acústicas utilizando a Transformada Wavelet e Aprendizagem de Máquina. Os autores dedicam a redação à apresentação dos principais métodos de Classificação de Cenas Acústicas (CCA) e os principais atributos utilizados para esta classificação, exemplos de aplicações, e uma investigação adicional centrada na utilização da Transformada Wavelet Contínua (TWC).

Caríssimo(a) leitor(a), convidamos você à leitura de Aplicações de Inteligência Artificial e Ciência de Dados, e esperamos que a mesma seja um deleite ilimitado e que contribua de alguma forma com suas aspirações.

Julio Cezar Uzinski


SUMÁRIO


Apresentação	4
Capítulo I.....	7
Obtenção de Tendências em Série Temporal empregando a Transformada Wavelet e o filtro Savitzky-Golay.....	7
Capítulo II.....	24
Aplicação de Redes Neurais Artificiais LSTM em domótica inteligente	24
Capítulo III.....	32
Uma Metodologia Simples para Descrição de Casos de Uso no Desenvolvimento de Sistemas de Informação.....	32
Capítulo IV.....	49
Aspectos e causas da obesidade: uma análise utilizando algoritmo de agrupamento <i>Fartbest First</i>	49
Capítulo V.....	59
Mapeamento de espaço de atributos não-linearmente separável baseado na Golden wavelet: aplicação na regressão logística	59
Capítulo VI.....	85
Classificação de Cenas Acústicas Utilizando a Transformada Wavelet Contínua e Aprendizagem de Máquina.....	85
Índice Remissivo.....	99

Obtenção de Tendências em Série Temporal empregando a Transformada Wavelet e o filtro Savitzky-Golay


Recebido em: 16/09/2020

Aceito em: 24/09/2020

 10.46420/9786588319260cap1

Julio Cezar Uzinski^{1*} 

Bruno Rodrigues de Oliveira² 

Caio Cesar Enside de Abreu³ 

INTRODUÇÃO

O mundo corporativo e os cientistas em geral estão inclinados cada vez mais a utilizarem aplicações de predição do comportamento de processos que variam ao longo do tempo, por meio da análise dos dados passados destes processos, para subsidiar tomadas de decisões e até mesmo definir políticas econômicas e comportamentais corporativas. Dentre alguns exemplos podemos citar: predição do preço das *comodities*; do comportamento do mercado de ações; previsão do número de infectados por determinado vírus; previsões de terremotos; do impacto ambiental causado por decisões a serem consolidadas, reconhecimento e identificação de padrões, dentre outros (Fu, et al., 2008).

Nesse contexto, a ciência de dados, a inteligência artificial, o aprendizado de máquina, a própria estatística, e diversas outras técnicas dentro de alguns desses campos científicos possuem uma gama de alternativas para realizar tais predições (Picasso, et al, 2019; Puchalsky, 2018; Radityo, 2017).

Uma série temporal é um conjunto de observações, cada uma sendo registrada em um dado momento, representando o comportamento de um processo em função do tempo (Puchalsky, 2018). Dentre os objetivos vinculados ao estudo de séries temporais, destacamos a estimativa de suas componentes, especialmente, a componente de tendência, que possibilita compreender o comportamento do processo (ou da série) no longo prazo. Por outro lado, a componente aleatória ou as oscilações, que representam a maior variabilidade da série, possibilitam a compreensão de seu comportamento no curto prazo (Schlüter e Deuschle, 2010).

Diversas técnicas podem ser utilizadas para a estimação da componente de tendência de uma série temporal, tais como filtros Média Móvel, Savitzky-Golay e Transformada Wavelet. Alguns

¹ Rua das Gaivotas, 325, Sinop – MT. CEP 78556-398.

² Editora Pantanal. E-mail: bruno@editorapantanal.com.br.

³ Universidade do Estado de Mato Grosso – UNEMAT, Rua Santa Rita, 128, Alto Araguaia-MT. CEP 78780-000. E-mail: caioenside@unemat.br

* Autor correspondente: uzinski.jc@gmail.com.

exemplos são encontrados em: Carbone (2009), que utiliza a remoção de tendência pela Média Móvel para estudar o parâmetro de Hurst de fractais com dimensão arbitrária; Zhang (2005) implementa a Transformada Wavelet para obtenção e remoção da linha de base de sinais de eletrocardiograma; Kordestani e Zhang (2020) que implementam um filtro Savitzky-Golay com o objetivo de localizar e quantificar a tendência do dano em estruturas de pontes sujeitas a movimentos.

O objetivo deste trabalho é a comparação dos resultados da Transformada Wavelet e do Filtro Savitzky-Golay na estimação da componente de tendência em séries temporais. Para tanto, primeiramente utilizamos uma série temporal artificial a fim de compreender como as abordagens mencionadas atuam e, em seguida, implementamos uma aplicação para a série da cotação³ da moeda americana (Dólar U\$) frente à moeda brasileira (Real R\$).

FUNDAMENTOS

Série Temporal

Uma série temporal é uma realização do processo estocástico $X_t(\omega)$, $t \in Z$, definido no espaço $Z \times \Omega$, sendo que $X_t(\omega)$ é uma variável aleatória sobre um espaço de probabilidade (Ω, \mathcal{A}, P) para um t fixo, onde Ω é o conjunto de todos os eventos elementares possíveis, \mathcal{A} é uma coleção dos subconjuntos $A \in \Omega$, ω é um evento elementar, P uma função de probabilidade e $Z = \{0, 1, 2, 3, \dots\}$ é um conjunto de índices (Fuller, 1996).

A série temporal mencionada acima pode ser vista como uma coleção $\{X_t: t \in Z\}$ de variáveis aleatórias. Por questões de compatibilidade de notação em relação aos conceitos de processamento digital de sinais, podemos reescrever a série temporal $\{X_t: t \in Z\}$ como um função do tempo t , ou seja, $x(t)$ com $t \in \{0, 1, 2, \dots\}$.

Alguns modelos de séries temporais do tipo não-estacionária⁴ podem ser escritos como a soma entre uma componente de tendência T_t , uma sazonal S_t e uma aleatória ou irregular V_t (Fuller, 1996, p. 475), de acordo com a equação (1).

$$X_t = T_t + S_t + V_t, \quad (1)$$

onde V_t também pode ser composta por algum ruído.

Como mencionado anteriormente, um dos objetivos no estudo de séries temporais é a estimativa de suas componentes. Estimar a componente de tendência é importante, por exemplo, pois possibilita compreender o comportamento da série no longo prazo, enquanto que a estimação da componente aleatória, que representa a maior variabilidade da série, possibilita a compreensão de seu

³ Conforme disponibilizado pelo portal br.investing.com.

⁴ Em uma série não-estacionária a média e a variância da série são funções do tempo e a série é gerada por um mecanismo estocástico não-estacionário (Fuller, 1996).

comportamento no curto prazo (Schlüter e Deuschle, 2010). Várias técnicas podem ser aplicadas na estimação da tendência da série temporal, tais como os filtros Média Móvel, Savitzky-Golay e Transformada Wavelet. Nestes casos, todas implementam filtragens do tipo suavização.

Filtro Savitzky-Golay

No trabalho apresentado em Savitzky e Golay (1964), os autores propuseram um método de suavização de dados, com capacidade de aumentar a precisão destes sem distorcer a tendência do sinal, baseando-se na aproximação local polinomial por mínimos quadrados locais. Além disso, os autores mostraram que ajustar um polinômio a um conjunto de amostras de entrada e então avaliar o polinômio resultante em um único ponto dentro do intervalo de aproximação é equivalente à convolução discreta com uma resposta de impulso fixa. Os filtros passa-baixa obtidos por este método são amplamente conhecidos como filtros Savitzky-Golay (Schafer, 2011).

Várias pesquisas têm mostrado que a propriedade de preservação da forma de pico dos filtros Savitzky-Golay é interessante em aplicações de processamento de sinais, como por exemplo, no processamento de sinais de eletrocardiograma (Referência). Quando este filtro é generalizado para duas dimensões, pode também ser empregado em processamento de imagens (Schafer, 2011). Aplicações desse tipo de filtro no estudo de séries temporais também podem ser encontradas em diversos artigos, dentre eles: Wang e Pan e Xia (2019), Liu e Zhan (2016) e Cao et al. (2018).

Considera-se o grupo de $2M + 1$ amostras centradas em $n = 0$, de onde se obtém os coeficientes de um polinômio

$$p(n) = \sum_{k=0}^N a_k n^k, \quad (2)$$

que minimiza o erro quadrático médio da aproximação para o grupo de amostras de entrada centradas em $n = 0$,

$$\epsilon_N = \sum_{n=-M}^M (p(n) - x[n])^2 = \sum_{n=-M}^M \left(\sum_{k=0}^N a_k n^k - x[n] \right)^2. \quad (3)$$

A análise é a mesma para qualquer outro grupo de amostras de entrada $2M + 1$ (Schafer, 2011).

De acordo com Schafer (2011), a saída $y[0]$ em $n = 0$ é $y[0] = p(0) = a_0$, isto é, o valor da saída é igual ao 0-ésimo coeficiente polinomial. O valor da saída da próxima amostra é obtido deslocando o intervalo de análise para a direita em uma amostra e repetindo o ajuste polinomial e a avaliação no local central. Isso é repetido em cada amostra da entrada, e a cada iteração é produzido um valor da sequência de saída $y[n]$. Em cada posição, o valor de saída suavizado obtido pela amostragem do polinômio ajustado é idêntico a uma combinação linear fixa do conjunto local de amostras de entrada, ou seja, o conjunto de $2M + 1$ amostras de entrada dentro do intervalo de aproximação são

efetivamente combinados por um conjunto fixo de coeficientes de ponderação que podem ser calculados uma vez para uma dada ordem polinomial N e intervalo de aproximação de comprimento $2M + 1$. Assim, o vetor de saída pode ser obtido por uma convolução discreta da forma

$$y[n] = \sum_{m=-M}^M h[m]x[n-m] = \sum_{m=n-M}^{n+M} h[n-m]x[m]. \quad (4)$$

Para determinar os coeficientes do filtro segue-se o seguinte procedimento: define-se o vetor dos coeficientes do polinômio $\mathbf{a} = [a_0, a_1, \dots, a_N]^T$ e o vetor de entrada $\mathbf{x} = [x_{-M}, \dots, x_{-1}, x_0, x_1, \dots, x_M]^T$, onde $x_n = x(n)$, e a matriz

$$A = \begin{bmatrix} (-M)^0 & (-M)^1 & \dots & (-M)^N \\ \vdots & \vdots & \ddots & \vdots \\ (-1)^0 & (-1)^0 & \dots & (-1)^0 \\ 1 & 0 & \dots & 0 \\ M^0 & M^1 & \dots & M^N \end{bmatrix}. \quad (5)$$

Deriva-se ϵ_N em relação a esses coeficientes e definimos as derivadas iguais a zero, levando $N + 1$ equações em $N + 1$ incógnitas como segue

$$\sum_{k=0}^N \left(\sum_{n=-M}^M n^{i+k} \right) a_k = \sum_{n=-M}^M n^i x[n], \quad (6)$$

$i = 0, 1, \dots, N$; e então escreve-se essa última equação na sua forma matricial:

$$(A^T A)^{-1} \mathbf{a} = A^T \mathbf{x}; \quad (7)$$

e a partir daí, o vetor de coeficientes pode ser obtido como

$$\mathbf{a} = (A^T A)^{-1} A^T \mathbf{x} = H \mathbf{x}. \quad (8)$$

É importante destacar que é necessário calcular apenas o coeficiente \mathbf{a}_0 , e portanto, determinar a primeira linha da matriz H é suficiente. A matriz H é independente das amostras de entrada e depende apenas da ordem do filtro (N) e do comprimento da janela (M). Então, pela definição de multiplicação de matrizes, a saída será

$$y[0] = a_0 = \sum_{m=-M}^M h_{0,m} x[m], \quad (9)$$

e $h_{0,m} = h[-m]$, onde $-M \leq m \leq M$ (Schafer, 2011).

Transforma Wavelet Discreta

A Transforma Wavelet Discreta, do inglês, *Discrete Wavelet Transform* (DWT), é uma ferramenta fundamental para o estudo de inúmeras aplicações em diversas áreas científicas, entre elas, as séries

temporais. A DWT pode ser vista como uma ferramenta equivalente a Transformada de Fourier, porém com características distintas que a tornam relevante (Percival e Walden, 2000).

Os coeficientes de decomposição em uma base ortogonal de funções wavelet são calculados com um algoritmo rápido, baseado em convoluções discretas com vetores h e g , seguidos de subamostragem na saída. Trata-se de um banco de filtros de dois canais que divide o sinal de entrada em baixas e altas frequências, e são descritos pelas bases ortonormais $\{\psi_{j,n}\}_{n \in \mathbb{Z}}$ e $\{\phi_{j,n}\}_{n \in \mathbb{Z}}$. As funções dessas bases são chamadas funções wavelet e escala, respectivamente, e são dadas pelas equações (10) e (11).

$$\psi_{j,n}(t) = \frac{1}{\sqrt{2^j}} \psi\left(\frac{t - 2^j n}{2^j}\right), \quad (10)$$

$$\phi_{j,n}(t) = \frac{1}{\sqrt{2^j}} \phi\left(\frac{t - 2^j n}{2^j}\right). \quad (11)$$

Essas fórmulas geram, de acordo com Mallat (2009), por meio das equações recursivas (12) e (13), os coeficientes dos filtros h e g , respectivamente:

$$h[n] = \left\langle \frac{1}{\sqrt{2}} \phi\left(\frac{t}{2}\right), \phi(t - n) \right\rangle, \quad (12)$$

$$g[n] = \left\langle \frac{1}{\sqrt{2}} \psi\left(\frac{t}{2}\right), \phi(t - n) \right\rangle. \quad (13)$$

Uma série $x(t)$ é decomposta pela Transformada Rápida Wavelet, do inglês, *Fast Wavelet Transform* (FWT), como $a_j[n] = \langle x(t), \phi_{j,n}(t) \rangle$ e $d_j[n] = \langle x(t), \psi_{j,n}(t) \rangle$, onde $a_j[n]$ são os coeficientes de aproximação na escala 2^j , sendo $j (j = 1, \dots, J)$ o nível de decomposição. Nas mesmas condições, $d_j[n]$ são os coeficientes de detalhes. Considerando esses coeficientes, a série $x(t)$ é composta pelos coeficientes de aproximação na última escala J e os coeficientes de detalhes nas escalas j , isto é,

$$x(t) = \sum_n a_j[n] \phi_{j,n}(t) + \sum_{j \leq J} \sum_n d_j[n] \psi_{j,n}(t), \quad (14)$$

(Mallat, 2009; Oliveira et al., 2018).

Na FWT, a série no domínio do tempo é convertida para uma representação nas bases wavelets, porém, podendo ser reconstruído no domínio anterior por meio da Transformada Rápida Wavelet Inversa, do inglês, *Inverse Fast Wavelet Transform* (IFWT). A reconstrução é feita por meio de filtros de quadratura espelhada. Os filtros da reconstrução serão os mesmos da decomposição apenas se o banco de filtros for ortogonal (Strang e Nguyen, 1996). Estas duas operações (decomposição e reconstrução)

são denominadas análise e síntese da série temporal, e funcionam conforme esquematizado na Figura 1.

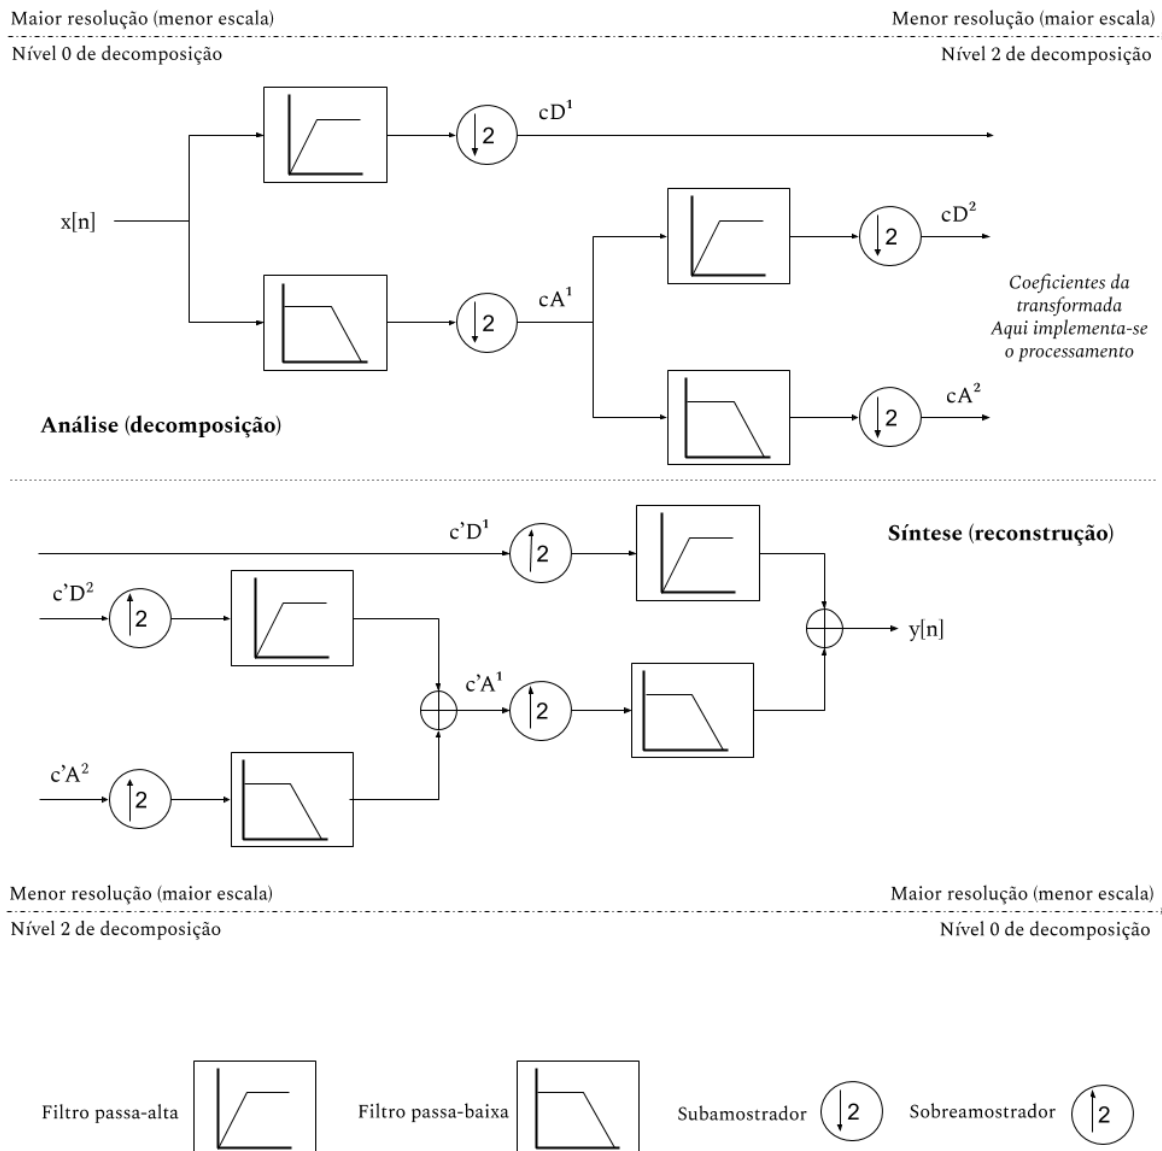


Figura 1. Banco de filtros de dois canais implementado pela Transformada Wavelet Discreta. Fonte: os autores.

De acordo com Stachura (2014), em geral, uma série temporal $x(t)$ é decomposta por meio da análise de multirresolução como

$$x(t) = S(t) + \sum_{j=1}^J D_j(t), \tag{15}$$

onde $S_j(t)$ denota as componentes cíclicas com periodicidade maior que 2^j períodos, e todos os $D_j(t)$ denotam componentes cíclicas com periodicidade entre 2^{j-1} e 2^j períodos. A componente $S(t)$

representa uma tendência (aproximação) de $x(t)$ e os $D_j(t)$ podem representar negócios e ciclos sazonais (detalhes), exceto por $D_1(t)$ que é da maior frequência e representa algum ruído.

A Equação (15) pode ser escrita na forma da Equação (1), ou vice-versa, porém esta última nos leva diretamente a uma associação com a Equação (14). Considere, na Equação (1), $X_t = x(t)$ e:

$$T_t = \sum_n a_j[n] \phi_{j,n}(t), \quad (16)$$

$$S_t + V_t = \sum_{j \leq J} \sum_n d_j[n] \psi_{j,n}(t). \quad (17)$$

Para se obter apenas a tendência T_t na equação (1), uma alternativa bem simples seria considerar todas as componentes de detalhes com $d_j[n] = 0$, o que anularia $S_t + V_t$ (Oliveira et al., 2018). Caso se queira considerar algum ruído, deve-se ter em mente que o mesmo é dado por V_t na Equação (1), e que na Equação (7) é dado por $D_1(t)$.

MATERIAL

Visto que o objetivo do presente trabalho é a estimação da componente de tendência em um série temporal, é necessário que tenhamos acesso a essa componente isoladamente, para comparar com a componente estimada pelo método de suavização aplicado. Uma vez que para séries temporais reais a componente de tendência não é conhecida, propomos a construção de uma série temporal artificial. Esta série é composta pela componente de tendência

$$T_t = \sin(\pi x), \quad (18)$$

com período de 2 segundos, e pela componente irregular (onda dente de serra - *Sawtooth wave*)

$$V_t = \frac{-2}{\pi} \arctan \left(\cot \left(\frac{x\pi}{7} \right) \right), \quad (19)$$

com período de 7 segundos, onde $0 < x \leq 4$ foi amostrado a 100Hz por 4 segundos. A Figura 2 painel (a) ilustra a série temporal artificial X_t , painel (b) a tendência T_t e painel (c) a componente irregular V_t .




Figura 2. (a) Série temporal, (b) componente de tendência dada pela Equação (10) e (c) componente irregular dada pela Equação (11). Fonte: os autores.

Para a análise de uma série temporal formada por dados reais, que envolve, geralmente, um processo de formação desconhecido e dependente de vários fatores, utilizamos a série da cotação do Dólar Americano frente ao Real Brasileiro, para todo o ano de 2019. Restringimos nossa análise apenas aos valores máximos das cotações diárias do Dólar. A série foi obtida do site br.invesing.com e é composta de 261 amostras. Entretanto, preferimos truncar a série para 256 amostras, somente para melhor visualização dos resultados.

RESULTADOS E DISCUSSÕES

O primeiro experimento consistiu da estimação da tendência da série artificial, descrita na seção anterior, utilizando o método baseado na DWT para várias bases wavelets (com diferentes momentos nulos) de Daubechies e o filtro Savitzky-Golay empregando polinômios de várias ordens. Para esta última abordagem foi considerada uma janela de tamanho 201 amostras, que correspondente a um período da série de tendência mais um, pois o filtro espera uma janela de tamanho ímpar. Para comparar

as tendências estimadas com a tendência real, considerou-se o erro quadrático médio (*Mean Square Error* - MSE), dado pela equação.

$$MSE = \frac{1}{N} \sqrt{x - \hat{x}}, \tag{20}$$

onde N é a quantidade de valores da série original x , sendo \hat{x} a sua estimação. Os resultados obtidos com esta implementação estão exibidos na Tabela 1.

Tabela 1. Resultados MSE do experimento com a série temporal artificial, considerando várias bases wavelets e ordens de polinômio para o filtro Savitzky-Golay.

Base Wavelet	MSE DWT	Ordem Polinômio	MSE Savitzky-Golay
Db2	165,79	1	153,96
Db3	26,77	2	23,31
Db4	8,81	3	23,31
Db5	2,17	4	3,25
Db6	3,35	5	3,25
Db7	22,89	6	2,49
Db8	25,18	7	2,49
Db9	24,30	8	199,99

Pelos resultados da Tabela 1, o menor MSE foi obtido ao empregar o método baseado na DWT com a base Db5. A fim de averiguar que a superioridade do método baseado na DWT não é apenas devida às características da série artificial ilustrada na Figura 1, propõe-se a obtenção de outras 20 séries temporais baseadas nos mesmos modelos das Equações (18) e (19), mas variando seus períodos, isto é: a tendência T_t tem um período que varia aleatoriamente entre 1 e 5 segundos, o que corresponde a senoides de 0,1Hz a 0,5Hz; já a componente irregular ou sazonal, V_t , tem seu período variando aleatoriamente entre 100 e 1000 segundos, correspondendo a frequências de 1Hz a 10Hz. Analogamente ao experimento anterior, variou-se as bases wavelets de Daubechies e a ordem dos polinômios do filtro Savitzky-Golay.

Tabela 2. Resultados para 20 experimentos onde foram escolhidos aleatoriamente os períodos das componentes de tendência e irregular. Aqueles experimentos cujos valores dos períodos são iguais não estão discriminados. Fonte: os autores.

Frequências (Hz)	MSE		Tempo de processamento (segundos)	
	DWT	Savitzky-Golay	DWT	Savitzky-Golay
$T_t: 0,1$ e $V_t: 5$	0,0177	0,0055	0,0311	0,0000
$T_t: 0,1$ e $V_t: 3$	0,0299	0,0115	0,0156	0,0311
$T_t: 0,2$ e $V_t: 2$	0,0638	0,0297	0,0000	0,0155
$T_t: 0,1$ e $V_t: 1$	0,1221	0,0613	0,0155	0,0155
$T_t: 0,4$ e $V_t: 3$	0,0598	0,0321	0,0155	0,0312
$T_t: 0,3$ e $V_t: 1$	0,2165	0,1337	0,0155	0,0000
$T_t: 0,4$ e $V_t: 4$	0,0354	0,0168	0,0156	0,0155
$T_t: 0,3$ e $V_t: 2$	0,1268	0,0243	0,0155	0,0312
$T_t: 0,3$ e $V_t: 4$	0,0316	0,0081	0,0155	0,0000
$T_t: 0,2$ e $V_t: 7$	0,0089	0,0028	0,0155	0,0312
$T_t: 0,4$ e $V_t: 8$	0,0093	0,0059	0,0155	0,0156
$T_t: 0,1$ e $V_t: 9$	0,0069	0,0014	0,0156	0,0155
$T_t: 0,3$ e $V_t: 7$	0,0080	0,0036	0,0156	0,0000
$T_t: 0,3$ e $V_t: 5$	0,0165	0,0074	0,0156	0,0000
$T_t: 0,3$ e $V_t: 6$	0,0113	0,0050	0,0156	0,0000
$T_t: 0,1$ e $V_t: 4$	0,0214	0,0083	0,0155	0,0311
Média	0,0565	0,0223	0,0154	0,0164
Estatística H	6,611		0,005	
p -valor	0,010		0,945	

Analisando os resultados da Tabela 2, o valor da estatística H do teste de Kruskal-Wallis e os p -valores associados, e considerando que a hipótese nula H_0 seja que ambas as abordagens possuem a mesma distribuição, para um nível de significância de 5%, concluímos pela rejeição desta hipótese em relação ao MSE e pela sua aceitação em relação ao tempo de processamento. Portanto, como a média para o filtro Savitzky-Golay é menor, então esta abordagem é melhor que o método baseado na DWT para as variações da série artificial analisada. Por outro lado, em relação ao tempo de processamento, ambas abordagens são estatisticamente iguais.

A Figura 2 ilustra as componentes de tendências com menores MSE (obtidas dos 20 experimentos aleatórios da Tabela 2), estimadas pelas abordagens implementadas em comparação com a tendência original. Podemos destacar dessas comparações que a aplicação do filtro Savitzky-Golay resulta em uma componente de tendência estimada com algumas distorções nos picos e vales dessa componente, enquanto que a estimação resultante do método baseado na DWT é mais suave e similar à tendência original. Porém, podemos também observar que nas bordas da série o filtro Savitzky-Golay provê uma estimação mais próxima à componente de tendência original que aquela estimação obtida pelo método baseado na DWT, sendo este o principal motivo desse método ter apresentado um MSE menor, pois podemos notar que nos demais segmentos, a componente estimada pelo método da DWT coincide muito bem com a componente original.




Figura 2. Comparação das séries de tendências estimadas pelo método baseado na DWT (curva alaranjada) e pelo filtro Savitzky-Golay (curva esverdeada), com a tendência original (curva azul). Fonte: os autores.

Para verificar se é o método de extensão das bordas que está ocasionando os problemas mencionados, outros 20 experimentos aleatórios foram executados, mas desta vez alternando os

métodos de extensão de bordas utilizados pela DWT. As médias de 20 MSEs estão exibidos na Tabela 3 para distintos modos de extensão das bordas da série temporal.

Tabela 3. Resultados médios dos MSEs de 20 experimentos considerando diferentes métodos de extensão das bordas da série temporal. Fonte: os autores.

Média dos MSEs		Modo de extensão da DWT*	Estatística H	p-valor	Hipótese H_0
DWT	Savitzky-Golay				
0,0305	0,0286	zero	0,059	0,808	Não rejeita
0,0601	0,0370	constante	5,418	0,020	Rejeita
0,0505	0,0272	simétrico	8,240	0,004	Rejeita
0,0202	0,0143	periódico	0,165	0,685	Não rejeita
0,0415	0,0172	suave	16,921	0,000	Rejeita
0,0211	0,0248	antissimétrico	0,237	0,626	Não Rejeita
0,0525	0,0158	antirreflexo	14,971	0,000	Rejeita

* Para informações sobre os modos de extensão consultar a biblioteca PyWavelets: <https://pywavelets.readthedocs.io/en/latest/ref/signal-extension-modes.html#modes>.

Nota-se pelos resultados da Tabela 3, analisando a última coluna, que apenas para os modos de extensão denominados de zero, periódico e antissimétrico, os resultados apresentados pelo filtro Savitzky-Golay foram estatisticamente superiores, tomando um nível de significância de 5%. Para os demais modos, ambas abordagens não apresentaram resultados estatisticamente diferentes. Portanto, pelo que foi destacado anteriormente, podemos afirmar que para os demais modos os problemas evidenciados nas bordas da série temporal afetam menos a estimação da componente de tendência. Vale destacar que para os experimentos cujos resultados estão discriminados na Tabela 2, foi empregado o modo de extensão denominado de reflexão.

No quarto experimento, foi adicionado à componente de tendência um ruído com distribuição gaussiana, com média nula e variância unitária. Analogamente aos dois experimentos anteriores, também variamos aleatoriamente os períodos das componentes de tendência e irregular nos mesmos intervalos anteriormente mencionados. Os resultados estão exibidos na Tabela 4.

Tabela 4. Resultados para 20 experimentos onde foram escolhidos aleatoriamente os períodos das componentes de tendência e irregular e adicionado um ruído com distribuição gaussiana à componente de tendência. Fonte: os autores.

Frequências (Hz)	MSE		Tempo de processamento (segundos)	
	DWT	Savitzky-Golay	DWT	Savitzky-Golay
$T_t: 0,3$ e $V_t: 5$	0,0388	0,0220	0,0155	1,5422
$T_t: 0,2$ e $V_t: 7$	0,0348	0,0382	0,0160	1,5210
$T_t: 0,2$ e $V_t: 2$	0,0387	0,0316	0,0170	1,7090
$T_t: 0,1$ e $V_t: 9$	0,0223	0,0122	0,0170	1,6660
$T_t: 0,4$ e $V_t: 9$	0,0207	0,0200	0,0160	1,5710
$T_t: 0,2$ e $V_t: 9$	0,0378	0,0196	0,0170	1,7430
$T_t: 0,3$ e $V_t: 4$	0,0256	0,0171	0,0270	1,9791
$T_t: 0,1$ e $V_t: 7$	0,0581	0,0142	0,0160	1,7330
$T_t: 0,1$ e $V_t: 3$	0,0316	0,0081	0,0155	0,0000
$T_t: 0,4$ e $V_t: 6$	0,0382	0,0291	0,0230	1,7851
$T_t: 0,4$ e $V_t: 8$	0,0350	0,0312	0,0190	1,9991
$T_t: 0,4$ e $V_t: 5$	0,0256	0,0181	0,0220	1,6610
$T_t: 0,1$ e $V_t: 6$	0,0119	0,0090	0,0150	1,9321
$T_t: 0,3$ e $V_t: 7$	0,0406	0,0333	0,0270	1,8411
$T_t: 0,2$ e $V_t: 8$	0,0246	0,0166	0,0210	1,5700
$T_t: 0,4$ e $V_t: 7$	0,0226	0,0180	0,0170	1,5150
Média	0,0326	0,0224	0,0192	1,7096
Estatística H	7,317		29,301	
p -valor	0,007		0,0000	

Pelos resultados da Tabela 4, notamos que, similarmente aos resultados da Tabela 2, considerando a estatística H e o p -valor, o filtro Savitzky-Golay gerou resultados superiores ao método baseado na DWT, mas apenas em relação ao MSE, pois para o tempo de processamento, esta última abordagem superou a primeira, pois em média foi aproximadamente 8,9 vezes menor, considerando a mesma hipótese nula e nível de significância estatística.

No quinto e último experimento, considerou-se a série temporal da cotação do Dólar Americano frente ao Real Brasileiro, discriminada na Seção Materiais. As abordagens baseadas na DWT e no filtro Savitzky-Golay foram empregadas com as seguintes configurações: base Db5 e quatro níveis

de resolução; e polinômio de ordem 6 e vários comprimentos de janelas, respectivamente, devido aos resultados constatados anteriormente. A Figura 3 ilustra os resultados obtidos para ambas abordagens, além de adicionar os resultados fornecidos pelo filtro Média Móvel, para fins de comparação.

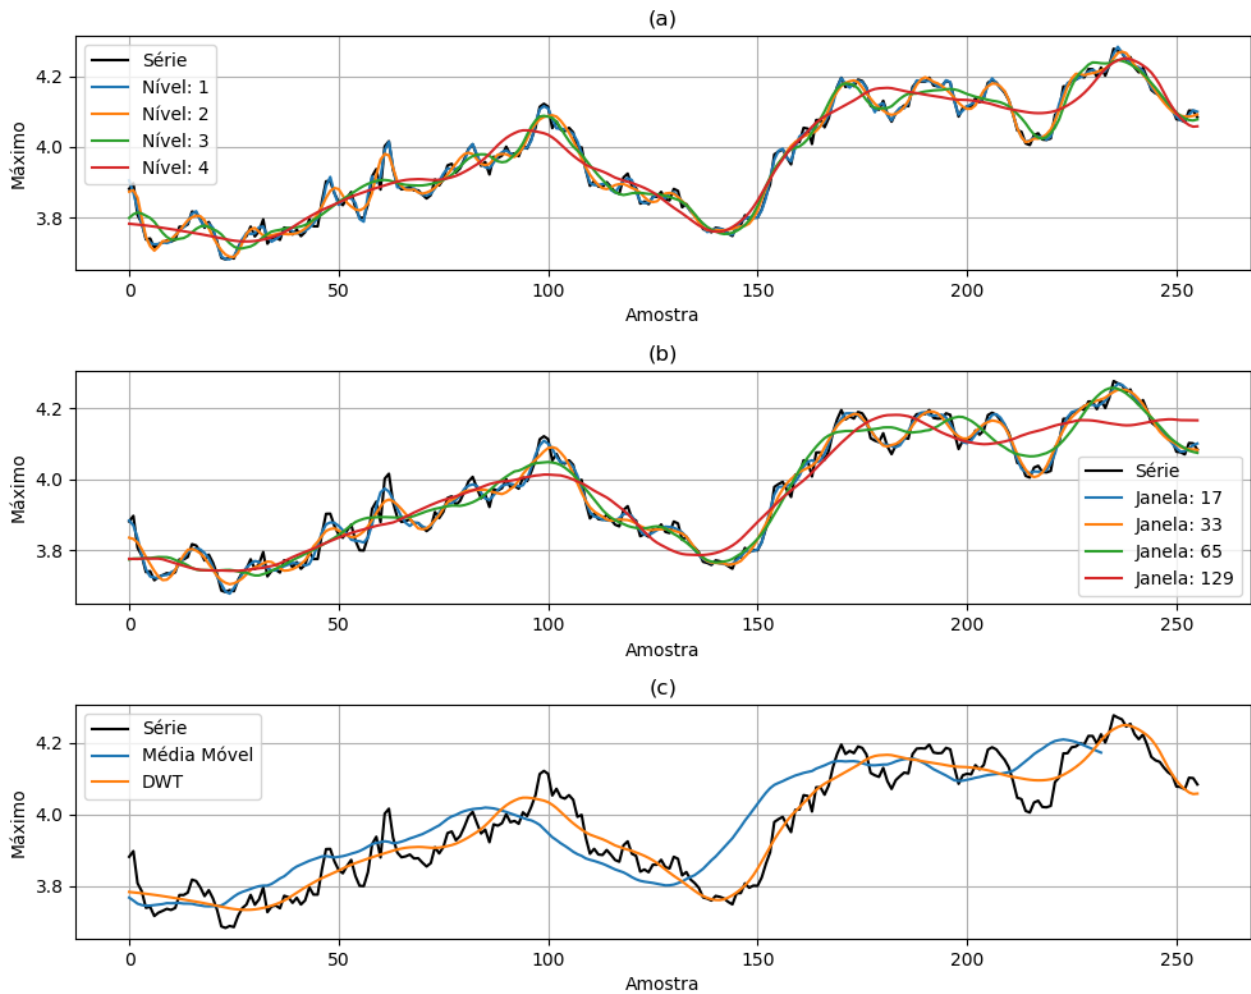


Figura 3. Estimações das componentes de tendências obtidas pelo método baseado na DWT (a) e pelo filtro Savitzky-Golay (b) e comparação das estimativas DWT e Média Móvel (c), para várias configurações. Fonte: os autores.

Nota-se, pela análise dos resultados da Figura 3, que as formas de onda das componentes de tendência estimadas são similares para níveis menores de resolução da DWT e tamanhos menores de janelas do filtro Savitzky-Golay. Ou seja, quanto maior o nível de resolução menos amostras temos nos coeficientes de aproximação devido a operação de subamostragem no banco de filtros, logo, estes coeficientes estão relacionados a uma porção maior da série temporal. Por isso, ao tomarmos uma janela de interpolação maior para o filtro Savitzky-Golay, obtemos resultados similares às estimações obtidas pela DWT, concernentes à tendência da série. Assim, as abordagens apresentam resultados análogos, mas com certas peculiaridades, para parâmetros específicos do nível de resolução e comprimento da janela.

Portanto, quando se pretende analisar as tendências de curto prazo de uma série temporal, deve-se escolher níveis de resolução mais altos para o método baseado na DWT e comprimentos de janela maiores para o filtro Savitzky-Golay, lembrando ainda que a escolha da base wavelet e da ordem do polinômio também influenciam nas estimações. Por outro lado, na análise das tendências de longo prazo, deve-se empregar níveis de resolução mais baixo e janelas de comprimentos menores. Esta constatação é evidente na estimação da tendência exibida na Figura 3 (curva azul), para um nível de resolução, pois a estimação quase que coincide completamente com a série original, enquanto que, na estimação do quarto nível, temos uma tendência que é relativa a média de cerca de 24 dias, já que o período de amostragem da série é de 1 dia, e no quarto nível analisamos as frequências entre $2^4 = 16$ e $2^5 = 32$ amostras (dias), assim:

$$24 = 2^4 + \frac{2^5 - 2^4}{2}. \quad (21)$$

Este resultado pode ser destacado na comparação das estimações da componente de tendência, Figura 3 (c), onde o resultado da DWT no quarto nível de resolução é comparado ao resultado obtido por um filtro Média Móvel empregando 24 elementos para calcular a média. Exceto pelo deslocamento natural da estimação pela Média Móvel, pois este método precisa das amostras futuras para calcular a média, ambas estimações são bem semelhantes em relação ao comportamento da componente de tendência da série.

CONSIDERAÇÕES FINAIS

Neste trabalho foi apresentado e estudado duas abordagens para estimação da componente de tendência de uma série temporal, a DWT e o filtro Savitzky-Golay. Os resultados foram avaliados utilizando o MSE e mostraram que, para a série temporal artificial gerada, o filtro Savitzky-Golay fornece melhores estimativas da componente de tendência dependendo do modo de extensão de bordas utilizado pela DWT. Os resultados mostraram que a abordagem via DWT possui algumas deficiências na estimação da componente de tendência nas bordas da série temporal. Quando utilizado o modo antissimétrico de extensão de bordas, o teste estatístico de Kruskal-Wallis, considerando uma significância estatística de 5%, estabeleceu que não existe diferença estatística entre as abordagens. O mesmo ocorre para o tempo de processamento, mas neste caso o resultado independe do modo de extensão escolhido.

Por outro lado, ao considerar ruído com distribuição gaussiana adicionado à componente de tendência artificial, verificamos que o filtro Savitzky-Golay resultou em um tempo de processamento cerca de 8 vezes maior que o método baseado na DWT, o que evidencia a vantagem da DWT principalmente para aplicações em tempo real.

Nas análises da série temporal do par de moedas dólar/real, constatamos que ambas as abordagens apresentaram resultados similares para certas escolhas dos parâmetros de nível de resolução e comprimento da janela, para as abordagens via DWT e filtro Savitzky-Golay, respectivamente. Nestes casos, uma comparação numérica não foi possível pois a componente de tendência original não é conhecida. Outro fato interessante constatado foi em relação à comparação da DWT com o filtro Média Móvel, pois observou-se que é possível ajustar o nível de resolução da DWT para que este tenha resultados similares ao filtro Média Móvel.

Em trabalhos futuros pretende-se investigar com maior profundidade todas as análises aqui realizadas, sendo que um dos objetivos prováveis será o emprego da *Wavelet Neural Networks*, que possibilita obter bases wavelets adaptadas aos dados analisados.

REFERÊNCIAS BIBLIOGRÁFICAS

- Carbone A (2009). *Detrending Moving Average algorithm: a brief review*. In: 2009 IEEE Toronto International Conference Science and Technology for Humanity (TIC-STH), DOI: 10.1109/TIC-STH.2009.5444412.
- Cao R, Chen Y, Shen M, Chen J, Zhou J, Wang C, Yang W (2018). *A simple method to improve the quality of NDVI time-series data by integrating spatiotemporal information with the Savitzky-Golay filter*. Remote Sensing of Environment, (217): 244-257.
- Fuller W A (1996). *Introduction to Statistical Time Series*. 2 ed. John Wiley & Sons, Inc., New York. 720p.
- Fu TC, Chung FL, Luk R, Ng CM (2008). *Representing financial time series based on data point importance*. Engineering Applications of Artificial Intelligence, 21(2): 277-300.
- Kordestani H, Zhang C (2020). *Direct Use of the Savitzky-Golay Filter to Develop an Output-Only Trend Line-Based Damage Detection Method*. Sensors: 1-15. DOI: 10.3390/s20071983.
- Liu J, Pei Z (2016). *The impacts of smoothing methods for time-series remote sensing data on crop phenology extraction*. IEEE International Geoscience and Remote Sensing Symposium (IGARSS). IEEE.
- Mallat, S (2009). *A wavelet tour of signal processing: The sparse way*. 3 ed. Editora: Academic Press, London.
- Oliveira BR de, Duarte MAQ, Abreu CCE de, Vieira Filho J (2018). *A wavelet-based method for power-line interference removal in ECG signals*. Res. Biomed. Eng, 34(1): 73-86. DOI: 10.1590/2446-4740.01817.
- Percival DB, Walden A. (2000). *Wavelet methods for time series analysis*, Cambridge University Press: Cambridge.
- Picasso A, Merello S, Ma Y, Oneto L, Cambria E (2019). *Technical analysis and sentiment embeddings for market trend prediction*. Expert Systems with Applications, 135: 60-70.

- Puchalsky W, Ribeiro GT, Veiga CP, Freire RZ, dos Santos CL (2018). *Agribusiness time series forecasting using Wavelet neural networks and metaheuristic optimization: An analysis of the soybean sack price and perishable products demand*. International Journal of Production Economics, (203): 174-189.
- Radityo A, Munajat Q, Budi I (2017). *Prediction of Bitcoin exchange rate to American dollar using artificial neural network methods*. In 2017 International Conference on Advanced Computer Science and Information Systems (ICACSIS): 433-438.
- Schlüter S, Deuschle C (2010). Using wavelets for time series forecasting: Does it pay off?. IWQW Discussion Papers, No. 04/2010, Friedrich-Alexander-Universität Erlangen-Nürnberg, Institut für Wirtschaftspolitik und Quantitative Wirtschaftsforschung (IWQW), Nürnberg.
- Stachura M (2014). *Detecting seasonality via wavelet methods*. Studia Ekonomiczne, 207:223-232.
- Strang, G. e Nguyen, T. (1996). *Wavelets and filter banks*. Wellesley, MA: Wellesley-Cambridge Press. (Livro)
- Savitzky A, Golay M (1964). *Smoothing and differentiation of data by simplified least squares procedures*. Analytical chemistry, 36(8): 1627-1639.
- Schafer RW (2011). *What is a savitzky-golay filter?*[lecture notes]. IEEE Signal processing magazine 28(4): 111-117.
- Xiaoxiong W, Pan M, Xia C (2019). *Water level data preprocessing method based on savitzky-golay filter*. 2019 International Conference on Modeling, Simulation and Big Data Analysis (MSBDA 2019). Atlantis Press
- Zhang D (2005). *Wavelet Approach for ECG Baseline Wander Correction and Noise Reduction*. In: 2005 IEEE Engineering in Medicine and Biology 27th Annual Conference. DOI: 10.1109/IEMBS.2005.1616642.

ÍNDICE REMISSIVO

A

agrupamento, 49, 53, 54
aprendizado de máquina, 8, 25, 28, 29, 59, 60, 61, 80
Aprendizagem de Máquina, 50, 57, 83

C

caso de uso, 41, 42, 44, 46
CCA, 84, 85, 86, 87, 88, 95
cenário, 39, 43, 44, 45, 85
Cenas Acústicas, 83, 84, 95

Ch

checklist, 34, 39, 41

C

Ciência de Dados, 33
classificação, 31, 39, 50, 56, 59, 60, 61, 62, 63, 68, 69, 72, 73, 74, 84, 85, 88, 90, 94
clusterização, 50, 51, 54
coeficiente, 10, 11, 89, 94
comportamento, 8, 9, 22, 26, 30, 32, 37, 56, 70

D

Deep Learning, 31, 32, 59, 81, 87, 90, 94
desenvolvimento de SI, 35, 36, 39
domótica, 25, 26

E

Engenharia de Requisitos, 33, 47, 48
escalograma, 89, 90
espaço de atributos, 59, 60, 70, 73, 74, 76, 80, 81
espectro, 86, 89
espectrograma, 85, 86

F

Farthest First, 49, 50, 53, 54, 56

filtro, 8, 9, 10, 11, 15, 16, 17, 18, 19, 20, 21, 22, 89

G

GWS, 89, 90, 91, 92, 93, 94

I

Inteligência Artificial, 25

M

machine learning, 30, 31, 84, 87
mapeamento, 48, 60, 70, 73, 74, 77, 78, 80, 81, 88
metodologia, 33, 34, 35, 36, 37, 39, 41, 42, 47
MFCCs, 84, 86, 87, 90, 91, 93, 94

O

obesidade, 49, 50, 55, 56, 57, 58

P

polinômio, 10, 11, 16, 20, 21
prototipação, 33, 35, 39, 41, 47

Q

qualidade, 33, 34, 35, 39, 41, 47, 57

R

Redes Neurais
 Artificiais, 25, 26
 LSTM, 26
regressão logística, 59, 62, 63, 70
requisitos, 28, 33, 34, 35, 39, 41, 48

S

Savitzky-Golay, 8, 9, 10, 15, 16, 17, 18, 19, 20, 21, 22, 23
sensores, 26, 27, 29
Série Temporal, 8, 9
Sistema de Informação, 47, 48

Software, 47, 48, 95

superfície de decisão, 62, 77

T

tendência, 8, 9, 10, 14, 15, 16, 17, 18, 19, 21,
22, 57, 58

Transformada Wavelet, 8, 9, 10, 13, 70, 83, 84,
87, 88, 90, 95



Pantanal Editora

Rua Abaete, 83, Sala B, Centro. CEP: 78690-000
Nova Xavantina – Mato Grosso – Brasil
Telefone (66) 99682-4165 (Whatsapp)
<https://www.editorapantanal.com.br>
contato@editorapantanal.com.br

ISBN 978-658831926-0



9

786588

319260