Revista Brasileira de Climatologia
Brazilian Journal of Climatology
OPEN ACCESS
LFG Editora

ANÁLISE ESTATÍSTICA DE AUTOCORRELAÇÃO E CORRELAÇÃO CRUZADA: UM ESTUDO DE CASO INERENETE A QUESTÃO DE SEGURANÇA HÍDRICA

Statistical analysis of auto-correlation and cross-correlation: a case of study inherent to the issue of water security

Análisis estadístico de autocorrelación y correlación cruzada: un estudio de caso inherente al tema de seguridad hídrica

Basílio Fernandez
Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente (PPGM)
Universidade Estadual de Feira de Santana (UEFS)
basilio.fernandez@hotmail.com

Lidiane Alves de Oliveira
Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente (PPGM)
Universidade Estadual de Feira de Santana (UEFS)
lidiane_alves@outlook.com.br

Gilney Figueira Zebende
Universidade Estadual de Feira de Santana (UEFS)
gfzebende@uefs.br

Resumo: Os índices de vegetação, NDVI e EVI, utilizados na análise de dados de sensoriamento remoto, avaliam a saúde e o vigor da vegetação com base na refletância medida por sensores em satélites. Com base nos valores desses índices (e suas bandas espectrais RGB) como função do tempo, este artigo propõe uma análise completa de autocorrelação e correlação cruzada, isto ao longo de mais de seis anos de observação. Para tanto, uma importante área de proteção ambiental foi escolhida, onde geração de energia e segurança hídrica são fatores cruciais no que diz respeito o bem estar de milhões de habitantes. Para esta análise, o método DFA e o coeficiente DCCA de correlação cruzada foram aplicados. Inicialmente, no estudo das autocorrelações, foi identificada uma mudança no comportamento da função de autocorrelação em torno de 30 observações, com valores distintos para os expoentes a depender do índice utilizado. Posteriormente, na análise da relação mútua entre todos os índices, por meio do coeficiente DCCA de correlação cruzada, percebe-se que o valor do coeficiente pode ser negativo ou positivo, com variação de DCCA correlação cruzada de nível fraco até nível forte, a depender de sua escala temporal.

Palavras-chave: NDVI. EVI. Segurança hídrica. DFA. ρ_{DCCA}

Abstract: The vegetation indexes, NDVI and EVI, used in the analysis of remote sensing data, assess the health and vigor of vegetation based on the reflectance measured by sensors on satellites. Based on these values (and its RGB spectral bands) as a function of time, this paper proposes a complete analysis of auto-correlation and cross-correlation, for more than six years of observation. For this purpose, an important environmental protection area was chosen, where energy generation and water security are crucial factors regarding the well-being of millions of inhabitants. For this analysis, the DFA method and the DCCA cross-correlation coefficient were applied. Initially, in the study of auto-correlations, a clear change of behavior in the auto-correlation function was identified around 30 observations, with different exponents values depending on the index applied. Subsequently, in the analysis of the mutual relationship between all indexes, through the DCCA cross-correlation coefficient, it was clear that the value of this coefficient can be negative or positive, with DCCA cross-correlation varying from a weak to a strong level, depending on its time scale.
Keywords: NDVI. EVI. Water Security. DFA. ρ_{DCCA}.

Resumen: Los índices de vegetación, NDVI y EVI, utilizados en el análisis de datos de teledetección, evalúan la salud y el vigor de la vegetación basándose en la reflectancia medida por sensores en satélites. Con base en estos valores (y sus bandas espectrales RGB) en función del tiempo, este artículo propone un análisis completo de autocorrelación y correlación cruzada, durante más de seis años de observación. Para ello se eligió una importante zona de protección ambiental, donde la generación de energía y la seguridad hídrica son factores cruciales para el bienestar de millones de habitantes. Para este análisis se aplicó el método DFA y el coeficiente de correlación cruzada DCCA. Inicialmente, en el estudio de las autocorrelaciones se identificó un claro cambio de comportamiento en la función de autocorrelación alrededor de 30 observaciones, con diferentes valores de exponentes según el índice aplicado. Posteriormente, en el análisis de la relación mutua entre todos los índices, a través del coeficiente de correlación cruzada DCCA, quedó claro que el valor de este coeficiente puede ser negativo o positivo, variando la correlación cruzada DCCA de un nivel débil a un nivel fuerte. dependiendo de su escala de tiempo.
Palabras clave: NDVI. EVI. Seguridad Hídrica. DFA. ρ_{DCCA}.

Submetido em: 22/08/2024
Aceito para publicação em: 12/12/2024
Publicado em: 18/12/2024

1. INTRODUÇÃO

O fornecimento de água para centros urbanos através de reservas hídricas tem recebido atenção ultimamente de gestores públicos, isto por meio da criação e manutenção de Áreas de Proteção Ambiental, APAs, destinadas à proteção dos solos e especialmente das matas ciliares (Brasil, 2012). Este tipo de vegetação tem como função de salvaguardar reservatórios, lagos e rios de assoreamentos, garantindo assim a biodiversidade dos ecossistemas, onde a fauna e a flora recebem destaque e, por conseguinte, a preservação dos recursos hídricos ficam garantidos (Brasil, 1981; UN-WATER, 2013). Neste artigo, uma área localizada no Estado da Bahia, onde encontra-se a APA de Pedra do Cavalo, ver **Fig. 1**, será destacada. Esta é uma área que abriga uma rica diversidade de ecossistemas terrestres e aquáticos. Dentro dessa área, está situada também uma usina de energia hidráulica e duas estações de tratamento de água, operadas pela EMBASA, Empresa Baiana de Águas e Saneamento da Bahia, que desempenham um papel vital na garantia de acesso a água potável e de qualidade para a Região Metropolitana de Salvador e da cidade de Feira de Santana. A coexistência destas infraestruturas, quando geridas de forma responsável e sustentável, exemplifica a importância de se conciliar o desenvolvimento socioeconômico com a conservação ambiental, promovendo um equilíbrio entre as necessidades humanas e a preservação dos recursos naturais.

Por sua clara importância, neste artigo, uma região pautada pelo bem-estar e pela segurança hídrica de milhões de pessoas será analisada. A análise desta região será feita a partir de dados de sensoriamento remoto, com índices de vegetação e as bandas espectrais correspondentes ao espectro no visível (RGB), medidos ao longo do tempo. Por meio do estudo de autocorrelação (para cada índice), via método **DFA**, e da aplicação do coeficiente **DCCA** de correlação cruzada, ρ_{DCCA}, os resultados serão obtidos, analisados e discutidos ao longo do trabalho.

Estes índices são essenciais para investigar a resposta da vegetação a variações climáticas, como seca e eventos extremos de precipitação, ver (Huete, Jackson, Post, 1985; Huntington *et al.*, 2017). Na região de estudo, esses índices podem auxiliar na avaliação da disponibilidade e do uso da água. Estudos como os de Ansari *et al*. (2024) destacam que a integração de dados climáticos e de vegetação permite a geração de indicadores que

fornecem suporte para a gestão de recursos hídricos, reduzindo os riscos associados à escassez de água. A relação entre os índices de vegetação e a climatologia é fundamental para compreender, por exemplo, os padrões de evapotranspiração e o ciclo hidrológico. Regiões com alta segurança hídrica frequentemente apresentam padrões consistentes de vegetação ao longo do tempo, refletidos por valores elevados e estáveis de NDVI e EVI (Gorelick *et al.*, 2017; Ansari *et al*.,2024).

Portanto, este trabalho tem como objetivo identificar a existência ou não de memórias (de curta ou de longo alcance) nos sinais produzidos por estes índices, e ao mesmo tempo, medir as suas relações mútuas. Desta forma, este artigo está dividido nas seguintes seções: área de estudo e dados, metodologia, resultados e conclusões, visto logo a seguir.

2. ÁREA DE ESTUDO E DADOS

A área de estudo é apresentada na **Fig. 1** (polígono interno), área com interesse ambiental e de fundamental importância sobre o ponto de vista da segurança hídrica. Nesta região está localizada uma APA, bem como várias cidades ao seu entorno. Entre as cidades, vê-se: Feira de Santana, Antônio Cardoso, Santo Estêvão, Cabaceiras do Paraguaçu, Cachoeira de São Félix, Conceição da Feira, São Gonçalo dos Campos, Rafael Jambeiro e áreas de Serra Preta, Anguera, Coração de Maria, Santo Amaro, Muritiba, Castro Alves e Ipecaetá, com um total de aproximadamente $2.500\ km^2$. Especificamente, a APA, denominada de Pedra do Cavalo, foi criada em 1997 por um decreto estadual da Bahia. Esta APA tem o objetivo de proteger o manancial de água no lago de Pedra do Cavalo, respeitando suas características ambientais, assegurando assim o abastecimento de água, em qualidade e quantidade, para boa parte da Região Metropolitana de Salvador e Feira de Santana, beneficiando assim cerca de 4 milhões de habitantes.

Figura 1 - Área de estudo, localizada dentro do Estado da Bahia, com a inclusão da APA de Pedra do Cavalo.

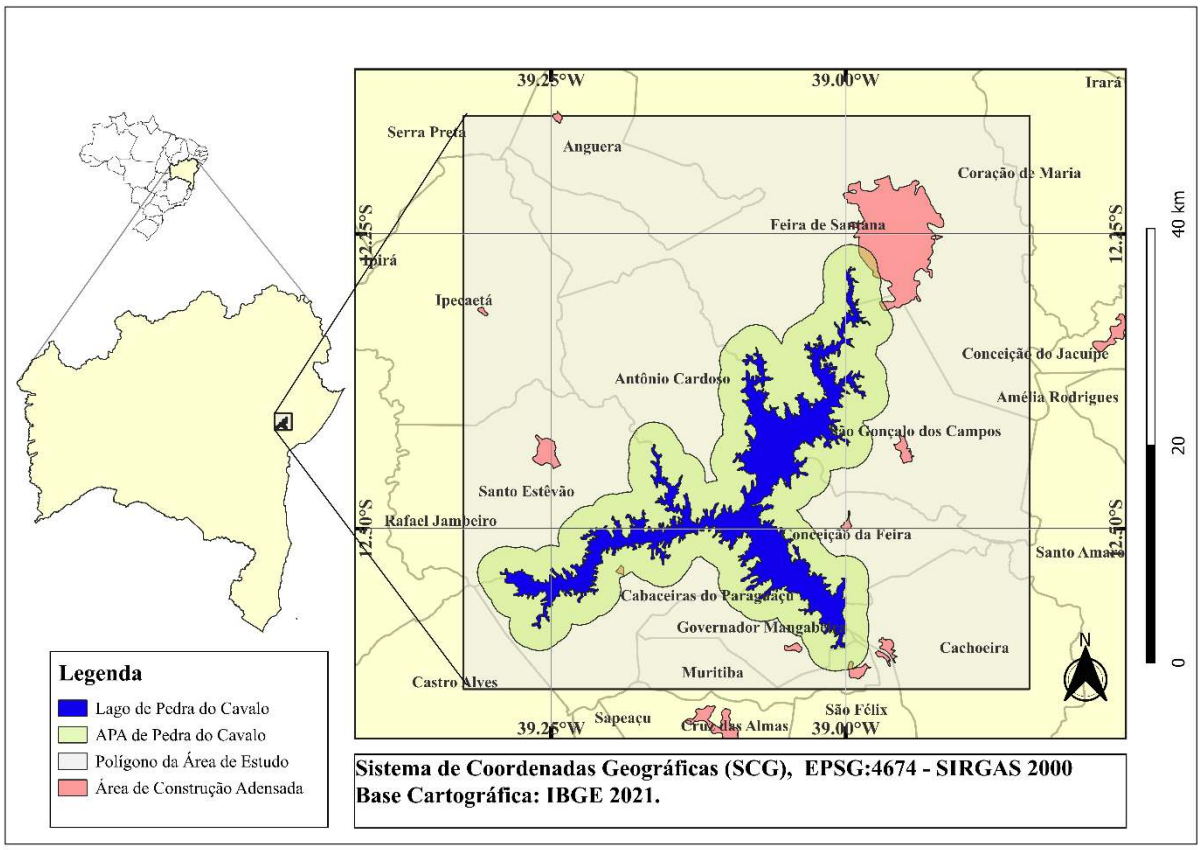

Fonte: Elaborado pelos autores (2024).

Para análise estatística dos índices de vegetação e bandas espectrais como função do tempo, os dados foram obtidos através de sensoriamento remoto a partir do *Google Earth Engine* (Gorelick *et al.*, 2017), utilizando de uma prática ferramenta, chamada de *Climate Engine* (Huntington *et al.*, 2017), útil para a aquisição dos dados de vegetação e bandas espectrais em nossa área de estudo. O *Climate Engine* utiliza dados do *Google Earth Engine*, para processamento sob demanda de dados climáticos e de satélite em um navegador da *web* e apresenta mapeamento sob demanda de conjuntos de dados monitoramento ambiental por meio de imagens de sensoriamento remoto. Com análises totalmente personalizáveis, o aplicativo permite ao usuário produzir mapas e resumos de séries temporais a partir desses conjuntos de dados. O aplicativo é customizável para análises espaciais e temporais. As métricas disponíveis para processamento incluem um conjunto abrangente de variáveis que fornecem indicadores de alerta precoce dos impactos climáticos, tais como secas, incêndios florestais, *stress* ecológico e produção agrícola. O aplicativo *Climate Engine* está disponível *on-line* em:

https://app.climateengine.org/climateEngine. Acesso em: 18 ago. de 2024.

O aplicativo é bem intuitivo, onde podemos escolher a área de estudo, o tipo de variável e o satélite, ver García *et al.* (2024), Ansari *et al.* (2024), dentre outros trabalhos.

O artigo opta pela escolha dos satélites *LANDSAT* 5,7 e 8, com uma resolução espacial de 30 m, para área reportada na **Fig. 1**. Sedo a análise estatística feita para os Índice de Vegetação por Diferença Normalizada (NDVI) e Índice de Vegetação Melhorado (EVI) - dois importantes indicadores, usados em sensoriamento remoto para avaliar a saúde e a vigorosidade da vegetação (Huete *et al*., 1985; Jackson e Huete, 1991; Liu e Huete, 1995).

O NDVI é calculado a partir de dados de refletância de luz visível e infravermelho próximo, que mede a quantidade de clorofila nas plantas e sua atividade fotossintética. Sabe-se que valores próximos a 1 indicam alta densidade de vegetação e valores próximos a 0 indicam pouca ou nenhuma vegetação. Já o EVI é uma versão melhorada do NDVI, que leva em consideração fatores como o efeito do solo e a dispersão atmosférica, tornando-o mais sensível a mudanças na vegetação em áreas densas. Ele é calculado usando as mesmas bandas espectrais do NDVI, mas com fórmula que compensa a distorção introduzida por esses fatores. O EVI é considerado mais robusto em áreas com vegetação densa e em ambientes urbanos. Ambos os índices são amplamente utilizados em uma variedade de aplicações, incluindo monitoramento da saúde das plantas, detecção de mudanças no uso da terra, estimativa de produtividade agrícola, estudos de ecologia e gestão de recursos naturais. A escolha entre o NDVI e o EVI depende das características específicas da área de estudo e dos objetivos da análise, para maiores detalhes ver (Nkiaka *et al.*, 2024; Gonçalves, *et al*., 2012; Godwin, *et al*., 2024; Saby, *et al*., 2022; Liu, *et al*., 2024).

Para complementação da análise, serão utilizadas as bandas do Azul (Blue Band), do Verde (Green Band), do Vermelho (Red Band) e o NIR - refletância espectral no infravermelho próximo, como pode ser visto na **Fig. 2**.

Figura 2 – Índices de vegetação e bandas espectrais em função do tempo obtidos por sensoriamento remoto, com período compreendido entre os dias de 25 de dezembro de 2013 e 25 de outubro de 2020, com um total de 273 imagens.

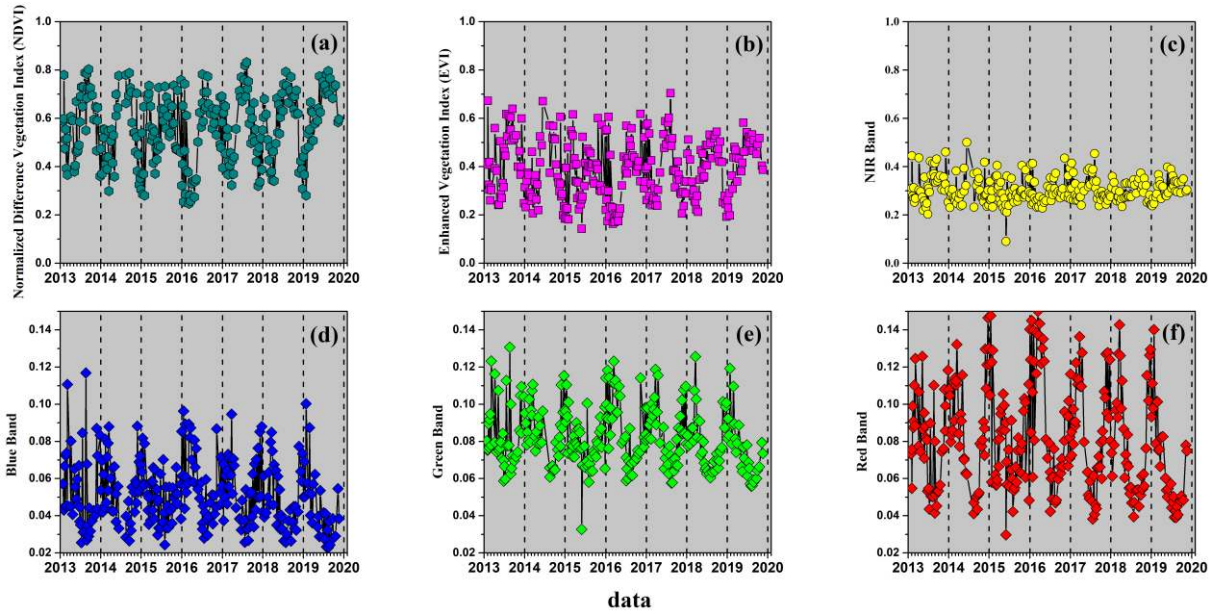

Fonte: Elaborado pelos autores (2024).

Com os dados tabulados (séries temporais) será aplicada a metodologia a seguir, no intuito de verificar a existência ou não de leis de potência (memória de curto ou longo alcance) ou mesmo relações mútuas (correlações cruzadas) entre os índices, por meio do método **DFA** e do coeficiente ρ_{DCCA}.

3. METODOLOGIA

3.1. Método DFA (PENG *et al.*, 1994)

O método **DFA** (Peng *et al.*, 1994) fornece uma relação entre a função de flutuação, F_{DFA}, e a escala temporal n. O método **DFA** tem sido muito eficiente na detecção de autocorrelações de longo alcance com caudas longas, do tipo lei de potência. A importância do método pode ser comprovada pelo grande número de aplicações e citações em diversas as áreas do conhecimento, como em Chen *et al.* (2002), Hu *et al.* (2001), Zebende *et al.* (2021), entre muitas outras. Nesta direção, logo abaixo é feita brevemente uma introdução ao algoritmo do método **DFA**, que envolve os seguintes passos (seis):

Passo 1- Considere um determinado sinal $u(i)$, com $i = 1, \cdots, N$, sendo N o tamanho da série temporal. O sinal $u(i)$ é integrado, e assim obtém-se:

(1) $x(k) = \sum_{i=1}^{k}[u(i) - \langle u \rangle]$,

sendo $\langle u \rangle$ a média aritmética de u para toda série temporal e $k = 1, \cdots, N$;

Passo 2- O sinal integrado $x(k)$ é dividido em caixas (box) de igual tamanho n (escala temporal);

Passo 3- Para cada caixa de tamanho n, um ajuste polinomial de ordem l (geralmente é usado l = 1) é feito em $x(k)$, que será a tendência do sinal dentro da caixa. A coordenada y do ajuste dentro de cada caixa será definida por $x_n(k, l)$;

Passo 4- O sinal integrado $x(k)$ é "destendenciado", isto pela subtração de $x_n(k, l)$ em cada caixa (de tamanho n);

Passo 5- Para caixas sobrepostas, com $(N - n)$ valores, calcula-se a função de covariância em todos as caixas, ou seja,

(2) $f_{DFA}^2(n, i) = \frac{1}{(n+1)} \sum_{k=i}^{i+n}[x(k) - x_n(k, l)]^2$

Logo após, calcula-se a sua função de flutuação, definida por

(3) $F_{DFA}(n) = \sqrt{\frac{1}{(N-n)} \sum_{i=1}^{N-n} f_{DFA}^2(n, i)}$

Passo 6 - O cálculo, dos passos anteriores, é repetido para as outras escalas temporais que compreendem, $4 \leq n \leq N/4$, e assim tem-se a relação entre F_{DFA} e a escala temporal n.

Se o sinal for caracterizado por uma lei de potência, então:

(4) $F_{DFA} \sim n^{\alpha_{DFA}}$

Neste sentido, α_{DFA} é definido como sendo o expoente de autocorrelação de longo-alcance, com as seguintes propriedades (ver Quadro 1 abaixo).

Quadro 1 - α_{DFA} e a característica da série temporal (WALLECZEK *et al.*, 2000, p. 421–428; ZEBENDE, FERNANDEZ e PEREIRA, 2016).

expoente	tipo de série temporal
$\alpha_{DFA} < 0{,}5$	antipersistente
$\alpha_{DFA} \cong 0{,}5$	descorrelacionada, ruído branco
$\alpha_{DFA} > 0{,}5$	persistente de longo alcance
$\alpha_{DFA} \cong 1{,}0$	ruído $1/f$
$\alpha_{DFA} > 1{,}0$	não estacionária
$\alpha_{DFA} \cong 3/2$	ruído Browniano

Fonte: Elaborado pelos autores (2020).

O expoente α_{DFA} é semelhante ao expoente de Hurst, porém α_{DFA} pode ser aplicado a sinais não estacionários e é mais robusto do que o expoente de Hurst, ver Hu *et al.* (2001) e Chen *et al.* (2002), em que efeitos de tendência e não estacionaridade foram testados. Porém, nem sempre há uma caracterização de lei de potência única, assim tendências e sazonalidades podem estar presentes no sinal. Nestes casos o método **DFA** também pode ser aplicado para a análise destes efeitos, como pode ser visto em Zebende *et al.* (2021).

Também, se houver interesse em se analisar correlações cruzadas entre as séries temporais, pode-se (e é bem-vindo) empregar o coeficiente **DCCA** de correlação cruzada, ρ_{DCCA}, que será descrito e aplicado entre todas as combinações das séries temporais (ver séries temporais na **Fig. 2**) logo abaixo.

3.2. Coeficiente DCCA de Correlação Cruzada ρ_{DCCA} (Zebende, 2011)

O coeficiente **DCCA** de correlação cruzada, ρ_{DCCA}, quantifica o nível de correlação entre duas séries não estacionárias de mesmo tamanho. Por exemplo, considerando duas séries temporais $\{x_i\}$ e $\{y_i\}$ com $i = 1, 2, 3, \cdots, N$ (tamanho da série), o cálculo de ρ_{DCCA} preconiza as seguintes etapas (ZEBENDE, 2011) :

i. Integrar $\{x_i\}$ e $\{y_i\}$, e assim obter duas novas séries

(5) $X_k = \sum_{i=1}^{k}[x_i - \langle x \rangle]$ e $Y_k = \sum_{i=1}^{k}[y_i - \langle y \rangle]$,
sendo $\langle x \rangle$ e $\langle y \rangle$ os respectivos valores médios de $\{x_i\}$ e $\{y_i\}$;

ii. Dividir as duas séries $\{X_k\}$ e $\{Y_k\}$ em $(N - n)$ caixas sobrepostas de igual comprimento n , cada uma contendo $n + 1$ valores, com início em i e término em $(i + n)$;

iii. Para cada caixa, calcula-se a tendência linear local, $\tilde{X}_{k,i}$ e $\tilde{Y}_{k,i}$ $(i \leq k \leq i + n)$ de X_k e Y_k respectivamente, e assim obtém-se a covariância dos resíduos em cada caixa

(6) $$f^2_{DCCA_{xy}}(n, i) = \frac{1}{n+1}\sum_{i}^{i+n}\left(X_k - \tilde{X}_{k,i}\right)\left(Y_k - \tilde{Y}_{k,i}\right);$$

iv. Seguidamente, para cada escala temporal de tamanho n (número de observações do satélite), calcula-se a função de covariância sem tendência, ou seja,

(7) $$F^2_{DCCA_{xy}}(n) = \frac{1}{N-n}\sum_{i=1}^{N-n} f^2_{DCCA}(n,i)\,;$$

v. As etapas acima são repetidas, para cada uma das escalas temporais, $4 \leq n \leq {}^{N}/_{4}$;

vi. Ao fim, o coeficiente ρ_{DCCA} é calculado pela equação

(8) $$\rho_{DCCA}(n) = \frac{F^2_{DCCA_{xy}}(n)}{F_{DFA_x}(n) \times F_{DFA_y}(n)}$$

O algoritmo, para o cálculo deste coeficiente, pode ser melhor compreendido a partir do vídeo publicado em Algoritmo para o rho_DCCA, por Gilney Zebende (2021).

Todos os resultados encontrados para ρ_{DCCA} são adimensionais e variam entre -1 e 1, em que:

$$\rho_{DCCA} = \begin{cases} -1 & \text{existe anticorrelação cruzada perfeita} \\ 0 & \text{ausência de correlação cruzada entre as duas séries temporais} \\ +1 & \text{existe correlação cruzada perfeita} \end{cases}$$

Várias aplicações do ρ_{DCCA} podem ser vistas na literatura, como em Kristoufek (2014), Podobnik *et al.* (2011), Vassoler e Zebende (2012), Zebende *et al.* (2018), dentre outras. Os resultados com a aplicação do método **DFA** e do ρ_{DCCA}, aos índices captados por sensoriamento remoto, serão apresentados na próxima seção.

4. RESULTADOS

Vendo a **Fig. 2**, como os valores dos índices em função do tempo (escala de dias), percebe-se, nitidamente, o efeito sazonal anual (ver linhas pontilhadas verticais) ao longo da área demarcada, com uma maior amplitude de variação para o NDVI, e seguido do EVI. Os valores para os quais o NDVI é máximo concentram-se basicamente no inverno, período de maior intensidade de chuvas, ao passo que ele é menor no verão, período de menor precipitação e por conseguinte menos verde. Para os outros espectros, também há esta variação sazonal ao longo do tempo (ver NIR Band, Blue Band, Green Band e Red Band). Ao olharmos diretamente para esta figura, em geral, não é possível se inferir conclusões a respeito de sua memória, ou mesmo, da relação estatística entre os índices. Para tanto, o método **DFA** e o coeficiente ρ_{DCCA} foram aplicados, com o objetivo de se aferir a memória da

série temporal e suas relações mútuas, de modo a se obter uma análise estatística robusta para uma importante região (APA de Pedra do Cavalo).

Inicialmente, os resultados para a aplicação do método **DFA** são apresentados na **Fig. 3**, com F_{DFA} como função de n. Os resultados mostram que, para todos os índices, há uma transição de comportamento para escalas temporais n em torno de 30 medições dos satélites (apresentado na figura pela linha vertical pontilhada). Os valores do expoente α_{DFA}, mostram-se persistentes ($\alpha_{DFA} > 0{,}5$) para $n < 30$ e antipersistentes ($\alpha_{DFA} < 0{,}5$) no caso em que $n > 30$. Também, os valores obtidos para o expoente α_{DFA} dependem de qual índice é analisado.

Figura 3 - F_{DFA} como função da escala temporal n, para os índices NDVI, EVI, NIR, Blue Band (Azul), Green (Verde) Band e Red Band (Vermelha). A linha vertical pontilhada separa as escalas temporais acima e abaixo $n = 30$ observações. Nesta figura vê-se os valores do expoente de autocorrelação calculado para escalas temporais menores e maiores do que 30 observações.

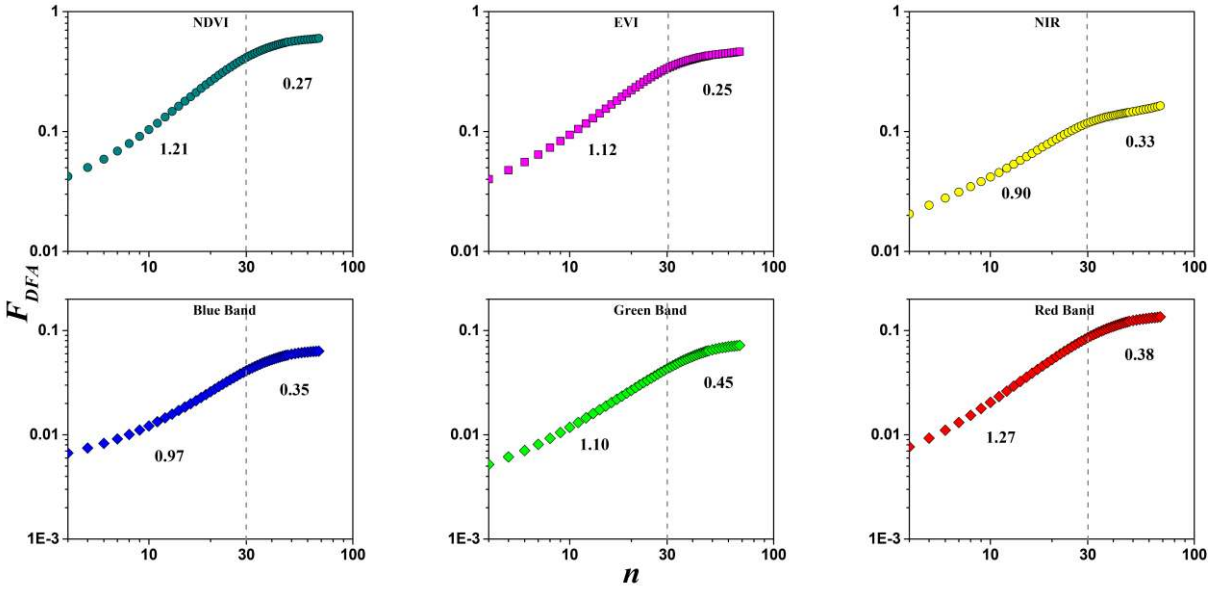

Fonte: Elaborado pelos autores (2020).

Sob a perspectiva das relações mútuas entre variáveis, ou das suas correlações cruzadas, aplica-se o coeficiente ρ_{DCCA} como função da escala temporal n entre todos os índices. O resultado para esta aplicação encontra-se na **Fig. 4**. A figura mostra todas as possíveis combinações entre estes índices e bandas. O valor de ρ_{DCCA} é dividido entre: valores positivos e valores negativos, tendo $n = 30$ como aquele em que ρ_{DCCA} tem aproximadamente a sua maior amplitude (veja a linha vertical tracejada na figura). Alguns dos resultados corroboram com a teoria, ou seja, NDVI com EVI tem $\rho_{DCCA} \cong 1{,}0$ (máximo valor)

e NDVI com Red tem $\rho_{DCCA} \cong -1{,}0$ (mínimo valor), principalmente a partir de $n = 30$ observações. Ou seja, é possível identificar em que escala temporal isto ocorre e aferir qual a relação entre todos estes índices. Por exemplo, NDVI com Blue não é totalmente anti-correlacionado (com $\rho_{DCCA} = -1{,}0$), mas tem um valor em torno de -0,8 para $n = 30$ observações, entre os outros casos.

Figura 4 - ρ_{DCCA} como função da escala temporal n, com a combinação entre os todos os índices. A linha vertical representa a escala temporal $n = 30$ (observações) e divide o estudo em pequenas e longas escalas temporais.

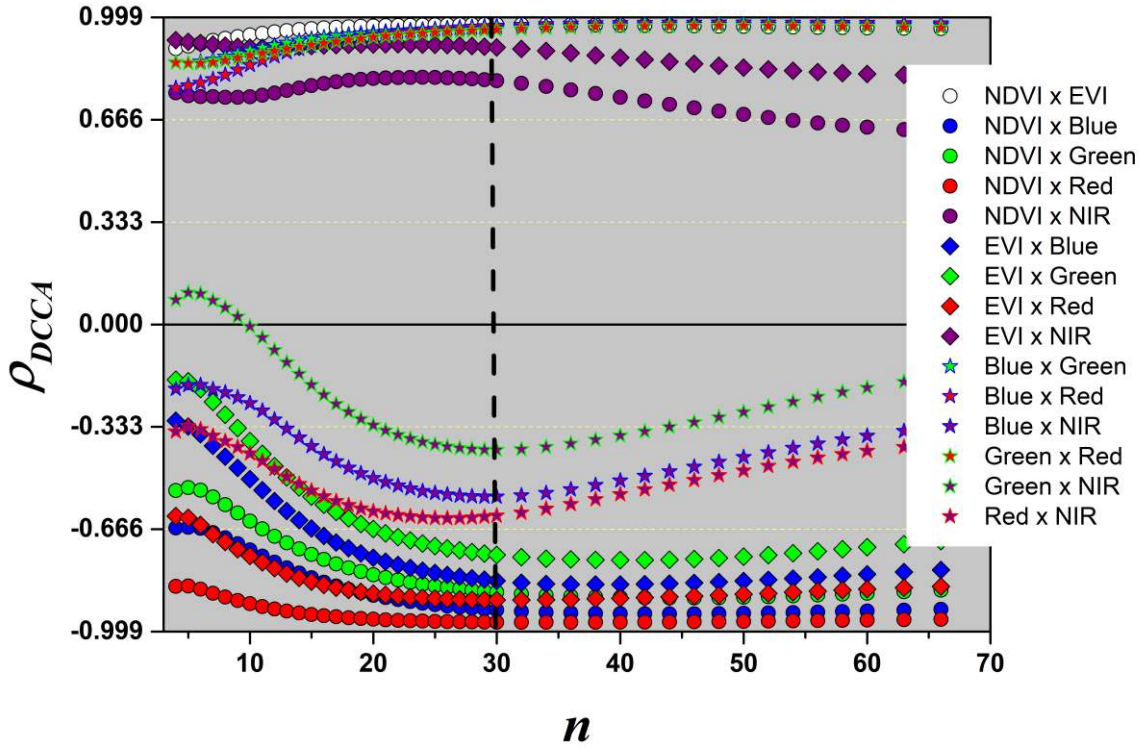

Fonte: Elaborado pelos autores (2020).

5. CONCLUSÕES

Sabendo da importância dos índices de vegetação NDVI e EVI, para o monitoramento da vegetação, na agricultura, no estudo climático, ou mesmo na gestão dos recursos hídricos. Inicialmente, são apresentados os referidos índices e as bandas espectrais como função do tempo, a partir de sensoriamento remoto (com suas sazonalidades) para uma importante área de proteção ambiental (APA de Pedra do Cavalo), onde geração de energia e segurança hídrica são fatores cruciais no que diz respeito o bem estar de milhões de habitantes.

Logo, neste primeiro momento, pôde-se observar que há nitidamente um efeito sazonal (na escala de meses) para todos os índices, um com maiores e outros com menores valores. Aqui, surge naturalmente o seguinte questionamento: qual é o valor sazonal e qual tipo de memória está associado a estas séries temporais? A resposta para estas questões foi dada pela aplicação do método **DFA** a todos os índices, que permitiu identificar a presença de autocorrelações persistente (em pequenas escalas temporais) e antipersistente (em grandes escalas temporais), divididas em torno de $n \cong 30$ (componente sazonal), onde há uma transição de comportamento da função de flutuação, F_{DFA}. O comportamento de F_{DFA} pode ser caracterizado pelo valor do expoente α_{DFA}, calculado aqui para cada índice e escala temporal, caracterizando assim, a natureza e o tipo de memória da série (veja quadro 1).

Fechando com os objetivos, também foi analisado como um índice se relaciona com o outro, através do coeficiente ρ_{DCCA}, mostrando que este coeficiente pode ser positivo, negativo e variando de fraca até forte correlação cruzada, a depender de sua escala temporal. O tratamento estatístico, via ρ_{DCCA}, permite analisar correlações cruzadas mesmo no caso em que as séreis temporais sejam não estacionárias (caso em que $\alpha_{DFA} > 1{,}0$), além de medir os níveis de correlações cruzadas em diferentes escalas temporais, detectando assim, padrões ocultos de interdependência entre todos os índices estudados (veja a Fig.4).

Finalmente, para a área onde está localizada a APA de Pedra do Cavalo, um completo mapeamento do ponto de vista das autocorrelações e correlações cruzadas foi feito, e o efeito de memória da série temporal e suas relações mútuas foram analisados. Aqui, foi mostrando ser possível fazer uma completa análise estatística com o método **DFA** e com ρ_{DCCA} , a partir de dados de sensoriamento remoto para uma importante porção da superfície da Terra, com um imenso valor no que tange a segurança hídrica. Além disso, a metodologia pode oferecer nova e sofisticada abordagem para desvendar as relações complexas entre os índices de vegetação e as variáveis climáticas (por exemplo), que seria particularmente útil na climatologia, no intuito de se compreender as interações entre vegetação e clima.

AGRADECIMENTOS

G. F. Zebende agradece ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) (Grant 310136/2020-2).

REFERÊNCIAS

Algoritmo para o rho_DCCA [por] Gilney Zebende. [*S. l.: s. n*], 2021. 1 vídeo (29:31 min). Publicado pelo canal do PPGM UEFS. Disponível em: https://www.youtube.com/watch?v=RQL7Db74yG0. Acesso em: 20 ago. 2024.

ANSARI, S. *et al.* Standardized Drought Indices on Drought.Gov, Produced with Climate Engine and Google Earth Engine, from Multiple Foundational Precipitation and Temperature Datasets. Disponível em: https://ams.confex.com/ams/104ANNUAL/meetingapp.cgi/Paper/428427. Acesso em: 22 ago. 2024.

BRASIL. **Lei nº 6.902, de 27 de abril de 1981**. Disponível em: https://www.planalto.gov.br/ccivil_03/LEIS/L6902.htm. Acesso em: 20 ago. 2024.

BRASIL. **Lei nº 12.651, de 25 de maio de 2012**. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2011-2014/2012/lei/l12651.htm?itid=lk_inline_enhanced-template. Acesso em: 20 ago. 2024.

BRITO, A. A.; de ARAÚJO, H. A.; ZEBENDE, G. F. Detrended multiple cross-correlation coefficient applied to solar radiation, air temperature and relative humidity. **Scientific Reports**, v. 9, n. 1, 1-10, 2019.

CHEN, Z. *et al.* Effect of nonstationarities on detrended fluctuation analysis. **Physical Review E**, v. 65, n. 4, 041107, 2002.

DEERING, D. W. **Rangeland Reflectance Characteristics Measured by Aircraft and Spacecraft Sensors**. Dissertação—Texas A&M University, 1978.

FRAEDRICH, K.; BLENDER, R. Scaling of Atmosphere and Ocean Temperature Correlations in Observations and Climate Models. **Physical Review Letters**, v. 90, n. 10, 11 mar. 2003.

GARCÍA, L. *et al.* Construction of Linear Models for the Normalized Vegetation Index (NDVI) for Coffee Crops in Peru Based on Historical Atmospheric Variables from the Climate Engine Platform. **Atmosphere**, v. 15, n. 8, p. 923–923, 1 ago. 2024.

GONÇALVES, R. V. *et al*. Analysis of NDVI time series using cross-correlation and forecasting methods for monitoring sugarcane fields in Brazil. **International Journal of Remote Sensing**, v. 33, n. 15, p. 4653-4672, 2012.

GODWIN, P. *et al*. Detecting groundwater dependence and woody vegetation restoration with NDVI and moisture trend analyses in an Indonesian karst savanna. **Frontiers in Remote Sensing**, v. 5, p. 1280712, 2024.

GORELICK, N. *et al.* Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, dez. 2017.

GUO, E. *et al.* Temporal and spatial characteristics of extreme precipitation events in the Midwest of Jilin Province based on multifractal detrended fluctuation analysis method and copula functions. **Theoretical and Applied Climatology**, v. 130, n. 1-2, p. 597–607, 26 ago. 2016.

HENEGHAN, C.; MCDARBY, G. Establishing the relation between detrended fluctuation analysis and power spectral density analysis for stochastic processes. **Physical Review E**, v. 62, n. 5, p. 6103–6110, 1 nov. 2000.

HU, K. *et al.* Effect of trends on detrended fluctuation analysis. **Physical Review E**, v. 64, n. 1, 26 jun. 2001.

HUBER, P. J. **Robust Statistics**. Hoboken, NJ, USA: John Wiley & Sons, Inc., 1981.

HUETE, A. R.; JACKSON, R. D.; POST, D. F. Spectral response of a plant canopy with different soil backgrounds. **Remote Sensing of Environment**, v. 17, n. 1, p. 37–53, fev. 1985.

HUNTINGTON, J. L. *et al.* Climate Engine: Cloud Computing and Visualization of Climate and Remote Sensing Data for Advanced Natural Resource Monitoring and Process Understanding. **Bulletin of the American Meteorological Society**, v. 98, n. 11, p. 2397–2410, 1 nov. 2017. Disponível em: hhttp://journals.ametsoc.org/doi/abs/10.1175/BAMS-D-15-00324.1. Acesso em: 20 ago. 2024.

JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. **Preventive Veterinary Medicine**, v. 11, n. 3-4, p. 185–200, dez. 1991.

JIANG, Z.-Q.; ZHOU, W.-X. Multifractal detrending moving-average cross-correlation analysis. **Physical Review E**, v. 84, n. 1, 21 jul. 2011.

KIRÁLY, A.; JÁNOSI, I. M. Detrended fluctuation analysis of daily temperature records: Geographic dependence over Australia. **Meteorology and Atmospheric Physics**, v. 88, n. 3-4, p. 119–128, 28 out. 2004.

KOSCIELNY-BUNDE, E. *et al.* Indication of a Universal Persistence Law Governing Atmospheric Variability. **Physical Review Letters**, v. 81, n. 3, p. 729–732, 20 jul. 1998.

KRISTOUFEK, L. Measuring Correlations between non-stationary Series with DCCA Coefficient. **Physica A: Statistical Mechanics and Its Applications**, v. 402, p. 291–298, maio 2014.

LIU, H. Q.; HUETE, A. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. **IEEE Transactions on Geoscience and Remote Sensing**, v. 33, n. 2, p. 457–465, mar. 1995.

LIU, Q. *et al*. Characteristics of groundwater drought and its correlation with meteorological and agricultural drought over the North China Plain based on GRACE. **Ecological Indicators**, v. 161, p. 111925, 2024.

NKIAKA, E. *et al.* Quantifying the effects of climate and environmental changes on evapotranspiration variability in the Sahel. **Journal of Hydrology**, p. 131874–131874, 1 ago. 2024.

PENG, C.-K. *et al.* Mosaic Organization of DNA Nucleotides. **Physical Review E**, v. 49, n. 2, p. 1685–1689, 1 fev. 1994.

PODOBNIK, B. *et al.* Statistical Tests for Power-law Cross-correlated Processes. **Physical Review E**, v. 84, n. 6, 22 dez. 2011.

PODOBNIK, B.; STANLEY, H. E. Detrended Cross-Correlation Analysis: a New Method for Analyzing Two Nonstationary Time Series. **Physical Review Letters**, v. 100, n. 8, 27 fev. 2008.

SABY, L. *et al*. Sensitivity of Remotely Sensed Vegetation to Hydrologic Predictors across the Colorado River Basin, 2001–2019. **Journal of the American Water Resources Association** v. 58 (6): 1017–1029. https://doi.org/10.1111/1752-1688.12965, 2022. Acesso em: 12 dez. 2024.

UN-WATER. **What Is Water Security? UN-Water**. [s.l: s.n.]. Disponível em: https://www.unwater.org/sites/default/files/app/uploads/2017/05/unwater_poster_Oct2013.pdf. Acesso em: 20 ago. 2024.

VASSOLER, R. T.; ZEBENDE, G. F. DCCA cross-correlation coefficient apply in time series of air temperature and air relative humidity. **Physica A: Statistical Mechanics and Its Applications**, v. 391, n. 7, p. 2438–2443, abr. 2012.

WALLECZEK, J. *et al.* **Self-Organized Biological Dynamics and Nonlinear Control**. [s.l.] Cambridge University Press, 2000. p. 421–428

WANG, G.-J. *et al.* Random Matrix Theory Analysis of cross-correlations in the US Stock market: Evidence from Pearson's Correlation Coefficient and Detrended cross-correlation Coefficient. **Physica A: Statistical Mechanics and Its Applications**, v. 392, n. 17, p. 3715–3730, set. 2013.

ZEBENDE, G. F. DCCA cross-correlation coefficient: Quantifying Level of cross-correlation. **Physica A: Statistical Mechanics and Its Applications**, v. 390, n. 4, p. 614–618, fev. 2011.

ZEBENDE, G. F.; FERNANDEZ, B. F.; PEREIRA, M. G. Analysis of the Variability in the sdB Star KIC 10670103: DFA Approach. **Monthly Notices of the Royal Astronomical Society**, v. 464, n. 3, p. 2638–2642, 12 out. 2016.

ZEBENDE, G. F. *et al.* rho_DCCA Applied between Air Temperature and Relative humidity: An hour/hour View. **Physica A: Statistical Mechanics and Its Applications**, v. 494, p. 17–26, 1 mar. 2018.

ZEBENDE, G. F. *et al.* UMA VISÃO HORA A HORA DA AUTOCORRELAÇÃO EM DADOS DE TEMPERATURA E UMIDADE RELATIVA DO AR NA BAHIA. **Revista Brasileira de Climatologia**, v. 29, p. 99–112, 2021.