



CORREÇÃO DE VIÉS EM PREVISÃO CLIMÁTICA GLOBAL DA TEMPERATURA DA SUPERFÍCIE DO MAR POR MEIO DE FILTROS ADAPTATIVOS NO DOMÍNIO DA FREQUÊNCIA

*Bias correction in global climate forecasting of sea surface
temperature using adaptive filters in the frequency domain*

*Corrección de sesgo en la previsión climática global de la
temperatura de la superficie del mar mediante filtros
adaptativos en el dominio de la frecuencia*

Hugo Hinostroza Farfán  

Universidade do Estado do Rio de Janeiro
hf.lhugo1@gmail.com

Michel Pompeu Tcheou  

Universidade do Estado do Rio de Janeiro
mtcheou@uerj.br

Lisandro Lovisolo  

Universidade do Estado do Rio de Janeiro
lisandro@uerj.br

Sin Chan Chou  

Instituto Nacional de Pesquisas Espaciais
chou.chan@inpe.br

Jorge Luís Gomes  

Instituto Nacional de Pesquisas Espaciais
jorge.gomes@inpe.br

Paulo Nobre  

Instituto Nacional de Pesquisas Espaciais
paulo.nobre@inpe.br

Resumo: Este artigo aplica a correção de viés nas previsões de temperatura da superfície do mar (TSM) usando filtros adaptativos RLS (Recursive Least Squares). Consideram-se as previsões climáticas de TSM

produzidas pelo Modelo Brasileiro do Sistema Terrestre (BESM). A previsão da TSM é corrigida usando como referência, proxy de observação, os dados do ERA5 (ECMWF Reanalysis v5). Os filtros são aplicados nas séries temporais das previsões para uma célula da grade ou em coeficientes frequenciais obtidos via Transformada Cosseno Discreta bidimensional (DCT-2D) em uma região em torno da célula. São testados filtros de diferentes ordens e são consideradas regiões de diferentes tamanhos. A metodologia de correção é testada para o horizonte de 1 ano e ainda considera-se a correção por estações do ano, separadamente. Avalia-se o desempenho da correção da previsão da usando a Raiz do Erro Quadrático Médio e o Erro Absoluto Médio, comparando-se a abordagem proposta com as da filtragem adaptativa RLS no domínio do tempo e os ajustes de média e variância (CMV) nos domínios do tempo e na frequência, tendo em vista os ajustes nas escalas anual e sazonal. De modo geral, verificou-se que o método proposto apresenta uma capacidade de correção equivalente ao do método RLS e CMV no domínio do tempo, enquanto o ajuste via CMV no domínio da frequência não oferece bons resultados.

Palavras-chave: Modelos climáticos. Correção de previsões. Filtragem adaptativa. Algoritmo RLS.

Abstract: This article applies bias correction to sea surface temperature (SST) predictions using the Recursive Least Squares (RLS) adaptive filter method. We consider the climate predictions of SST produced by the Brazilian Earth System Model (BESM). The SST prediction is corrected using observation proxy data from ERA5 (ECMWF Reanalysis v5). The filters are applied to the prediction time series for the cell or to the frequency coefficients in a region around it obtained by means of the Discrete Cosine Transform in two dimensions (DCT-2D). Filters of different orders and different size for the region are tested. The correction methodology is tested for the one-year horizon or the seasons separately. The performance of the correction of the BESM SST prediction is evaluated using the Root Mean Squared Error and the Mean Absolute Error, comparing the proposed approach with adaptive RLS filtering in the time domain and the CMV (mean and variance adjustments) in both time and frequency domains, considering adjustments on annual and seasonal scales. In general, it was found that the proposed method presents a correction capability equivalent to that of the RLS and CMV methods in the time domain, while the adjustment via CMV in the frequency domain does not offer good results.

Keywords: Climate models. Forecast correction. Adaptive filtering. RLS algorithm.

Resumen: Este artículo aplica la corrección de sesgo en las predicciones de la temperatura de la superficie del mar (TSM) utilizando el método de filtros adaptativos RLS (Recursive Least Squares). Las predicciones climáticas de TSM son producidas por el Modelo Brasileño del Sistema Terrestre (BESM). La predicción de TSM se corrige utilizando como referencia un proxy de observación, los datos del ERA5 (ECMWF Reanalysis v5). Los filtros se aplican a las series de predicciones para cada celda o en los coeficientes frecuenciales obtenidos a través de la Transformada de Coseno Discreta bidimensional (DCT-2D) en una región alrededor de la celda. Se prueban filtros de diferentes órdenes y se consideran regiones de diferentes tamaños. La metodología de corrección se prueba considerando la serie anual y estaciones del año, por separado. Se evalúa el rendimiento de la corrección de la predicción de TSM prevista por BESM utilizando la Raíz del Error Cuadrático Medio y el Error Absoluto Medio, comparando el enfoque propuesto con el uso de filtrado adaptativo RLS en el dominio del tiempo y los ajustes de media y varianza (CMV) en los dominios del tiempo y la frecuencia, teniendo en cuenta los ajustes en las escalas anual y estacional. En general, se encontró que el método propuesto presenta una capacidad de corrección equivalente a la del método RLS y CMV en el dominio del tiempo, mientras que el ajuste mediante CMV en el dominio de la frecuencia no ofrece buenos resultados.

Palabras clave: Modelos climáticos. Corrección de Pronósticos. Filtrado adaptativo. Algoritmo RLS.

Submetido em: 19/04/2023

Aceito para publicação em: 10/07/2024

Publicado em: 12/07/2024



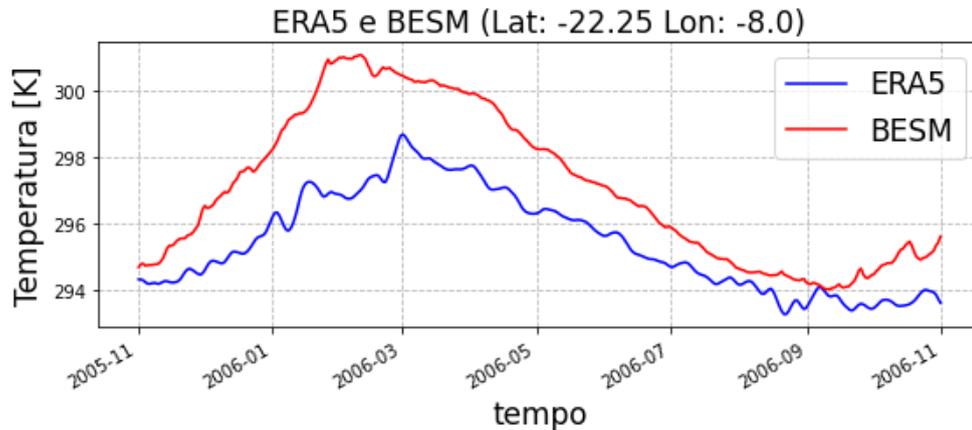
1. INTRODUÇÃO

O Clima está associado ao estado médio de condições meteorológicas em uma região ou um ponto da Terra (SAMPAIO; DA SILVA DIAS, 2014). Nas últimas décadas, o monitoramento meteorológico e o desenvolvimento de modelos de previsão de tempo e clima têm desempenhado papéis importantes para a tomada de decisões cotidianas e de longo prazo. Hoje em dia, prever o clima é de extrema importância para planejamento e desenvolvimento sustentável – tanto em escala local quanto global. Consequentemente, tem se utilizado modelos físico-matemáticos para reproduzir a dinâmica do sistema climático para um determinado período futuro (YNOUE et al., 2017).

O Brazilian Earth System Model (BESM) é um modelo global desenvolvido pelo Instituto Nacional de Pesquisas Espaciais (INPE) para estudo do clima (NOBRE et al., 2013). Tal modelo fornece uma sequência de valores temporais de variáveis climáticas em uma grade global contendo células na atmosfera e nos oceanos em função da latitude, longitude e altitude, isto é, fornece valores volumétricos a intervalos temporais. O BESM foi empregado para estudos de mudanças climáticas seguindo o protocolo do projeto CMIP5 (TAYLOR et al., 2012) e mostrou-se capaz de reproduzir temperatura, precipitação e padrões atmosféricos comparáveis com os demais modelos de sua categoria (VEIGA et al., 2019, p. 1620, CAPISTRANO et al., 2020).

A variável temperatura da superfície do mar (TSM) é crucial para a previsibilidade climática na região tropical (SHUKLA, 1998). Em (VEIGA et al., 2019), mostrou-se que o BESM apresenta, em geral, viés positivo nas simulações históricas da TSM. Este viés é confirmado em um ponto do Atlântico Sul (Figura 1) em previsão de um ano quando comparado com os dados de reanálise ERA5, produzidos pelo European Centre for Medium-Range Weather Forecasts (ECMWF). Uma reanálise climática fornece uma descrição numérica do clima recente (CENTRO EUROPEU DE PREVISÕES METEOROLÓGICAS A MÉDIO PRAZO, 2022), o ERA5 corresponde à quinta geração em reanálise atmosférica do clima global desenvolvida pelo ECMWF (HERSBACH et al., 2020) e fornece parâmetros atmosféricos na superfície terrestre e do estado do mar mais acurados.

Figura 1 -Série temporal anual, de 2005-11-01 a 2006-10-31, da Temperatura da Superfície do Mar fornecida pelo ERA5 e pelo BESM, na posição 22.25 S, 8.00 W.



Este trabalho tem por objetivo reduzir o viés da temperatura da superfície do mar prevista pelo modelo BESM, com ênfase na região do Atlântico Tropical Sul. O emprego de ferramentas externas que aprendam modelos para processar a previsão visando melhorar a acurácia pode ser uma alternativa para, ao menos, reduzir erros extremos. Por exemplo, em (BEZERRA et al., 2008), utiliza-se uma técnica de pós-processamento e aplica-se para corrigir estatisticamente as previsões de precipitação geradas pelos modelos climáticos numéricos disponíveis no INPE através de regressão linear. Recentemente, métodos de aprendizado de máquina têm sido aplicados. Em (ÁVILA et al., 2009), aplicam-se técnicas de correção estatística visando remover erros sistemáticos e aumentar a acurácia da previsão. Por outro lado, (FREITAS et al., 2015; PINTO et al., 2018; TCHEOU et al., 2021) abordam o uso de filtros adaptativos para esse fim.

Este trabalho estende as propostas em (FREITAS et al., 2015; PINTO et al., 2018; TCHEOU et al., 2021) que reduzem desvios de previsão climática usando filtros adaptativos. Tais abordagens aplicam o filtro RLS para corrigir diretamente a série temporal da previsão climática. Neste trabalho, consideramos a aplicação de filtros adaptativos Recursive Least Squares (RLS) no domínio da frequência e no tempo para reduzir os erros de previsão. Propomos a correção dos coeficientes da Transformada Cosseno Discreta em duas dimensões (DCT-2D) do bloco/região em torno da célula. A proposta é testada para a correção da previsão da TSM prevista pelo BESM, empregando as séries providas pelo ERA5 como referência. Obtêm-se as séries DCT-2Ds dos blocos da previsão nos diferentes dias e treina-se o filtro RLS para ajustar os coeficientes da DCT-2D da previsão do BESM. O filtro empregado para corrigir

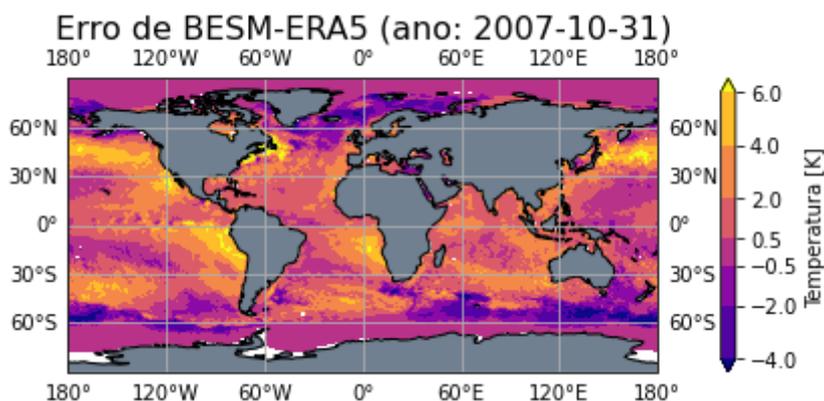
a previsão do ano é treinado usando os dados (previsão e reanálise do ano anterior). Usamos diferentes métricas de distorção para avaliar a efetividade de tal proposta para reduzir as amplitudes dos erros da previsão BESM relativamente ao ERA5.

2. MATERIAIS E MÉTODOS

2.1. Conjuntos de Dados

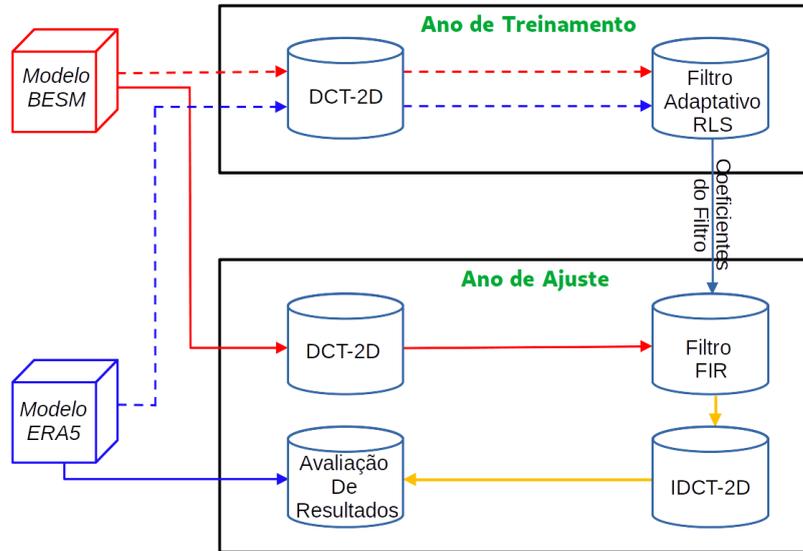
A Figura 2 apresenta o erro da TSM no dia 31/10/2007. Por considerarmos a TSM, as regiões de interesse para este trabalho estão limitadas ao mar, ignorando-se os continentes do globo (sombreado cinza da Figura 2).

Figura 2 -Erro da Temperatura da Superfície do Mar (TSM) prevista pelo BESM, em relação ao ERA5. Os continentes (região sombreada) são excluídos das análises.



Com o objetivo de reduzir os erros de previsão do modelo BESM, em relação ao ERA5, aplica-se um filtro FIR (Finite Impulse Response) com coeficientes obtidos adaptativamente (por treinamento). A Figura 3 apresenta a metodologia empregada. No “Ano de Treinamento”, o filtro é obtido a partir dos erros de previsão em um ano anterior ao de ajuste (usamos os dados de um ano antes). O filtro obtido é empregado para corrigir a previsão para o “Ano de Ajuste”. Consideramos dados do BESM e do ERA5 temporal e espacialmente alinhados.

Figura 3 -Esquema de ajuste/correção das previsões climáticas da TSM do BESM, tendo ERA5 como referência, através de filtros adaptativos no domínio da frequência.



Obtêm-se os componentes (DCT-2D) dos modelos BESM e ERA5 em cada dia. O filtro FIR é obtido por meio do algoritmo adaptativo RLS (Recursive Least-Square) (DINIZ, 2013; HAYKIN, 2008) considerando a sequência temporal de cada coeficiente DCT na região em torno de cada célula/pixel. Na sequência de coeficientes DCT do ano de ajuste, aplicam-se os filtros. Aplicando a transformada inversa, a IDCT-2D, à série corrigida (na saída do filtro), volta-se ao domínio original da variável prognóstica.

Para avaliar a eficácia da correção, compara-se os erros entre as sequências temporais da variável prognóstica do BESM e os valores fornecidos pela reanálise do ERA5, antes e após a metodologia de correção proposta, verificando se ela é capaz de melhorar a acurácia da previsão.

2.2. Análise Espectral Bidimensional

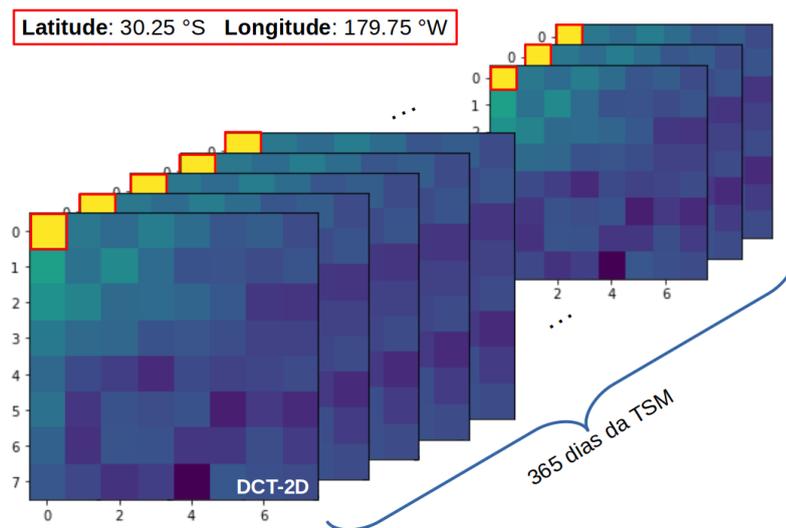
A DCT-2D obtém a representação de uma matriz numa base de cossenos bidimensionais de diferentes frequências. Cada elemento da DCT-2D de uma matriz mede o quanto há do padrão bidimensional formado pelo produto do cosseno na direção horizontal por outro na vertical de frequências dependentes da posição (índices na matriz) do elemento. Assim, a DCT-2D de um bloco de valores da variável prognóstica fornece uma análise espectral (em frequência) ou dos modos presentes no bloco (AHMED et al., 1974; JAIN, 1989). Para



blocos suaves, isto é, cujos valores dos pixels variam lentamente – o que esperamos para variáveis climáticas, a maioria da informação significativa estará concentrada em poucos coeficientes da DCT-2D, correspondendo a poucas funções base (produtos de cossenos nas duas direções). Obtêm-se as DCT-2Ds dos blocos da variável prognóstica em cada dia da série, como exemplificado Figura 4. Se $x_{l,c}$ é o valor da variável prognóstica na célula de posição (l, c) , os elementos $b_{i,j}$ do bloco \mathbf{B} de $B \times B$ pixels em torno da célula (l, c) é dado por

$$(1) \quad b_{i,j} = x_{l+i-\lceil(B/2)\rceil-1, c+j-\lceil(B/2)\rceil-1}, \\ i = 0 \dots B - 1, \quad j = 0 \dots B - 1$$

Figura 4 -DCT-2D dos blocos de 8×8 pixels da variável TSM durante uma sequência de dias correspondentes a um ano.



2.3. Projeto de Filtros de Ajuste das Componentes Espectrais

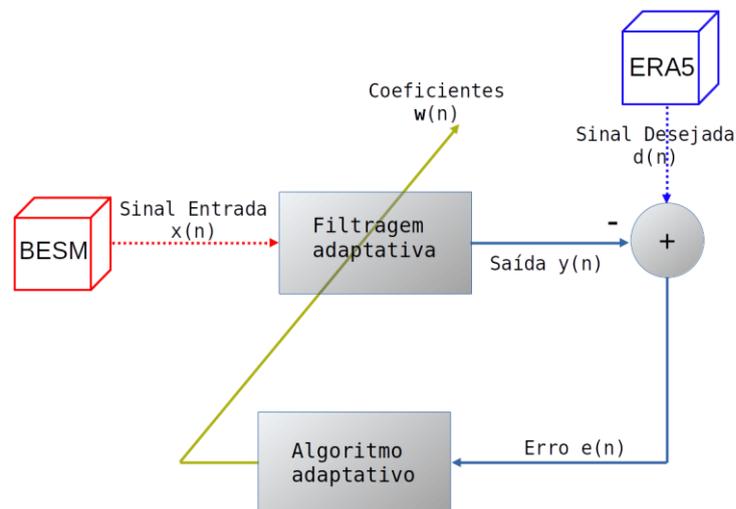
Genericamente, um filtro adaptativo atua como esquematizado na Figura 5. Nesse diagrama de blocos, n representa o índice da iteração, $d(n)$ é o sinal de referência/desejado, $x(n)$ é sinal de entrada, $w(n)$ é o vetor de coeficientes do filtro adaptativo, e $y(n)$ é a saída do filtro. Ela é comparada à amostra correspondente do sinal desejado $d(n)$, gerando o erro do sinal $e(n)$. O sinal de erro é usado para adaptar os coeficientes do filtro a cada iteração n , visando reduzir o erro $e(n)$ (DINIZ, 2013).

Para os propósitos deste trabalho, a sequência $x(n), n = 0, \dots, L$ é a série temporal dos valores do coeficiente na posição $(i, j), 0 \leq i, j \leq B$, do bloco transformado de uma dada região da variável predita (BESM), e $d(n)$ é o equivalente obtido a partir do ERA5. A saída do filtro $y(n)$ de comprimento $L + 1$ é

$$(2) \quad y(n) = \sum_{i=0}^L \omega_i(n)x(n-i) = \mathbf{w}^T(n)\tilde{\mathbf{x}}(n),$$

na qual, L é a ordem do filtro adaptativo, o vetor do sinal de entrada é $\mathbf{x}(n) = [x(n) \ x(n-1) \ x(n-2) \ \dots \ x(n-L)]^T$, e o vetor de coeficientes do filtro é $\mathbf{w}(n) = [w_0(n) \ w_1(n) \ \dots \ w_L(n)]^T$ e $.^T$ indica a transposição de \cdot . Em geral, na filtragem adaptativa, adota-se o erro quadrático médio (MSE-*Mean Squared Error*) como critério alvo do ajuste do filtro, isto é, ajustam-se os coeficientes do filtro para minimizá-lo (DINIZ, 2013). Nesse caso, o vetor de coeficientes ótimos ou o filtro ótimo é dado pela solução de Wiener $w_0 = \mathbf{R}^{-1}\mathbf{p}$, onde \mathbf{R} é a matriz de autocorrelação da sequência $x(n)$. Para obter w_0 é necessário calcular a inversa da matriz \mathbf{R} que pode não ter uma solução viável ou demandar alta complexidade computacional. Algoritmos adaptativos contornam essa dificuldade usando uma abordagem iterativa.

Figura 5 -Diagrama em blocos genérico para um sistema adaptativo.



Algoritmos de mínimos quadrados têm como objetivo minimizar a soma dos quadrados do sinal de erro (a diferença entre o sinal desejado e a saída do filtro). Essa solução pode ser obtida recursivamente, resultando na classe de algoritmos recursivos de mínimos



quadrados (RLS – *Recursive Least Squares*). Os coeficientes do filtro são atualizados a cada iteração visando a minimização do erro médio quadrático (GOODWIN, 1977; HAYKIN, 2008; DINIZ, 2013). A função objetivo é determinística é dada por

$$(3) \quad \xi(n) = \sum_{m=0}^n \lambda^{(n-m)} \epsilon^2(m) = \sum_{m=0}^n \lambda^{(n-m)} [d(m) - \mathbf{w}(n)\tilde{\mathbf{x}}(m)]^2,$$

na qual, $\epsilon(m)$ é o erro de saída a *posteriori* no instante m , e λ é o fator de aprendizado que deve ser escolhido no intervalo $0 \ll \lambda < 1$. O efeito deste fator decresce exponencialmente, provocando atenuação da influência de amostras passadas (esquecimento). O erro é computado após a atualização do vetor coeficiente do filtro e atualizado na função objetivo para o novo vetor de entrada. Para ajustar os coeficientes do filtro \mathbf{w} , a cada iteração (n) computam-se (DINIZ, 2013)

$$(4) \quad \begin{aligned} \mathbf{R}_D(n) &= \sum_{m=0}^n \lambda^{(n-m)} \tilde{\mathbf{x}}(m)\tilde{\mathbf{x}}^T(m) \\ \mathbf{p}_D(n) &= \sum_{m=0}^n \lambda^{(n-m)} \tilde{\mathbf{x}}(m)d(m), \\ \mathbf{w}(n) &= \mathbf{R}_D^{-1}(n)\mathbf{p}_D(n). \end{aligned}$$

O Algoritmo 1 traz o RLS, as grandezas $\mathbf{R}_D(n)$ e $\mathbf{p}_D(n)$ são chamadas de matriz de correlação determinística do sinal de entrada e vetor de correlação cruzada determinística entre os sinais de entrada e desejado, respectivamente. Por meio do lema da inversão de matriz (GOODWIN, 1977), é possível calcular a inversa de $\mathbf{R}_D(n)$ da seguinte forma

$$(5) \quad \begin{aligned} \mathbf{R}_D^{-1}(n) &= \mathbf{S}_D(n) = \\ &= \frac{1}{\lambda} \left[\mathbf{S}_D(n-1) - \frac{\mathbf{S}_D(n-1)\mathbf{x}(n)\mathbf{x}^T(n)\mathbf{S}_D(n-1)}{\lambda + \mathbf{S}_D(n-1)\mathbf{x}(n)\mathbf{x}^T(n)} \right] \end{aligned}$$

Com o objetivo de reduzir os erros de previsão do modelo BESM, aplica-se um filtro adaptativo RLS a cada um dos coeficientes da DCT-2D do bloco em torno da célula de previsão. Isto é, para cada elemento $b_{i,j}$ de \mathbf{B} , onde aplica-se um filtro distinto na dimensão temporal (a sequência da DCT-2D dos blocos em torno da célula alvo). Uma vez ajustados os coeficientes, reconstruem-se os blocos de variáveis prognósticas e obtém-se a sequência de valores prognósticos corrigida $\hat{v}_{l,c}(n)$ para a célula na posição (l, c) no período $0 \leq n < N - 1$.

Algoritmo 1 - Algoritmo RLS convencional.

Algoritmo 1: Algoritmo RLS convencional

Entrada: dados de BESM

```

1 início
2   se para  $n < 0$  então
3      $\mathbf{S}_D(-1) = \delta \mathbf{I}$   $\triangleright \delta$  pode ser o inverso de uma
      estimativa;
4      $\mathbf{x}(-1) = \mathbf{w}(-1) = [0 \ 0 \ \dots \ 0]^T$ 
5   senão
6      $\mathbf{S}_D(n) =$ 
       $\frac{1}{\lambda} \left[ \mathbf{S}_D(n-1) - \frac{\mathbf{S}_D(n-1)\mathbf{x}(n)\mathbf{x}^T(n)\mathbf{S}_D(n-1)}{\lambda + \mathbf{S}_D(n-1)\mathbf{x}(n)\mathbf{x}^T(n)} \right];$ 
7      $\mathbf{p}_D(n) = \lambda \mathbf{p}_D(n-1) + d(n)\mathbf{x}(n);$ 
8      $\mathbf{w}(n) = \mathbf{S}_D(n)\mathbf{p}_D(n);$ 
9      $y(n) = \mathbf{w}^T(n)\mathbf{x}(n);$ 
10     $e(n) = d(n) - y(n)$ 
11  fim
12 fim
```

3. METODOLOGIA EXPERIMENTAL

3.1. Procedimentos Metodológicos

Aplicamos a metodologia na correção da variável prognóstica TSM em graus Kelvin (K) do BESM tomando como referência o ERA5, alinhados temporal e espacialmente. Apresentamos resultados para o período compreendido entre 01 de Novembro de 2006 às 12 h e 31 de Outubro de 2007 até às 12 h (um ano). Assim, o treinamento dos filtros emprega o período entre 2005-11-01 e 2006-10-31; e, corrigem-se as previsões para o período de 2006-11-01 a 2007-10-31 (ano seguinte do treinamento). Dadas as variações de clima ao longo do ano, consideramos também a correção de previsões por trimestres (Novembro/Dezembro/Janeiro, Fevereiro/Março/Abril, Maio/Junho/Julho e Agosto/Setembro/Outubro) que correspondem às estações do ano de verão, outono, inverno e primavera, respectivamente. Cada trimestre tem entre 90 e 93 dias. A metodologia é aplicada usando a série anual completa ou dividida por estações, obtendo assim um ou quatro filtros por coeficiente DCT para a correção da previsão.

Os filtros são projetados para os pixels ao qual aplica-se a metodologia de correção. Os pixels escolhidos aleatoriamente no globo (na superfície do mar) são os mesmos para BESM e ERA5. O bloco para a análise espectral é definido a partir das coordenadas do pixel sorteado. Aplicamos a metodologia usando blocos de 32×32 , 16×16 e 8×8 pixels para o cômputo da



DCT-2D em torno da célula que desejamos corrigir.

3.2. Critérios de Avaliação

Avaliamos a qualidade da previsão no domínio do tempo (o domínio em que ela é produzida e disponibilizada). O erro original da previsão na célula (l, c) no n -ésimo dia é

$$(6) \quad e_{l,c}(n) = x_{l,c}(n) - d_{l,c}(n)$$

onde $d_{l,c}(n)$ é o valor da célula advindo do ERA5 e $x_{l,c}(n)$, o do BESM. Comparamos esse erro com o resultante da correção,

$$(7) \quad \hat{e}_{l,c}(n) = \hat{x}_{l,c}(n) - d_{l,c}(n)$$

na qual, $\hat{x}_{l,c}(n)$ é o valor ajustado (filtrado) da variável prognóstica conforme descrito nas seções anteriores. Para cada célula, obtemos o erro absoluto máximo (MAE – *Maximum Absolute Error*),

$$(8) \quad \text{MAE}_{l,c} = \max_n |e_{l,c}(n)|$$

o MAE percentual (PMAE),

$$(9) \quad \text{PMAE}_{l,c} = 100\% \max_n \left| \frac{e_{l,c}(n)}{d_{l,c}(n)} \right|$$

e, ainda, o erro médio quadrático (MSE–Mean Squared Error)

$$(10) \quad \text{MSE}_{l,c} = \overline{e_{l,c}^2} = \frac{1}{N} \sum_{n=1}^N e_{l,c}^2(n)$$

antes e após a correção (para $e_{l,c}(n) = \hat{e}_{l,c}(n)$) proposta visando avaliar se há ou não melhorias.

Para avaliar o desempenho dos diferentes métodos de correção de viés empregados, computam-se, inicialmente, as métricas de MSE, MAE e PMAE entre as previsões do BESM e os dados de reanálise do ERA5. Em seguida, calculam-se essas mesmas métricas entre as previsões corrigidas do BESM e os dados do ERA5. Por fim, verifica-se se as previsões corrigidas resultam em erros menores ou maiores em relação aos dados do ERA5, quando comparados aos erros entre BESM e ERA5. Nesse caso, quando os erros são menores, rotula-se o emprego do método de correção como “melhor”, do contrário, como “pior”.

3.3. Configuração do Filtro Adaptativo

Os fatores de esquecimento utilizados são $\lambda = 0,98$ e $\lambda = 0,99$. Este último reduz mais o erro de previsão no ano de ajuste, em outras palavras obtém um melhor filtro (\mathbf{w}) no ano de treinamento. O λ está incorporado na matriz de correlação determinística do sinal de entrada ($\mathbf{R}_D(n)$) e o vetor de correlação cruzada determinística ($\mathbf{p}_D(n)$). As sequências temporais empregadas no ano de treinamento do filtro adaptativo são repetidas 10 vezes tanto no treinamento de filtros de aplicação anual como nos de por estação, a fim de favorecer a convergência do algoritmo de adaptação.

Empregamos a autocorrelação $R_w(l)$ do módulo do filtro ótimo $||\mathbf{w}_n||$

$$(11) \quad R_w(l) = \frac{1}{N} \sum_{n=1}^N ||\mathbf{w}_n|| ||\mathbf{w}_{n-l}||$$

para avaliar as flutuações e periodicidade do processo de adaptação do filtro.

3.4. Método de Correção de Média e Variância

Usamos os critérios acima para avaliar se a metodologia proposta é efetiva na melhoria da acurácia da variável climática TSM do BESM, relativamente ao ERA5. Entretanto, de forma a avaliar a adequação da proposta, devemos compará-la com outros métodos. Por exemplo, o ajuste diretamente no domínio temporal; quando obtêm-se os filtros de ajuste diretamente no domínio da variável prognóstica sem realizar a análise espectral. Outro ajuste simples que não pode ser ignorado na avaliação é a correção de média e variância, denominado aqui como CMV. Sejam μ_X e σ_X a média e a variância da série BESM $x_{l,c}(n)$, $n = 1 \dots N$, e μ_D e σ_D a as da série $d_{l,c}(n)$ (do ERA). Então, corrige-se a sequência BESM via (eliminamos o subscrito da posição por simplicidade notacional)

$$(12) \quad \hat{x}(n) = (x(n) - \mu_X) \frac{\sigma_D}{\sigma_X} + \mu_D$$

Aplicamos tal correção nos valores das células no tempo e também no domínio transformado. No último caso, obtém-se a DCT, aplica-se o ajuste, e aplica-se a IDCT para obter a série ajustada. Desta forma, o método proposto é comparado com outras três abordagens que combinam o uso ou não da análise espectral com o ajuste via filtros adaptativos ou ajuste de média e variância da série.

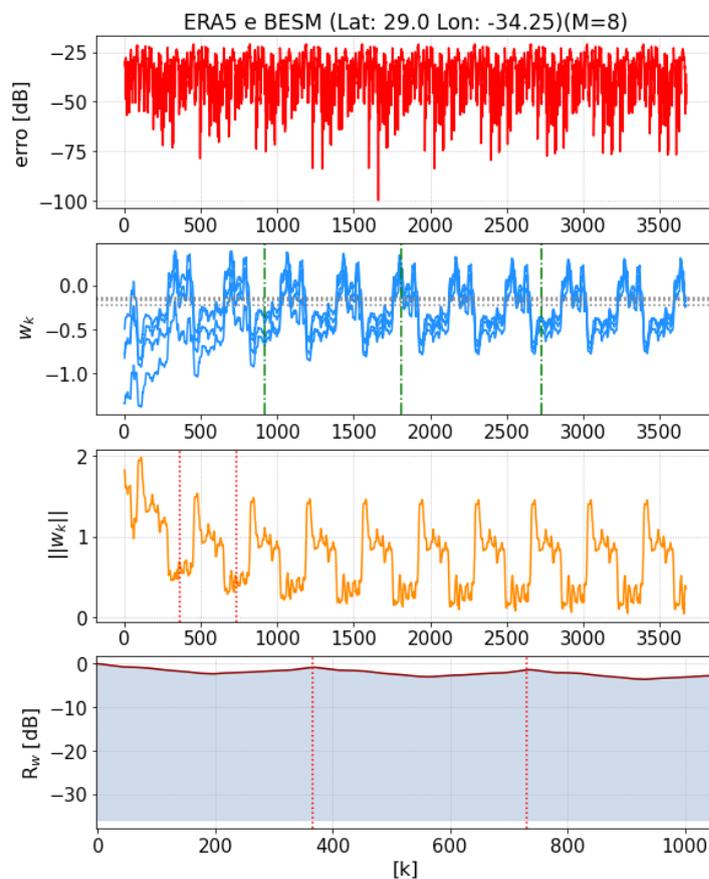


4. RESULTADOS

4.1. Treinamento do Filtro Adaptativo RLS

O processo de treinamento do filtro adaptativo de $L = 4$ coeficientes, empregando o algoritmo RLS com fator de esquecimento $\lambda = 0.99$, para uma célula localizada em $(-29.0; -34.25)$, (lat,lon), são apresentados na Figura 6.

Figura 6 -Comportamento do processo de convergência do algoritmo RLS aplicados a séries temporais de coeficientes DCT-2D, referente a região quadrada 8×8 centrada em (lat = 29.0; lon = -34.25).

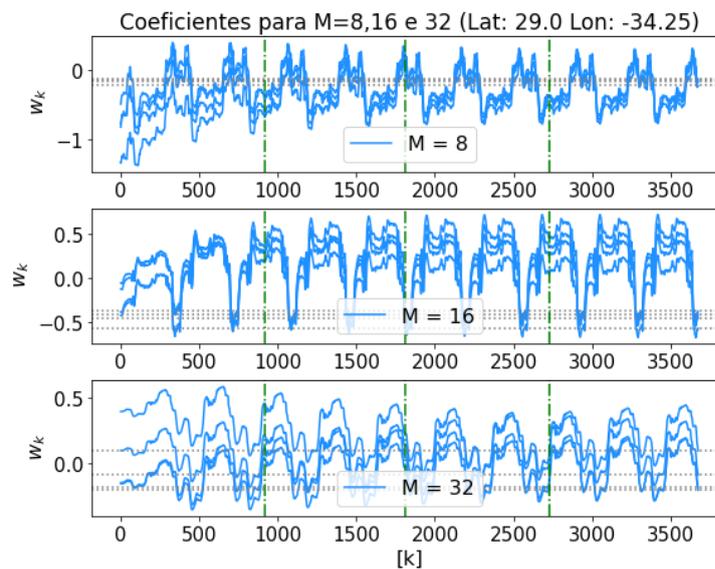


Na Figura 6, observam-se, de cima para baixo, o sinal de erro obtido subtraindo-se o sinal de saída do filtro (BESM corrigido) do sinal de referência (ERA5), a evolução dos coeficientes do filtro com as iterações, do módulo do vetor de coeficientes e de sua autocorrelação. É importante mencionar que as séries utilizadas no treinamento advêm do período de novembro de 2007 a outubro de 2008. Nota-se que o erro se concentra em valores acima de -50 dB e os coeficientes w_k dos filtros não convergem para patamares fixos, posto

que o sinal de TSM apresenta um comportamento não estacionário ao longo do ano e das estações. O comportamento da norma dos coeficientes $\|\mathbf{w}_k\|$ ao longo das 10 repetições das seqüências de TSM anuais indica uma oscilação. Ademais, por meio da função de autocorrelação da norma (as linhas vermelhas tracejadas indicam os inícios da primeira e segunda repetições anuais) é possível observar que uma flutuação lenta intra-anual da energia dos coeficientes.

Na Figura 7, observam-se os comportamentos de convergência dos $L = 4$ coeficientes ao longo das iterações, para regiões quadradas de diferentes dimensões para $M = \{8, 16, 32\}$. Observa-se que quanto maior o valor de M , a convergência se torna mais suave e os ciclos temporais mais bem definidos. Quanto maior a região, maior é a capacidade do algoritmo de ajustar componentes de maiores comprimentos de onda.

Figura 7 - Comportamento do processo de convergência do algoritmo RLS aplicados a séries temporais de coeficientes DCT-2D, referente a regiões quadradas de dimensões 8×8 , 16×16 e 32×32 centradas em (lat = -29.0 ; lon = -34.25).

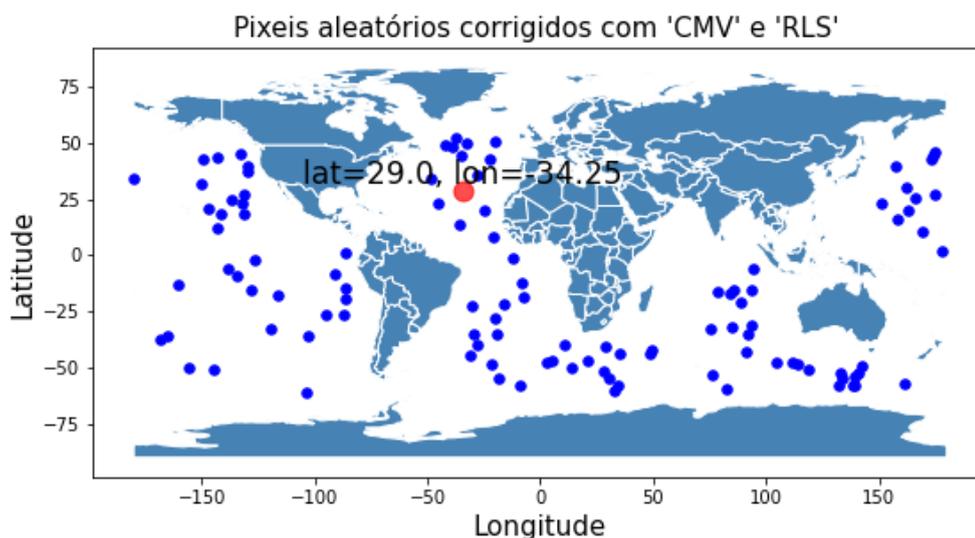


4.2. Correção de Viés da TSM

Neste trabalho, realiza-se a correção de viés da previsão da TSM do BESM em referência ao ERA5, nos domínios do tempo e da frequência por meio de Filtragem Adaptativa RLS (denominados de RLS_temp e RLS_freq) e do Método de Correção de Média e Variância (CMV_temp e CMV_freq). As previsões de TSM do BESM possuem duração anual com discretização temporal diária, e se iniciam em novembro de um ano específico e terminam em

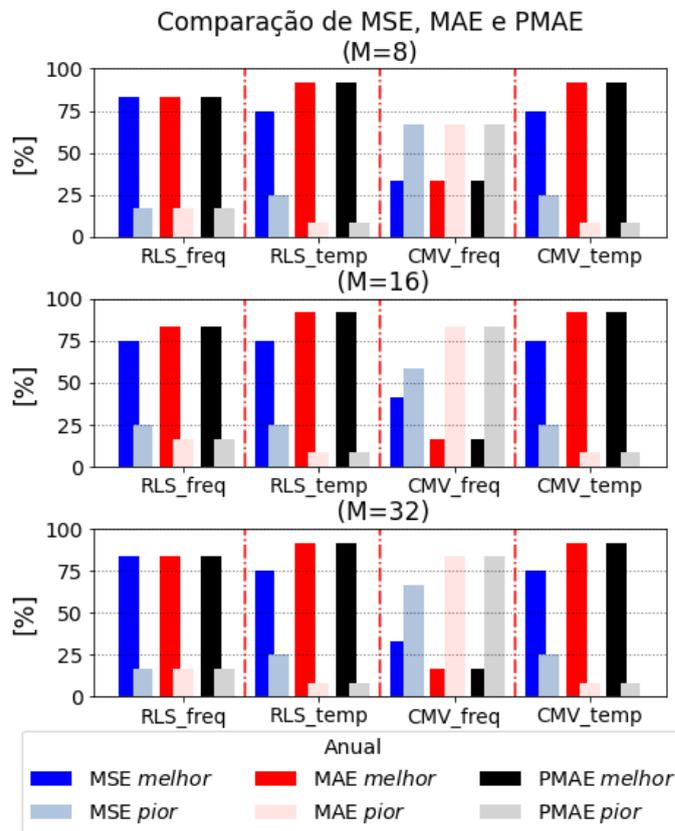
outubro do ano seguinte. Para avaliar a robustez das abordagens de correção de viés sem gerar um alto custo computacional, sorteia-se aleatoriamente $T=100$ pixels/células sobre o domínio marítimo do planeta. A Figura 8 apresenta um mapa com as indicações geográficas dos T pixels escolhidos aleatoriamente, avaliados neste trabalho. O pixel com marcação em vermelho, situado em latitude e longitude (29.0; -34.25), será avaliado especificamente em detalhes mais adiante. Nas abordagens de correção no domínio da frequência em que se aplica a DCT bidimensional considera-se a região quadrada $M \times M$ tendo o pixel escolhido como central.

Figura 8 - Pixels aleatoriamente selecionados para o emprego dos métodos de correção de viés baseados em RLS e CMV. O pixel vermelho é examinado em detalhes.



As Figuras 9 e 10 apresentam os percentuais referentes às ocorrências de redução (“melhor”) ou aumento (“pior”) de MSE, MAE e PMAE, quando comparado aos níveis de erro sistemático entre BESM e ERA5. A primeira figura corresponde ao desempenho de correção considerando um ano completo, e a segunda, ao desempenho de correção por estações. Observa-se que em ambas as correções, tanto anual quanto por estações, a estratégia CMV_freq apresenta o pior desempenho, provocando, na maioria dos casos, um aumento das medidas de erro em vez de redução.

Figura 9 - Percentuais de redução e aumento do erro da TSM para os diferentes métodos de correção, no caso de correção ANUAL.



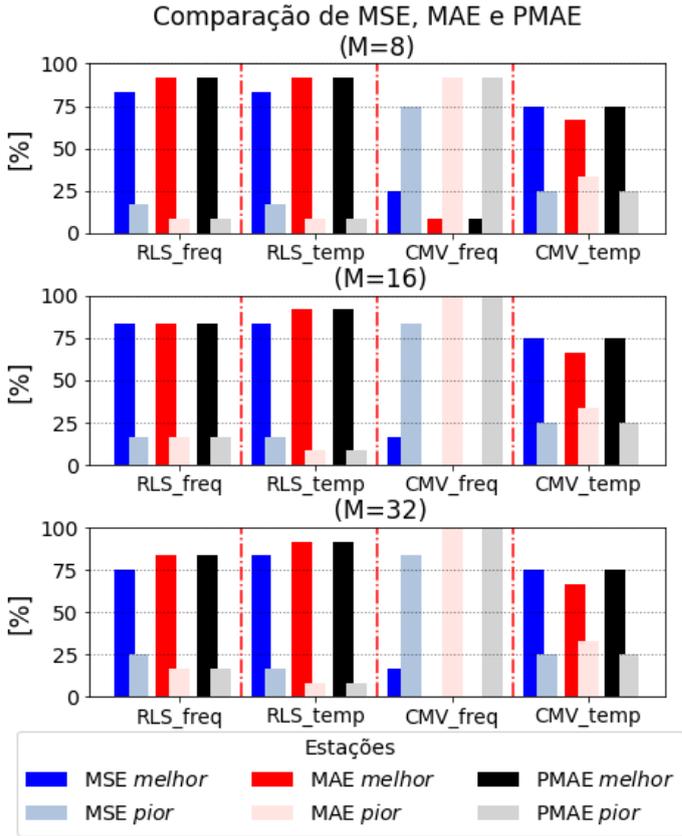
Já, as abordagens baseadas em RLS e o CMV_temp apresentaram desempenhos semelhantes na correção anual, enquanto que na correção por estações, as abordagens baseadas em RLS apresentaram desempenhos superiores ao CMV_temp, com percentuais de redução de erro acima de 75%. Note que nesses casos o percentual de redução de erro foi significativamente maior que o percentual de aumento. Verifica-se que somente o CMV_freq apresentou sensibilidade com relação à variação de M , diminuindo ainda mais o percentual de redução de erro com o aumento de M , tanto na correção anual quanto na por estações. As técnicas de correção de viés baseadas em RLS apresentam capacidades similares para a redução de erro sistemático entre o modelo BESM e os dados observacionais de TSM.

A seguir, avaliamos a correção da série temporal de TSM prevista pelo BESM para a célula localizada em (29.0;-34.25) indicada em vermelho no mapa da Figura 8. Na Figura 11, são apresentados os erros subtraindo-se o sinal de TSM do ERA5 do sinal BESM original ou corrigido. O gráfico superior traz o resultado da correção anual e, o de baixo, o da correção por estações. Nota-se que ao serem empregados, os métodos baseados em RLS promovem



erros mais próximos de zero ao longo da série, quando a correção é realizada por estações. O mesmo ocorre para o método CMV_temp, contudo, no caso de CMV_freq o ajuste é deficiente em ambas as correções, anual e por estações.

Figura 10 - Percentuais de redução e aumento do erro da TSM para os diferentes métodos de correção, no caso de correção POR ESTAÇÕES.



Na Figura 12, apresentam-se os erros resultantes da correção por meio do método RLS_freq, variando-se o tamanho da região $M = \{8, 6, 32\}$. Observa-se que neste caso o desempenho de correção é pouco sensível à variação de M tanto para o ajuste anual quanto para o ajuste por estações. Contudo, nota-se que, em torno do dia 200, o erro para blocos menores se afasta de zero, enquanto que, a partir do dia 300, o erro se aproxima de zero.

Figura 11 -Erros resultantes da correção da TSM produzida pelo BESM em relação ao dado observacional, corrigidas por ano e por estações.

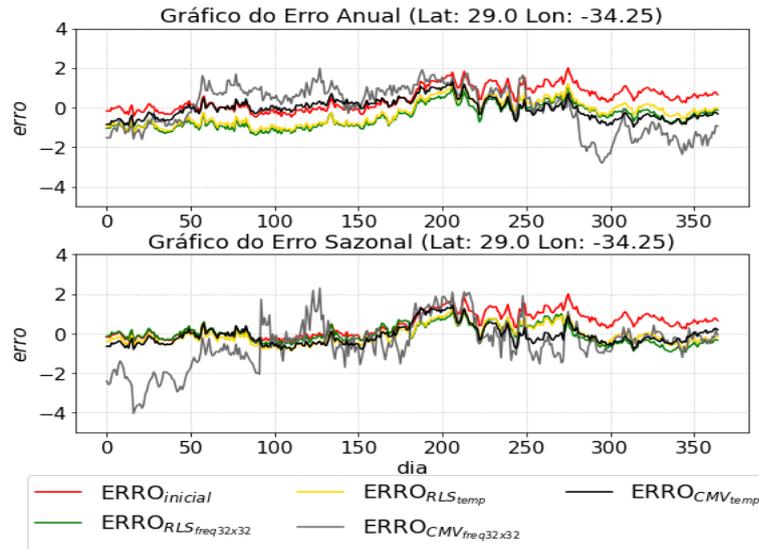
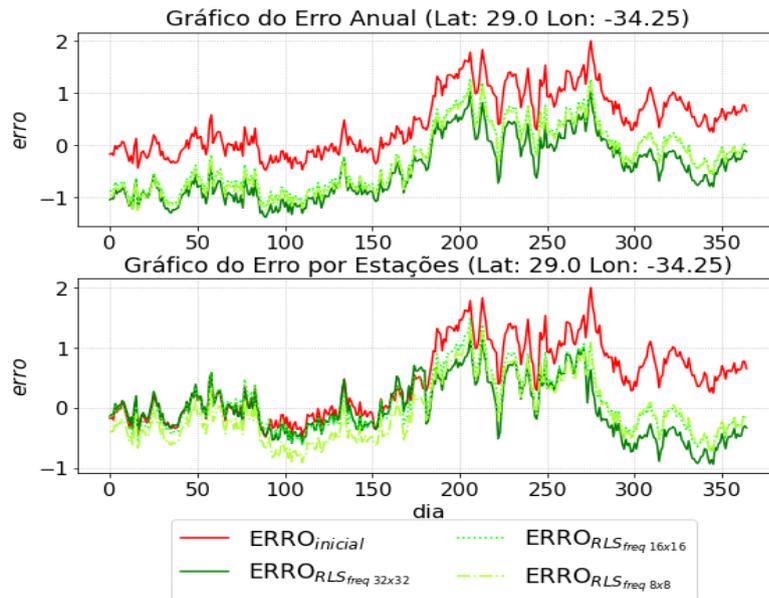


Figura 12 -Erros resultantes da correção da TSM produzida pelo BESM em relação ao dado observacional, corrigidas por ano e por estações por meio do método RLS_freq para $M = \{8, 6, 32\}$.

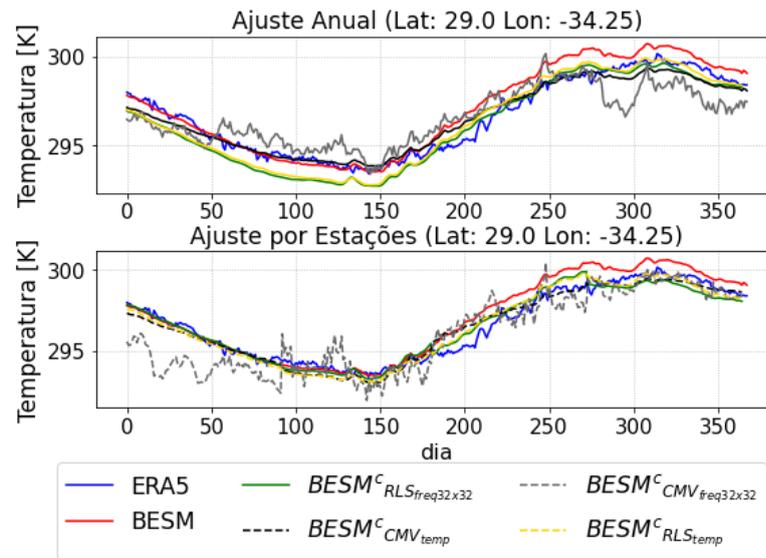


Na Figura 13, apresentam-se as séries temporais para a mesma célula (29.0;-34.25) produzidas pelo ERA5 e BESM, bem as decorrentes do ajuste de viés por meio dos algoritmos baseados em RLS e CMV nos domínios do tempo e da frequência. No ajuste anual, observa-se que o CMV_tmp resulta em uma melhor correção a partir do dia 50, já as técnicas baseadas em RLS aproximam melhor a série observacional a partir do dia 200. No ajuste por estações, os métodos RLS_temp, RLS_freq e CMV_temp induzem correções adequadas ao longo de todo



o período. Já o CMV_freq não é capaz de produzir uma versão adequada para a série, tanto no ajuste anual quanto no ajuste por estações.

Figura 13 -Correção anual e por estações da temperatura da superfície do mar por meio dos métodos RLS e CMV nos domínios do tempo e da frequência.



Na Figura 14, avalia-se o desempenho da correção pelo algoritmo RLS_freq para tamanhos de região variados. Nota-se que a variação de M provoca pouco impacto no desempenho da correção de viés.

A Figura 15 apresenta uma visão ampliada a cada três meses do gráfico inferior da Figura 13 referente à correção por estações. É importante lembrar que o modelo produz a previsão iniciando-se em novembro, nesse caso no ano de 2008. Observe que para os 6 primeiros meses, de novembro de 2008 a abril de 2009, o BESM produziu uma previsão bastante aderente ao ERA5. De maio em diante, período em que há um descolamento entre BESM e ERA5, os métodos de correção de viés, entre eles, RLS_temp, RLS_freq e CMV_temp, ajustam a previsão do BESM, tornando-a mais aderente ao ERA5. Na Figura 16, analisa-se o desempenho de correção de viés do RLS_freq a cada três meses para diferentes valores de M. Em geral, a variação de M apresenta pouca influência na capacidade de correção do RLS_freq, nota-se apenas um descolamento da série corrigida com M=32 no último trimestre da previsão Ago-Set-Out.

Figura 14 - Correção anual e por estações da temperatura da superfície do mar por meio do filtro adaptativo RLS no domínio da frequência (RLS_freq), variando-se o tamanho da região.

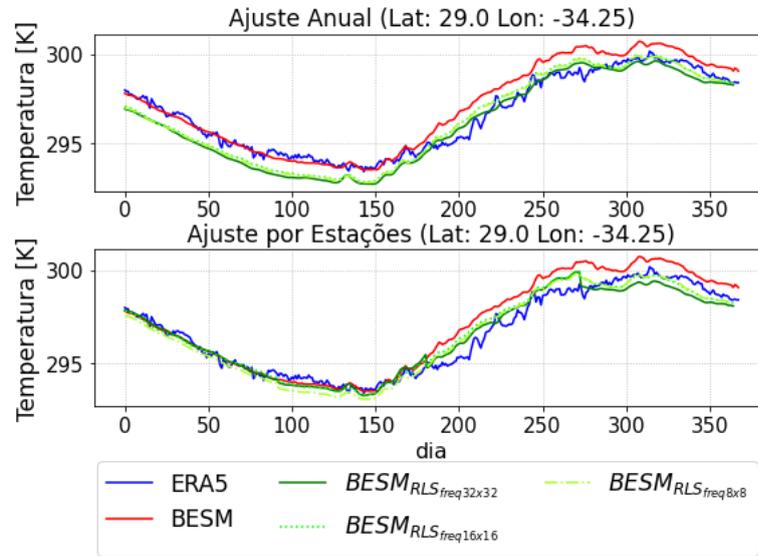
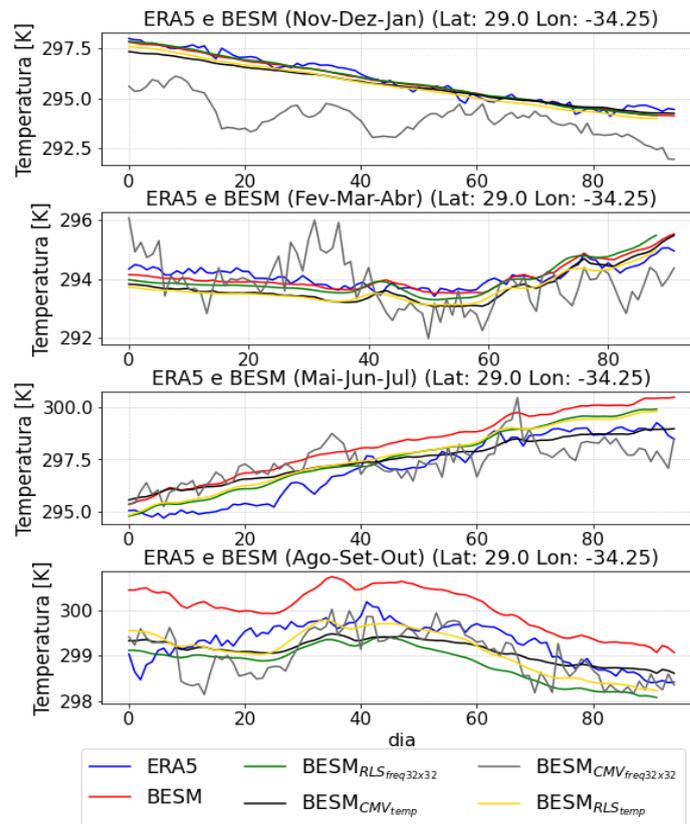


Figura 15 - Análise a cada três meses da correção por estações da TSM por meio de filtros RLS e CMV nos domínios do tempo e da frequência.





5. CONCLUSÕES

Neste trabalho, propôs-se a correção de viés das previsões de temperatura da superfície do mar do modelo BESM a partir do emprego de filtragem adaptativa RLS aplicada no domínio da frequência por meio da Transformada Discreta de Cosseno Bidimensional (DCT-2D).

A aplicação da correção no domínio da frequência visa ajustar possíveis erros de previsão em regiões em torno da quadrícula alvo/localização geográfica, enquanto a correção no domínio temporal diretamente não é capaz de avaliar esse comportamento. A correção de viés proposta foi aplicada nas séries horárias de previsões da temperatura da superfície do mar. As previsões são produzidas para o horizonte de um ano. Comparou-se o desempenho do método proposto com as da filtragem adaptativa RLS no domínio do tempo e os ajustes de média e variância (CMV) nos domínios do tempo e na frequência, considerando ajustes nas escalas anual e sazonal (por estações).

De modo geral, verificou-se que o método proposto apresenta uma capacidade de correção equivalente ao do método RLS e CMV no domínio do tempo, enquanto o ajuste via CMV no domínio da frequência não oferece bons resultados. Primeiramente, avaliaram-se as eficácias dos métodos em reduzir o erro entre a TSM prevista pelo BESM e observada (ERA5), por meio de diferentes métricas tais como MAE (Maximum Absolute Error) e MSE (Mean Squared Error). Verificou-se que o método proposto foi capaz de alcançar percentuais de redução de erro acima de 75%. Em seguida, analisou-se o desempenho de correção de viés, tendo em vista uma localização geográfica específica. Observou-se que, quanto maior o erro da previsão da TSM em relação aos dados observacionais, melhor é o desempenho do método de correção.

Observou-se ainda que os métodos baseados em RLS promovem erros menores, quando a correção é realizada por estações. Tal resultado possivelmente indica que os filtros corretores de viés devem ser adaptados/projetados por estação, o que pode derivar de desajustes distintos entre o BESM e o ERA5 para cada estação do ano, mas que não são capturados pelo método CMV simples. Além disso, observou-se que no primeiro semestre o BESM produz uma previsão de TSM bem aderente ao dado observacional, já no segundo semestre, o erro sistemático passa a ser mais evidente. Portanto, é nesse período em que os

métodos de correção de viés são mais eficientes e se sobressaem. Enfim, foi possível notar que a variação do tamanho da região considerada no cálculo da DCT-2D provoca pouco impacto no desempenho da correção de viés.

REFERÊNCIAS

ÁVILA, A.M.H. de; CARDOSO, A. de O.; PINTO, H.S. *Aplicação da correção estatística na previsão de tempo estendida, para três localidades da Região Sul*. In: Congresso BRASILEIRO DE AGROMETEOROLOGIA, 16., 2009, Belo Horizonte. **Anais [...]**. Belo Horizonte: Sociedade Brasileira de Agrometeorologia, 2009.

AHMED, N.; NATARAJAN, T.; RAO, K. R. Discrete cosine transform. **IEEE Transactions on Computers**, v. C-23, n. 1, p. 90-93, Jan. 1974.

BEZERRA, A.C.N.; PEZZI, L.P.; KAYANO, M.T. *Esquema Estatístico de Combinação e Correção de Previsões Climáticas-ECCOCLIM*. **Revista Brasileira de Meteorologia**, v. 23, n. 4, p. 347-359, 2008.

CAPISTRANO, V. B. et al. Assessing the performance of climate change simulation results from BESM-OA2.5 compared with a CMIP5 Model Ensemble. **Geoscientific Model Development**, v. 13, p. 2277-2296, 2020. DOI: <https://doi.org/10.5194/gmd-13-2277-2020>.

CENTRO EUROPEU DE PREVISÕES METEOROLÓGICAS A MÉDIO PRAZO. **Serviço de mudanças climáticas**. 2022. Disponível em: <<https://climate.copernicus.eu/climate-reanalysis>>. Acesso em: 29 jan. 2022.

DINIZ, P. S. R. **Adaptive filtering: algorithms and practical implementation**. Springer, 2013.

FREITAS, A. R.; TCHEOU, M. P.; LOVISOLO, L.; CHOU, S. C. Filtragem adaptativa para a redução de desvios em séries temporais de previsão numérica climática. In: SIMPÓSIO BRASILEIRO DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS, 28., 2015, Rio de Janeiro. **Anais [...]**. Rio de Janeiro: SBrT, 2015. p. 1-6.

GOODWIN, G. C. Dynamic system identification: experiment design and data analysis. **Mathematics in science and engineering**, v. 136. Academic press, 1977.

HAYKIN, S. **Adaptive filter theory**. Pearson, 2008.

HERSBACH, H., et al. The ERA5 global reanalysis. **QJR Meteorol Soc**, v. 146, p. 1999-2049, 2020. DOI: 10.1002/qj.3803.

JAIN, A. K. **Fundamentals of digital image processing**. Prentice-Hall, Inc., 1989.

NOBRE, P., et al. Climate Simulation and Change in the Brazilian Climate Model. **Journal of Climate**, v. 26, p. 6716-6732, 2013. DOI: 10.1175/JCLI-D-12-00580.1.

PINTO, L. F. G.; TCHEOU, M. P.; LOVISOLO, L.; CHOU, S. C. Redução de Desvios de Previsão Climática usando Filtragem Adaptativa no Domínio da Frequência. In: SIMPÓSIO BRASILEIRO

DE TELECOMUNICAÇÕES E PROCESSAMENTO DE SINAIS, 2018, Rio de Janeiro. **Anais [...]**. Rio de Janeiro, 2018.

SAMPAIO, G.; DA SILVA DIAS, P. L. Evolução dos Modelos Climáticos e de Previsão de Tempo e Clima. **Revista USP**, São Paulo, v.103, p. 41-54, 2014.

SHUKLA, J. Predictability in the Midst of Chaos: A Scientific Basis for Climate Forecasting. **Science**, v. 282, p. 728-731, 1998. DOI: 10.1126/science.282.5389.728.

TAYLOR, K. E.; STOUFFER, R. J.; MEEHL, G. A. An overview of CMIP5 and the experiment design. **B. Am. Meteorol. Soc.**, v. 93, p. 485-498, 2012. <https://doi.org/10.1175/BAMS-D-11-00094.1>

TCHEOU, M. P.; LOVISOLO, L.; FREITAS, A. R.; CHOU, S. C. Reducing Forecast Errors of a Regional Climate Model Using Adaptive Filters. **Applied Sciences**, v. 11, n. 17, p. 8001, 29 ago. 2021.

VEIGA, S. F., et al. The Brazilian Earth System Model ocean–atmosphere (BESM-OA) version 2.5: evaluation of its CMIP5 historical simulation. **Geoscientific Model Development**, 12(4), 2019, p. 1613-1642. <https://doi.org/10.5194/gmd-12-1613-2019>

YNOUE, Rita Yuri; REBOITA, M. S.; AMBRIZZI, T.; DA SILVA, G. A. M. **Meteorologia: Noções básicas**. São Paulo: Oficina de Textos, 2017.