



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Faculdade de Engenharia

Leandro Ferreira Gentile Pinto

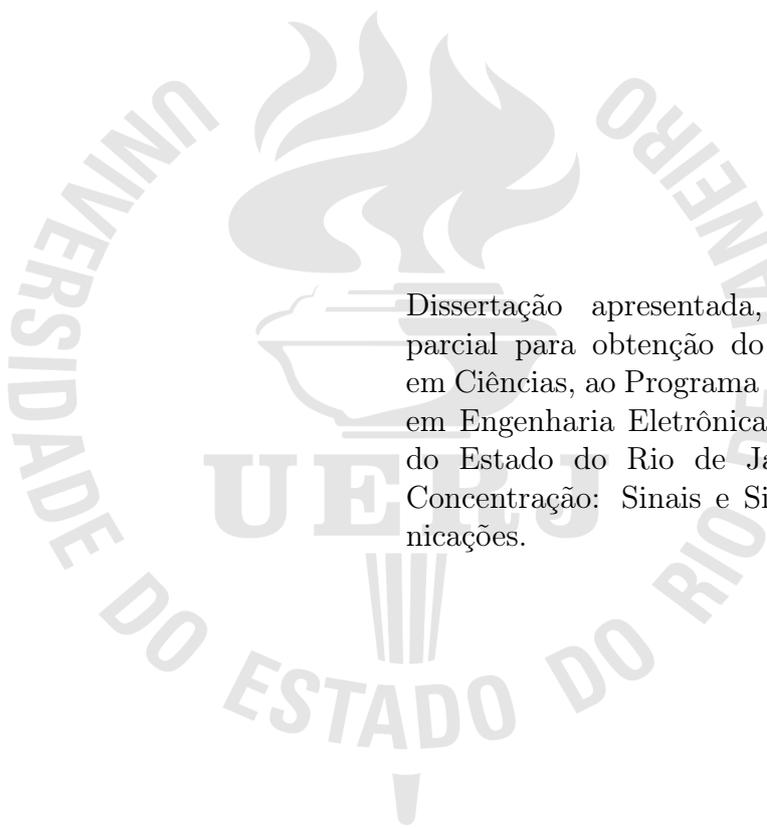
Filtragem adaptativa no domínio da frequência aplicada à  
redução de erros de previsão climática

Rio de Janeiro

2018

Leandro Ferreira Gentile Pinto

**Filtragem adaptativa no domínio da frequência aplicada à redução de erros  
de previsão climática**



Dissertação apresentada, como requisito parcial para obtenção do título de Mestre em Ciências, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de Concentração: Sinais e Sistemas de Comunicações.

Orientadores: Prof. Dr. Michel Pompeu Tcheou  
Prof. Dr. Lisandro Lovisolo

Rio de Janeiro

2018

CATALOGAÇÃO NA FONTE  
UERJ / REDE SIRIUS / BIBLIOTECA CTC/B

P659	<p>Pinto, Leandro Ferreira Gentile. Filtragem adaptativa no domínio da frequência aplicada à redução de erros de previsão climática / Leandro Ferreira Gentile Pinto – 2018. 177 f.</p> <p>Orientadores: Michel Pompeu Tcheou, Lisandro Lovisolo. Dissertação (Mestrado) – Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia.</p> <p>1. Engenharia eletrônica - Teses. 2. Filtros adaptativos - Teses. 3. Mudanças climáticas - Teses. 4. Algoritmos - Teses. 5. Processamento de sinais - Teses. I. Tcheou, Michel Pompeu. II. Lovisolo, Lisandro. III. Universidade do Estado do Rio de Janeiro, Faculdade de Engenharia. IV. Título.</p> <p>CDU 004.421:551.509</p>
------	--

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, desde que citada a fonte.

---

Assinatura

---

Data

Leandro Ferreira Gentile Pinto

**Filtragem adaptativa no domínio da frequência aplicada à redução de erros  
de previsão climática**

Dissertação apresentada, como requisito parcial para obtenção do título de Mestre em Ciências, ao Programa de Pós-Graduação em Engenharia Eletrônica, da Universidade do Estado do Rio de Janeiro. Área de Concentração: Sinais e Sistemas de Comunicações.

Aprovado em: 07 de Agosto de 2018.

Banca Examinadora:

---

Prof. Dr. Michel Pompeu Tcheou (Orientador)  
Faculdade de Engenharia - UERJ

---

Prof. Dr. Lisandro Lovisolo (Orientador)  
Faculdade de Engenharia - UERJ

---

Profa. Dra. Sin Chan Chou  
Instituto Nacional de Pesquisas Espaciais - INPE

---

Prof. Dr. Tadeu Nagashima Ferreira  
Universidade Federal Fluminense - UFF

Rio de Janeiro

2018

## DEDICATÓRIA

À minha amada Whana e aos meus pais Carmela e Hernani.

## AGRADECIMENTO

Agradeço primeiramente a Deus por me guiar nesta jornada de estudos e conhecimentos adquiridos.

Agradeço a minha amada Whana pelas palavras de amor e incentivo e por sempre acreditar na minha capacidade.

Agradeço aos meus pais Carmela e Hernani por me ensinarem que a educação é a base para a construção de uma sociedade mais justa.

Agradeço aos orientadores Michel Pompeu Tcheou e Lisandro Lovisolo, pela dedicação, paciência e críticas construtivas para a melhoria do meu desempenho durante o desenvolvimento da dissertação.

Agradeço a Dra. Sin Chan Chou pela ajuda e disponibilidade de recursos no CPTEC/INPE e também por esclarecer dúvidas com relação à área de meteorologia.

Agradeço aos colegas Adan Silva e Luis Felipe Alves, do CPTEC/INPE, pela ajuda na coleta de dados importantes para o trabalho e ao colega Alexandre Freitas, da UERJ, por esclarecer dúvidas em relação aos procedimentos iniciais dos testes experimentais da dissertação.

Agradeço aos meus amigos de mestrado Valmir Junior, Marco Netto e Leandro Ribeiro pela contribuição de ideias e conversas produtivas e casuais no Laboratório de Processamento de Sinais, Aplicações Inteligentes e Comunicações (PROSAICO).

Agradeço a todos os professores do Programa de Pós-Graduação em Engenharia Eletrônica que são instrumentos importantes para o avanço do conhecimento.

Agradeço ao PROSAICO por permitir realizar atividades experimentais deste trabalho e também agradeço à CAPES pelo suporte financeiro.

*A persistência é o caminho do êxito.*

Charles Chaplin

## RESUMO

PINTO, Leandro Ferreira Gentile. *Filtragem adaptativa no domínio da frequência aplicada à redução de erros de previsão climática*. 177 f. Dissertação (Mestrado em Engenharia Eletrônica) - Faculdade de Engenharia, Universidade do Estado do Rio de Janeiro (UERJ), Rio de Janeiro, 2018.

Este trabalho apresenta os resultados sobre o emprego de filtros adaptativos no domínio da frequência. Isso é feito utilizando o algoritmo RLS (*Recursive Least Squares*) e a DCT (Discrete Cosine Transform) bidimensional, respectivamente, com o objetivo de reduzir desvios em previsões climáticas. As diferenças entre as variáveis climáticas observadas na atmosfera e as previstas por um modelo numérico tendem a aumentar com o tempo da integração, devido a erros e simplificações nas equações. O modelo atmosférico regional Eta é utilizado pelo CPTEC/INPE para cálculos de previsão numérica climática, que contém erros. Esta dissertação adota o uso da filtragem adaptativa e técnicas de processamento digital de sinais e imagens para reduzir os erros das previsões climáticas do modelo Eta, de modo a aprimorar essas previsões. Os erros são calculados a partir dos dados das reanálises do NCEP. As variáveis climáticas utilizadas neste trabalho são as componentes zonal e meridional do vento, altura geopotencial e umidade específica, analisadas em vinte níveis de pressão atmosférica e na resolução espacial de 40 km. Os resultados experimentais indicam que os filtros adaptativos de ordem ( $N = 4$ ) conseguem reduzir os erros de previsão, que são avaliados usando o erro quadrático médio e o erro máximo.

Palavras-chave: Filtros adaptativos; DCT-2D; Algoritmo RLS; Previsões climáticas.

## ABSTRACT

PINTO, Leandro Ferreira Gentile. *Adaptive filtering in the frequency domain applied to the reduction of climate prediction errors*. 177 p. Dissertation (Master in Electronic Engineering) - Faculty of Engineering, State University of Rio de Janeiro (UERJ), Rio de Janeiro, 2018.

This work presents the results about the use of adaptive filters in the frequency domain. This is done using the RLS (Recursive Least Squares) algorithm and the two-dimensional DCT (Discrete Cosine Transform), respectively, with the objective to reduce deviations in climatic forecasts. The differences between the climatic variables observed in the atmosphere and those predicted by a numerical model tend to increase with the integration time due to errors and simplifications in the equations. The Eta regional atmospheric model is used by CPTEC / INPE for numerical climate prediction calculations, which contains errors. This dissertation adopts the use of adaptive filtering and digital signal and image processing techniques to reduce Eta model weather forecasts to improve these predictions. Errors are calculated from the NCEP reanalysis data. The climatic variables used in this work are the zonal and meridional components of the wind, geopotential height and specific humidity, analyzed in twenty atmospheric pressure levels and in the spatial resolution of 40 km. The experimental results indicate that the adaptive filters of order ( $N = 4$ ) are able to reduce the prediction errors, which are evaluated using the mean square error and the maximum error.

Keywords: Adaptive filters; DCT-2D; Algorithm RLS; Climatic forecasts.

## LISTA DE SIGLAS

INPE	Instituto Nacional de Pesquisas Espaciais
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
COLA	<i>Center for Ocean, Land and Atmosphere Studies</i>
MCGA	Modelo de Circulação Geral da Atmosfera
GFS	<i>Global Forecast System</i>
NOAA	<i>National Oceanic and Atmospheric Administration</i>
NCEP	<i>National Centers for Environmental Prediction</i>
CFSR	<i>Climate Forecast System Reanalysis</i>
MRF	<i>Medium Range Forecasting Model</i>
GFDL	<i>Geophysical Fluid Dynamics Laboratory</i>
DCT - 2D	<i>Two-Dimensional Discrete Cosine Transform</i>
IDCT - 2D	<i>Two-Dimensional Inverse Discrete Cosine Transform</i>
RLS	<i>Recursive Least Squares</i>
GrADS	<i>Grid Analysis and Display System</i>
NetCDF	<i>Network Common Data Format</i>
MSE	<i>Mean Square Error</i>

## SUMÁRIO

	<b>INTRODUÇÃO</b> .....	11
1	<b>MODELAGEM ATMOSFÉRICA</b> .....	17
1.1	<b>Modelo de Circulação Geral Atmosférico (MCGA)</b> .....	18
1.1.1	<u>Coordenada vertical sigma (<math>\sigma</math>)</u> .....	19
1.1.2	<u>Variáveis prognósticas e resolução espacial do MCGA</u> .....	20
1.1.3	<u>Condições iniciais e condições de contorno do MCGA</u> .....	20
1.2	<b>Modelo GFS (<i>Global Forecast System</i>)</b> .....	21
1.2.1	<u>Variáveis prognósticas e resolução espacial do GFS</u> .....	21
1.3	<b>Modelo Atmosférico Regional Eta</b> .....	21
1.3.1	<u>Coordenada vertical eta (<math>\eta</math>)</u> .....	22
1.3.2	<u>Variáveis prognósticas do modelo Eta</u> .....	23
1.3.3	<u>Grade E de Arakawa</u> .....	23
1.3.4	<u>Condições iniciais e condições de contorno do modelo Eta</u> .....	24
1.4	<b>Conjunto das reanálises do NCEP</b> .....	24
2	<b>METODOLOGIA</b> .....	26
2.1	<b>Metodologia proposta</b> .....	28
2.2	<b>Interpolação bidimensional</b> .....	29
2.3	<b>Decomposição espectral usando a Transformada Discreta do Coseno Bidimensional</b> .....	30
2.3.1	<u>Varredura Zig-Zag</u> .....	32
2.3.2	<u>Separação por regiões frequenciais</u> .....	33
2.4	<b>Filtragem adaptativa FIR através do algoritmo RLS</b> .....	34
2.4.1	<u>Filtragem adaptativa</u> .....	34
2.4.2	<u>Algoritmo RLS</u> .....	37
2.4.3	<u>Vetor de coeficientes ótimo</u> .....	41
3	<b>PROCEDIMENTOS EXPERIMENTAIS</b> .....	42
3.1	<b>Conjunto de dados</b> .....	42
3.1.1	<u>Agrupamento de dados no domínio espectral</u> .....	42

3.2	<b>Critérios de avaliação</b> .....	43
3.2.1	<u>MSE (<i>Mean Square Error</i>)</u> .....	44
3.2.2	<u>Erro máximo</u> .....	44
3.2.3	<u>Média do erro quadrático médio</u> .....	44
3.2.4	<u>Taxa de efetividade</u> .....	45
3.3	<b>Configurações do algoritmo RLS</b> .....	45
3.3.1	<u>Escolha da ordem do filtro adaptativo (<math>N</math>)</u> .....	46
3.3.2	<u>Escolha do fator de ponderação exponencial (<math>\lambda</math>)</u> .....	50
4	<b>RESULTADOS OBTIDOS</b> .....	54
4.1	<b>Componente meridional do vento</b> .....	54
4.2	<b>Componente zonal do vento</b> .....	61
4.3	<b>Altura geopotencial</b> .....	68
4.4	<b>Umidade específica</b> .....	73
4.5	<b>Análise agregada</b> .....	78
	<b>CONCLUSÃO</b> .....	81
	<b>REFERÊNCIAS</b> .....	83
	<b>ANEXO</b> .....	89

## INTRODUÇÃO

A previsão climática contribui para o desenvolvimento da humanidade através do estudo e análise das condições climáticas que influenciam diversos setores da sociedade, como a agricultura, a logística de transportes (exportação e importação), o consumo de energia elétrica, entre outros setores. A disponibilidade de previsões meteorológicas cada vez mais acuradas auxilia para uma maior prevenção dos danos decorrentes de extremos climáticos e amplia a capacidade de adequação de diversos setores econômicos às condições climáticas de seus interesses [1], [2], [3], [4].

Os modelos de previsão climática podem decompor a atmosfera em células (volumes), modelando numericamente as interações dos processos entre as células e avaliando a evolução do estado da atmosfera utilizando métodos numéricos. Esses modelos numéricos dependem de condições iniciais e, em alguns casos, de condições de contorno. As condições iniciais descrevem o estado observado na atmosfera e servem como um ponto de partida para o modelo. Modelos regionais necessitam das condições de contorno lateral. As condições de contorno são dados inseridos nas bordas do modelo, e a informação das bordas pode se propagar para o interior do domínio, onde o modelo é capaz de descrever eventos climatológicos de pequena escala [5], [6]. Os modelos de previsão têm desempenhos que podem variar conforme a estação do ano, a região, o horário inicial de integração, a resolução do modelo e também a quantidade de observações assimiladas pelas análises [6], [7], [8].

A grande variedade de modelos numéricos existentes [9], [10], [11] contribui para a implementação de uma previsão numérica climática. Nesta dissertação é abordado o modelo atmosférico regional Eta utilizado pelo CPTEC / INPE (Centro de Previsão de Tempo e Estudos Climáticos / Instituto Nacional de Pesquisas Espaciais). No CPTEC, o Eta objetiva em aumentar a resolução da previsão numérica climática do modelo de circulação geral atmosférico (MCGA) [12], [13]. A previsão climática tem como variáveis prognósticas: temperatura do ar, componentes zonal e meridional do vento, umidade específica, pressão à superfície, energia cinética turbulenta, umidade e temperatura do solo, água líquida ou gelo das nuvens [14], [15].

A versão operacional do modelo Eta utilizada neste trabalho possui resolução horizontal de 40 km, com previsões que se estendem até em quatro meses e meio e cobrem

a maior parte da superfície da América do Sul [14], [16].

O modelo regional Eta [14] utiliza como condição inicial os dados de análise do modelo GFS (*Global Forecast System*) [17], fornecidos pelo NCEP (*National Centers for Environmental Prediction*) dos EUA e como condições de contorno, as previsões do modelo de circulação geral atmosférico (MCGA) do CPTEC [6], [7], [14]. O NCEP fornece um conjunto de dados que representam com maior acurácia as condições climáticas observadas; tal conjunto de dados é chamado de reanálises do NCEP / CFSR (*Climate Forecast System Reanalysis*) [7], [18]. As reanálises do NCEP são um conjunto de dados meteorológicos, organizados numa grade de cobertura global representando o estado atmosférico mais próximo da observação.

O estado real da atmosfera e o previsto através de modelagem numérica tendem a apresentar diferenças, gerando erros, o que interfere na qualidade da previsão. Os erros podem ser definidos em dois tipos: i) erros devidos às aproximações físicas do modelo numérico e ii) erros nas condições iniciais, que aumentam com o tempo de integração do modelo, devido às não-linearidades nas equações do mesmo [6], [19].

As condições iniciais impactam as integrações de curto a médio prazo, de alguns dias a algumas semanas. Os erros de previsão geralmente aumentam ao longo do tempo e contribuem para deteriorar a qualidade das previsões. Para as previsões sazonais (horizonte e alguns meses), os modelos numéricos apresentam erros nas propriedades estatísticas [5], [6], [7].

As condições de contorno afetam de forma importante as integrações climáticas de modelos regionais em horizontes de meses a décadas. Os erros originados desse contorno resultam em um limite de utilização dos dados do modelo Eta além de um prazo específico de previsão, por exemplo, em casos de previsões para os próximos 100 anos [6].

A Figura 1 ilustra a variável prognóstica componente zonal do vento para séries temporais previstas pelo modelo Eta e obtidas pelas reanálises do NCEP, no período total de 13 de Dezembro de 2008 a 30 de Abril de 2009, o que corresponde a 139 dias de previsão para um ponto. Para cada dia de previsão é apresentado resultados de previsão quatro vezes ao dia, às 00:00, 06:00, 12:00 e 18:00h UTC, assim, temos 553 amostras (valores) na série temporal de quatro meses e meio. Nota-se que há uma discrepância entre as duas séries, portanto, este trabalho visa a redução de erros entre os dados fornecidos pelo modelo Eta e os das reanálises do NCEP.

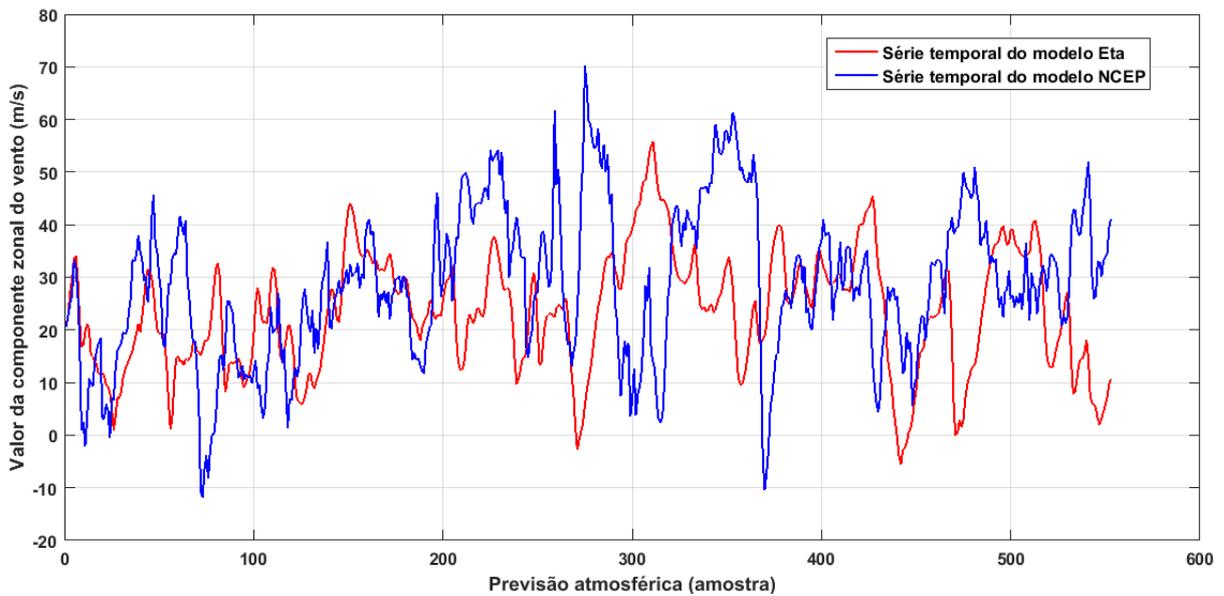


Figura 1 - Séries temporais dos modelos Eta e reanálises do NCEP para a componente zonal do vento.

Dados atmosféricos oriundos de modelos numéricos são considerados volumétricos; temos a resolução sobre a superfície terrestre em função da altura, de forma a fornecer células atmosféricas em função de latitude, longitude e altitude, para as quais se obtêm as variáveis prognósticas. Além disso, essas variáveis são fornecidas para um intervalo de tempo, em geral fixo de algumas horas. Temos assim dados volumétricos discretos no tempo. Por outro lado, o valor de uma variável prognóstica em uma dada altitude numa determinada região da superfície terrestre pode ser representada como uma imagem digital, para cada pixel dessa imagem há uma coordenada geográfica (em função da latitude e longitude) associada.

Um pixel representa o menor elemento constituinte de uma imagem digital e contém um valor numérico que é a unidade básica de informação sobre a imagem, para uma dada resolução espacial. O conteúdo de informação dos pixels pode variar consideravelmente, dependendo do tipo de imagem em processamento [20]. Uma das operações utilizadas no processamento digital de imagens é o uso de transformação, que se baseia na premissa de que os pixels de uma imagem exibem níveis de correlação com pixels vizinhos. Consequentemente, esta correlação pode ser explorada para prever o valor de um pixel a partir de seus respectivos vizinhos. Assim, define-se uma transformação que mapeia os dados espaciais (correlacionados) em componentes (descorrelacionadas). A principal vantagem de utilizar a transformação de imagens é a capacidade de remover a correlação

entre pixels vizinhos, concentrando a energia [21], [22].

Uma das técnicas de transformação utilizadas é a Transformada do Cosseno Discreta (DCT - *Discrete Cosine Transform*), que obtém a decorrelação de pixels de imagens digitais. Após a decorrelação, cada componente da transformada pode ser codificada independentemente, sem perder eficiência de compressão. A DCT transforma uma representação espacial em uma representação em frequências espaciais. Em uma imagem natural, a maior parte da energia está concentrada em frequências mais baixas, portanto, se transformamos uma imagem em seus componentes de frequência e eliminamos as componentes de frequência mais altas, podemos reduzir a quantidade de dados necessária para descrever a imagem sem sacrificar demais a sua qualidade [21], [22].

Um sinal no tempo discreto pode ser associado a uma sequência de números finita  $\{x(n)\}$ , com  $n \in Z$ . Cada número  $x(n)$  corresponde à amplitude do sinal no instante  $nT$ , onde  $T$  representa o intervalo entre dois pontos consecutivos nos quais o sinal é definido [23], [24]. O símbolo  $T$  não é exclusivamente uma unidade de tempo, ele pode ser definido para unidades de temperatura, comprimento, velocidade, entre outros [23].

A interpretação de dados climáticos como sinais de tempo discreto permite avaliá-los usando sistemas digitais que transformam entradas de tempo discreto em saídas de tempo discreto [23], [24]. Um sistema ou filtro discreto é constituído pela relação da sequência de entrada  $x(n)$  com a sequência de saída  $y(n)$ , sendo  $n$  um valor inteiro, de forma que  $y(n) = H\{x(n)\}$ , onde o operador  $H\{\cdot\}$  é o filtro no tempo discreto.

Pela suposição de que  $h(n)$  é a resposta para a entrada impulso, então, para um sistema linear e invariante no tempo discreto podemos considerar que  $y(n) = x(n) * h(n)$ , onde o símbolo  $*$  é o operador de convolução. Podemos arbitrar que  $y(n)$  são os dados climáticos das reanálises do NCEP e  $x(n)$  são os dados climáticos do modelo Eta. Dessa forma, presume-se que existe um sistema de resposta ao impulso  $h(n)$  que quando aplicado aos dados climáticos do modelo Eta produz sinais de saída mais aderentes aos dados das reanálises do NCEP.

A filtragem FIR (*Finite Impulse Response*) é caracterizada pela aplicação de um sinal do tipo impulso na entrada do filtro e gera uma resposta de duração finita. Os filtros digitais FIR são importantes em diversas aplicações como processamento de áudio e imagens, biomedicina, transmissão de dados, etc [25], [26], [27]. A filtragem FIR é realizada de modo não-recursivo, o que implica estabilidade [23], [24].

A possibilidade de adaptar filtros e aplicá-los aos sinais discretos indica que a filtragem adaptativa é um procedimento valioso para reduzir erros de previsão. A filtragem adaptativa emprega algoritmos recursivos, utilizados para o ajuste automático dos coeficientes do filtro de acordo com as características do sinal de entrada, tornando possível o projeto de filtros satisfatórios em ambientes não-estacionários. Os coeficientes do filtro adaptativo são ajustados em função de um sinal de referência, portanto, a aplicação do filtragem adaptativa no sinal de entrada resulta, na saída do filtro, em um sinal mais próximo do sinal de referência. O algoritmo de mínimos quadrados recursivo RLS (*Recursive Least Squares*) é utilizado em filtragem adaptativa para encontrar os coeficientes do filtro que permitem obter o mínimo erro quadrático (definido como a diferença entre o sinal de referência e o sinal produzido na saída do filtro) de forma recursiva [28], [29]. A Figura 2 ilustra o mecanismo de filtros adaptativos.

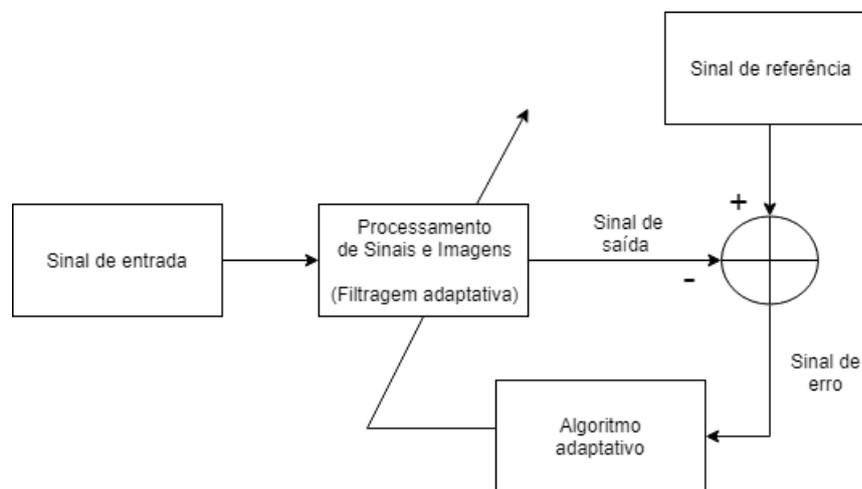


Figura 2 - Configurações da filtragem adaptativa.

## Objetivo do trabalho

Esta dissertação tem por objetivo avaliar a capacidade de filtros FIR (*Finite Impulse Response*) para o aprimoramento da previsão climática do modelo Eta (previsão sazonal - quatro meses e meio) e para isso, projetam-se filtros para minimizar os erros entre as séries temporais do modelo Eta e as séries temporais das reanálises do NCEP. Ao empregar os dados das reanálises do NCEP como referência, podemos avaliar o erro de previsão climática fornecido pelos dados do Eta. Conseqüentemente, utilizam-se filtros adaptativos com o intuito de reduzir erros de previsão numérica climática. O presente

trabalho utiliza a filtragem adaptativa FIR através do algoritmo RLS (*Recursive Least Squares*). Os filtros são aplicados no domínio da frequência através da DCT-2D (*Two-Dimensional Discrete Cosine Transform*). Entende-se que a correção das componentes espectrais, em vez dos valores espaciais (pixels), permitiria corrigir os modos implícitos ao modelo matemático empregado para a previsão, em todo o domínio espacial.

## Organização do texto

Este trabalho apresenta cinco capítulos que enfatizam as características, modelagens e aplicações referentes ao uso de filtros adaptativos no domínio da frequência para a redução de erros de previsão climática.

O Capítulo 1 descreve de forma sucinta a utilização de modelos atmosféricos fundamentais para o desenvolvimento da dissertação. São empregados o modelo regional Eta, o modelo GFS (*Global Forecast System*), o modelo circular geral atmosférico (MCGA) e as renálises do NCEP (*National Centers for Environmental Prediction*). As particularidades de cada modelo são apresentadas.

O Capítulo 2 aborda a metodologia aplicada para a redução de desvios de previsão climática. São mencionadas as etapas que constituem o uso da filtragem adaptativa no domínio da frequência, tais como o emprego de interpolação bidimensional, o processamento de imagens através da aplicação da DCT-2D (*Two-dimensional Discrete Cosine Transform*) e da IDCT-2D (*Two-dimensional Inverse Discrete Cosine Transform*). A varredura zig-zag e a sua inversa auxiliam na organização e reordenação de elementos. A separação por regiões de frequência limita a aplicação da filtragem adaptativa na região de frequências baixas. São apresentados os filtros digitais FIR e a filtragem adaptativa. O emprego do algoritmo RLS (*Recursive Least Squares*) auxilia a atualização dos coeficientes dos filtros adaptativos.

O Capítulo 3 apresenta as configurações essenciais para a aplicação da proposta do trabalho, tais como as variáveis climáticas escolhidas, o intervalo de previsão e as características importantes da filtragem adaptativa. Este capítulo também indica as métricas de desempenho empregadas.

O Capítulo 4 relata os resultados experimentais obtidos com o intuito de avaliar o comportamento das previsões climáticas através do uso de filtros adaptativos.

O Capítulo 5 apresenta as conclusões obtidas e aponta prováveis pesquisas futuras.

## 1 MODELAGEM ATMOSFÉRICA

O modelo atmosférico é uma ferramenta que reproduz as condições da atmosfera que pode ser utilizada tanto de forma diagnóstica - para avaliação de características climáticas passadas, com o uso de dados observados, ou de caráter prognóstico - com o intuito de prever comportamentos futuros do clima [30], [31].

Os modelos atmosféricos podem ser divididos em dois tipos: modelos atmosféricos de circulação global (MCGs) e modelos atmosféricos regionais (MCRs). MCGs reproduzem o comportamento de dados atmosféricos em toda a superfície terrestre. MCRs analisam o desempenho de variáveis atmosféricas para uma determinada região da Terra. A vantagem de empregar modelos regionais climáticos está na possibilidade de detalhar os cenários climáticos fornecidos pelos modelos globais, que geralmente apresentam baixa resolução espacial, a menor custo computacional. Mesmo com o aumento do poder computacional e da resolução dos modelos globais, continuará existindo o interesse em maior detalhamento na descrição de processos atmosféricos, das características das superfícies, etc [5], [6], [13].

Os MCRs dependem de condições iniciais e condições de contorno para a obtenção de melhores desempenhos da previsão atmosférica. As condições iniciais representam a atmosfera observada em pontos de grade, em um determinado instante de tempo, utilizadas pelo modelo para realizar as previsões do estado futuro da atmosfera. As condições de contorno são informações climáticas empregadas nas bordas dos modelos numéricos regionais, geralmente provenientes de informações produzidas por um MCG de baixa resolução [5], [6]. Os métodos utilizados para transformar as saídas do MCG em variáveis meteorológicas de escala regional são geralmente chamados de *downscaling* [5], [13].

A redução de escala espacial significa relacionar as variáveis de previsão atmosférica em grande escala simulada pelos MCGs para escala local ou ponto de estação. Duas abordagens de *downscaling* são identificadas, a dinâmica e a estatística [32]. Este trabalho utiliza as previsões resultantes de *downscaling* dinâmico a partir do modelo de clima regional (MCR), utilizando os dados climáticos do MCG como condições de contorno [13], [33].

O modelo Eta é um modelo atmosférico regional que adota as condições iniciais do GFS (*Global Forecast System*) e as condições de contorno do MCGA do CPTEC/INPE

[7], [14], [17]. O MCGA do CPTEC também utiliza o modelo GFS como condição inicial. A Figura 3 ilustra o aninhamento do modelo Eta às condições dos modelos GFS e MCGA do CPTEC/INPE.

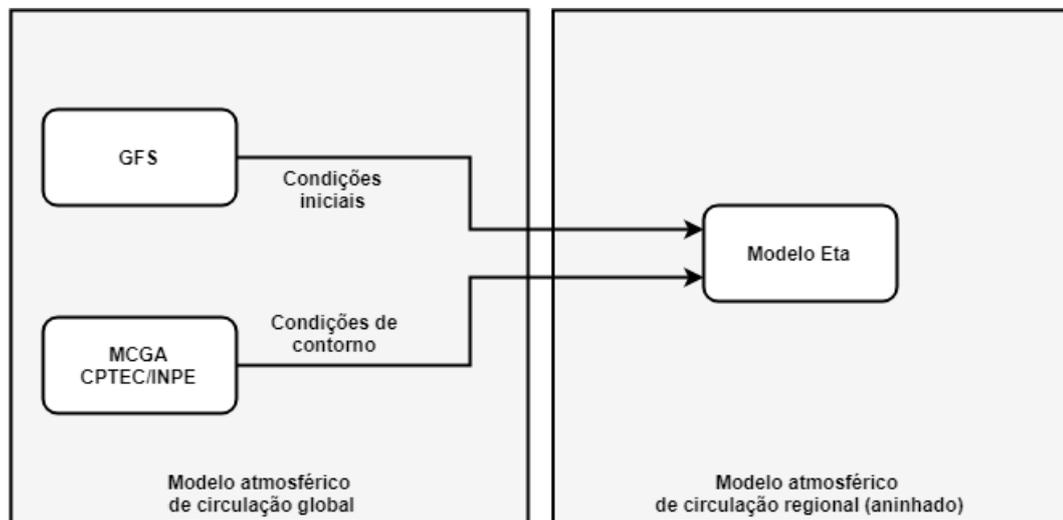


Figura 3 - Aninhamento do modelo Eta aos modelos GFS e MCGA do CPTEC/INPE.

Os modelos atmosféricos possuem características diferentes, tais como as configurações vertical e horizontal, variáveis prognósticas, condições iniciais e condições de contorno. As seções seguintes apresentam as peculiaridades básicas dos modelos que fornecem os dados para a previsão climática, contribuindo para a validação dos resultados oriundos das previsões climáticas analisadas.

### 1.1 Modelo de Circulação Geral Atmosférico (MCGA)

O MCGA do CPTEC/INPE, base do Modelo Brasileiro do Sistema Climático Global (MBSCG), tem sido desenvolvido pelo CPTEC a partir da sua versão inicial do COLA (*The Center for Ocean-Land-Atmosphere Studies*) de 1994 [13], [34]. Ele foi originado através do modelo MRF (*Medium Range Forecasting Model*), nomeado pelo NCEP (*National Centers for Environmental Prediction*) dos Estados Unidos para previsão de tempo de médio prazo. O MRF era uma combinação do código espectral global desenvolvido pelo NCEP e as parametrizações físicas desenvolvidas no GFDL (*Geophysical Fluid Dynamics Laboratory*) do NOAA (*National Oceanic and Atmospheric Administration*), também com sede nos EUA. A transferência do modelo MRF para o COLA incluiu cálculos diagnósticos, o que resultou em um melhor entendimento dos processos físicos

simulados e de sua importância relativa [12]. A partir da implantação do MRF, os grupos do NCEP e do COLA efetuaram atualizações significativas para a evolução conjunta do MCGA. Em contrapartida, devido à natureza experimental das mudanças feitas, tornou-se impraticável sua adoção pelo NCEP. Com isso, ocorreram divergências dos modelos empregados por cada grupo, causando diferenças substanciais [12]. O MCGA do COLA é utilizado pelo CPTEC/INPE para as previsões climáticas.

### 1.1.1 Coordenada vertical sigma ( $\sigma$ )

A coordenada vertical sigma ( $\sigma$ ) é utilizada pelo MCGA e auxilia as equações de previsão climáticas em diferentes níveis de pressão atmosférica e é definida como a pressão normalizada expressa por

$$\sigma = \frac{p - p_T}{p_S - p_T}, \quad (1.1)$$

onde  $p$  é a pressão em um determinado ponto da atmosfera,  $p_S$  é a pressão na superfície terrestre (base do domínio) e  $p_T$  é a pressão no topo do domínio do modelo. A coordenada  $\sigma$  varia de zero a um, quando  $p$  está localizado no topo do modelo ( $\sigma = 0$ ) e quando  $p$  está na superfície terrestre ( $\sigma = 1$ ), mas não necessariamente no nível médio do mar [12], [35].

A Figura 4 ilustra a coordenada  $\sigma$  de acordo com a forma do relevo terrestre. Isto permite avaliar que o modelo seja sensível a regiões onde a topografia é acentuadamente inclinada, gerando erros no cálculo do gradiente de pressão. Nestas regiões, os erros são produzidos nos cálculos de variáveis obtidas a partir de derivadas horizontais. Para inclinações abruptas, pode ocorrer a representação errônea de uma determinada altitude verdadeira (nível de pressão atmosférica), causando erros nas previsões próximos a montanhas [6], [12].

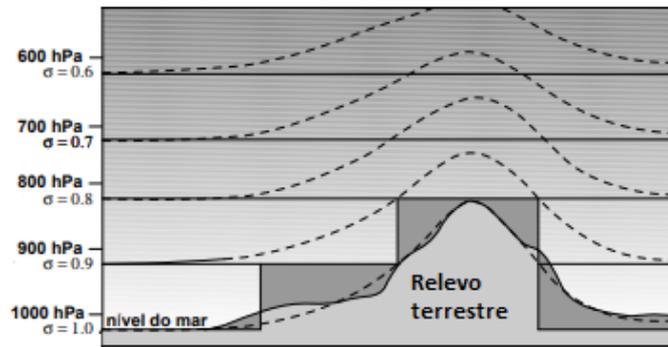


Figura 4 - Coordenada sigma ( $\sigma$ ) para os níveis de pressão atmosférica [36].

### 1.1.2 Variáveis prognósticas e resolução espacial do MCGA

As variáveis prognósticas do MCGA são: o logaritmo da pressão à superfície, a vorticidade (componente vertical do rotacional do vento), a divergência do vento horizontal, a temperatura virtual e a umidade específica. Outras variáveis são previstas nas parametrizações inseridas no modelo, tais como a temperatura de superfície, do interior do solo e do interior do dossel (extrato superior de florestas composto pelas árvores mais altas que recebem a intensidade de luz solar), umidade do solo, etc. As equações do modelo são escritas no formato espectral e suas resoluções são efetuadas por métodos numéricos [12].

O MCGA do CPTEC/INPE apresenta resultados de previsão quatro vezes ao dia, às 00:00, 06:00, 12:00 e 18:00h UTC e o período de previsão se estende até seis meses [6], [37]. O MCGA é constituído por uma resolução horizontal de  $200 \text{ km} \times 200 \text{ km}$ .

### 1.1.3 Condições iniciais e condições de contorno do MCGA

As condições iniciais do MCGA são inseridas a partir dos valores das variáveis: logaritmo da pressão à superfície, temperatura virtual, divergência horizontal, vorticidade vertical e umidade específica. A topografia é tratada em forma espectral, de modo que é representada por um série truncada, sujeita a problemas como o efeito Gibbs, ou seja, a soma das componentes da série de Fourier geram movimentos ondulatórios no espaço físico, com perturbações em pontos de descontinuidade, sem convergência [6], [12].

O MCGA necessita de condições de contorno inferior (da superfície da Terra) e a condição de contorno superior do MCGA é uma restrição cinemática que impõe velocidade

vertical, em coordenada sigma ( $\sigma$ ), nula em todos os pontos na superfície e no topo do modelo, para satisfazer a conservação de massa. Estas condições visam representar os processos atmosféricos na escala do tempo de um mês ou mais [6], [12].

## 1.2 Modelo GFS (*Global Forecast System*)

Os dados de previsão climáticas do GFS são disponibilizados pelo NOAA. Este modelo apresenta resultados de previsão às 00:00, 06:00, 12:00 e 18:00h UTC [17].

O modelo GFS fornece previsões determinísticas e probabilísticas para o horizonte de 16 dias, utilizando a coordenada vertical  $\sigma$  em 64 camadas e, temporalmente, produz saídas de previsões irregularmente espaçadas até o 16º dia. As saídas de previsões do GFS são usadas para produzir estatísticas da saída do modelo [38].

### 1.2.1 Variáveis prognósticas e resolução espacial do GFS

As variáveis prognósticas do modelo GFS são a vorticidade, divergência, temperatura virtual, pressão atmosférica e umidade específica. O período de previsão se estende em meses [6], [17]. A resolução horizontal do GFS é de aproximadamente 70 km, em previsões de tempo, para o horizonte entre uma e duas semanas [17].

## 1.3 Modelo Atmosférico Regional Eta

O modelo regional Eta, utilizado pelo CPTEC/INPE para gerar previsões climáticas na maior parte da América do Sul, foi desenvolvido pela Universidade de Belgrado em conjunto com o Instituto de Hidrometeorologia da Iugoslávia, mas tornou-se operacional através do NCEP [39], [40]. Esse modelo foi implantado no CPTEC em 1996 [14], com o propósito de complementar a previsão numérica de tempo que vinha sendo realizada desde o início de 1995 com o modelo de circulação geral atmosférico (MCGA), o modelo global CPTEC/COLA. O nome do modelo regional deriva da letra grega eta ( $\eta$ ), que indica a coordenada vertical [41], uma das características do modelo.

O modelo se propõe a complementar e a aumentar o detalhamento do modelo global sobre uma área de interesse. A maior resolução espacial permite prever com maiores detalhes fenômenos associados a frentes, orografia, brisa marítima, tempestades severas,

entre outros, com sistemas organizados em mesoescala [14]. A resolução horizontal do modelo Eta utilizada neste trabalho é de 40 km e a resolução vertical de 38 camadas [16].

### 1.3.1 Coordenada vertical eta ( $\eta$ )

A coordenada vertical eta ( $\eta$ ) foi definida por [41] e expressa como

$$\eta = \left( \frac{p - p_T}{p_S - p_T} \right) \left[ \frac{p_{ref}(z_s) - p_T}{p_{ref}(0) - p_T} \right], \quad (1.2)$$

onde  $p$  é a pressão atmosférica medida em hPa (hectopascal),  $p_S$  é a pressão ao nível médio do mar,  $p_T$  é a pressão no topo do modelo,  $p_{ref}(z_s)$  é a pressão de uma atmosfera de referência expressa em função da distância acima do nível do mar e  $z_s$  representa a altitude da superfície medida em metros. Nota-se que o primeiro termo da Equação (1.2) refere-se à coordenada sigma ( $\sigma$ ) descrita na subseção 1.1.1, isto se deve ao fato de que a coordenada  $\eta$  foi criada para reduzir os erros inerentes ao cálculo da força gradiente de pressão em modelos que usam a coordenada  $\sigma$  [40]. As coordenadas  $\eta$  e  $\sigma$  são iguais em regiões sem topografia, pois ambas possuem como referência a superfície do mar ( $z_s = 0$ ).

A Figura 5 mostra que a coordenada  $\eta$  transforma as áreas em superfícies que são aproximadamente horizontais, em cada nível de pressão atmosférica. A coordenada  $\eta$  também opera com pressão normalizada, portanto, significa dizer que ela utiliza as vantagens matemáticas da modelagem das equações governantes da atmosfera em uma forma relativamente simples [14], [40].

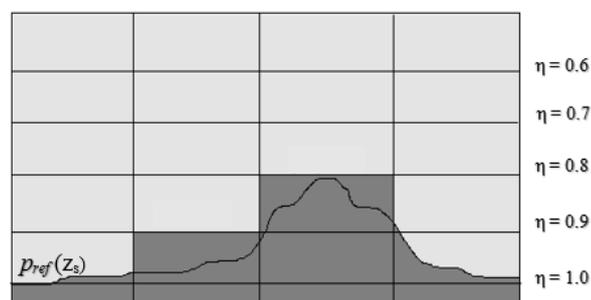


Figura 5 - Coordenada eta ( $\eta$ ) para os níveis de pressão atmosférica de referência em uma determinada altitude ( $p_{ref}(z_s)$ ) [36].

De acordo com a premissa de que as superfícies constituídas pela coordenada  $\eta$  são aproximadamente horizontais, os erros obtidos a partir das derivadas horizontais, tais

como a força gradiente de pressão, difusão ou advecção horizontal, podem ser reduzidos nessa coordenada e, conseqüentemente, espera-se a diminuição de erros na resolução [40], [42].

### 1.3.2 Variáveis prognósticas do modelo Eta

As variáveis prognósticas do modelo são: componentes meridional e zonal do vento, umidade específica, pressão à superfície, temperatura do ar, energia cinética turbulenta, umidade e temperatura do solo e água líquida ou gelo das nuvens [14], [15], [43]. O Eta, através da integração no tempo, utiliza a técnica de *split-explicit* [44]. O modelo Eta utiliza o esquema de Betts-Miller-Janjic com o intuito de produzir a precipitação convectiva [45]. O esquema de parametrização de radiação foi desenvolvido pelo *Geophysical Fluid Dynamics Laboratory*, composto por radiações de onda longas e curtas. O esquema de radiação de ondas longas foi desenvolvido por *Fels e Schwarzkopf* [46], enquanto que o esquema de ondas curtas foi proposto por *Lacis e Hansen* [47].

### 1.3.3 Grade E de Arakawa

A versão operacional do modelo Eta possui resolução horizontal de 40 km. As equações do modelo são discretizadas para a grade E de Arakawa, identificada como o alicerce para a estrutura horizontal do modelo [48]. A distância entre dois pontos adjacentes define a resolução da grade. A Figura 6 ilustra as superfícies horizontais (níveis de pressão atmosférica) de acordo com a coordenada eta ( $\eta$ ), espelhadas na grade E de Arakawa. Os pontos indicados como **H** são definidas as variáveis de pressão, temperatura e umidade específica. Os pontos **V** representam a posição das componentes horizontais do vento. O comprimento **d** indica o espaçamento entre os pontos de **H** ou de **V**. A magnitude desse comprimento é geralmente utilizada para definir a resolução horizontal do modelo, no caso,  $\mathbf{d} = 40$  km [6]. Esta grade apresenta regularidade em coordenadas esféricas, com o ponto de interseção entre o Equador e o meridiano de  $0^\circ$  deslocado para o centro do domínio, para que ocorra a minimização da convergência entre os paralelos e meridianos, na região central do domínio [6].

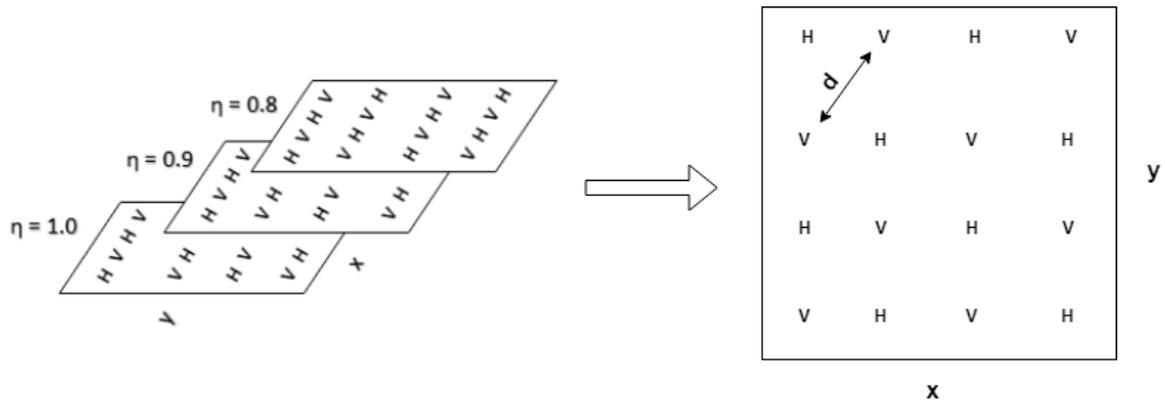


Figura 6 - Grade E de Arakawa

#### 1.3.4 Condições iniciais e condições de contorno do modelo Eta

O modelo regional Eta adota como condição inicial os dados do modelo GFS (*Global Forecast System*) e como condição de contorno os dados do modelo de circulação geral atmosférico (MCGA) do CPTEC [7], [13], [17]. A condição inicial é gerada por meio de uma análise estatística, onde há o ajuste da estimativa inicial de acordo com as observações investigadas do horário de análise. Os dados das análises estão dispostos em uma grade de resolução de modelo global e posteriormente são interpolados para a grade do modelo Eta [14]. Nas condições de contorno, a atualização do modelo ocorre a cada 6h [14].

#### 1.4 **Conjunto das reanálises do NCEP**

O NCEP (*National Centers for Environmental Prediction*), assim como o modelo GFS, apresenta um conjunto de dados que representam de forma minuciosa as condições climáticas observadas. Esses dados são nomeados como reanálises do NCEP/CFSR (*Climate Forecast System Reanalysis*). As reanálises do NCEP são constituídas por variáveis prognósticas obtidas a partir da investigação e incorporação de dados coletados em toda a superfície terrestre [18].

O conjunto de dados do CFSR consiste em previsões meteorológicas a cada hora, geradas pelo serviço nacional de meteorologia do NCEP (*the National Weather Services NCEP*). Os modelos de previsão são reinicializados a cada 6h (00:00h, 06:00h, 12:00h e 18:00h UTC) usando informações da rede global de estações meteorológicas. Para cada hora de análise, o CFSR inclui os dados de previsão previstos a partir da hora de análise anterior, e os dados da análise utilizada para reinicializar os modelos de previsão. Este

conjunto de dados contém informações de variáveis prognósticas em qualquer localidade no mundo. Além disso, como estas variáveis são atualizadas quase em tempo real a cada 6h, elas também podem apresentar estimativas em tempo real [18], [49].

O procedimento a partir da inserção das condições iniciais e de contorno contribui para a propagação de erros ao longo da integração do modelo Eta. Os dados das reanálises do NCEP servem como referência para o ajuste dos dados do Eta pelo fato de serem mais acurados.

O próximo capítulo relata a metodologia aplicada ao modelo Eta e as reanálises do NCEP, que foram abordados de forma sucinta no Capítulo 1.

## 2 METODOLOGIA

A Figura 7 apresenta a região na qual é aplicada a proposta desta dissertação, que engloba a América do Sul, partes da América Central e África. As coordenadas dos vértices do retângulo que delimita esta região são  $115^{\circ}\text{W}$  e  $30^{\circ}\text{N}$ ,  $115^{\circ}\text{W}$  e  $58^{\circ}\text{S}$ ,  $6^{\circ}\text{W}$  e  $30^{\circ}\text{N}$  e  $6^{\circ}\text{W}$  e  $58^{\circ}\text{S}$ . A condição de contorno lateral proveniente do modelo global se situa nas arestas do retângulo.

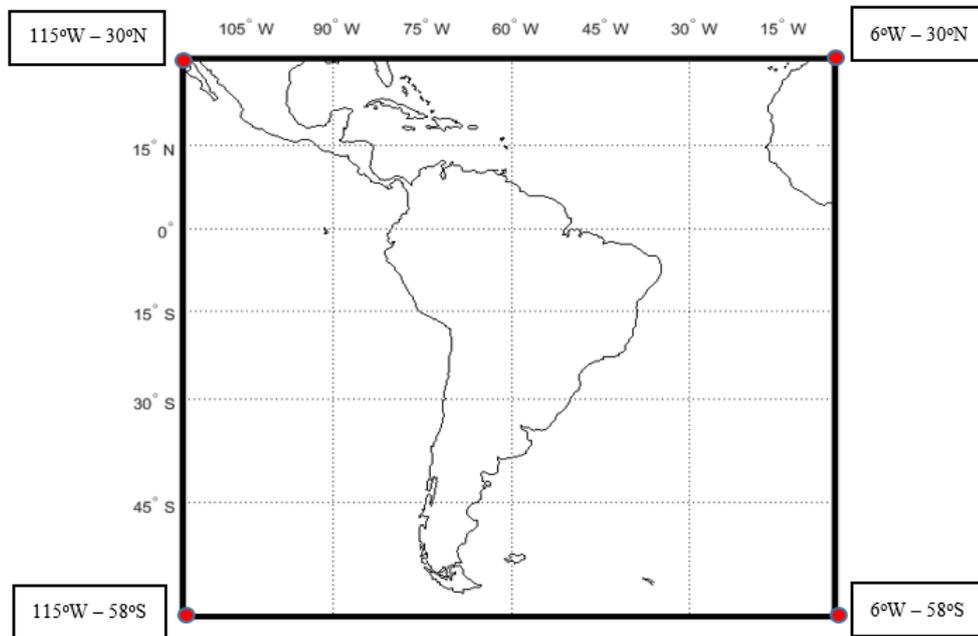


Figura 7 - Região de análise da superfície terrestre.

Os dados de previsão atmosférica provenientes do modelo Eta são disponibilizados pelo CPTEC/INPE e as reanálises do NCEP estão disponíveis em [50]. Tanto os dados provenientes do modelo Eta quanto os dados de reanálise do NCEP estão em formato de “Ponto de Grade”, que representam os dados de forma discreta em pontos fixos de uma malha ou grade. Uma forma de acessar esses dados é utilizar um software denominado GrADS (*Grid Analysis and Display System*) [51]. O GrADS é um software utilizado no acesso, manipulação e visualização de dados geofísicos. Dados no formato binário, GRIB (*Gridded Binary or General Regularly-distributed Information in Binary form*) ou NetCDF (*Network Common Data Format*) são compatíveis com o GrADS. As variáveis podem possuir até quatro dimensões (longitude, latitude, níveis verticais e tempo). No GrADS, os dados em forma de matriz podem conter uma ou mais variáveis dispostas

sobre uma grade regular, ou não-linear, ou gaussiana, ou em pontos de estações ou de resolução variável. Pode-se visualizar essas variáveis por meio de vários tipos de gráficos que podem ser salvos em diferentes formatos de imagens gráficas [6], [51]. A Figura 8 ilustra a interface do software GrADS.

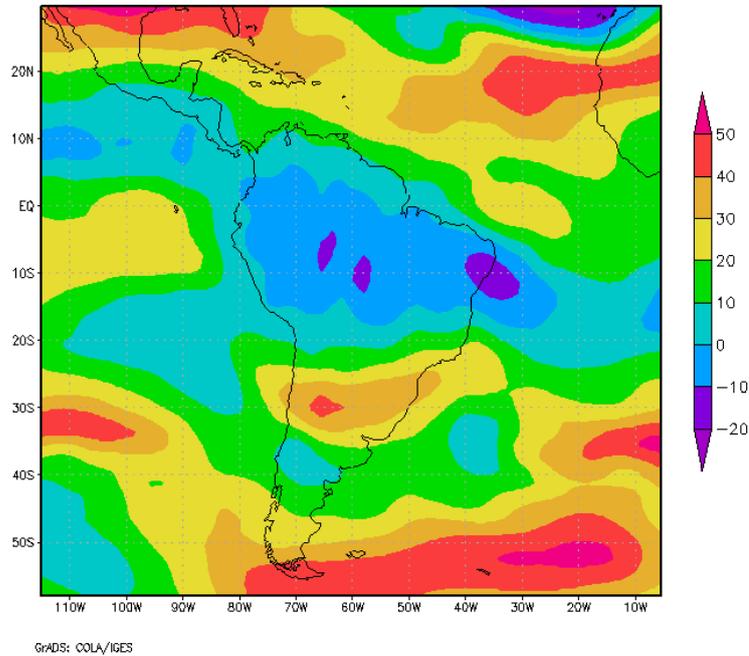


Figura 8 - Componente zonal do vento (em m/s) no software GrADS.

Por meio da interface programável do GrADS pode-se desenvolver diversas análises, calcular variáveis atmosféricas e aplicar visualizações automáticas. *Scripts* GrADS podem ser criados para desempenhar inúmeras funções, como calcular a velocidade do vento, retornar um valor mínimo sobre uma série de tempo de dados de estação, entre outras funções relevantes [51]. Assim, formulam-se *scripts* para converter os dados fornecidos pelo modelo Eta e as reanálises do NCEP para um arquivo em formato GRIB que possa ser lido no software FORTRAN. No ambiente do FORTRAN, é realizada a transformação dos dados climáticos no formato binário e, em seguida, estes dados binários são lidos no software Matlab, no qual são realizadas todas as análises e testes apresentados nesta dissertação, aplicando a filtragem adaptativa no domínio da frequência e posteriormente a obtenção de resultados de avaliação desse procedimento.

O modelo Eta e o modelo das reanálises do NCEP são constituídos por superfícies isobáricas (de mesmos níveis de pressão atmosférica) e estas superfícies possuem igualdade de pressão atmosférica em todos os seus pontos. Este trabalho aborda a aplicação de

filtragem em vinte níveis de superfície isobárica, com pressão atmosférica medida em hPa (hectopascal), sendo que a superfície ao nível médio do mar é de 1000 hPa e a superfície no topo dos modelos é de 50 hPa. A Figura 9 ilustra diversas superfícies isobáricas analisadas neste trabalho; os vinte níveis são: 50 hPa, 100 hPa, 150 hPa, 200 hPa, 250 hPa, 300 hPa, 350 hPa, 400 hPa, 450 hPa, 500 hPa, 550 hPa, 600 hPa, 650 hPa, 700 hPa, 750 hPa, 800 hPa, 850 hPa, 900 hPa, 925 hPa e 1000 hPa.

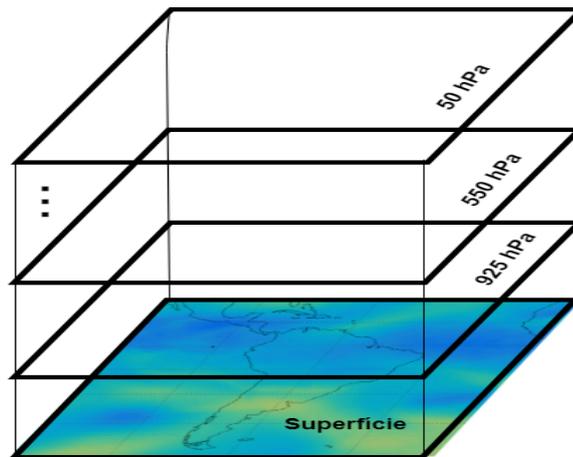


Figura 9 - Superfícies isobáricas da região terrestre.

## 2.1 Metodologia proposta

A Figura 10 ilustra a metodologia empregada nos anos de treinamento e ajuste, para o processamento de uma variável prognóstica, enfatizando o uso da filtragem adaptativa no domínio da frequência. A aplicação da filtragem adaptativa é realizada nos anos de treinamento e nos anos de ajuste são aplicados os coeficientes resultantes dos filtros adaptativos, com o objetivo de avaliar a redução de erros entre as séries temporais do modelo Eta e as séries do modelo NCEP.

Os dados do NCEP e do Eta correspondem a séries temporais para um ponto (coordenada geográfica), para diversas variáveis prognósticas – a Figura 10 apresenta o processamento para uma variável prognóstica. A interpolação bidimensional por splines redimensiona os dados do Eta para a resolução do NCEP. A filtragem adaptativa requer treinamento. Os filtros que processam as componentes espectrais da previsão, por isso são aplicados após a DCT bidimensional (DCT-2D) [52], [53], [54] e seu arranjo através de um varredura zig-zag e o consequente agrupamento em regiões frequenciais. O filtro

RLS (*Recursive Least Squares*) [28], [29] é usado para projetar filtros que atuam em subconjuntos de séries temporais de componentes espectrais. Os filtros FIR (*Finite Impulse Response*) [23], [24] projetados adaptativamente são usados para ajustar a previsão obtida com o Eta no domínio da DCT-2D. A varredura zig-zag inversa reordena os coeficientes e finalmente aplica-se a Transformada Inversa Discreta do Cosseno Bidimensional (IDCT-2D, *Two-dimensional Inverse Discrete Cosine Transform*) [52], [53], [55] para a obtenção da variável prognóstica Eta ajustada.

Consideramos o ajuste de previsões climáticas entre os anos de 2008 e 2010 e filtros são projetados/treinados para corrigir a previsão do ano XX usando os dados correspondentes ao ano (XX-1). Por exemplo, se queremos ajustar o ano de 2009, usamos o ano de 2008 para gerar o conjunto de treinamento.

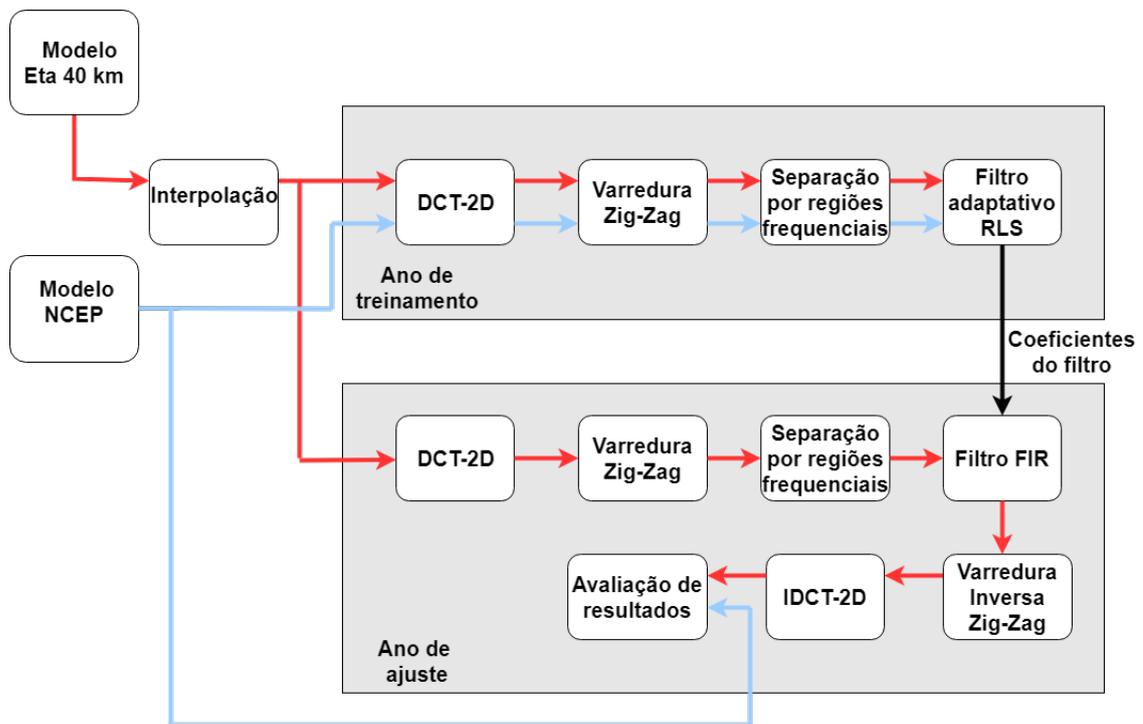


Figura 10 - Esquema da utilização de filtros adaptativos no domínio da frequência.

## 2.2 Interpolação bidimensional

A diferença entre as grades (amostragem espacial em termos de latitude e longitude) do modelo Eta e das reanálises do NCEP requer o ajuste dos dois modelos para uma grade comum. A uma determinada altitude (ou nível de pressão atmosférica) os dados do modelo Eta possuem  $220 \times 275$  elementos e os do NCEP  $177 \times 219$  elementos na região

da Figura 7. Isto é, o modelo Eta utiliza uma resolução de  $0,4^\circ$ , enquanto o NCEP é disponibilizado com resolução de  $0,5^\circ$ . Assim, aplica-se uma interpolação bidimensional para redimensionar os dados do Eta de forma que em cada nível de pressão haja  $177 \times 219 = 38.763$  elementos, equivalente ao modelo NCEP.

A interpolação bidimensional implementada emprega Splines. No caso, emprega-se uma Spline cúbica, assim, o valor interpolado em um ponto utiliza uma interpolação cúbica em cada dimensão [56].

### 2.3 Decomposição espectral usando a Transformada Discreta do Cosseno Bidimensional

Na maioria dos sistemas de compressão de imagens é possível identificar a presença de redundância espacial (semelhança entre um pixel e os pixels vizinhos) em uma imagem, o que pode ser averiguado através da Transformada Discreta do Cosseno Bidimensional ao longo da imagem. A DCT-2D (*Two-Dimensional Discrete Cosine Transform*) é um processo sem perda e reversível [52], [53], [57]. Uma imagem, um conjunto ou um bloco de dimensão  $M \times N$  contém dados de amplitude indexados espacialmente. A Transformada Discreta do Cosseno Bidimensional DCT-2D desse conjunto permite indexar as amplitudes das componentes frequenciais. A DCT-2D de uma matriz  $\mathbf{U}$  de tamanho  $M \times N$  resulta em uma matriz  $\mathbf{G}$ , cujos elementos são definidos por [52], [53], [54]

$$g_{p,q} = c_p c_q \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} u_{m,n} \cos \left[ \frac{\pi p}{M} \left( m + \frac{1}{2} \right) \right] \cos \left[ \frac{\pi q}{N} \left( n + \frac{1}{2} \right) \right], \quad (2.1)$$

$$c_p = \begin{cases} \frac{1}{\sqrt{M}}, & p = 0 \\ \sqrt{\frac{2}{M}}, & 1 \leq p \leq M - 1 \end{cases} \quad c_q = \begin{cases} \frac{1}{\sqrt{N}}, & q = 0 \\ \sqrt{\frac{2}{N}}, & 1 \leq q \leq N - 1 \end{cases}$$

com  $0 \leq p \leq M - 1$  e  $0 \leq q \leq N - 1$ , onde  $u_{m,n}$  representa o elemento na  $m$ -ésima linha e  $n$ -ésima coluna da matriz  $\mathbf{U}$  e  $g_{p,q}$  o valor na  $p$ -ésima linha e  $q$ -ésima coluna da matriz  $\mathbf{G}$ . Os valores de  $p$  e  $q$  determinam a frequência dos elementos de  $\mathbf{G}$ , os argumentos dos cossenos na Equação (2.1). As constantes de normalização  $c_p$  e  $c_q$  dependem das quantidades de linhas  $M$  e colunas  $N$  de  $\mathbf{U}$ , respectivamente.

A IDCT - 2D (*Two-Dimensional Inverse Discrete Cosine Transform*) converte os dados de indexação em frequências para os dados de indexação espaciais, sem causar

perdas relevantes no processo de restauração de uma determinada matriz  $\mathbf{U}$  (imagem). A equação que rege a IDCT – 2D de uma matriz  $\mathbf{G}$  de tamanho  $M \times N$  resulta em uma matriz  $\mathbf{U}$  de mesma dimensão, cujos elementos são expressos por [53], [55]

$$u_{m,n} = \sum_{p=0}^{M-1} \sum_{q=0}^{N-1} c_p c_q g_{p,q} \cos \left[ \frac{\pi p}{M} \left( m + \frac{1}{2} \right) \right] \cos \left[ \frac{\pi q}{N} \left( n + \frac{1}{2} \right) \right], \quad (2.2)$$

$$c_p = \begin{cases} \frac{1}{\sqrt{M}}, & p = 0 \\ \sqrt{\frac{2}{M}}, & 1 \leq p \leq M - 1 \end{cases} \quad c_q = \begin{cases} \frac{1}{\sqrt{N}}, & q = 0 \\ \sqrt{\frac{2}{N}}, & 1 \leq q \leq N - 1 \end{cases}$$

com  $0 \leq m \leq M - 1$  e  $0 \leq n \leq N - 1$ , onde  $u_{m,n}$ ,  $g_{p,q}$ ,  $c_p$  e  $c_q$  são equivalentes à descrição da seção 2.3. Os valores de  $m$  e  $n$  determinam a amplitude espacial dos elementos de  $\mathbf{U}$ .

A DCT-2D tem sido empregada na codificação de imagens, pois, em geral, permite concentrar grande fração da energia de imagens naturais em  $p$  e  $q$  pequenos, em frequências espaciais baixas, da mesma forma também ocorre para os dados climáticos. A Figura 11 apresenta a DCT-2D (Figura 11(b)) de uma variável prognóstica do modelo Eta num nível de pressão (Figura 11(a)).

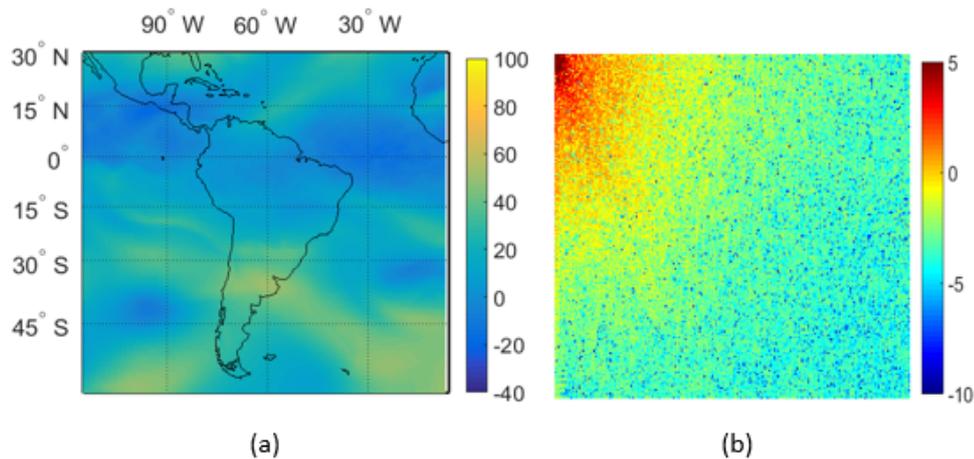


Figura 11 - Componente zonal do vento em  $m/s$  gerada pelo Eta para um determinado nível de pressão (altura atmosférica) em (a) e (b) é a sua DCT-2D, com frequências espaciais (componentes espectrais) em ciclos/km.

A componente no canto superior esquerdo ( $p=q=0$ ) possui, em geral, para imagens suaves, o maior valor, que é o valor médio (ou DC, as outras componentes são chamadas de valores AC). É possível observar que a energia de um sinal espacial da componente

zonal do vento se concentra em baixas frequências espaciais, da mesma forma como é verificado em imagens naturais.

As componentes da DCT-2D próximas ao canto inferior direito possuem valores pequenos, para imagens suaves, e normalmente podem ser desprezadas (substituindo-as por zero), sem que a imagem sofra grandes deformações. A principal razão de se utilizar a DCT-2D em compressão de imagens se baseia na possibilidade de desprezar estas componentes menos significativas, acarretando em mínima perda da qualidade dos dados processados [57].

### 2.3.1 Varredura Zig-Zag

A varredura zig-zag ordena crescentemente as componentes espectrais da DCT-2D em função da frequência ( $\omega$ ) correspondente aos elementos ( $\omega = (p^2 + q^2)^{1/2}$ ). Em geral, para imagens suaves, isso corresponde a organizar as componentes em ordem decrescente de energia. Como resultado deste procedimento obtém-se um vetor no qual podemos dividir as componentes em regiões frequenciais, agrupando-as por faixas de baixa, média e alta frequência que são utilizadas para a filtragem adaptativa.

A Figura 12 indica o procedimento da varredura zig-zag. Por exemplo, se temos uma imagem, um conjunto ou um bloco de dimensão  $8 \times 8$  teremos um total de 64 pixels. Ao aplicarmos a DCT-2D obteremos 64 componentes espectrais e, a partir da varredura, podemos organizá-las ordenadamente em um vetor-linha.

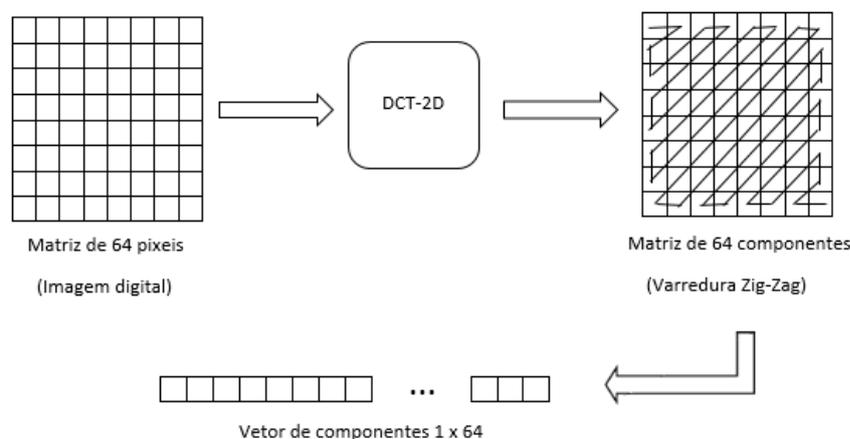


Figura 12 - Aplicação da varredura zig-zag.

Nesta dissertação, para cada nível de pressão atmosférica existe 553 matrizes, onde cada matriz contém 38.763 componentes espectrais de DCT-2D. A varredura zig-zag per-

mite ordenar todas estas matrizes em vetores-linha contendo 38.763 componentes cada uma. Este procedimento auxilia a separação destas componentes em regiões de frequências.

O procedimento da varredura zig-zag inversa consiste em reordenar os elementos que estão organizados no vetor-linha para uma matriz, onde cada elemento do vetor retorna a sua posição inicial na matriz reordenada, obedecendo a critérios de avaliação. Em relação à DCT-2D, as componentes espectrais são reorganizadas em função da ordem decrescente de energia.

### 2.3.2 Separação por regiões frequenciais

A aplicação da varredura zig-zag permite a organização dos elementos de uma matriz em um vetor-linha, contudo, pode-se realizar a separação destes elementos em vetores menores. A possibilidade de criar subconjuntos de vetores permite avaliar a característica de cada subconjunto. No campo da DCT-2D, é relevante dividir o vetor-linha contendo todas as componentes espectrais em subconjuntos de acordo com as faixas de frequências espaciais (frequências baixas, médias e altas). Através deste procedimento, a filtragem adaptativa pode ser realizada em função das regiões de frequência, o que a princípio contribui para um projeto melhor de filtros, pois na DCT-2D geralmente as faixas de frequências médias e altas possuem valores próximos de zero, tornando-se descartável a aplicação da filtragem, assim o procedimento de filtragem torna-se necessário somente na faixa de frequências baixas. A separação por regiões frequenciais auxilia a formação de séries de componentes espectrais da DCT-2D em cada nível de pressão atmosférica e variável prognóstica, onde cada série possui 553 amostras, conseqüentemente são projetados filtros adaptativos para cada série de componentes que esteja incluída na região de frequências baixas.

A Figura 13 apresenta o processo de separação por regiões de frequência. A Etapa I indica a distribuição das componentes espectrais da DCT-2D em regiões de frequência. A Etapa II refere-se a varredura zig-zag contendo todos os elementos. A Etapa III ilustra a separação de regiões frequenciais, com subconjunto de vetores relacionados a cada região.

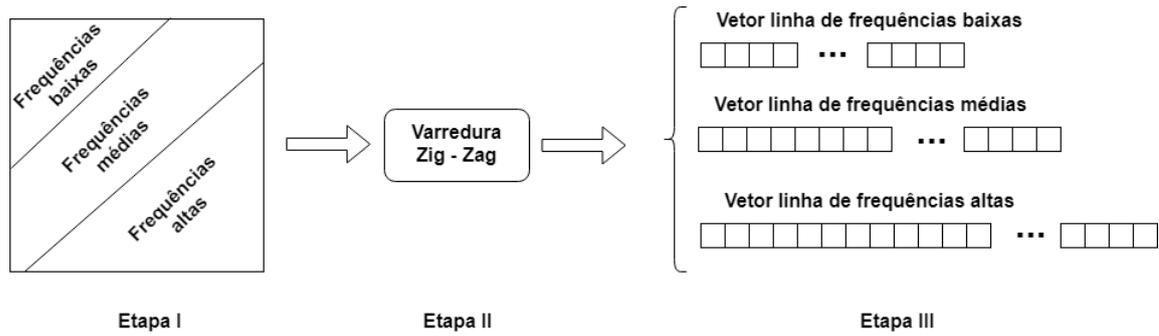


Figura 13 - Procedimento para a separação de regiões frequenciais.

## 2.4 Filtragem adaptativa FIR através do algoritmo RLS

Um filtro digital processa sinais digitais de forma a transformar o sinal de entrada em um sinal de saída [23], [24]. O filtro linear e invariante no tempo pode ser caracterizado em função de sua resposta  $y(n)$  quando se aplica na entrada  $x(n)$  do filtro um sinal  $h(n)$ . Se a saída do sistema depende somente da entrada presente e de um número finito de entradas passadas, então o filtro de Resposta ao Impulso Finita (FIR – *Finite Impulse Response*) tem uma resposta impulsiva finita. Devido ao fato de que os valores de saída passados não influenciam no cálculo dos valores de saída presentes, este filtro também é chamado de filtro não-recursivo [23], [24]. Os filtros FIR são do tipo BIBO (*bounded input-bounded output*) estáveis, ou seja, se para todo o sinal de entrada limitado em amplitude implica em um sinal de saída também limitado em amplitude [23], [24].

Desta forma, com o objetivo de reduzir os erros de previsão dos dados da DCT-2D do modelo Eta com relação aos dados da DCT-2D das reanálises do NCEP, aplica-se um filtro cujos coeficientes são ajustados por meio da filtragem adaptativa FIR.

### 2.4.1 Filtragem adaptativa

Nos últimos anos, as técnicas de processamento digital de sinais e, particularmente, as de processamento adaptativo de sinais alcançaram um elevado patamar de eficiência. Entre as causas desse fenômeno, destaca-se o surgimento dos processadores digitais de sinais de alto desempenho, os quais proporcionam precisão, flexibilidade e capacidade de implementação robusta de algoritmos. Um segmento importante nessa área de pesquisa consiste na filtragem adaptativa, a qual contempla uma ampla gama de aplicações, tais como realce, cancelamento de eco, identificação de sistemas, entre outros [28], [29], [58].

Um filtro adaptativo é um sistema variante no tempo, dotado de um mecanismo de ajuste dos coeficientes através de um critério específico. Quanto à forma de resolução do problema de filtragem adaptativa, diferentes pontos de vista são empregados, destacando-se as abordagens de aproximação estocástica e de minimização de funções-custo determinísticas [29], [58].

A utilização de filtros adaptativos nesse trabalho compreende dois períodos. O primeiro é de regime transitório e outro é de regime permanente. No regime transitório o filtro adaptativo é iniciado com um vetor aleatório de coeficientes que, através da adaptação, são atualizados de acordo com um critério de otimização específico. Após esse período, os coeficientes obtidos podem ser usados para aplicar o filtro em regime permanente, ou seja, eles podem ser mantidos pois alcançaram através da otimização uma resposta em conformidade com o desejado [6], [28].

A Figura 14 apresenta o diagrama em blocos esquemático de um sistema adaptativo, onde  $d(n)$  é o sinal de referência ou sinal desejado,  $\mathbf{x}(n)$  é o vetor do sinal de entrada,  $\mathbf{w}(n)$  é o vetor de coeficientes do filtro adaptativo,  $y(n)$  é o sinal de saída do filtro e  $e(n) = d(n) - y(n)$ , chamado de sinal de erro, reflete a discrepância entre os sinais  $d(n)$  e  $y(n)$ . O processo ajusta os coeficientes do filtro adaptativo de modo que o sinal de erro  $e(n)$  seja reduzido. Assim, em um instante  $n$ , uma amostra do sinal  $x(n)$  é submetida ao filtro adaptativo gerando a amostra do sinal  $y(n)$ . Esta é comparada à amostra correspondente do sinal  $d(n)$ , gerando o erro do sinal  $e(n)$ . O sinal de erro é usado para adaptar os coeficientes do filtro de iteração  $n$  para a iteração  $n + 1$ . Este procedimento se baseia na redução da magnitude do erro  $e(n)$  [6], [28].

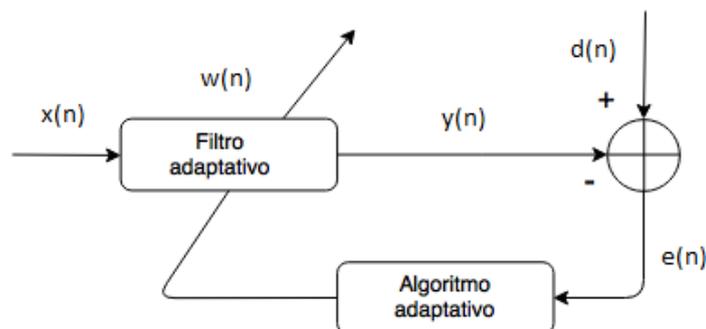


Figura 14 - Sistema adaptativo.

A saída do filtro  $y(n)$  de comprimento  $N$  é definida por

$$y(n) = \sum_{i=0}^N w_i(n)x(n-i) = \mathbf{w}^T(n)\mathbf{x}(n), \quad (2.3)$$

onde  $N$  é a ordem do filtro adaptativo,  $\mathbf{x}(n) = [x(n) \ x(n-1) \ x(n-2) \ \dots \ x(n-N)]^T$  e  $\mathbf{w}(n) = [w_0(n) \ w_1(n) \ \dots \ w_N(n)]^T$ . O símbolo  $T$  indica a transposição da matriz. O algoritmo adaptativo é responsável pelo ajuste dos coeficientes do filtro, visando a redução do erro quadrático.

A filtragem adaptativa FIR geralmente adota o erro quadrático médio (MSE - *Mean Square Error*) como critério de minimização, ao longo da etapa de adaptação do filtro [28]. O MSE é expresso por

$$\epsilon(n) = E[e^2(n)] = E[(d(n) - y(n))^2] = E[d^2(n) - 2d(n)y(n) + y^2(n)], \quad (2.4)$$

onde  $E[\cdot]$  é o operador valor esperado. Podemos ver que

$$\epsilon(n) = E[d^2(n)] - 2E[d(n)y(n)] + E[y^2(n)]. \quad (2.5)$$

Ao aplicarmos a Equação (2.3) na Equação (2.5), temos

$$\epsilon(n) = E[d^2(n)] - 2E[d(n)\mathbf{w}^T(n)\mathbf{x}(n)] + E[\mathbf{w}^T(n)\mathbf{x}(n)\mathbf{x}^T(n)\mathbf{w}(n)]. \quad (2.6)$$

Um filtro adaptativo com vetor de coeficientes fixos  $\mathbf{w}(n)$ , ou seja, para uma situação que  $\mathbf{w}(n)$  é aproximadamente  $\mathbf{w}(n-1)$ , temos

$$\epsilon(n) = E[d^2(n)] - 2\mathbf{w}^T E[d(n)\mathbf{x}(n)] + \mathbf{w}^T E[\mathbf{x}(n)\mathbf{x}^T(n)]\mathbf{w}. \quad (2.7)$$

A partir da Equação (2.7), define-se  $\mathbf{p} = E[d(n)\mathbf{x}(n)]$  e  $\mathbf{R} = E[\mathbf{x}(n)\mathbf{x}^T(n)]$ , com o que,

$$\epsilon(n) = E[d^2(n)] - 2\mathbf{w}^T \mathbf{p} + \mathbf{w}^T \mathbf{R} \mathbf{w}, \quad (2.8)$$

onde  $\mathbf{p}$  e  $\mathbf{R}$  são, respectivamente, o vetor de correlação cruzado entre o sinal de referência e o sinal de entrada e a matriz de correlação do sinal de entrada.

Os valores ótimos dos coeficientes do vetor  $\mathbf{w}$  podem ser obtidos a partir do mínimo do MSE ( $\epsilon$ ) em função de  $\mathbf{w}$ . Para isso, é preciso calcular o vetor gradiente do MSE em

relação a  $\mathbf{w}$ , assim

$$\mathbf{g}_{\mathbf{w}} = \frac{\partial \epsilon(n)}{\partial \mathbf{w}} = -2\mathbf{p} + 2\mathbf{R}\mathbf{w}. \quad (2.9)$$

O objetivo é a minimização de  $\epsilon(n)$ , portanto, para  $\mathbf{g}_{\mathbf{w}} = 0$  (ponto estacionário), temos

$$\mathbf{w}_o = \mathbf{R}^{-1}\mathbf{p}, \quad (2.10)$$

onde o vetor de coeficientes ótimos ( $\mathbf{w}_o$ ), através de uma perspectiva estatística, é denominado de solução de Wiener.

Em termos práticos, efetuar uma estimação precisa dos parâmetros  $\mathbf{R}$  e  $\mathbf{p}$  é uma tarefa árdua [6], [28]. A Equação (2.10) necessita do cálculo da inversa da matriz  $\mathbf{R}$  e, do ponto de vista analítico, na maioria das vezes não há uma solução viável, requerendo uma complexidade computacional muito elevada. Por isso, é imprescindível usar métodos alternativos que possam contribuir de forma prática para a resolução desse tipo de adversidade, portanto, utilizar algoritmos adaptativos que podem dirimir as dificuldades de se obter a solução de Wiener.

#### 2.4.2 Algoritmo RLS

A escolha de um algoritmo apropriado influencia a filtragem adaptativa em importantes fatores, tais como a complexidade computacional e a velocidade de convergência. Os algoritmos adaptativos que se baseiam no método dos mínimos quadrados têm suas soluções fundamentadas na redução da soma ponderada dos quadrados dos erros das estimativas, visando contornar o problema da solução de Wiener. Os algoritmos que usam mínimos quadrados têm como vantagem uma maior velocidade de convergência (medida em número de iterações), porém, demandam uma maior complexidade computacional [58].

A velocidade de convergência pode ser descrita como a quantidade de iterações necessárias para que o algoritmo adaptativo, na presença de sinais estacionários, convirja para a solução ótima de Wiener (coeficientes do filtro), com o intuito de minimizar o erro quadrático médio. Uma alta velocidade de convergência influencia o ajuste rápido do filtro adaptativo [59].

A complexidade computacional é avaliada a partir da quantidade de operações requeridas para efetuar uma iteração do algoritmo, isto é, o número de adições, multiplicações, divisões, comparações e acessos à memória, que podem acarretar em um processo

de informações mais demorado [59].

O algoritmo RLS (*Recursive Least Squares*) é um procedimento de estimação paramétrica utilizado em filtragem adaptativa, objetivando encontrar os coeficientes do filtro que acarretam a produção recursiva de mínimos quadrados do sinal de erro (diferença entre o sinal desejado e o verdadeiro). No RLS, os coeficientes do filtro são atualizados a cada iteração [28], [29], e ele apresenta bom desempenho para sistemas sujeitos a rápidas variações na amplitude do sinal.

A adaptação dos coeficientes a cada iteração tem por finalidade minimizar a função-objetivo

$$\xi(n) = \sum_{i=0}^n \lambda^{(n-i)} e^2(i), \quad (2.11)$$

onde  $e(i)$  é o erro de saída *a posteriori* no instante  $i$ . Esse erro é computado após a atualização dos coeficientes do filtro e utilizado na função-objetivo para o novo vetor de dados. O parâmetro  $\lambda$  é um fator de ponderação exponencial, ou constante de esquecimento, e deve ser arbitrado no intervalo  $0 \ll \lambda < 1$ . O valor de  $\lambda$  controla a influência das amostras passadas.

De acordo com as Equações (2.3) e (2.11), a função-objetivo pode ser expressa por

$$\xi(n) = \sum_{i=0}^n \lambda^{(n-i)} [d(i) - y(i)]^2 = \sum_{i=0}^n \lambda^{(n-i)} [d(i) - \mathbf{x}^T(i) \mathbf{w}(n)]^2. \quad (2.12)$$

Com a pretensão de minimizar o erro *a posteriori*, deriva-se  $\xi(n)$  em relação a  $\mathbf{w}(n)$ , assim,

$$\frac{\partial \xi(n)}{\partial \mathbf{w}(n)} = -2 \sum_{i=0}^n \lambda^{(n-i)} \mathbf{x}(i) [d(i) - \mathbf{x}^T(i) \mathbf{w}(n)]. \quad (2.13)$$

Ao igualar a zero a Equação (2.13), é possível encontrar o vetor ótimo  $\mathbf{w}(n)$  que minimiza o erro quadrático, portanto,

$$-\sum_{i=0}^n \lambda^{(n-i)} \mathbf{x}(i) \mathbf{x}^T(i) \mathbf{w}(n) + \sum_{i=0}^n \lambda^{(n-i)} \mathbf{x}(i) d(i) = \begin{bmatrix} 0 \\ \vdots \\ 0 \end{bmatrix}. \quad (2.14)$$

Podemos agora definir a expressão que rege o vetor de coeficientes do filtro  $\mathbf{w}(n)$  oriundos do algoritmo RLS e que são atualizados a cada iteração, portanto,

$$\mathbf{w}(n) = \left[ \sum_{i=0}^n \lambda^{(n-i)} \mathbf{x}(i) \mathbf{x}^T(i) \right]^{-1} \sum_{i=0}^n \lambda^{(n-i)} \mathbf{x}(i) d(i), \quad (2.15)$$

assim,

$$\mathbf{w}(n) = \mathbf{R}_D^{-1}(n) \mathbf{p}_D(n) \quad (2.16)$$

onde

$$\mathbf{R}_D(n) = \sum_{i=0}^n \lambda^{(n-i)} \mathbf{x}(i) \mathbf{x}^T(i) \quad (2.17)$$

e

$$\mathbf{p}_D(n) = \sum_{i=0}^n \lambda^{(n-i)} \mathbf{x}(i) d(i). \quad (2.18)$$

$\mathbf{R}_D(n)$  e  $\mathbf{p}_D(n)$  são nomeados, respectivamente, de matriz de correlação determinística do sinal de entrada e vetor de correlação cruzada determinístico entre o sinal de entrada e o sinal desejado.

O algoritmo RLS convencional é inicializado para  $n < 0$ , usando

$$\mathbf{S}_D(-1) = \delta I, \quad (2.19)$$

$$\mathbf{p}_D(-1) = \mathbf{x}(-1) = [0 \ 0 \ 0 \ \dots \ 0]^T, \quad (2.20)$$

onde  $\mathbf{S}_D(-1)$  é o lema da inversão de matrizes para  $n < 0$ ,  $\delta$  é a constante de regularização (um valor arbitrário),  $I$  é a matriz identidade (a sua dimensão depende do número de coeficientes do filtro),  $\mathbf{p}_D(-1)$  e  $\mathbf{x}(-1)$  são, respectivamente, o vetor de correlação cruzada determinístico e o vetor do sinal de entrada para  $n < 0$ .

Após a inicialização, o algoritmo RLS executa a iteração a cada instante de tempo  $n$ , para  $n \geq 0$ , então

$$\mathbf{R}_D^{-1}(n) = \mathbf{S}_D(n) = \frac{1}{\lambda} \left[ \mathbf{S}_D(n-1) - \frac{\mathbf{S}_D(n-1) \mathbf{x}(n) \mathbf{x}^T(n) \mathbf{S}_D(n-1)}{\lambda + \mathbf{S}_D(n-1) \mathbf{x}(n) \mathbf{x}^T(n)} \right], \quad (2.21)$$

$$\mathbf{p}_D(n) = \lambda \mathbf{p}_D(n-1) + d(n)\mathbf{x}(n) \quad (2.22)$$

e

$$\mathbf{w}(n) = \mathbf{S}_D(n)\mathbf{p}_D(n). \quad (2.23)$$

O algoritmo 1 apresenta as etapas fundamentais para a aplicação do algoritmo RLS Convencional. A partir dele obtém-se os vetores de coeficientes do filtro, os sinais de saída da filtragem adaptativa e os sinais de erro resultantes em cada iteração do algoritmo [28], [29].

<b>Algoritmo 1:</b> Algoritmo RLS Convencional	
1	<b>início</b>
2	<b>se</b> $n < 0$ <b>então</b>
3	$\mathbf{S}_D(-1) = \delta I;$
4	$\mathbf{p}_D(-1) = \mathbf{x}(-1) = [0 \ 0 \ 0 \ \dots \ 0]^T;$
5	<b>senão</b>
6	$\mathbf{R}_D^{-1}(n) = \mathbf{S}_D(n) = \frac{1}{\lambda} \left[ \mathbf{S}_D(n-1) - \frac{\mathbf{S}_D(n-1)\mathbf{x}(n)\mathbf{x}^T(n)\mathbf{S}_D(n-1)}{\lambda + \mathbf{S}_D(n-1)\mathbf{x}(n)\mathbf{x}^T(n)} \right];$
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	<b>fim</b>
12	<b>fim</b>
13	<b>fim</b>

O algoritmo RLS é utilizado para obter filtros e serem aplicados no domínio da frequência. As componentes espectrais da DCT-2D do modelo Eta oriundas das séries temporais são utilizadas para o treinamento dos filtros, isto é, a DCT-2D do modelo Eta é o sinal de entrada  $x(n)$  do sistema adaptativo. O sinal de referência  $d(n)$  refere-se as componentes espectrais da DCT-2D das reanálises do NCEP.

### 2.4.3 Vetor de coeficientes ótimo

O algoritmo RLS Convencional atualiza o vetor de coeficientes  $\mathbf{w}(n)$  a cada iteração  $n$ . A filtragem adaptativa utiliza séries de componentes espectrais da DCT-2D para obter a atualização dos coeficientes do filtro em cada rodada do algoritmo. Cada série de componentes possuem 553 amostras cada uma, implicando em 553 iterações do algoritmo para cada série.

O vetor de coeficientes ótimo para cada série de componentes ocorre quando há a convergência dos coeficientes para o regime permanente. Neste trabalho foram utilizados os vetores de coeficientes ótimos resultantes da última iteração do algoritmo RLS, ou seja,  $\mathbf{w}(553)$ , para cada série de componentes DCT-2D. Assim, são aplicados os vetores de coeficientes ótimos resultantes de cada série de componentes do ano de treinamento nas respectivas séries de DCT-2D no ano de ajuste, através da filtragem FIR.

Este capítulo apresentou a formulação teórica dos métodos que são abordados nesta dissertação. O Capítulo 3 indica as configurações necessárias para a aplicação dos métodos descritos no Capítulo 2.

### 3 PROCEDIMENTOS EXPERIMENTAIS

Este capítulo relata as etapas, as condições e os critérios estabelecidos para averiguar os resultados da aplicação da filtragem adaptativa no domínio da frequência.

#### 3.1 Conjunto de dados

O período do conjunto de previsão considerado é de 2008 a 2010, compreendendo amostras de previsões entre 13 de Dezembro a 30 de Abril do ano seguinte. As séries utilizadas apresentam 139 dias de previsão. As previsões do modelo Eta e das reanálises do NCEP apresentam resolução temporal de seis horas, portanto, por dia há quatro valores de previsão (às 00:00, 06:00, 12:00 e 18:00 UTC). Neste trabalho utilizamos o intervalo de 13 de Dezembro às 12 horas a 30 de Abril às 12 horas do ano seguinte, correspondendo a uma série temporal de  $P = 553$  amostras em cada célula.

As variáveis prognósticas utilizadas para a análise da proposta são as componentes zonal e meridional do vento (em  $m/s$ ), altura geopotencial (em  $m_{gp}$  - metro geopotencial) e a umidade específica (em  $kg$  de massa de vapor d'água/ $kg$  de massa de ar) [60]. A metodologia descrita no Capítulo 2 é aplicada em dados correspondentes a vinte níveis de pressão atmosférica (50 hPa a 1000 hPa, com intervalo de 50 hPa, com exceção em 925 hPa). Porém, para a umidade específica não se aplica a proposta em níveis da alta troposfera (pressão  $< 250$  hPa), onde a água é quase ausente e os valores das componentes da DCT-2D são todos quase nulos.

##### 3.1.1 Agrupamento de dados no domínio espectral

Para cada cenário (ano, variável prognóstica e nível de pressão) é utilizada a varredura zig-zag em todas as matrizes de componentes espectrais da DCT-2D no período de conjunto de previsão citado na Seção 3.1. Para cada matriz do modelo Eta e NCEP obtêm-se vetores-linha contendo 38.763 elementos.

A separação por regiões frequenciais auxilia o agrupamento dos elementos de acordo com a Figura 15. Neste caso são utilizadas três regiões. A região 1 contém 3.600 componentes (equivale a um vetor-linha de 3.600 elementos), a região 2 tem 16.000 componentes e a região 3 é composta por 19.163 componentes. É importante ressaltar que cada com-

ponente corresponde a uma série temporal de coeficientes DCT-2D e que a aplicação da filtragem adaptativa no domínio da frequência é realizada somente na região 1 (faixa de frequências baixas), assim há um filtro adaptativo para cada série. Nas regiões 2 e 3, os valores das componentes são muito próximos de zero (faixas de frequências médias e altas), possibilitando desprezar estes elementos, portanto, é feita a substituição dos seus valores por zero.

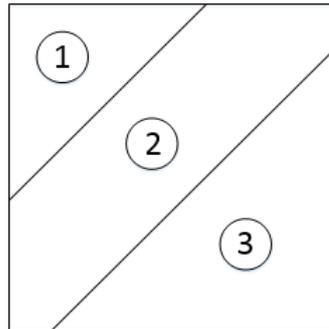


Figura 15 - Componentes espectrais da DCT-2D separadas por regiões frequenciais.

### 3.2 Critérios de avaliação

O desempenho do ajuste das séries temporais do modelo Eta pode ser avaliado usando o erro entre as séries das reanálises do NCEP e as séries ajustadas do modelo Eta. Para cada nível de pressão atmosférica há um total de 38.763 séries temporais para o modelo Eta e também para o modelo NCEP, assim, é possível calcular 38.763 valores de MSE (*Mean Square Error*) em cada nível de pressão atmosférica. É importante frisar que os critérios de avaliação são aplicados no domínio do tempo e podemos reiterar que os filtros adaptativos no domínio da frequência são usados somente na região de frequências baixas, o que corresponde a 3.600 séries de componentes da DCT-2D, em cada nível de pressão. Por isso, é necessário utilizar métricas de avaliação que elucidem de forma contundente e simples o desempenho das séries temporais dos modelos Eta e NCEP através da aplicação da filtragem adaptativa no domínio da frequência.

Como exposto, lidamos com séries temporais correspondentes a variáveis climáticas em coordenadas geográficas específicas. Conseqüentemente, na região e na resolução do Eta analisado temos  $I = 38.763$  séries, onde cada série refere-se a uma dada previsão que contém 553 amostras. Utilizemos o subscrito  $i$  para referenciar cada série. Podemos

definir o erro na  $n$ -ésima amostra da  $i$ -ésima série como

$$e_i(n) = y_i(n) - d_i(n), \quad (3.1)$$

onde  $d_i(n)$  corresponde à série temporal do NCEP e  $y_i(n)$  à do Eta ajustado ou não.

### 3.2.1 MSE (Mean Square Error)

Para cada célula  $i$  podemos definir o erro quadrático médio (*MSE*)

$$MSE_i = \overline{e_i^2} = \frac{1}{P} \sum_{n=1}^P e_i^2(n), \quad (3.2)$$

onde a média é realizada no tempo e  $P$  é o comprimento das previsões climáticas em amostras.

### 3.2.2 Erro máximo

De forma a avaliar corretamente a proposta, faz-se necessário atentar para desvios extremos. Assim, avaliamos também o efeito da proposta sobre o erro máximo entre as previsões do modelo Eta e das reanálises do NCEP para as diferentes variáveis prognósticas. Para esse fim, utilizamos o erro máximo absoluto definido por

$$e_{i,\text{máx}} = \max_n |e_i(n)|. \quad (3.3)$$

Este é computado para cada série  $i$  do Eta em relação à série correspondente do NCEP, antes e após o ajuste proposto de forma a permitir compará-los.

### 3.2.3 Média do erro quadrático médio

Dada a impossibilidade de apresentar resultados para todas as variáveis prognósticas e níveis de pressão, esses dados são sintetizados em índices médios.

Por exemplo, para um nível de pressão específico, a média do erro quadrático médio (*MSEM*) é

$$MSEM = \overline{MSE_i} = \frac{1}{I} \sum_{i=1}^I \overline{e_i^2} = \frac{1}{I} \sum_{i=1}^I \left[ \frac{1}{P} \sum_{n=1}^P e_i^2(n) \right], \quad (3.4)$$

onde  $MSE_i$  é o MSE da série temporal da variável climática na  $i$ -ésima coordenada geográfica.

A partir do  $MSEM$  pretendemos analisar se globalmente (em toda a região,  $i = 1, \dots, I$ ) os filtros adaptativos para cada variável climática são ou não efetivos na redução do erro da previsão após suas aplicações, isto é, se há redução dos valores de  $MSEM$  após o ajuste das séries temporais do modelo Eta. A redução percentual da média do erro quadrático médio ( $MSEM_p$ ) é expressa por

$$MSEM_p = \left(1 - \frac{MSEM_{ap}}{MSEM_{an}}\right) \times 100, \quad (\%) \quad (3.5)$$

onde  $MSEM_{an}$  e  $MSEM_{ap}$  são, respectivamente, a média dos valores de MSE antes e após o ajuste das séries temporais do modelo Eta. É possível afirmar que, se a redução percentual da média do erro quadrático médio apresentar valor positivo pode-se concluir que ocorreu uma diminuição do erro de previsão.

#### 3.2.4 Taxa de efetividade

Outra forma de avaliar o efeito geral da proposta é avaliando uma “taxa de efetividade” ( $T_{ef}$ ), que resulta da fração das séries temporais para as quais se consegue uma redução do erro de previsão numérica (avaliado, por exemplo, através do MSE ou do erro máximo) para os diferentes níveis de pressão atmosférica. Tal taxa seria definida por

$$T_{ef} = \left(\frac{N_r}{N_s}\right) \times 100, \quad (\%) \quad (3.6)$$

onde  $N_r$  é o número de séries temporais nas quais se observou redução do índice avaliado (MSE ou erro máximo) e  $N_s$  é o número total de séries em cada nível de pressão atmosférica.

### 3.3 **Configurações do algoritmo RLS**

Os parâmetros relevantes para a aplicação do algoritmo RLS são a ordem do filtro adaptativo ( $N$ ), o vetor inicial de coeficientes do filtro, a constante de regularização ( $\delta$ ) e o fator de ponderação exponencial ( $\lambda$ ). O vetor de coeficientes  $\mathbf{w}(n)$  foi inicializado com zeros e a constante de regularização ( $\delta = 1$ ).

As subseções seguintes justificam as seleções da ordem do filtro adaptativo e do fator de ponderação exponencial, os quais são importantes parâmetros para a aplicação da filtragem adaptativa.

### 3.3.1 Escolha da ordem do filtro adaptativo ( $N$ )

Para os anos de treinamentos de 2008 e 2009 são feitas separações de regiões frequenciais em cada nível de pressão atmosférica. A partir desta separação, a filtragem adaptativa é realizada somente na região de frequências baixas, onde se situam 3.600 componentes e cada componente possui uma série temporal de coeficientes DCT-2D, ou seja, temos 3.600 séries que contém 553 amostras cada. É importante frisar que há um filtro adaptativo para cada série de coeficientes DCT-2D. A cada nível de pressão atmosférica podem ser calculados 3.600 valores de erro quadrático médio MSE (*Mean Square Error*) e podem ser ilustradas 3.600 curvas de aprendizado do MSE. A escolha da ordem do filtro adaptativo ( $N$ ) é constituída pela análise das médias de dois indicadores (valores do MSE e curvas de aprendizado do MSE).

As médias dos valores do MSE ( $MED$ ) são calculadas para vinte níveis de pressão atmosférica. Assim, efetua-se a média do MSE de cada série  $i$  de coeficientes, ou seja, a razão entre o somatório dos MSE's para cada série e o número total de níveis de pressão atmosférica aplicado neste trabalho. A partir da Equação (3.2) podemos expressar que

$$MED_i = \frac{1}{M} \sum_{r=1}^M MSE_i(r), \quad (3.7)$$

onde  $M = 20$  para as variáveis componente zonal e meridional do vento e altura geopotencial, mas para a umidade específica adota-se  $M = 16$  e  $i = 1, \dots, 3.600$ .

As médias das curvas de aprendizado do MSE ( $MCA$ ) são feitas através de duas etapas. A primeira etapa consiste na média preliminar ( $MP$ ) das 3.600 curvas de aprendizado do MSE, onde cada curva possui 553 iterações, em cada nível de pressão atmosférica. A segunda etapa é feita por outra média de curvas de aprendizado, mas neste caso solicita-se a curva resultante da primeira etapa, de cada nível de pressão. Assim é efetuada a média das curvas resultantes de cada nível de pressão em função do número total de níveis de pressão atmosférica utilizado nesta dissertação. Assim, a primeira etapa é expressa por

$$MP_k = \frac{1}{Q} \sum_{t=1}^Q e_t^2(k), \quad (3.8)$$

onde  $Q = 3.600$  e  $k = 1, \dots, 553$ . Com isso, se adicionarmos todos os  $k$  valores de  $MP$  em um mesmo vetor, podemos ilustrar a curva de aprendizado do MSE resultante da primeira etapa, para cada nível de pressão atmosférica.

A segunda etapa resulta na média dos  $k$  valores de  $MP$  em função do total de níveis de pressão atmosférica, portanto, a média das curvas de aprendizado do MSE é expressa por

$$MCA_k = \frac{1}{M} \sum_{q=1}^M MP_k(q), \quad (3.9)$$

onde  $M = 20$  para as variáveis componente zonal e meridional do vento e altura geopotencial, mas para a umidade específica adota-se  $M = 16$  e  $k = 1, \dots, 553$ .

Foram realizados testes para quatro ordens de filtro adaptativo ( $N = 4$ ,  $N = 8$ ,  $N = 16$  e  $N = 32$ ). Por exemplo, escolhe-se a ordem do filtro para a aplicação no ano de treinamento (2008). Os coeficientes ótimos do filtro adaptativo são aplicados nos dados do ano de ajuste (2009), através da filtragem FIR. Com isso, é feita uma comparação entre as médias dos valores do MSE após a filtragem adaptativa no ano de treinamento (2008) e as obtidas a partir da aplicação da filtragem FIR no ano de ajuste (2009). Para as médias das curvas de aprendizado do MSE também é adotado o mesmo procedimento. A ordem do filtro escolhida será aquela em que as médias dos dois indicadores (valores de MSE e curvas de aprendizado) após a aplicação da filtragem FIR no ano de ajuste for menor que as outras ordens testadas. As Figuras 16 e 17 retratam, respectivamente, as médias dos valores de MSE após a filtragem adaptativa no ano de treinamento de 2008 ( $MED_{at}$ ) e as médias ( $MED_{aj}$ ) após a filtragem FIR no ano de ajuste de 2009, para a variável prognóstica componente zonal do vento ( $uvel$ ).

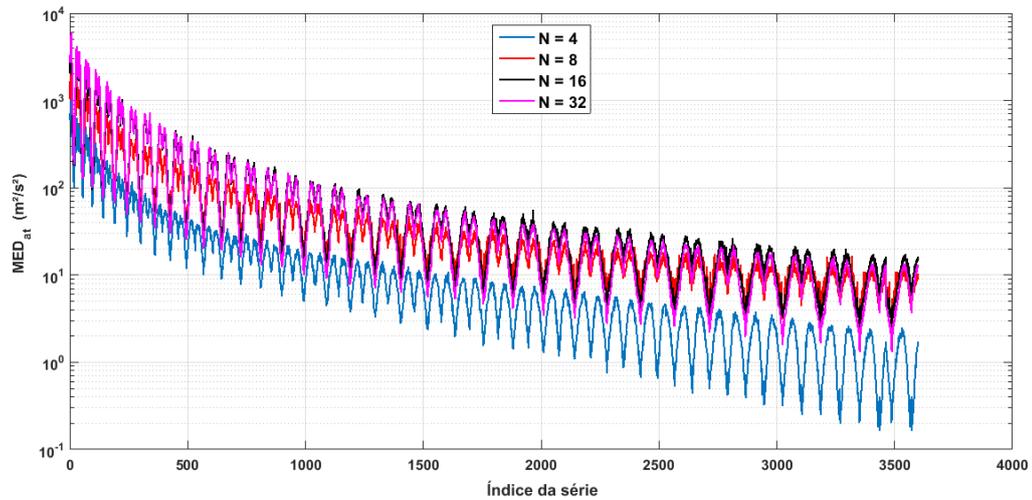


Figura 16 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a componente zonal do vento, no ano de treinamento de 2008.

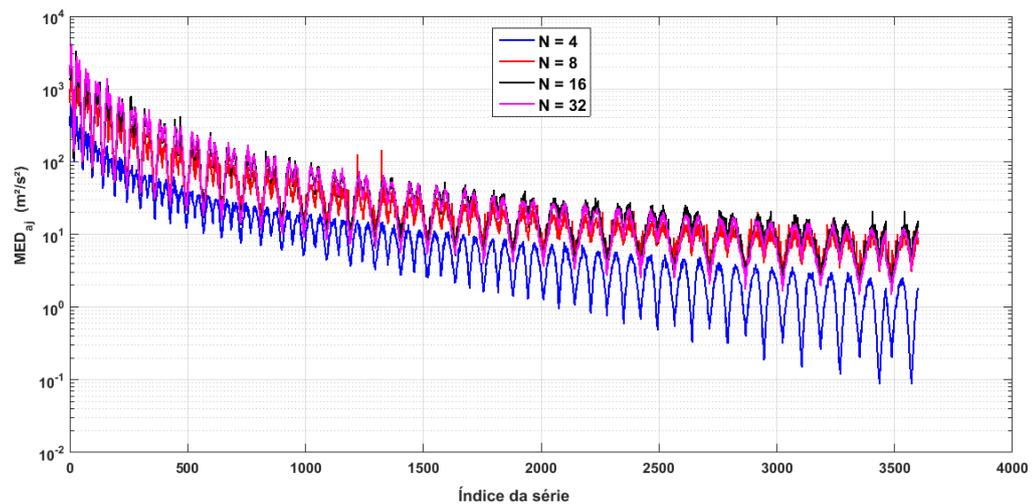


Figura 17 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a componente zonal do vento, no ano de ajuste de 2009.

É possível constatar a partir das Figuras 16 e 17 que a ordem de filtro ( $N = 4$ ) apresenta as menores médias de valores do MSE para a componente zonal do vento, no ano de treinamento de 2008 e ano de ajuste 2009.

As Figuras 18 e 19 ilustram, respectivamente, as médias das curvas de aprendizado do MSE após a filtragem adaptativa no ano de treinamento de 2008 ( $MCA_{at}$ ) e as médias após a aplicação da filtragem FIR ( $MCA_{aj}$ ) no ano de ajuste de 2009, para a variável prognóstica componente zonal do vento ( $uvel$ ).

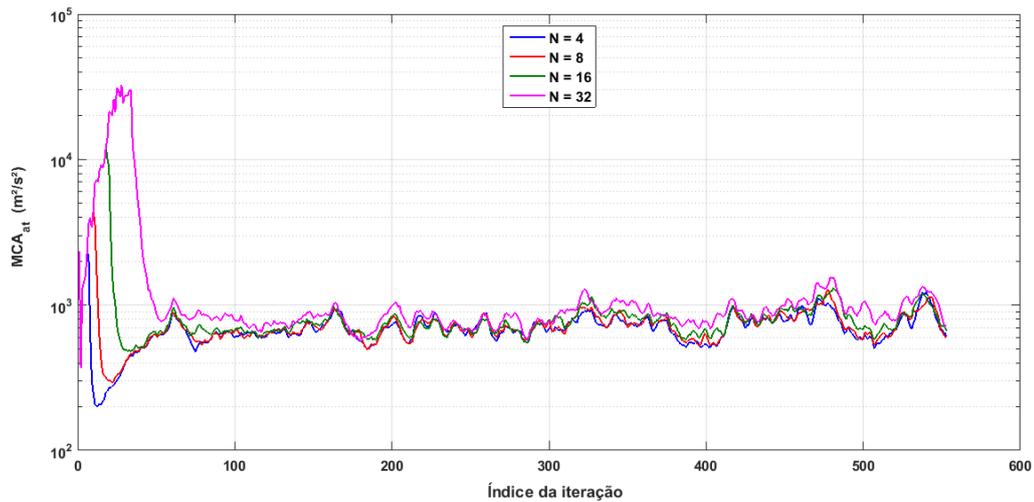


Figura 18 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a componente zonal do vento, no ano de treinamento de 2008.

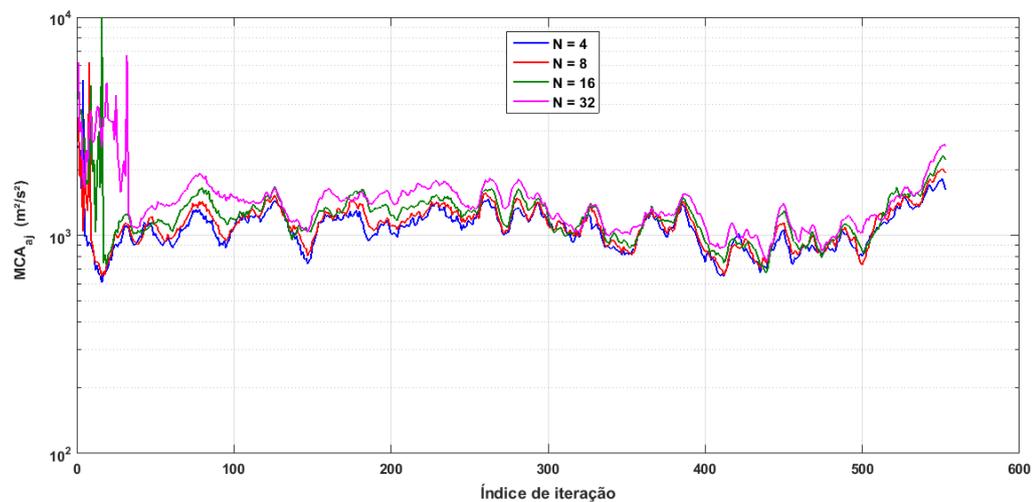


Figura 19 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a componente zonal do vento, no ano de ajuste de 2009.

As Figuras 18 e 19 também indicam que a ordem do filtro ( $N = 4$ ) apresentou os menores valores para as curvas de aprendizado do MSE.

A partir das análises efetuadas, foi feita a aplicação das médias das curvas de aprendizado do MSE e as dos valores de MSE para todas as variáveis prognósticas escolhidas neste trabalho, de acordo com os anos de treinamento e ajuste. Assim, verificou-se que a ordem ( $N = 4$ ) apresentou as menores médias de todas as variáveis prognósticas.

Com isso, os resultados experimentais desta dissertação foram desenvolvidos aplicando a ordem de filtro ( $N = 4$ ), no uso da filtragem adaptativa no domínio da frequência.

### 3.3.2 Escolha do fator de ponderação exponencial ( $\lambda$ )

Em cada cenário (ano, variável prognóstica e nível de pressão atmosférica), projetaram-se filtros adaptativos com diferentes valores de  $\lambda$ . A escolha do valor de  $\lambda$  influencia na redução dos mínimos quadrados do sinal de erro. Ao escolher um valor de  $\lambda$  é possível verificar se há redução significativa do erro quadrático médio (MSE) referente a cada componente que trata de uma série temporal de coeficientes da DCT-2D. De acordo com a subseção 3.3.1, são realizados filtros adaptativos em 3.600 séries de coeficientes de DCT-2D da região de frequências baixas, para todos os níveis de pressão atmosférica e os dois anos de treinamento (2008 e 2009). Assim, temos 3.600 valores de MSE em cada nível de pressão e ano de treinamento.

A taxa de efetividade do MSE mede quantas séries temporais de coeficientes da DCT-2D obtêm redução do MSE após a aplicação de filtros adaptativos. Para efeitos gerais da proposta, pode-se calcular uma média da taxa de efetividade ( $MED_{tef}$ ), que consiste em analisar estas taxas em cada nível de pressão atmosférica e calcular a média entre elas. Assim, nesta subseção, a escolha do valor de  $\lambda$  é baseada nesta média. A partir da Equação (3.6), temos

$$MED_{tef} = \frac{1}{M} \sum_{i=1}^M Tef_i, \quad (\%) \quad (3.10)$$

onde  $M = 20$  para as variáveis componente zonal e meridional do vento e altura geopotencial, mas para a umidade específica adota-se  $M = 16$  e o subscrito  $i$  referencia as taxas de efetividade em cada nível de pressão atmosférica. A média das taxas de efetividade é calculada para cada valor de  $\lambda$  arbitrado.

Foram escolhidos cinco valores de  $\lambda$  (0,92;0,95;0,98;0,99;0,998). O procedimento é realizado através das análises das médias das taxas de efetividade do MSE. Por exemplo, escolhe-se a variável componente zonal do vento para a aplicação no ano de treinamento (2008). É possível calcular os MSE's antes e após o uso de filtros adaptativos, de acordo com as 3.600 séries, em cada nível de pressão. Com isso, é efetuada a média das taxas de efetividade do MSE da componente zonal do vento para o ano de treinamento de 2008.

O valor de  $\lambda$  escolhido será aquele em que a média da taxa de efetividade do MSE tiver o maior valor entre os demais fatores de ponderação exponencial testados. As Figuras 20 e 21 indicam as médias das taxas de efetividade do MSE ( $MED_{tef}$ ) para a variável prognóstica componente zonal do vento, nos anos de treinamento. Estas figuras ilustram que a componente zonal do vento obteve melhores médias de taxa de efetividade do MSE para os valores de  $\lambda$  iguais a 0,98 e 0,998, de acordo com os anos de treinamento de 2008 e 2009, respectivamente.

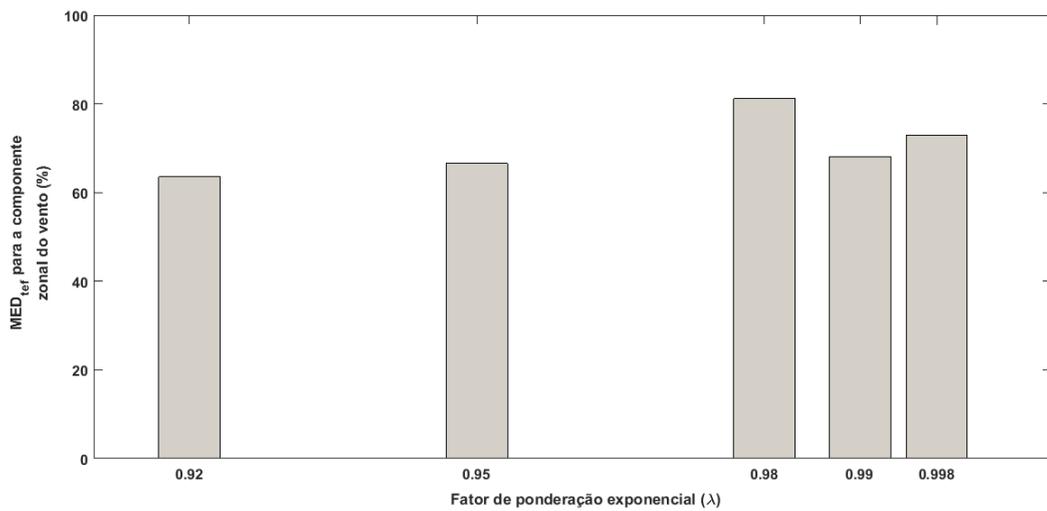


Figura 20 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a componente zonal do vento ( $uvel$ ), no ano de treinamento de 2008.

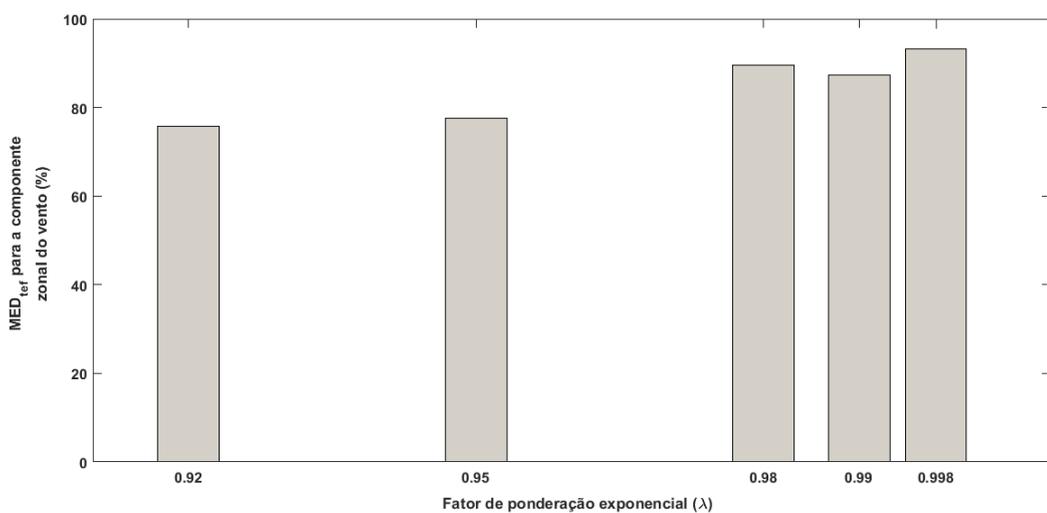


Figura 21 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a componente zonal do vento ( $uvel$ ), no ano de treinamento de 2009.

As Figuras 22 e 23 indicam os comportamentos da taxa de efetividade do MSE ( $T_{ef}$ ) para a componente zonal do vento, de acordo com os valores de  $\lambda$  testados (0,98 e 0,998) para os anos de treinamento de 2008 e 2009. Os percentuais de  $T_{ef}$  estão dispostos para todos os níveis de pressão atmosférica, portanto, podemos salientiar que a média das taxas para cada ano de treinamento valida a utilização dos valores de  $\lambda$  nos respectivos anos de treinamento, de acordo com as Figuras 20 e 21.

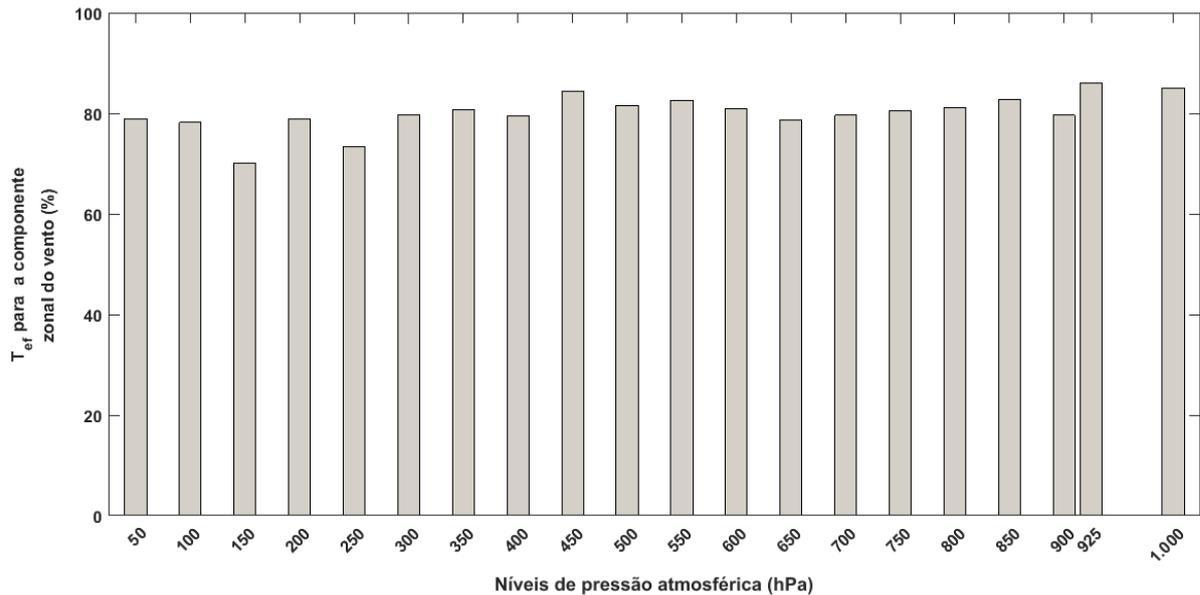


Figura 22 - Taxa de efetividade do MSE ( $T_{ef}$ ), para a componente zonal do vento, no ano de treinamento de 2008.

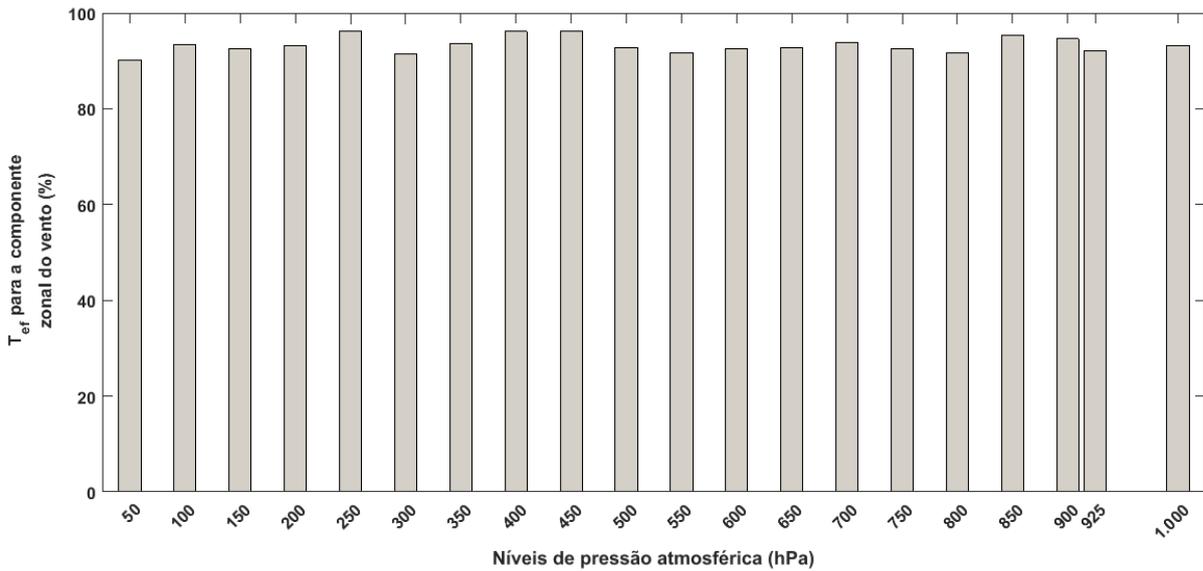


Figura 23 - Taxa de efetividade do MSE ( $T_{ef}$ ), para a componente zonal do vento, no ano de treinamento de 2009.

Assim, podemos fazer o mesmo para as outras variáveis prognósticas inseridas no trabalho. A partir disso, obtêm-se o  $\lambda$  que possui o maior valor de  $MED_{tef}$  em cada caso. A Tabela 1 apresenta o valor de  $\lambda$  que utilizamos para cada variável prognóstica no restante desta dissertação.

Tabela 1 - Fatores de ponderação exponencial ( $\lambda$ ) utilizados para os anos de treinamento de filtros adaptativos.

Variável prognóstica		Valores de $\lambda$	
Nome Eta	Significado	2008	2009
<i>uvel</i>	Comp. zonal do vento (m/s)	0,980	0,998
<i>vvel</i>	Comp. meridional do vento (m/s)	0,980	0,980
<i>zgeo</i>	Altura geopotencial (m/gp)	0,990	0,990
<i>umes</i>	Umidade específica (kg/kg)	0,990	0,990

## 4 RESULTADOS OBTIDOS

Este capítulo apresenta as métricas de avaliação aplicadas as quatro variáveis prognósticas: componentes meridional e zonal do vento (em  $m/s$ ), umidade específica (em  $kg/kg$ ) e altura geopotencial ( $mgp$ ). São apresentadas as reduções percentuais da média do erro quadrático médio ( $MSEM_p$ ) e as taxas de efetividade do MSE e do  $e_{max}$ . As ilustrações de regiões da superfície terrestre indicam o comportamento do desvio padrão do MSE e do  $e_{max}$  para um determinado nível de pressão atmosférica. Também são ilustrados séries temporais relativas ao modelo NCEP e ao modelo Eta antes e após o ajuste.

### 4.1 Componente meridional do vento

A Figura 24 indica os valores da redução da média do erro quadrático médio ( $MSEM_p$ ) para a componente meridional do vento ( $vvel$ ). É possível constatar que as porcentagens de redução para os dois anos de ajuste (2009 e 2010) apresentam valores em torno de 45% para o nível de pressão atmosférica 50 hPa (topo do modelo). Percebe-se que os valores de  $MSEM_p$  apresentam comportamentos semelhantes para o ano de ajuste de 2009, nos níveis de 100 hPa a 1.000 hPa. O ano de ajuste de 2010 apresenta valores muito oscilatórios de  $MSEM_p$  a partir do nível 100 hPa, sendo este o que obteve o menor valor de redução, em comparação com os outros níveis de pressão atmosférica.

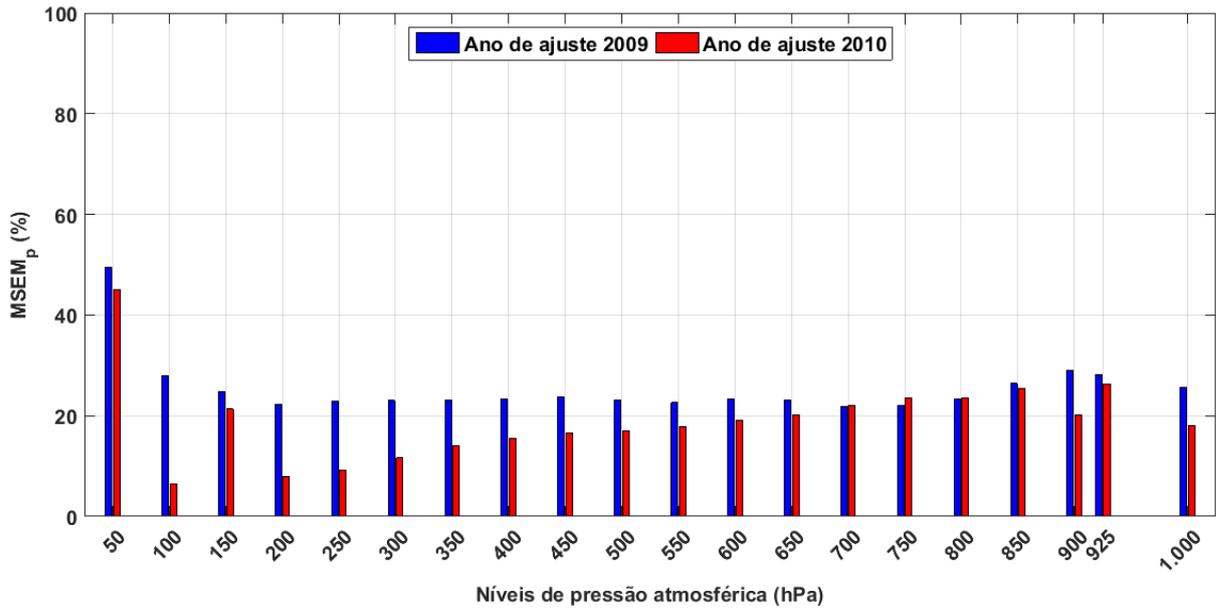


Figura 24 - Percentual de redução da média do erro quadrático médio ( $MSEM_p$ ) da componente meridional do vento ( $vvel$ ) para os anos de ajuste de 2009 e 2010.

Ao analisar a Figura 25, podemos avaliar que a efetividade na redução do MSE para a componente meridional do vento é relevante para os dois anos de ajuste. As taxas apresentam, em sua maioria, valores entre 50% a 80%, indicando que a utilização de filtros adaptativos minimizou de forma abrangente o erro quadrático médio para todos os níveis de pressão atmosférica. Para efeitos de comparação entre os anos de ajuste, os resultados para o ano de 2009 apresentam menores oscilações na taxa de efetividade do MSE. É possível averiguar que, para os níveis 50 hPa, 150 hPa, 700 hPa, 750 hPa, 800 hPa e 850 hPa, o comportamento das taxas são quase idênticos para os dois anos de ajuste.

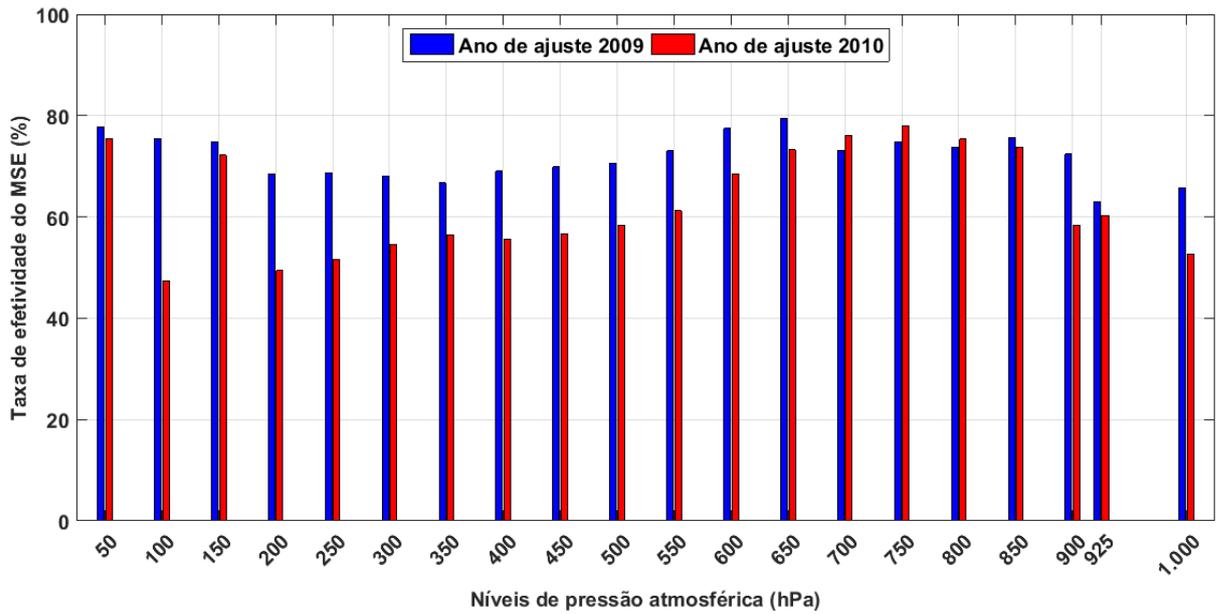


Figura 25 - Taxa de efetividade do erro quadrático médio (MSE) da componente meridional do vento ( $v_{vel}$ ) para os anos de ajuste de 2009 e 2010.

A Figura 26 indica que o ano de ajuste de 2009 apresenta taxas de efetividade do  $e_{max}$  mais uniformes que o ano de 2010. O nível atmosférico 50 hPa apresenta as melhores taxas para os dois anos, com valores em torno de 80%. Nota-se também que no ano de 2010 as taxas de efetividade tendem a ter um comportamento semelhante nos níveis de pressão atmosférica intermediários (200 a 550 hPa).

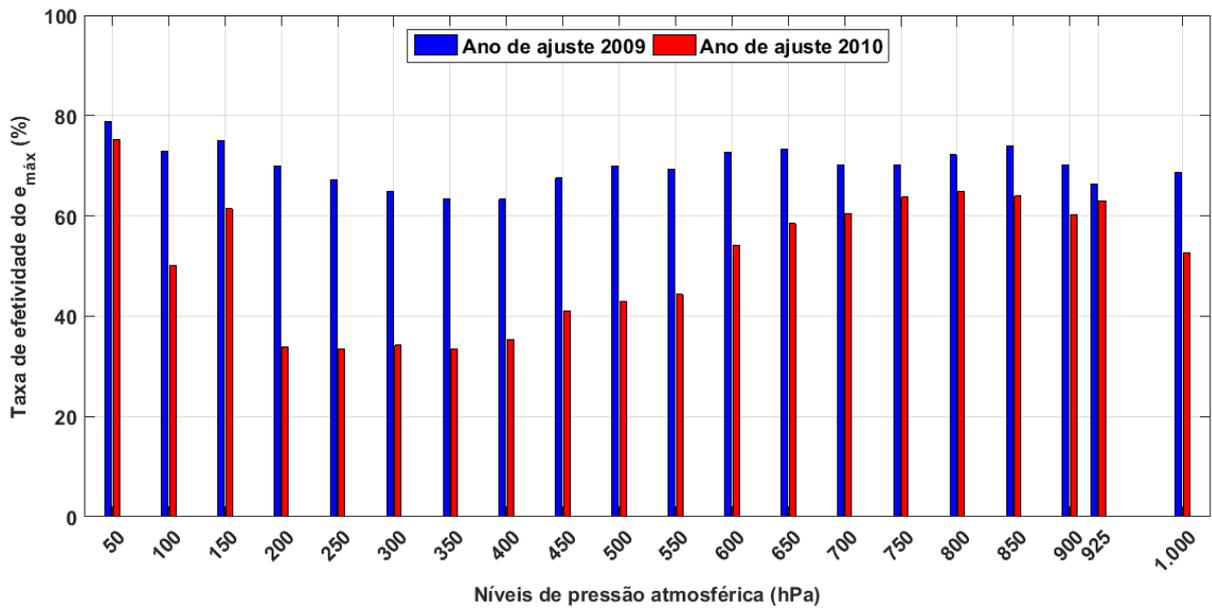


Figura 26 - Taxa de efetividade do erro máximo ( $e_{m\acute{a}x}$ ) da componente meridional do vento ( $vvel$ ) para os anos de ajuste de 2009 e 2010.

A Figura 27 exemplifica os comportamentos do desvio padrão do MSE e do  $e_{max}$  para a componente meridional do vento, antes e após a aplicação da filtragem adaptativa para o ano de 2009, a 1.000 hPa. A partir das Figuras 27(a) e 27(b), observa-se que ocorreu uma redução do desvio padrão do MSE para as regiões da América Central e perto do continente africano. Na região da América do Sul, as reduções dos erros estão concentradas em quase todo a sua extensão, principalmente no Brasil. As Figuras 27(c) e 27(d) indicam que há uma redução do  $e_{max}$  em partes da região da América do Sul, região norte da América Central e uma parte perto da África, o que corrobora o uso de filtros adaptativos de forma eficiente.

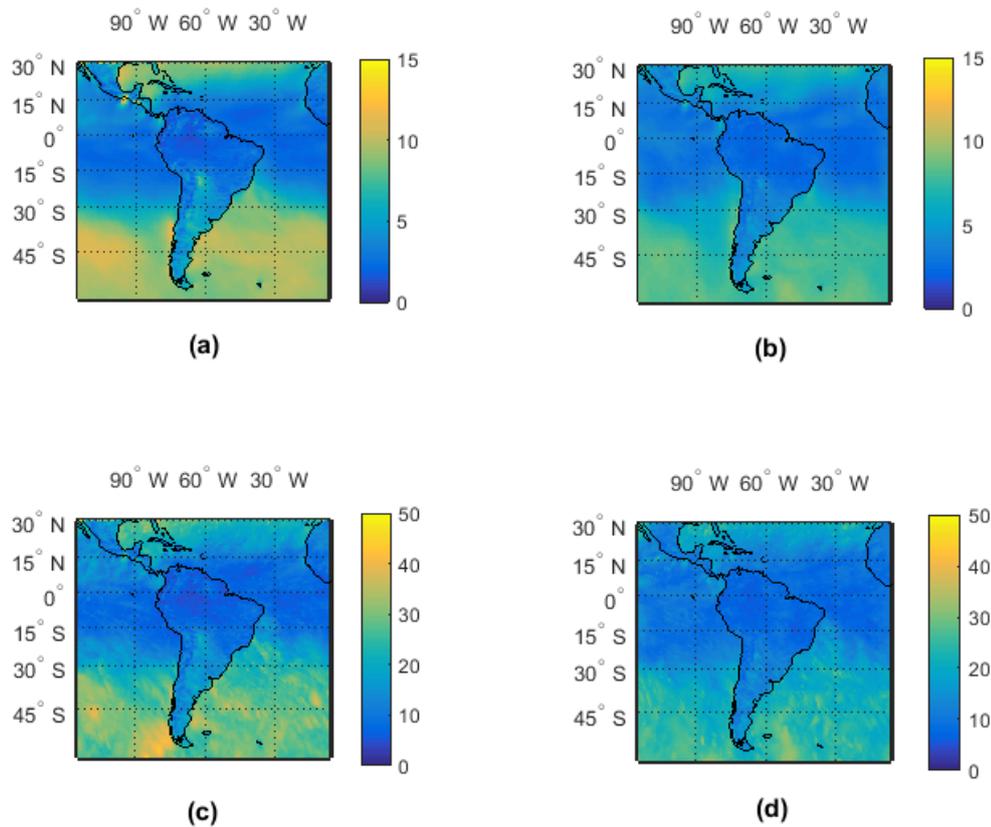


Figura 27 - Erros da previsão antes e após a utilização dos filtros propostos. Considere-se a componente meridional do vento (em  $m/s$ ) a 1000 hPa no ano de 2009: (a) desvio padrão do MSE entre o Eta e o NCEP (em  $m/s$ ); (b) desvio padrão do MSE após o ajuste do Eta (em  $m/s$ ); (c)  $e_{m\acute{a}x}$  entre o Eta e o NCEP (em  $m/s$ ) e (d)  $e_{m\acute{a}x}$  após o ajuste do Eta (em  $m/s$ ).

A Figura 28 apresenta as aplicações do desvio padrão do MSE e  $e_{max}$  para a componente meridional do vento, no ano de ajuste de 2010, no nível atmosférico 1.000 hPa. As Figuras 28(a) e 28(b) mostram que o comportamento do desvio padrão do MSE para a região da América do Sul, em geral, manteve-se estável antes e após o uso de filtros adaptativos. As reduções do desvio padrão do MSE foram maiores em partes da América Central e África. A partir das Figuras 28(c) e 28(d) podemos observar que o comportamento de valores de  $e_{max}$  apresentam reduções na região sul da América do Sul e alguns trechos na região norte. Também ocorre reduções de  $e_{max}$  em pequenas regiões da América Central e da África.

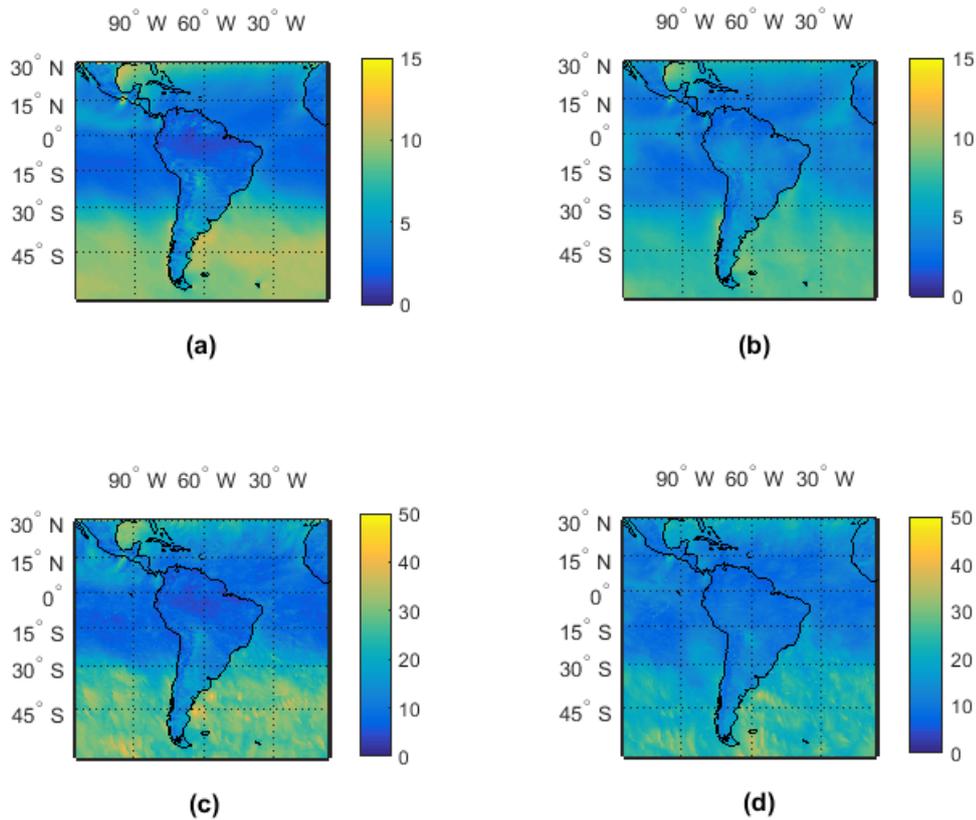


Figura 28 - Erros da previsão antes e após a utilização dos filtros propostos. Considere-se a componente meridional do vento (em  $m/s$ ) a 1000 hPa no ano de 2010: (a) desvio padrão do MSE entre o Eta e o NCEP (em  $m/s$ ); (b) desvio padrão do MSE após o ajuste do Eta (em  $m/s$ ); (c)  $e_{\max}$  entre o Eta e o NCEP (em  $m/s$ ) e (d)  $e_{\max}$  após o ajuste do Eta (em  $m/s$ ).

As Figuras 27 e 28 apresentam os comportamentos do desvio padrão do MSE e  $e_{\max}$  para a componente meridional do vento, nível de 1.000 hPa, nos dois anos de ajuste. É possível notar que as reduções de erros alcançadas concentram-se em maior parte na América do Sul, onde se aplica o modelo atmosférico regional Eta.

A Figura 29 apresenta séries temporais da componente meridional do vento para o modelo Eta antes e após o uso de filtros adaptativos e a série do NCEP correspondente, no ano de ajuste de 2009 e nível de pressão atmosférica 1.000 hPa. Cada série temporal possui 553 amostras. Nota-se que a implementação proposta neste trabalho consegue aproximar a curva referente à série Eta ajustada à curva da série NCEP, assim, é possível reduzir os erros de previsão climática em determinados trechos das séries temporais, o que colabora para o aumento da qualidade de previsão.

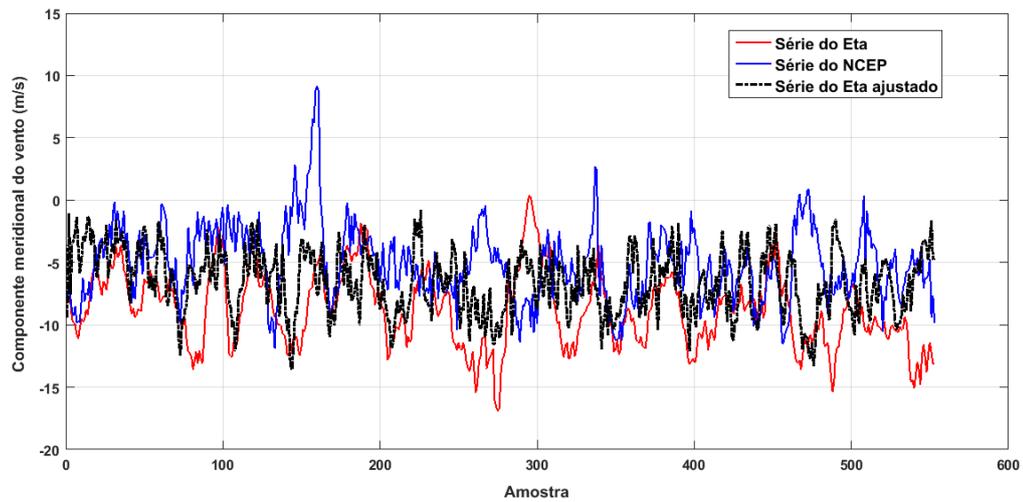


Figura 29 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 1.000 hPa, coordenadas geográficas dos pixels ( $50^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

A partir da Figura 30 podemos interpretar que, no ano de ajuste de 2010 e mesmo nível de pressão atmosférica, a componente meridional do vento apresenta aproximações significativas da série ajustada do modelo Eta em relação à série do NCEP. Observa-se que a série ajustada consegue reduzir os picos da série do Eta original. Os picos são frutos dos valores característicos da componente meridional do vento no intervalo de previsão (no caso, o período de horizonte sazonal de 13 de Dezembro de 2009 a 30 de Abril de 2010) com 553 amostras na série temporal. Também podemos visualizar que o início da curva do Eta ajustado apresenta ruído, isto pode ter ocorrido pelo fato de que os coeficientes ótimos do filtro adaptativo não cooperam para um comportamento adequado nas amostras iniciais da série.

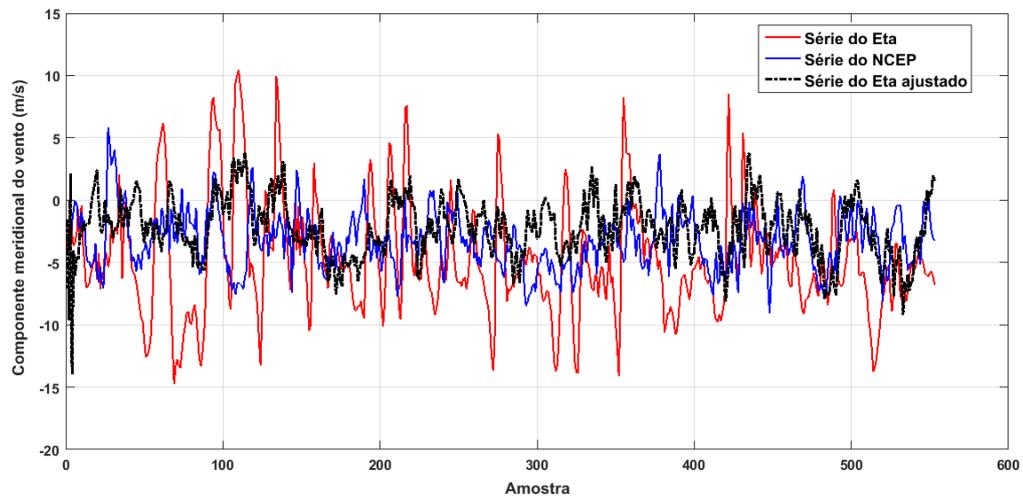


Figura 30 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 1.000 hPa, coordenadas geográficas dos pixels ( $55^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

#### 4.2 Componente zonal do vento

A Figura 31 apresenta os valores da redução da média do erro quadrático médio ( $MSEM_p$ ) para a componente zonal do vento. É possível interpretar que as porcentagens de redução dos dois anos de ajuste (2009 e 2010) são melhores no nível de pressão atmosférica 50 hPa (topo do modelo). Observa-se que os valores de  $MSEM_p$  possuem comportamentos oscilatórios nos dois anos. Os menores valores de  $MSEM_p$  ocorrem para os níveis 150 hPa e 200 hPa, do ano de ajuste de 2009. Os comportamentos das porcentagens de  $MSEM_p$  para os níveis de pressão de 400 hPa a 550 hPa são semelhantes nos dois anos de ajuste, o que também ocorre para os níveis 900 hPa e 925 hPa.

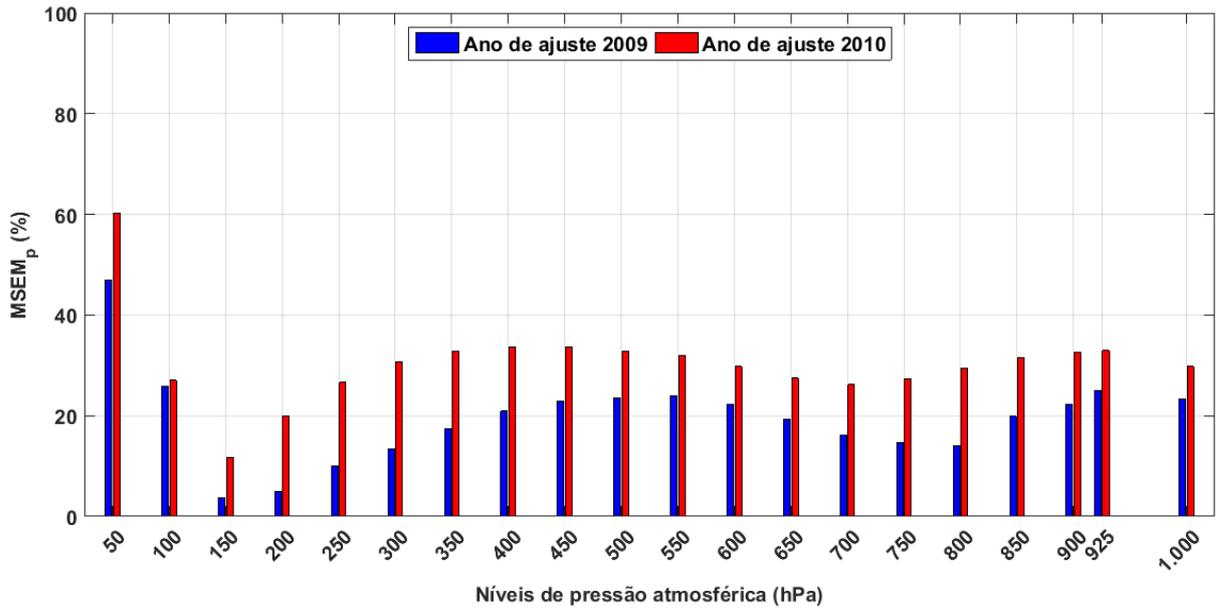


Figura 31 - Percentual de redução da média do erro quadrático médio ( $MSEM_p$ ) da componente zonal do vento ( $uvel$ ) para os anos de ajuste de 2009 e 2010.

Na Figura 32, tem-se a taxa de efetividade do  $MSE$  para a componente zonal do vento, nos dois anos de ajuste. Em sua grande maioria, com valores compreendidos entre 55% a 95%, indicando que o uso de filtros adaptativos conseguiu reduzir os erros quadráticos médios em todos os níveis de pressão atmosférica. As melhores taxas, comparando os dois anos, estão concentradas nos níveis de pressão intermediários, entre 450 hPa e 650 hPa, com valores que variam entre 80% a 95%.

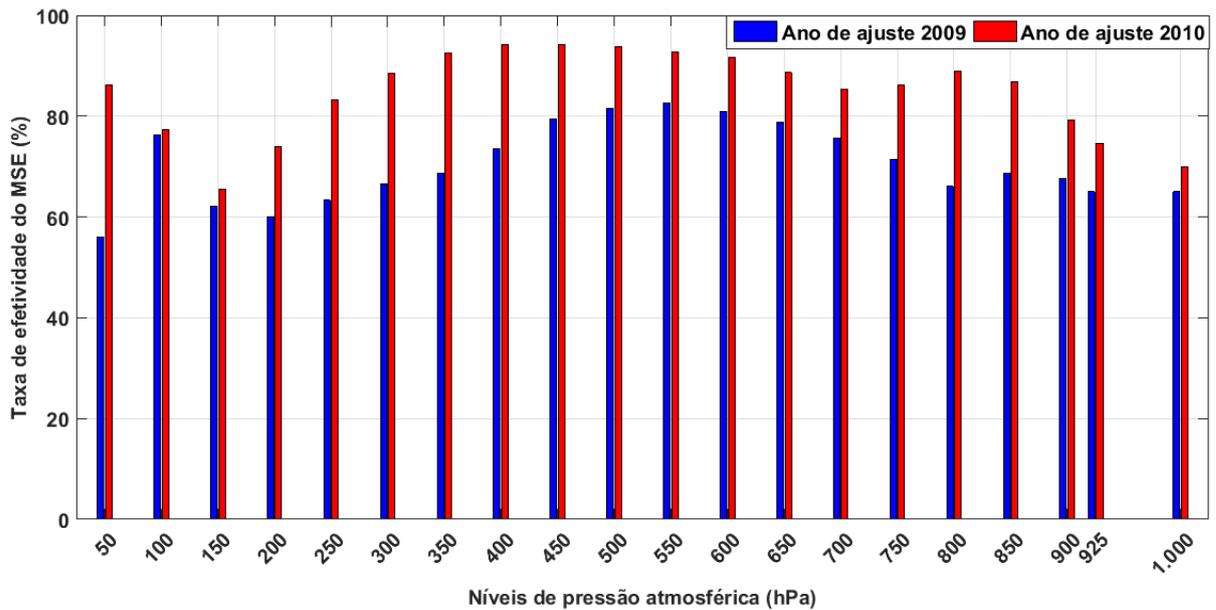


Figura 32 - Taxa de efetividade do erro quadrático médio ( $MSE$ ) da componente zonal do vento ( $uvel$ ) para os anos de ajuste de 2009 e 2010.

A Figura 33 ilustra as taxas de efetividade do  $e_{max}$  para a componente zonal do vento nos dois anos. As maiores efetividades são obtidas no ano de 2010, com valores entre 70% a 90%, indicando um bom desempenho das taxas em todos os níveis de pressão atmosférica. Os menores valores ocorrem para os níveis de 50 hPa e 150 hPa para o ano de 2009, porém, ao analisar de forma geral as taxas de efetividade do  $e_{max}$  calculadas em todos os níveis de pressão atmosférica, podemos concluir que a utilização da filtragem adaptativa no domínio da frequência contribui para a redução dos valores de  $e_{max}$  nas séries temporais.

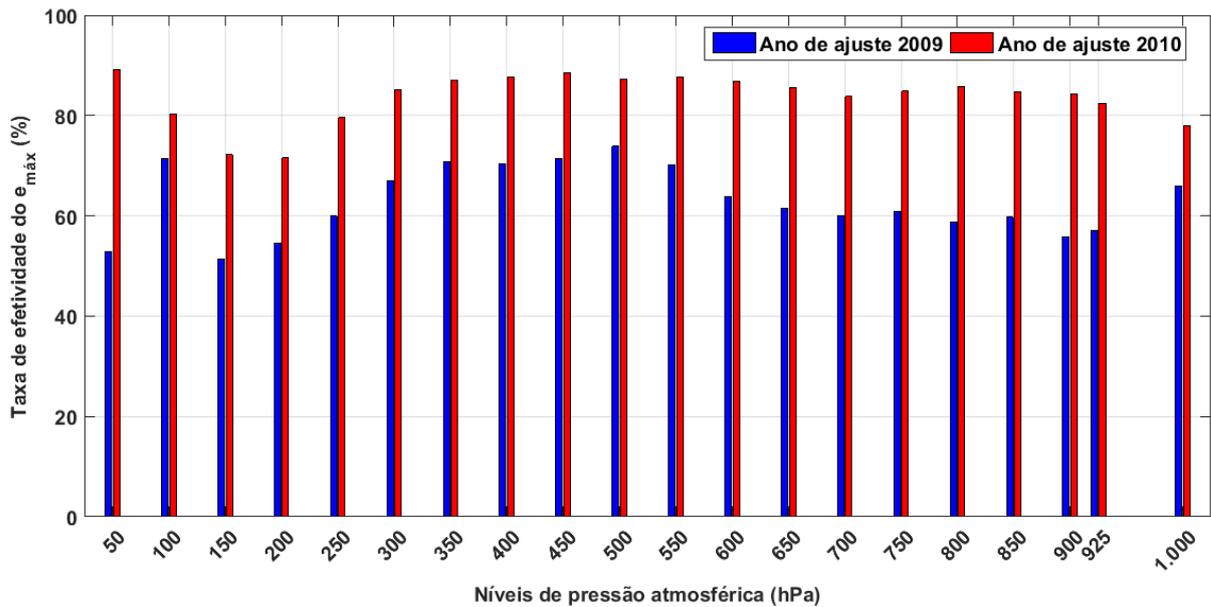


Figura 33 - Taxa de efetividade do erro máximo ( $e_{\text{máx}}$ ) da componente zonal do vento ( $u_{\text{vel}}$ ) para os anos de ajuste de 2009 e 2010.

A Figura 34 apresenta os comportamentos do desvio padrão do MSE e  $e_{\text{max}}$  para a componente zonal do vento, antes e após a aplicação dos filtros adaptativos no ano de 2009, a 50 hPa. A partir das Figuras 34(a) e 34(b), observa-se que ocorreu uma redução do desvio padrão do MSE nas regiões norte e sul da América do Sul, porém isto não é evidenciado na zona central. Em alguns trechos, principalmente no Brasil, há um aumento dos valores dos desvios padrões nesta região. As Figuras 34(c) e 34(d) indicam que há uma redução de valores do  $e_{\text{max}}$  em partes da região da América Central, uma parte do continente africano e a região sul da América do Sul, mas também ocorre aumento de valores do  $e_{\text{max}}$  na zona central.

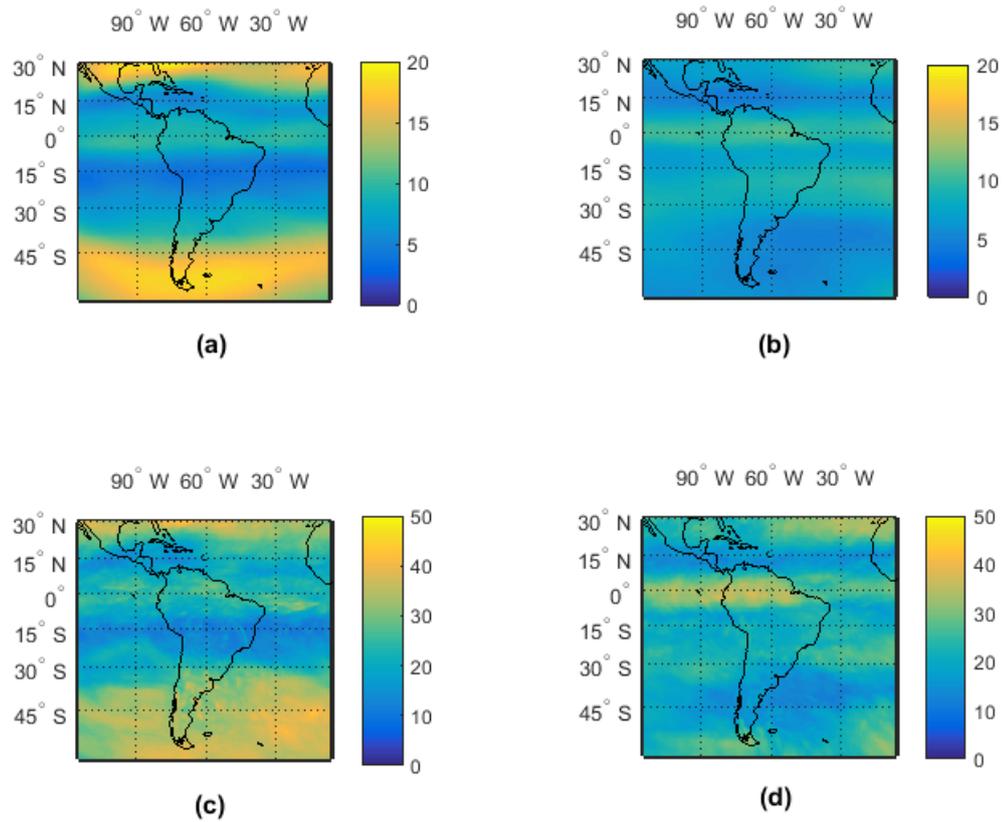


Figura 34 - Erros da previsão antes e após a utilização dos filtros propostos. Considera-se a componente zonal do vento (em  $m/s$ ) a 50 hPa no ano de 2009: (a) desvio padrão do MSE entre o Eta e o NCEP (em  $m/s$ ); (b) desvio padrão do MSE após o ajuste do Eta (em  $m/s$ ); (c)  $e_{\text{máx}}$  entre o Eta e o NCEP (em  $m/s$ ) e (d)  $e_{\text{máx}}$  após o ajuste do Eta (em  $m/s$ ).

A Figura 35 apresenta as aplicações de desvio padrão do MSE e  $e_{\text{max}}$  para a componente zonal do vento, no ano de ajuste de 2010, nível atmosférico 50 hPa. As Figuras 35(a) e 35(b) mostram que o comportamento do desvio padrão do MSE para a região central da América do Sul obteve valores de redução significativos, o mesmo ocorre também para as partes da América Central, da África e a região sul da América do Sul. As Figuras 35(c) e 35(d) ilustram que o comportamento da redução dos valores de  $e_{\text{max}}$  também é alterado na parte central e sul da América do Sul, principalmente nas regiões Norte e Nordeste do Brasil e países adjacentes.

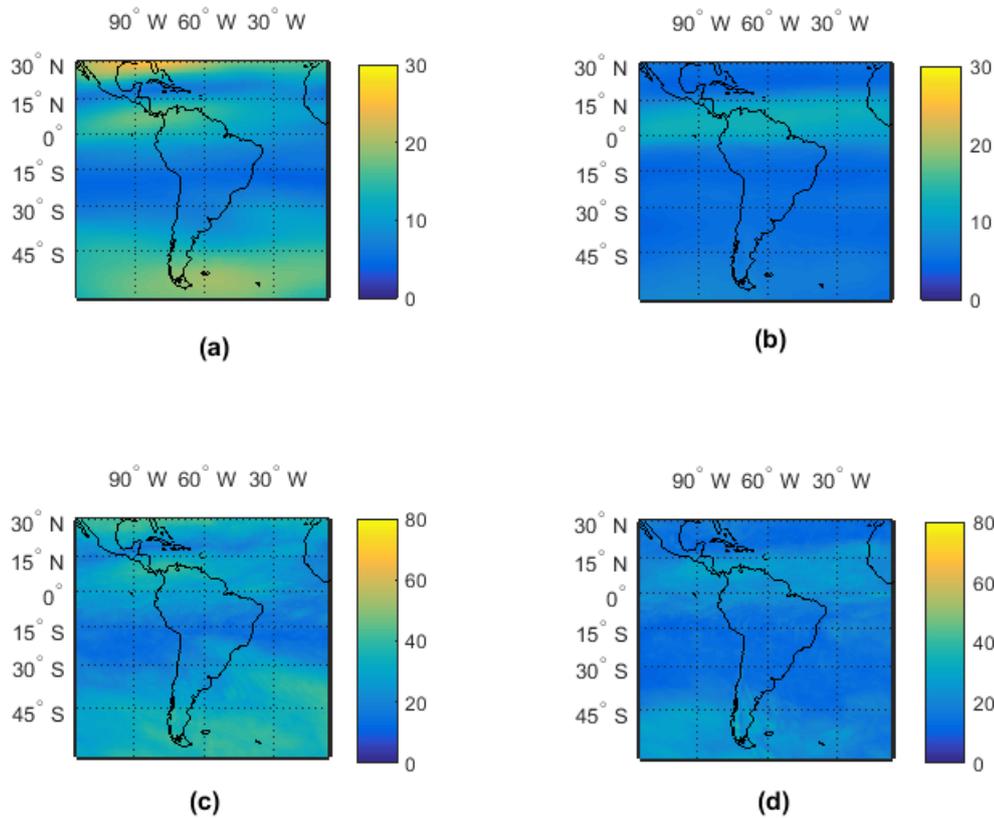


Figura 35 - Erros da previsão antes e após a utilização dos filtros propostos. Considera-se a componente zonal do vento (em  $m/s$ ) a 50 hPa no ano de 2010: (a) desvio padrão do MSE entre o Eta e o NCEP (em  $m/s$ ); (b) desvio padrão do MSE após o ajuste do Eta (em  $m/s$ ); (c)  $e_{\max}$  entre o Eta e o NCEP (em  $m/s$ ) e (d)  $e_{\max}$  após o ajuste do Eta (em  $m/s$ ).

A Figura 36 ilustra séries temporais do modelo Eta antes e após a utilização de filtros adaptativos e a série do NCEP correspondente, aplicadas para a componente zonal do vento, no ano de ajuste de 2009 e nível de pressão atmosférica 50 hPa. Observa-se que há uma aproximação da curva referente à série do Eta ajustado com a curva da série do NCEP, o que implica em menores erros, com isso, pode-se obter uma melhora na qualidade de previsão. A série do Eta ajustado também apresenta ruído no início da série, o que pode indicar que os coeficientes ótimos do filtro adaptativo não tiveram uma boa aplicação nas amostrais iniciais da série.

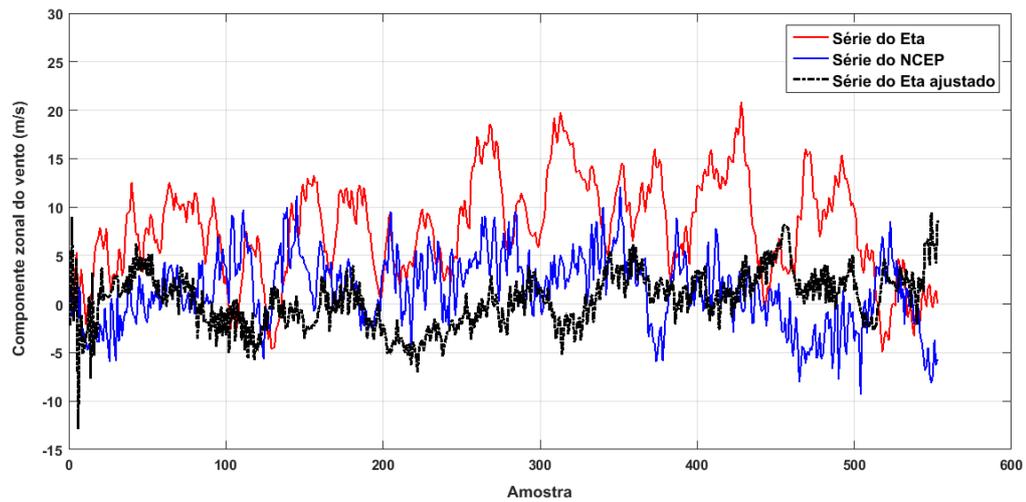


Figura 36 - Séries temporais para a componente zonal do vento ( $uvel$ ) a 50 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

Ao analisar a Figura 37, percebe-se que há uma discrepância entre a série do NCEP e a série do modelo Eta não ajustado, para a componente zonal do vento, no nível de pressão atmosférica 50 hPa, no ano de ajuste de 2010. Quando ocorre o ajuste da série temporal do Eta, nota-se que a discrepância sofre uma redução considerável e que as últimas trezentas amostras da série do Eta ajustado aproximam-se da série do NCEP de forma contundente, acarretando em diminuição de erros de previsão climática.

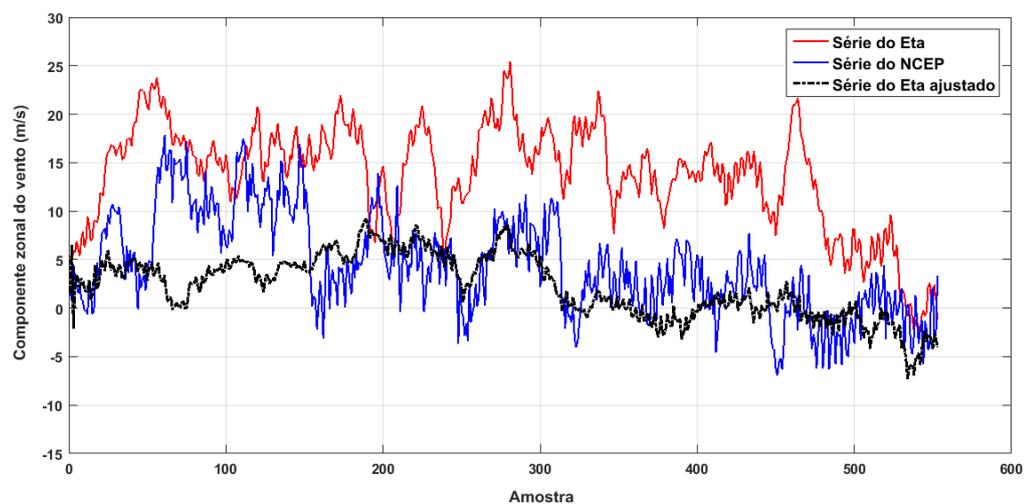


Figura 37 - Séries temporais para a componente zonal do vento ( $uvel$ ) a 50 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

### 4.3 Altura geopotencial

Na Figura 38 podemos notar que as maiores reduções percentuais da média do erro quadrático médio ( $MSEM_p$ ) para a altura geopotencial ocorrem no nível de pressão atmosférica 50 hPa, com valores em torno de 80%, nos dois anos de ajuste. É possível observar que os valores de  $MSEM_p$  apresentam comportamentos equivalentes se compararmos as reduções em cada nível de pressão, nos anos de ajuste de 2009 e 2010.

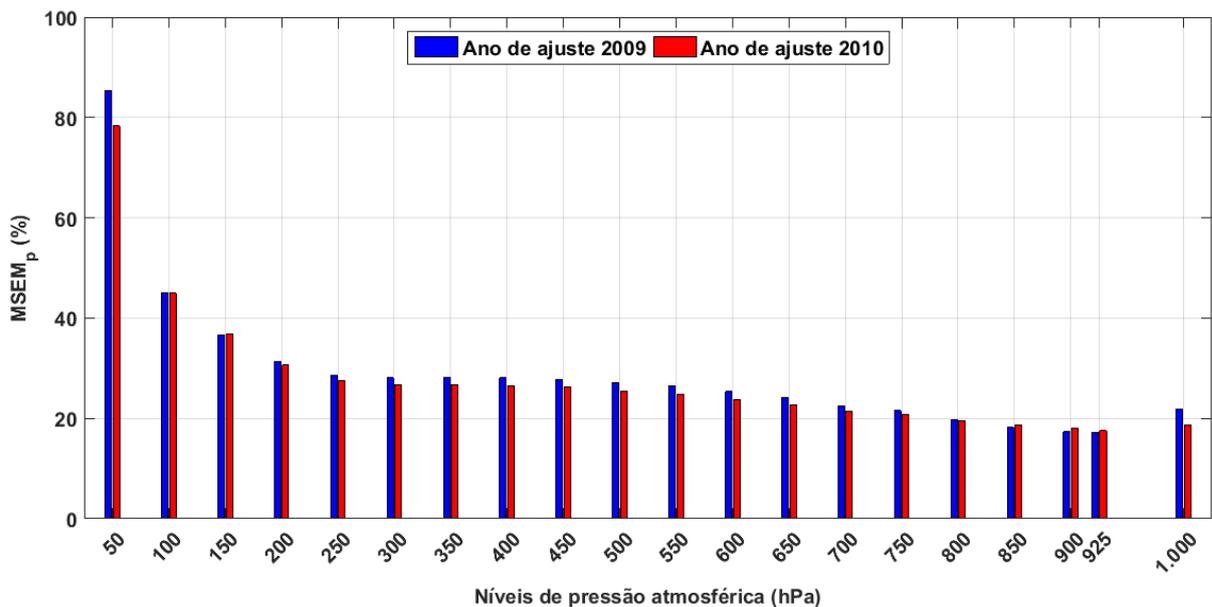


Figura 38 - Percentual de redução da média do erro quadrático médio ( $MSEM_p$ ) da altura geopotencial ( $z_{geo}$ ) para os anos de ajuste de 2009 e 2010.

A Figura 39 ilustra resultados interessantes para a taxa de efetividade do erro quadrático médio (MSE) da altura geopotencial. O nível de pressão atmosférica 50 hPa apresenta taxas de aproximadamente 100% para os dois anos de análise. Também é possível averiguar que somente os quatro níveis de pressão (100 hPa, 900 hPa, 925 hPa e 1000 hPa) possuem valores de taxa de efetividade perto da faixa de 60%, o que indica a efetividade da proposta para a redução do erro.

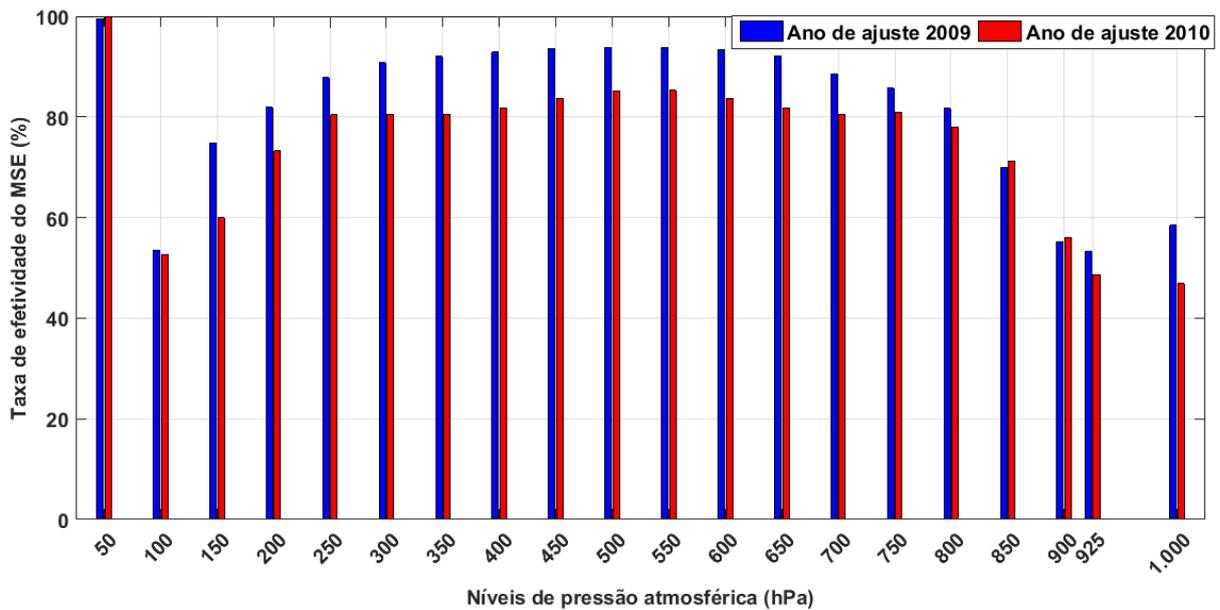


Figura 39 - Taxa de efetividade do erro quadrático médio (MSE) da altura geopotencial ( $z_{geo}$ ) para os anos de ajuste de 2009 e 2010.

A Figura 40 indica que o nível de pressão atmosférica 50 hPa apresenta valores em torno de 100% para taxa de efetividade do erro máximo ( $e_{max}$ ), nos anos de ajuste analisados. Os outros níveis apresentam valores entre 20% a 50%, portanto, de forma geral, podemos concluir que para o ano de ajuste de 2009 consegue-se maior efetividade na redução do  $e_{max}$  que para o ano de ajuste de 2010.

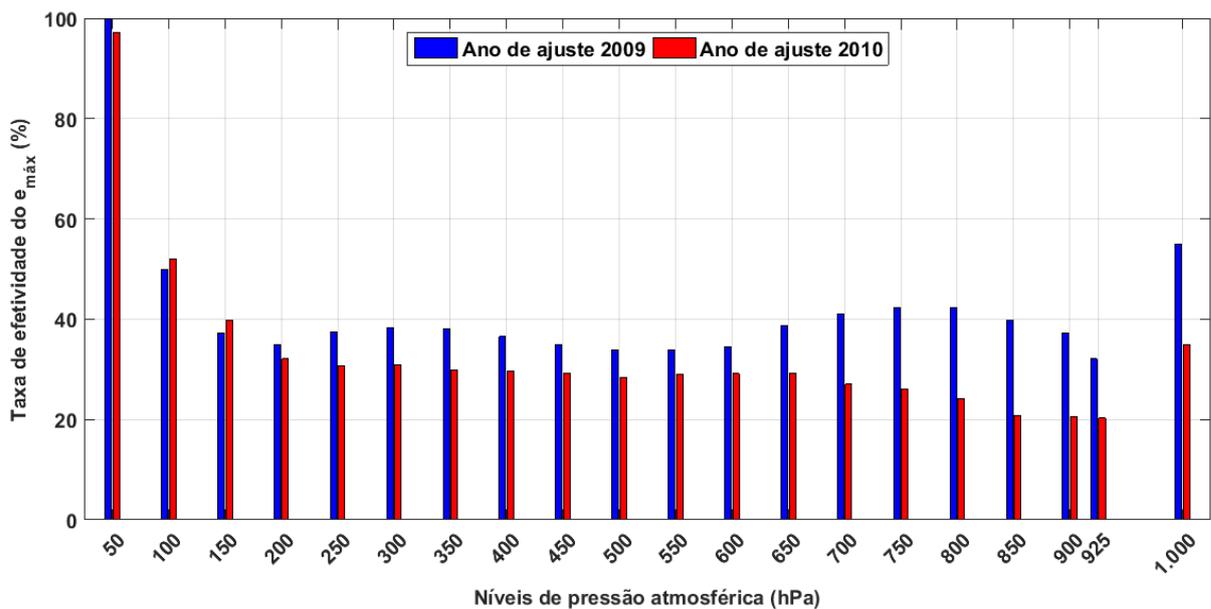


Figura 40 - Taxa de efetividade do erro máximo ( $e_{m\acute{a}x}$ ) da altura geopotencial ( $z_{geo}$ ) para os anos de ajuste de 2009 e 2010.

A Figura 41 apresenta o desvio padrão do MSE e  $e_{max}$  para a altura geopotencial, no ano de ajuste de 2009, nível atmosférico 50 hPa. As Figuras 41(a) e 41(b) mostram que obteve-se redução significativa do desvio padrão do MSE em quase toda a região de análise. As Figuras 41(c) e 41(d) ilustram que a redução do  $e_{max}$  ocorre em toda a América do Sul e também nos trechos correspondentes à América Central, resultando em valores menores de  $e_{max}$  para o ano de 2009.

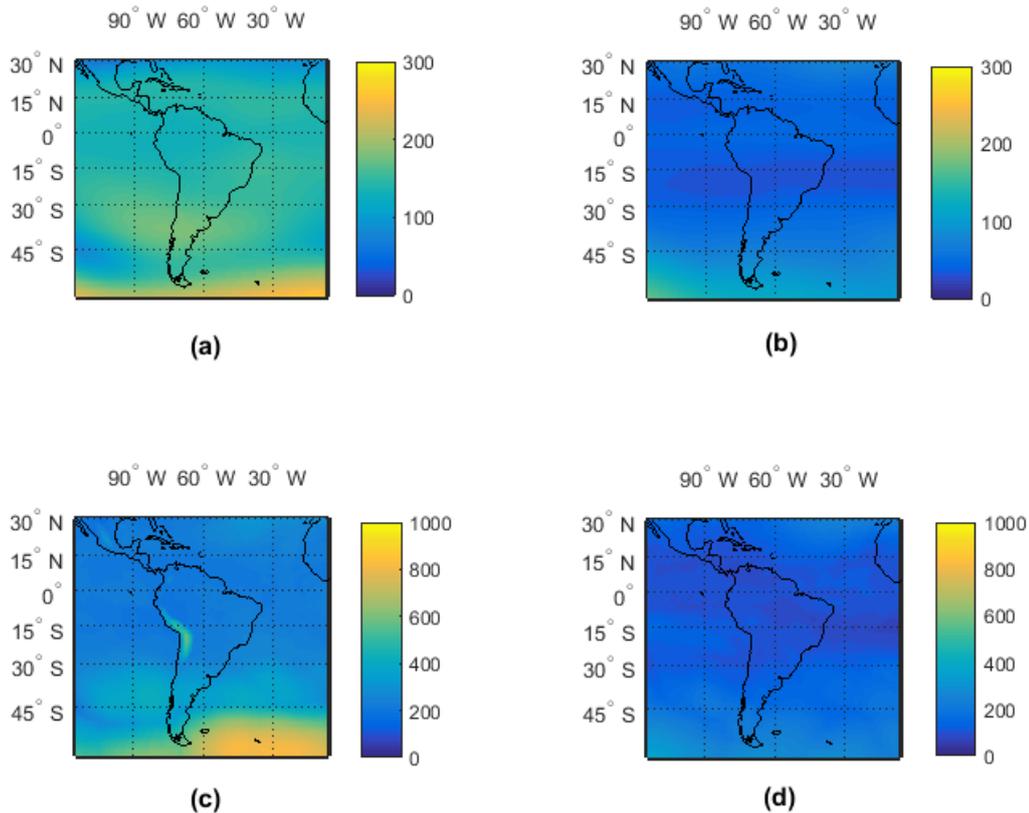


Figura 41 - Erros da previsão antes e após a utilização dos filtros propostos. Considera-se a altura geopotencial (em  $m_{gp}$ ) a 50 hPa no ano de 2009: (a) desvio padrão do MSE entre o Eta e o NCEP (em  $m_{gp}$ ); (b) desvio padrão do MSE após o ajuste do Eta (em  $m_{gp}$ ); (c)  $e_{m\acute{a}x}$  entre o Eta e o NCEP (em  $m_{gp}$ ) e (d)  $e_{m\acute{a}x}$  após o ajuste do Eta (em  $m_{gp}$ ).

A Figura 42 apresenta o desvio padrão do MSE e  $e_{max}$  da altura geopotencial, no ano de ajuste de 2010, nível atmosférico 50 hPa. As Figuras 42(a) e 42(b) ilustram que obteve-se valores de redução significativa do desvio padrão do MSE para toda a região de análise. As Figuras 42(c) e 42(d) indicam que a redução do  $e_{max}$  apresenta menores valores em determinados trechos da América do Sul e em partes da América Central e África.

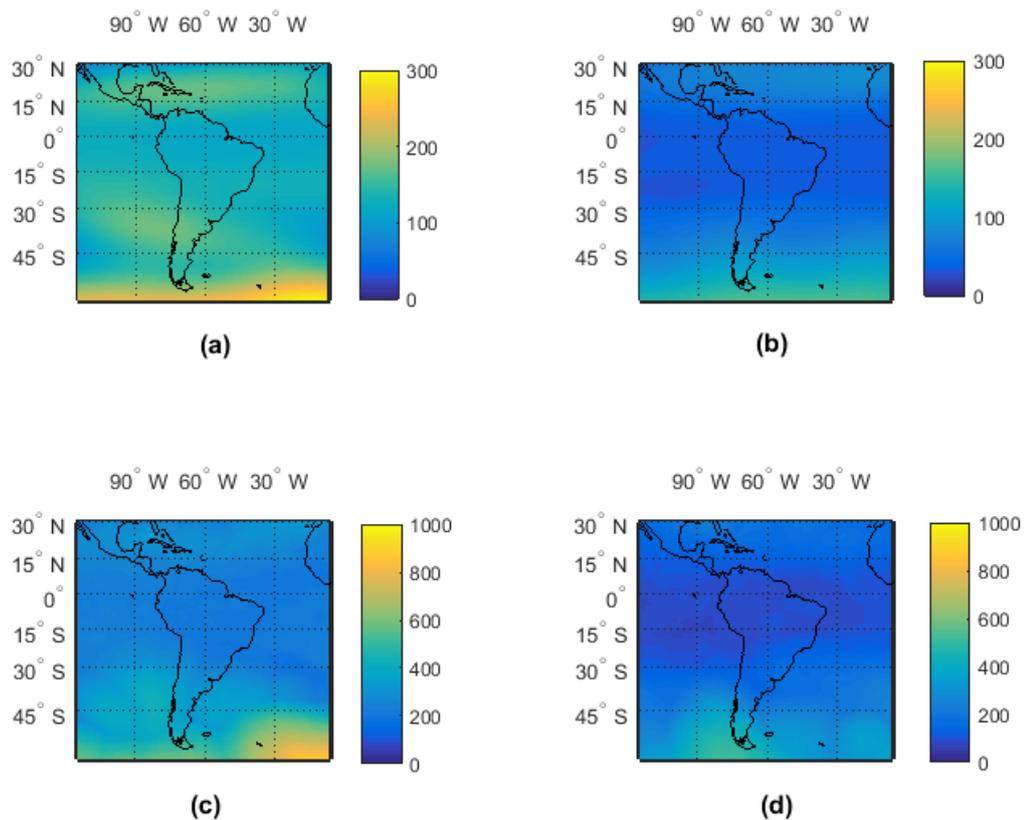


Figura 42 - Erros da previsão antes e após a utilização dos filtros propostos. Considera-se a altura geopotencial (em *mgp*) a 50 hPa no ano de 2010: (a) desvio padrão do MSE entre o Eta e o NCEP (em *mgp*); (b) desvio padrão do MSE após o ajuste do Eta (em *mgp*); (c)  $e_{\text{máx}}$  entre o Eta e o NCEP (em *mgp*) e (d)  $e_{\text{máx}}$  após o ajuste do Eta (em *mgp*).

Ao analisar a Figura 43, percebe-se que há uma diferença entre a série do NCEP e a série do modelo Eta não ajustado, na altura geopotencial, nível de pressão atmosférica 50 hPa, no ano de ajuste de 2009. A partir do ajuste da série do modelo Eta, percebe-se que esta diferença sofre uma redução relevante e que as amostras da série do Eta ajustado aproximam-se das amostras da série do NCEP de forma incisiva, o que auxilia a minimização de erros de previsão climática.

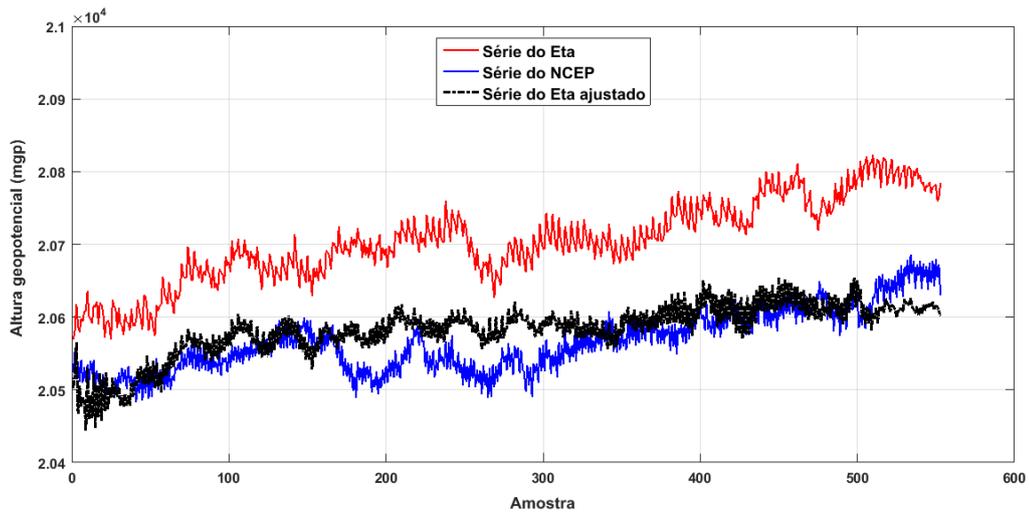


Figura 43 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 50 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

A Figura 44 ilustra séries temporais do modelo Eta antes e após o ajuste e a série do NCEP correspondente, para a altura geopotencial, no ano de ajuste de 2010 e nível de pressão atmosférica 50 hPa. Observa-se que a implementação proposta neste trabalho consegue aproximar a curva referente à série do Eta ajustado da curva da série do NCEP, assim, é possível reduzir os erros de previsão climática.

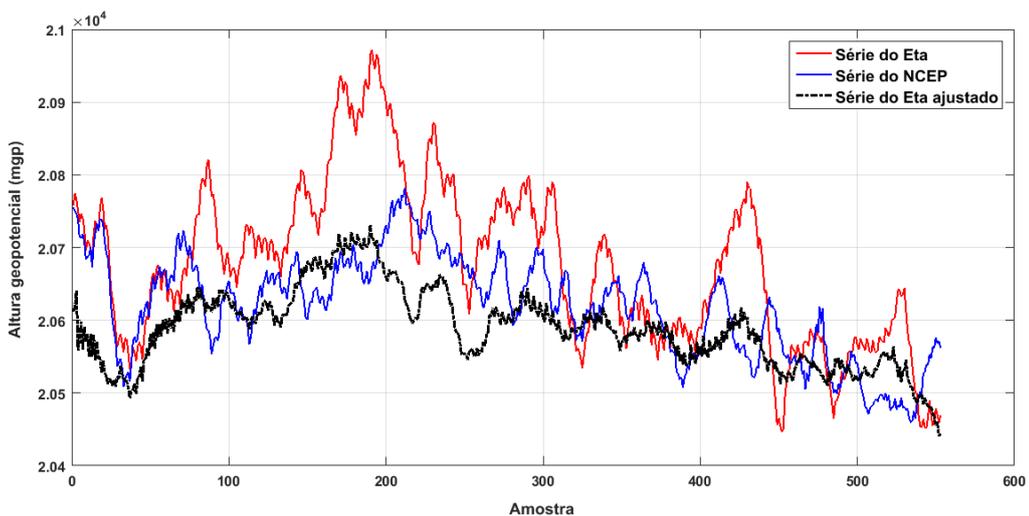


Figura 44 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 50 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

#### 4.4 Umidade específica

A Figura 45 apresenta maiores reduções da média do erro quadrático médio ( $MSEM_p$ ) para a umidade específica, nos níveis de pressão atmosférica (850 hPa, 900 hPa e 925 hPa) que estão mais próximos do nível do mar (base do modelo). Esses níveis apresentam redução em torno de 40%. Os níveis restantes apresentam reduções em torno de 15% a 30%. Os valores de  $MSEM_p$  culminam em características oscilatórias para todos os níveis de pressão atmosférica da umidade específica.

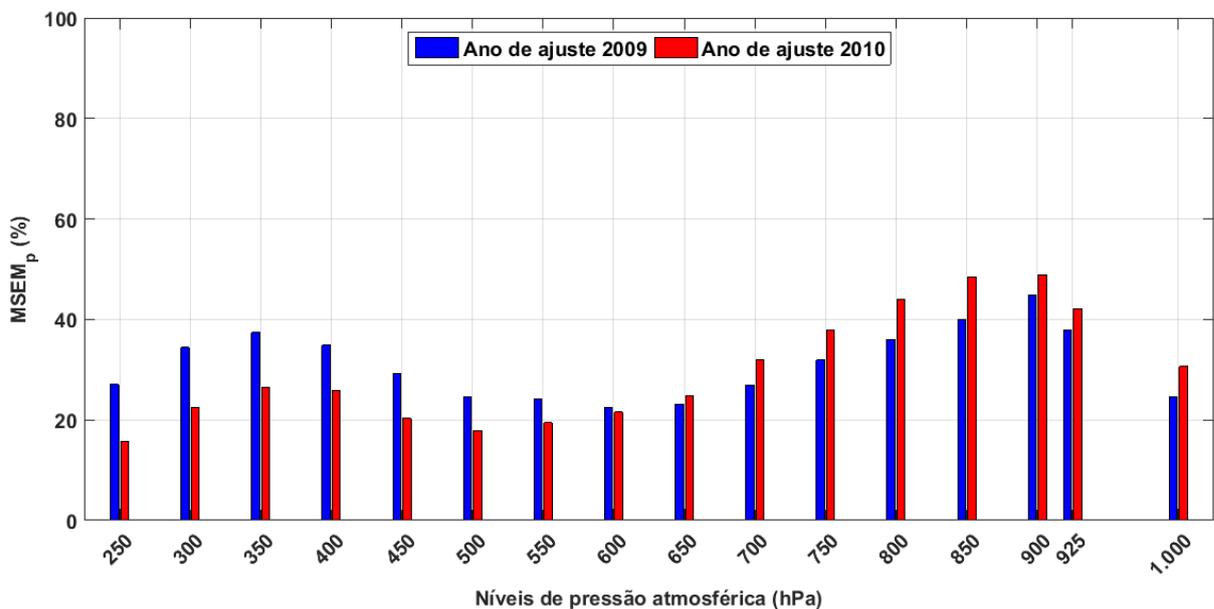


Figura 45 - Percentual de redução da média do erro quadrático médio ( $MSEM_p$ ) da umidade específica ( $umes$ ) para os anos de ajuste de 2009 e 2010.

A Figura 46 indica que a taxa de efetividade do erro quadrático médio (MSE) para a umidade específica é consistente em todos os níveis de pressão atmosférica, com valores em torno de 80% a 90%, exceto para o nível de 1.000 hPa (nível mais próximo do mar), que apresenta valores em torno de 65% e 75%, nos dois anos de ajuste.

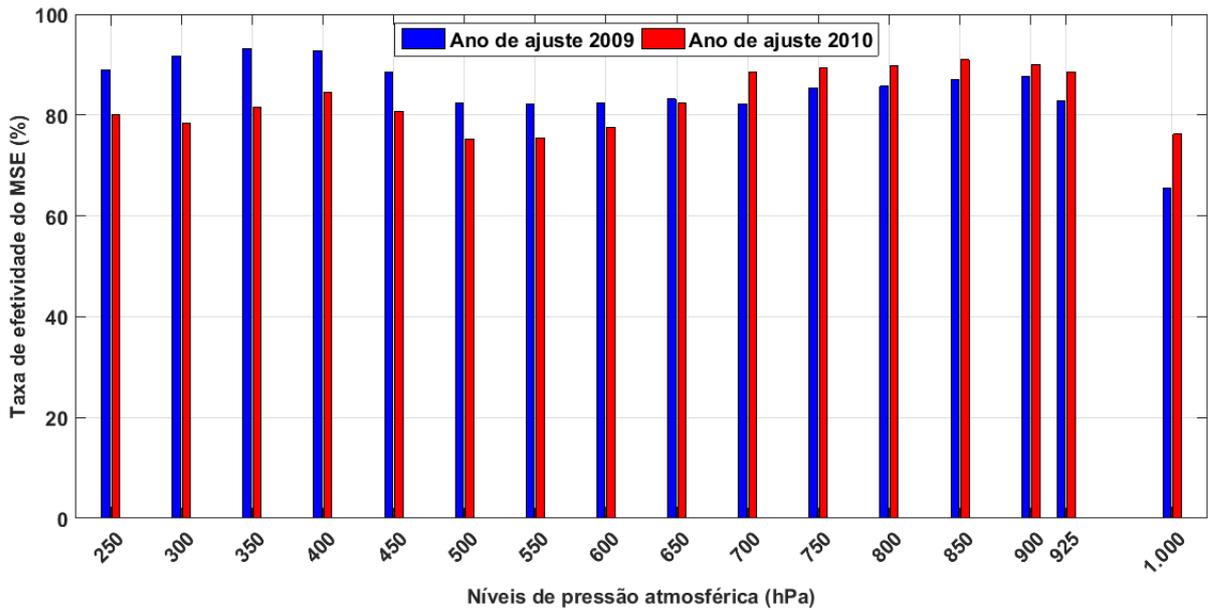


Figura 46 - Taxa de efetividade do erro quadrático médio (MSE) da umidade específica ( $umes$ ) para os anos de ajuste de 2009 e 2010.

Ao analisar a Figura 47, podemos avaliar que a taxa de efetividade do MSE para a umidade específica é razoável, nos dois anos de ajuste. As taxas apresentam, em sua maioria, valores entre 60% a 80%, exceto para o nível de 1.000 hPa, com taxas em torno de 30% a 40%. Para efeitos de comparação entre os anos de ajuste, o ano de 2009 apresenta menores oscilações da taxa de efetividade do  $e_{max}$ .

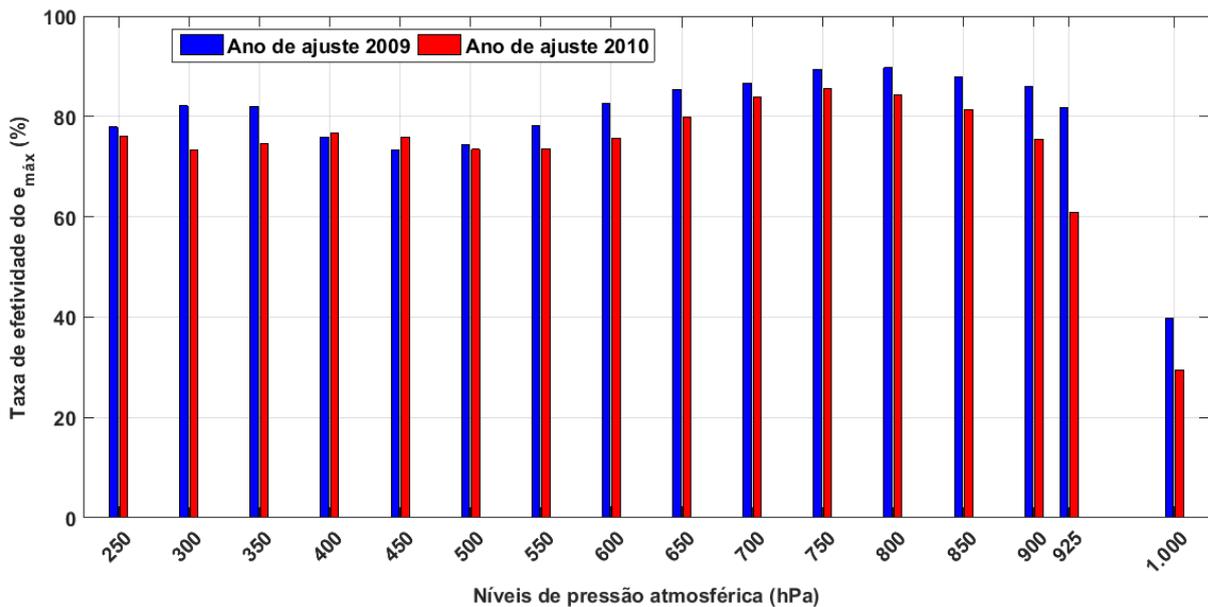


Figura 47 - Taxa de efetividade do erro máximo ( $e_{m\acute{a}x}$ ) da umidade específica ( $umes$ ) para os anos de ajuste de 2009 e 2010.

A Figura 48 apresenta o desvio padrão do MSE e o  $e_{max}$  para a umidade específica, no ano de ajuste de 2009, nível atmosférico 650 hPa. As Figuras 48(a) e 48(b) mostram que os desvios padrões de MSE tiveram redução em alguns trechos da América do Sul e partes da América Central. As Figuras 48(c) e 48(d) ilustram que o comportamento da redução dos valores de  $e_{max}$  possui poucas alterações, em compensação há pequenos trechos da América do Sul nas quais se observou a redução de valores de  $e_{max}$ .

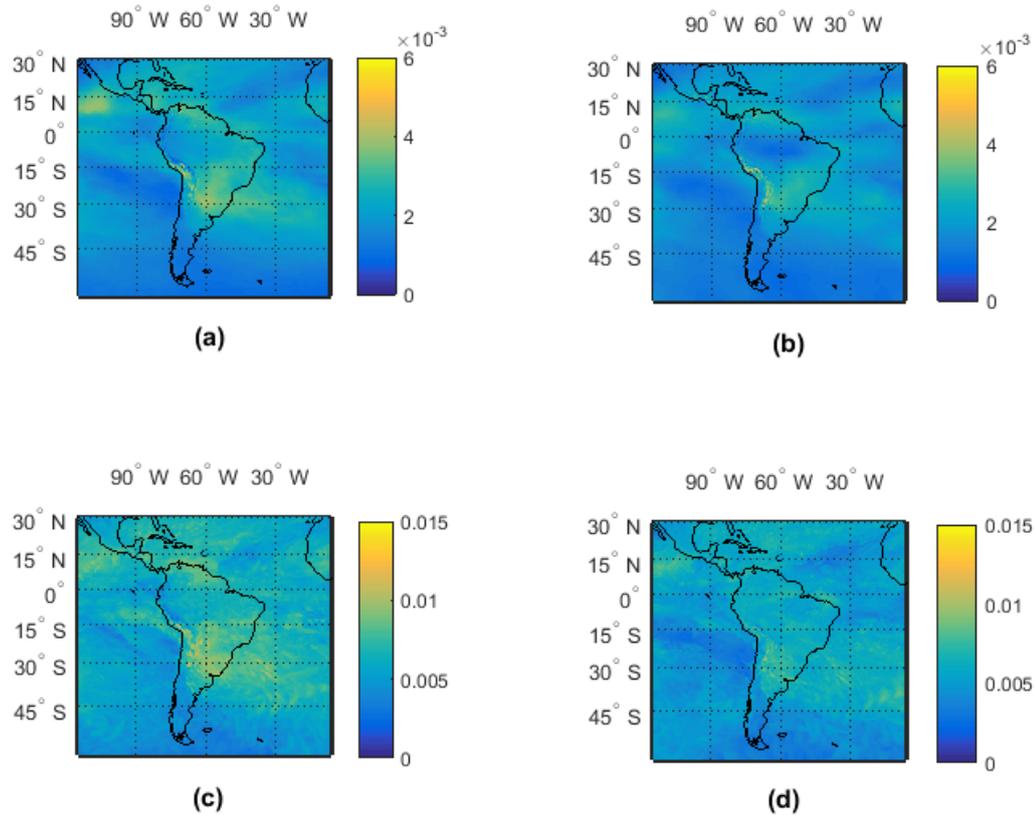


Figura 48 - Erros da previsão antes e após a utilização dos filtros propostos. Considera-se a umidade específica (em  $kg/kg$ ) a 650 hPa no ano de 2009: (a) desvio padrão do MSE entre o Eta e o NCEP (em  $kg/kg$ ); (b) desvio padrão do MSE após o ajuste do Eta (em  $kg/kg$ ); (c)  $e_{m\acute{a}x}$  entre o Eta e o NCEP (em  $kg/kg$ ) e (d)  $e_{m\acute{a}x}$  após o ajuste do Eta (em  $kg/kg$ ).

A Figura 49 apresenta o desvio padrão do MSE e o  $e_{max}$  para a umidade específica, no ano de ajuste de 2010, nível atmosférico 650 hPa. As Figuras 49(a) e 49(b) ilustram que os valores de MSE tiveram redução em alguns trechos da região central da América do Sul, partes da América Central e da África. As Figuras 49(c) e 49(d) indicam redução dos valores de  $e_{max}$  na região sul da América do Sul e partes da América Central.

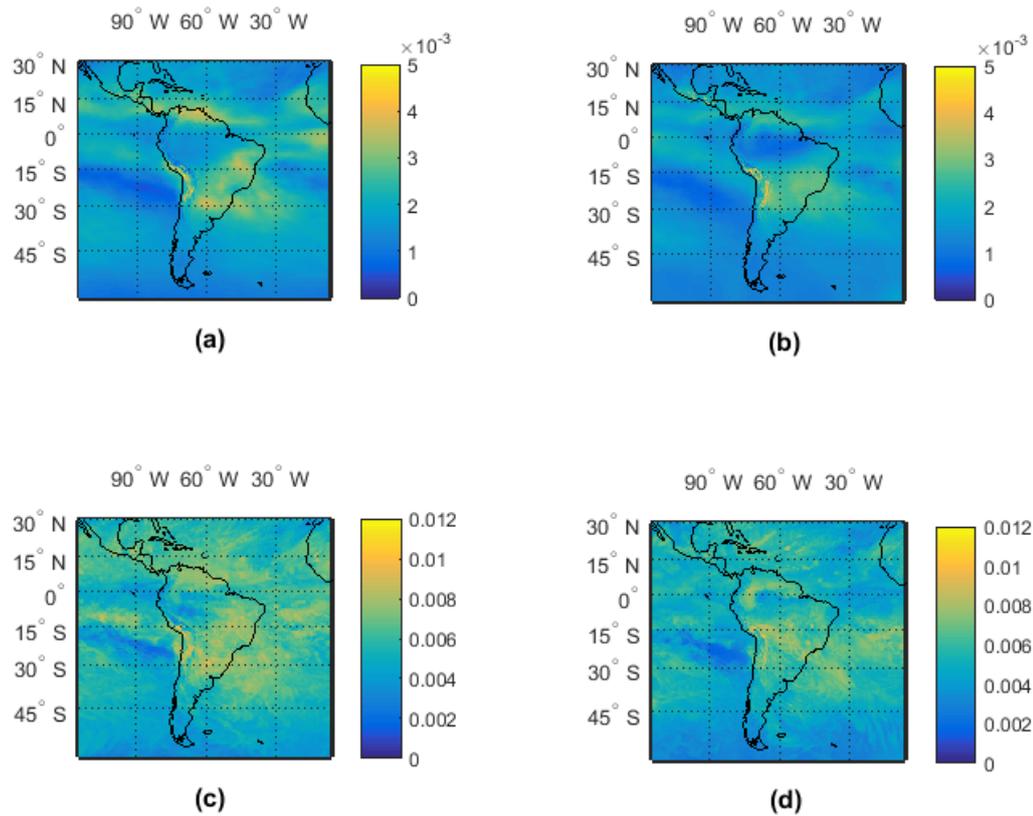


Figura 49 - Erros da previsão antes e após a utilização dos filtros propostos. Considera-se a umidade específica (em  $kg/kg$ ) a 650 hPa no ano de 2010: (a) desvio padrão do MSE entre o Eta e o NCEP (em  $kg/kg$ ); (b) desvio padrão do MSE após o ajuste do Eta (em  $kg/kg$ ); (c)  $e_{\text{máx}}$  entre o Eta e o NCEP (em  $kg/kg$ ) e (d)  $e_{\text{máx}}$  após o ajuste do Eta (em  $kg/kg$ ).

A Figura 50 apresenta séries temporais do modelo Eta antes e após o ajuste e a série do NCEP correspondente, aplicadas para a umidade específica, no ano de ajuste de 2009 e nível de pressão atmosférica 650 hPa. Observa-se que a curva do Eta ajustado consegue se aproximar da curva da série do NCEP em algumas amostras. Tanto a série do NCEP quanto a série do Eta não ajustado possuem picos, entretanto, consegue-se diminuí-los no Eta ajustado, isto é, com a aplicação da metodologia proposta nesta dissertação.

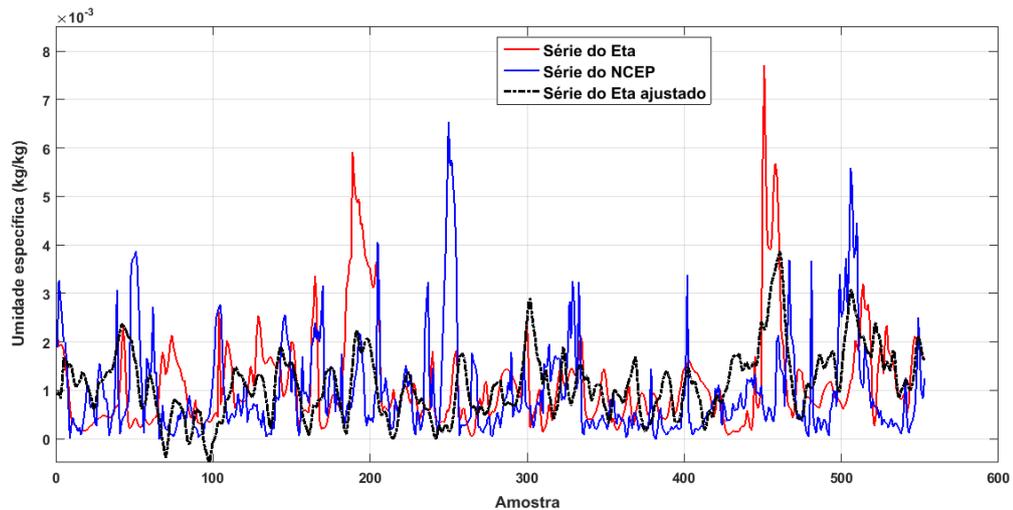


Figura 50 - Séries temporais para a umidade específica (*umes*) a 650 hPa, coordenadas geográficas dos pixels ( $45^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

A Figura 51 retrata a discrepância entre a série do modelo Eta não ajustado e a série do NCEP, para a umidade específica a 650 hPa, no ano de ajuste de 2010. Tanto a série do NCEP quanto a série não ajustada do Eta apresentam picos elevados em todo o intervalo de previsão. A aplicação de filtros adaptativos auxilia na diminuição desses picos e também ajuda a aproximar, em determinados intervalos, a série ajustada do modelo Eta com a série do NCEP.

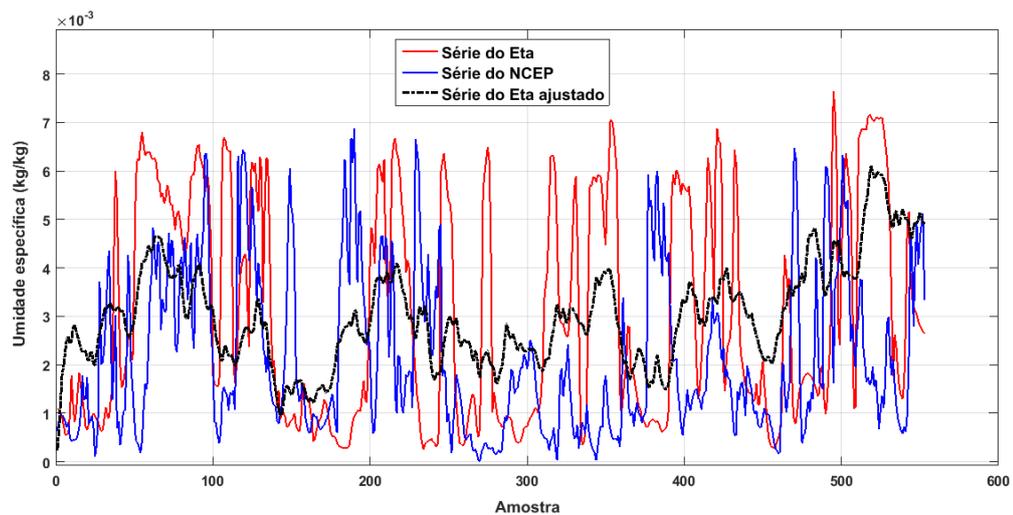


Figura 51 - Séries temporais para a umidade específica (*umes*) a 650 hPa, coordenadas geográficas dos pixels ( $40^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2010.

#### 4.5 Análise agregada

A Figura 52 apresenta os percentuais de redução no  $MSEM_p$  para todas as variáveis prognósticas. Vemos que a metodologia proposta fornece resultados muito semelhantes nos dois anos estudados (2009 e 2010) para diferentes variáveis prognósticas ( $vvel$ ,  $uvel$ ,  $umes$  e  $zgeo$ ) e níveis de pressão. Por exemplo, as reduções observadas no  $MSEM_p$  da altura geopotencial em 2009 e em 2010 são quase coincidentes, as outras, apesar de menos coincidentes, apresentam comportamentos bastante semelhantes nos dois anos. Com exceção de níveis de pressão específicos para os quais há maiores discrepâncias, como por exemplo para a componente meridional do vento entre 100 e 250 hPa, vemos que o comportamento do  $MSEM_p$  mostra-se correlacionado para uma mesma variável climática nos dois anos analisados.

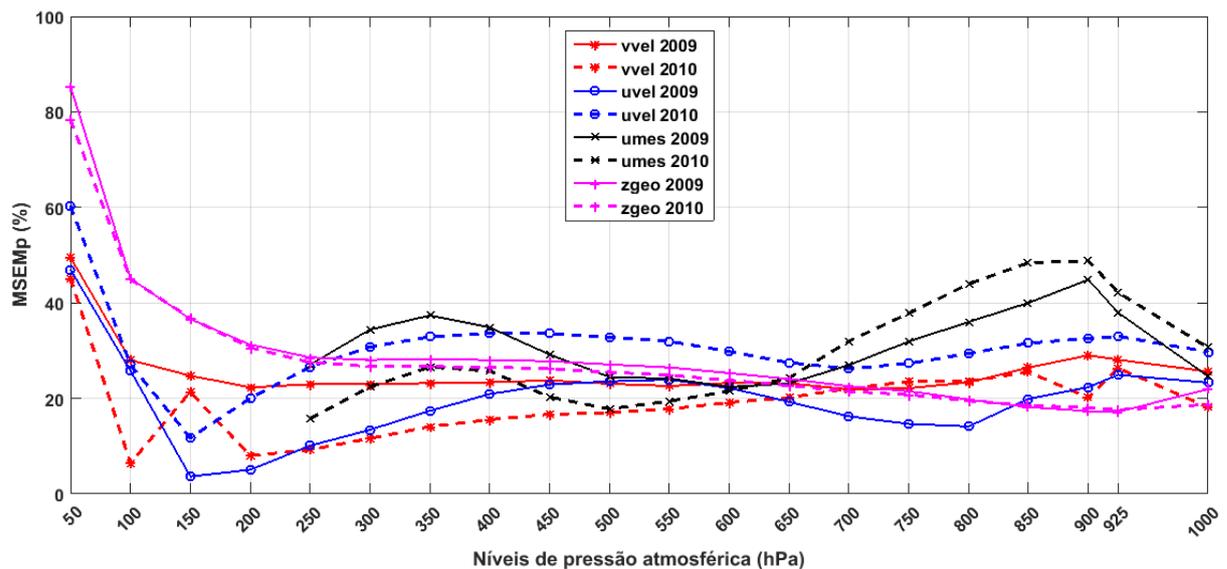


Figura 52 - Percentual de redução da média do erro quadrático médio ( $MSEM_p$ ) dos anos de ajuste de 2009 e 2010, para a componente meridional do vento ( $vvel$ ), componente zonal do vento ( $uvel$ ), altura geopotencial ( $zgeo$ ) e umidade específica ( $umes$ ).

A Figura 53 apresenta a taxa de efetividade na redução do MSE da previsão: a fração das séries temporais (cada pixel na região corresponde a uma) para as quais observa-se redução do MSE após o ajuste da previsão climática proposto. Através dessas curvas é calculada a taxa de efetividade média, que equivale a 76,77%, indicando uma melhora geral do prognóstico climático.

As taxas relativas às variáveis componente meridional do vento ( $vvel$ ) em 2009

e umidade específica (*umes*) em 2010 se mantêm equilibradas para os níveis de pressão atmosférica a partir de 250 hPa. Com exceção de alguns percentuais de efetividade que apresentam ligeira queda, por exemplo, para a altura geopotencial (*zgeo*) em 2009 e componente meridional do vento (*vvel*) em 2010 em 100 hPa, os comportamentos das taxas não sofrem oscilações acentuadas.

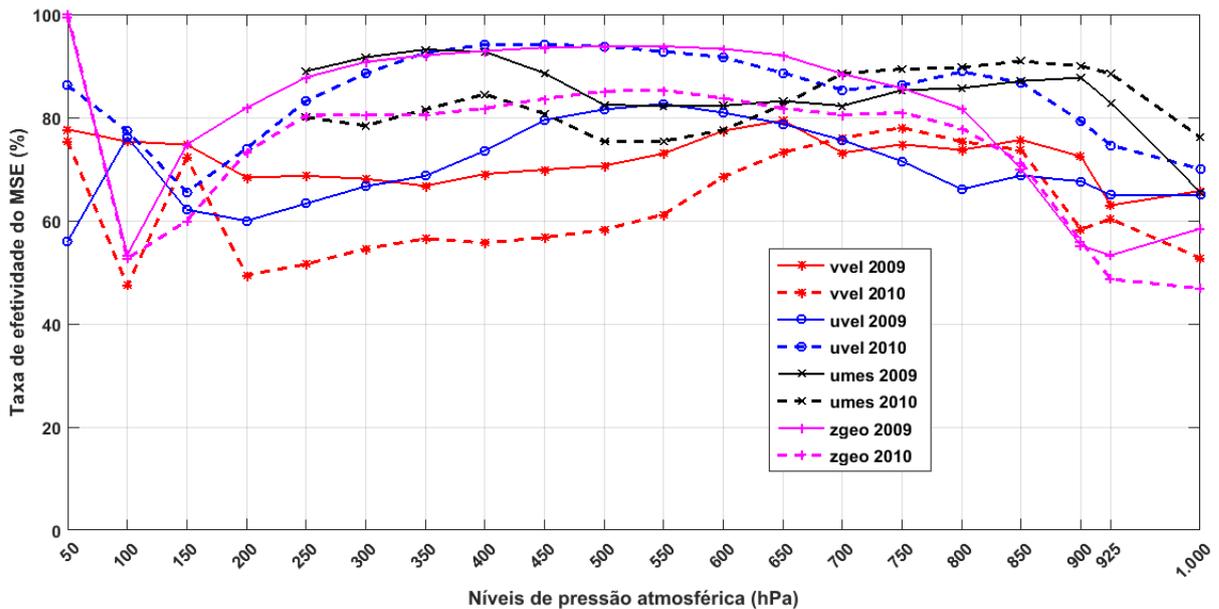


Figura 53 - Taxa de efetividade do MSE dos anos de ajuste de 2009 e 2010, para a componente meridional do vento (*vvel*), componente zonal do vento (*uvel*), altura geopotencial (*zgeo*) e umidade específica (*umes*).

A Figura 54 apresenta os percentuais de efetividade na redução do erro máximo da previsão correspondentes as variáveis prognósticas (*uvel*, *vvel*, *umes* e *zgeo*) nos anos de 2009 e 2010. Afora para a variável altura geopotencial (*zgeo*), a média dos percentuais de efetividade que reduzem o erro máximo das previsões climáticas é de 62,03%, referentes às coordenadas geográficas e níveis de pressão.

É possível constatar que os comportamentos do  $e_{\max}$  para a componente meridional do vento (*vvel*) em 2009 e componente zonal do vento (*uvel*) em 2010 não sofrem variações bruscas em todos os níveis de pressão atmosférica, ao contrário da análise para a altura geopotencial (*zgeo*) de 2009 e 2010, que apresentam curvas semelhantes nos dois anos de ajuste e quedas acentuadas de taxa de efetividade a partir de 100 hPa. As curvas de efetividade do  $e_{\max}$  para a umidade específica (*umes*) em 2009 e 2010 também apresentam comportamentos similares, mas ao analisar de uma forma geral, podemos notar que as

taxas de efetividade do MSE possuem maior correlação que as do  $e_{\max}$ .

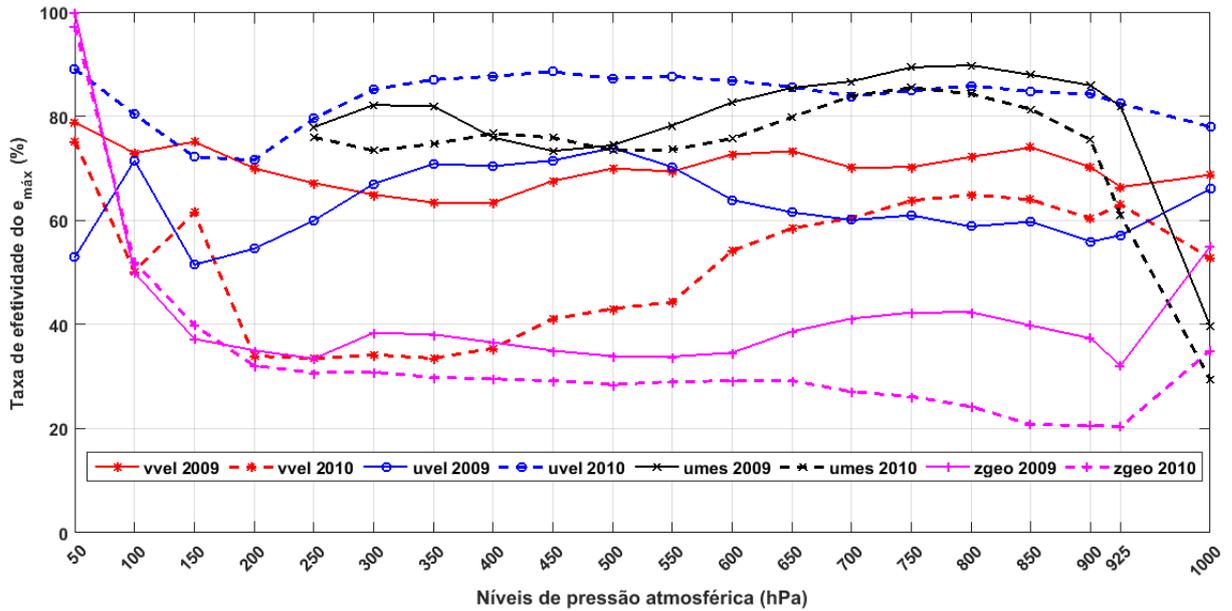


Figura 54 - Taxa de efetividade do erro máximo ( $e_{\max}$ ) dos anos de ajuste de 2009 e 2010, para a componente meridional do vento ( $vvel$ ), componente zonal do vento ( $uvel$ ), altura geopotencial ( $zgeo$ ) e umidade específica ( $umes$ ).

## CONCLUSÃO

Este trabalho apresentou resultados experimentais da aplicação da filtragem adaptativa no domínio da frequência para a diminuição de erros de previsão entre as séries temporais do modelo Eta e as séries temporais das reanálises do NCEP.

Os filtros são aplicados a coeficientes frequenciais da DCT-2D. Apenas uma faixa de componentes espectrais (região de frequências baixas) é empregada, resultando em uma maior velocidade computacional e otimização do processo de adaptação dos coeficientes dos filtros em cada iteração do algoritmo RLS. A varredura zig-zag e a sua inversa permitiram ordenar as componentes espectrais em função da ordem decrescente de energia, possibilitando desprezar as componentes inseridas nas faixas de frequências médias e altas.

A filtragem adaptativa FIR com ordem de filtro ( $N = 4$ ) gerou resultados relevantes de redução de erros, conforme indicado pelas métricas de avaliação - redução percentual da média do erro quadrático médio ( $MSEM_p$ ), taxa de efetividade do MSE e taxa de efetividade do  $e_{max}$ .

As taxas de efetividade de redução do MSE para as quatro variáveis prognósticas analisadas (componentes zonal e meridional do vento, altura geopotencial e umidade específica) sempre apresentaram valores acima de 40% para todos os níveis de pressão atmosférica testados, lembrando que esta métrica indica a quantidade de séries temporais nas quais se observa redução do erro quadrático médio após os ajustes do modelo Eta para os anos de 2009 e 2010.

Ao analisar as taxas de efetividade do  $e_{max}$ , podemos perceber que as taxas para a umidade específica apresentaram comportamentos correlacionados entre os dois anos de ajuste. Para a componente zonal do vento, as taxas de efetividade de redução do  $e_{max}$  tiveram um melhor desempenho para o ano de ajuste de 2010, com valores em torno de 80%. A componente meridional do vento apresentou taxas em torno 70% para o ano de ajuste de 2009. As menores taxas de efetividade do  $e_{max}$  são definidas para a altura geopotencial, com valores em torno de 40%, exceto para o nível de pressão atmosférica 50 hPa (topo do modelo), pois ele apresenta taxas muito próximas de 100%, nos dois anos.

A redução percentual da média do erro quadrático médio ( $MSEM_p$ ) apresentou valores significativos para todas as variáveis prognósticas de análise, com reduções, em

torno de 20% a 30%. Para a umidade específica, o  $MSEM_p$  apresenta reduções maiores para os níveis de pressão mais próximos ao nível do mar (1.000 hPa). Os comportamentos das reduções percentuais para a componente zonal do vento mostram-se bastante oscilatórios em função dos níveis de pressão atmosférica, no entanto, no nível de 50 hPa, a redução está entre 45% e 60%. Para a componente meridional do vento, a partir do nível de pressão 100 hPa, as reduções estão em uma mesma faixa de valores para o ano de ajuste de 2009, porém para o nível de 50 hPa os valores são diferentes, entre 45% a 50%. As reduções percentuais na altura geopotencial mostram-se bastante correlacionadas entre todos os níveis de pressão e os dois anos de ajuste, porém, no nível de 50 hPa observa-se valores entre 75% a 85%.

A partir da análise de todos os resultados experimentais deste trabalho podemos afirmar que, para a taxa de efetividade do MSE, os melhores percentuais ocorreram para a umidade específica, com valores muito correlacionados para os dois anos de ajuste. Os resultados para a taxa de efetividade do erro máximo ( $e_{max}$ ) também indicam que os valores mais correlacionados ocorrem com a umidade específica, apesar de ocorrer uma queda brusca dos percentuais para o nível de pressão 1.000 hPa. Para o percentual de redução da média do erro quadrático médio ( $MSEM_p$ ) podemos constatar que os resultados para a altura geopotencial mostram-se mais correlacionados e que também apresenta os maiores percentuais de redução, considerando os dois anos de ajuste.

Para trabalhos futuros pode-se utilizar a filtragem adaptativa no domínio da frequência para redução de erros de previsão climática através dos algoritmos LMS (*Least Mean Squares*) e NLMS (*Normalized Least Mean Squares*), analisando os níveis de pressão atmosférica citados, para efeitos de comparação com o algoritmo RLS (*Recursive Least Squares*).

## REFERÊNCIAS

- [1] BRAVO, J. M. et al. Avaliação dos benefícios de previsões de vazão na operação de reservatórios. *Revista Brasileira de Recursos Hídricos*, v. 13, p. 197–213, 2009.
- [2] FREI, T. Economic and social benefits of meteorology and climatology in switzerland. *Meteorological Applications*, Wiley Online Library, v. 17, n. 1, p. 39–44, 2010.
- [3] ANAMAN, K. A. et al. Methods for assessing the benefits of meteorological services in australia. *Meteorological Applications*, Wiley Online Library, v. 2, n. 1, p. 17–29, 1995.
- [4] MCCLURE, A.; LACHLAN-COPE, T. Assessment of the benefits of weather forecasting for british antarctic survey operations. *Meteorological Applications*, Cambridge University Press, v. 5, n. 2, p. 95–102, 1998.
- [5] LAPRISE, R. et al. Challenging some tenets of Regional Climate Modelling. *Meteorology and Atmospheric Physics*, v. 100, n. 1-4, p. 3–22, 2008.
- [6] FREITAS, A. R. *Filtragem adaptativa aplicada à redução de desvios em séries temporais de previsão numérica climática*. Dissertação (Mestrado) — Universidade do Estado do Rio de Janeiro, 2015.
- [7] CHOU, S. C.; BUSTAMANTE, J. F.; GOMES, J. Evaluation of Eta model seasonal precipitation forecasts over south america. *Nonlinear Processes in Geophysics*, v. 12, n. 4, p. 537–555, 2005.
- [8] ROZANTE, J. R.; CAVALCANTI, I. F. Influência da condição inicial na simulação do evento de precipitação extrema na serra do mar. *Congresso Brasileiro de Meteorologia (CBMET), XIV*, 2006.
- [9] LAWRENCE, H. et al. Evaluation and assimilation of the microwave sounder mwhs-2 onboard fy-3c in the ecmwf numerical weather prediction system. *IEEE Transactions on Geoscience and Remote Sensing*, IEEE, v. 56, n. 6, p. 3333–3349, 2018.
- [10] MOCAVERO, S. et al. Performance analysis of the cosmo-clm model. *High Performance Computing & Simulation (HPCS), International Conference on*, IEEE, p. 581–588, 2015.

- [11] MELKONYAN, H. et al. An analysis of wintertime cold-air pool in armenia using climatological observations and wrf model data. *Computer Science and Information Technologies (CSIT)*, IEEE, p. 130–134, 2017.
- [12] BONATTI, J. Modelo de circulação geral atmosférico do cptec. *Climanalise*, INPE, 1996.
- [13] CAMARGO-USP, R.; FIGUEIROA-INPE, S. N.; SOARES-INPE, W. Avaliação de modelos globais e regionais climáticos. 2014.
- [14] CHOU, S. C. Modelo regional eta, climanalise, edição comemorativa de 10 anos. *INPE. São Jose dos Campos, SP, Brasil*, 1996.
- [15] MESINGER, F. et al. The Eta model: Design, use, and added value. In: *Topics in Climate Modeling*. : InTech, 2016.
- [16] CHOU, S. et al. Refinamento estatístico das previsões horárias de temperatura a 2 m do modelo eta em estações do nordeste do brasil. *Revista Brasileira de Meteorologia*, v. 22, n. 3, p. 287–296, 2007.
- [17] NOAA/GFS. *Global Forecast System*. Acesso em: Junho de 2017. Disponível em: <<http://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-forecast-system-gfs>>.
- [18] SAHA, S. et al. The ncep climate forecast system reanalysis. *Bulletin of the American Meteorological Society*, American Meteorological Society, v. 91, n. 8, p. 1015–1058, 2010.
- [19] TEUTSCHBEIN, C.; SEIBERT, J. Is bias correction of regional climate model (rcm) simulations possible for non-stationary conditions? *Hydrology and Earth System Sciences*, Copernicus GmbH, v. 17, n. 12, p. 5061–5077, 2013.
- [20] SOLOMON, C.; BRECKON, T. *Fundamentos de processamento digital de imagens: uma abordagem prática com exemplos em Matlab*. : Grupo Gen-LTC, 2000.
- [21] RAO, K. R.; YIP, P. *Discrete cosine transform: algorithms, advantages, applications*. : Academic press, 2014.
- [22] KHAYAM, S. A. The discrete cosine transform (dct): theory and application. *Michigan State University*, v. 114, 2003.

- [23] DINIZ, P. S. R.; SILVA, E. A. B. D.; NETTO, S. L. *Digital signal processing: system analysis and design*. : Cambridge University Press, 2010.
- [24] OPPENHEIM, A. V. *Sinais e sistemas*. : Prentice-Hall, 2010.
- [25] AQUINO, F. J. A. de; ALCÓCER, J. C. A.; MEDEIROS, F. N. S. de. Aplicação de filtros digitais tipo fir a sinais biométricos. *Revista Tecnologia*, v. 24, n. 2, 2003.
- [26] ABABNEH, J. I.; BATAINEH, M. H. Linear phase fir filter design using particle swarm optimization and genetic algorithms. *Digital Signal Processing*, Elsevier, v. 18, n. 4, p. 657–668, 2008.
- [27] ZHANG, S.; SALARI, E. Reducing artifacts in coded images using a neural network aided adaptive fir filter. *Neurocomputing*, Elsevier, v. 50, p. 249–269, 2003.
- [28] DINIZ, P. S. R. *Adaptive filtering: Algorithms and Practical Implementation*. : Springer, 2013.
- [29] HAYKIN, S. S. *Adaptive filter theory*. : Pearson, 2008.
- [30] CAVALCANTI, I. F. et al. Global climatological features in a simulation using the cptec–cola agcm. *Journal of Climate*, v. 15, n. 21, p. 2965–2988, 2002.
- [31] MARTINS, G. et al. Características da circulação atmosférica e precipitação utilizando o modelo acoplado mcga/ibis. *Boletim de Geografia*, v. 33, n. 2, p. 100–114, 2015.
- [32] STORCH, H. V. et al. Combining paleoclimatic evidence and gcms by means of data assimilation through upscaling and nudging (datun). *GKSS FORSCHUNGSZENTRUM GEESTHACHT GMBH-PUBLICATIONS-E*, GKSS-FORSCHUNGSZENTRUM GEESTHACHT GMBH, n. 18, p. 15–18, 2000.
- [33] CASTRO, C. L.; SR, R. A. P.; LEONCINI, G. Dynamical downscaling: Assessment of value retained and added using the regional atmospheric modeling system (rams). *Journal of Geophysical Research: Atmospheres*, Wiley Online Library, v. 110, n. D5, 2005.
- [34] COLA. *The Center for Ocean-Land-Atmosphere Studies*. Acesso em: Junho de 2017. Disponível em: <<http://cola.gmu.edu/cola.html>>.

- [35] KINTER, J. L. *The COLA atmosphere-biosphere general circulation model: Formulation.* : Center for Ocean-Land-Atmosphere Studies, Institute of Global Environment and Society, 1997.
- [36] LI, Y.; WANG, B.; WANG, D. *A New Approach to Implement Sigma Coordinate in a Numerical Model.* Acesso em: Junho de 2017. Disponível em: <<https://www.newton.ac.uk/files/seminar/20120824110011301-153257.pdf>>.
- [37] SATYARMURTY, P.; BITENCOURT, D. P. *Previsão Numérica de Tempo no CPTEC/INPE.* Acesso em: Junho de 2017. Disponível em: <<http://climanalise.cptec.inpe.br/~rclimanl/boletim/cliesp10a/daniel.html>>.
- [38] NOAA/GFS. *Environmental Modeling Center.* Acesso em: Junho de 2017. Disponível em: <<http://www.emc.ncep.noaa.gov/GFS/doc.php>>.
- [39] MESINGER, F. et al. The step-mountain coordinate: Model description and performance for cases of alpine lee cyclogenesis and for a case of an appalachian redevelopment. *Monthly Weather Review*, v. 116, n. 7, p. 1493–1518, 1988.
- [40] BLACK, T. L. The new NMC mesoscale eta model: Description and forecast examples. *Weather and forecasting*, v. 9, n. 2, p. 265–278, 1994.
- [41] MESINGER, F. A blocking technique for representation of mountains in atmospheric models. *Riv. Meteor. Aeronaut.*, v. 44, p. 195–202, 1984.
- [42] CHOU, S. C. Comparison between eta vs sigma coordinate model runs over south america. 2015.
- [43] MESINGER, F. et al. An upgraded version of the Eta model. *Meteorology and Atmospheric Physics*, Springer, v. 116, n. 3-4, p. 63–79, 2012.
- [44] GADD, A. A split explicit integration scheme for numerical weather prediction. *Quarterly Journal of the Royal Meteorological Society*, Wiley Online Library, v. 104, n. 441, p. 569–582, 1978.
- [45] JANJIĆ, Z. I. The step-mountain eta coordinate model: Further developments of the convection, viscous sublayer, and turbulence closure schemes. *Monthly Weather Review*, v. 122, n. 5, p. 927–945, 1994.

- [46] FELLS, S. B.; SCHWARZKOPF, M. D. The simplified exchange approximation: A new method for radiative transfer calculations. *Journal of the Atmospheric Sciences*, v. 32, n. 7, p. 1475–1488, 1975.
- [47] LACIS, A. A.; HANSEN, J. A parameterization for the absorption of solar radiation in the earth's atmosphere. *Journal of the atmospheric sciences*, v. 31, n. 1, p. 118–133, 1974.
- [48] MESINGER, F.; ARAKAWA, A. Numerical methods used in atmospheric models. Global Atmospheric Research Programme (GARP), 1976.
- [49] FUKA, D. R. et al. Using the climate forecast system reanalysis as weather input data for watershed models. *Hydrological Processes*, Wiley Online Library, v. 28, n. 22, p. 5613–5623, 2014.
- [50] NCAR/UCAR, R. D. A. *NCEP Climate Forecast System Reanalysis (CFSR) 6-hourly Products, January 1979 to December 2010*. Acesso em: Junho de 2017. Disponível em: <<http://rda.ucar.edu/datasets/ds093.0/#!description>>.
- [51] COLA. *Grid Analysis and Display System (GrADS)*. Acesso em: Junho de 2017. Disponível em: <<http://cola.gmu.edu/grads/grads.php>>.
- [52] JAIN, A. K. *Fundamentals of digital image processing*. : Englewood Cliffs, NJ: Prentice Hall, 1989.
- [53] AHMED, N.; NATARAJAN, T.; RAO, K. R. Discrete cosine transform. *IEEE transactions on Computers*, IEEE, v. 100, n. 1, p. 90–93, 1974.
- [54] BELLIFEMINE, F. et al. Statistical analysis of the 2d-dct coefficients of the differential signal for images. *Signal Processing: Image Communication*, Elsevier, v. 4, n. 6, p. 477–488, 1992.
- [55] ZHU, P.; LIU, J.; DAI, S. Fixed-point idct without multiplications based on bg lee's algorithm. *Digital Signal Processing*, Elsevier, v. 19, n. 4, p. 770–777, 2009.
- [56] KNOTT, G. D. *Interpolating cubic splines*. : Springer Science & Business Media, 2012.

- [57] CONCI, A. *Transformada Discreta do Cosseno (DCT) - Universidade Federal Fluminense*. Acesso em: Junho de 2017. Disponível em: <<http://www2.ic.uff.br/~aconci/CosenosTransformada.pdf>>.
- [58] MARQUES, E. L. *Algoritmos de Filtragem Adaptativa em Subbandas com Reúso de Dados*. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2016.
- [59] KUHN, E. V. *Modelagem estocástica do algoritmo NLMS: revisão e aprimoramentos*. Dissertação (Mestrado) — Universidade Federal de Santa Catarina, 2012.
- [60] NOAA/NCEP. *Parameters and Units*. Acesso em: Junho de 2017. Disponível em: <<http://www.nco.ncep.noaa.gov/pmb/docs/on388/table2.html>>.

## ANEXO

Este anexo apresenta as médias das taxas de efetividade do MSE, as médias dos valores de MSE, as médias das curvas de aprendizado do MSE e por fim, algumas séries temporais para as quatro variáveis prognósticas - componentes zonal e meridional do vento, altura geopotencial e umidade específica.

### Componente meridional do vento

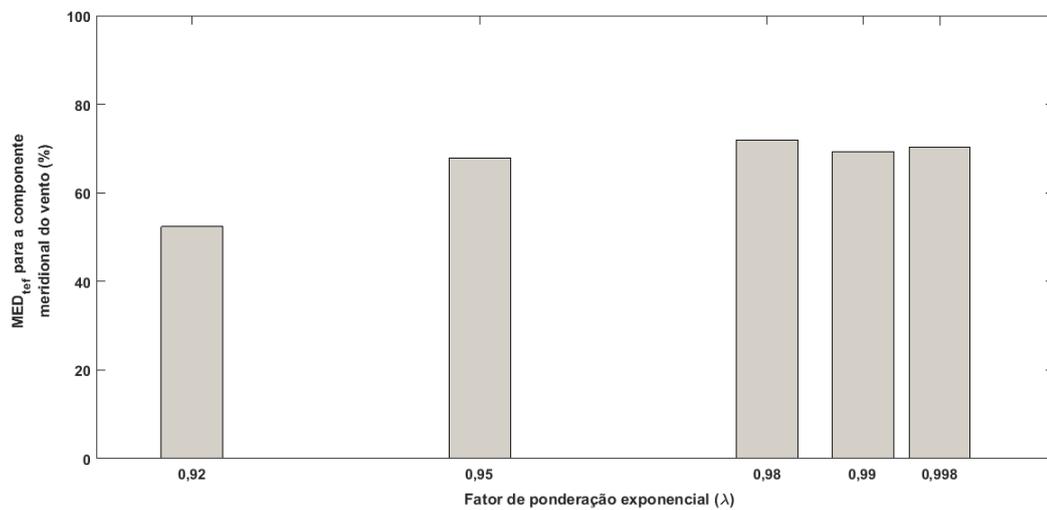


Figura 55 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a componente meridional do vento ( $v_{vel}$ ), no ano de treinamento de 2008.

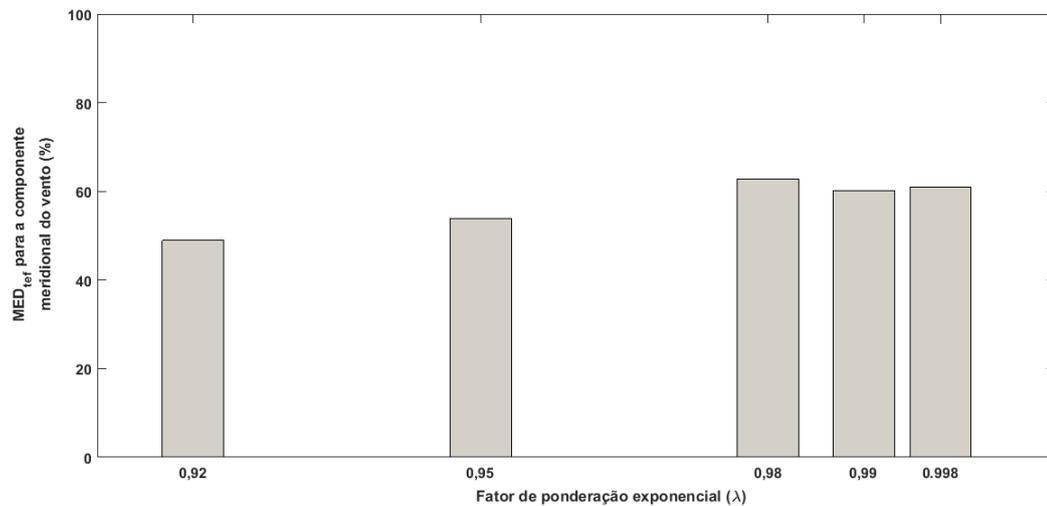


Figura 56 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a componente meridional do vento ( $v_{vel}$ ), no ano de treinamento de 2009.

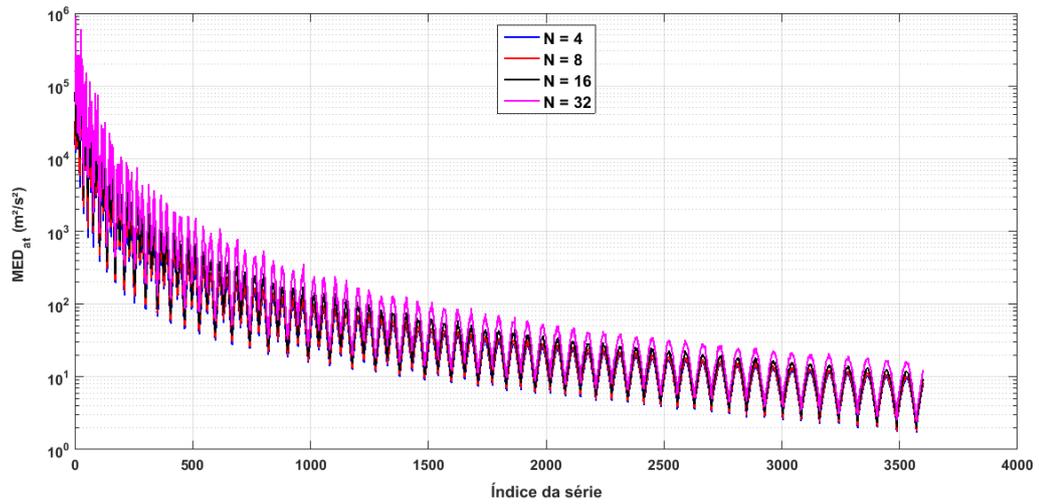


Figura 57 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a componente meridional do vento, no ano de treinamento de 2008.

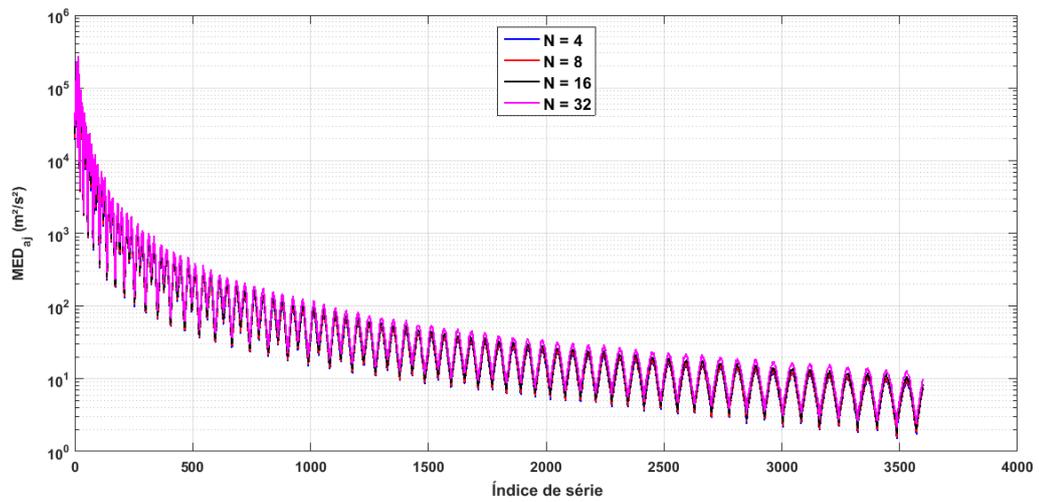


Figura 58 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a componente meridional do vento, no ano de ajuste de 2009.

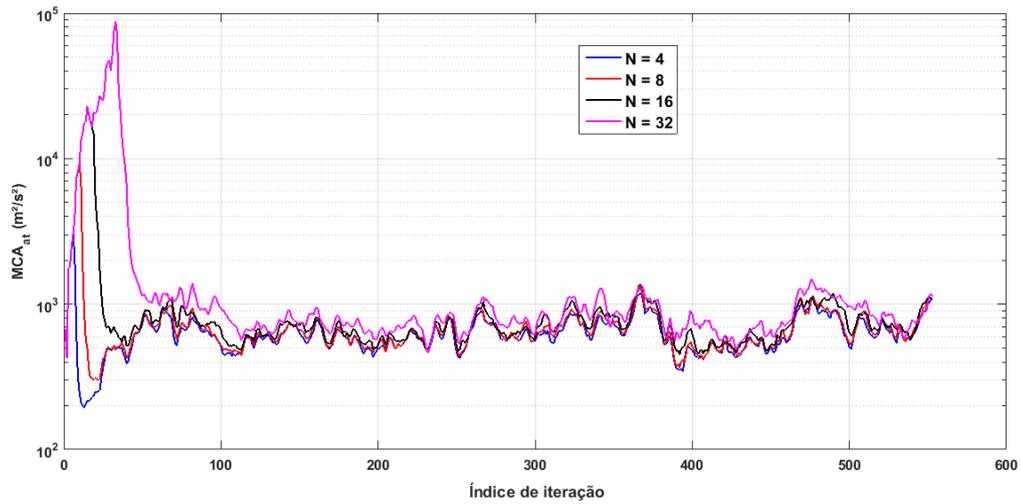


Figura 59 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a componente meridional do vento, no ano de treinamento de 2008.

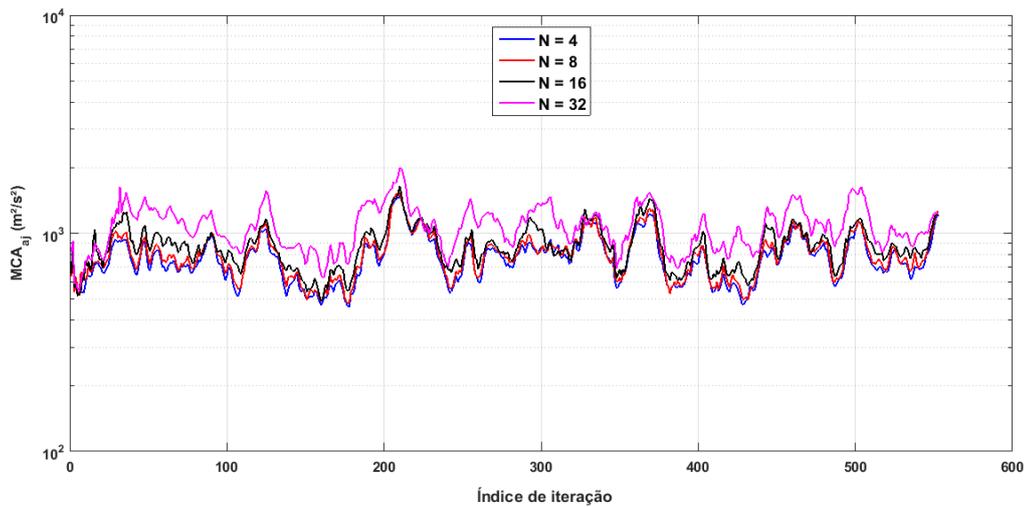


Figura 60 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a componente meridional do vento, no ano de ajuste de 2009.

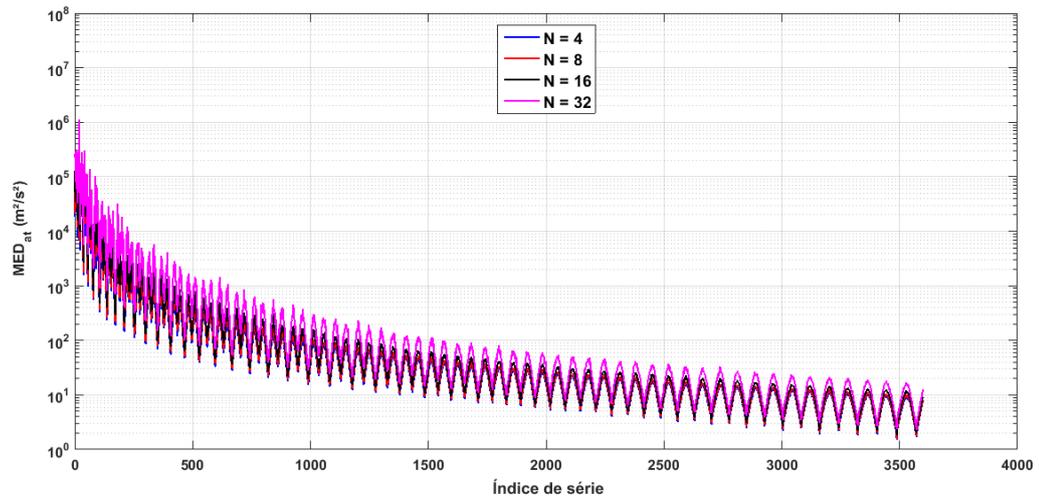


Figura 61 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a componente meridional do vento, no ano de treinamento de 2009.

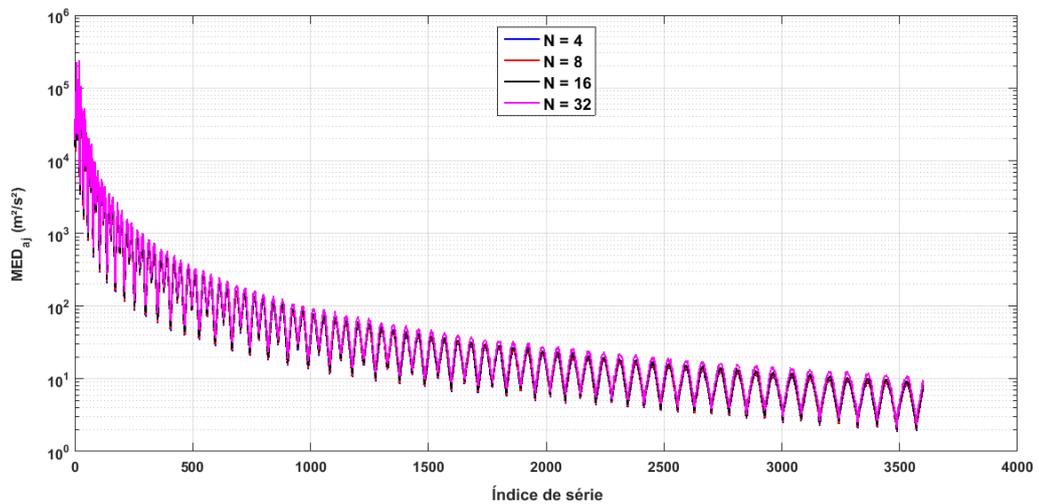


Figura 62 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a componente meridional do vento, no ano de ajuste de 2010.

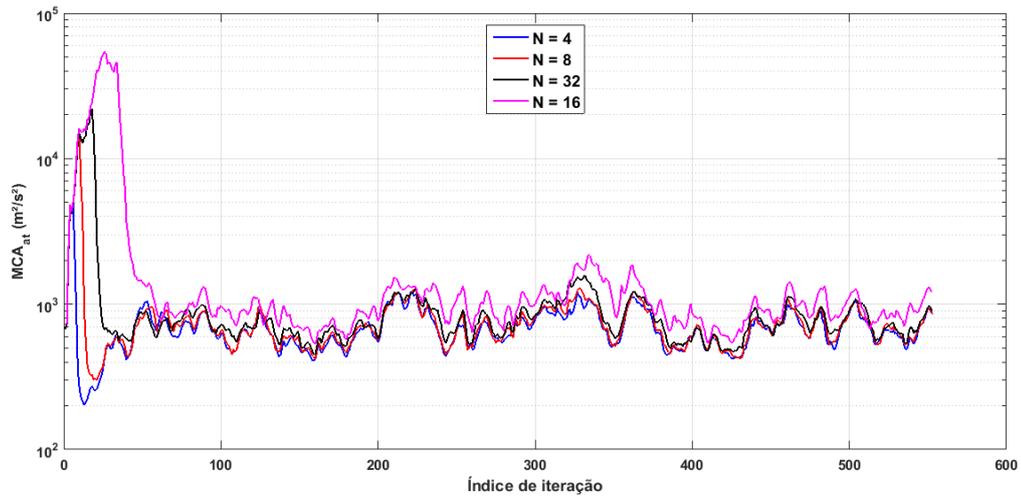


Figura 63 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a componente meridional do vento, no ano de treinamento de 2009.

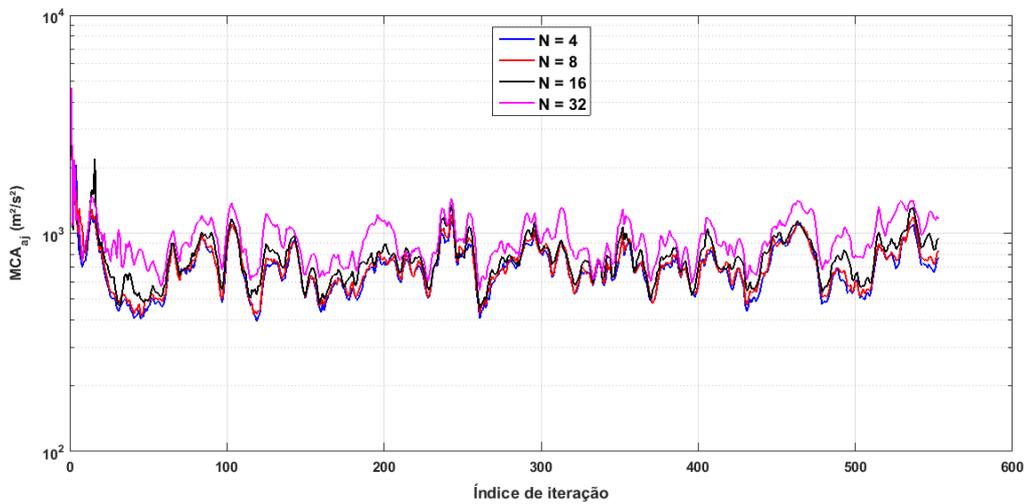


Figura 64 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a componente meridional do vento, no ano de ajuste de 2010.

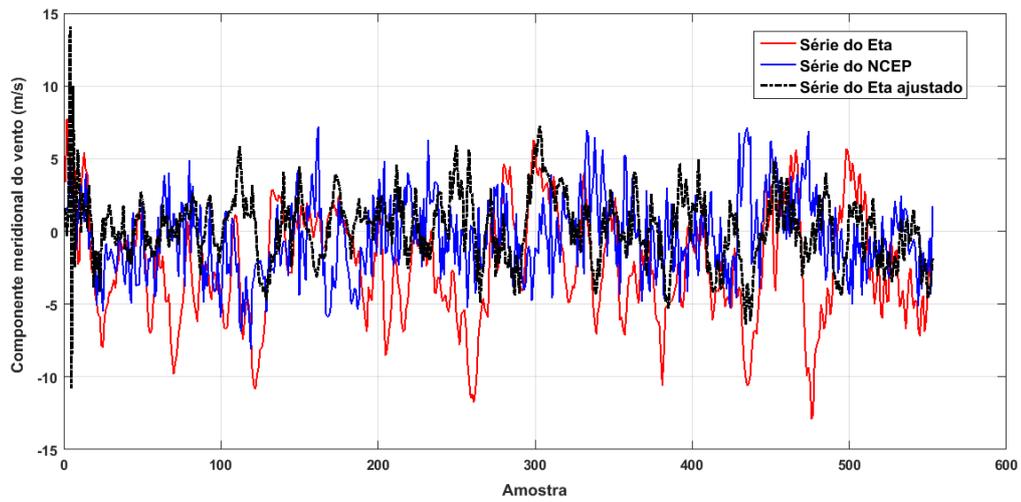


Figura 65 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 50 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

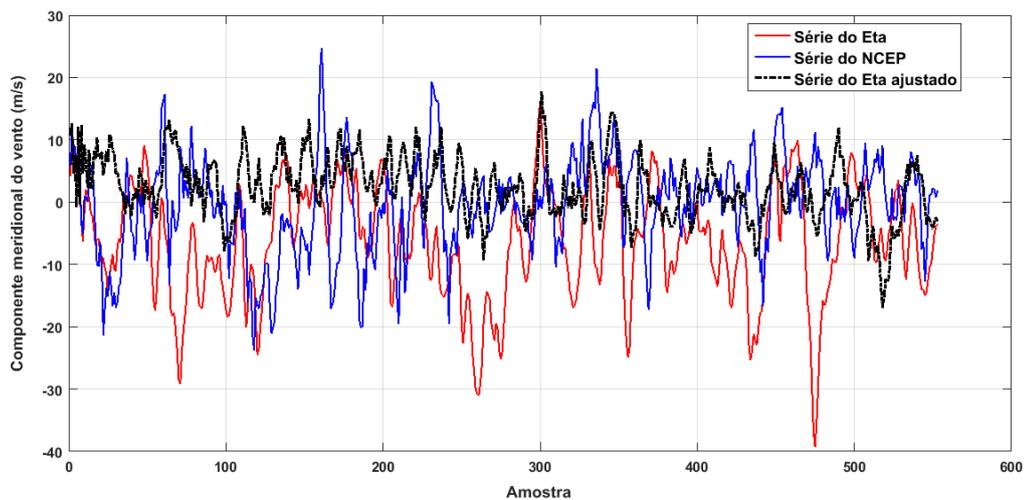


Figura 66 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 100 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

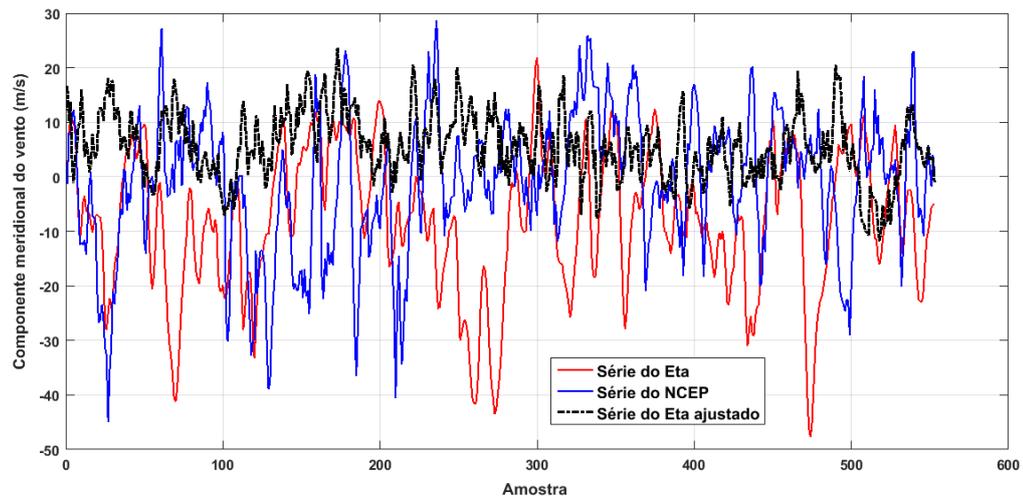


Figura 67 - Séries temporais para a componente meridional do vento (*vvel*) a 150 hPa, coordenadas geográficas dos pixels (50°W e 15°S), no ano de ajuste de 2009.

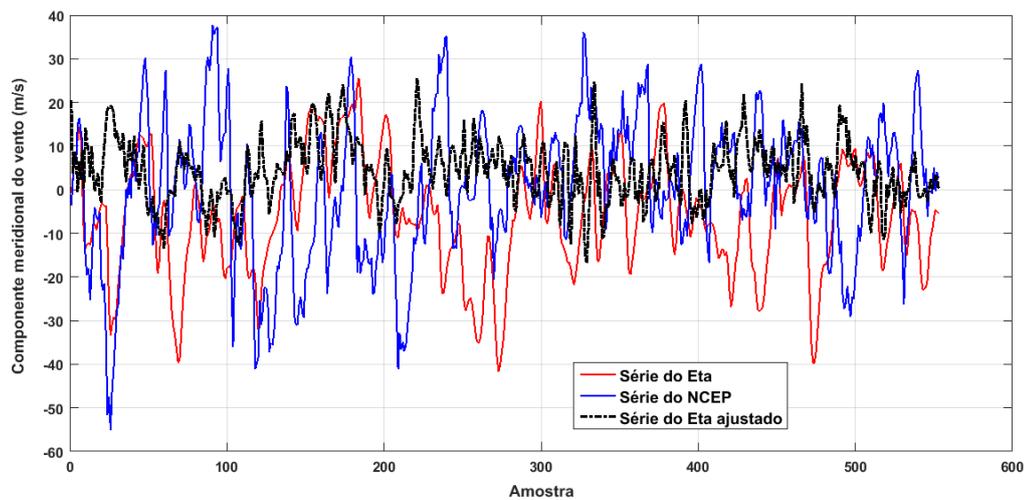


Figura 68 - Séries temporais para a componente meridional do vento (*vvel*) a 200 hPa, coordenadas geográficas dos pixels (50°W e 15°S), no ano de ajuste de 2009.

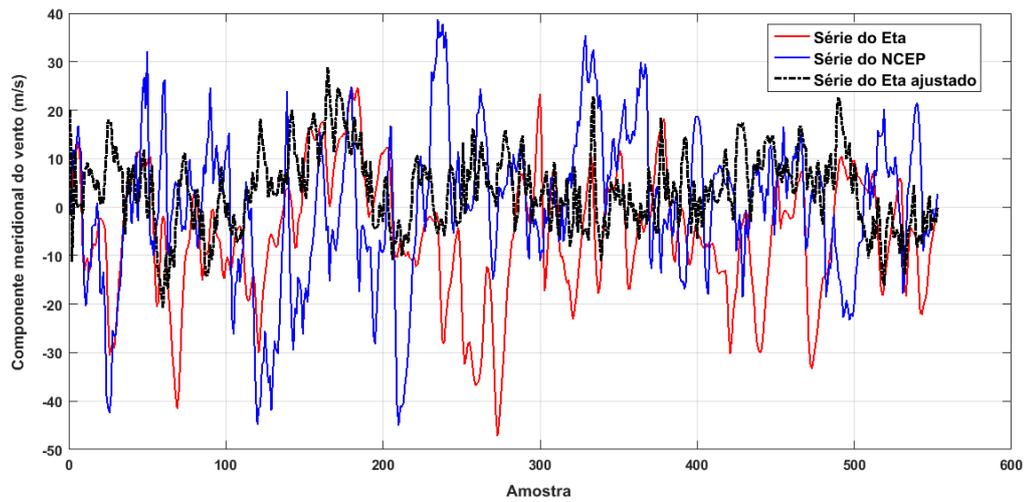


Figura 69 - Séries temporais para a componente meridional do vento ( $vvel$ ) a 250 hPa, coordenadas geográficas dos pixels ( $50^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

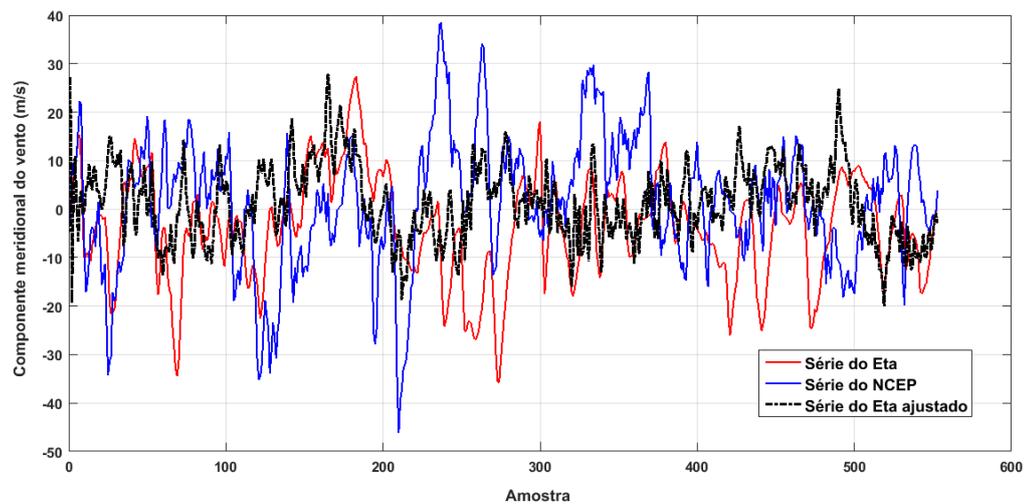


Figura 70 - Séries temporais para a componente meridional do vento ( $vvel$ ) a 300 hPa, coordenadas geográficas dos pixels ( $50^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

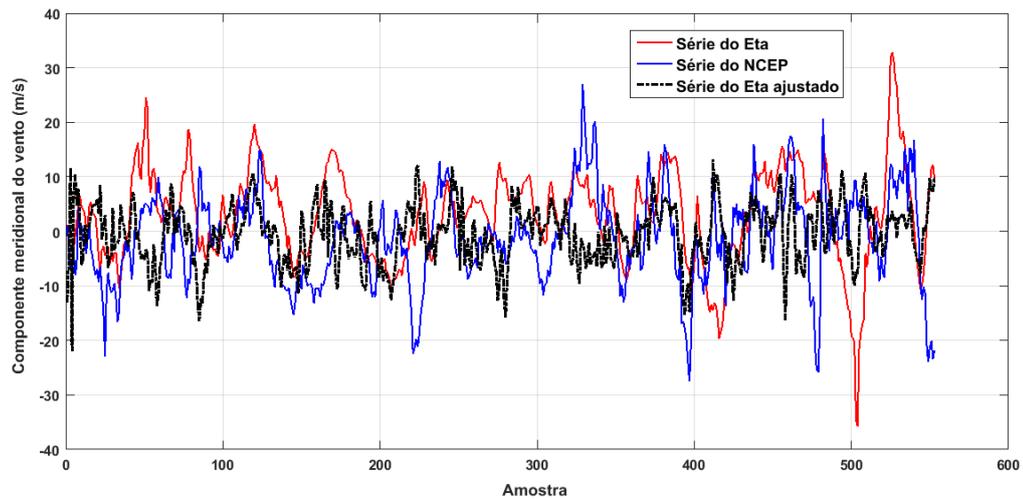


Figura 71 - Séries temporais para a componente meridional do vento (*vvel*) a 350 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

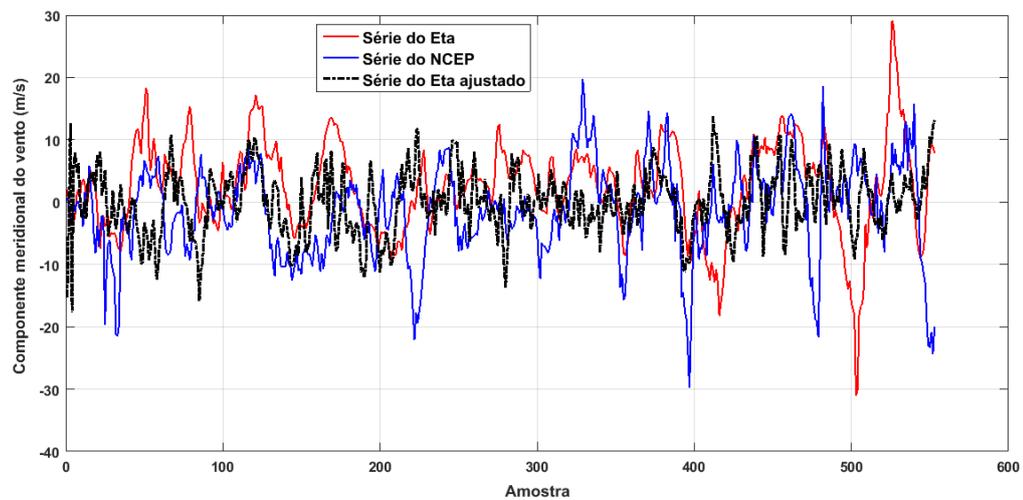


Figura 72 - Séries temporais para a componente meridional do vento (*vvel*) a 400 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

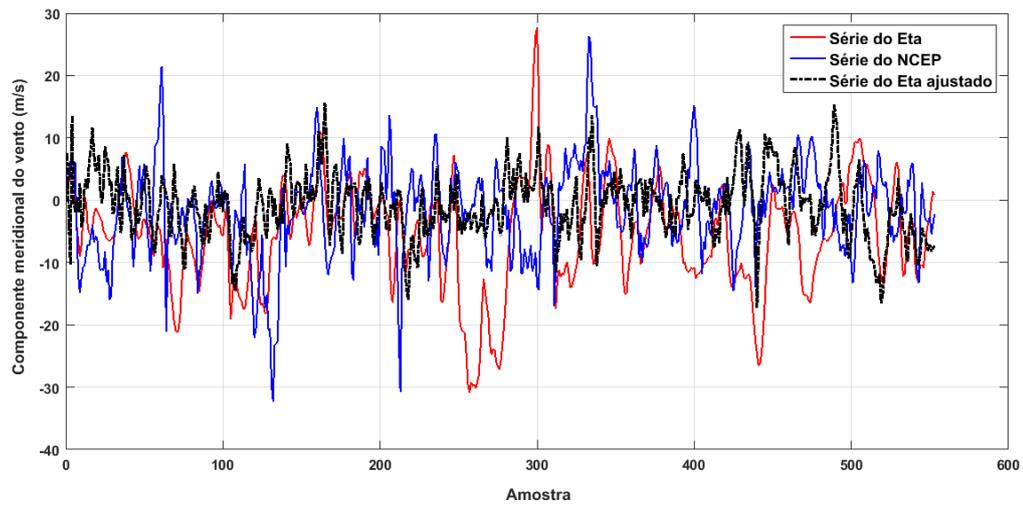


Figura 73 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 450 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

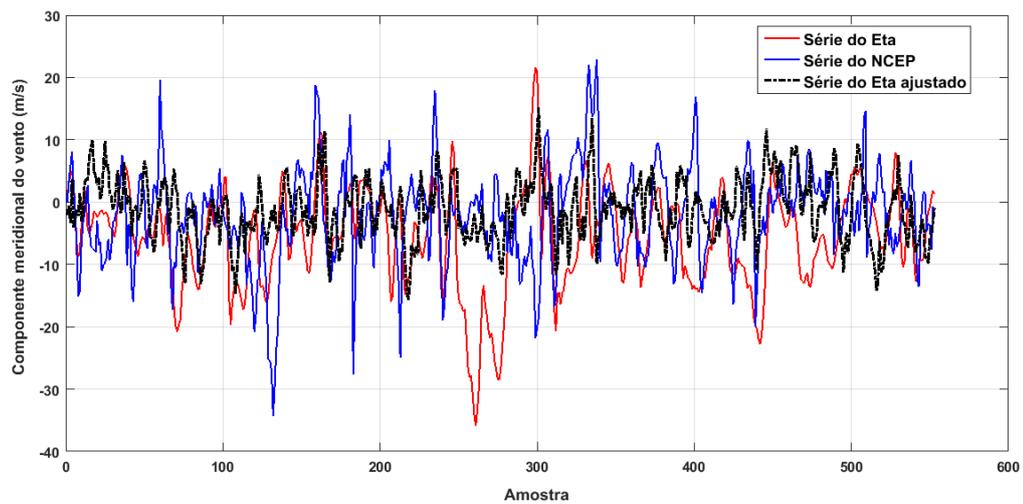


Figura 74 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 500 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

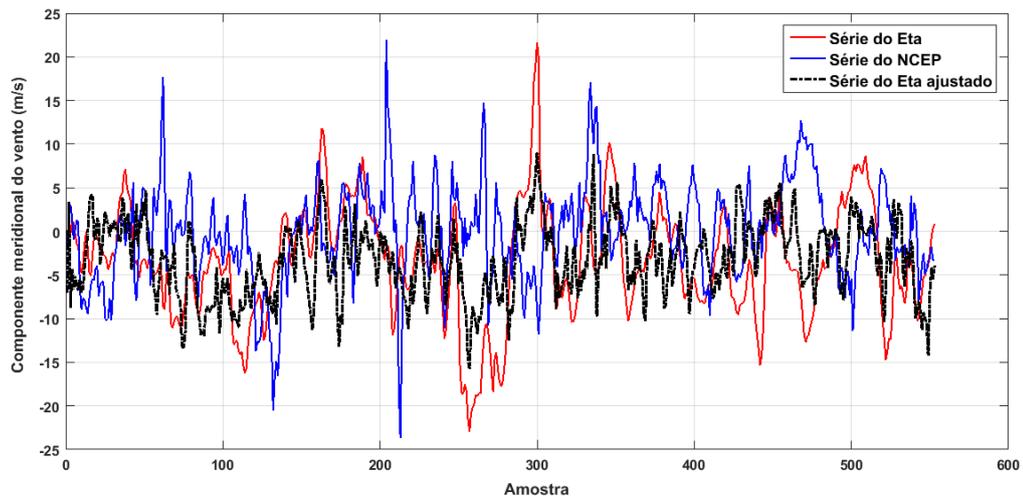


Figura 75 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 550 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

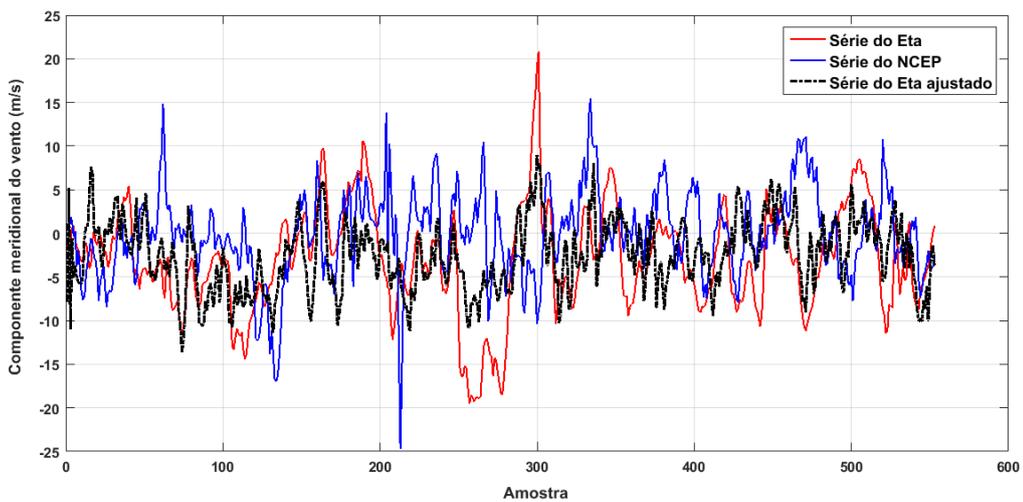


Figura 76 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 600 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

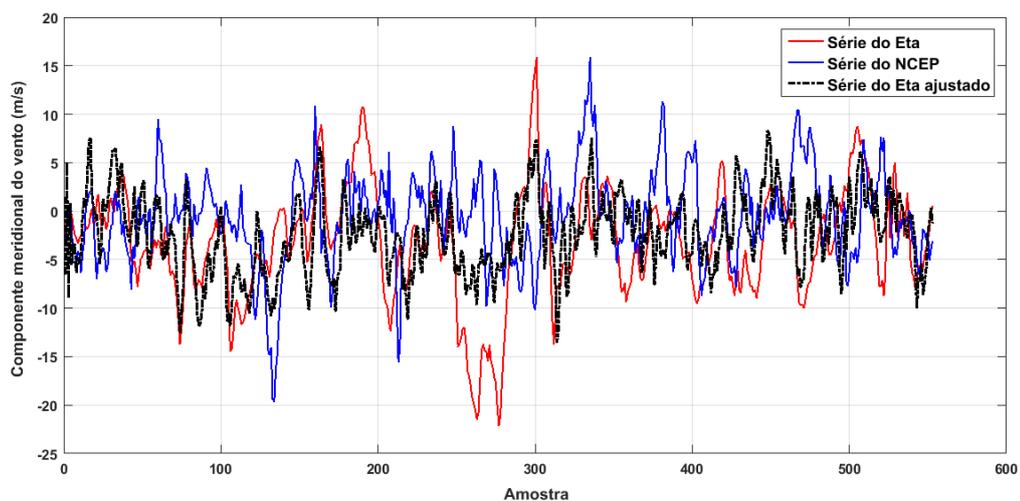


Figura 77 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 650 hPa, coordenadas geográficas dos pixels ( $50^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

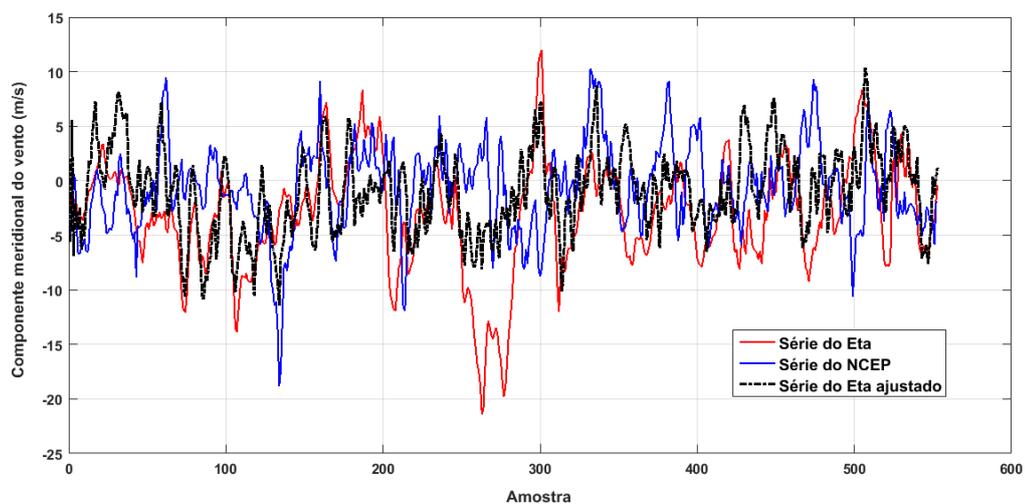


Figura 78 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 700 hPa, coordenadas geográficas dos pixels ( $50^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

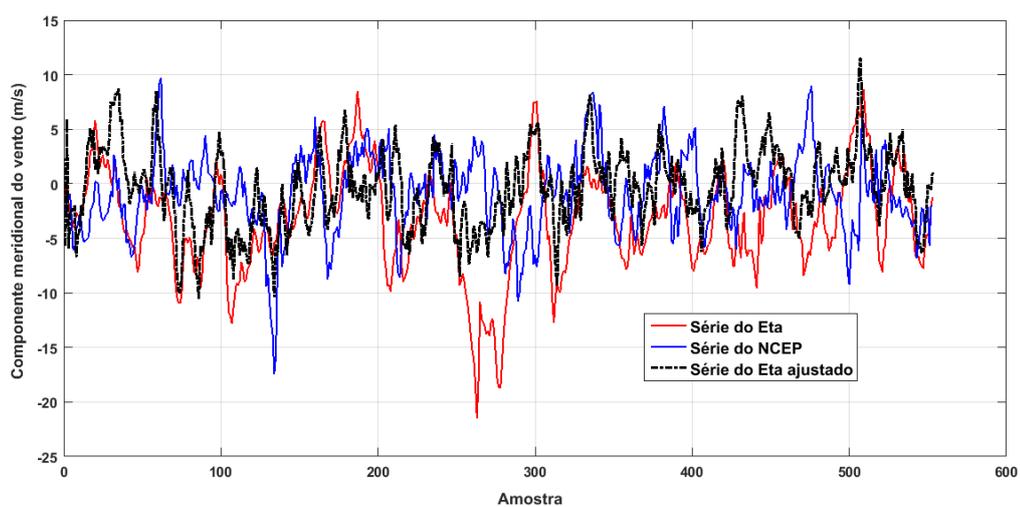


Figura 79 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 750 hPa, coordenadas geográficas dos pixels ( $50^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

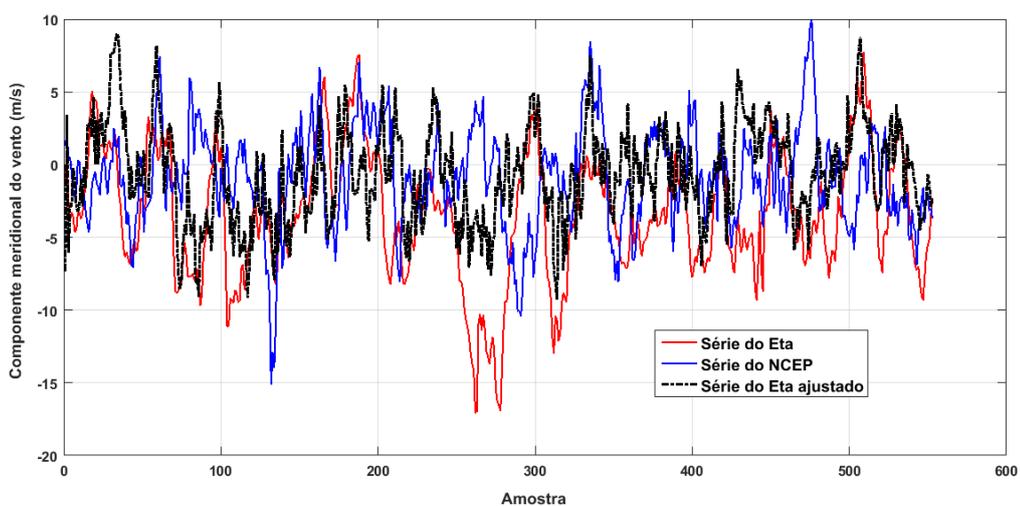


Figura 80 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 800 hPa, coordenadas geográficas dos pixels ( $50^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

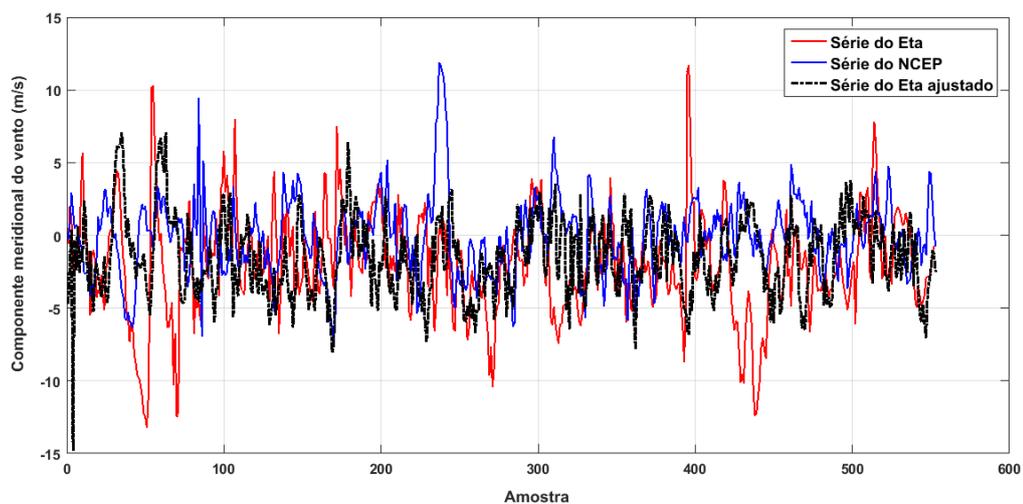


Figura 81 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 850 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

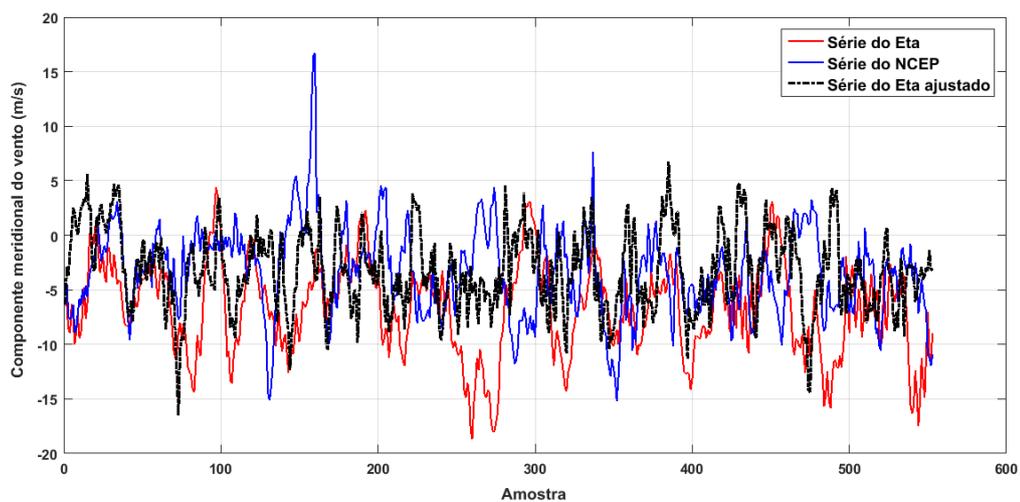


Figura 82 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 900 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

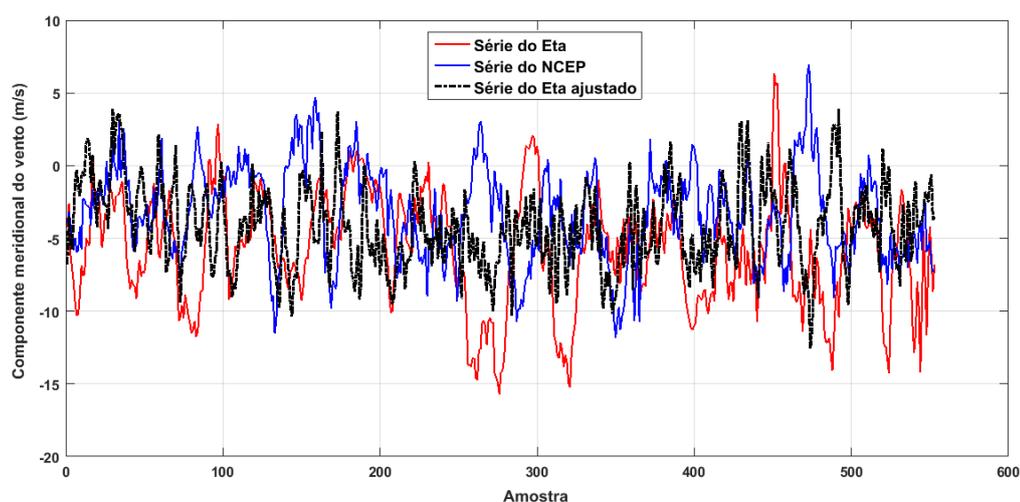


Figura 83 - Séries temporais para a componente meridional do vento (*vvel*) a 925 hPa, coordenadas geográficas dos pixels ( $50^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

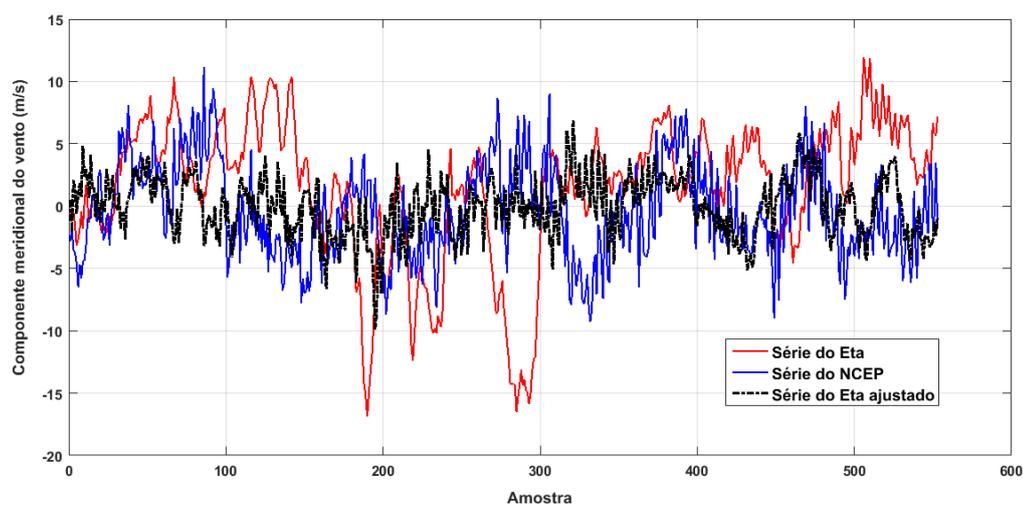


Figura 84 - Séries temporais para a componente meridional do vento (*vvel*) a 50 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

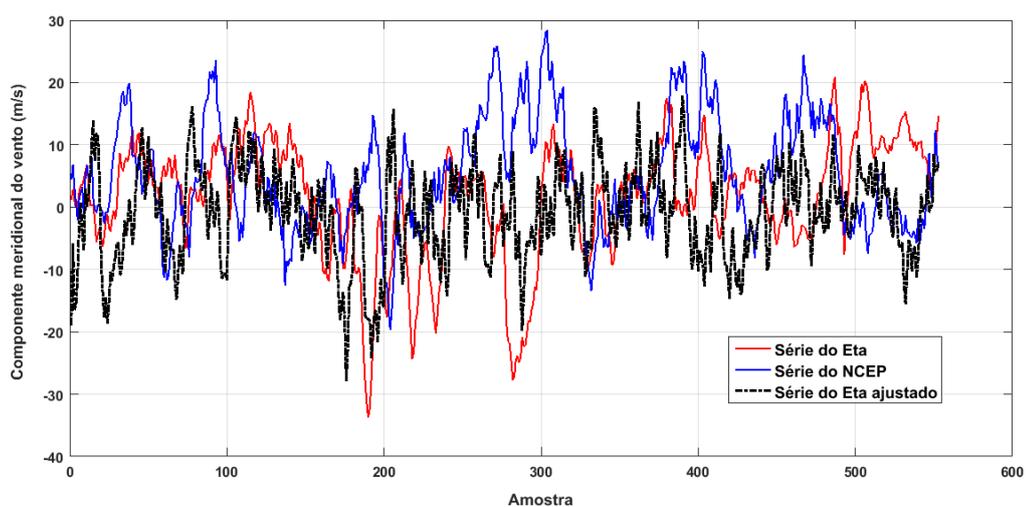


Figura 85 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 100 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

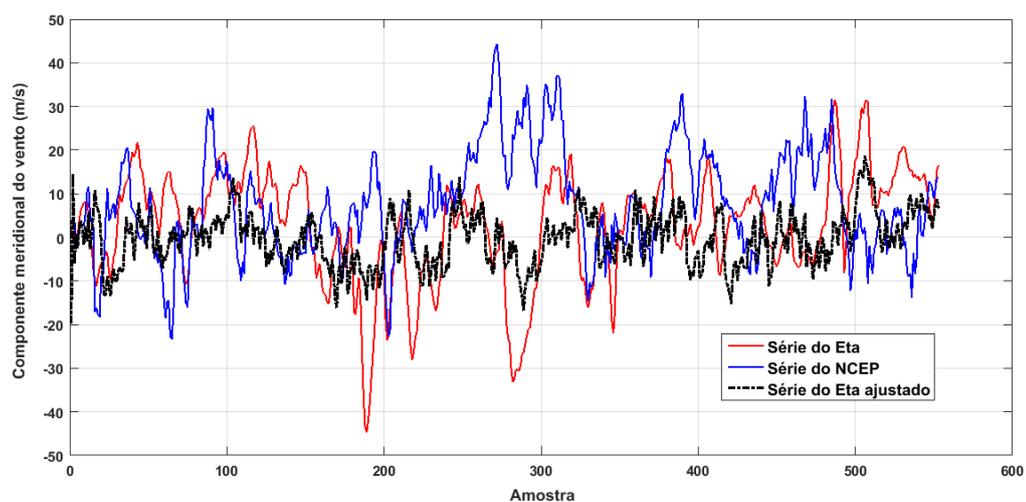


Figura 86 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 150 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

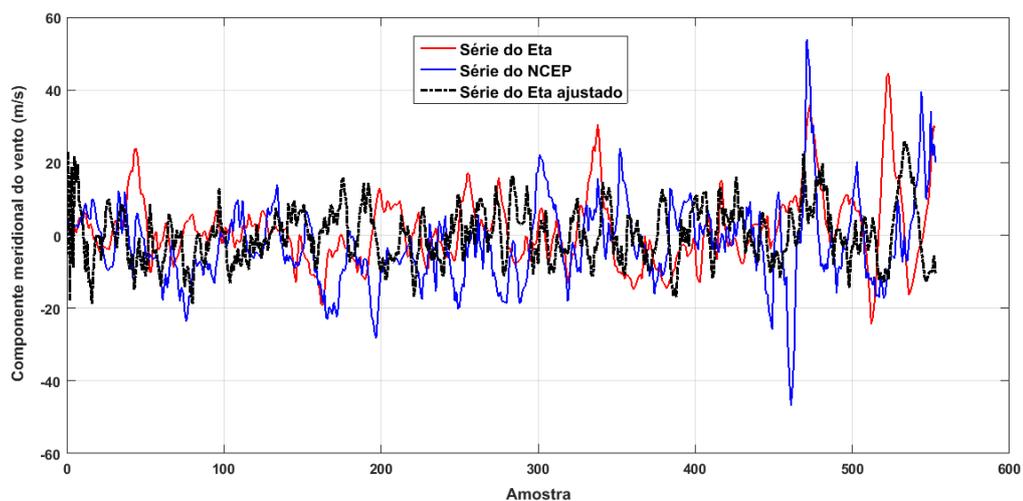


Figura 87 - Séries temporais para a componente meridional do vento ( $vvel$ ) a 200 hPa, coordenadas geográficas dos pixels ( $55^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

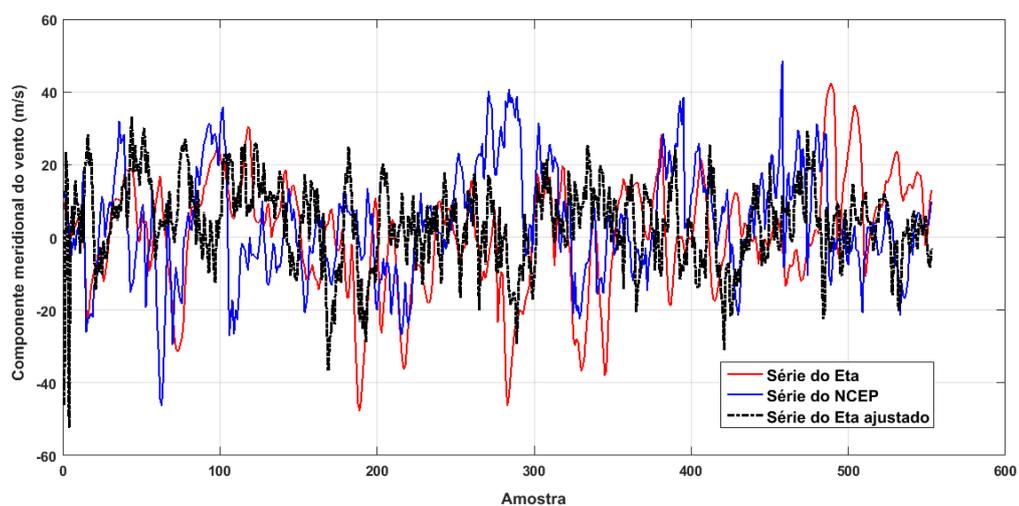


Figura 88 - Séries temporais para a componente meridional do vento ( $vvel$ ) a 250 hPa, coordenadas geográficas dos pixels ( $55^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

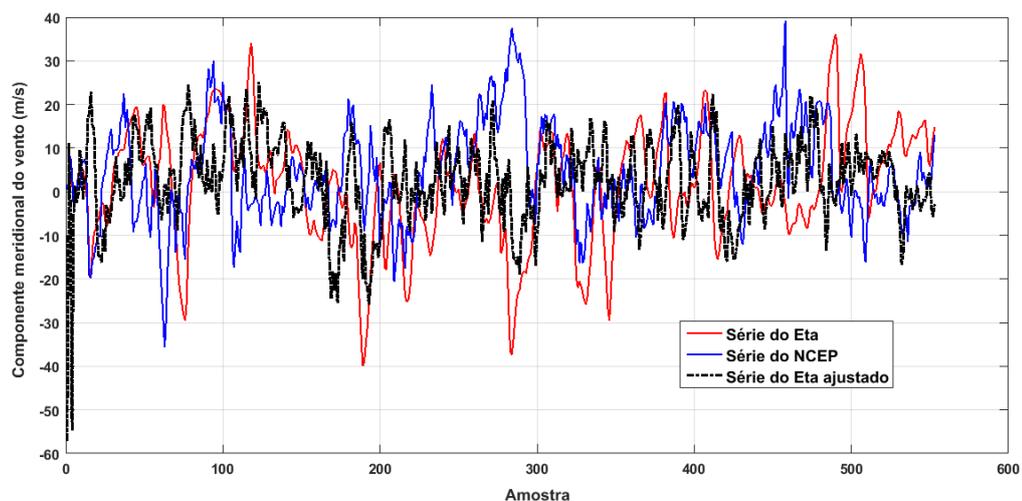


Figura 89 - Séries temporais para a componente meridional do vento (*vvel*) a 300 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

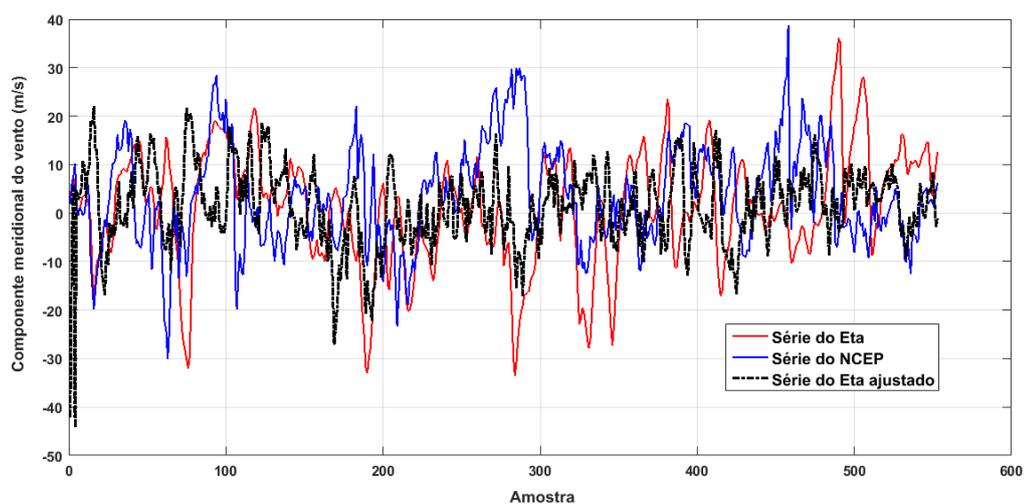


Figura 90 - Séries temporais para a componente meridional do vento (*vvel*) a 350 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

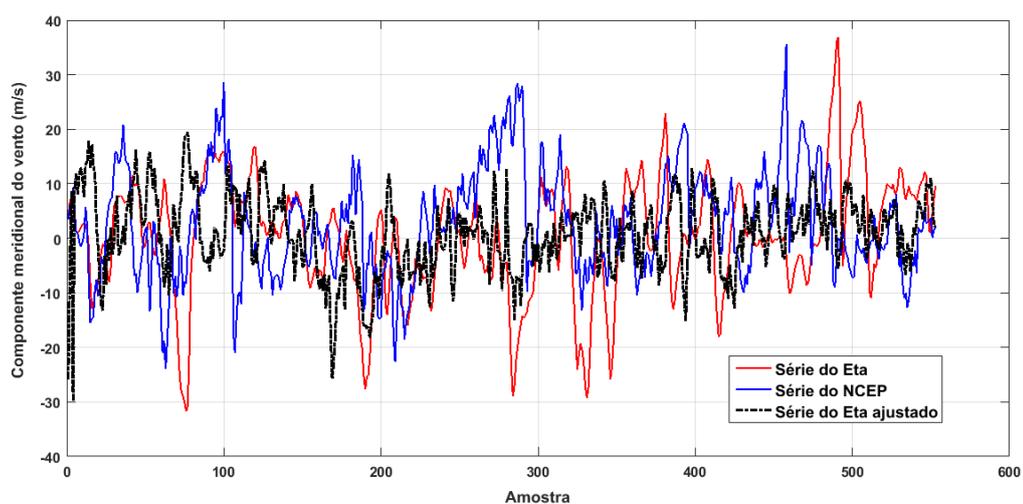


Figura 91 - Séries temporais para a componente meridional do vento (*vvel*) a 400 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

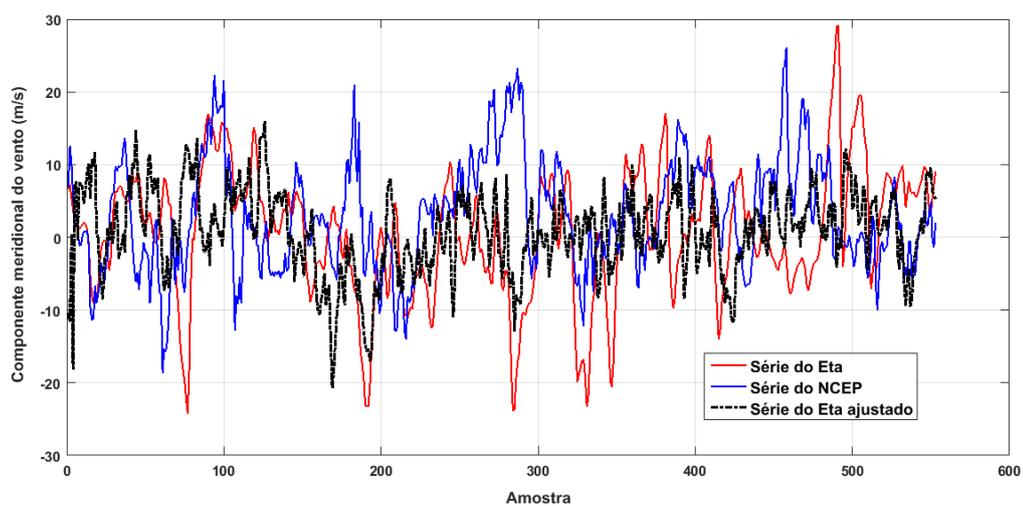


Figura 92 - Séries temporais para a componente meridional do vento (*vvel*) a 450 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

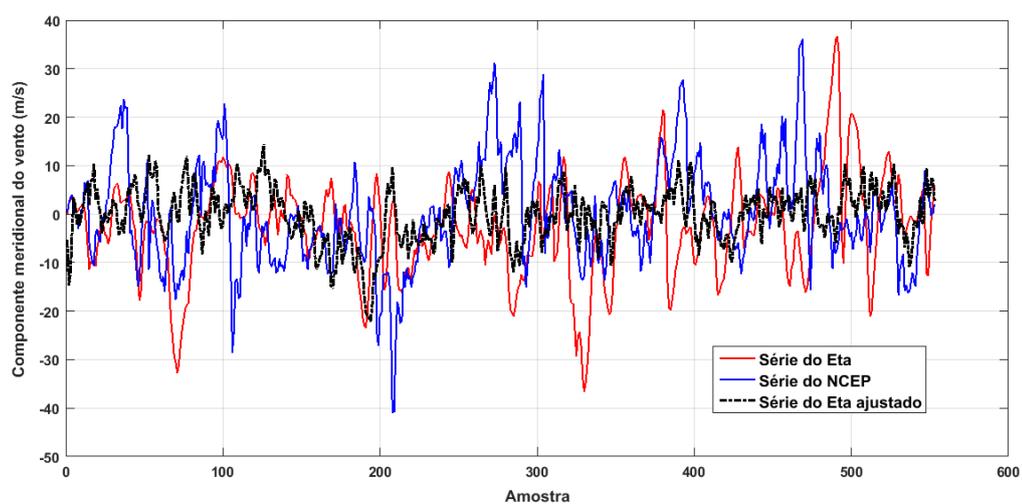


Figura 93 - Séries temporais para a componente meridional do vento (*vvel*) a 500 hPa, coordenadas geográficas dos pixels (55°W e 30°S), no ano de ajuste de 2010.

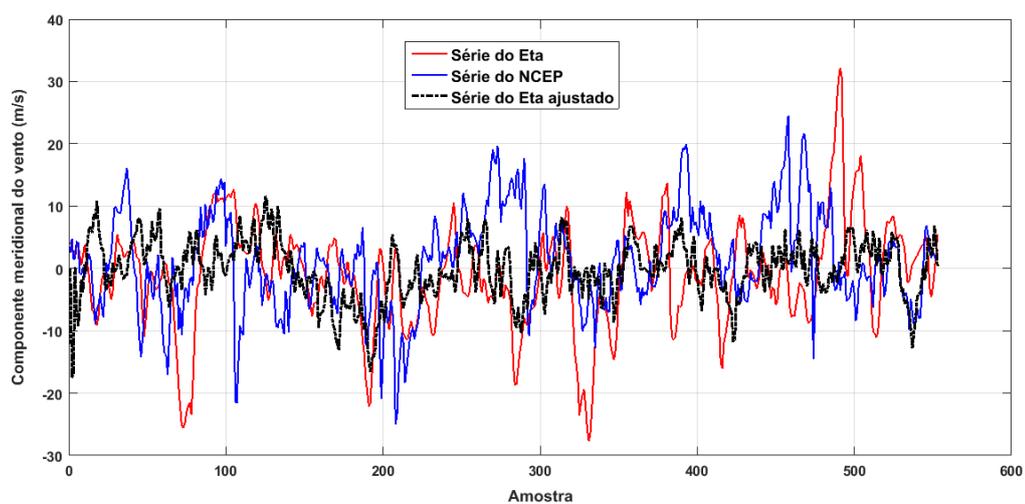


Figura 94 - Séries temporais para a componente meridional do vento (*vvel*) a 550 hPa, coordenadas geográficas dos pixels (55°W e 30°S), no ano de ajuste de 2010.

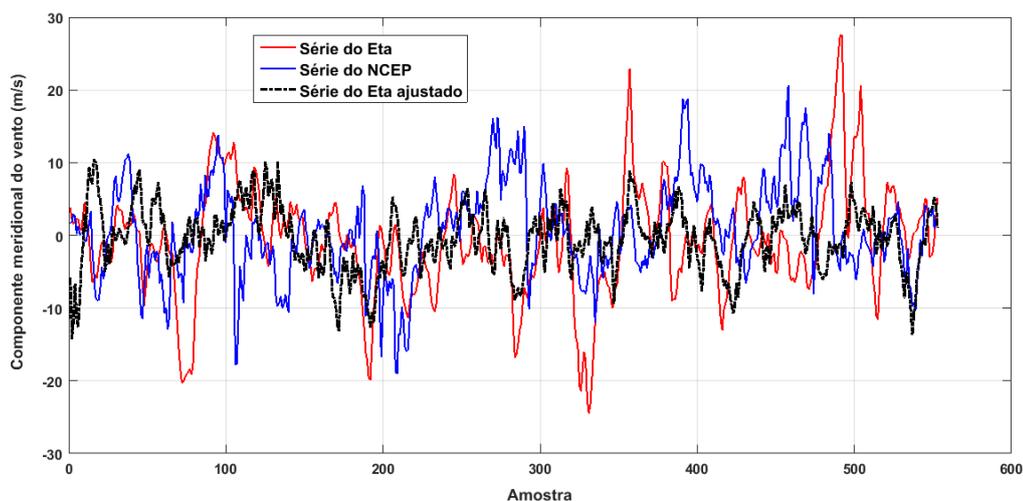


Figura 95 - Séries temporais para a componente meridional do vento (*vvel*) a 600 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

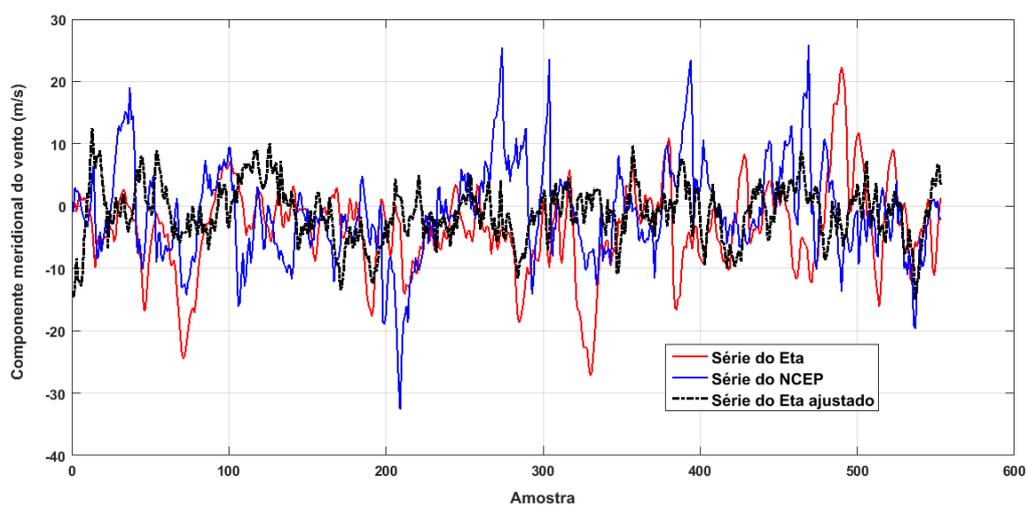


Figura 96 - Séries temporais para a componente meridional do vento (*vvel*) a 650 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

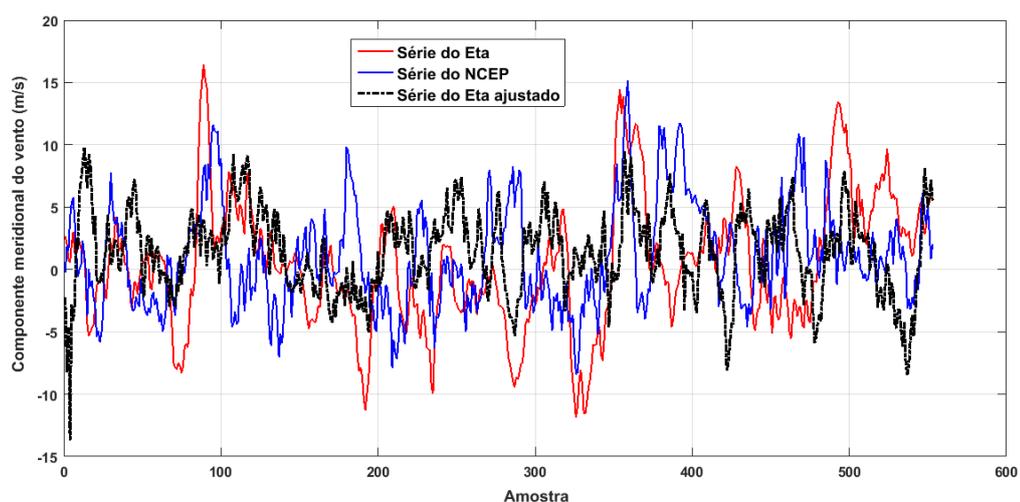


Figura 97 - Séries temporais para a componente meridional do vento ( $vvel$ ) a 700 hPa, coordenadas geográficas dos pixels ( $55^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

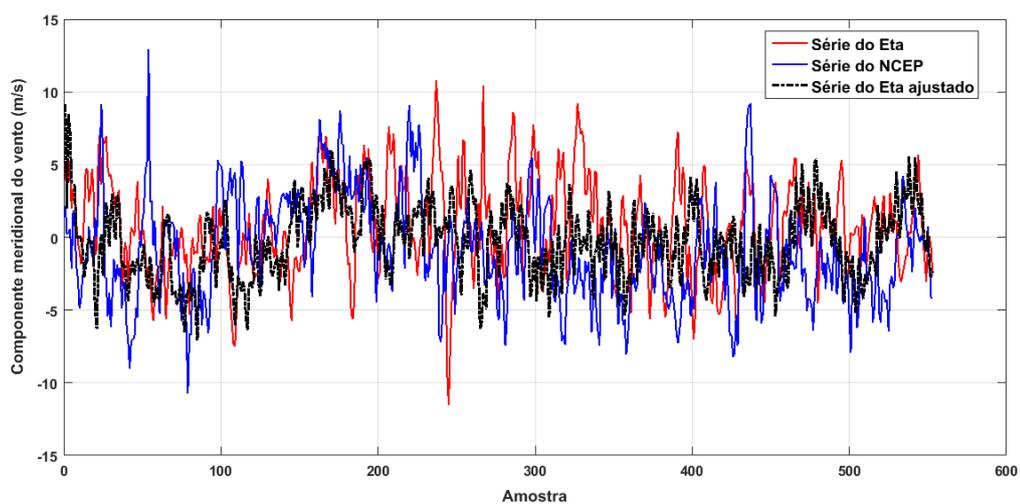


Figura 98 - Séries temporais para a componente meridional do vento ( $vvel$ ) a 750 hPa, coordenadas geográficas dos pixels ( $55^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

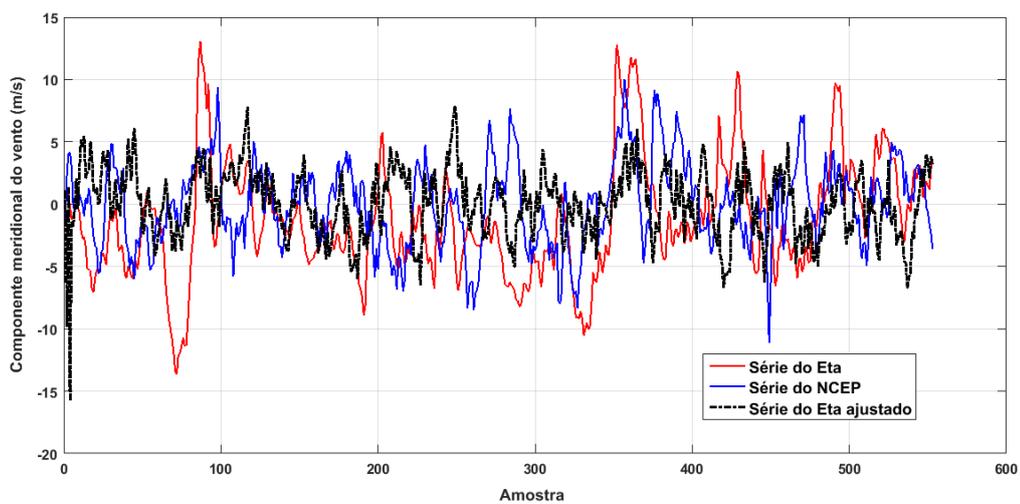


Figura 99 - Séries temporais para a componente meridional do vento (*vvel*) a 800 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

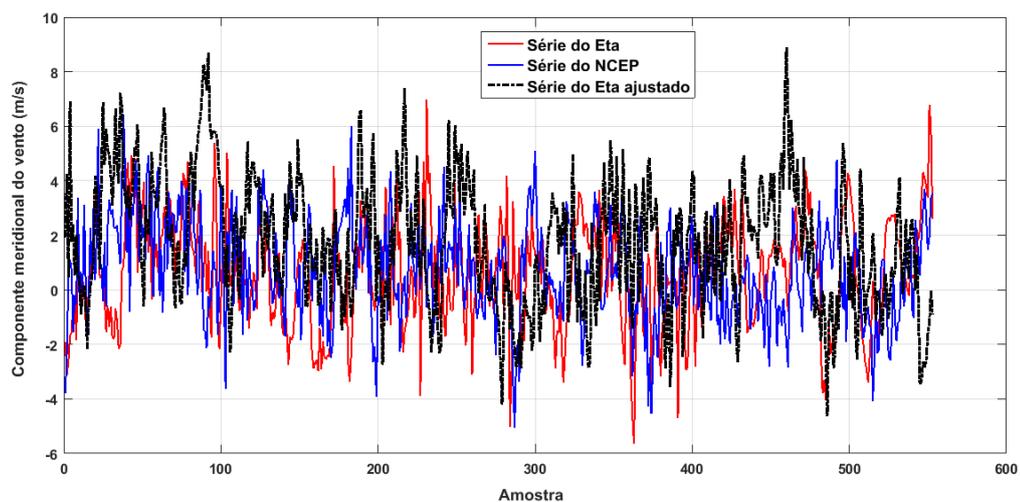


Figura 100 - Séries temporais para a componente meridional do vento (*vvel*) a 850 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

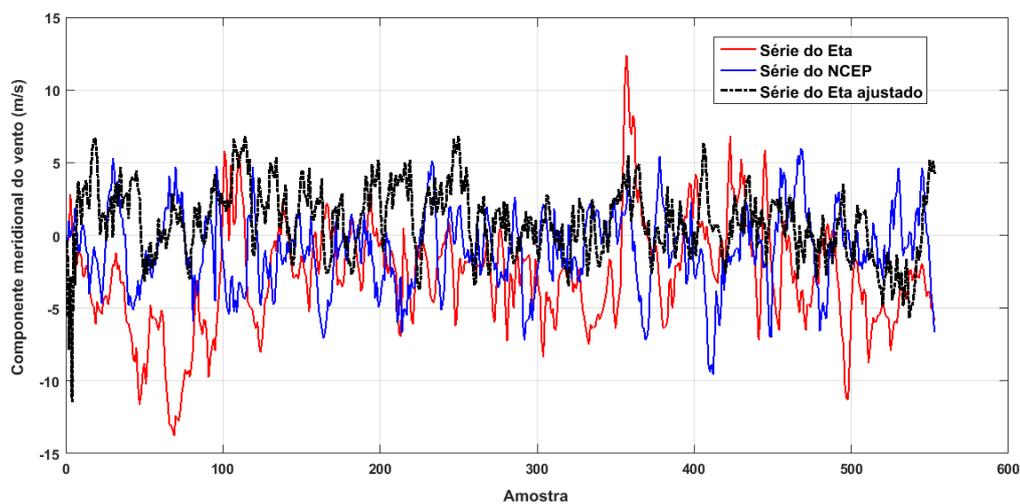


Figura 101 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 900 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

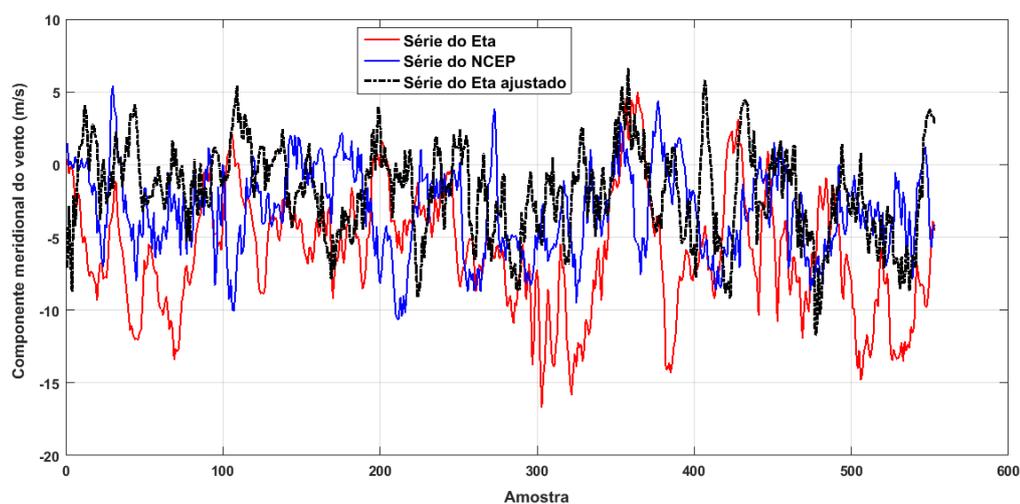


Figura 102 - Séries temporais para a componente meridional do vento ( $v_{vel}$ ) a 925 hPa, coordenadas geográficas dos pixels ( $55^{\circ}\text{W}$  e  $30^{\circ}\text{S}$ ), no ano de ajuste de 2010.

## Umidade específica

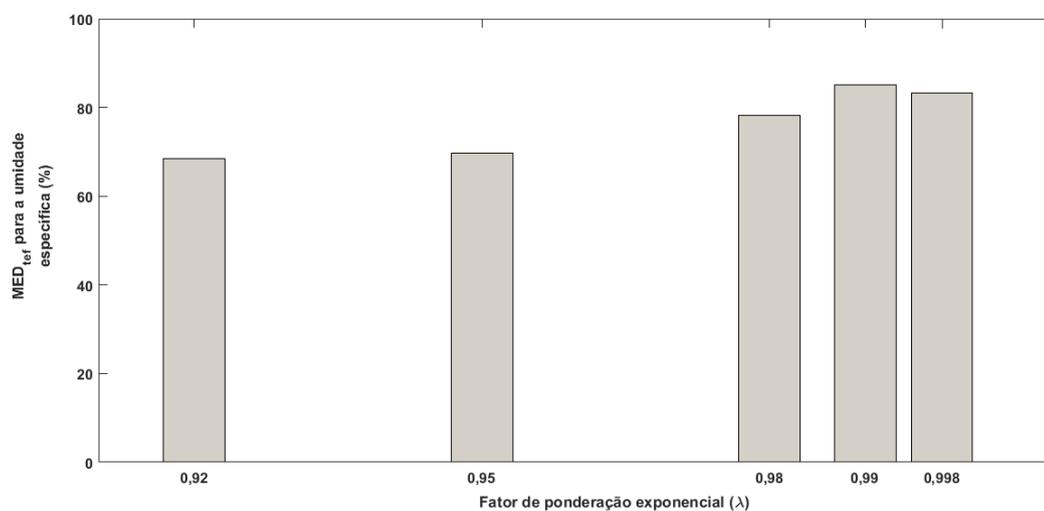


Figura 103 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a umidade específica ( $umes$ ), no ano de treinamento de 2008.

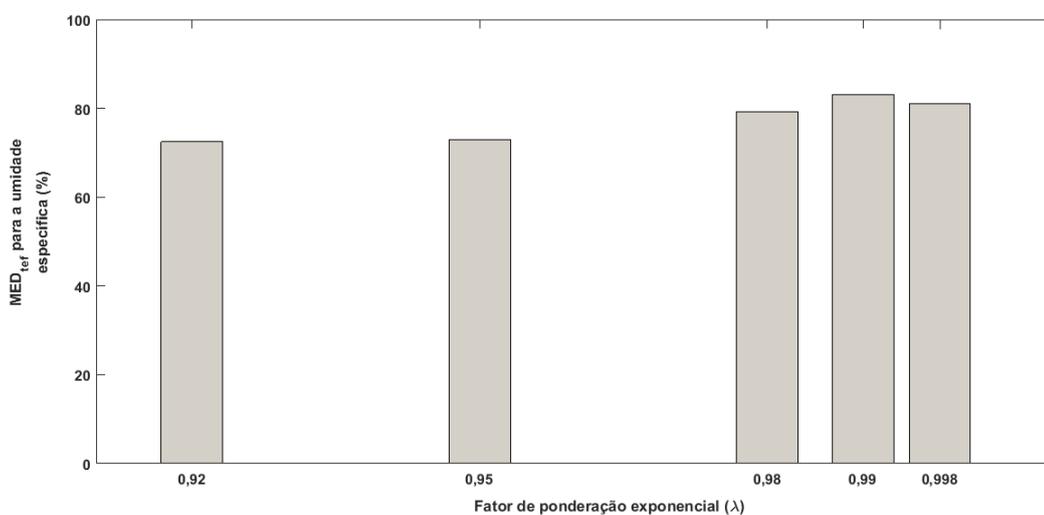


Figura 104 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a umidade específica ( $umes$ ), no ano de treinamento de 2009.

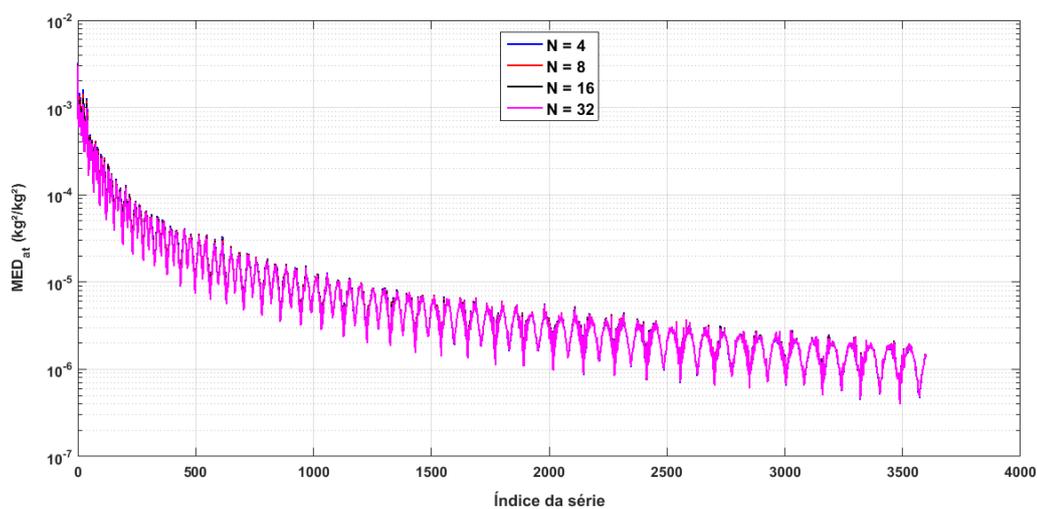


Figura 105 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a umidade específica, no ano de treinamento de 2008.

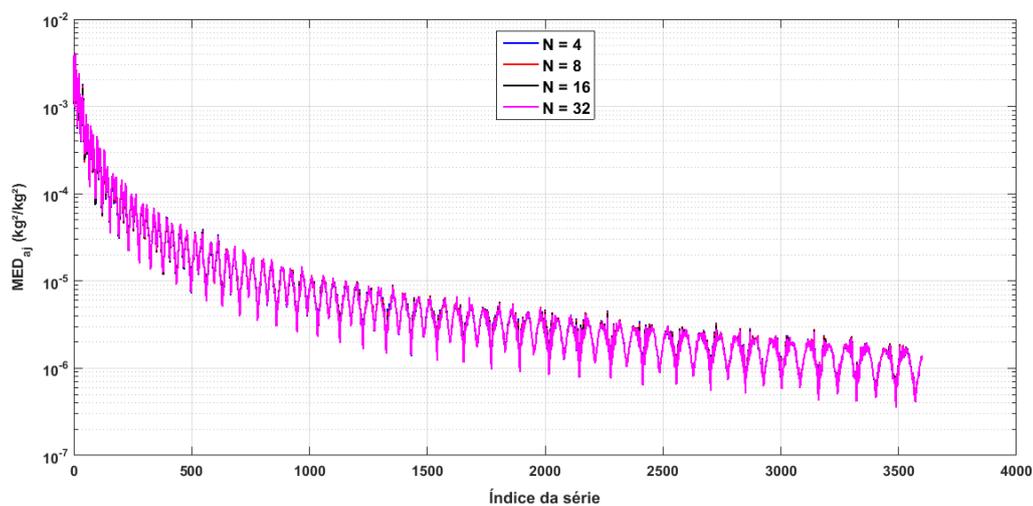


Figura 106 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a umidade específica, no ano de ajuste de 2009.

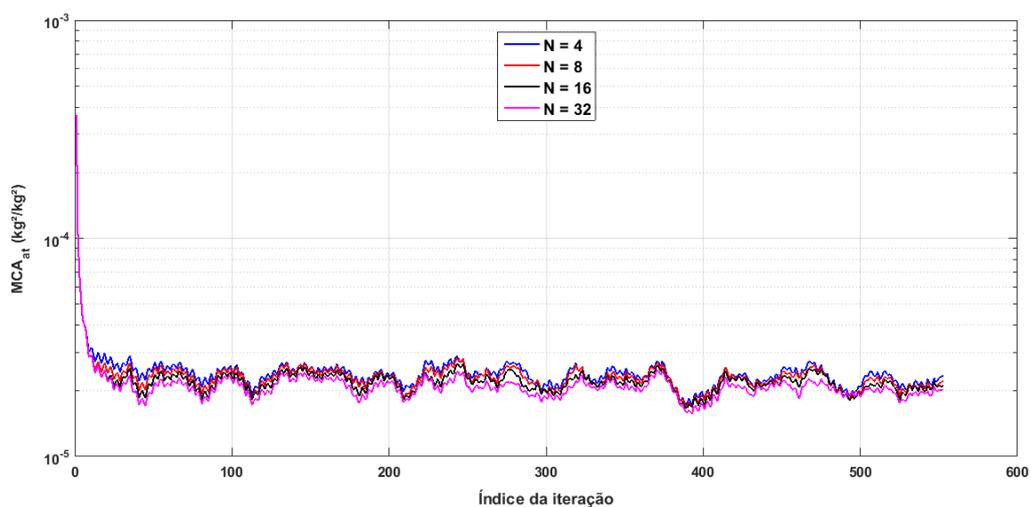


Figura 107 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a umidade específica, no ano de treinamento de 2008.

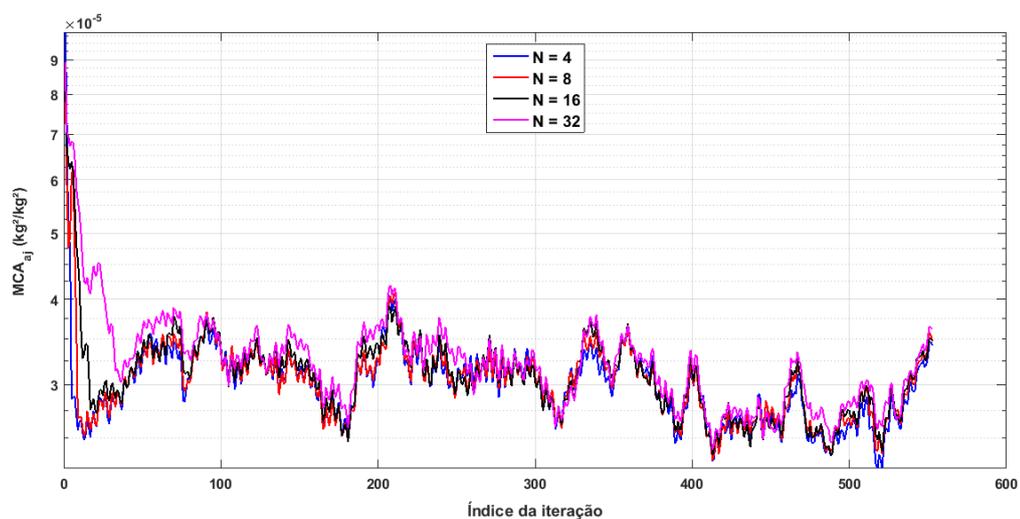


Figura 108 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a umidade específica, no ano de ajuste de 2009.

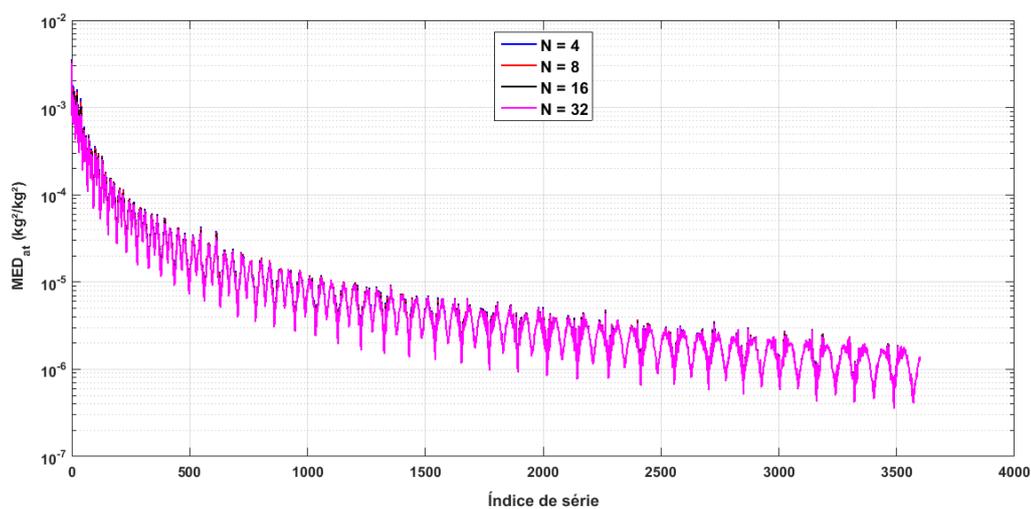


Figura 109 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a umidade específica, no ano de treinamento de 2009.

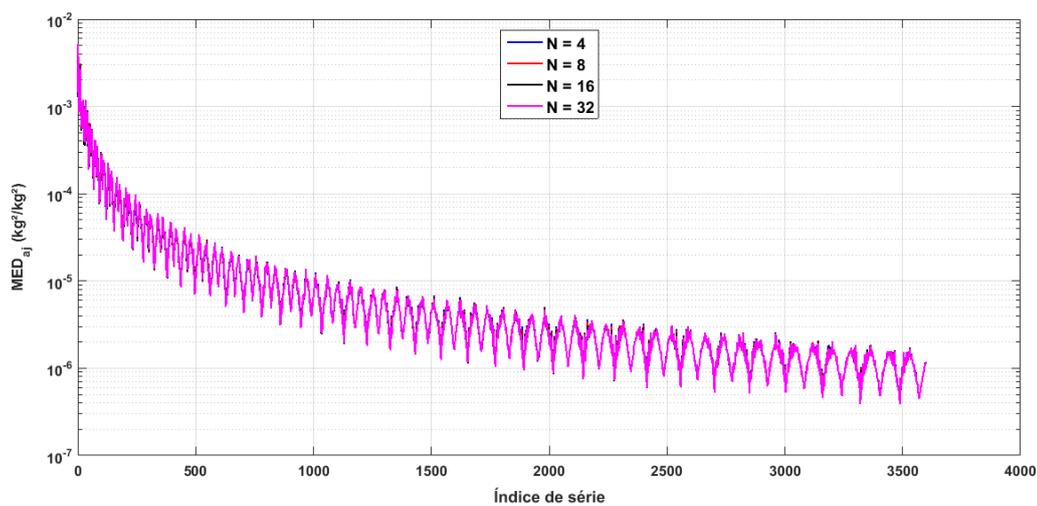


Figura 110 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a umidade específica, no ano de ajuste de 2010.

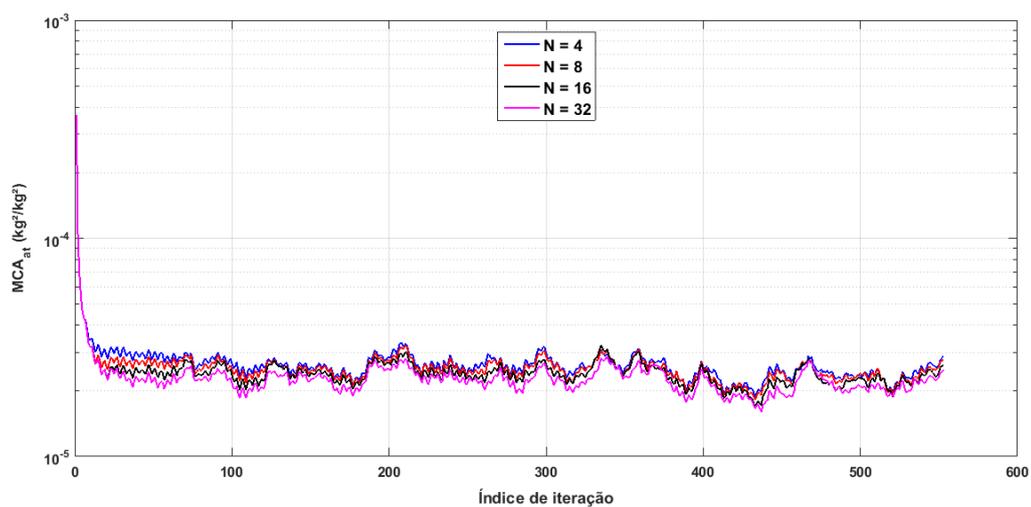


Figura 111 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a umidade específica, no ano de treinamento de 2009.

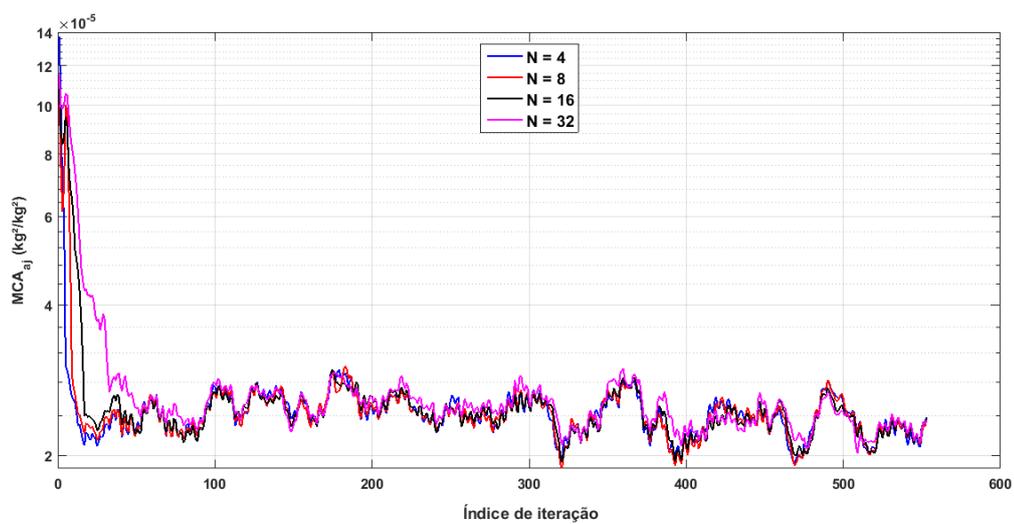


Figura 112 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a umidade específica, no ano de ajuste de 2010.

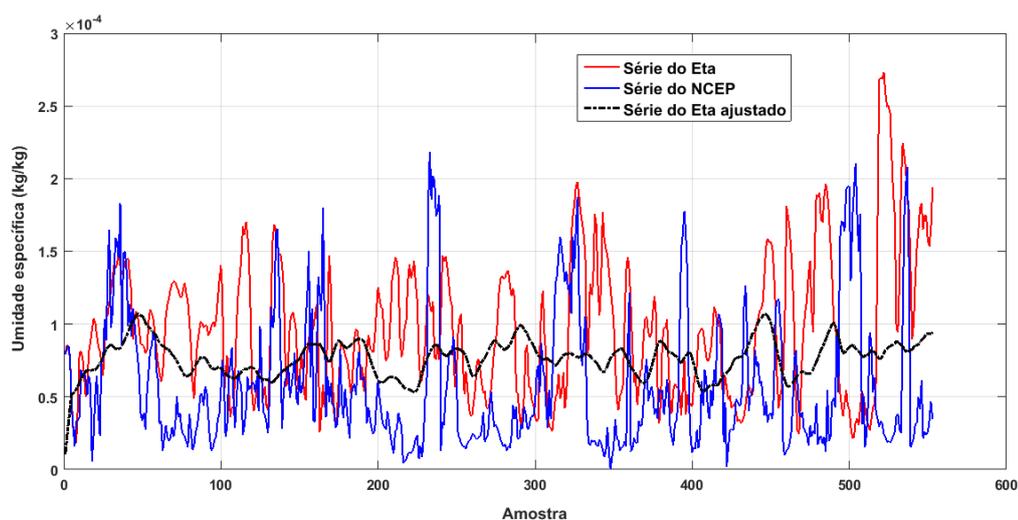


Figura 113 - Séries temporais para a umidade específica ( $umes$ ) a 250 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

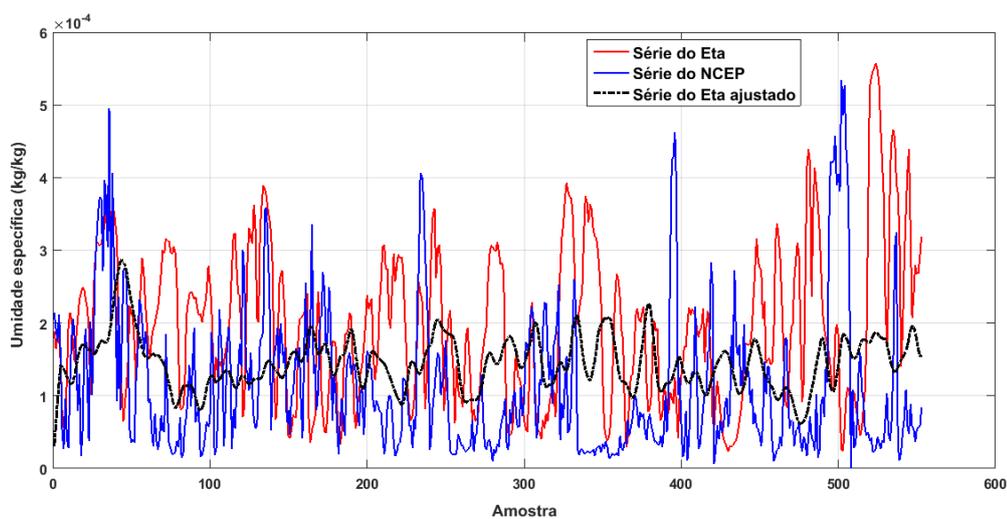


Figura 114 - Séries temporais para a umidade específica ( $umes$ ) a 300 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

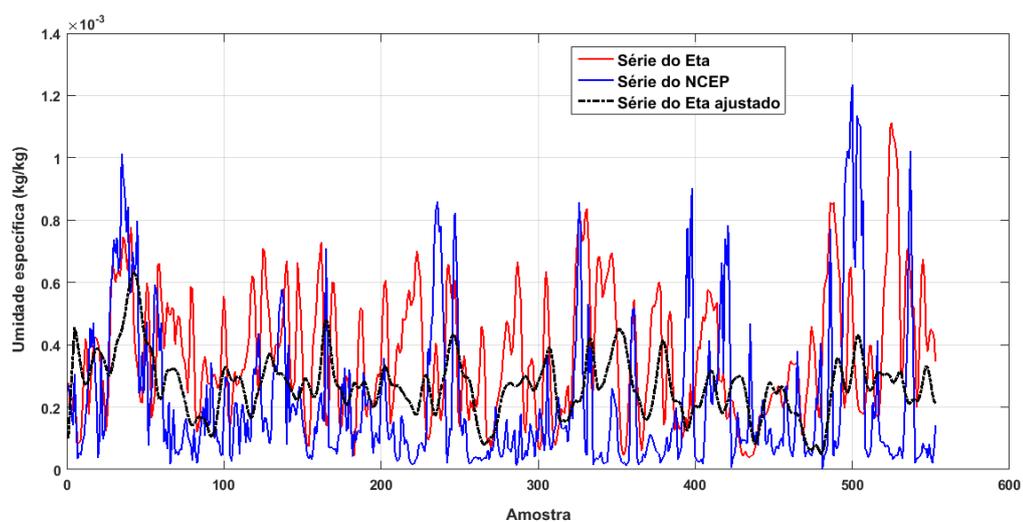


Figura 115 - Séries temporais para a umidade específica ( $umes$ ) a 350 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

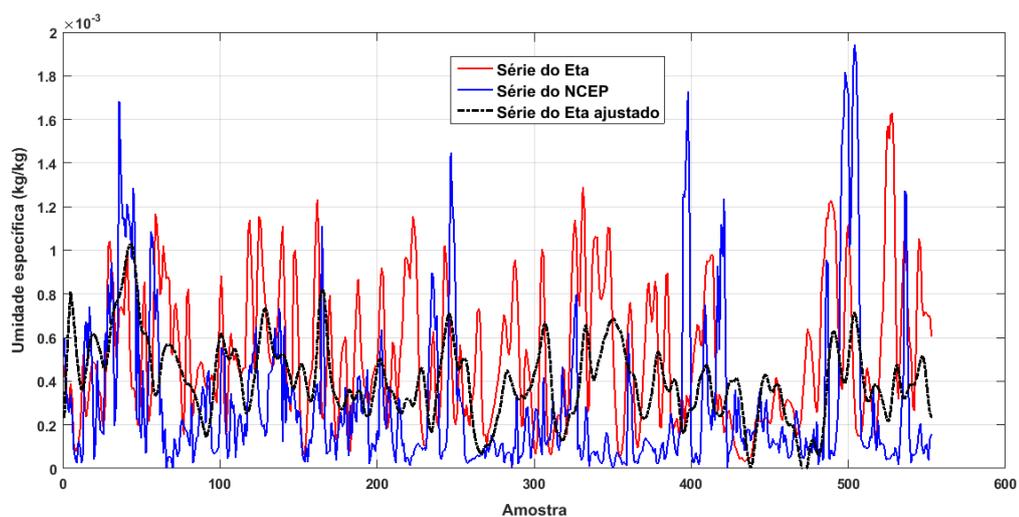


Figura 116 - Séries temporais para a umidade específica ( $umes$ ) a 400 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

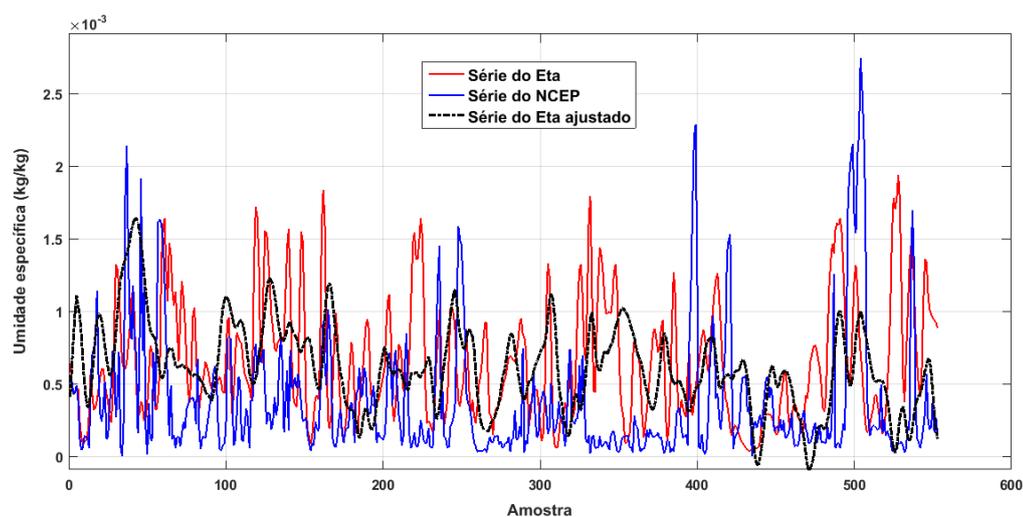


Figura 117 - Séries temporais para a umidade específica ( $umes$ ) a 450 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

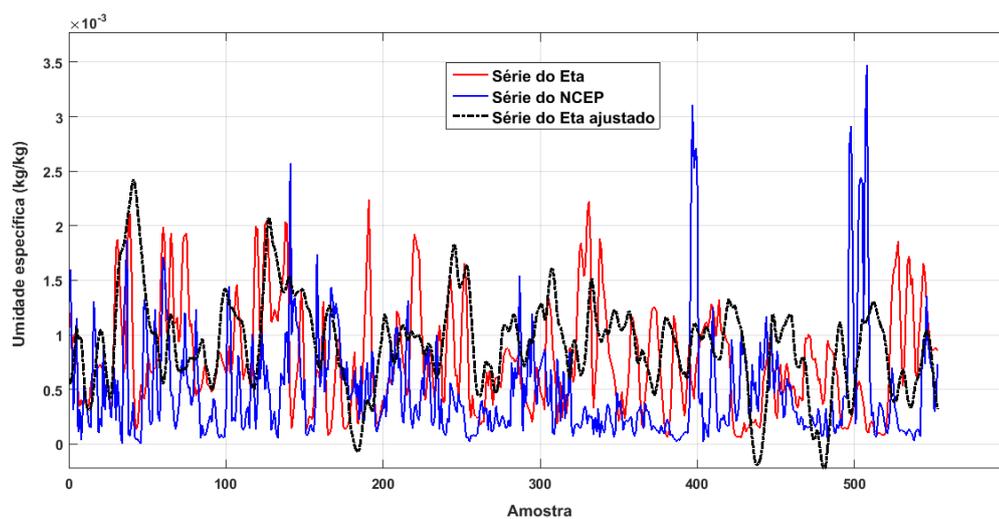


Figura 118 - Séries temporais para a umidade específica ( $umes$ ) a 500 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

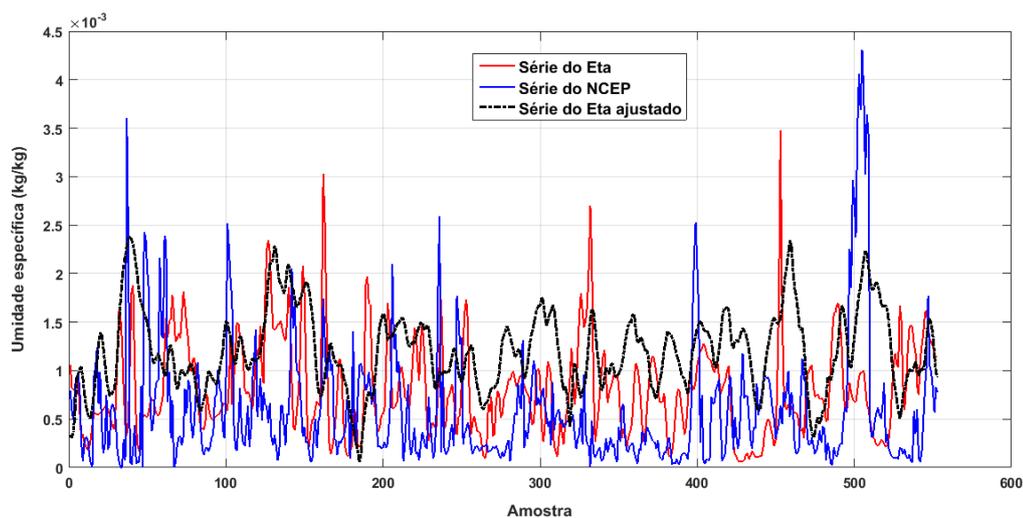


Figura 119 - Séries temporais para a umidade específica ( $umes$ ) a 550 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

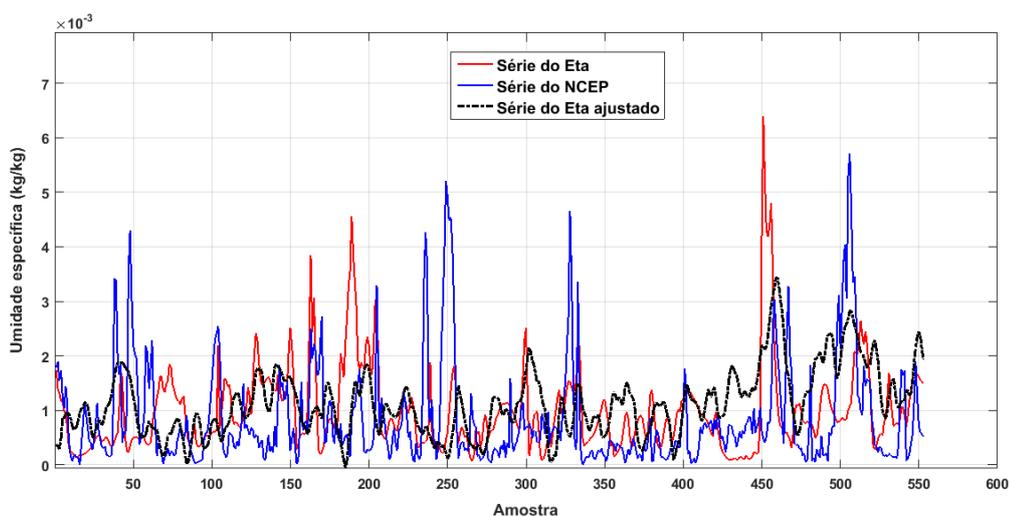


Figura 120 - Séries temporais para a umidade específica ( $umes$ ) a 600 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

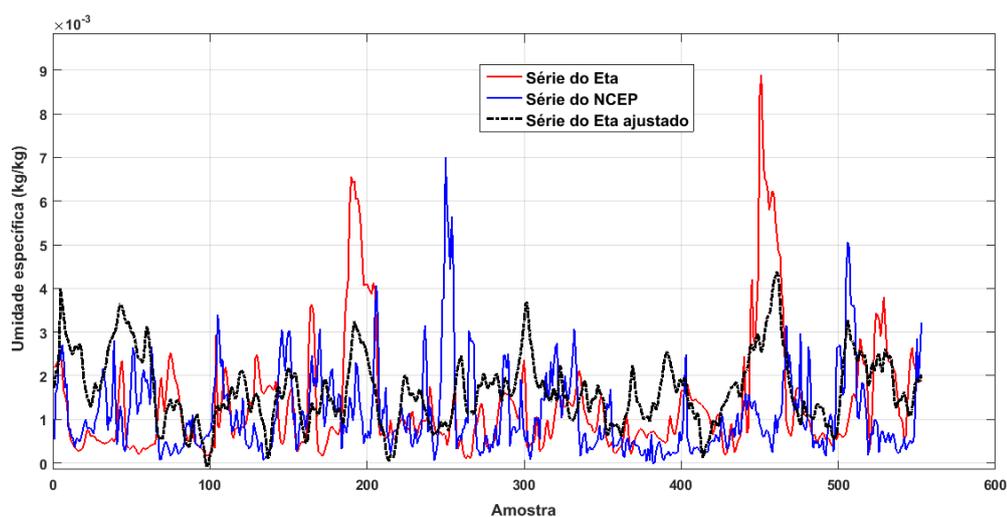


Figura 121 - Séries temporais para a umidade específica ( $umes$ ) a 700 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

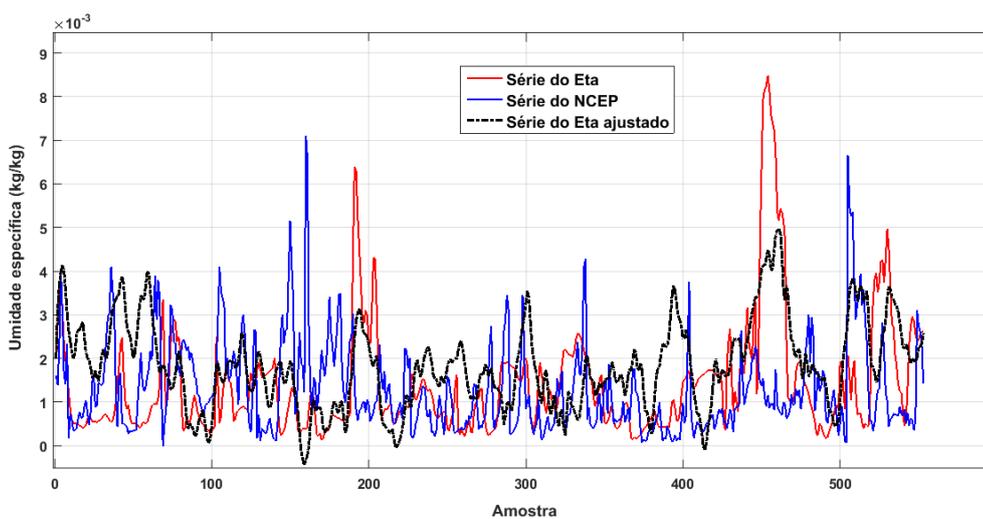


Figura 122 - Séries temporais para a umidade específica ( $umes$ ) a 750 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

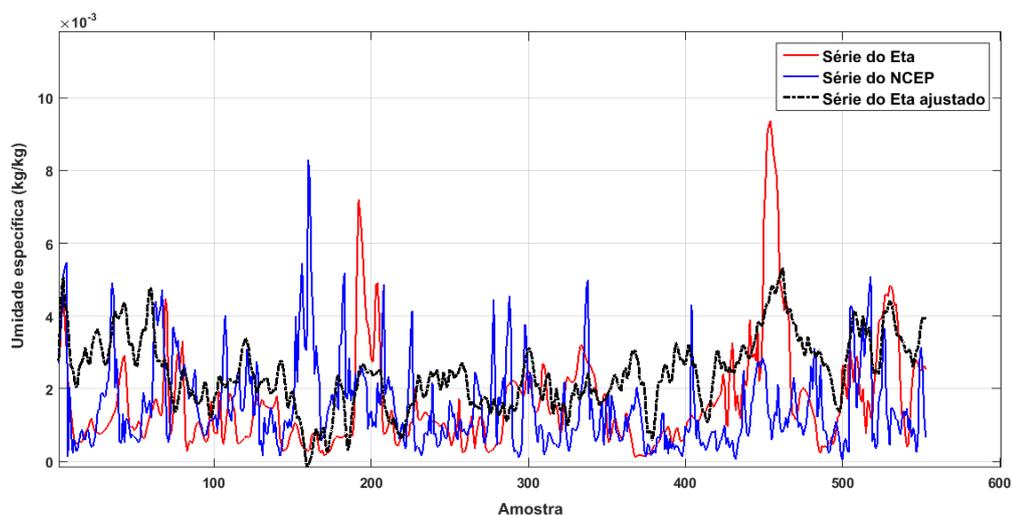


Figura 123 - Séries temporais para a umidade específica ( $umes$ ) a 800 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

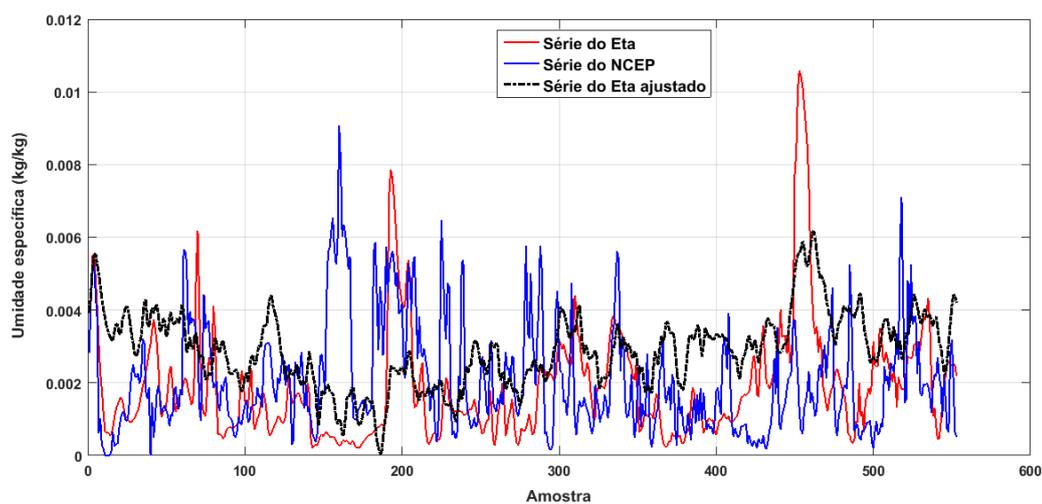


Figura 124 - Séries temporais para a umidade específica ( $umes$ ) a 850 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

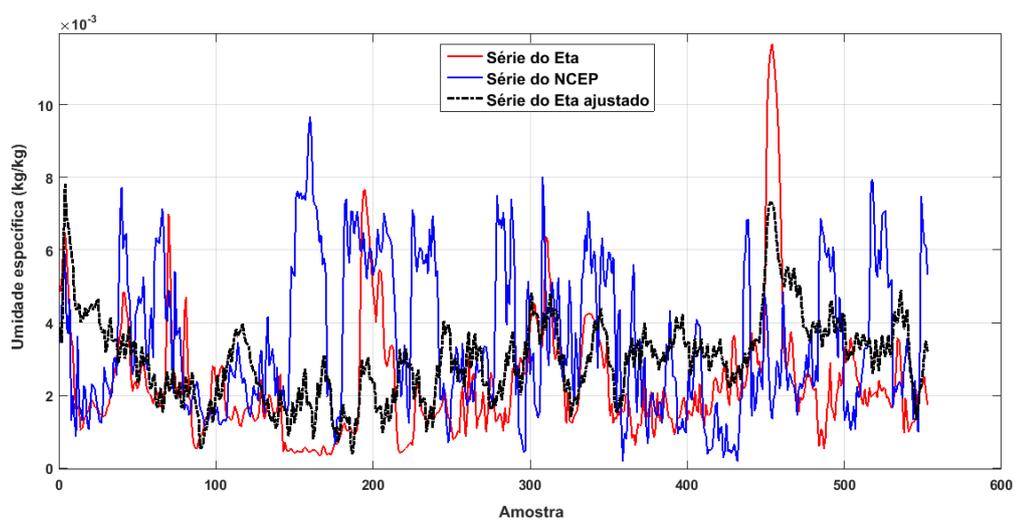


Figura 125 - Séries temporais para a umidade específica ( $umes$ ) a 900 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

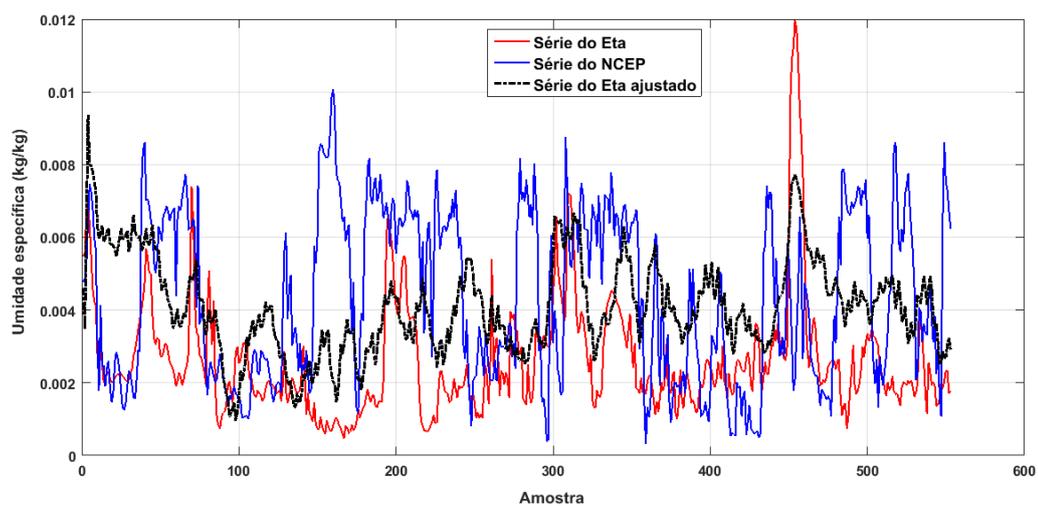


Figura 126 - Séries temporais para a umidade específica ( $umes$ ) a 925 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

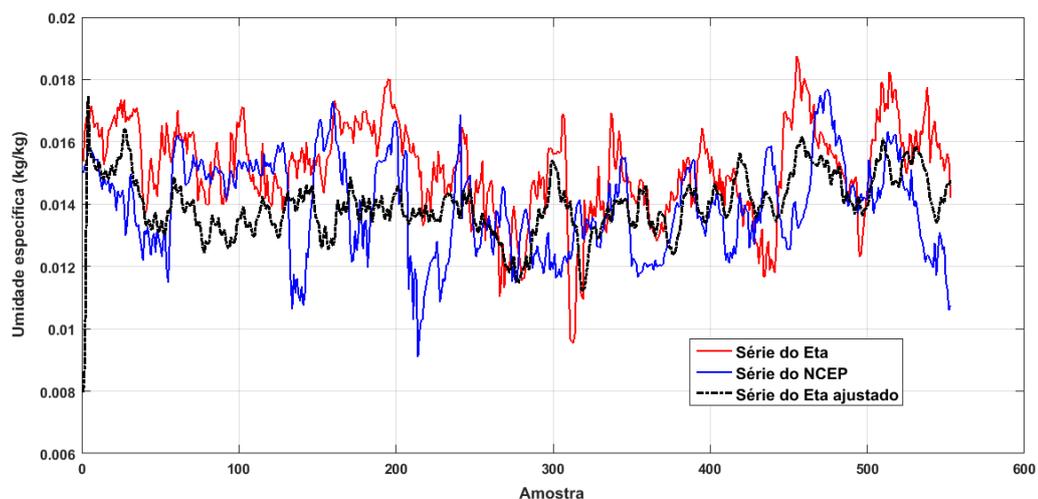


Figura 127 - Séries temporais para a umidade específica ( $umes$ ) a 1000 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

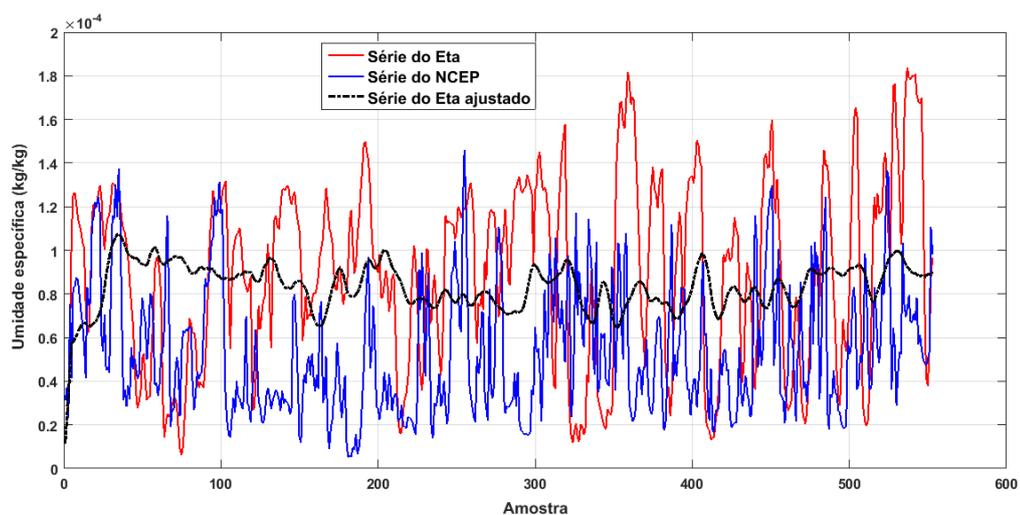


Figura 128 - Séries temporais para a umidade específica ( $umes$ ) a 250 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

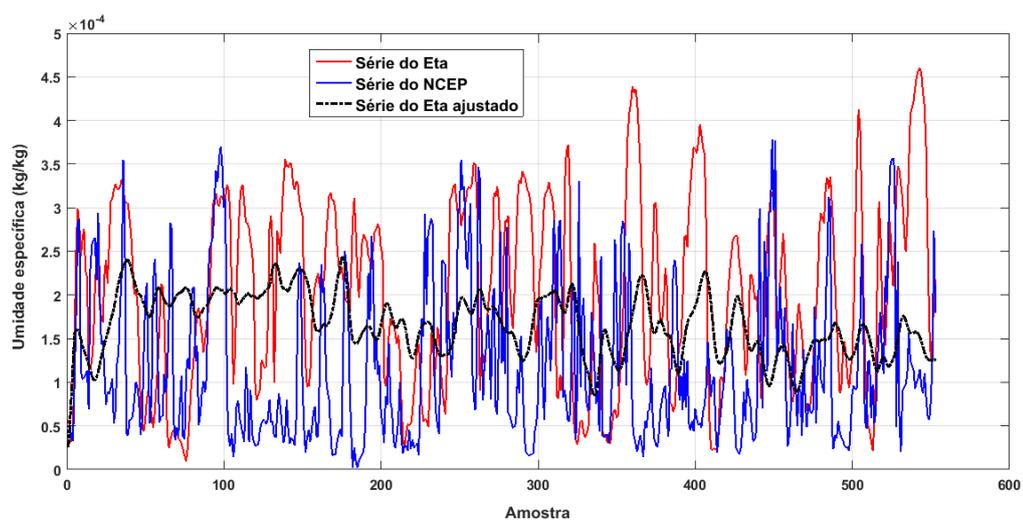


Figura 129 - Séries temporais para a umidade específica ( $umes$ ) a 300 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

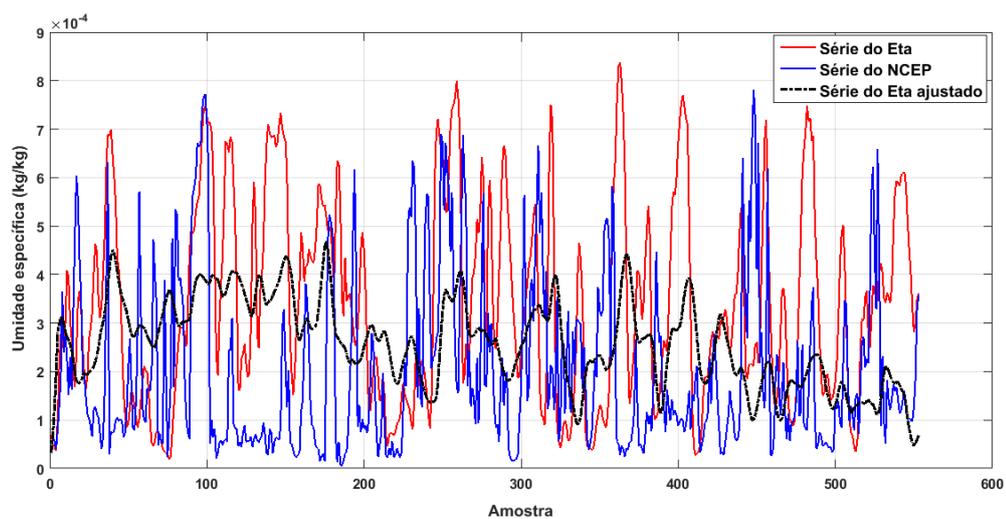


Figura 130 - Séries temporais para a umidade específica ( $umes$ ) a 350 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

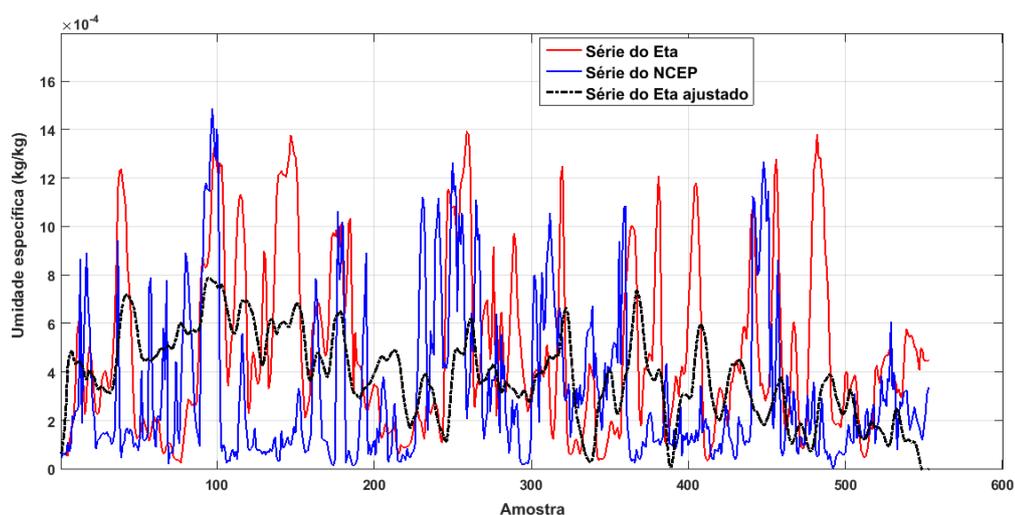


Figura 131 - Séries temporais para a umidade específica ( $umes$ ) a 400 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

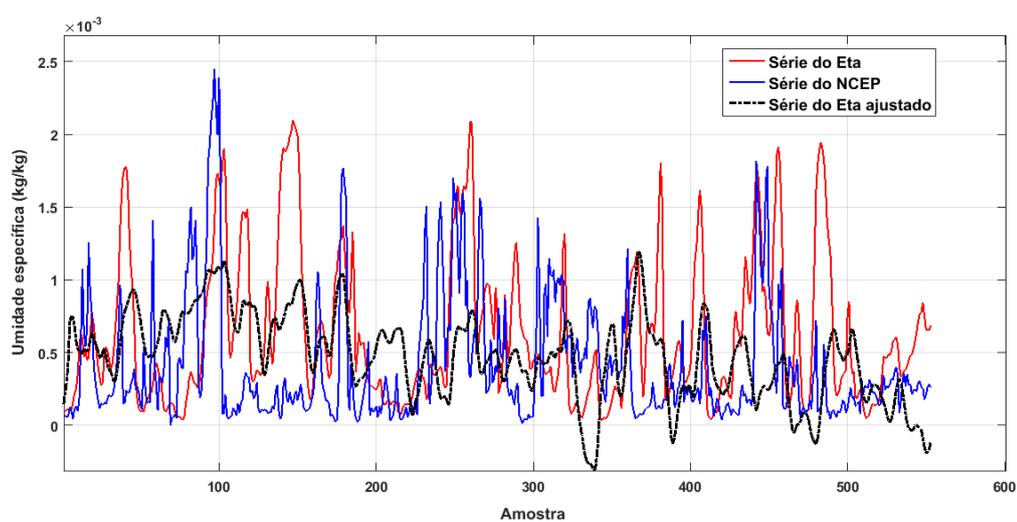


Figura 132 - Séries temporais para a umidade específica ( $umes$ ) a 450 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

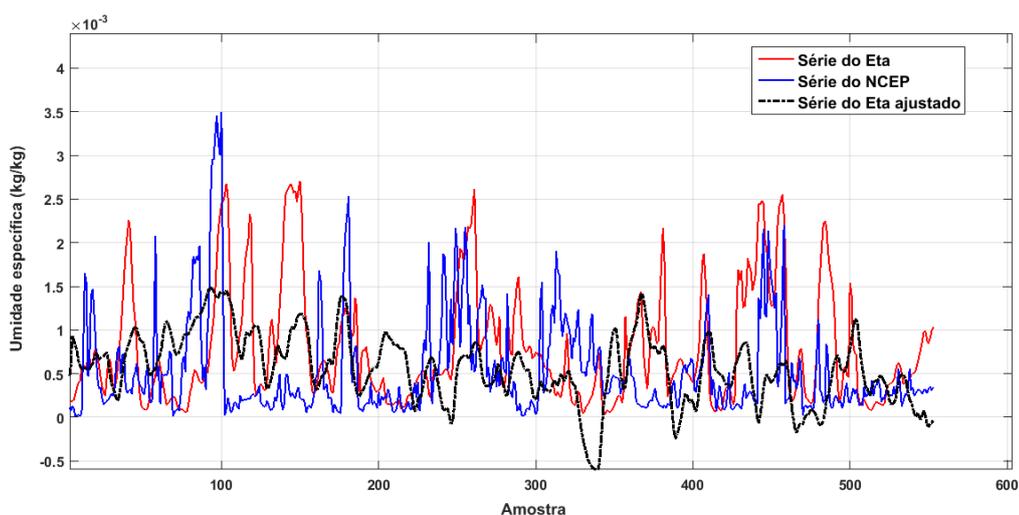


Figura 133 - Séries temporais para a umidade específica ( $umes$ ) a 500 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

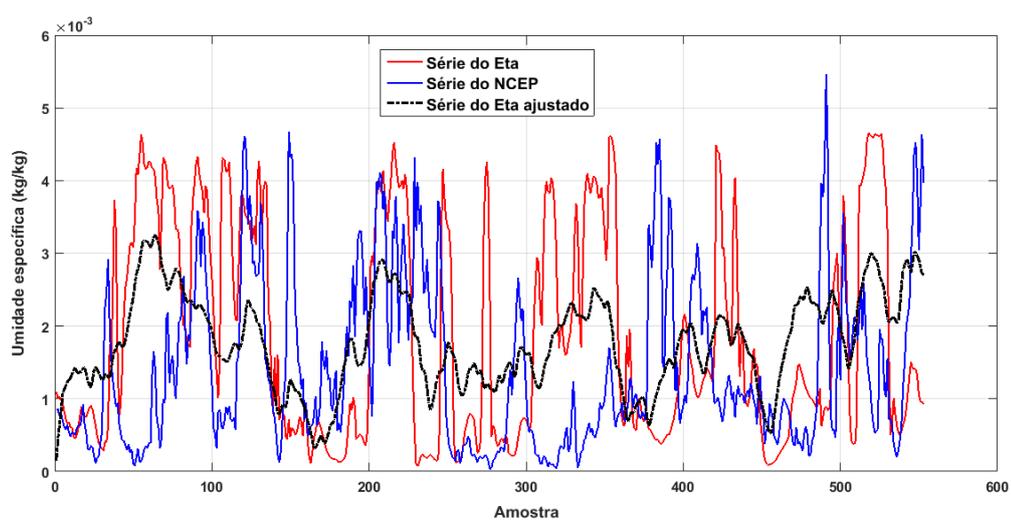


Figura 134 - Séries temporais para a umidade específica ( $umes$ ) a 550 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

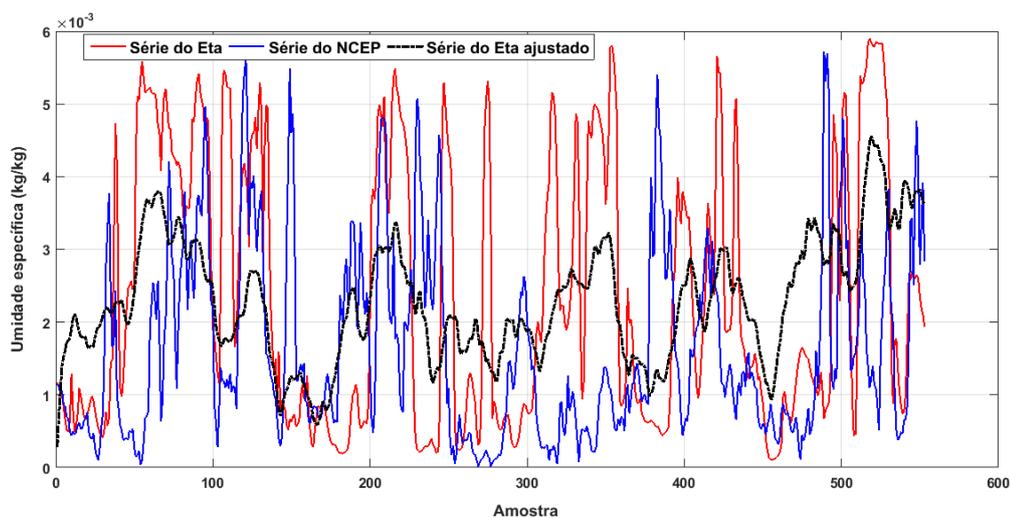


Figura 135 - Séries temporais para a umidade específica ( $umes$ ) a 600 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

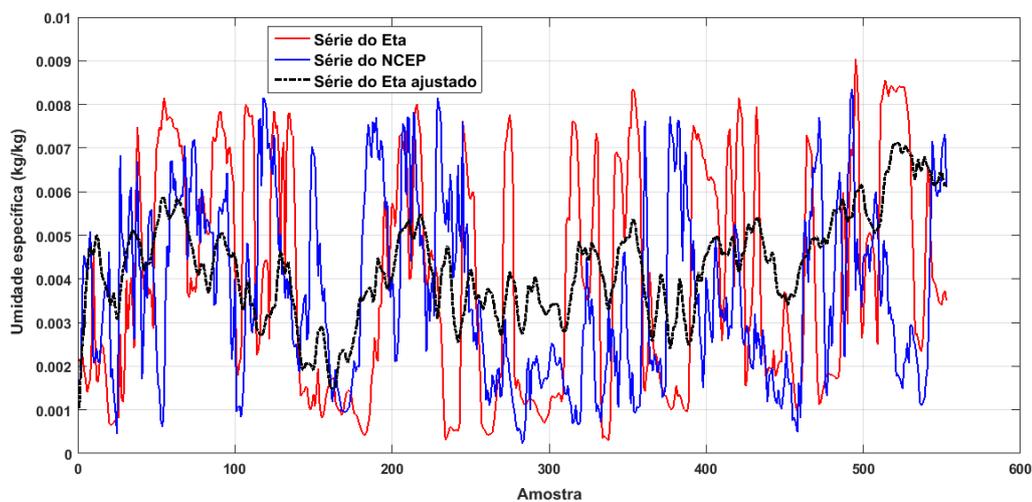


Figura 136 - Séries temporais para a umidade específica ( $umes$ ) a 700 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

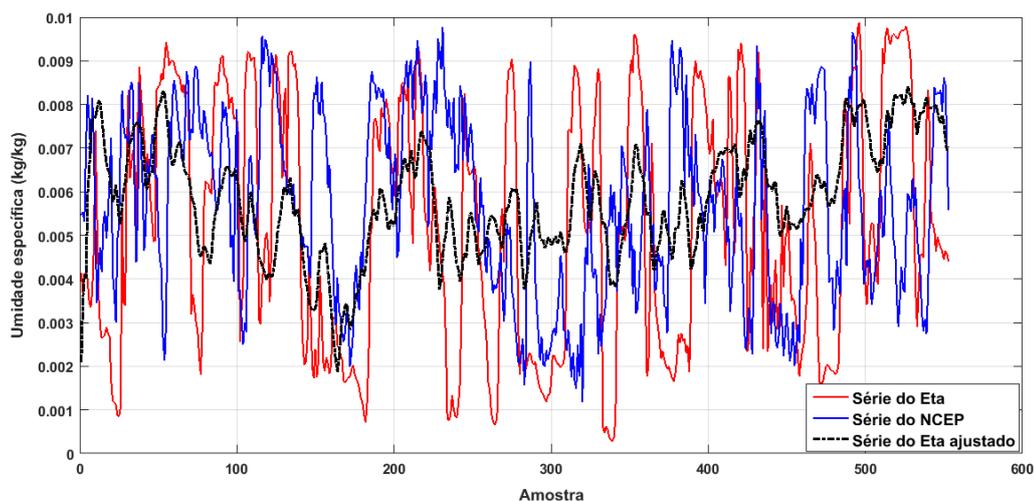


Figura 137 - Séries temporais para a umidade específica ( $u_{mes}$ ) a 750 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

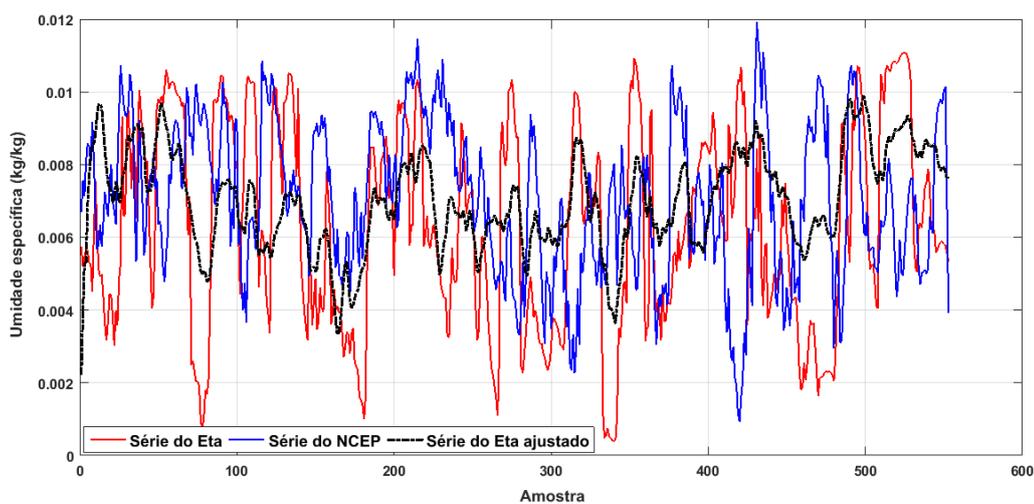


Figura 138 - Séries temporais para a umidade específica ( $u_{mes}$ ) a 800 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

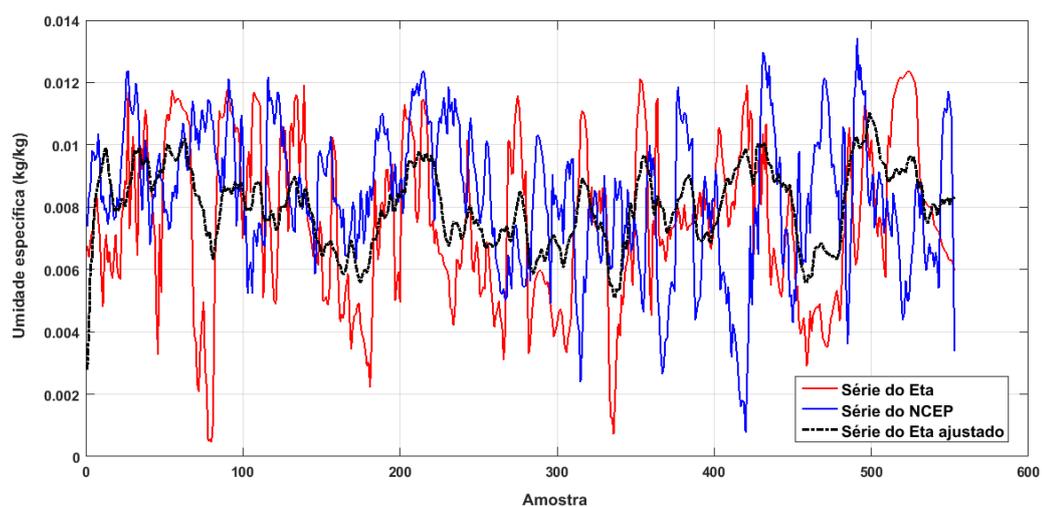


Figura 139 - Séries temporais para a umidade específica ( $umes$ ) a 850 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

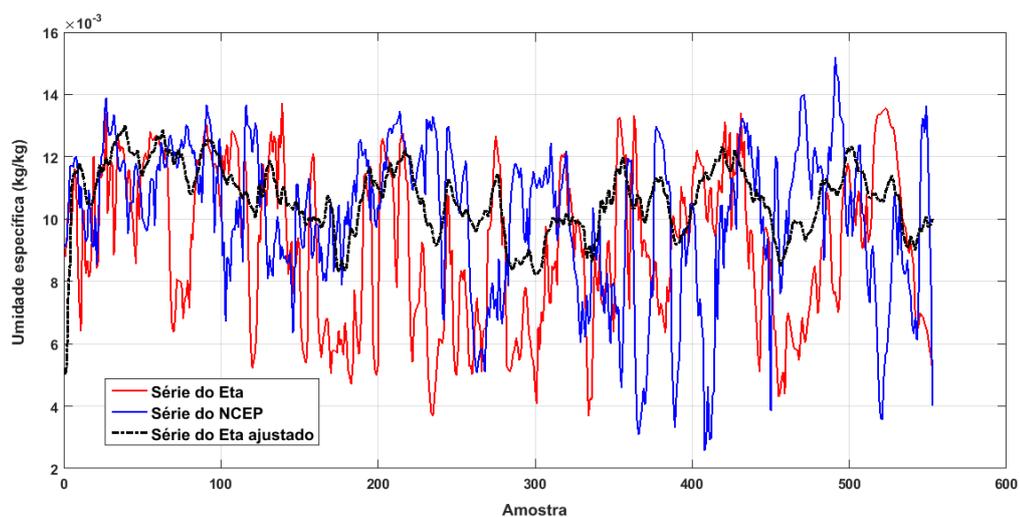


Figura 140 - Séries temporais para a umidade específica ( $umes$ ) a 900 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

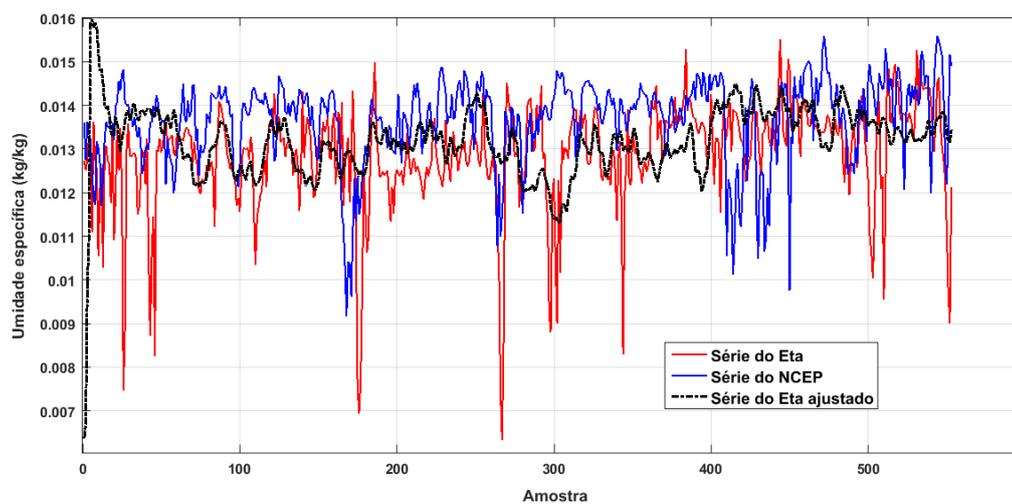


Figura 141 - Séries temporais para a umidade específica ( $umes$ ) a 925 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

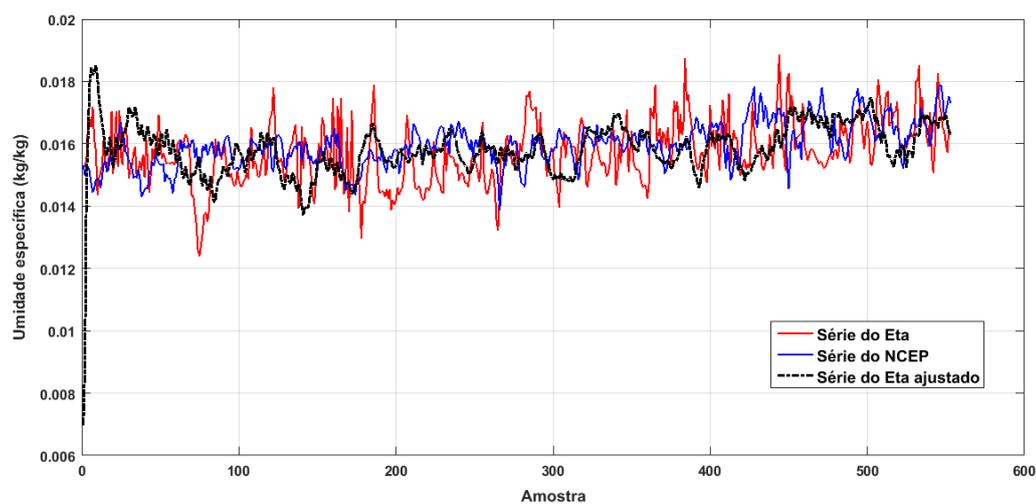


Figura 142 - Séries temporais para a umidade específica ( $umes$ ) a 1000 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2010.

## Altura geopotencial

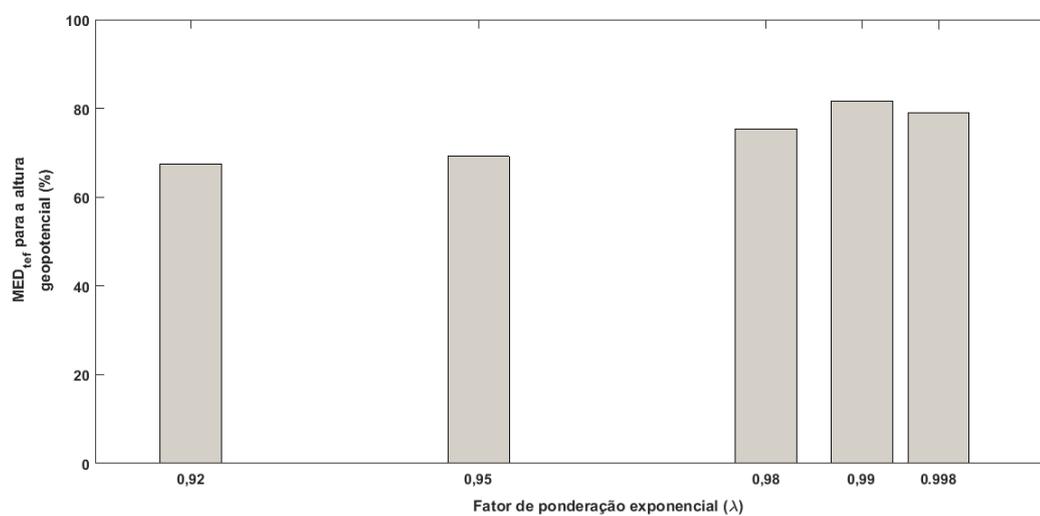


Figura 143 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a altura geopotencial ( $z_{geo}$ ), no ano de treinamento de 2008.

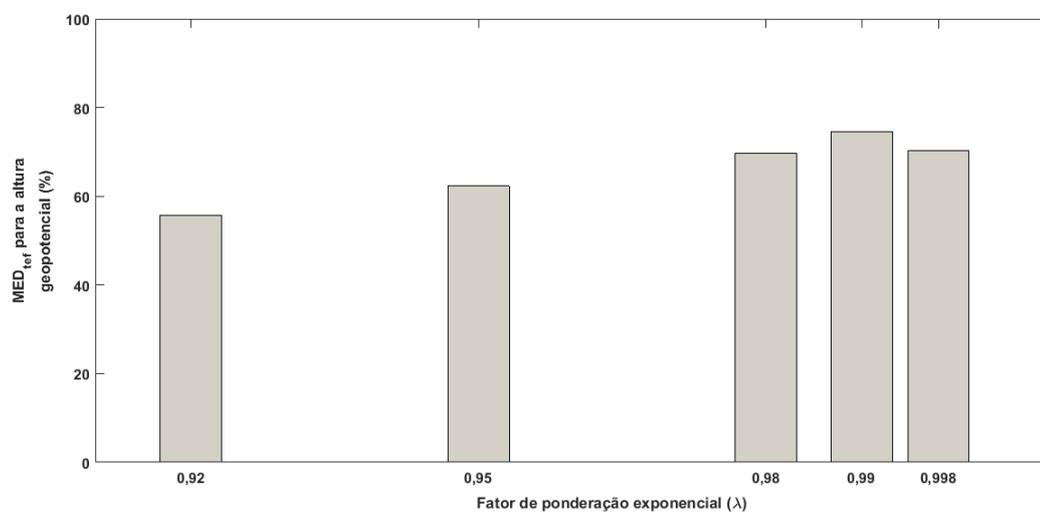


Figura 144 - Média das taxas de efetividade do MSE ( $MED_{tef}$ ), para a altura geopotencial ( $z_{geo}$ ), no ano de treinamento de 2009.

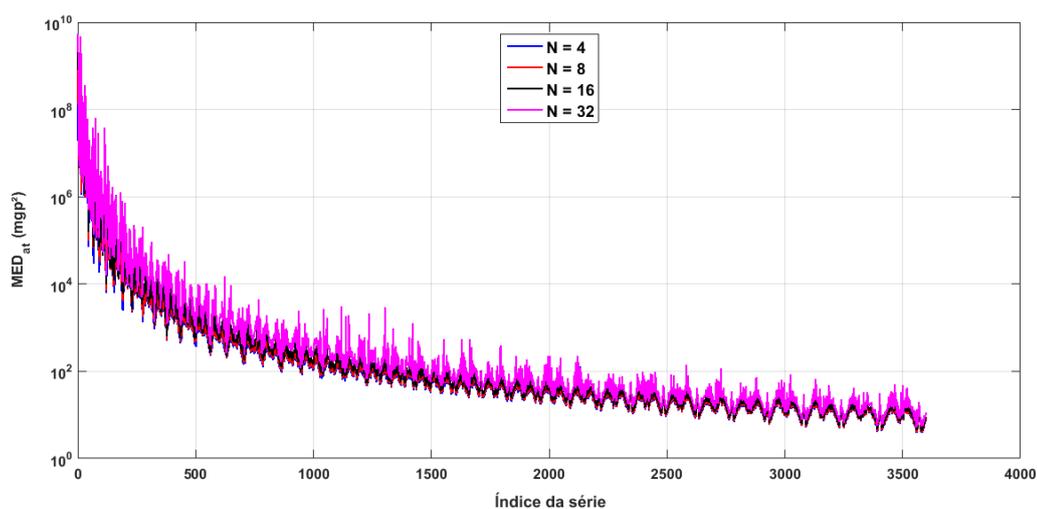


Figura 145 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a altura geopotencial, no ano de treinamento de 2008.

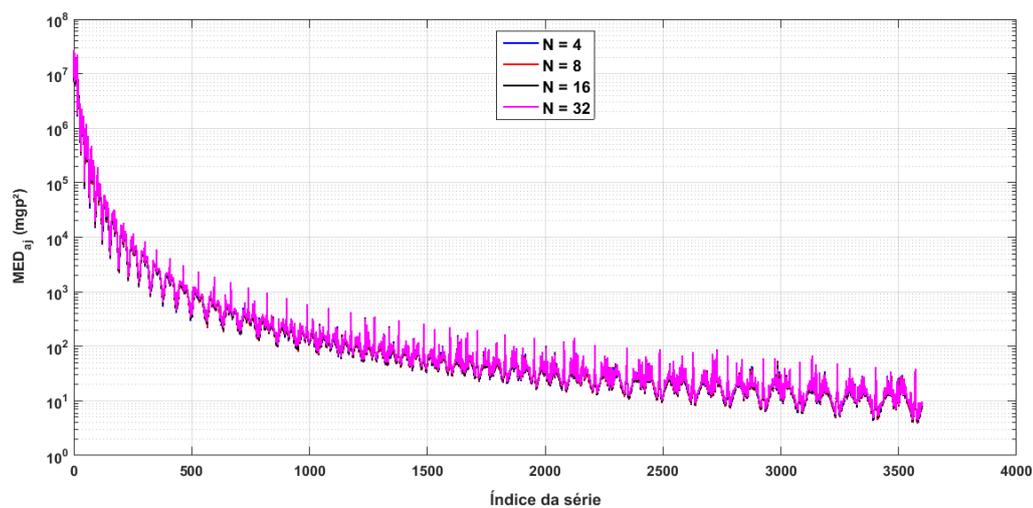


Figura 146 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a altura geopotencial, no ano de ajuste de 2009.

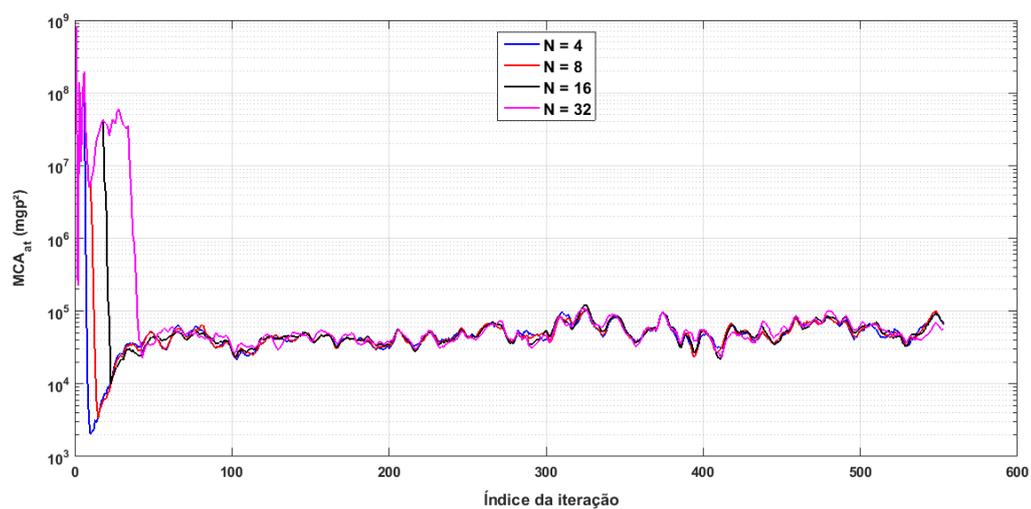


Figura 147 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a altura geopotencial, no ano de treinamento de 2008.

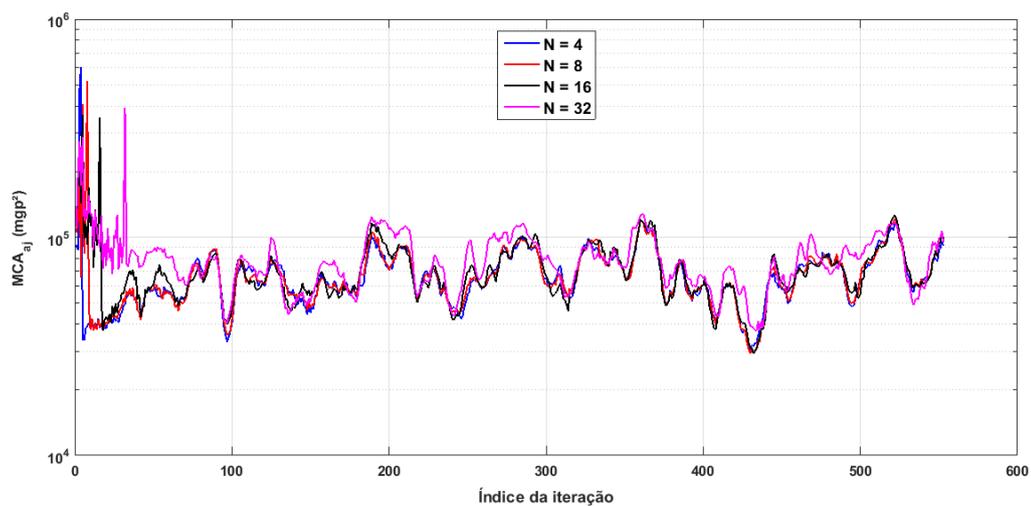


Figura 148 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a altura geopotencial, no ano de ajuste de 2009.

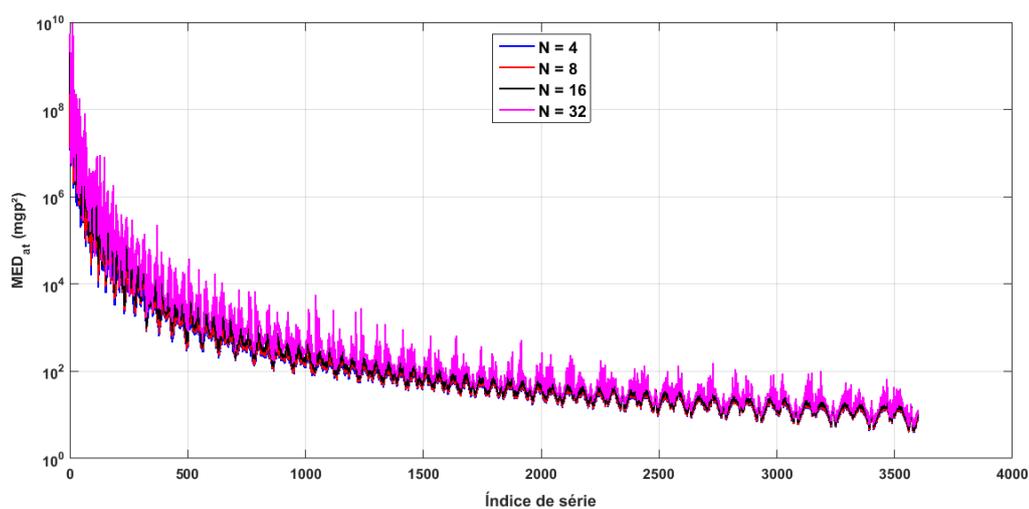


Figura 149 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a altura geopotencial, no ano de treinamento de 2009.

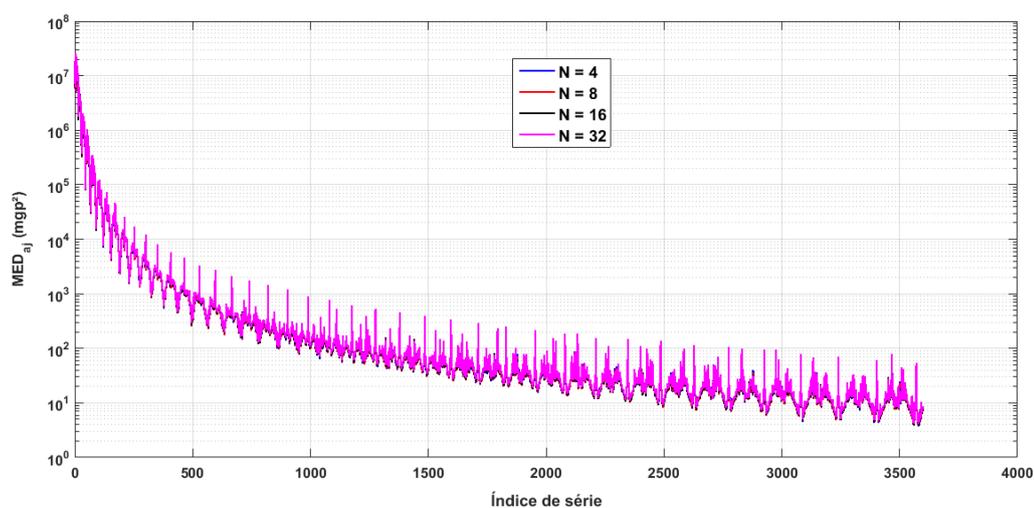


Figura 150 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a altura geopotencial, no ano de ajuste de 2010.

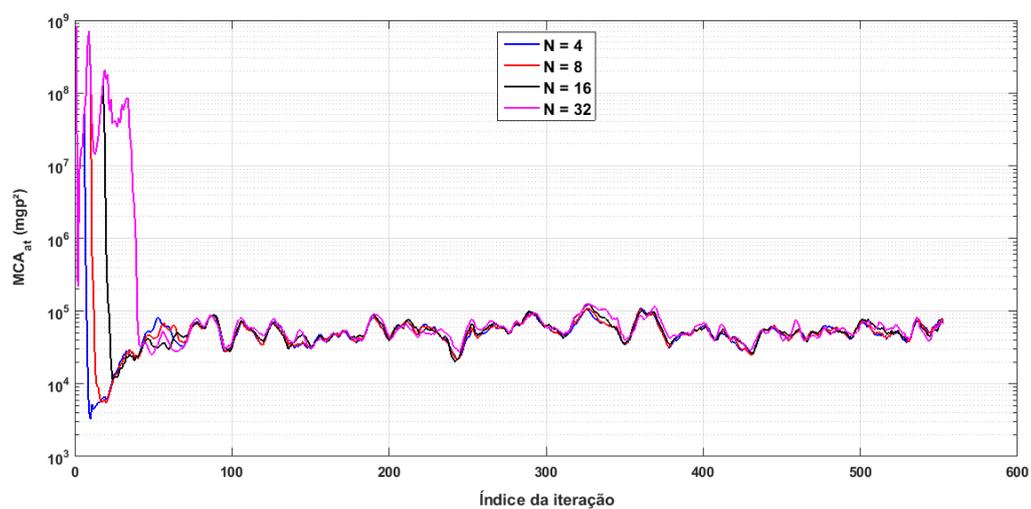


Figura 151 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a altura geopotencial, no ano de treinamento de 2009.

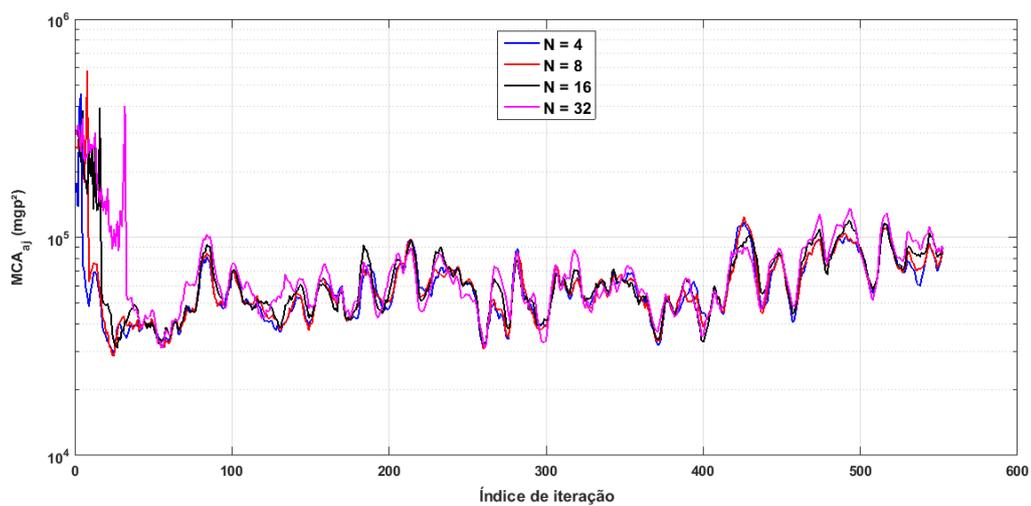


Figura 152 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a altura geopotencial, no ano de ajuste de 2010.

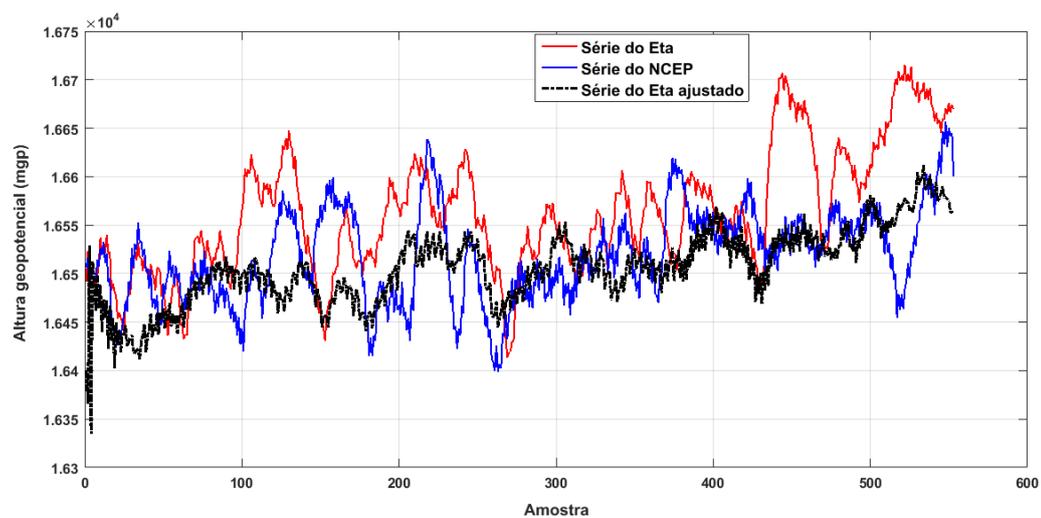


Figura 153 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 100 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

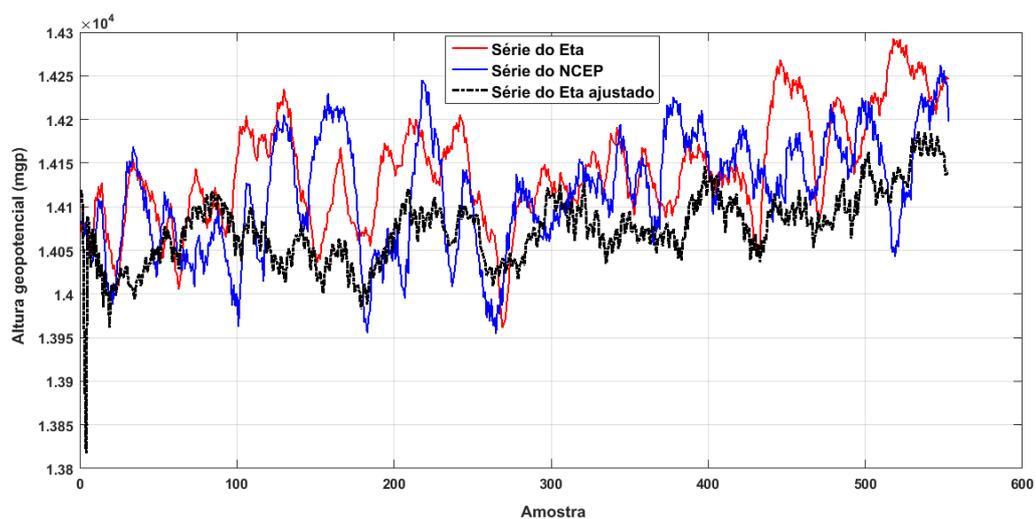


Figura 154 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 150 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

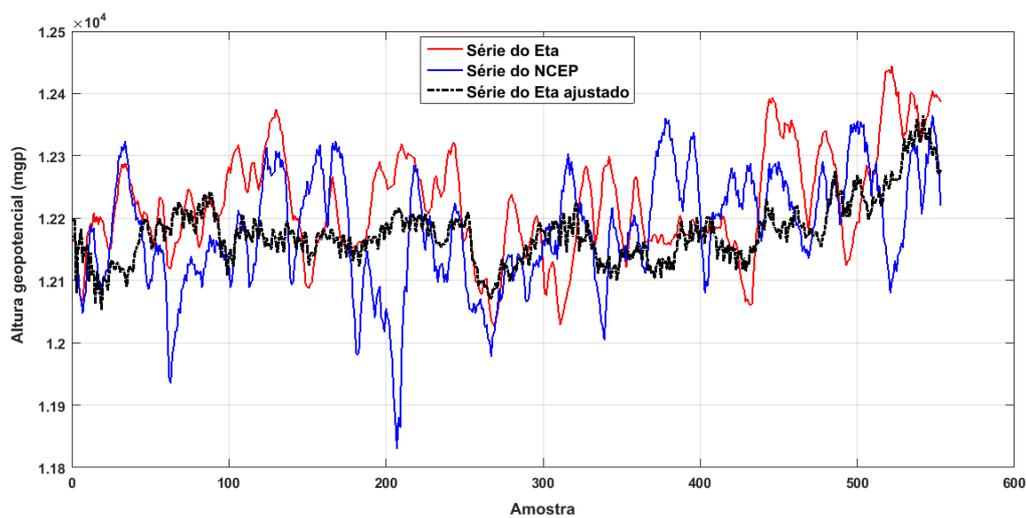


Figura 155 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 200 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

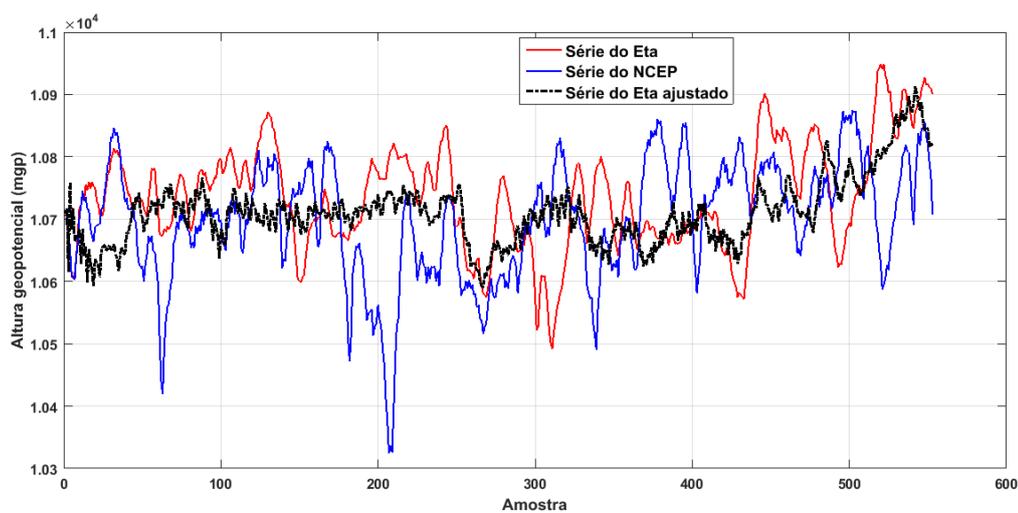


Figura 156 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 250 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

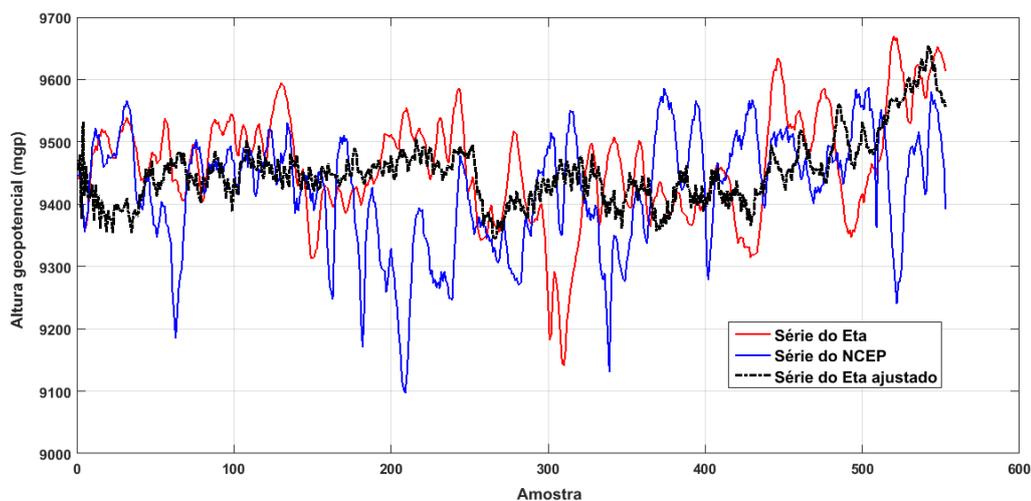


Figura 157 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 300 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

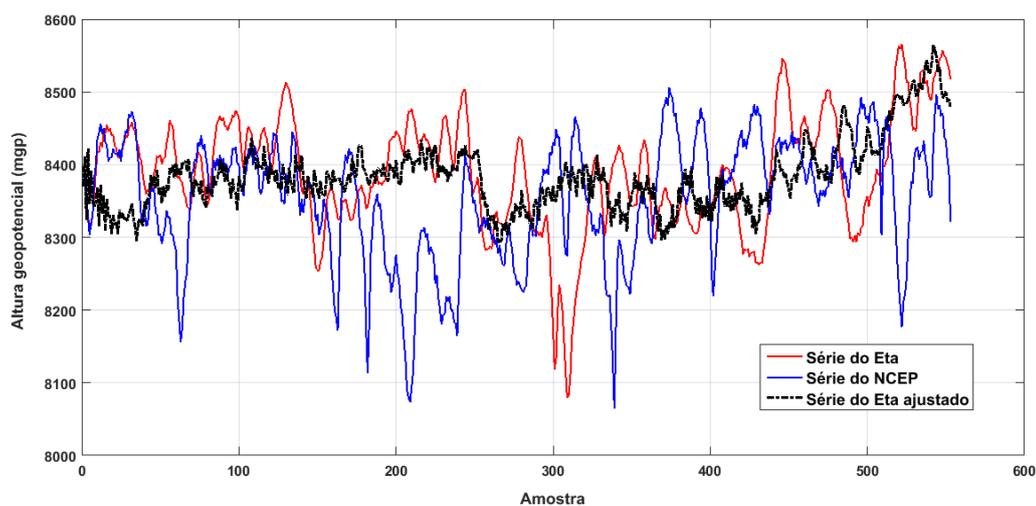


Figura 158 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 350 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

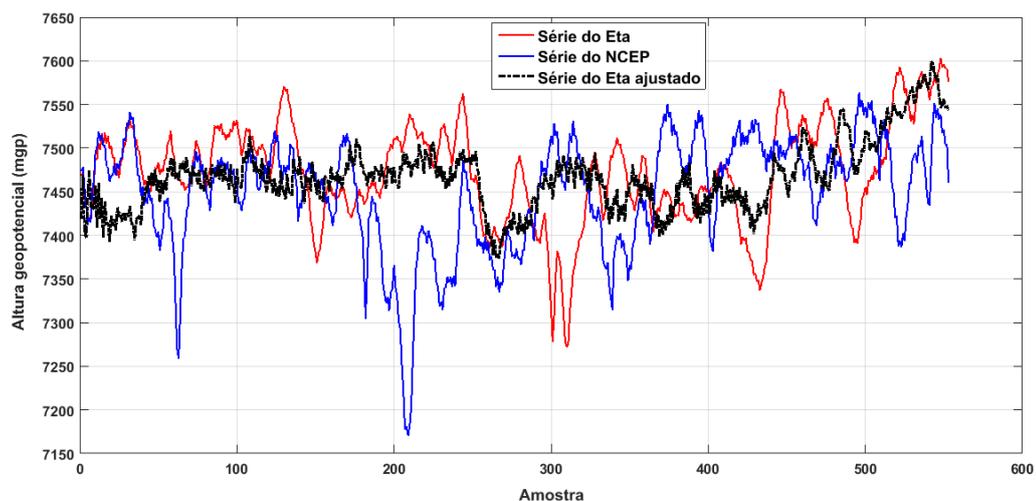


Figura 159 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 400 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

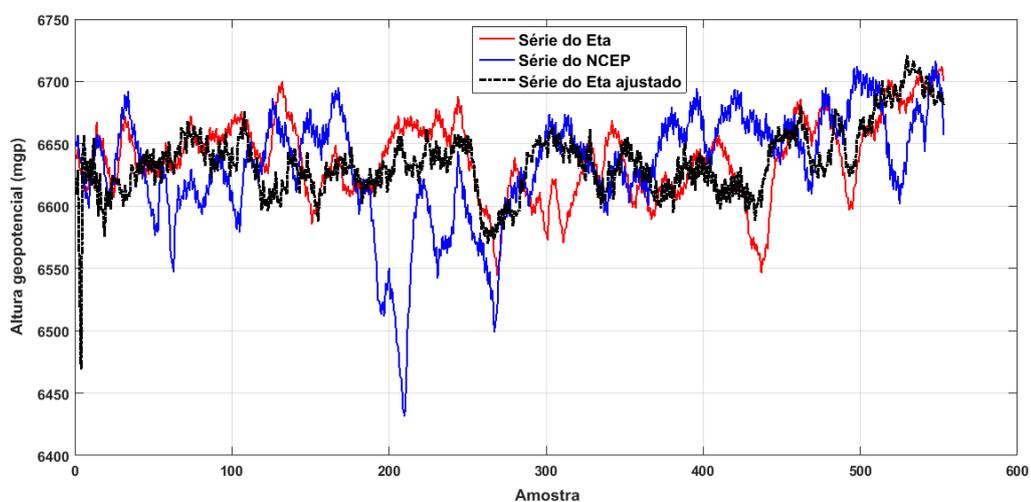


Figura 160 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 450 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

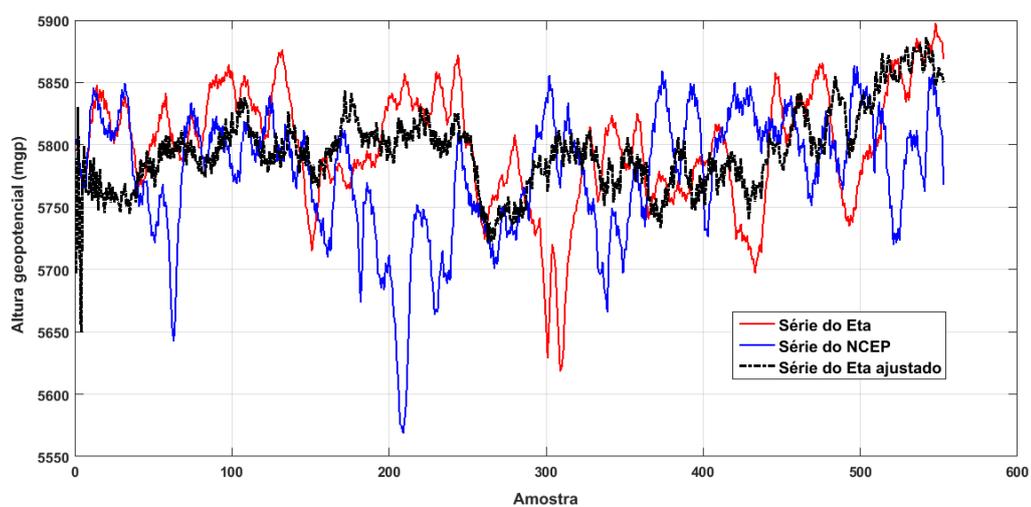


Figura 161 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 500 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

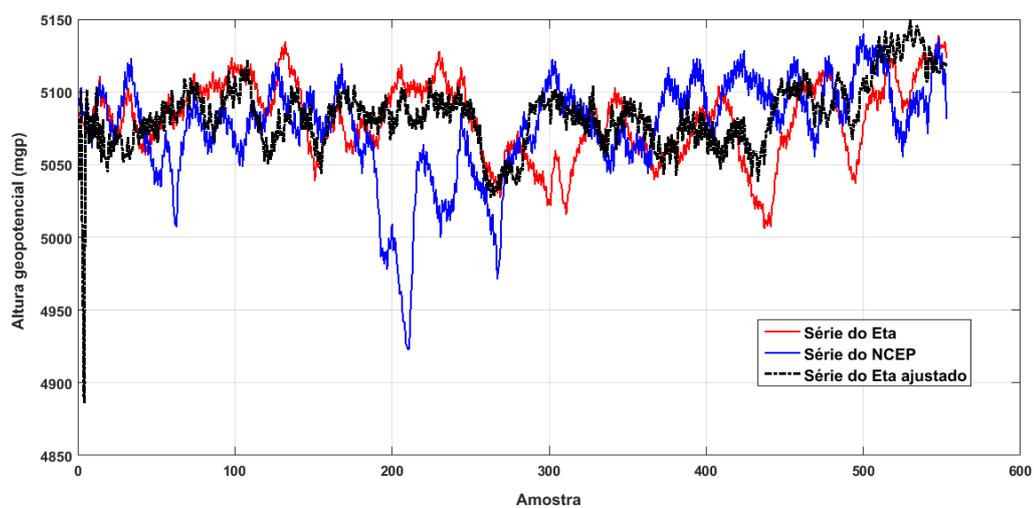


Figura 162 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 550 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

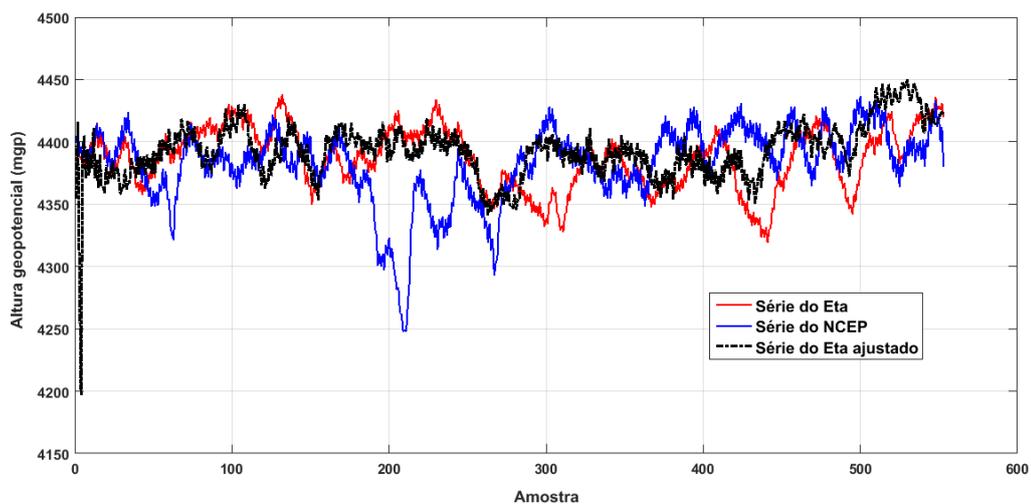


Figura 163 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 600 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

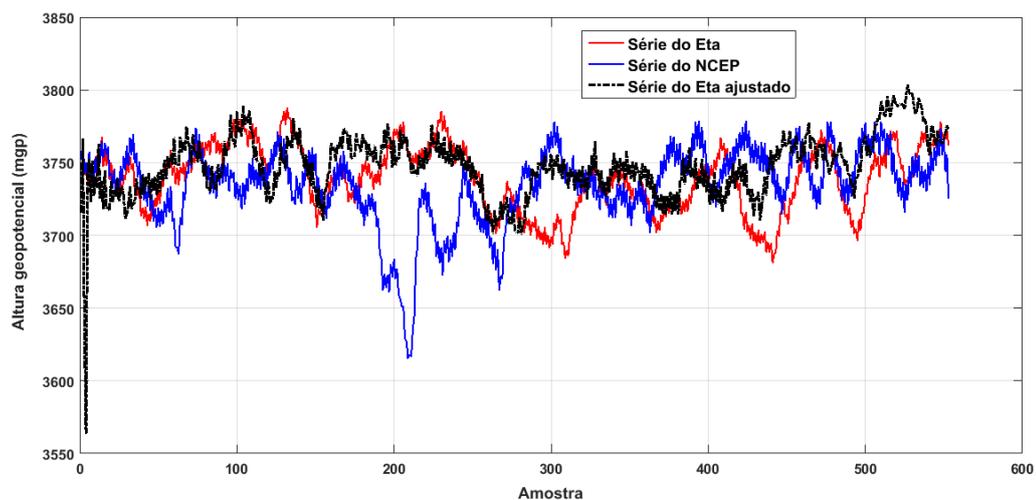


Figura 164 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 650 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

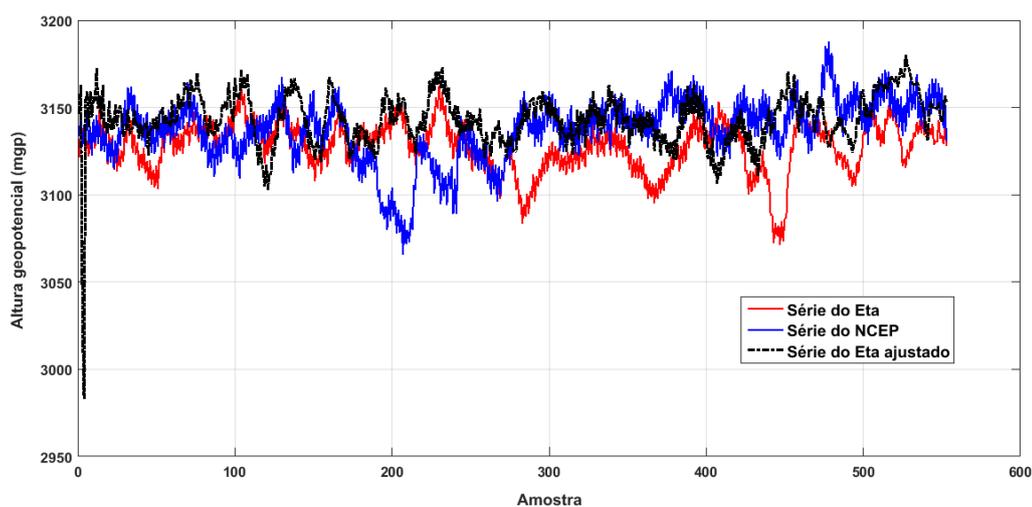


Figura 165 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 700 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

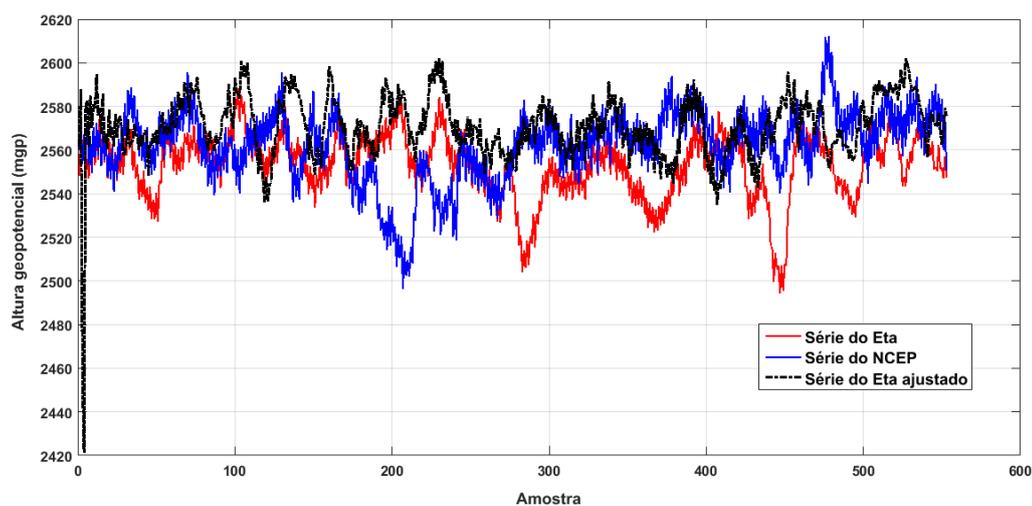


Figura 166 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 750 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

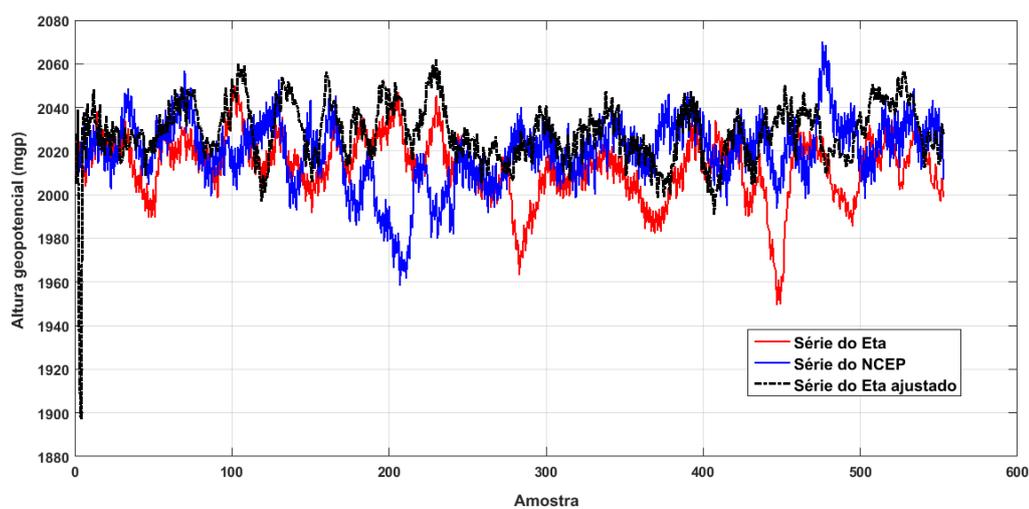


Figura 167 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 800 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

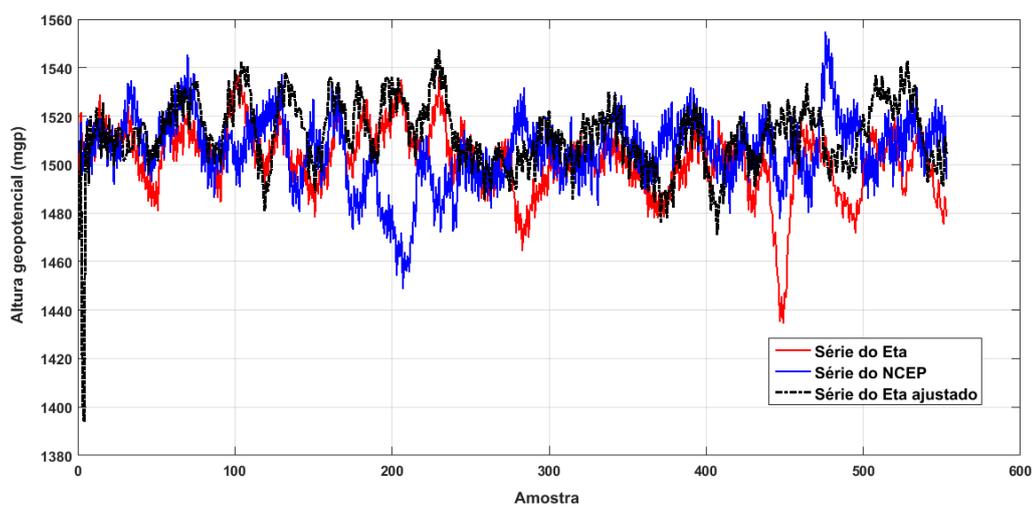


Figura 168 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 850 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

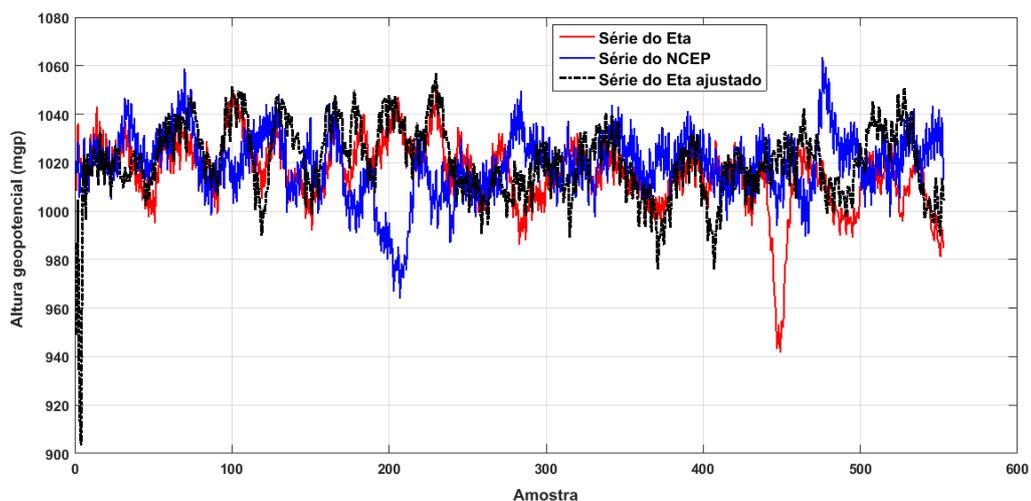


Figura 169 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 900 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

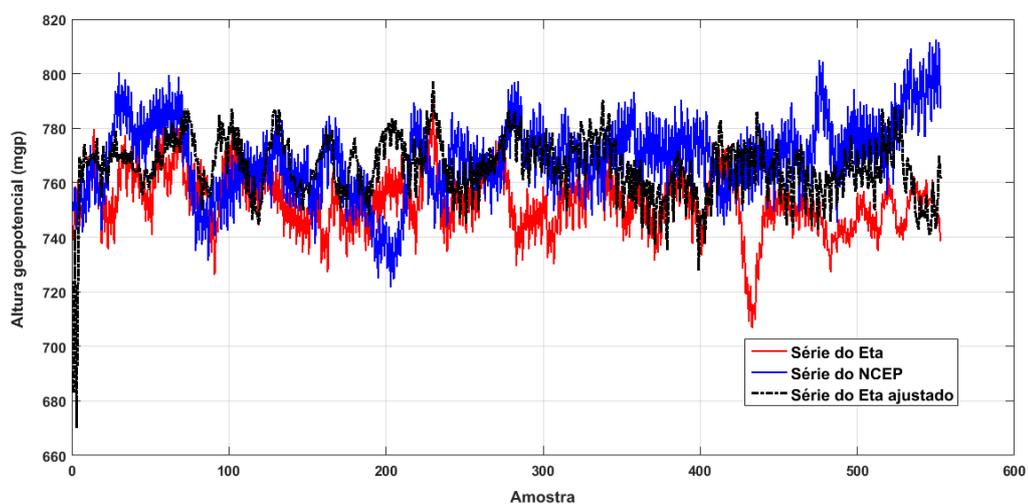


Figura 170 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 925 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

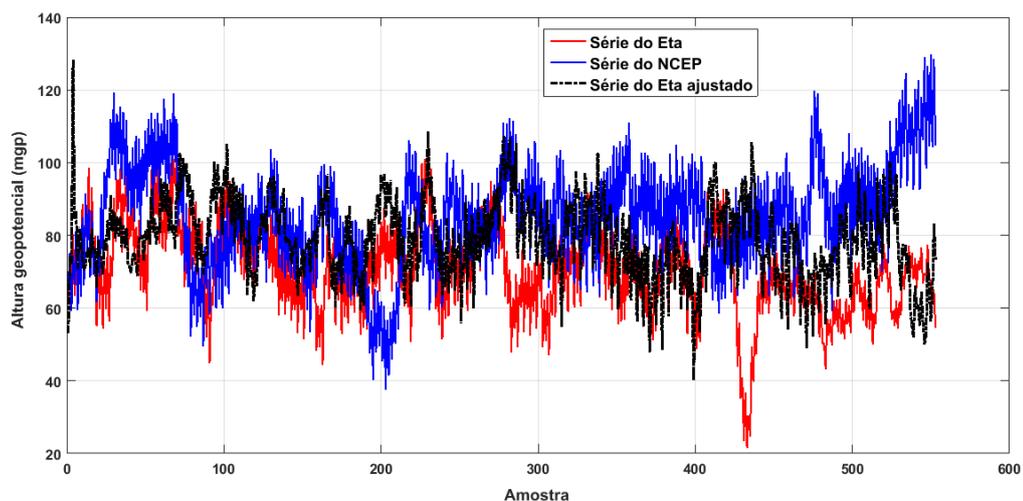


Figura 171 - Séries temporais para a altura geopotencial ( $z_{geo}$ ) a 1000 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

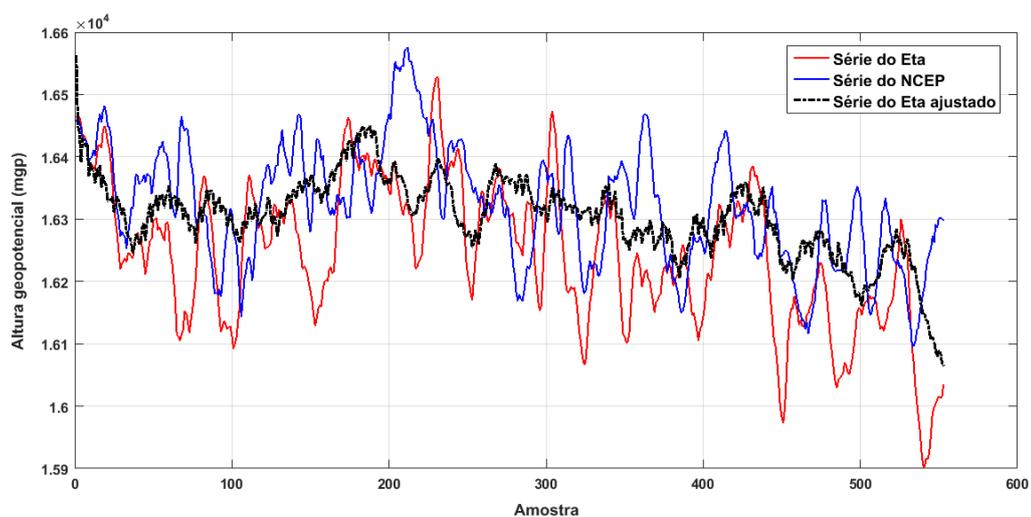


Figura 172 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 100 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

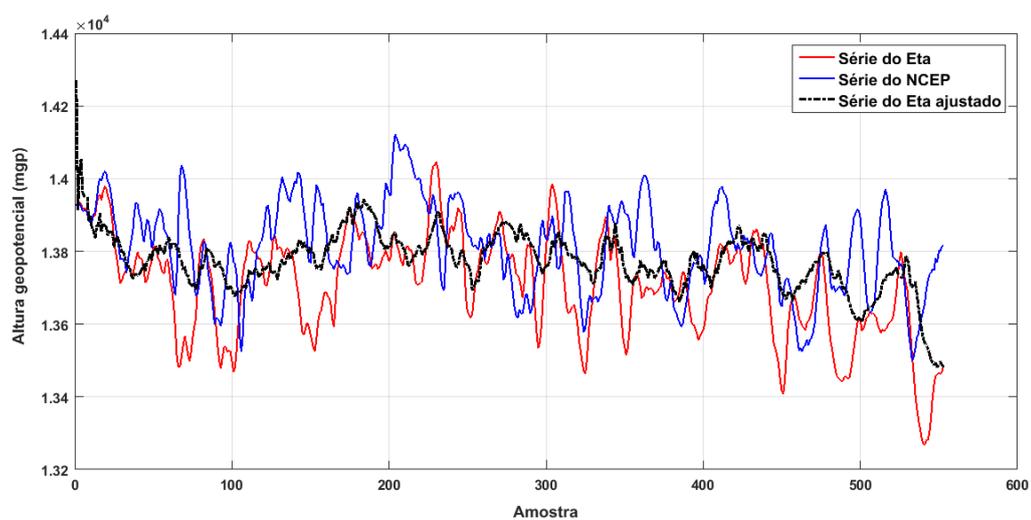


Figura 173 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 150 hPa, coordenadas geográficas dos pixels ( $60^{\circ}$ W e  $30^{\circ}$ S), no ano de ajuste de 2010.

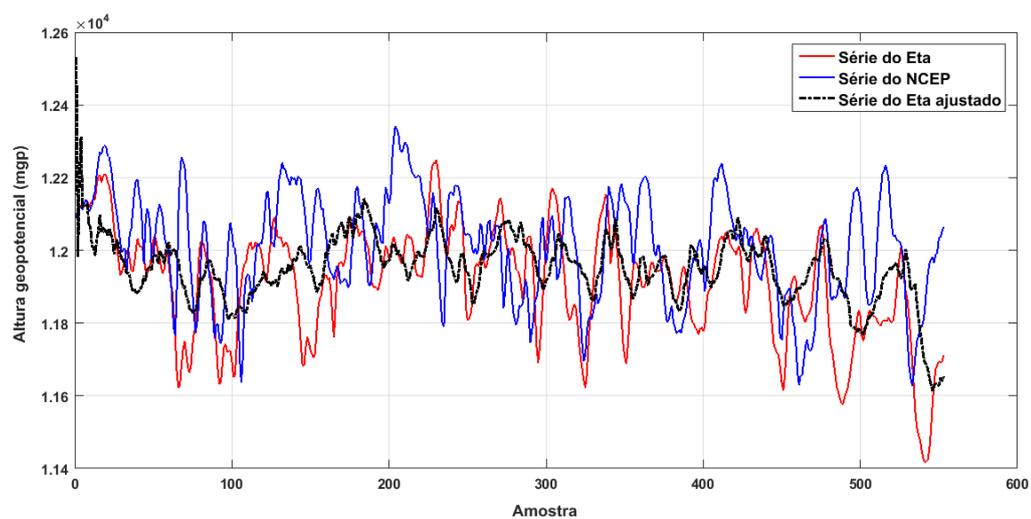


Figura 174 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 200 hPa, coordenadas geográficas dos pixels ( $60^{\circ}$ W e  $30^{\circ}$ S), no ano de ajuste de 2010.

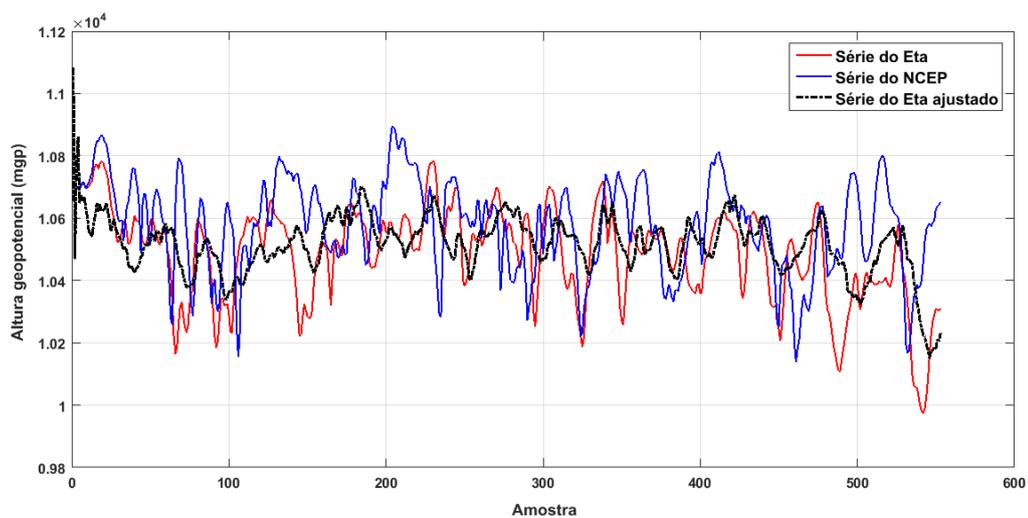


Figura 175 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 250 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

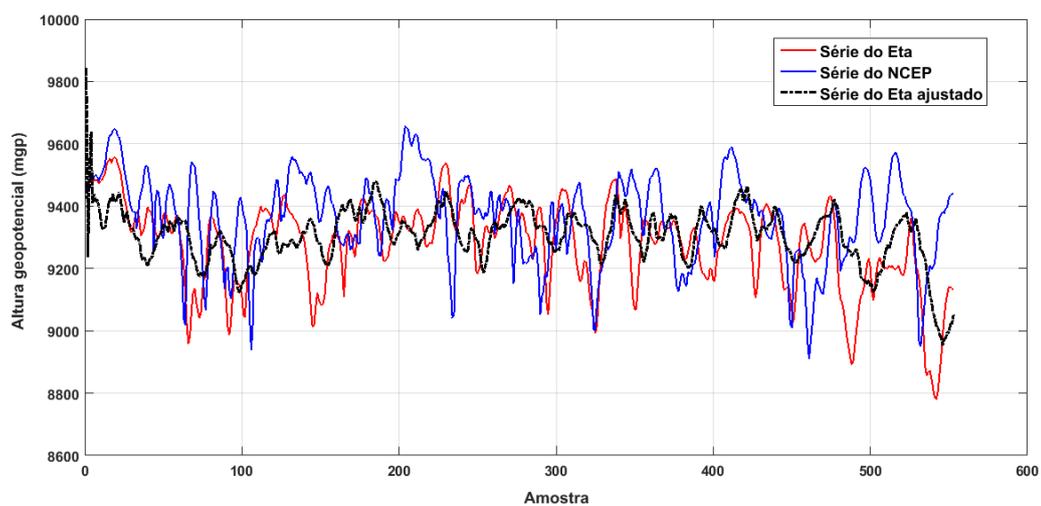


Figura 176 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 300 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

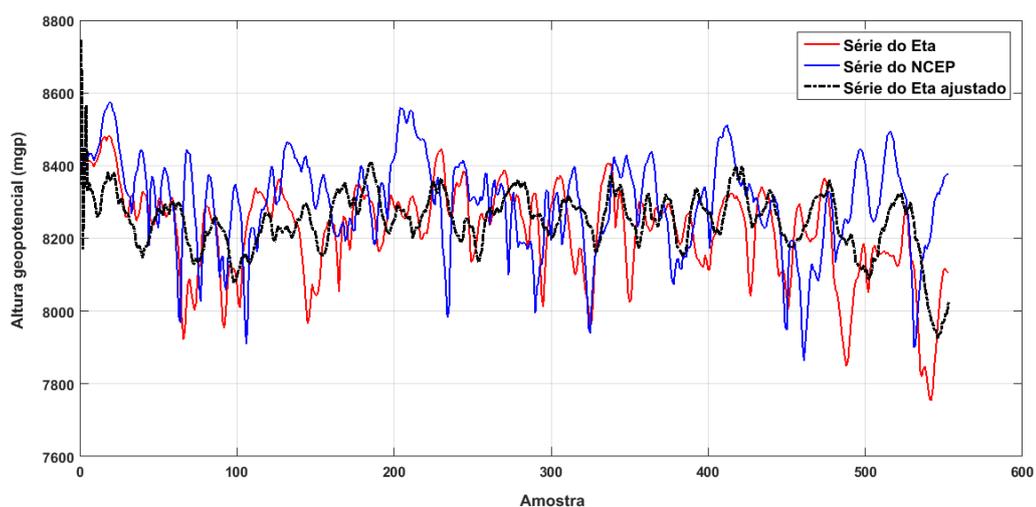


Figura 177 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 350 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

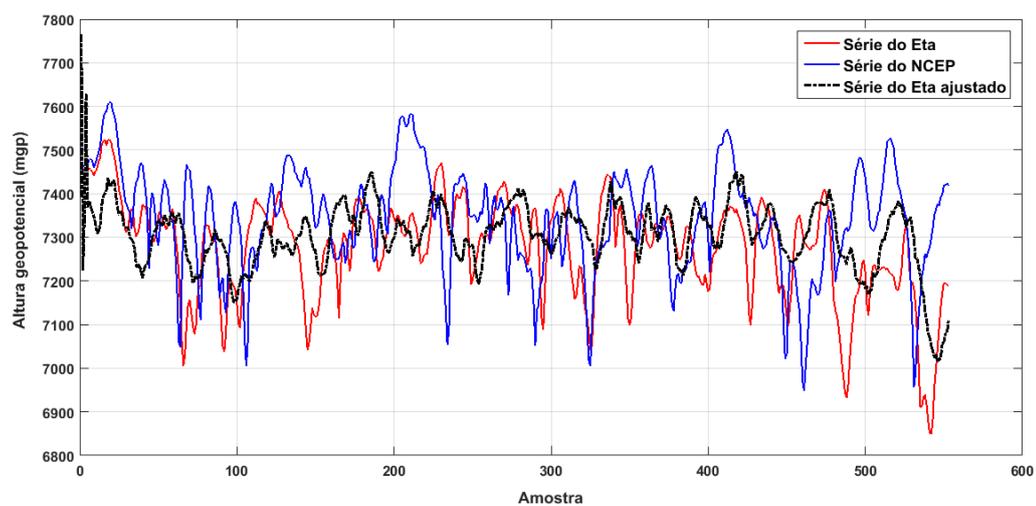


Figura 178 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 400 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

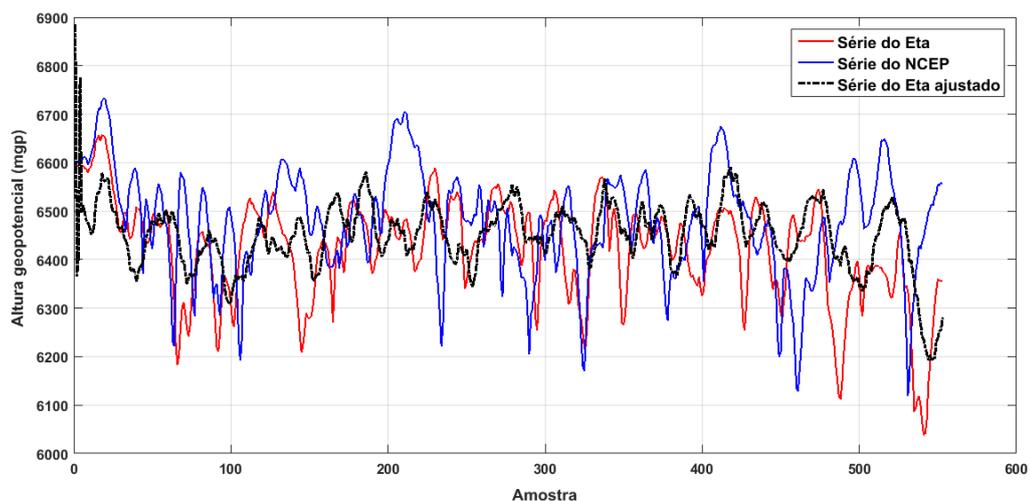


Figura 179 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 450 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

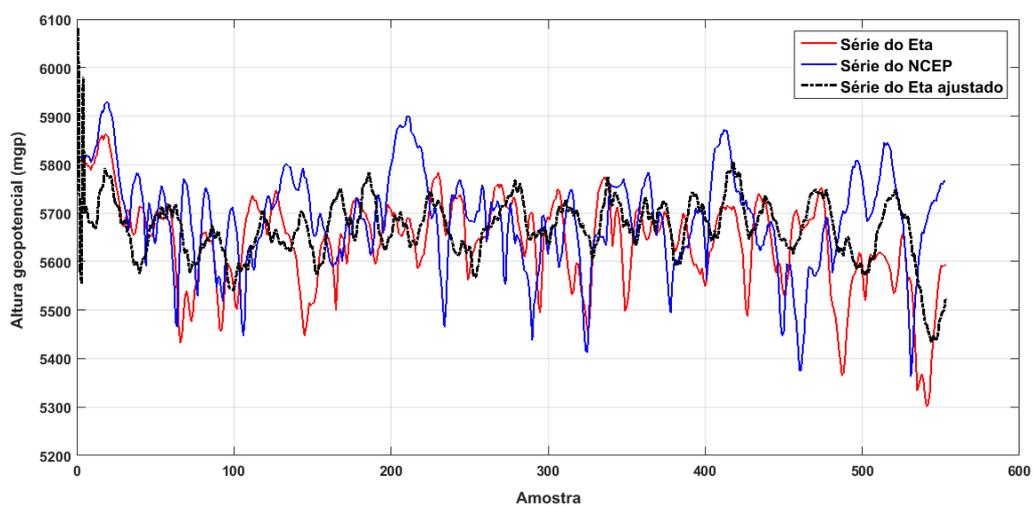


Figura 180 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 500 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

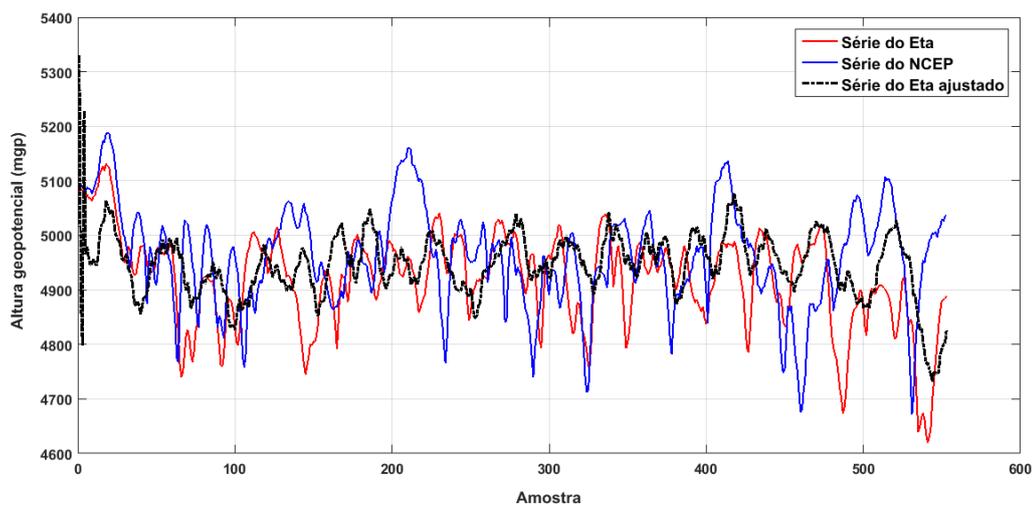


Figura 181 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 550 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

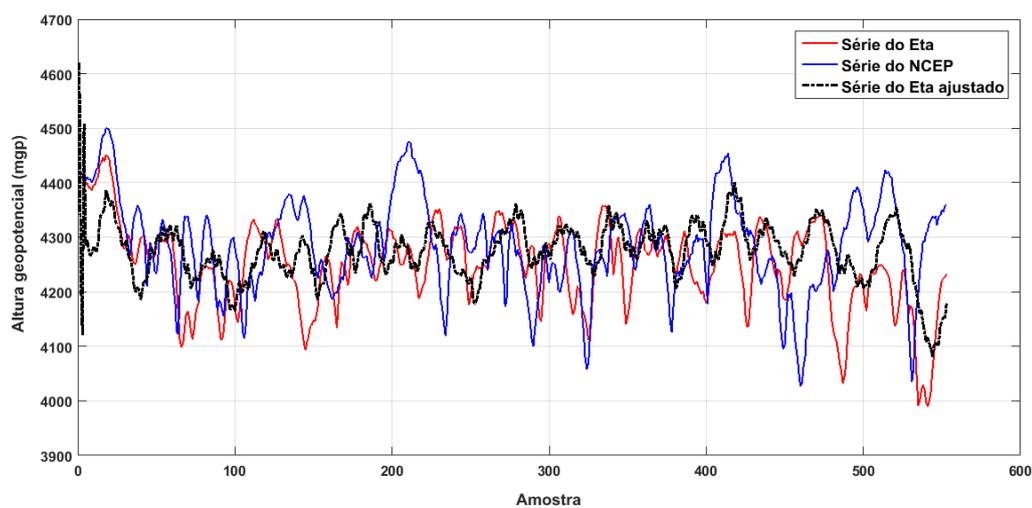


Figura 182 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 600 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

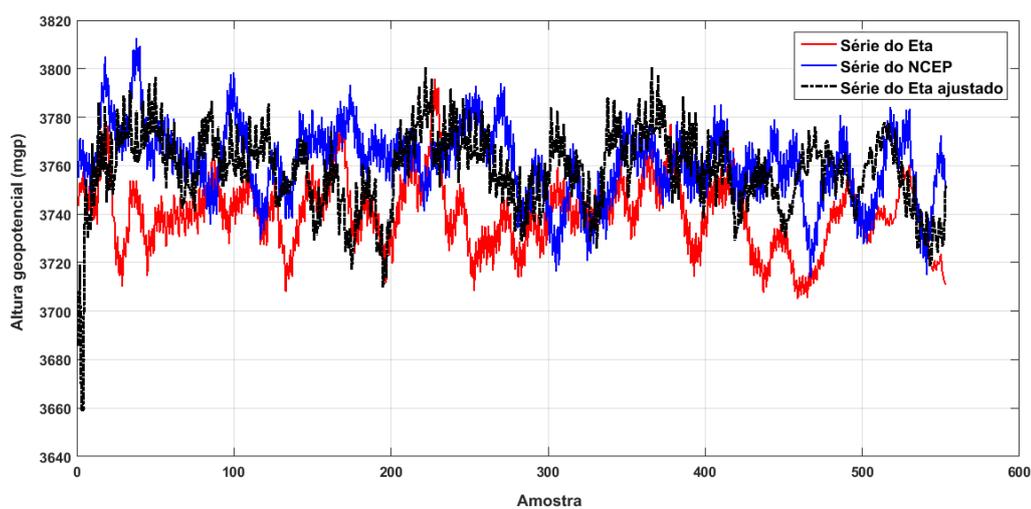


Figura 183 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 650 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

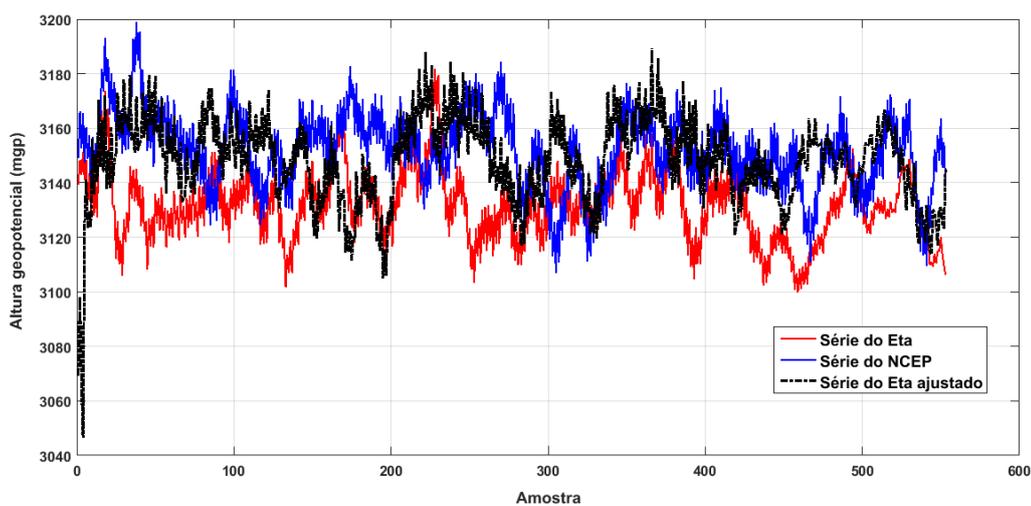


Figura 184 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 700 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

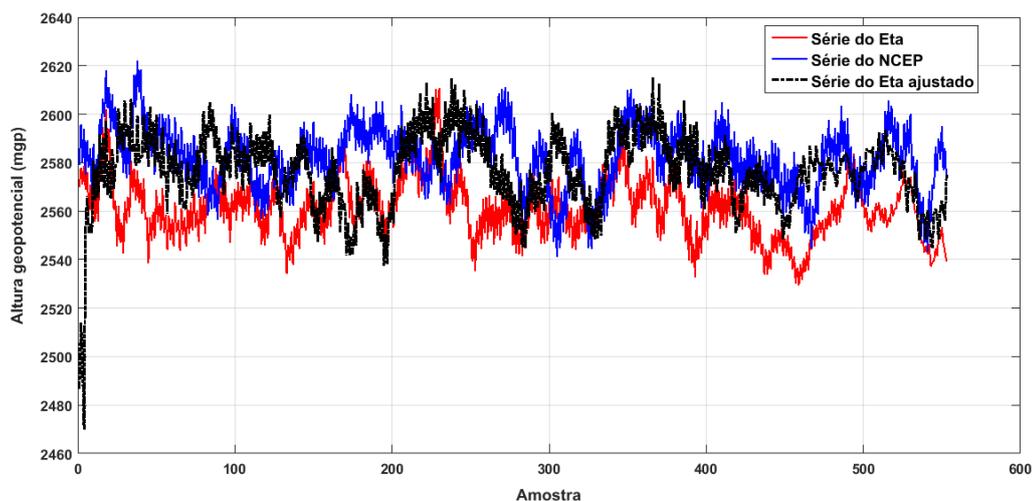


Figura 185 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 750 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

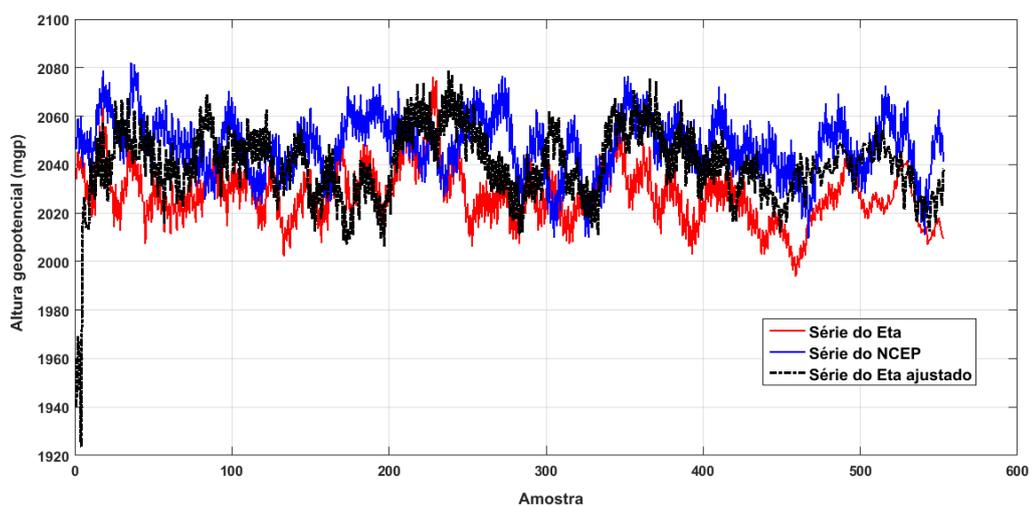


Figura 186 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 800 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

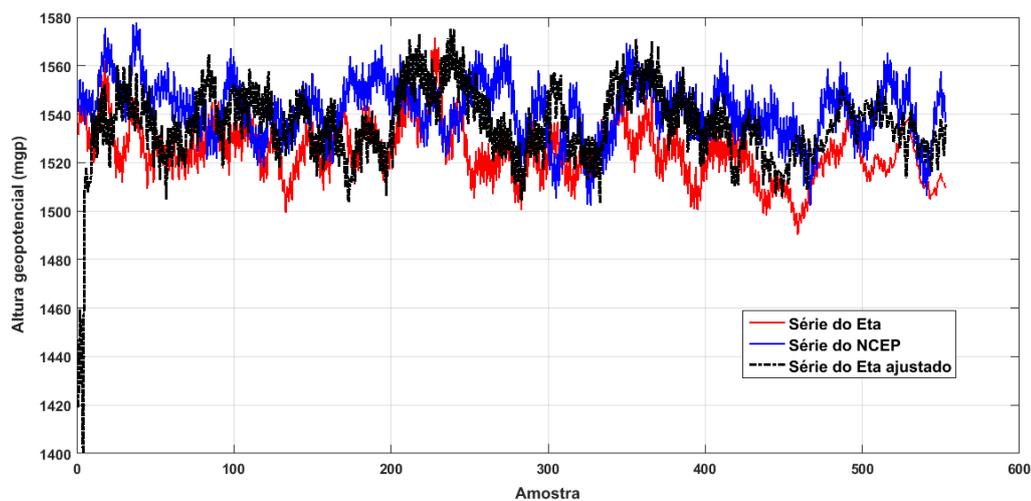


Figura 187 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 850 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

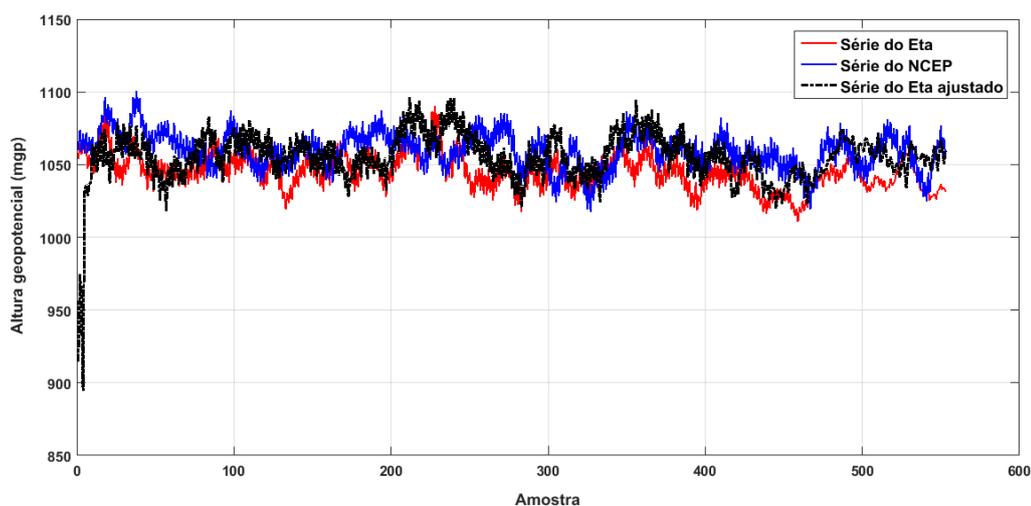


Figura 188 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 900 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

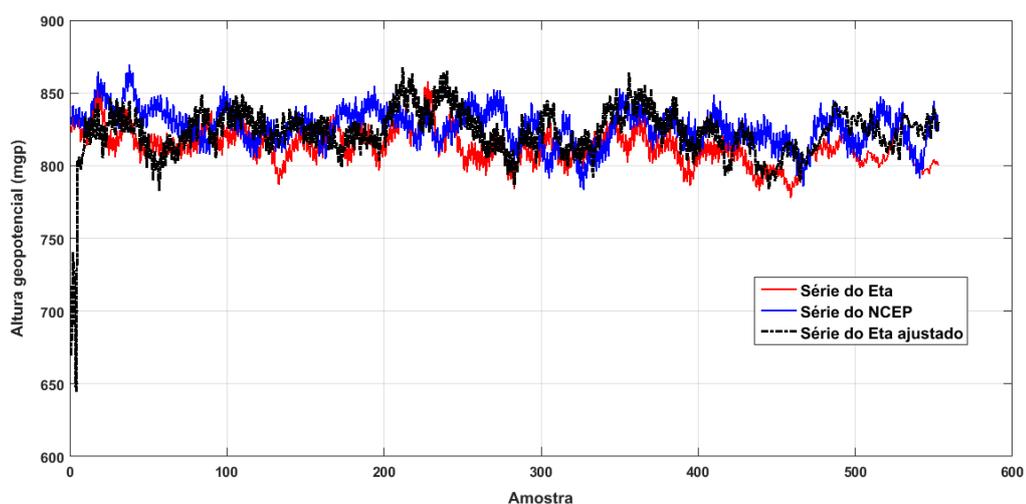


Figura 189 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 925 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

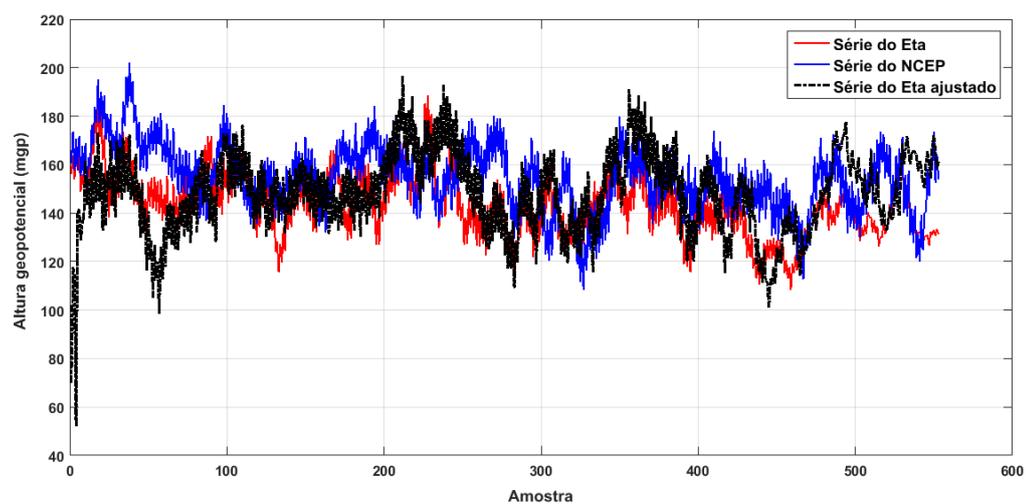


Figura 190 - Séries temporais da altura geopotencial ( $z_{geo}$ ) a 1000 hPa, coordenadas geográficas dos pixels ( $60^{\circ}W$  e  $30^{\circ}S$ ), no ano de ajuste de 2010.

## Componente zonal do vento

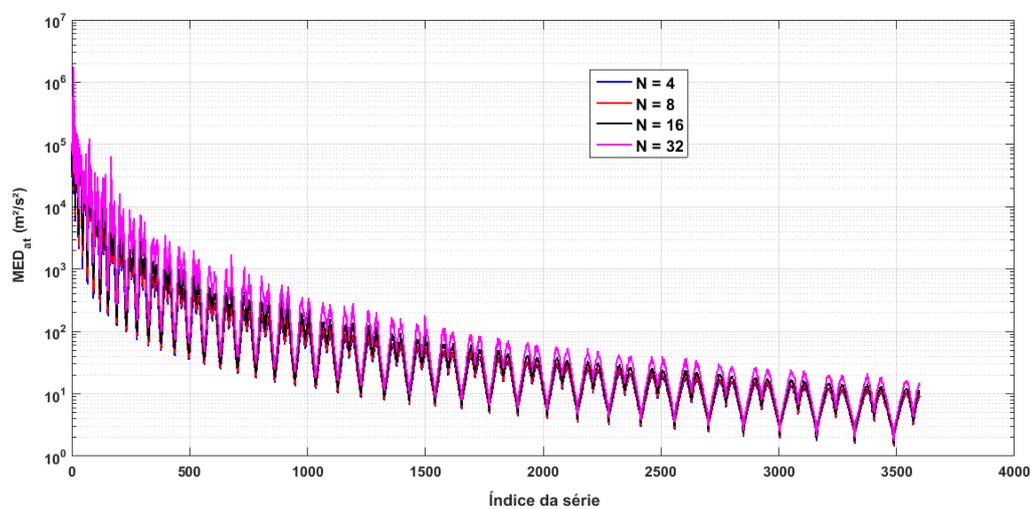


Figura 191 - Média dos valores de MSE após a filtragem adaptativa ( $MED_{at}$ ) para a componente zonal do vento, no ano de treinamento de 2009.

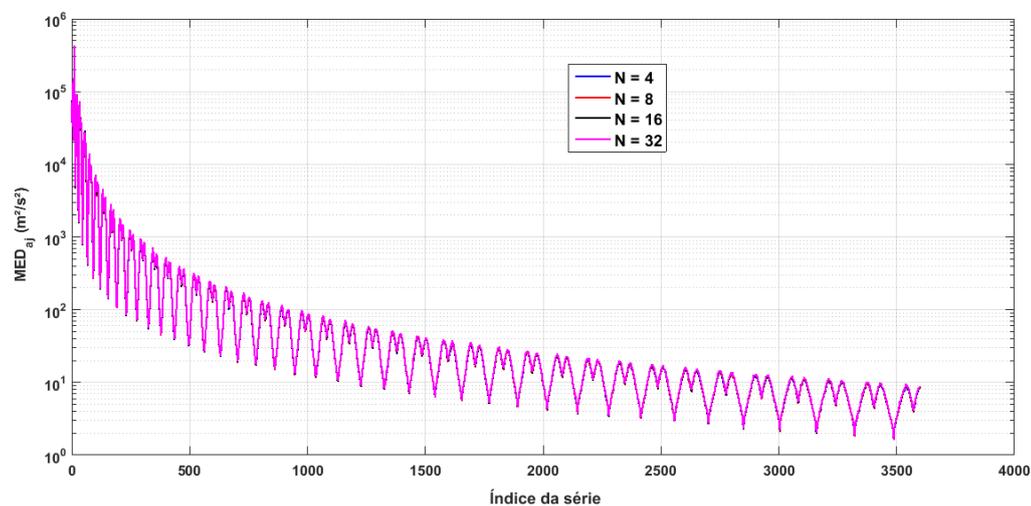


Figura 192 - Média dos valores de MSE após a filtragem FIR ( $MED_{aj}$ ) para a componente zonal do vento, no ano de ajuste de 2010.

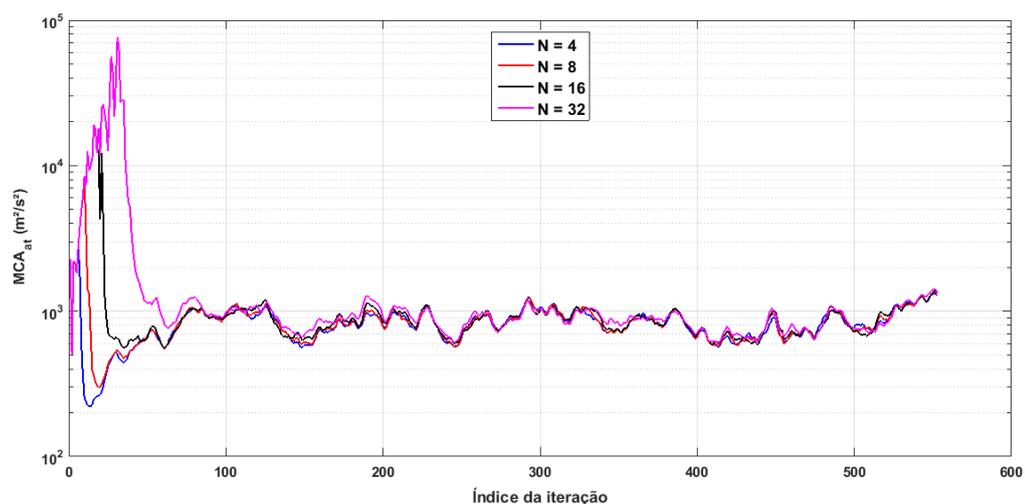


Figura 193 - Média das curvas de aprendizado do MSE após a filtragem adaptativa ( $MCA_{at}$ ) para a componente zonal do vento, no ano de treinamento de 2009.

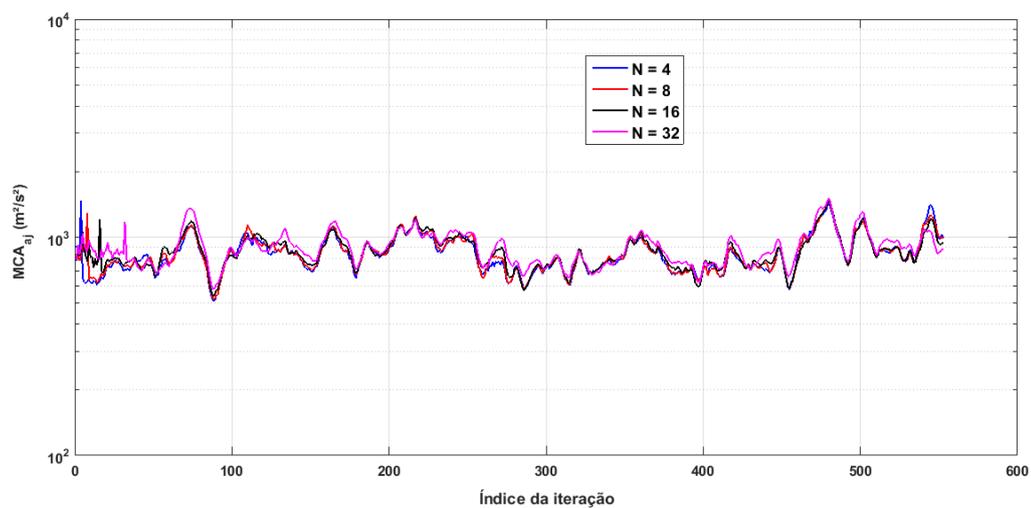


Figura 194 - Média das curvas de aprendizado do MSE após a filtragem FIR ( $MCA_{aj}$ ) para a componente zonal do vento, no ano de ajuste de 2010.

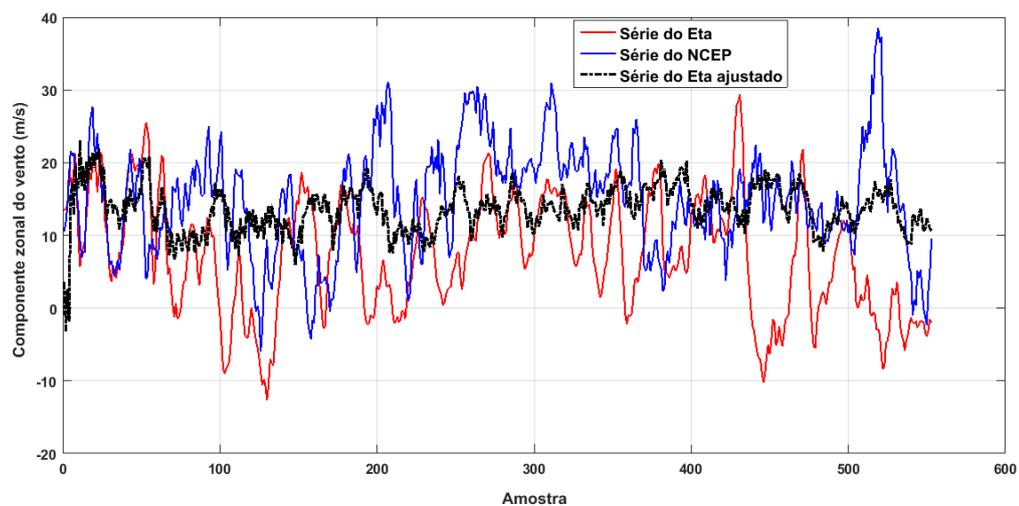


Figura 195 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 100 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

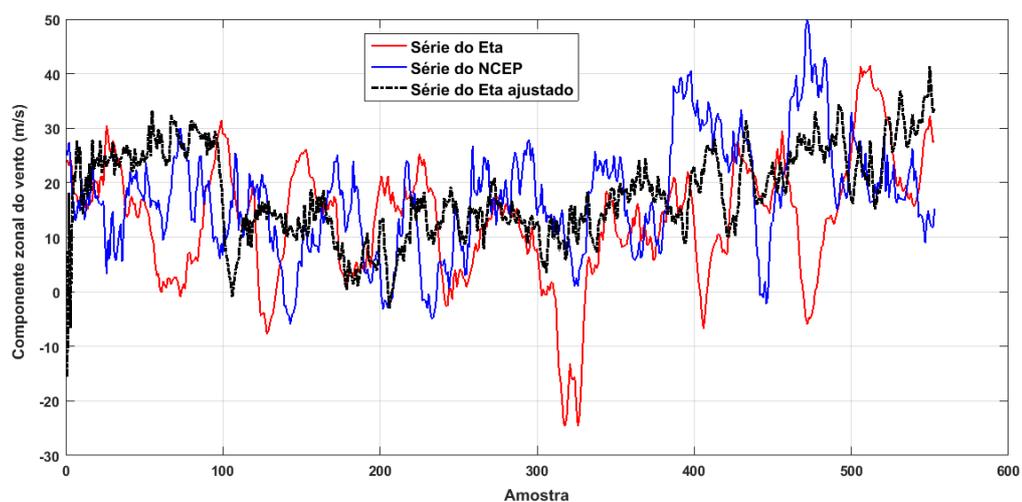


Figura 196 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 150 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

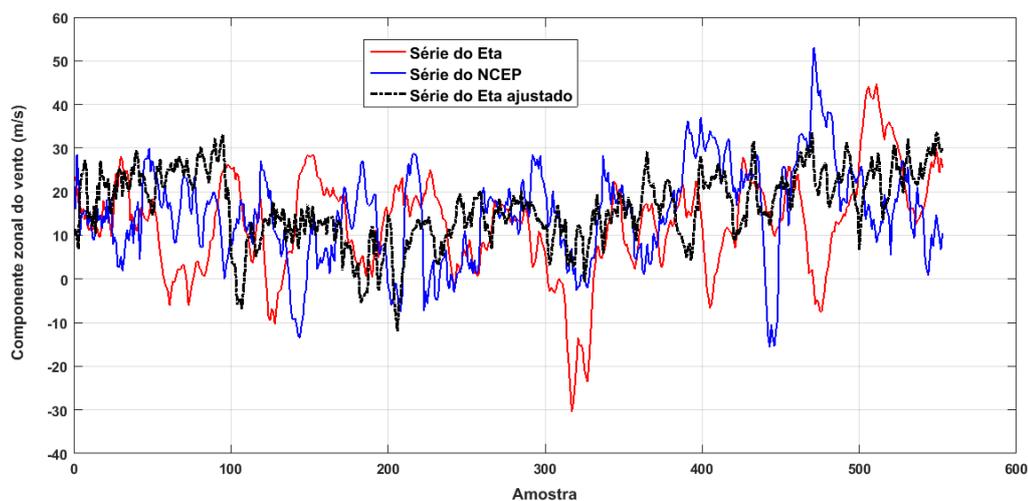


Figura 197 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 200 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

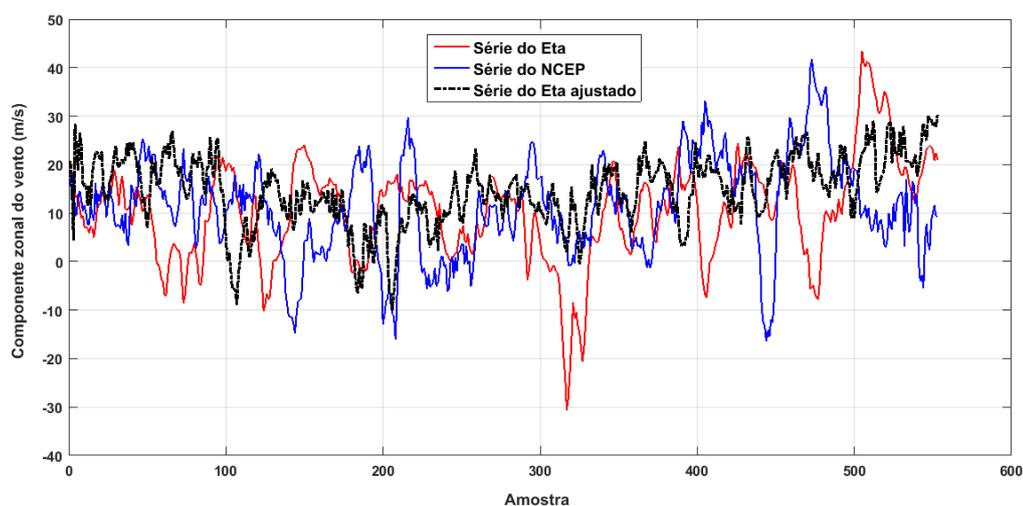


Figura 198 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 250 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

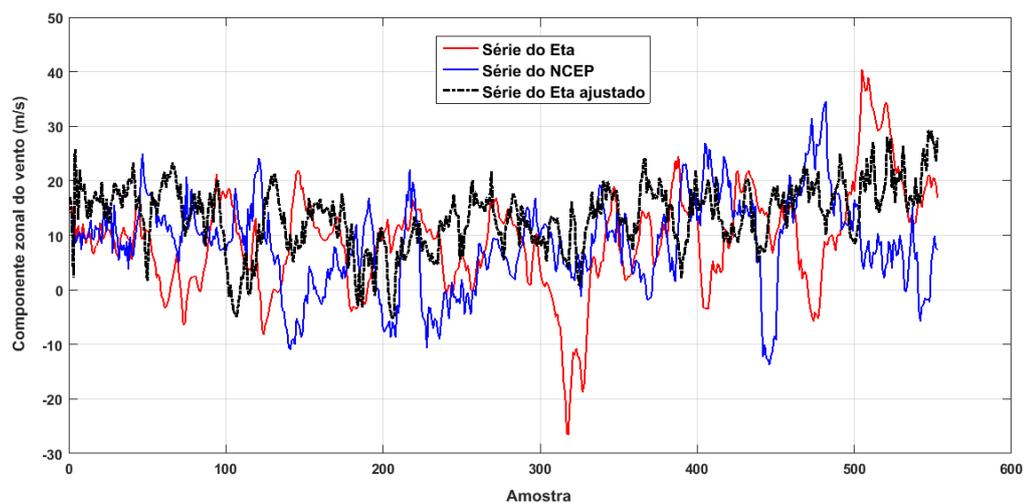


Figura 199 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 300 hPa, coordenadas geográficas dos pixels ( $45^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

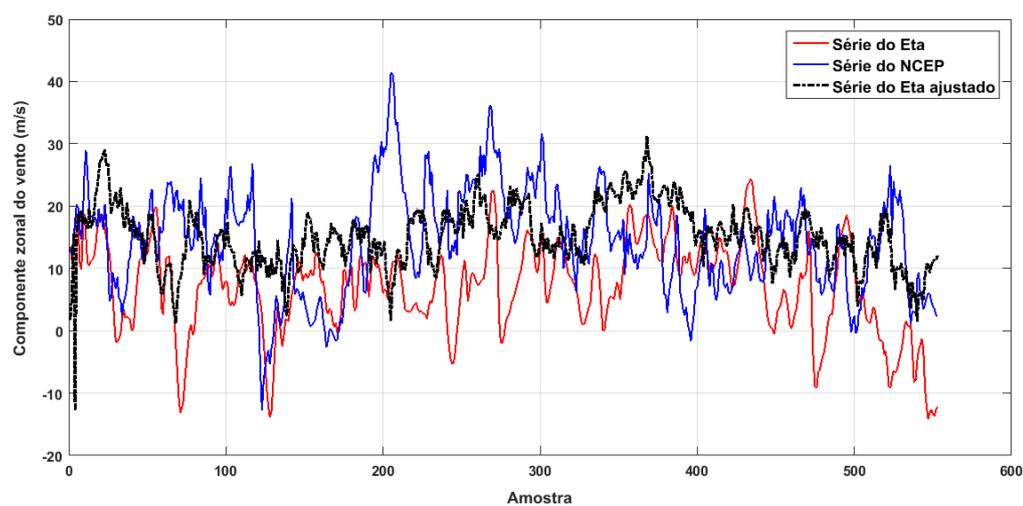


Figura 200 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 350 hPa, coordenadas geográficas dos pixels ( $45^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

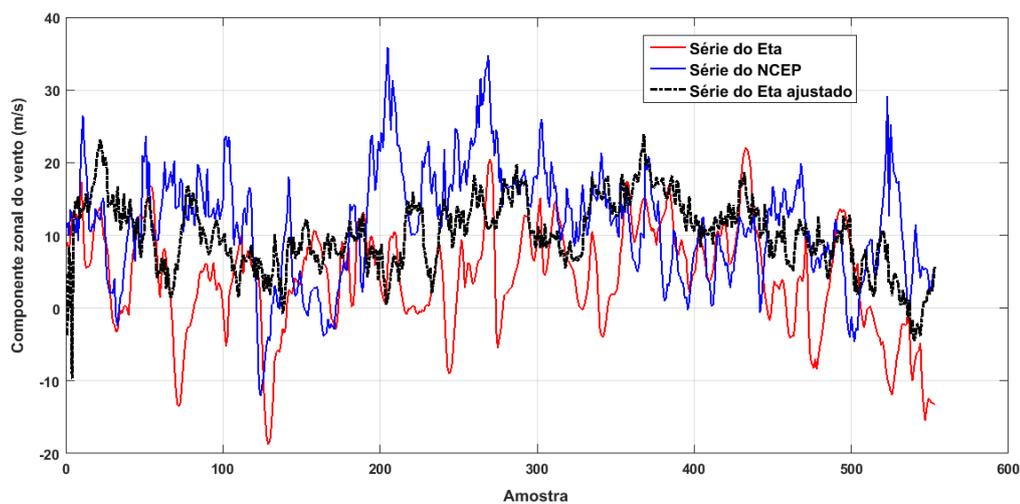


Figura 201 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 400 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

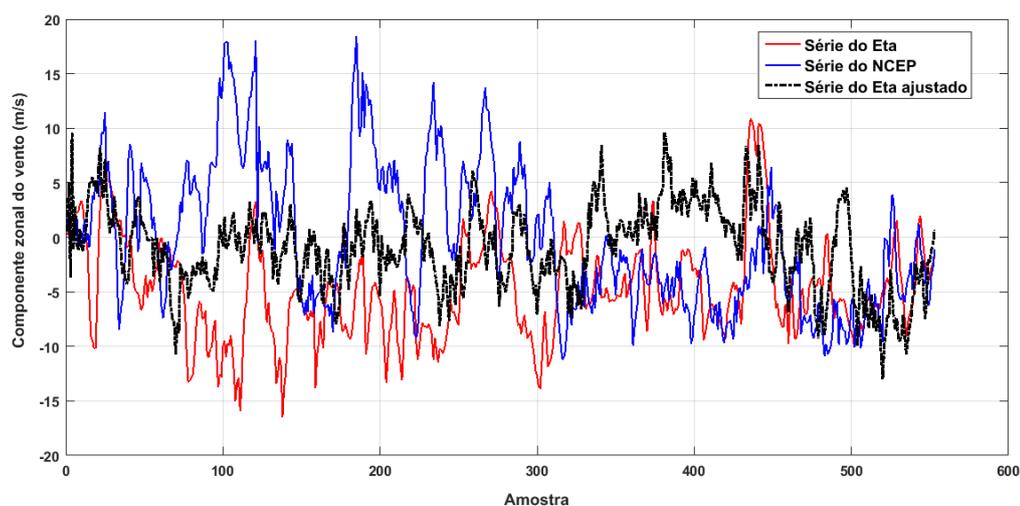


Figura 202 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 450 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

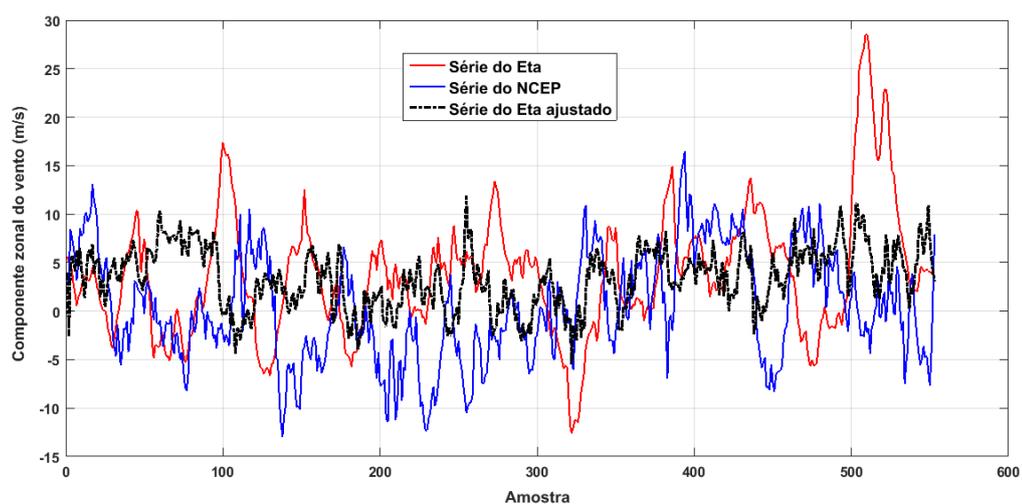


Figura 203 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 500 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

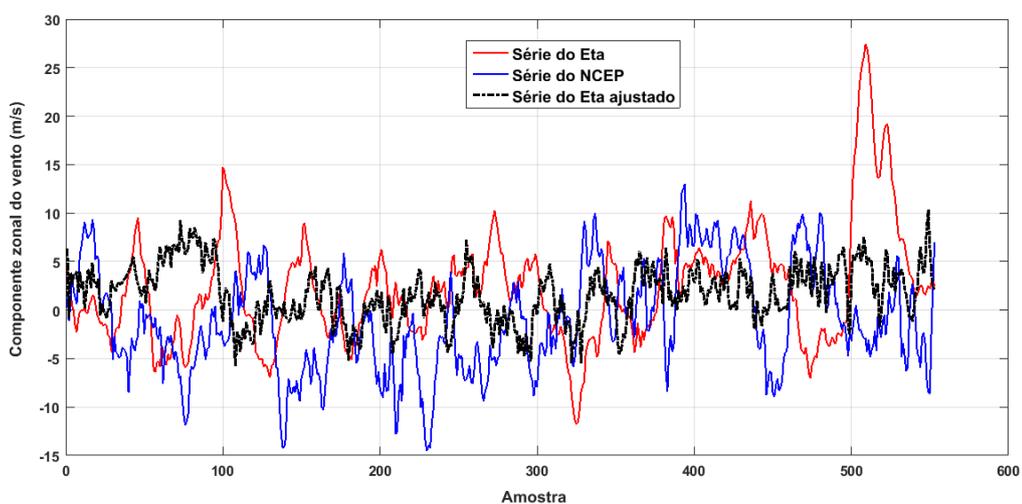


Figura 204 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 550 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

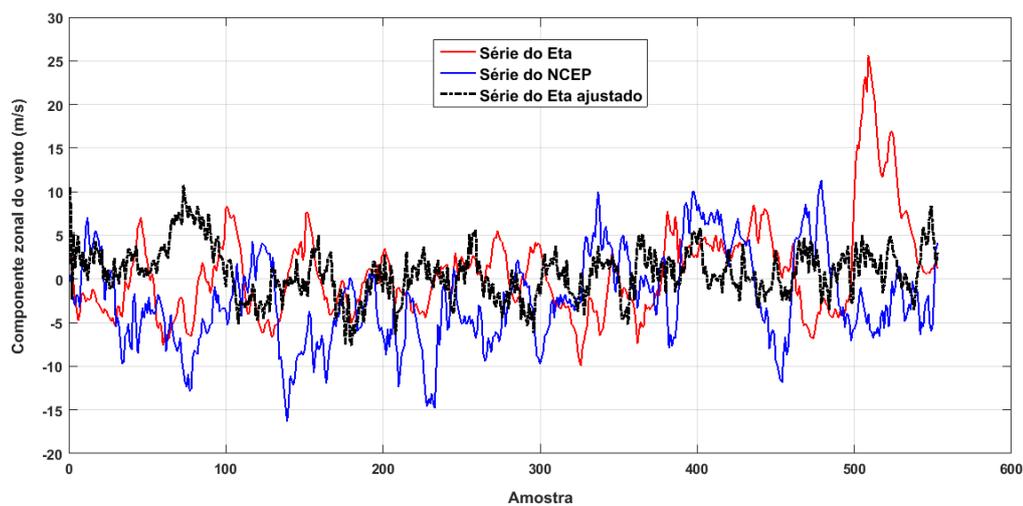


Figura 205 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 600 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

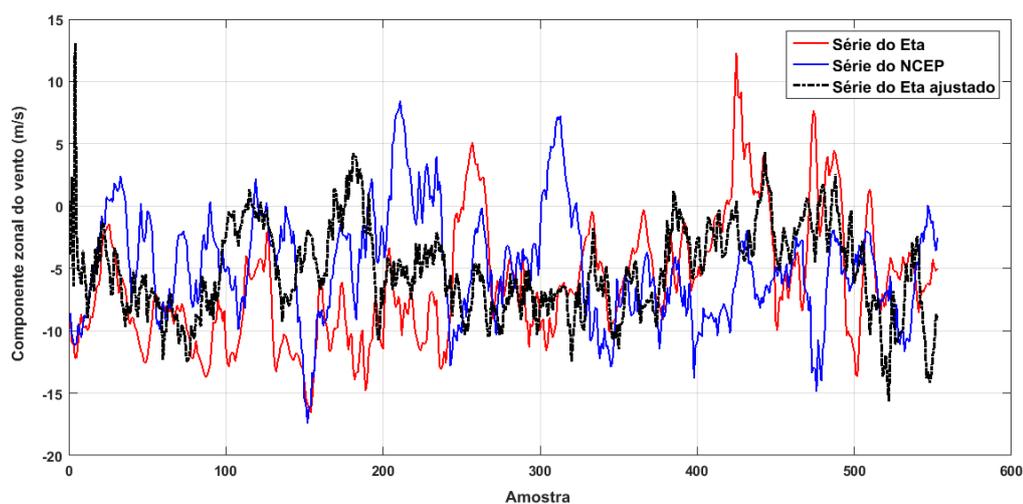


Figura 206 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 650 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

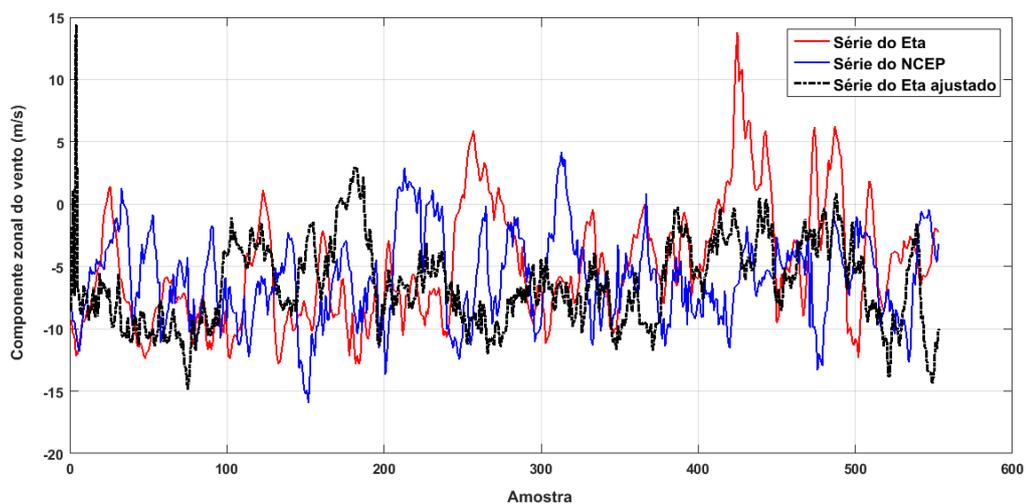


Figura 207 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 700 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

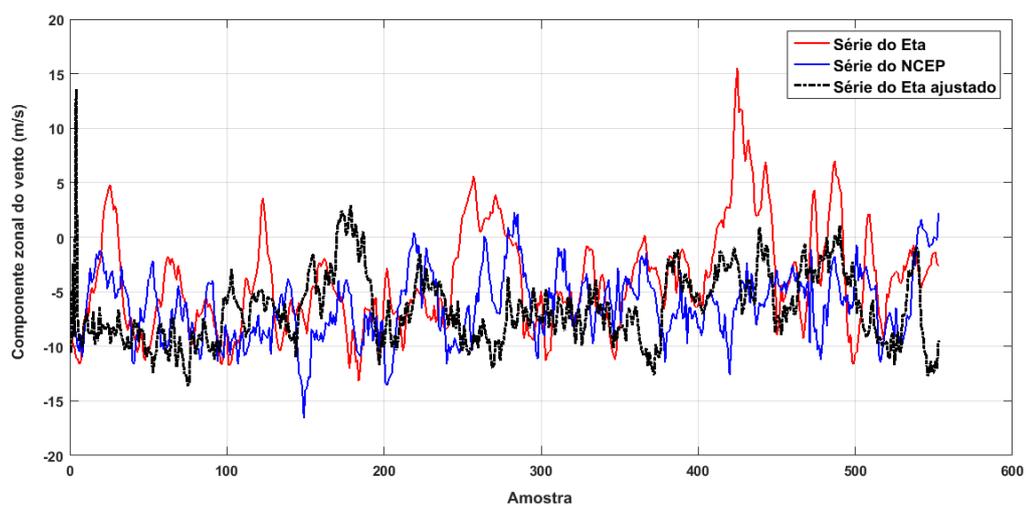


Figura 208 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 750 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

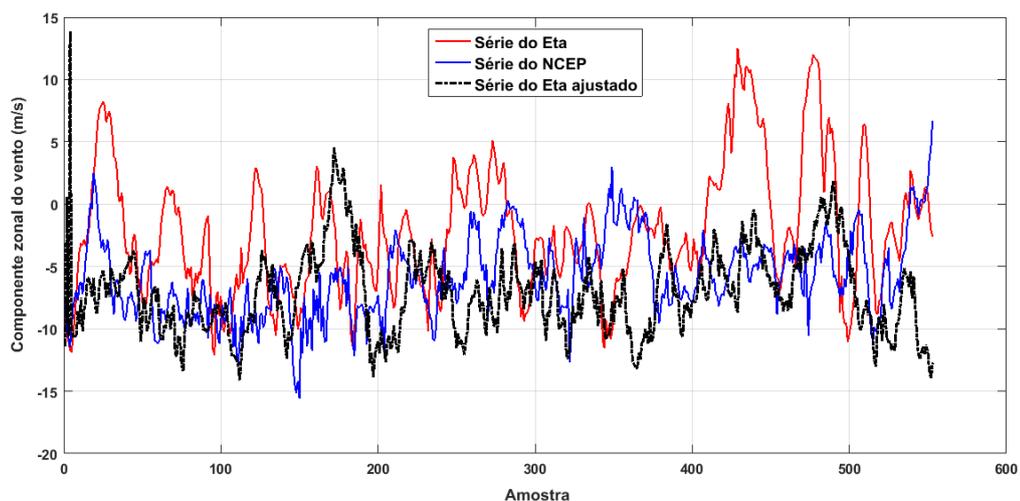


Figura 209 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 800 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

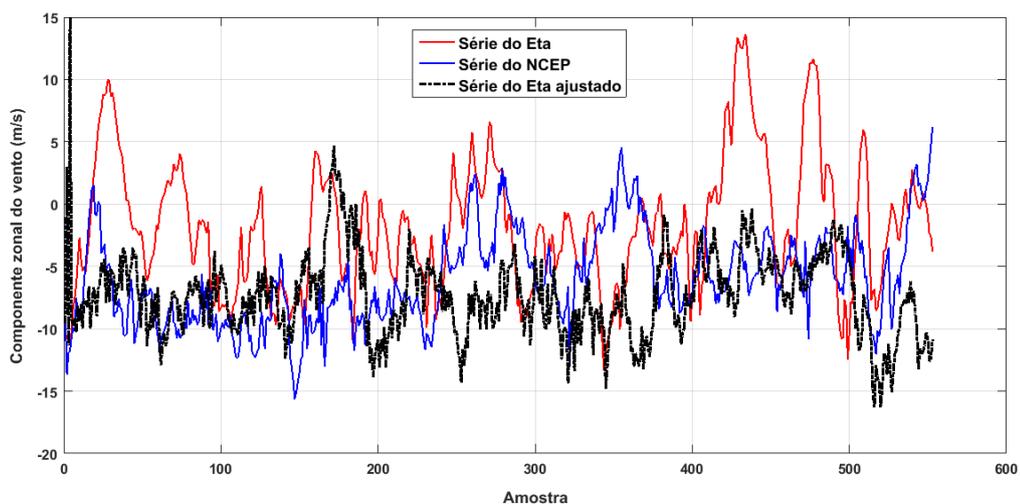


Figura 210 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 850 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

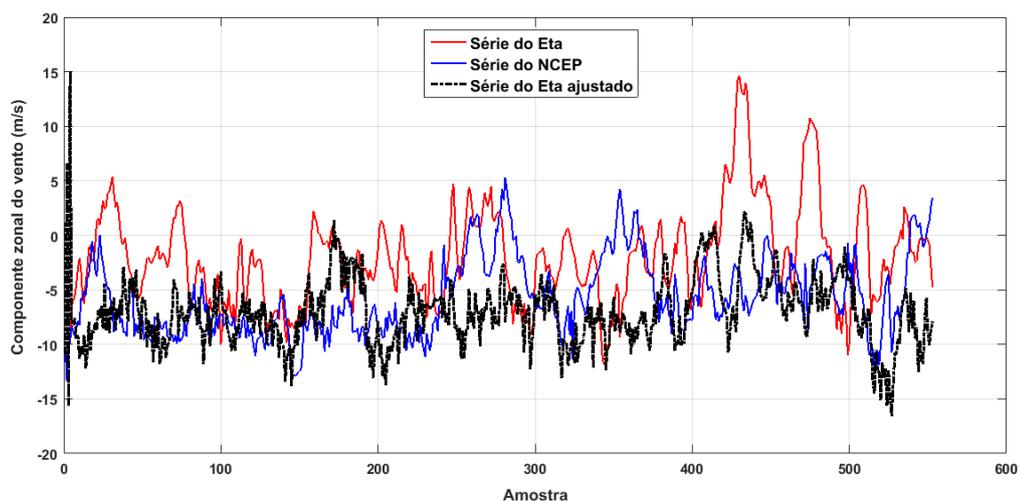


Figura 211 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 900 hPa, coordenadas geográficas dos pixels ( $45^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

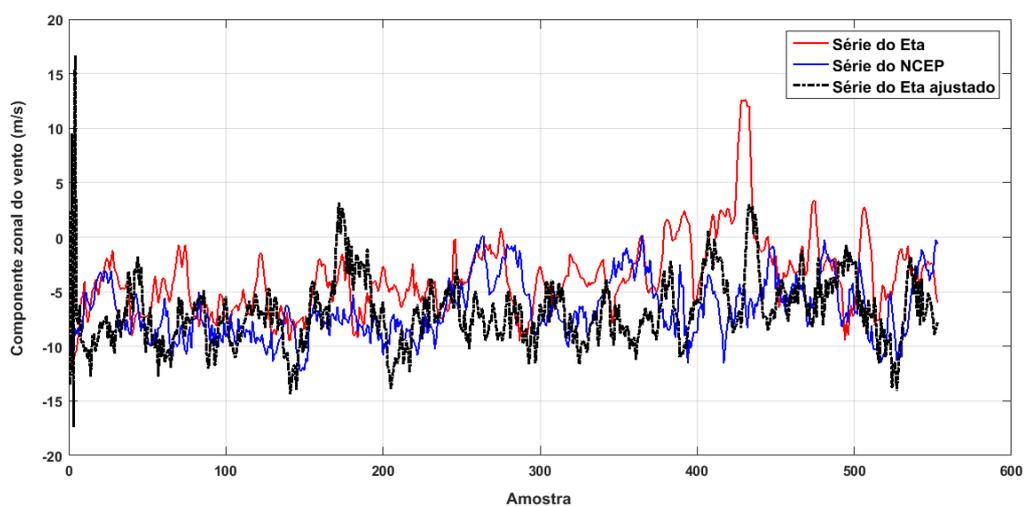


Figura 212 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 925 hPa, coordenadas geográficas dos pixels ( $45^{\circ}\text{W}$  e  $15^{\circ}\text{S}$ ), no ano de ajuste de 2009.

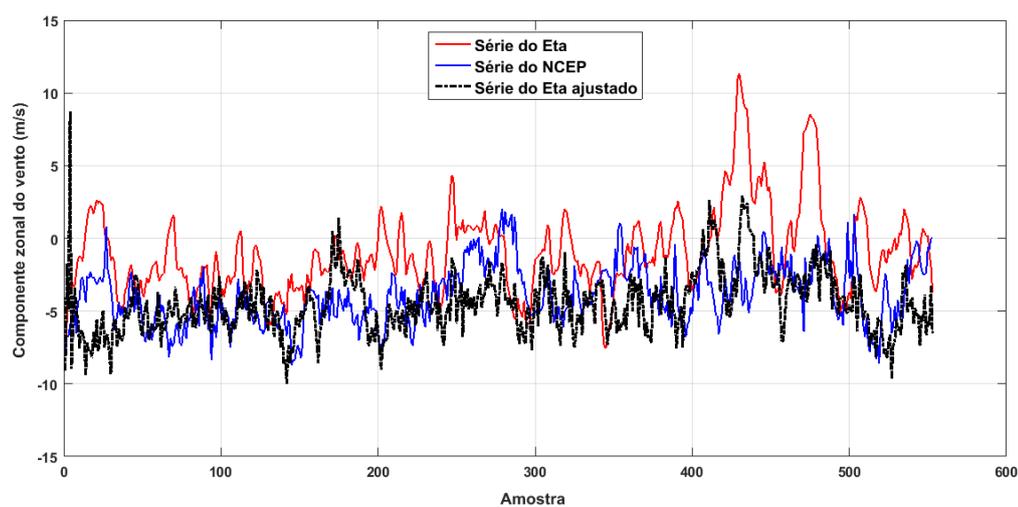


Figura 213 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 1000 hPa, coordenadas geográficas dos pixels ( $45^{\circ}W$  e  $15^{\circ}S$ ), no ano de ajuste de 2009.

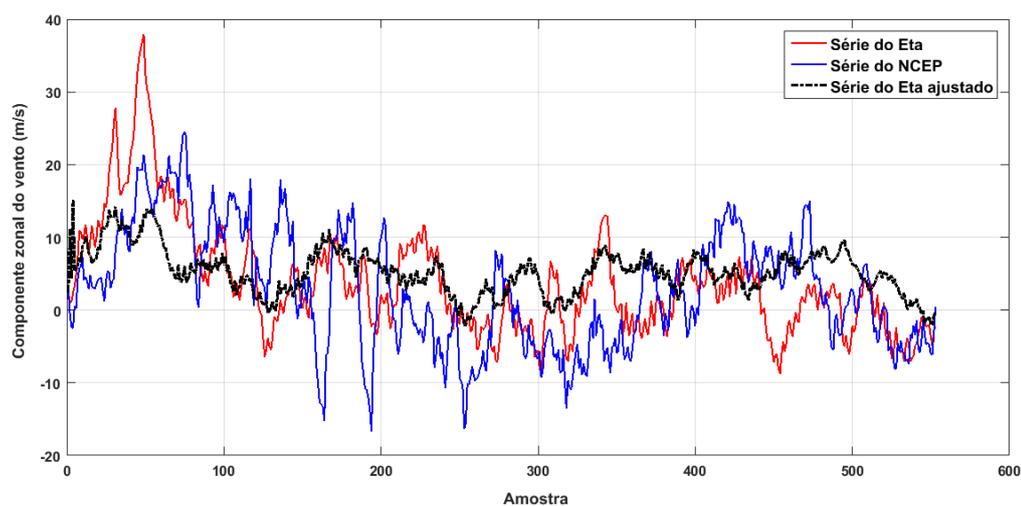


Figura 214 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 100 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

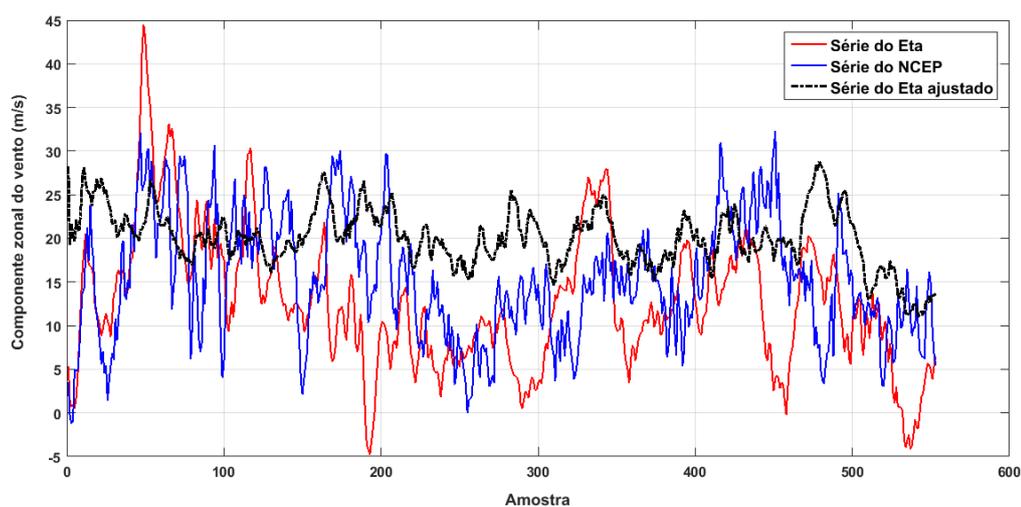


Figura 215 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 150 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

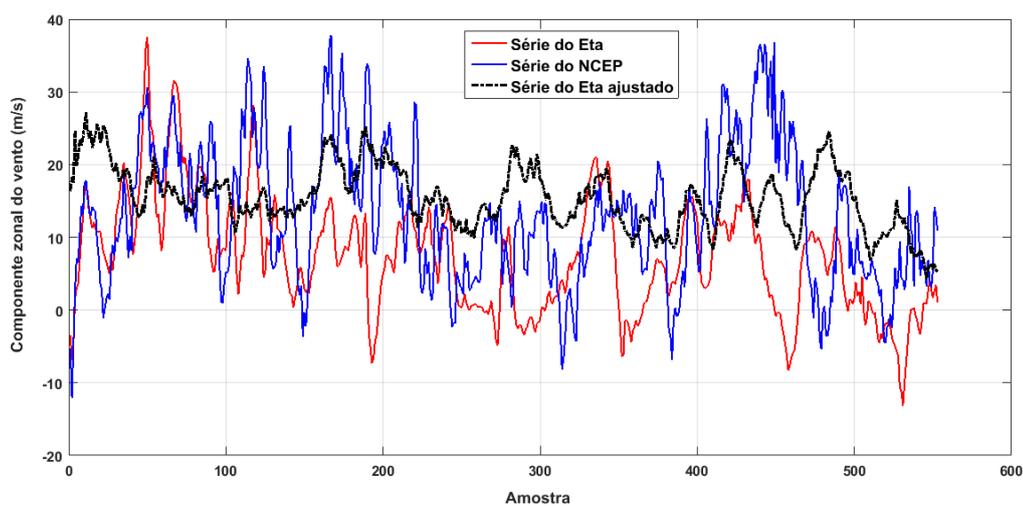


Figura 216 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 200 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

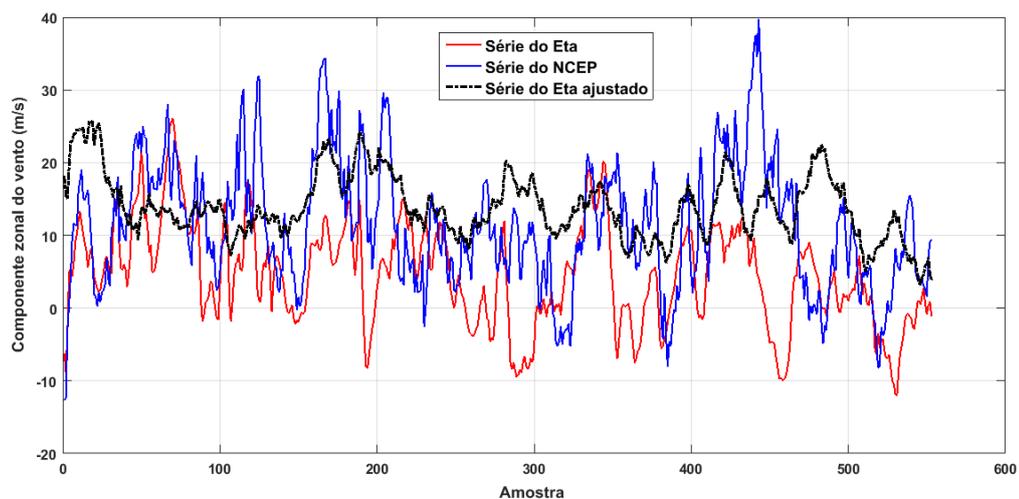


Figura 217 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 250 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

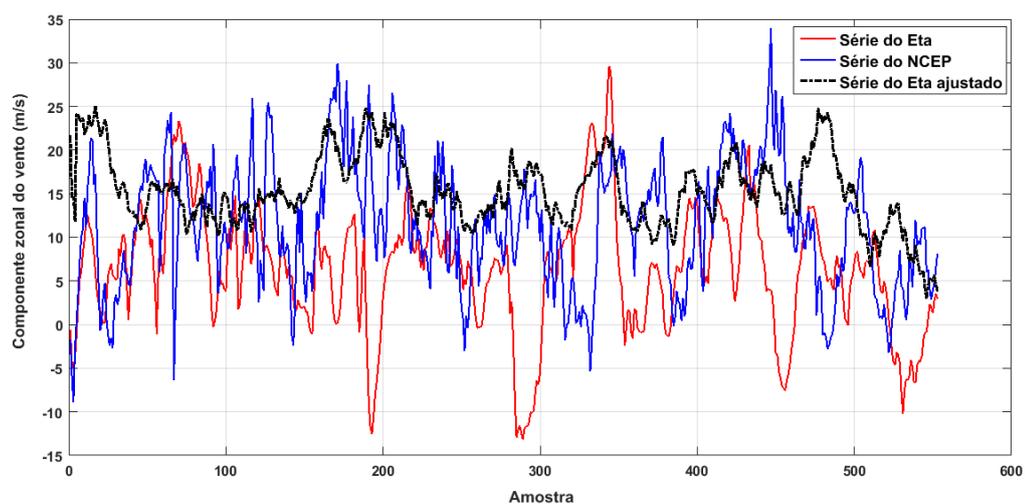


Figura 218 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 300 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

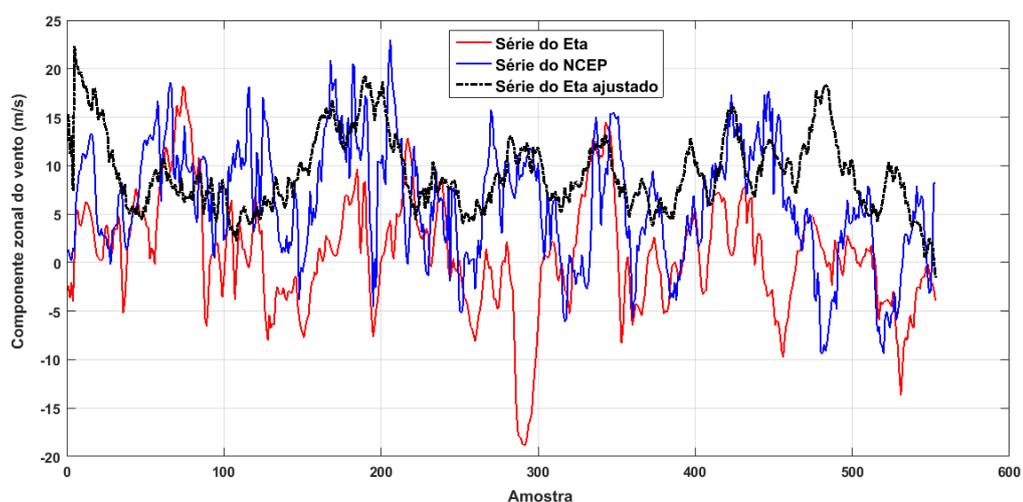


Figura 219 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 350 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

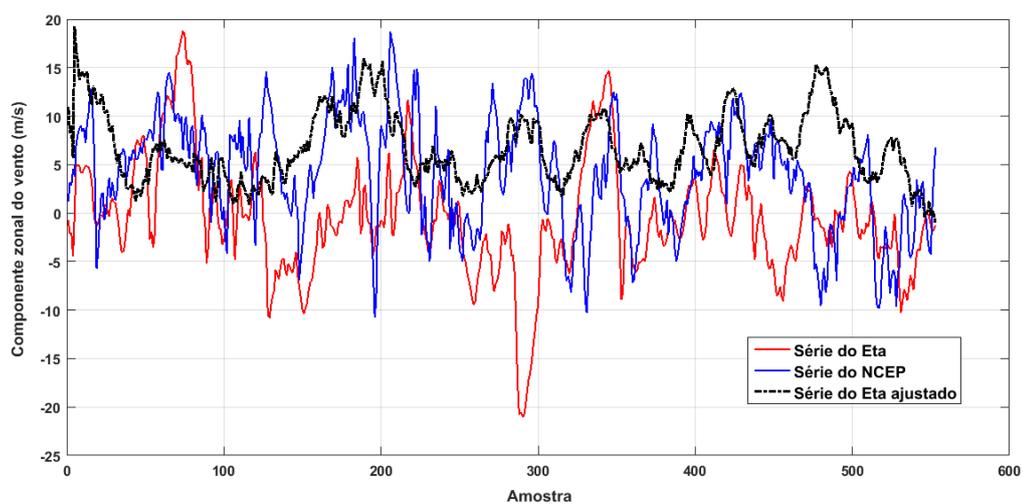


Figura 220 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 400 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

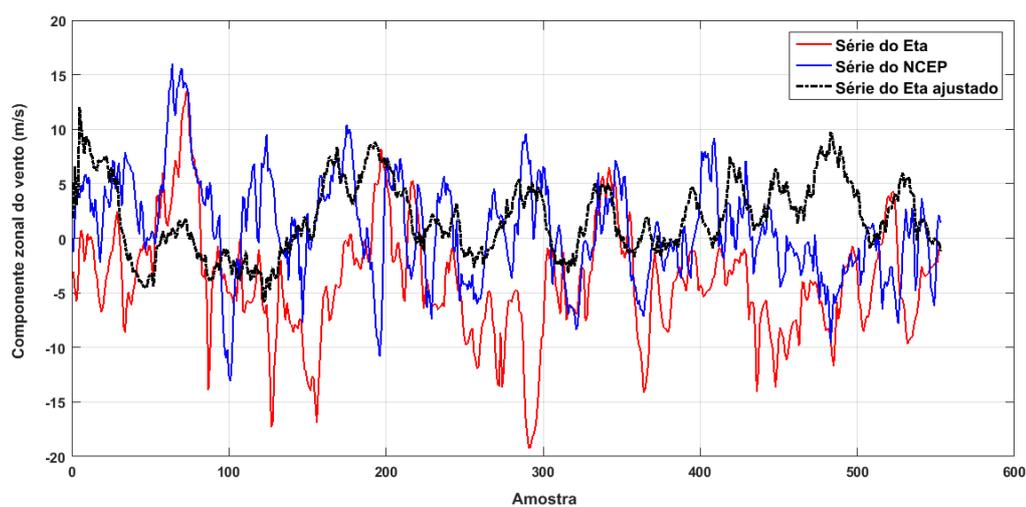


Figura 221 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 450 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

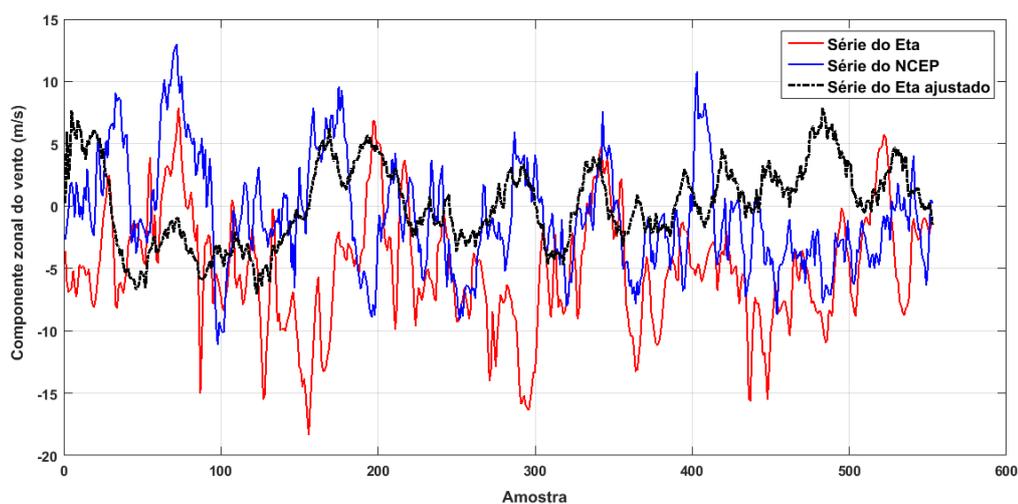


Figura 222 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 500 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

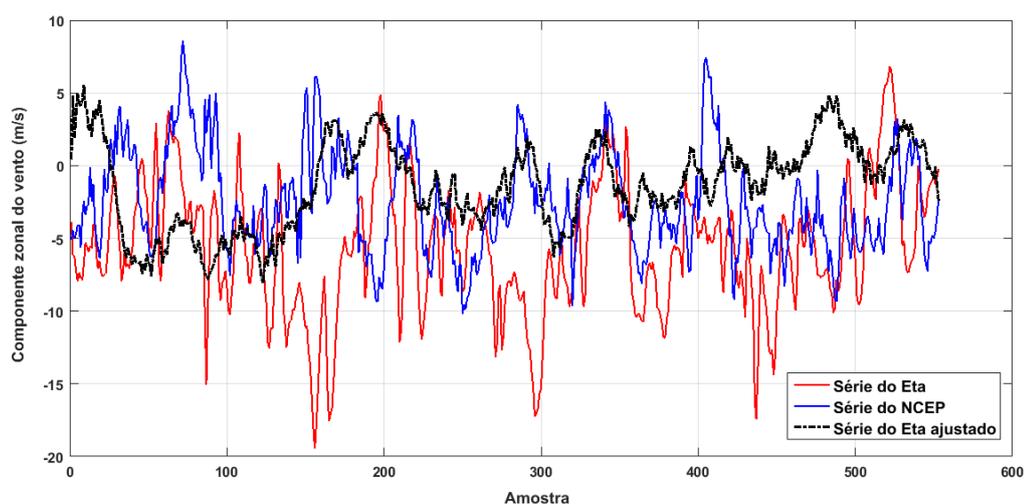


Figura 223 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 550 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

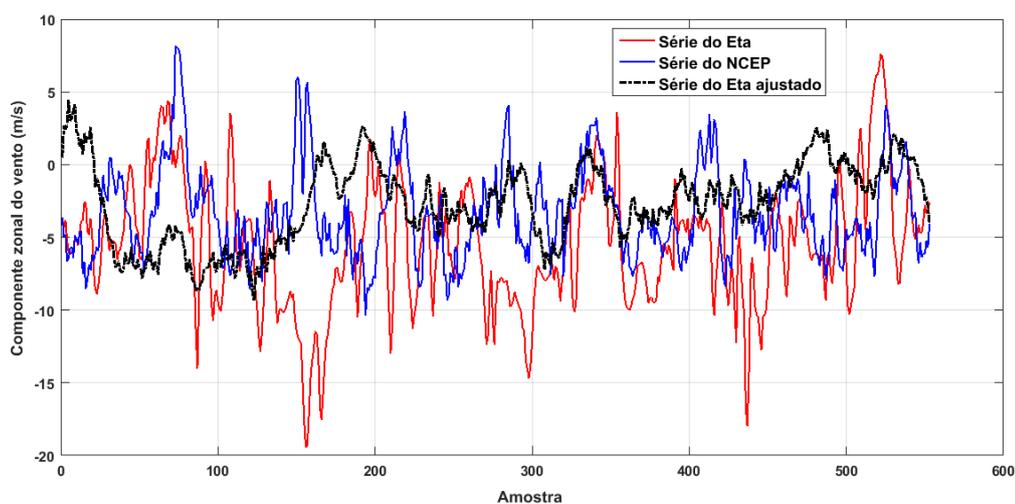


Figura 224 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 600 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

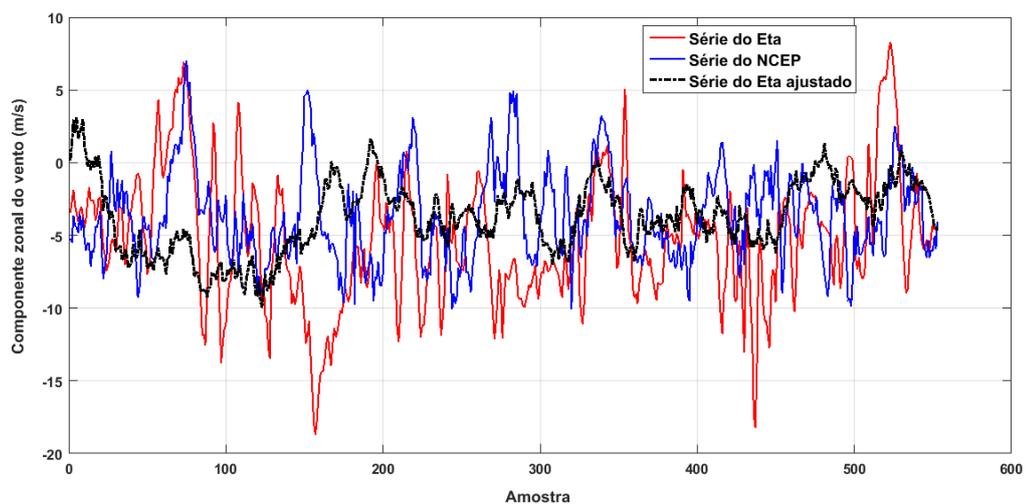


Figura 225 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 650 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

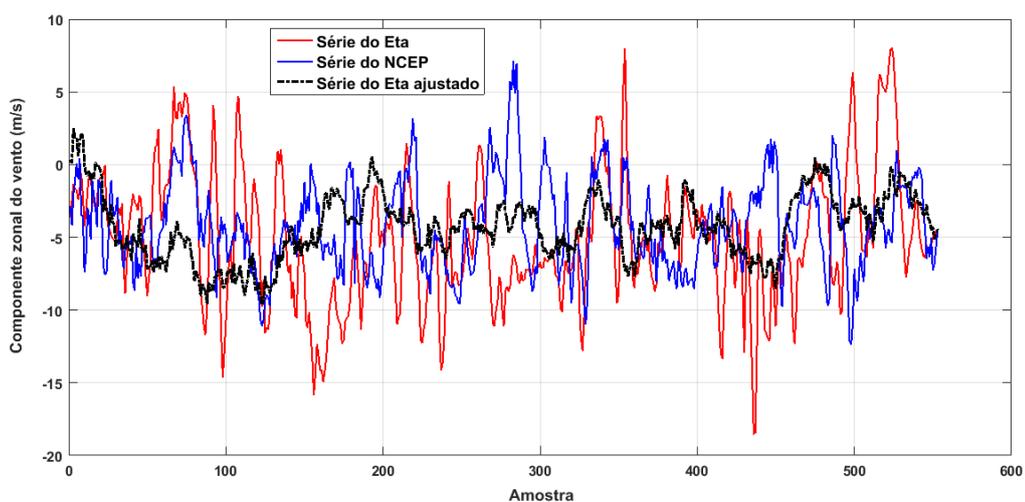


Figura 226 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 700 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

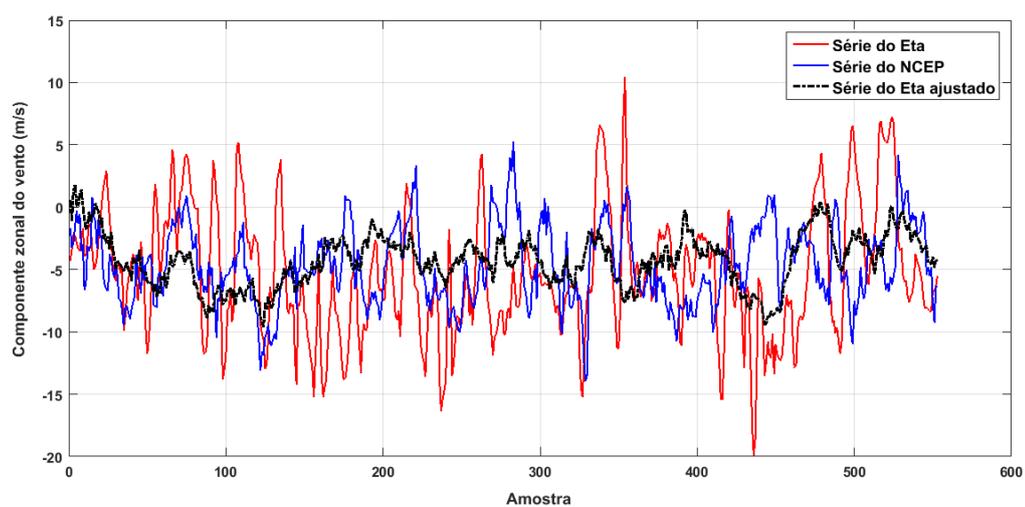


Figura 227 - Séries temporais para a componente zonal do vento ( $uvel$ ) a 750 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

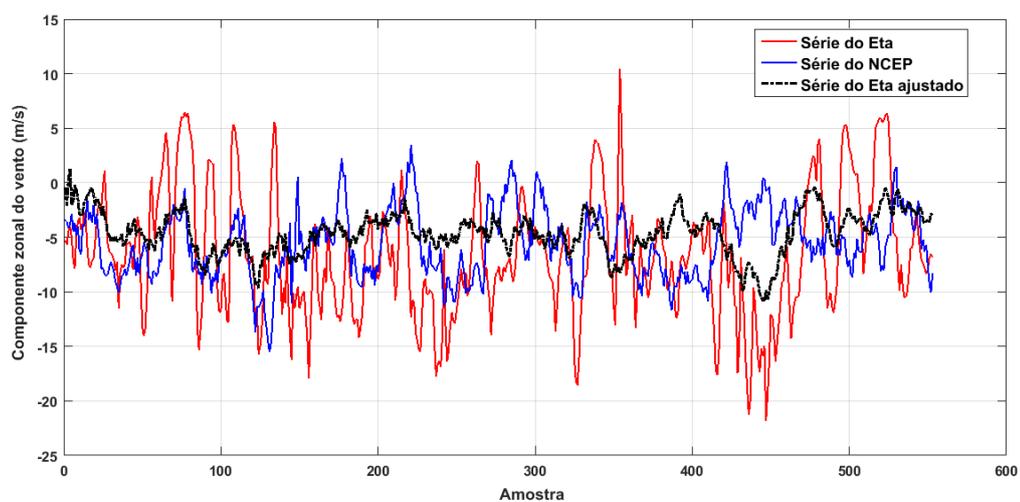


Figura 228 - Séries temporais para a componente zonal do vento ( $uvel$ ) a 800 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

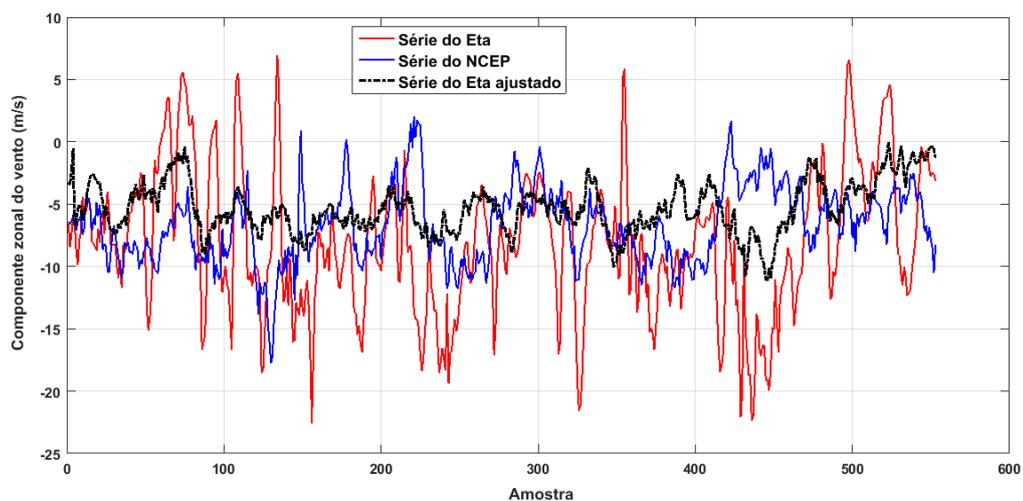


Figura 229 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 850 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

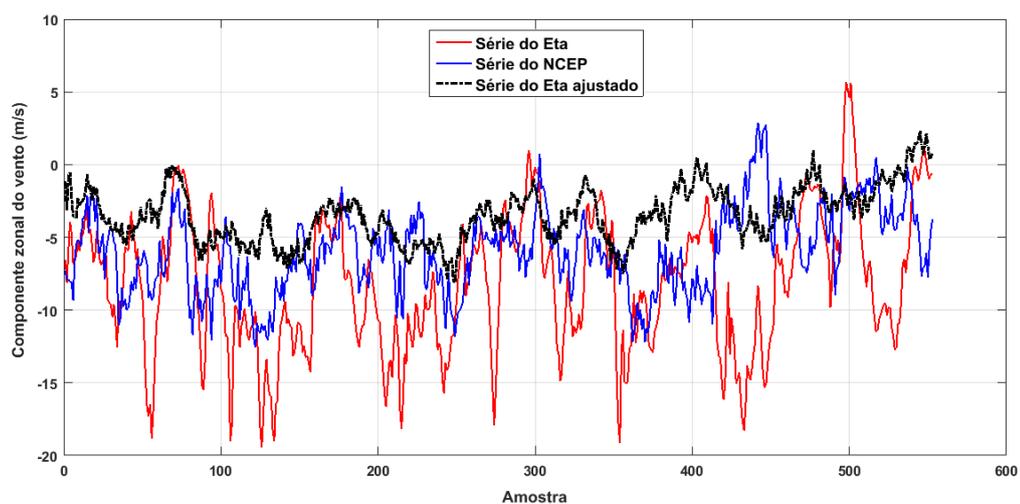


Figura 230 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 900 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

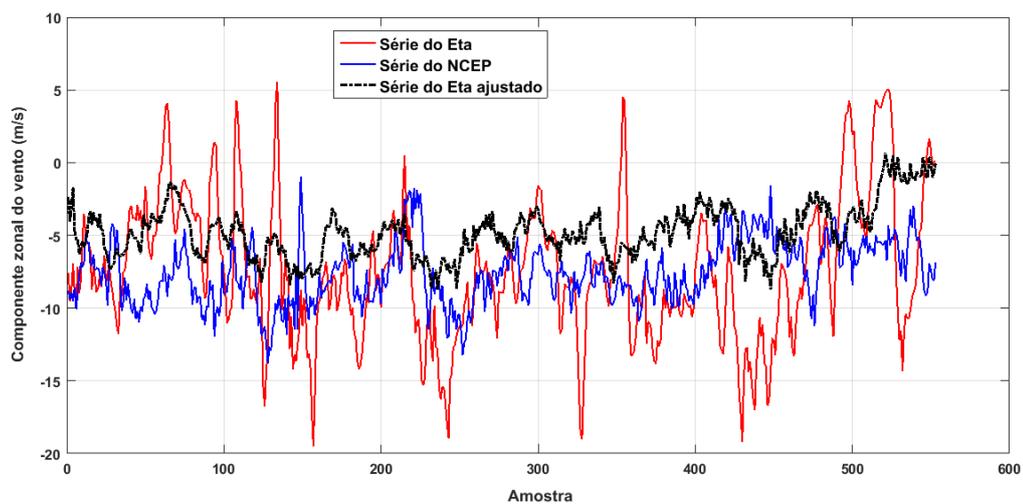


Figura 231 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 925 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.

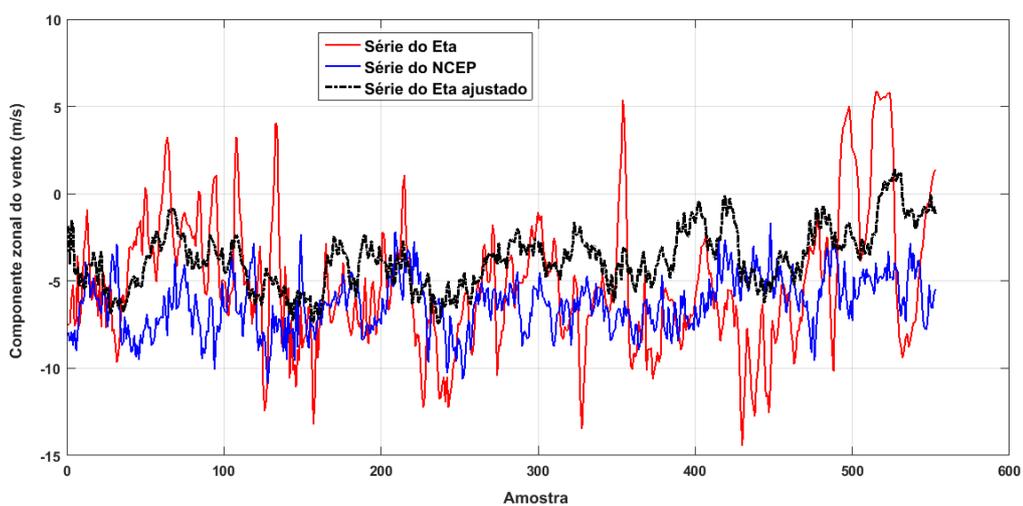


Figura 232 - Séries temporais para a componente zonal do vento ( $u_{vel}$ ) a 1000 hPa, coordenadas geográficas dos pixels ( $40^{\circ}W$  e  $10^{\circ}S$ ), no ano de ajuste de 2010.