



**Avaliação do Método de Assimilação de Dados En4DVar Implementado no Modelo WRF**  
Assessment of the En4DVar Data Assimilation Method implemented in WRF Model

Otávio Medeiros Feitosa; Fabrício Pereira Härter & Leonardo Calvetti

*Universidade Federal de Pelotas - Faculdade de Meteorologia, Departamento de Meteorologia,  
Avenida Engenheiro Ildefonso Simões Lopes, 2751, 96060-290, Arco-Iris Pelotas, RS – Brasil*

*E-mails: otaviomf123@gmail.com; fabricio.harter@ufpel.edu.br; lcalvetti@gmail.com*

*DOI: [http://doi.org/10.11137/2020\\_2\\_405\\_414](http://doi.org/10.11137/2020_2_405_414); Recebido: 27/01/2019 Aceito: 26/03/2019*

## Resumo

Métodos Híbridos baseados em previsão por conjuntos e cálculo variacional quadri-dimensional (En4DVAR) representam o estado da arte em métodos de assimilação de dados aplicados às ciências atmosféricas. Esta técnica permite a atualização da matriz de covariância de erros de previsão, sem o cálculo explícito destes erros, conforme a derivação teórica do filtro de Kalman ou suas aplicações operacionais; e também evita o cálculo do trabalhoso e custoso modelo adjunto e tangente linear, como no 4DVAR. Neste trabalho, avalia-se o método En4DVAR implementado no Weather Research and Forecasting Model (WRF), quanto a sua precisão nas primeiras 48 horas de previsão na região sul do Brasil no período de 09/04/2018 à 15/05/2018 dias. Utiliza-se como verdade terrestre dados das estações do Instituto Nacional de Meteorologia (INMET). Os resultados obtidos pelas métricas estatísticas Viés e Raiz do Erro Quadrático Médio, mostram que a o WRF-En4DVAR segue as mesmas tendências do WRF, com a particularidade de reduzir significativamente os erros. Entretanto, as variáveis Pressão à Superfície e Temperatura à 2m, apresentam melhor previsibilidade, tanto com como sem assimilação, ao passo que Umidade Relativa e Vento à 10 apresentam menor precisão tanto com o WRF como com o WRF-En4DVAR.

**Palavras-chave:** Assimilação; En4DVAR; WRF

## Abstract

Hybrid methods based on ensemble prediction and four-dimensional variational calculus (En4DVAR) are the state of the art in data assimilation techniques applied to the atmospheric sciences. This technique allows the updating the prediction errors of covariance matrix, without explicit calculation of these errors, according to the theoretical derivation of the Kalman filter or its operational applications; and also avoids the calculation of the laborious and costly adjoint and tangent linear model, as in 4DVAR. In this work, the En4DVAR method implemented in the Weather and Research and Forecasting Model (WRF) is evaluated for its accuracy in the first 48 hour forecasting for the southern region of Brazil, from 04/09/2018 to 05/15/2018. Data from National Institute of Meteorology (INMET) weather stations are used as ground truth. The results show that the WRF-En4DVAR has the same tendencies as the WRF, with the particularity of significantly reducing errors. However, the variables Surface Pressure and Temperature at 2m show better predictability comparing to while Relative Humidity and Wind at 10 m for both WRF and the WRF-En4DVAR.

**Keywords:** Assimilation; En4DVAR; WRF

## 1 Introdução

Problemas de valor inicial, com previsão numérica de tempo, apresentam menor erro em sua solução quando se combina previsão de curto prazo com dados oriundos das variadas fontes disponíveis na rede mundial de observação. Entretanto, a previsão de curto prazo, conhecida como *informação a priori* em teoria de estimação, tem imperfeições próprias da modelagem do sistema terra-atmosfera, tais como representação do contínuo de forma discreta e erros de arredondamento e truncamento. Por sua vez, a rede de observações nunca representará com perfeição o estado da atmosfera. Alguns erros de observação podem ser tratados com técnicas estatísticas, como erros de instrumento e erros de representatividade. Estes erros podem ter viés, podem ser espacialmente e temporalmente correlacionados com o sinal e não se ajusta a funções de distribuição conhecidas. Todavia, em assimilação de dados, a combinação da integração curta do modelo com dados observados, leva em consideração o conhecimento estatístico dos erros de modelagem e de observação. Contudo, é importante destacar que mesmo na situação hipotética de previsão por modelo perfeito assimilando dados sem ruído, haveria limite de imprevisibilidade típico da natureza caótica do sistema. O estado da arte em métodos de assimilação são métodos baseados no cálculo variacional e em filtragem de Kalman, especificamente o Método Variacional Quadridimensional (4DVar) (Rabier & Courtier, 1992; Courtier & Talagrand, 1998); e Filtro de Kalman por Conjuntos (*Ensemble*) EnKF (Evensen, 1994; Burgers *et al.*, 1998; Kalnay, 2003). Inclusive, em alguns trabalhos como Li & Navon (2001) mostram que estas técnicas tem resultados com igual precisão sob determinadas condições. Entretanto, estas técnicas tem suas limitações quando aplicadas a Previsão Numérica de Tempo (PNT), próprias da alta dimensão do problema, do fato dos erros serem tendenciosos e correlacionados além de não apresentarem função de distribuição gaussiana, restrições impostas em suas derivações, por hipótese.

Estas dificuldades motivam derivações destes métodos, tais como ensemble transform Kalman filter - ETKF (Bishop *et al.*, 2001), ensemble adjustment Kalman filter - EAKF (Anderson, 2001), local ensemble Kalman filter (LEKF) (Ott *et al.*, 2004), Variacional Tridimensional (3DVar)

(Huang & Yang, 1996).

Liu *et al.* (2008) e Liu *et al.* (2009) apresentam resultados da implementação do En4DVAR no modelo WRF. Esta técnica permite a atualização da matriz de covariância de erros de previsão (leva em conta os erros do dia), sem o cálculo explícito destes erros, conforme a derivação teórica do filtro de Kalman ou suas aplicações operacionais como em Parrish & Derber (1992); e também evita o cálculo do trabalhoso e custoso modelo adjunto e tangente linear do modelo, como no 4DVAR.

Neste trabalho, avalia-se o método En4DVAR implementado no modelo WRF, com foco nas primeiras 48 horas de previsão para região sul do Brasil, no período de 09/04/2018 à 15/05/2018. Utiliza-se como verdade terrestre as estações do Instituto Nacional de Meteorologia (INMET).

## 2 Metodologia

### 2.1 Modelo WRF

O WRF é um modelo de equações primitivas desenvolvido pelo National Center for Atmospheric Research (NCAR) em colaboração com o National Centers for Environmental Prediction/ National Oceanic and Atmospheric Administration (NCEP/NOAA) e o Forecast Systems Laboratory (FSL). O sistema de assimilação formado pelo modelo, pelo método de assimilação e demais utilitários resultam num sistema de previsão numérica de tempo de última geração, podendo ser implementado em várias arquiteturas de computadores e suportando diferentes diretivas de paralelismo.

O WRF utilizado nesta pesquisa está instalado num cluster Beowulf (clusters de computadores pessoais, não desenvolvidos especificamente para este fim e, portanto com custo mais barato), sob sistema operacional Linux64 e compilado com diretivas Message Passing Interface (MPI). O domínio escolhido para a simulação compreende basicamente a região centro-sul da América do Sul. O modelo é integrado no modo não-hidrostático por excesso de precaução, resolução de 15 km, passo de tempo 90 s, 40 níveis verticais com coordenadas híbridas Eta/Sigma e projeção Lambert.

Os prognósticos de 48 horas são realizados diariamente a partir das 00 UTC, do dia 09/04/2018

até o dia 15/05/2018, com assimilação horária durante a janela de assimilação de 12 horas. Não foi realizado o *spin up* do modelo, porque a variável precipitação esta fora do escopo deste trabalho. Entretanto, explora-se esta variável em uma pesquisa exclusiva sobre a previsibilidade do WRF-En4DVar.

A verificação, Viés e Raiz do Erro Quadrático Médio (REQM), é feita em ponto da localização das estações meteorológicas, ou seja, as variáveis do modelo em ponto de grade são interpoladas para o ponto de observação e comparadas com a observação.

## 2.2 Método Variacional Quadrimensional Baseado em Conjuntos (En4DVAR)

O En4DVAR consiste em calcular a matriz de covariância dos erros e previsão por médias de um conjunto de previsões e trabalhar no espaço físico ao invés do espaço das variáveis do modelo. Isso implica instabilidade numérica própria do mal condicionamento das matrizes envolvidas no processo de minimização. Este processo causa erros de amostragem, pois o número de membros do conjunto é usualmente menor do que o espaço do modelo. Entretanto este problema é resolvido por técnicas de localização. No caso do WRF a localização é obtida através de Funções Empíricas Ortogonais (EOF).

Matematicamente, minimiza-se a seguinte função custo nas variáveis de controle no espaço do modelo

(1)

$$J(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \sum_{i=0}^I (\mathbf{H} \mathbf{M} \mathbf{U} \mathbf{w} + \mathbf{d}_i)^T \mathbf{O}^{-1} (\mathbf{H} \mathbf{M} \mathbf{U} \mathbf{w} + \mathbf{d}_i),$$

onde  $\mathbf{w}$  é a variável de controle,  $I$  é o número total de tempos nos quais as observações estão disponíveis para assimilação,  $\mathbf{H}$  é o operador de observação linearizado,  $\mathbf{M}$  é o operador de modelagem linearizado e  $\mathbf{O}$  representa a covariância dos erros de observação. O vetor inovação para cada

passo de tempo  $i$  é calculado por

$$\mathbf{d}_i = \mathbf{H} \mathbf{M}(\mathbf{x}_b) - \mathbf{y}_i \quad (2)$$

onde  $\mathbf{x}_b$  é a matriz de background das variáveis do modelo, no qual cada coluna representa um membro do vetor de estado do campo de background,  $\mathbf{H}$  é o operador de observações,  $\mathbf{M}$  representa o modelo de previsão e  $\mathbf{y}$  o vetor de observações. Entretanto, define-se uma matriz de condicionamento  $\mathbf{U}$ , tal que

$$\mathbf{B} = \mathbf{U} \mathbf{U}^T, \quad (3)$$

de forma que a análise é obtida por

$$\mathbf{x}_a = \mathbf{x}_b + \mathbf{U} \mathbf{w}. \quad (4)$$

O diferencial do En4DVAR é que a matriz de condicionamento da abordagem incremental do 4DVAR é substituída por uma matriz de perturbação, na qual suas colunas, são desvios normalizados obtidos por uma média dos  $N$  membros e um conjunto definido por

(5)

$$\mathbf{X}'_b = \frac{1}{\sqrt{N-1}} (\mathbf{x}_{b1} - \overline{\mathbf{x}_b}, \mathbf{x}_{b2} - \overline{\mathbf{x}_b}, \dots, \mathbf{x}_{bN} - \overline{\mathbf{x}_b}).$$

Portanto, a matriz de covariância dos erros de background pode ser aproximada por

$$\mathbf{B} \approx \mathbf{X}'_b \mathbf{X}'_b{}^T. \quad (6)$$

Assim, a função custo a ser minimizada no En4DVAR no espaço das variáveis de controle é dada por

(7)

$$J(\mathbf{w}) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \sum_{i=0}^I (\mathbf{H} \mathbf{M} \mathbf{X}'_b \mathbf{w} + \mathbf{d}_i)^T \mathbf{O}^{-1} (\mathbf{H} \mathbf{M} \mathbf{X}'_b \mathbf{w} + \mathbf{d}_i).$$

Com o objetivo de se evitar o cálculo do operador tangente linear, modelo tangente linear ( $\mathbf{M}$ ), operador adjunto e modelo adjunto ( $\mathbf{M}^T$ ) no cálculo do gradiente da função custo, transforma-se a matriz de perturbação para o espaço de observação via

(8)

$$HM\mathbf{x}'_b \approx \frac{1}{\sqrt{N-1}}(HM\mathbf{x}_{b1} - HM\bar{\mathbf{x}}_b, HM\mathbf{x}_{b2} - HM\bar{\mathbf{x}}_b, \dots, HM\mathbf{x}_{bN} - HM\bar{\mathbf{x}}_b).$$

Portanto, a derivação do gradiente da função custo resulta em

(9)

$$\nabla_w J = \mathbf{w} + \sum_{i=0}^I (HM\mathbf{x}'_b)^T \mathbf{O}^{-1} (HM\mathbf{x}'_b \mathbf{w} + \mathbf{d}_i).$$

Na Equação 9, o erro de *background* no espaço de observação é calculado apenas uma vez através das  $N$  previsões do conjunto, tal que o custo computacional da minimização da função custo é reduzido, além e não ser necessário o cálculo do modelo adjunto, nem da linearização do modelo direto e do operador de observações  $H$ .

No En4DVAR a degeneração causada pela redução do espaço de busca gera a necessidade do uso de técnicas de localização (*localization*) para reduzir este erro de amostragem. No WRF está implementado um esquema de localização baseado em Funções Empíricas Ortogonais (EOF), descrito em Buehner (2005).

### 2.3 Rede de Observações, Condições Iniciais e de Fronteira

Os dados utilizados no processo de assimilação são obtidos do Meteorological Assimilation Data Ingest System (MADIS) ([www.madis.noaa.gov](http://www.madis.noaa.gov)), radiâncias dos sensores

AMSU-A, AMSU-B, e Atmospheric Infrared Sounder (AIRS) e, Advanced Technology Microwave Sounder (ATMS) e Microwave Humid Sound (MHS). A verificação é realizada com dados de estações de superfície do Instituto Nacional de Meteorologia (INMET) e as Condições Iniciais (CI) e de fronteira (CF) são oriundas do Global Forecasting System (GFS) no formato grib2. O GFS tem resolução horizontal de 50 Km com 32 níveis de pressão sem contar com a superfície. Inclui-se a temperatura da superfície do mar do dia anterior a rodada e dados terrestres com 2 minutos de resolução. Optou-se por reservar os dados convencionais apenas para a verificação, pois assim se evita avaliar

resultados baseados em assimilações que usam a mesma fonte de dados tanto para assimilar como para verificar. Também, se tem especial interesse em assimilação de dados de satélite, devido a escassez de dados meteorológicos em altitude na América do Sul.

### 3 Resultados

Os resultados apresentados nesta seção, são obtidos de previsões de 48 horas do WRF por um período de 36 dias, a saber: do dia 09/04/2018 até o dia 15/05/2018 (a partir das análises das 12 UTC). Grafou-se integrações sem assimilação (WRF) e com assimilação (WRF-En4DVAR) contra dados observados nas estações do INMET. Explorou-se os resultados, através da Raiz do Erro Quadrático Médio e Viés médios sobre o domínio de integração. A estratégia de assimilação utilizada compreende janela de assimilação de 12 horas, sendo 6 horas para trás e 6 horas para frente em relação a condição inicial com ciclo de assimilação de 1 hora,

A seguir são grafados os resultados do WRF e WRF-En4DVAR contra a Verdade Terrestre (dados coletados nas estações do INMET), bem como os EMQ e viés destas previsões.

Para cada variável, tem-se o seguinte padrão de figuras: na esquerda grafa-se a evolução temporal da previsão do WRF, WRF-En4DVAR e verdade terrestre; no centro grafa-se o EMQ e na direita grafa-se o Viés.

A Figura 1A mostra que o modelo com ou sem sistema de assimilação tem boa previsibilidade da variável Pressão à Superfície, haja vista a magnitude da variável frente aos erros da ordem de  $10^1$  hPa. Observa-se também, a tendência do modelo em apresentar viés positivo de pressão à superfície (Figura 1C), sendo que essa tendência positiva é da ordem de 1 hPa maior na previsão do WRF em relação ao WRF-En4DVar durante todo o período de previsão. No cálculo do EMQ, Figura 1B, erros positivos e negativos de mesma magnitude se anulam, entretanto é possível observar que ocorre menor EMQ na previsão gerada com assimilação.

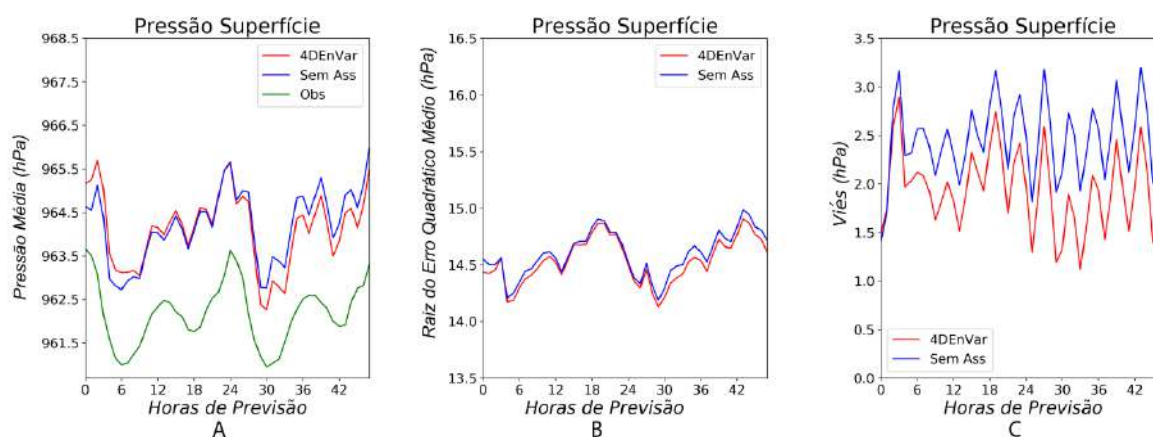


Figura 1 48 horas de previsão de Pressão à Superfície (hPa). A. WRF com assimilação em vermelho, WRF sem assimilação em azul e verdade terrestre em verde; B. Raiz do Erro Quadrático Médio (hPa) da previsão do WRF com assimilação em vermelho e sem assimilação em azul; C. Viés (hPa) da previsão do WRF com assimilação em vermelho e sem assimilação em azul.

A previsão de Temperatura à 2m, Figura 2A, é bem prevista tanto pelo WRF como pelo WRF-En4DVar, sendo que a assimilação faz com que o modelo superestime os picos de máxima temperatura, enquanto o modelo sem assimilação subestima os picos de máxima, ou seja, o processo de assimilação gera máximas mais altas. Os picos de mínima são superestimados tanto pelo WRF como pelo WRF-En4DVar. Durante todo o domínio, o EMQ gerado pelo modelo com assimilação híbrida (Figura 2B), é menor do que o modelo sem assimilação. Esta diferença no EMQ é no máximo 1°C, mas se deve considerar que esta evolução

temporal representa uma média do domínio espacial. Portanto, pode haver regiões com erros maiores e outras com erros menores. Esta situação é evidenciada na espacialização dos erros, explorada adiante. O Viés, grafado na Figura 2C, confirma que o WRF-En4DVAR tem a tendência de aquecer a atmosfera próxima aos picos de máximas, enquanto o WRF tem a tendência em esfriar a atmosfera. Todavia, nos picos de mínima temperatura, tanto o En4DVAR como o WRF tendem a esfriar a atmosfera, sendo que o esfriamento gerado pelo En4DVAR é um pouco menos intenso.

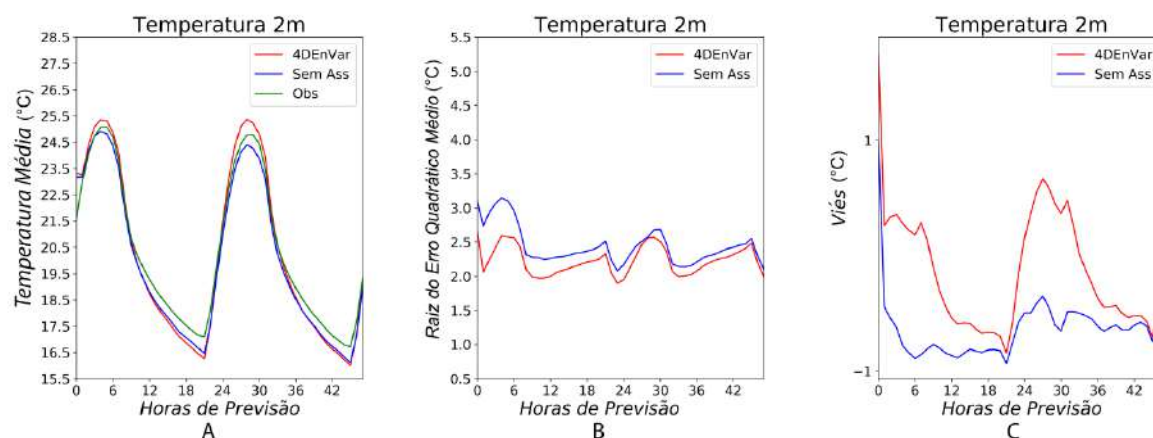


Figura 2 48 horas de previsão de Temperatura à 2m(°C). A. WRF com assimilação em vermelho, WRF sem assimilação em azul e verdade terrestre em verde; B. Raiz do Erro Quadrático Médio (°C) da previsão do WRF com assimilação em vermelho e sem assimilação em azul e; C. Viés (°C) da previsão do WRF com assimilação em vermelho e sem assimilação em azul.

Os Campos de Umidade Relativa do Ar à 2 m, previstos tanto pelo WRF como pelo WRF-En4DVAR, também acompanham o ciclo diurno observado na natureza, porém o método de

assimilação resulta em previsão dos extremos com maior precisão, “secando” corretamente a atmosfera adjacente à superfície, Figura 3A. O gráfico de EMQ evidencia a superioridade do modelo com

assimilação durante todo o período de integração (Figura 3B). O modelo não foi submetido a um período de spin up, de forma que os resultados mostram que, tanto o WRF como o WRF-En4DVar, geram uma atmosfera mais seca do que a verdade

terrestre apenas no período anterior a primeira hora de integração. Logo após este curto período, se observa viés positivo, Figura 3C, ou seja, o modelo subestima a umidade.

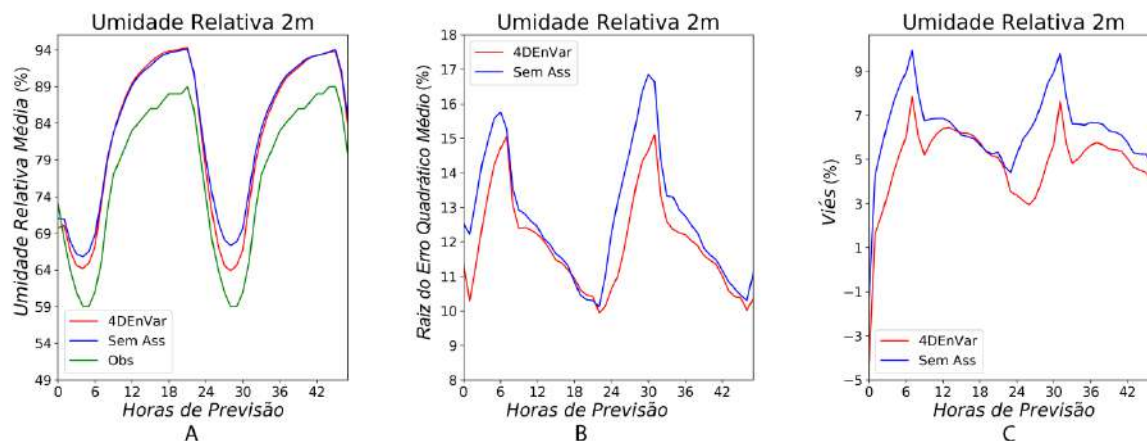


Figura 3 48 horas de previsão de Umidade Relativa do Ar à 2 metros (%). A. WRF com assimilação em vermelho, WRF sem assimilação em azul e verdade terrestre em verde; B. Raiz do Erro Quadrático Médio (%) da previsão do WRF com assimilação em vermelho e sem assimilação em azul e; C. Viés (%) da previsão do WRF com assimilação em vermelho e sem assimilação em azul.

Os resultados apresentados na Figuras 4A, evidenciam que a Velocidade do Vento à 10 m é uma variável de difícil previsão, pois tanto as previsões com como sem assimilação apresentam erros que chegam até 100% já nas primeiras horas de previsão. Entretanto, a assimilação nas primeiras 24 horas de previsão, geram ganhos de precisão de aproximadamente 20% na previsão desta variável (EMQ - Figura 4B) e Viés (Figura 4C). A

difficuldade de previsão da Velocidade do Vento à Superfície, deve-se principalmente a dificuldade em representar os termos não-lineares da Camada Limite Planetária. Esta imprecisão da previsão do vento à superfície, também se verifica quanto a direção (Figuras 5A-C). Embora, tanto o WRF quanto o WRF-En4DVAR tenham acertado a direção do vento predominante de Sudeste, há considerável erro na intensidade e na mudança de direção.




Figura 4 48 horas de previsão de Vento à 10 metros do solo ( $\text{ms}^{-1}$ ). A. WRF com assimilação em vermelho, WRF sem assimilação em azul e verdade terrestre em verde; B. Raiz do Erro Quadrático Médio ( $\text{ms}^{-1}$ ) da previsão do WRF com assimilação em vermelho e sem assimilação em azul; C. Viés ( $\text{ms}^{-1}$ ) da previsão do WRF com assimilação em vermelho e sem assimilação em azul.

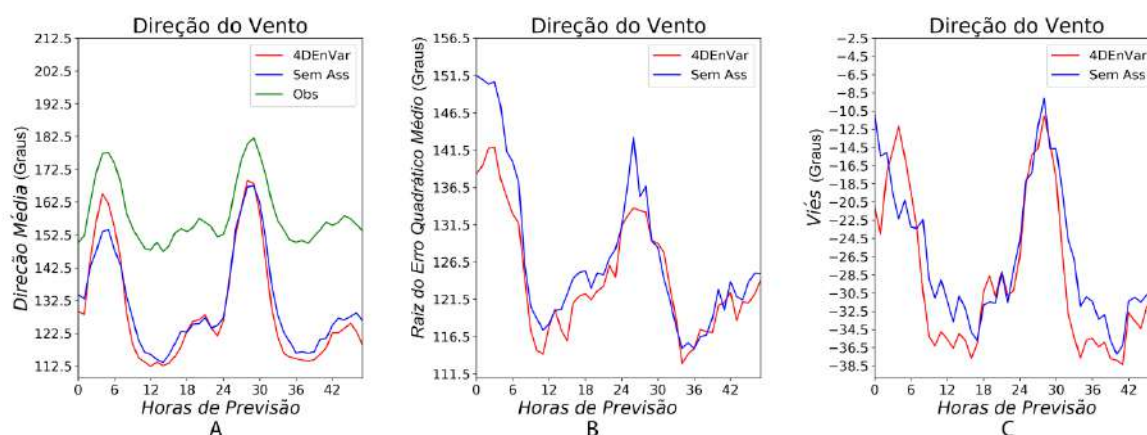


Figura 5 48 horas de previsão de Direção do Vento (graus). A. WRF com assimilação em vermelho, WRF sem assimilação em azul e verdade terrestre em verde; B. Raiz do Erro Quadrático Médio (graus) da previsão do WRF com assimilação em vermelho e sem assimilação em azul; C. Viés (graus) da previsão do WRF com assimilação em vermelho e sem assimilação em azul.

As Figuras 6 à 9, ilustram a distribuição espacial média do EMQ com e sem assimilação de dados (médio sobre os 36 dias de previsão). O tamanho dos círculos, explícitos nas legendas,

descrevem a intensidade dos erros em cada região do domínio, para cada variável sem (WRF) e com assimilação (WRF-En4DVar).

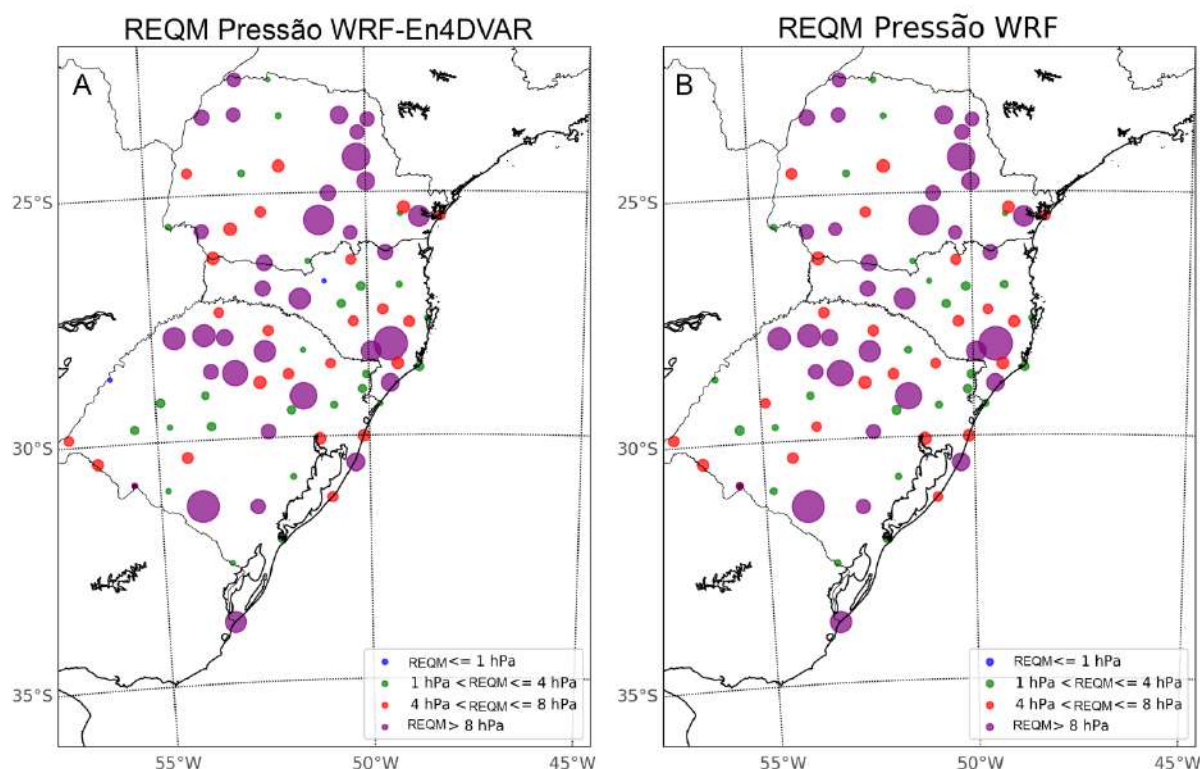


Figura 6 Raiz do Erro Quadrático Médio para Pressão à Superfície (hPa). A. com; B. sem assimilação.

A Figura 6, confirma que o campo de Pressão à Superfície tem excelente previsibilidade, pois mesmo as regiões com maiores erros (círculos roxos no mapa), representam erro da ordem  $10^0$  hPa. Embora estes erros sejam espacialmente bem distribuídos no domínio de previsão, estão mais

concentrados no norte do RS, sul de SC e leste do PR. Observa-se também na Figura 6, a melhora do WRF-En4DVAR em relação ao WRF, na região centro-oeste do RS, evidente por ter mais círculos verdes (EMQ entre 1 e 4 hPa) do que vermelhos (EMQ entre 4 e 8 hPa).

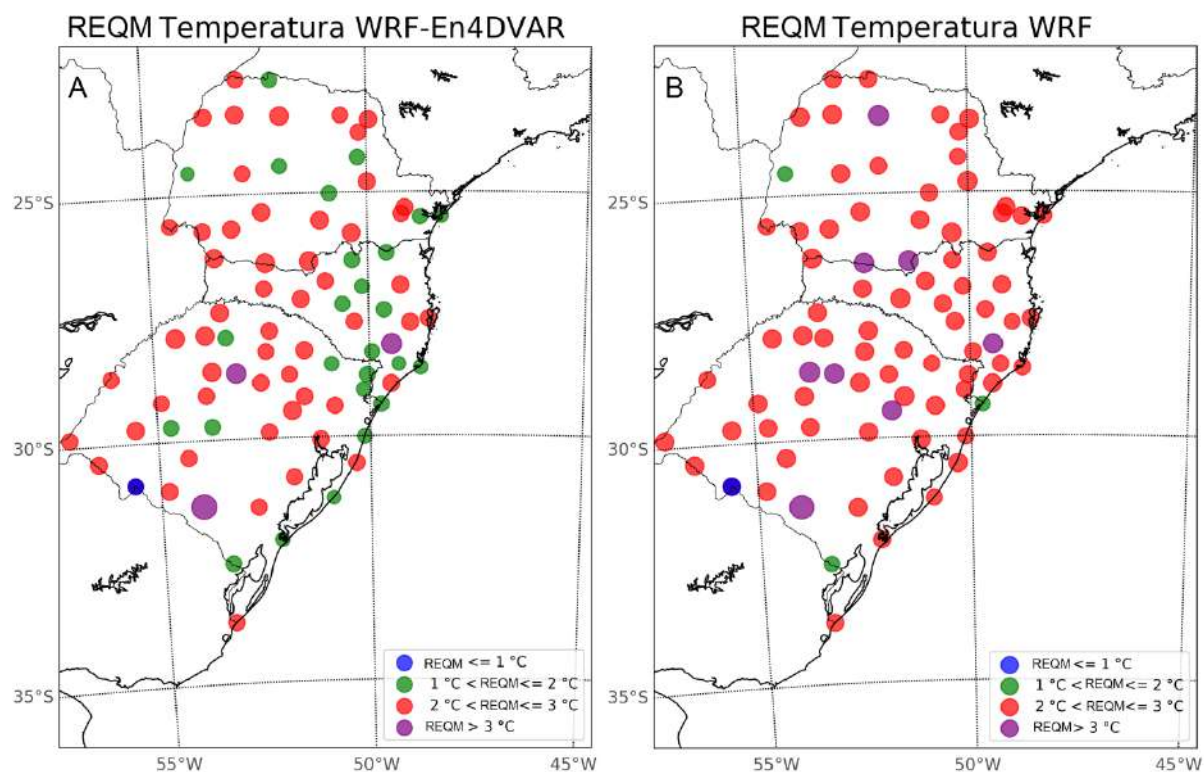


Figura 7 Raiz do Erro Quadrático Médio para Temperatura à 2m (°C). A. com; B. sem assimilação.

O campo de Temperatura à 2m, mostra que predomina EMQ bem distribuido entre 2 e 3 °C, o que esta dentro de limiares de boa previsibilidade para estas latitude, onde o tempo tem grande variabilidade temporal, devido sobretudo, a passagem de sistemas

frontais. Destaca-se, que o modelo com assimilação, tem evidente melhora, em torno de 1°C na previsão desta variável, no litoral do RS, leste de SC e centro do PR.

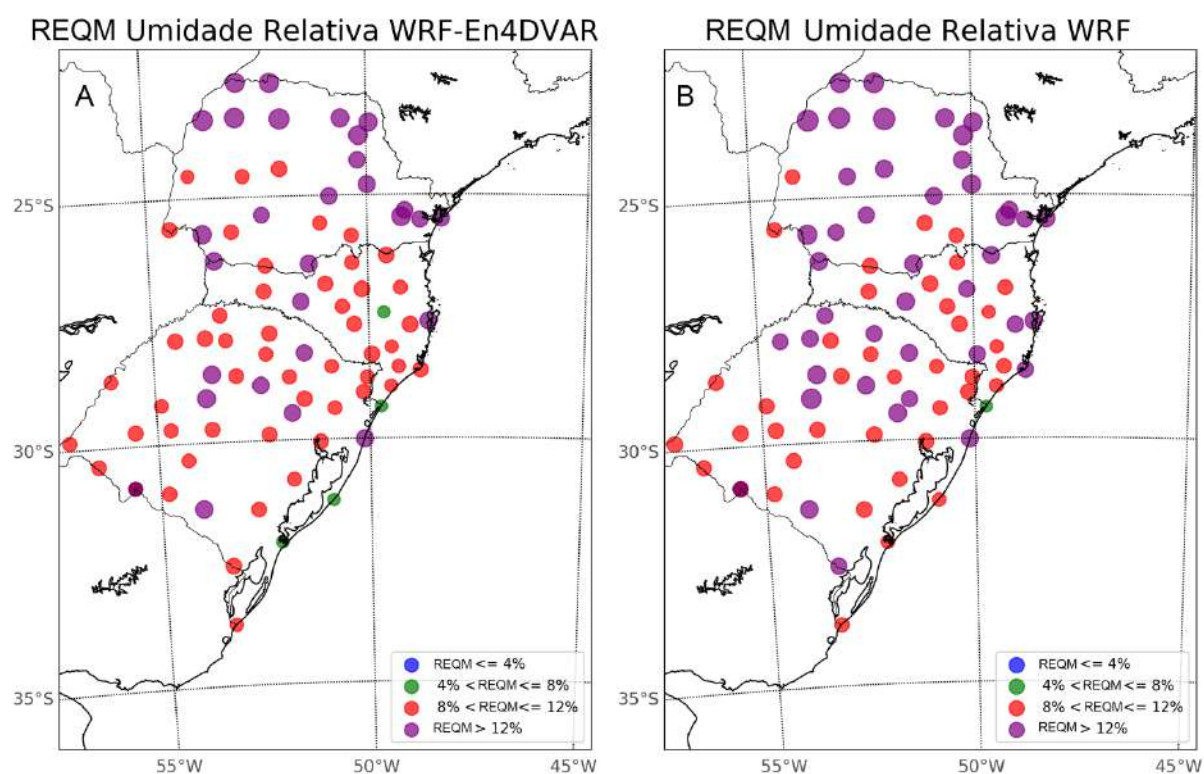


Figura 8 Raiz do Erro Quadrático Médio para Umidade Relativa do Ar à 2m (%). A. com; B. sem assimilação.



A Umidade Relativa do Ar à 2m, importante para o cálculo de precipitação, tem baixa previsibilidade, haja vista que a maior parte do domínio apresenta erros superiores a 8%. Todavia, o procedimento de assimilação de dados, reduz o EMQ no leste de RS e SC e centro do PR.

O Campo de Vento à 2m, Figura 9, sofre influência da rugosidade da superfície e por consequência, parametrizações da camada limite planetária. Esta variável é especialmente importante

para inicialização de modelos de previsão de ondas oceânicas e modelos de estimativa de geração de energia elétrica. Os resultados mostram, que o padrão de diminuição dos erros na previsão do WRF-En4DVAR em relação à previsão do WRF, se repete nesta variável, ou seja, leste e norte do RS, leste de SC e centro do PR tem mais pontos com erros entre 2 e 3  $\text{ms}^{-1}$  e menos pontos com erros superiores a 3  $\text{ms}^{-1}$ .




Figura 9 Raiz do Erro Quadrático Médio para Vento à 2m ( $\text{ms}^{-1}$ ). A. com; B. sem assimilação.

#### 4 Considerações Finais

Avaliou-se WRF-En4DVAR tendo-se como verdade terrestre os dados das estações automáticas do INMET e como referência o WRF. Este método híbrido de assimilação de dados, tem a vantagem de fazer a atualização da matriz de covariância dos erros de previsão sem a necessidade do cálculo do modelo adjunto e tangente linear, como o método 4DVAR. Portanto, a técnica tem custo computacional inferior a outros métodos quadridimensionais, como o 4DVAR. Sua implementação no modelo WRF, referenciada neste texto como WRF-En4DVAR, resultou em previsões com menor EMQ em comparação com o WRF sem assimilação e tendência em suavizar os extremos de erros. Mesmo nas variáveis com menor previsibilidade como vento,

os erros são reduzidos em até 20%. Em variáveis como temperatura e umidade, os ciclos diurnos são reproduzidos com ganho significativo de precisão. Portanto, En4DVAR tem baixo custo computacional e é fisicamente preciso, em comparação com as metodologias que representam o estado da arte em termos de assimilação de dados.

#### 5 Referências

- Anderson, J. 2001. An Ensemble Adjustment Filter for Data Assimilation. *Monthly Weather Review*, 129: 2884-2903.
- Bishop, C.; Etherton, B. & Majumdar, S. 2001. Adaptive Sampling with the Ensemble Transform Kalman Filter part I: The Theoretical Aspects. *Monthly Weather Review*, 129: 420-436.
- Buehner, M. 2005: Ensemble-derived Stationary and Flow-de-

- pendent Background Error Covariance: Evolution in a Quasi-operation NWP Setting. *Quarterly Journal Royal of the Meteorological Society*, 131: 1013-1043.
- Burgers, G.; Leeuwen, P.J.V. & Evensen, G. 1998. Analysis Scheme in the Ensemble Kalman Filter. *Monthly Weather Review*, 126: 1719-1724.
- Courtier, P. & Talagrand, O. 1998. Variational Assimilation of Meteorological Observation with the Adjoint Vorticity Equation. Part II: Numerical Results. *Quarterly Journal Royal of the Meteorological Society*, 113: 1329-1347.
- Evensen, G. 1994. Sequential Data Assimilation with a Nonlinear Quasi-geostrophic Model using Monte Carlo Methods to Forecast Errors Statistics. *Journal of Geophysical Research*, 99(5): 143-162.
- Huang, X.-Y. & Yang, X. 1996. *Variational Data Assimilation with Lorenz Model*. Hirlam Technical Report, 26, S-601 76 SMHI Norrköping, Sweden.
- Kalnay, E. 2003. *Atmospheric Modeling, Data Assimilation and Predictability*. Cambridge. Cambridge University Press. 369 p.
- Li, Z. & Navon, I.M. 2001: Optimality of Variational Data Assimilation and its Relationship with the Kalman Filter and Smoother. *Quarterly Journal Royal of the Meteorological Society*, 127: 661-683.
- Liu, C.; Xiao, Q. & Wang, B. 2008. An Ensemble-Based Four-Dimensional Variational Data Assimilation Scheme. Part I: Technical Formulation and Preliminary Test. *Monthly Weather Review*, 136: 3363-3373.
- Liu, C.; Xiao, Q. & Wang, B. 2009. An Ensemble-Based Four-Dimensional Variational Data Assimilation Scheme. Part II: Observing System Simulation Experiments with Advanced Research WRF (ARW). *Monthly Weather Review*, 137: 1687-1704.
- Ott, E.; Hunt, B.; Szunyogh, I.; Zimin, A.; Kostelich, E.; Corazza, M.; Kalnay, E.; Patil, D. & Yorke, J. 2004. A Local Ensemble Kalman Filter for Atmospheric Data Assimilation. *Tellus*, 56A: 415-428.
- Parrish, D. & Derber, J. 1992. The National Meteorological Center's Spectral Statistical-Interpolation Analysis System. *Monthly Weather Review*, 120: 1747-1763.
- Rabier, F. & Courtier, P. 1992. Four-Dimensional Assimilation in the Presence of Baroclinic Instability. *Quarterly Journal Royal of the Meteorological Society*, 118: 649-672.