

Avaliação de Agregação Temporal na Previsão da Temperatura de Superfície do Mar do Oceano Atlântico

Rebecca Salles, Patricia Mattos, Eduardo Bezerra,
Leonardo Lima, Eduardo Ogasawara

Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ)
Rio de Janeiro, RJ – Brasil

rebeccapsalles@acm.org, {ebezerra, leolima}@cefet-rj.br, eogasawara@ieee.org

Abstract. *Extreme environmental events such as droughts affect millions of people all around the world. Its prediction enables the mitigation of eventual damages caused by its occurrence. An important variable for identifying occurrences of droughts is the Sea Surface Temperature (SST). In the Tropical Atlantic Ocean, SST data are collected and provided by the PIRATA Project, which is an observation network composed of sensor buoys arranged in this region. Sensors of this type, such as Internet of Things (IoT) sensors, commonly fails, leading to data losses that influence the quality of datasets collected for adjusting prediction models. In this paper, we explore the influence of temporal aggregation in predicting step-ahead SST considering different prediction horizons and different sizes for training datasets. Our results point out scenarios for training datasets and prediction horizons indicating whether or not temporal aggregated SST time series may be beneficial for prediction.*

Resumo. *Eventos ambientais extremos como secas afetam milhões de pessoas em todo o mundo. A sua previsão permite a mitigação de eventuais danos causados por sua ocorrência. Uma variável importante para a identificação de ocorrências de secas é a Temperatura da Superfície do Mar (TSM). No Oceano Atlântico Tropical, dados de TSM são coletados e fornecidos pelo projeto PIRATA, que é uma rede de observação composta por boias com sensores dispostas nesta região. Sensores deste tipo, assim como sensores relacionados a Internet das Coisas (IoT), comumente falham, levando a perda de dados que influencia a qualidade dos conjuntos de dados coletados para o ajustamento de modelos de previsão. Neste contexto, esta pesquisa explora a influência da agregação temporal na previsão de horizontes à frente de TSM considerando diferentes horizontes de previsão e diferentes tamanhos dos conjuntos de dados de treino. Os resultados obtidos apontam cenários para conjuntos de treino e horizontes de previsão indicando se séries temporais agregadas de TSM podem ser vantajosas para a previsão.*

1. Introdução

Há evidências na literatura que apontam para o relacionamento entre as temperaturas da superfície do mar do oceano Atlântico sudoeste tropical (TSM) e a ocorrência de eventos climáticos extremos no nordeste do Brasil [Cho et al. 2010]. Entre tais eventos, as secas são muito relevantes por causa do seu impacto econômico. As causas para as secas severas

foram estudadas por um longo tempo e atualmente entende-se que os principais fatores que contribuem para a sua ocorrência estão relacionados a TSM, incluindo a oscilação sul do El Niño (OSEN) e a Zona de Convergência Intertropical (ZCIT) [Durand et al. 2005]. É estimado que 32.8 milhões de pessoas foram afetadas pela seca nos últimos trinta anos, o que levou a uma perda de aproximadamente R\$2.4 bilhões para o país [EM-DAT 2016].

A pesquisa tem por objetivo contribuir para o monitoramento das séries temporais da TSM do Atlântico Sul e a construção de um modelo de maior precisão de sua evolução com o intuito de colaborar para a redução, na medida do possível, da vulnerabilidade da sociedade diante de eventos extremos. Embora haja muitos trabalhos que focam o estudo e previsão de curto prazo da TSM [Hertig e Jacobeit 2010], o objetivo desta pesquisa é analisar as vantagens de diferentes técnicas para a previsão de TSM com diferentes horizontes de previsão e diferentes tamanhos do conjunto de dados de treinamento, que se torna particularmente importante quando dados são coletados por sensores (sensores de IoT) onde dados faltantes podem interferir nos tamanhos dos conjuntos de dados de treino [Perera et al. 2014].

Nesta pesquisa, especial atenção é atribuída às chamadas técnicas de pré-processamento de dados, principalmente a agregação temporal. Apesar dos efeitos da agregação temporal na previsão de séries temporais serem extensivamente abordados na literatura [Tiao 1972, Wei 2005], as pesquisas mostraram que as vantagens da agregação temporal estão fortemente ligadas às propriedades estatísticas das séries temporais básicas (não-agregadas) disponíveis, como estacionariedade, autocorrelação e sazonalidade. Entretanto, análises estatísticas demonstraram considerável diversidade em tais propriedades nas séries temporais de TSM, cenário que impossibilita o uso direto de conhecimento prévio quanto a influência da agregação temporal.

Os efeitos das agregações temporais foram avaliados utilizando-se os modelos lineares: Modelos Autorregressivos Integrados de Médias Móveis (ARIMA) [Gujarati 2002] e o modelo *Random Walk*, utilizado como base de referência para se analisar os resultados experimentais obtidos. Ambos ARIMA e *Random Walk* são modelos estatísticos interpretáveis e bem-estabelecidos. Conjuntos de dados contendo séries temporais diárias de TSM obtidas *online* a partir do sítio do projeto *Prediction and Research Moored Array in the Tropical Atlantic* (PIRATA) [GOOS-Brasil 2015] foram utilizados durante a avaliação experimental. Os resultados indicam que a previsão usando séries temporais de TSM agregadas leva a previsões mais precisas em horizontes de longo prazo de acordo com várias medidas de precisão. Além disso, os experimentos mostram que os benefícios da aplicação de agregação temporal são influenciados pelo horizonte de previsão e também pelo tamanho do conjunto de dados de treinamento.

Além desta introdução, esta pesquisa está organizada em mais seis seções. A Seção 2 apresenta uma contextualização da pesquisa. A Seção 3 apresenta uma base teórica de previsão de séries temporais e de agregação temporal. A Seção 4 apresenta a metodologia de previsão aplicada nesta pesquisa. A Seção 5 apresenta as configurações e resultados da avaliação experimental. Finalmente, a Seção 6 apresenta as conclusões.

2. Contexto da Pesquisa

Esta pesquisa teve como ponto de partida a dissertação de mestrado de Patrícia Mattos, formada pelo CEFET/RJ, que resultou na publicação de um artigo nos anais do congresso

IX *Brazilian e-Science Workshop* (BreSci) [Teixeira et al. 2015]. O trabalho apontava que a aplicação da agregação temporal deveria ser considerada na previsão de TSM. O trabalho se baseava em dados também do PIRATA, mas que haviam sido coletados de uma única boia. Por conta disso a análise foi feita com um número limitado de conjuntos de treinamento e avaliados em horizontes de previsão restritos. Esta pesquisa, entretanto, estende os resultados obtidos, visando avaliar as condições em que a agregação temporal traz benefícios para a previsão de TSM com diferentes horizontes de previsão e diferentes quantidades de dados disponíveis para treinamento, os quais foram coletados de várias boias em diferentes posições geográficas, apresentando propriedades estatísticas diversas e observando que nem sempre a agregação temporal é vantajosa. Tal avaliação gerou quase 99.000 resultados de previsão analisados comparativamente. Esta pesquisa produziu um artigo científico publicado no periódico *Ecological Informatics* [Salles et al. 2016], tendo a aluna Rebecca Salles como autora principal, sob orientação do professor Eduardo Ogasawara, e com colaboração de Patrícia Mattos, Ana-Maria Iorgulescu e dos professores Eduardo Bezerra e Leonardo Lima.

Além disso, foram realizados estudos complementares sobre o desempenho de modelos lineares para a previsão e imputação de séries temporais frente a métodos de aprendizado de máquina. Os estudos foram de auxílio na escolha dos métodos de previsão aplicados, assim como na análise da possibilidade de preenchimento de observações faltantes nas séries de TSM. Neste contexto, a aluna Rebecca Salles desenvolveu o pacote *TSPred* [Salles e Ogasawara 2015] de funções R para ajustamento otimizado e previsão de séries temporais com modelos lineares. Estes estudos culminaram na produção de 2 artigos científicos, publicados nos anais do XXX Simpósio Brasileiro de Banco de Dados (SBBD) [Salles et al. 2015], onde o trabalho foi apresentado por Rebecca Salles, e nos anais do *International Joint Conference on Neural Networks* (IJCNN) [Salles et al. 2017]. Ambos os artigos têm Rebecca Salles como autora principal.

3. Séries Temporais e a Agregação Temporal

3.1. Modelagem de Séries Temporais

Uma série temporal x_t é uma sequência $\langle x_1, x_2, x_3, \dots, x_n \rangle$ de observações de um fenômeno de interesse coletadas ao longo do tempo, tal que x_1 corresponde ao valor da primeira (mais antiga) observação, enquanto x_n é a última (mais recente) delas. O comprimento n de uma série temporal x_t é representado como $|x_t| = n$.

A maioria dos trabalhos com séries temporais assume a estacionariedade, em que propriedades estatísticas não mudam ao longo do tempo. Se essa restrição não for atendida, a série temporal é classificada como não-estacionária. Este é o caso para a maioria das séries temporais encontradas em aplicações reais [Gujarati 2002].

Um objetivo comum para se ajustar/treinar modelos matemáticos para que reflitam uma série temporal x_t é a obtenção de previsões precisas de valores futuros de x_t baseadas em dados coletados previamente [Shumway e Stoffer 2010]. Um dos métodos lineares mais importantes de previsão de séries temporais é a classe de modelos ARIMA [Gujarati 2002]. Modelos ARIMA(p, d, q) são derivados de uma composição dos processos de modelagem autorregressivo (AR) e de média móvel (MA) (respectivamente representados por p e q) com um processo de diferenciação preliminar adicional (I) (representado por d), desenvolvidos para lidar com não-estacionariedade [Gujarati 2002].

Em muitas situações, encontra-se séries temporais que parecem se comportar de forma aleatória ao longo do tempo. Neste caso, um modelo muito útil para se estimar tal série temporal é o *Random Walk* com desvio (*drift*), no qual o valor de uma série temporal x_t em um instante t é basicamente explicado pelo valor da série no instante $t - 1$ mais um movimento completamente aleatório. O modelo *Random Walk* pode também ser expressado como um modelo ARIMA(0, 1, 0), [Shumway e Stoffer 2010].

3.2. Agregação Temporal de Séries Temporais

Seja x_t uma série temporal cujas observações são coletadas em intervalos de tempo equidistantes, por exemplo, a TSM diária do Atlântico. Neste caso, é frequentemente interessante a previsão não das observações diárias subsequentes mas de um próximo período semanal ou mensal de temperaturas médias, que são agregações temporais dos dados diários [Tiao 1972]. Considerando x_t como uma entrada, uma série temporal agregada não-sobreposta de período m , X_T , é definida na Equação 1, onde X_T é a série temporal agregada e m corresponde às agregações de x_t de período m , *i.e.*, a ordem de agregação. Assim, no exemplo anterior, t representa a unidade de tempo de dia e se m é 7 ou 30, então X_T é respectivamente uma série temporal de médias aritméticas semanais ou mensais de x_t [Wei 2005].

$$X_T = \sum_{t=m(T-1)+1}^{mT} \frac{x_t}{m} = \frac{(1 + B + \dots + B^{m-1})x_{mT}}{m} \quad (1)$$

Se x_t é uma série temporal de frequência mais alta e X_T é a série agregada temporalmente (de frequência mais baixa), a previsão das próximas observações de X_T pode seguir duas diferentes abordagens: (i) agrega-se as previsões de x_t ou (ii) prevê-se diretamente com os dados de X_T .

4. Metodologia de Previsão de TSM

A metodologia aqui apresentada possibilita a avaliação da técnica de agregação temporal para a previsão de TSM do Oceano Atlântico. Assume-se a disponibilidade de várias instâncias de conjuntos de observações de séries temporais de treino e de teste de alta frequência (séries temporais diárias). Esta pesquisa se baseia na previsão de X_{T+j} ($j = 1, \dots, N$), para uma série temporal agregada correspondente (semanal e mensal), para permitir a previsão de ambos curto e longo prazo. Mais especificamente, pretende-se obter 52 e 12 passos a frente de séries temporais agregadas semanalmente e mensalmente, respectivamente, prevendo-se assim 12 meses (1 ano) a frente. Com este propósito, define-se $N = 365/m_w$ com $m_w = 7$ e $N = 365/m_m$ com $m_m = 30$, respectivamente para séries temporais agregadas semanais e mensais.

Daqui por diante adotam-se duas abordagens diferentes para a previsão das agregações temporais desejadas (semanais e mensais), referenciadas como *PrePred* e *PostPred*. Na Tabela 1 são descritos os parâmetros e notações da metodologia desta pesquisa. No Algoritmo *PrePred* e no Algoritmo *PostPred* os conceitos gerais de ambas abordagens são apresentadas.

Na primeira abordagem, *PrePred*, representada pelo Algoritmo *PrePred*, o parâmetro $k = 1$ indica que o modelo ARIMA será ativado e $k = 0$ indica que o *Random*

Tabela 1. Parâmetros e notações para a metodologia e avaliação experimental

Variável	Valores Padrão	Descrição
x_t	N/A	série temporal diária básica
\tilde{X}_T	N/A	série temporal agregada correspondente a x_t
x_{tr}	N/A	subconjunto de x_t usado para treinamento
x_{ts}	N/A	subconjunto de x_t usado para teste
m	7 ou 30	parâmetro de unidade de tempo para agregação temporal
m_i	7 ou 30	parâmetro de unidade de tempo para agregação temporal realizada antes da previsão
m_f	7 ou 30	parâmetro de unidade de tempo para agregação temporal realizada após a previsão
N	$ x_{ts} /m = 365/m$	número de observações agregadas de série temporal a serem previstas
r	$ x_{ts} = mN = 365$	número de observações básicas de série temporal a serem previstas
k	ARIMA ou <i>Random Walk</i>	modelo de série temporal a ser aplicado para previsão
<i>PrePred</i>	$\text{PrePred}(x_{tr}, x_{ts}, r, m, k)$	previsão de agregações futuras baseada em dados diários básicos
<i>PostPredW</i>	$\text{PostPred}(x_{tr}, x_{ts}, r, 7, m, \text{ARIMA})$	previsão de agregações futuras baseada em dados semanais agregados
<i>PostPredM</i>	$\text{PostPred}(x_{tr}, x_{ts}, r, 30, 30, \text{ARIMA})$	previsão de agregações futuras baseada em dados mensais agregados

Walk será usado. O modelo é então usado para gerar r previsões diárias com base em x_{tr} , que são representadas por p no passo 2 do Algoritmo *PrePred*. A partir destas previsões, a previsão para as agregações futuras desejadas são geradas analogamente à Equação 1, e são representadas por pa . Aqui a notação a significa *agregada*.

A segunda abordagem, *PostPred*, é representada pelo Algoritmo *PostPred*. No passo 2, aplica-se a Equação 1 a x_{tr} com $m = m_i$ para construir a série agregada representada por $x_{tr}a$. Então constrói-se um modelo para $x_{tr}a$, que é usado para gerar as previsões desejadas, representadas como p . Vale a pena mencionar que o passo 5 do Algoritmo *PostPred* é incluído para considerar o caso em que haja interesse em se prever agregações futuras baseadas em dados previamente agregados (previsão de dados mensais a partir de dados semanais). No caso de $m_i = m_f, pa = p$.

Prepara-se o conjunto de teste agregado $x_{ts}a$ aplicando-se a Equação 1 a x_{ts} com m ou $m = m_f$. Em seguida, os erros das previsões geradas pa são computados nos passos 5 e 7 dos Algoritmos *PrePred* e *PostPred*, respectivamente. Tais previsões são comparadas às N observações de teste agregadas em $x_{ts}a$. Os erros de previsão calculados são então analisados estatisticamente para avaliação da eficiência de cada abordagem, usando o teste t ou o teste Wilcoxon, dependendo da normalidade da distribuição dos erros.

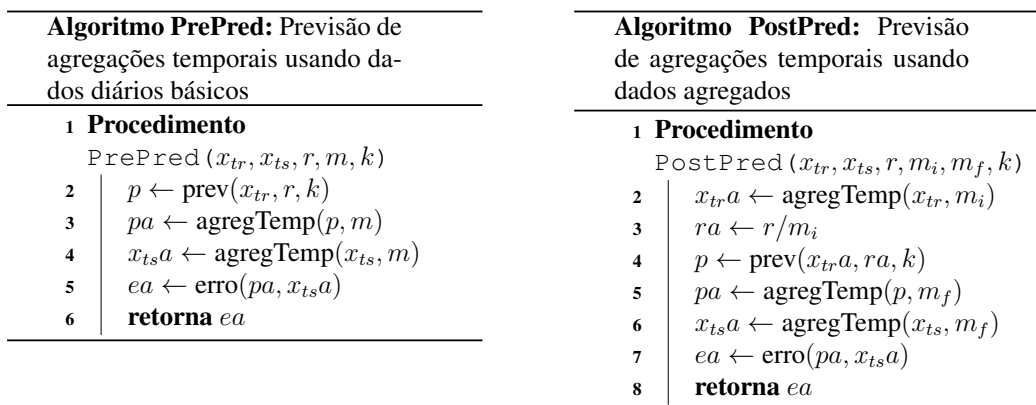


Figura 1. Algoritmos das abordagens adotadas para a previsão de agregações temporais

Os Algoritmos PrePred e PostPred foram implementados utilizando-se a linguagem e ambiente para computação estatística e ciência de dados R. Particularmente, foi desenvolvido um pacote de funções R chamado *TSPred* [Salles e Ogasawara 2015] para automatizar o treinamento e previsão de séries temporais com modelos lineares, entre eles, os modelos ARIMA. Estas funções selecionam um modelo ARIMA otimizado, enquanto também consideram sazonalidade.

5. Avaliação Experimental

Diversos experimentos foram realizados utilizando-se séries temporais diárias coletadas pelo projeto PIRATA. Este projeto corresponde a uma rede de observação composta por 21 boias distribuídas pelo oceano Atlântico tropical, e foi planejada para monitorar uma série de variáveis oceano-atmosféricas [GOOS-Brasil 2015]. Uma das variáveis observadas é a TSM, medida entre 1 metro e 1,5 metro de profundidade, cujos dados são utilizados nos experimentos desta pesquisa. As observações diárias de TSM são constantemente atualizadas e estão publicamente disponíveis [GOOS-Brasil 2015]. O intervalo geral dos dados de medições de TSM disponíveis até a realização desta pesquisa compreende o período de janeiro de 1998 até março de 2015.

No conjunto de dados disponível pelo PIRATA, nenhuma das boias produziu registros completos. Devido às dificuldades resultantes da ausência de dados [Salles et al. 2015], o primeiro passo experimental desta pesquisa foi a seleção de dados para gerar um conjunto de dados que maximize a quantidade de observações ininterruptas. Para este propósito, foi considerado uma interrupção de dados quando ocorria uma ausência de dados consecutivos correspondentes a um mês de medição. Além disso, foram selecionados apenas períodos com pelo menos dois anos de observações ininterruptas, o que permite a formação de um conjunto de dados de treino com no mínimo um ano de observações utilizado para a previsão de um ano à frente. Seguindo este critério, ao todo foram selecionadas 17 boias que contribuíram para a soma de 50.000 observações de TSM selecionadas para análise.


As séries temporais de TSM selecionadas foram sujeitas a análises estatísticas nas quais foram executados oito dos testes mais adotados para autocorrelação, aleatoriedade e independência, heterocedasticidade, linearidade e estacionariedade. Um resumo dos resultados dos experimentos estatísticos é apresentado na Tabela 2, onde se pode observar a porcentagem dos resultados dos testes que confirmam a hipótese nula de cada teste (H_0).

Cada série temporal de dados de TSM selecionada foi particionada em conjuntos de treino e conjuntos de teste para a aplicação da metodologia experimental desta pesquisa. A fim de se promover uma melhor discussão sobre o efeito do número de observações dos conjuntos de treino nas tarefas de construção de modelos (x_{tr}) e previsão (x_{ts}), foi aplicado o processo exemplificado pela Figura 2 que apresenta o particionamento de séries temporais selecionadas da bóia *OnOe*. O número de observações nos conjuntos de teste permanece fixo e equivalente ao número de previsões de um ano à frente, enquanto que o tamanho dos conjuntos de treino crescem gradualmente para $|x_t| - |x_{ts}| = |x_t| - n$ observações.

Durante os experimentos, foram computados doze valores de erro de previsão para cada horizonte de previsões agregadas. Estes erros são cumulativamente produzidos

Tabela 2. Resultados e análise dos testes estatísticos

Testes Estatísticos	Hipótese Nula (H0)	Análise
Durbin-Watson	Resíduos não-correlacionados	0%
Breusch-Godfrey		0%
Box-Pierce	Aleatoriedade	0%
Goldfeld-Quandt	Homoscedasticidade	68%
White Neural Network	Linearidade na média	60%
<i>Augmented Dickey-Fuller</i> (ADF)	Não-estacionariedade	44%
<i>Kwiatkowski-Phillips-Schmidt-Shin</i> (KPSS)	Estacionariedade de tendência	64%
KPSS	Estacionariedade de nível	56%

**Figura 2. Exemplo de particionamento de dados para as séries temporais da boia 0n0e**

através do aumento do número de passos à frente sob análise. Quatro medidas de erro diferentes foram adotadas para análise, incluindo MSE [Shumway e Stoffer 2010], NMSE, MAPE e SMAPE [Chen e Yang 2004].

5.1. Discussão de Resultados

Nos experimentos realizados foram calculados 24.720 erros de previsão para cada uma das quatro medidas de erro adotadas. Todos estes resultados foram estatisticamente analisados, o que permitiu a comparação do comportamento de *PrePred* e *PostPred*. Além disso, foi possível observar como o desempenho de previsão foi afetado pela agregação temporal com diferentes horizontes à frente e tamanhos de conjuntos de treino.

A metodologia de particionamento de dados aplicada nesta pesquisa resultou em conjuntos de treino contendo entre um e onze anos de observações. Contudo, com o intuito de evitar conclusões tendenciosas, foram escolhidos para discussão somente os erros provenientes de previsões baseadas em conjuntos de treino com seis anos de observações ou menos, já que se sabe que eles se originam de pelo menos oito boias diferentes. Além disso, notou-se que não existia diferença estatística entre os erros de previsão computados em medidas de acurácia diferentes, por isso a análise foi limitada a apresentar o Erro Médio Quadrático (MSE). Uma visão mais geral do processo experimental aplicado nesta pesquisa para a geração dos dados de erro de previsão analisados e discutidos nesta seção pode ser mais facilmente obtida pela análise da Figura 3.

O modelo *Random Walk* usado na abordagem *PrePred* foi adotado como base de referência. Com isso, foi estudada a validade do uso dos modelos ARIMA através da sua comparação com esta base. A Figura 4 apresenta gráficos com o número relativo de vezes em que cada abordagem de previsão aplicada (*PrePred* e *PostPred*) teve um melhor desempenho estatisticamente significativo quando comparada à base de referência *Random Walk*. A Figura 4(a) refere-se aos erros de previsão para a previsão de 12 semanas


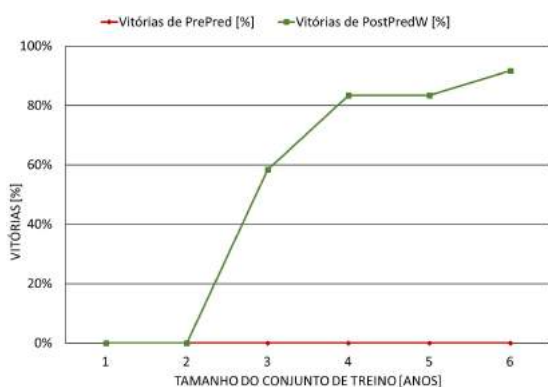
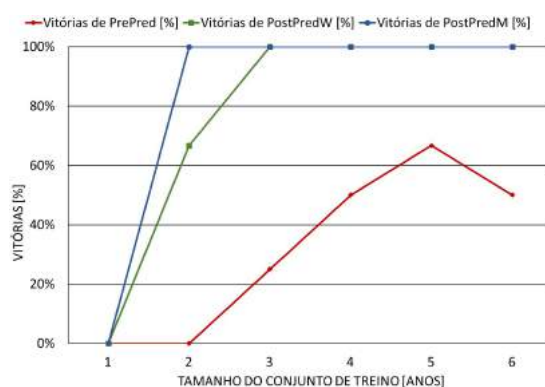


Figura 3. Visão geral do processo experimental aplicado para a geração dos dados de erro de previsão analisados

à frente, enquanto a Figura 4(b) refere-se aos erros de previsão para a previsão de 12 meses à frente. Os resultados estão agrupados de acordo com o tamanho (em anos) dos conjuntos de treino modelados.



(a) Comparação do ARIMA (*PrePred* e *PostPredW*) contra o *Random Walk* para 12 agregações semanais




(b) Comparação do ARIMA (*PrePred*, *PostPredW* e *PostPredM*) contra o *Random Walk* para 12 agregações mensais

Figura 4. Número relativo de vezes em que cada abordagem de previsão aplicada teve um melhor desempenho estatisticamente significativo quando comparada à base de referência *Random Walk*

Foi feito um estudo comparativo dos erros de previsão produzidos pelos experimentos desta pesquisa usando o modelo ARIMA. Para melhor compreensão, define-se *vitória* como o número de vezes em que uma abordagem em particular apresentou um melhor desempenho, *i.e.*, menores erros de previsão em comparação a outras abordagens. A Figura 5(a) mostra um gráfico com as vitórias das abordagens de previsão aplicadas, *PrePred* e *PostPred*, de acordo com o tamanho em anos do conjunto de treino modelado. Um gráfico análogo, na Figura 5(b), apresenta as vitórias de *PrePred*, *PostPredW*, e *PostPredM* de acordo com o tamanho em anos dos conjuntos de treino modelados.

Embora na revisão da literatura tenha sido observado que *PrePred* é a abordagem mais adotada durante previsões de TSM, as análises experimentais apontaram que esta foi geralmente superada pelo *Random Walk* em previsões semanais e mensais. Tal comportamento não ocorreu quando *PostPred* foi usado. Quando o tamanho do conjunto de



(a) Desempenho na geração de até doze previsões agregadas semanais

(b) Desempenho na geração de até doze previsões agregadas mensais

Figura 5. Gráficos das vitórias de cada abordagem de previsão com relação aos seus desempenhos na geração de previsões agregadas

treinamento foi maior que dois anos, *PostPred* superou o *Random Walk*. Ademais, foram feitos testes estatísticos sob diferentes horizontes de previsão entre *PrePred* e *PostPred* e na maioria dos casos, *PostPred* foi significativamente melhor que *PrePred*. *PrePred* foi competitivo apenas quando ambos o horizonte de previsão e o tamanho do conjunto de treinamento eram pequenos.

6. Conclusões

A previsão de longo prazo da TSM no Oceano Atlântico Tropical é extremamente relevante como uma forma de auxiliar as agências governamentais e sociedade a prepararem-se para a ocorrência futura de eventos extremos, como as secas. Assim, melhorar a previsão da TSM em diferentes horizontes é uma questão primordial. Esta pesquisa avalia o uso da agregação temporal e suas consequências em diferentes horizontes de previsão de TSM. Além dos dados diários da TSM obtidos do projeto PIRATA, foram modeladas e avaliadas séries temporais semanais e mensais derivadas para analisar o impacto da agregação temporal na previsão de futuras observações agregadas de TSM. Esta pesquisa também explora diferentes tamanhos de conjuntos de dados de treino.

Os resultados apontaram para a importância da aplicação da agregação temporal para fornecer previsões de longo prazo para a TSM. Além disso, esta pesquisa destaca a influência dos horizontes de previsão e do tamanho dos conjuntos de dados de treinamento sobre os possíveis benefícios da aplicação de agregação temporal para a previsão da TSM, especialmente quando existe significativa diversidade nas características estatísticas das séries temporais disponíveis. Não apenas os resultados desta pesquisa podem ser usados como critério para o planejamento de experimentos de previsão de TSM, mas também esta metodologia pode servir como base para estudos futuros sobre o valor prático de diferentes estratégias de agregação temporal para a previsão de diferentes conjuntos de dados de TSM de diferentes tamanhos.

Referências

Chen, Z. e Yang, Y. (2004). Assessing forecast accuracy measures. *Preprint Series*, (2004-2010):2004–10.

- Cho, J., Yeh, P. J. F., Lee, Y.-W., Kim, H., Oki, T., Kanae, S., Kim, W., e Otsuki, K. (2010). A study on the relationship between Atlantic sea surface temperature and Amazonian greenness. *Ecological Informatics*, 5(5):367–378.
- Durand, B., Servain, J., Laurent, H., e Machado, L. A. T. (2005). Tropical Atlantic Moisture Flux, Convection over Northeastern Brazil, and Pertinence of the PIRATA Network*. *Journal of Climate*, 18(12):2093–2101.
- EM-DAT (2016). The international disasters database.
- GOOS-Brasil (2015). PIRATA Dataset. Technical report, <http://www.goosbrasil.org>.
- Gujarati, D. (2002). *Basic Econometrics*. McGraw-Hill/Irwin, Boston; Montreal, 4 edition edition.
- Hertig, E. e Jacobeit, J. (2010). Predictability of Mediterranean climate variables from oceanic variability. Part II: Statistical models for monthly precipitation and temperature in the Mediterranean area. *Climate Dynamics*, 36(5-6):825–843.
- Perera, C., Liu, C. H., Jayawardena, S., e Chen, M. (2014). A survey on internet of things from industrial market perspective. *IEEE Access*, 2:1660–1679.
- Salles, R., Assis, L., Guedes, G., Bezerra, E., Porto, F., e Ogasawara, E. (2017). A framework for benchmarking machine learning methods using linear models for univariate time series prediction. In *The 2017 International Joint Conference on Neural Networks (IJCNN)*, pages 1–8.
- Salles, R., Bezerra, E., Soares, J., e Ogasawara, E. (2015). Evaluating Linear Models as a Baseline for Time Series Imputation. In *XXX Simpósio Brasileiro de Banco de Dados*, Petrópolis, RJ.
- Salles, R., Mattos, P., Iorgulescu, A.-M. D., Bezerra, E., Lima, L., e Ogasawara, E. (2016). Evaluating temporal aggregation for predicting the sea surface temperature of the Atlantic Ocean. *Ecological Informatics*, 36:94–105.
- Salles, R. P. e Ogasawara, E. (2015). TSPred: Functions for Baseline-Based Time Series Prediction. Technical report, <http://cran.r-project.org/web/packages/TSPred/index.html>.
- Shumway, R. H. e Stoffer, D. S. (2010). *Time Series Analysis and Its Applications: With R Examples*. Springer, New York, 3rd ed. 2011 edition edition.
- Teixeira, P. M., Dubois-Iorgulescu, A.-M., Salles, R., Bezerra, E., Ogasawara, E., e Lima, L. S. d. (2015). Uso de Redes Neurais para Previsão da Temperatura da Superfície do Mar do Oceano Atlântico Tropical. In *IX Brazilian e-Science Workshop*, Recife, PE.
- Tiao, G. C. (1972). Asymptotic behaviour of temporal aggregates of time series. *Biometrika*, 59(3):525–531.
- Wei, W. W. S. (2005). *Time Series Analysis : Univariate and Multivariate Methods*. Pearson, Boston, 2 edition edition.