

# ESTUDO DA PREDIÇÃO DE VELOCIDADE DOS VENTOS EM UM PARQUE EÓLICO NO LITORAL CEARENSE

RONALD ANDERSON GOMES DE CASTRO\*, JOSÉ DANIEL DE ALENCAR SANTOS\*, RAMIRO FRANCISCO BEZERRA DOS SANTOS†

\**Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE  
Campus Maracanaú  
Ceará, Brasil*

†*Instituto Federal de Educação, Ciência e Tecnologia do Ceará - IFCE  
Campus Fortaleza  
Ceará, Brasil*

Emails: roonald.anderson017@gmail.com, jdaniel@ifce.edu.br, ramirofb@gmail.com

**Abstract**— Satisfactory estimates of wind speed prediction are essential for the design and operation of a wind farm. In order to improve these estimates, it is necessary to carefully analyze aspects such as geographical location of the wind farm, as well as the behavior and seasonality of the winds, since significant oscillations in its speed can generate large losses in energy production, increasing operating costs. In this context, the present paper presents a comparative study of the application of linear (based on least squares) and nonlinear (based on kernel methods) estimators to solve a real problem of time series prediction, namely, the prediction of wind speed in a wind farm located in the state of Ceará. It is worth highlighting that this is the first time that the dynamic behavior of this dataset was investigated in the paradigm of time series prediction. The obtained results from computer simulations point to a linear behavior of this dataset, since the OLS and KRLS<sub>L</sub> (with linear kernel function) models have achieved the best performances among the tested estimators, in all the evaluated predicted scenarios.

**Keywords**— Wind Farm, Wind Speed, Time Series Prediction, Linear Estimators, Nonlinear Estimators.

**Resumo**— Estimativas satisfatórias na predição da velocidade dos ventos são essenciais para o projeto e funcionamento de um parque eólico. Como forma de melhorar essas estimativas, faz-se necessário analisar cuidadosamente aspectos como a localização geográfica do parque eólico, bem como o comportamento e sazonalidade dos ventos, uma vez que oscilações significativas em sua velocidade podem gerar grandes perdas na produção de energia, aumentando os custos de operação. Nesse contexto, o presente artigo apresenta um estudo comparativo da aplicação de estimadores lineares (baseados em mínimos quadrados) e não lineares (baseados em métodos de *kernel*) para resolver um problema real de predição de séries temporais, no caso, a predição da velocidade dos ventos em um parque eólico localizado no estado do Ceará. É importante ressaltar que essa é a primeira vez que o comportamento dinâmico da referida base de dados foi investigada no paradigma de predição de séries temporais. Os resultados obtidos a partir de simulações computacionais apontam para um comportamento linear dos dados, uma vez que os modelos OLS e KRLS<sub>L</sub> (com função de kernel linear) obtiveram os melhores desempenhos entre os estimadores testados, em todos os cenários de predição avaliados.

**Palavras-chave**— Parque Eólico, Velocidade do Vento, Predição de Séries Temporais, Estimadores Lineares, Estimadores Não Lineares.

## 1 Introdução

Ao longo das últimas décadas, as fontes renováveis de energia têm ocupado lugar de destaque entre as melhores alternativas para geração sustentável de eletricidade. Dentre elas, a energia eólica é a que se expande mais rapidamente em relação às demais (Zolfaghari et al., 2015), pois além de ser uma fonte de energia consideravelmente “limpa”, não exige a utilização de combustíveis fósseis. Dessa forma, os impactos naturais em consequência da poluição ambiental podem ser significativamente reduzidos.

No cenário brasileiro, o avanço no desenvolvimento e implantação de parques eólicos tem sido bastante promissor, tendo em vista que o Brasil lidera a produção de energia elétrica a partir dos ventos na América Latina e está entre os dez países no mundo com maiores capacidades instaladas (GWEC 2016). Especificamente na Região Nor-

deste, caracterizada por condições relativamente regulares na disponibilidade dos ventos, estados como Ceará, Bahia e Rio Grande do Norte têm perspectivas de crescimento significativas para as próximas décadas (de Jong et al., 2016).

Entretanto, apesar da incontestável atratividade, estimar recursos eólicos para produção de energia elétrica é ainda uma tarefa bastante desafiadora. O aspecto sazonal e intermitente dos ventos fornece uma natureza probabilística a esses recursos, o que naturalmente dificulta o planejamento, controle e operacionalidade de parques eólicos (Cheng et al., 2012). Além disso, ao se utilizar modelos autorregressivos para descrever o comportamento dinâmico dos ventos, as chances de se obter predições satisfatórias normalmente diminuem à medida em que se aumenta o horizonte de predição (Menezes-Júnior, 2012).

De uma forma geral, a velocidade média do vento e a curva de potência de um aerogerador

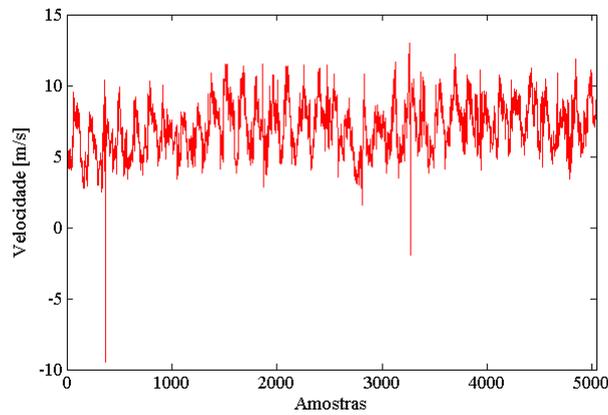


Figura 1: Série temporal das medições de velocidade do vento.

são as variáveis mais importantes e com maior impacto no projeto de instalação de parques eólicos (Afanasyeva et al., 2016; Rolik, 2017). Adicionalmente, a modelagem do comportamento do vento deve ser o primeiro passo na determinação da potência de um parque eólico (Zolfaghari et al., 2015), a qual pode ser realizada supondo, por exemplo, o comportamento do vento de acordo com distribuições de probabilidades (Conradsen et al., 1984) ou, mais recentemente, com a previsão de séries temporais aplicando modelos de aprendizagem de máquinas e inteligência artificial (Lei et al., 2009; Lahouar and Slama, 2017; Santamaría-Bonfil et al., 2016; Doucoure et al., 2016).

Diante do exposto, o presente artigo apresenta um estudo comparativo, através de experimentos computacionais, da aplicação de estimadores lineares (variantes do estimador mínimos quadrados) e não lineares (baseados em métodos de *kernel*) a um problema real de previsão dos ventos, em um parque eólico instalado no estado do Ceará. É importante destacar que essa foi a primeira vez que o comportamento dinâmico da referida base de dados foi investigada no paradigma de previsão de séries temporais.

A motivação para o estudo proposto é desenvolver técnicas para viabilizar, a partir das medições de velocidade dos ventos e de suas previsões satisfatórias a médio e longo prazo, por exemplo, o agendamento de atividades de parada para manutenção nos equipamentos, bem como a instalação de novos parques eólicos. Além disso, a utilização de estimadores de complexidade relativamente reduzida, tais como os supracitados, pode facilitar a sua aplicação em sistemas embarcados para previsão em tempo real.

O restante do artigo está organizado conforme a seguir. A Seção 2 apresenta a base de dados utilizada para a previsão dos ventos. Na Seção 3, são comentados resumidamente os estimadores lineares e não lineares testados. A Seção 4 apresenta e discute os resultados obtidos com simulações com-

putacionais. Por fim, o artigo é concluído na Seção 5.

## 2 Base de Dados

A base de dados utilizada no presente artigo, disponibilizada por Gomes (2017), foi gerada originalmente a partir de medições da velocidade do vento por sensores anemômetros instalados em um aerogerador do tipo VSWT (*Variable Speed Wind Turbine*). O referido aerogerador encontra-se instalado em um parque eólico no litoral do estado do Ceará, em que algumas de suas especificações técnicas são mostradas na Tabela 1.

Características do Aerogerador	
Potência Nominal	1500kW
Velocidade mínima do vento	3m/s
Velocidade nominal do vento	12m/s
Velocidade máxima do vento	22m/s
Faixa de velocidade angular	9 - 17,3rpm

Tabela 1: Especificações técnicas do aerogerador.

O conjunto de dados é composto por um total de 56838 registros da velocidade do vento, medidos ao longo do período entre 00h00 do dia 25/05/2014 e 23h50 do dia 27/07/2015, em que cada amostra equivale a velocidade média do vento durante um intervalo de tempo de 10 minutos. Adicionalmente, também foram feitos registros da disponibilidade diária do aerogerador nesse período (Gomes, 2017).

Uma vez que cada registro de velocidade é uma média dos valores ao longo de 10 minutos, variações instantâneas que eventualmente possam ocorrer (devido a turbulências, por exemplo) têm os seus efeitos reduzidos nos registros de medição e, portanto, não causam variações significativas nas leituras de velocidade (Jervell, 2008). Dessa forma, as medições que realmente estiverem muito acima ou muito abaixo daquelas consideradas “normais” podem ser tratadas como erros

de medição. Assim, Gomes (2017) submeteu a base de dados a uma etapa de pré-processamento, em que foi realizada uma filtragem no intuito de desconsiderar as amostras de velocidade que correspondem a um regime de operação classificado como fora do normal.

Por fim, após o processo de filtragem, foi selecionado um total de 5040 amostras, equivalente a 35 dias de operação, em que cada amostra corresponde à velocidade média do vento que incide sobre o aerogerador em intervalos de 10 minutos. A Figura 1 ilustra a série temporal que corresponde à base de dados utilizada no presente trabalho.

### 3 Estimadores Lineares e Não Lineares

A fim de avaliar o desempenho de estimadores lineares e não lineares na predição da velocidade do vento no litoral do Ceará, foram realizados experimentos computacionais com o conjunto de dados tratado, aplicando o estimador linear clássico OLS (*Ordinary Least Squares*) e três de suas variantes, a saber, os algoritmos ELS (*Extended Least Squares*) (Aguirre, 2007), LMS (*Least Mean Square*) (Widrow and Hoff, 1960) e RLS (*Recursive Least Squares*) (Haykin, 2013), além dos estimadores que são considerados versões *kernelizadas* (e não lineares) desses dois últimos, chamados KLMS (*Kernel Least Mean Square*) (Liu et al., 2008) e KRLS (*Kernel Recursive Least Squares*) (Engel et al., 2004), respectivamente.

A ideia básica dos métodos de *kernel* é que eles constroem um modelo linear no chamado espaço de atributos, onde os padrões de entrada são transformados por meio de um mapeamento não linear  $\phi$  de alta dimensionalidade (podendo ser infinita). Assim, o problema pode ser resolvido usando-se uma função apropriada de *kernel*  $k(\cdot, \cdot)$  (Schölkopf and Smola, 2002), sem a necessidade de se calcular explicitamente o mapeamento  $\phi$ .

Entre os estimadores baseados em *kernel* utilizados, o KRLS possui a característica de usar um procedimento de esparsificação baseado no chamado critério ALD (*approximate linear dependence*) (Engel et al., 2002), no qual é selecionada apenas uma pequena parcela dos padrões de entrada disponíveis, para utilização nas fases de estimação de parâmetros e de validação. Além disso, para os experimentos realizados, foram utilizadas para os estimadores KRLS e KLMS as funções de kernel linear (KRLS<sub>L</sub>, KLMS<sub>L</sub>) e *Gaussiana* (KRLS<sub>G</sub>, KLMS<sub>G</sub>), conforme as equações a seguir:

$$\begin{aligned} k(\mathbf{x}_1, \mathbf{x}_2) &= \mathbf{x}_1^T \mathbf{x}_2, \text{ (linear)} \\ k(\mathbf{x}_1, \mathbf{x}_2) &= \exp\left\{-\frac{\|\mathbf{x}_1 - \mathbf{x}_2\|_2^2}{2\sigma^2}\right\}, \text{ (Gaussiana)} \end{aligned} \quad (1)$$

em que  $\|\cdot\|_2$  denota a norma *Euclidiana* e  $\sigma$  é a largura de banda para o *kernel Gaussiano*.

## 4 Resultados e Discussões

Para a realização dos experimentos computacionais, primeiramente a base de dados disponível foi dividida, de forma tal que as  $N = 1000$  primeiras amostras foram usadas para a fase de estimação de parâmetros e as  $N' = 4040$  restantes para a validação dos modelos.

Na sequência, usou-se a estratégia de *10-fold cross validation* (*10-fold CV*), em um processo de seleção de modelos automático, para a busca dos hiperparâmetros ótimos para cada estimador. Dessa forma, decidiu-se por otimizar a ordem do vetor de regressores para o estimador OLS, ( $\hat{n}_y = 3$ ), usando-se esse valor para os demais modelos. Depois disso, *10-fold CV* foi aplicada para otimizar os valores do passo de aprendizagem  $\mu$  para o LMS e o KLMS, do fator de esquecimento  $\lambda$  para o RLS, do parâmetro de esparsidade  $\nu$  para o KRLS e, adicionalmente, do  $\sigma$  para o *kernel Gaussiano* nos modelos KLMS<sub>G</sub> e o KRLS<sub>G</sub>.

Para avaliação dos resultados, foi utilizada como figura de mérito os valores médios de RMSE (*Root Mean Square Error*) calculados com as amostras de validação, ao longo de 20 rodadas independentes de cada estimador. Por fim, os cenários avaliados a seguir foram baseados em predições de 1 passo, 6 passos, 12 passos e 18 passos à frente, correspondendo, respectivamente, a horizontes de predição de 10 minutos, 1 hora, 2 horas e 3 horas, cujos resultados estão mostrados na Tabela 2.

É possível observar nos resultados da Tabela 2 que os estimadores não lineares KLMS<sub>G</sub> e KRLS<sub>G</sub> obtiveram, em geral, desempenho inferior comparativamente com os demais estimadores, para todos os cenários de predição avaliados. Isso é um indicativo de que o conjunto de dados utilizado tem um comportamento linear. Por outro lado, os estimadores lineares baseados em mínimos quadrados (OLS, ELS, LMS e RLS) obtiveram desempenhos relativamente similares aos obtidos com os estimadores *kernelizados* com função de *kernel* linear (KLMS<sub>L</sub> e KRLS<sub>L</sub>).

Em uma análise mais cuidadosa da Tabela 2, pode-se ainda verificar que o estimador OLS obteve os menores valores (média e dispersão) de RMSE entre todos os modelos investigados, o que pode ser justificado pelo fato de se tratar de um algoritmo com estimação em *batch* (assim como o ELS), ou seja, todas as amostras de estimação disponíveis são previamente armazenadas na memória para, em uma fase posterior, calcular-se o vetor de parâmetros do estimador.

Um outro ponto que merece ser ressaltado é que o estimador KRLS<sub>L</sub> (com kernel linear) obteve valores médios de RMSE praticamente iguais aos obtidos pelo OLS, para todos os cenários de predição. Adicionalmente, o KRLS<sub>L</sub> usou apenas 3 padrões de entrada, dentre os 1000 disponíveis,

Estimadores	RMSE - Cenários de Predição			
	1 passo à frente	6 passos à frente	12 passos à frente	18 passos à frente
OLS	<b>6,83E-1 ±6,24E-16</b>	<b>1,26E0 ±3,06E-15</b>	<b>1,57E0 ±8,98E-15</b>	<b>1,79E0 ±1,01E-14</b>
ELS	6,83E-1 ±2,21E-4	1,26E0 ±4,61E-4	1,57E0 ±1,30E-3	1,79E0 ±3,10E-3
LMS	7,74E-1 ±2,94E-2	1,46E0 ±1,92E-3	2,02E0 ±5,14E-1	2,61E0 ±8,63E-1
RLS	6,83E-1 ±2,80E-5	1,26E0 ±1,62E-4	1,57E0 ±5,12E-4	1,79E0 ±1,30E-3
KLMS <sub>L</sub>	7,75E-1 ±1,33E-1	1,62E0 ±4,77E-1	2,63E0 ±1,01E0	4,17E0 ±3,39E0
KLMS <sub>G</sub>	8,24E-1 ±9,09E-2	1,92E0 ±1,20E0	2,53E0 ±9,72E-1	2,47E0 ±8,00E-1
KRLS <sub>L</sub>	<b>6,83E-1 ±4,87E-4</b>	<b>1,26E0 ±3,70E-3</b>	<b>1,57E0 ±9,28E-3</b>	<b>1,82E0 ±3,55E-2</b>
KRLS <sub>G</sub>	7,52E-1 ±4,86E-2	1,44E0 ±4,36E-1	1,55E0 ±3,45E-1	1,71E0 ±2,04E-1

Tabela 2: RMSE obtidos com as amostras de ao longo de 20 rodadas independentes de cada estimador, em diferentes cenários de predição.

para realizar as predições com as amostras de validação. Essa é uma evidência de que a esparsidade do algoritmo, promovida neste caso pelo critério ALD, pode aliar performances satisfatórias a modelos significativamente reduzidos.

Os resultados no pior caso (as saídas preditas que levaram aos maiores valores de RMSE ao longo das rodadas independentes) para as predições dos melhores modelos, de acordo com os valores em destaque na Tabela 2, estão reportados nas Figuras 2(a) a 2(h), para os cenários de 1, 6, 12 e 18 passos à frente, respectivamente. Nessas figuras, é possível notar que em todos os cenários tanto o modelo OLS quanto o KRLS<sub>L</sub> conseguiram, em geral, acompanhar o comportamento dinâmico da saída real, mesmo considerando suas piores predições (aquelas que obtiveram os maiores valores de RMSE) ao longo das 20 repetições.

#### 4.1 Análise de Resíduos

Por fim, de maneira a validar ainda mais os resultados obtidos, foi aplicado um teste estatístico para os resíduos produzidos pelos modelos OLS e KRLS<sub>L</sub> (Aguirre, 2007; Billings, 2013). O objetivo desse teste é verificar se os resíduos  $\xi = \mathbf{y}_{\text{real}} - \mathbf{y}_{\text{pred}}$  são descorrelacionados, ou seja, se o modelo realmente conseguiu explicar tudo que for explicável nos dados (Aguirre, 2007). Para um problema de séries temporais, onde o modelo não apresenta entrada, é utilizada apenas a função de autocorrelação:

$$r_{\xi\xi}(\tau) = E\{(\xi(k) - \overline{\xi(k)})(\xi(k - \tau) - \overline{\xi(k)})\} = \delta(\tau), \quad (2)$$

em que  $E\{\cdot\}$  é o valor esperado e  $\delta(\cdot)$  é a função delta de Dirac. Nesse contexto, um intervalo de confiança de 95% é usado para decidir se o teste é satisffeito e se os modelos são validados.

Os resultados da análise de resíduos para os modelos OLS e KRLS<sub>L</sub> são mostrados na Figura 3, onde se pode observar que ambos os estimadores passaram no teste, o que é um indicativo de que o resíduo obtido é um ruído branco. Dessa forma, é possível afirmar que os estimadores supracitados

obtiveram desempenho satisfatório na predição da velocidade dos ventos, com a base de dados utilizada.

## 5 Conclusões

Neste artigo, foi feito um estudo comparativo com estimadores lineares e não lineares aplicados a um problema prático de predição de séries temporais, no caso, para a predição da velocidade dos ventos em um parque eólico localizado no estado do Ceará.

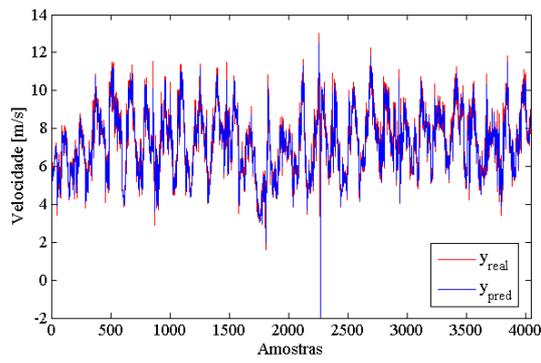
Com base nos resultados obtidos, percebeu-se um comportamento linear na base de dados utilizada, tendo em vista que os estimadores OLS e KRLS<sub>L</sub> obtiveram os melhores desempenhos, dentre os modelos avaliados (inclusive os não lineares). Para todo os horizontes de predição testados, de 10 minutos até 3 horas, é possível afirmar que os modelos OLS e KRLS<sub>L</sub> conseguiram acompanhar, em geral, o comportamento dinâmico da saída real.

Por fim, é importante ressaltar que essa foi a primeira vez que o comportamento dinâmico da referida base de dados foi investigada no paradigma de predição de séries temporais.

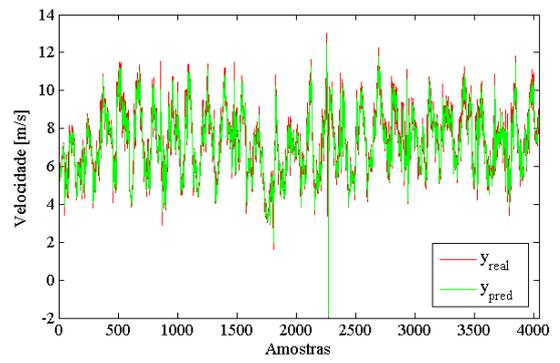
Para trabalhos futuros, pretende-se aplicar técnicas de pré-processamento nos dados, no intuito de melhorar a qualidade da informação e diminuir redundância, bem como aumentar o desempenho dos modelos em cenários de predição maiores. Uma outra linha a ser investigada é aplicar esses estimadores em sistemas embarcados para aplicações em predição em tempo real para fins de manutenção de equipamentos e instalação de novos parques eólicos.

## Agradecimentos

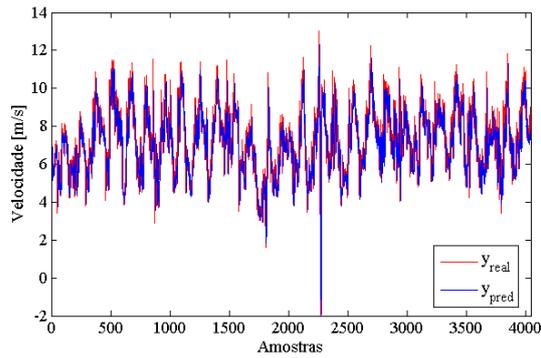
Ao LAMSC (Laboratório de Aprendizagem de Máquinas e Simulações Computacionais) do IFCE - Campus Maracanaú, pelo apoio a esta pesquisa. Os autores também agradecem o apoio financeiro



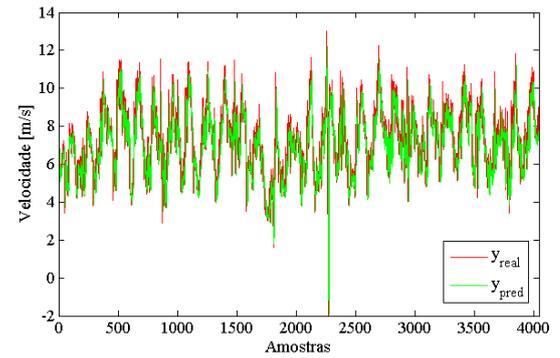
(a) 1 passo à frente - OLS.



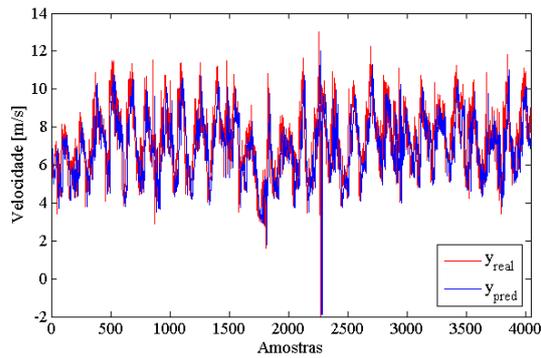
(b) 1 passo à frente - KRLS<sub>L</sub>.



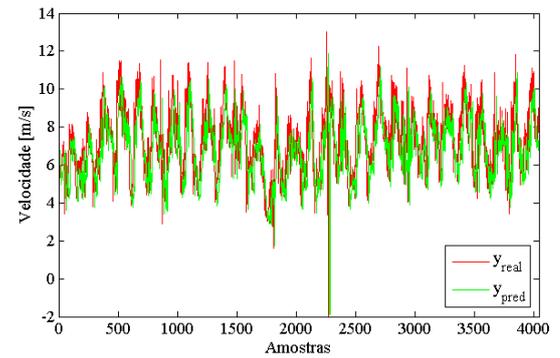
(c) 6 passos à frente - OLS.



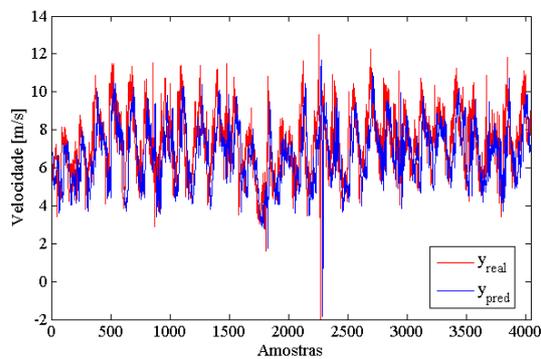
(d) 6 passos à frente - KRLS<sub>L</sub>.



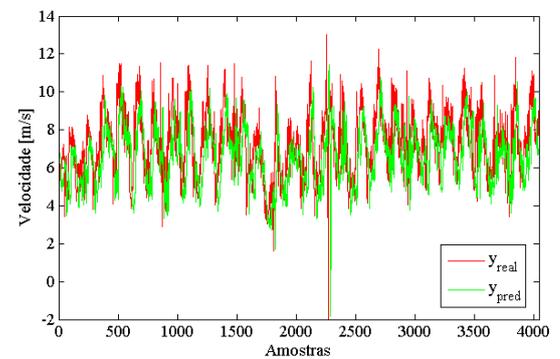
(e) 12 passos à frente - OLS.



(f) 12 passos à frente - KRLS<sub>L</sub>.

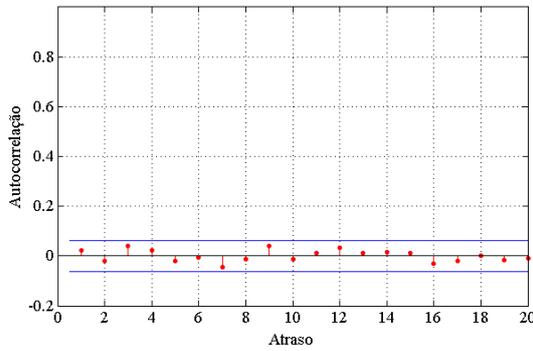


(g) 18 passos à frente - OLS.

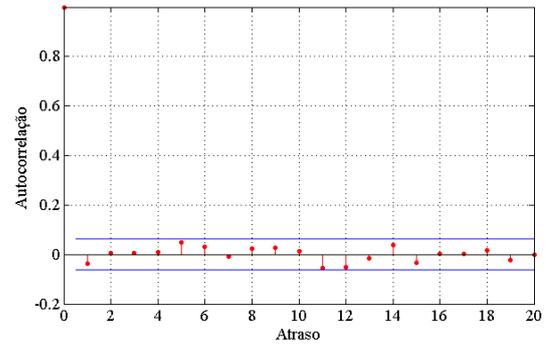


(h) 18 passos à frente - KRLS<sub>L</sub>.

Figura 2: Saídas previstas em cada cenário pelos melhores modelos na Tabela 2, de acordo com suas piores performances em termos de RMSE, ao longo de 20 rodadas independentes.



(a) Estimador OLS.



(b) Estimador KRLS<sub>L</sub>.

Figura 3: Autocorrelação dos resíduos obtidos com os estimadores OLS e KRLS<sub>L</sub>.

da FUNCAP e CAPES via Edital 05/2014 da FUNCAP/CAPES.

### Referências

- Afanasyeva, S., Saari, J., Kalkofen, M., Partanen, J. and Pyrhonen, O. (2016). Technical, economic and uncertainty modelling of a wind farm project, *Energy Conversion and Management* **107**: 22–33.
- Aguirre, L. A. (2007). *Introdução à identificação de sistemas - Técnicas lineares e não lineares aplicadas a sistemas reais*, 3th edn, Editora UFMG, Belo Horizonte, Brazil.
- Billings, S. A. (2013). *Nonlinear System Identification NARMAX Methods in the Time, Frequency and Spatio-Temporal Domains*, 1st edn, John Wiley & Sons, Hoboken, NJ, USA.
- Cheng, L., Lin, J., Sun, Y.-Z., Singh, C., Gao, W.-Z. and Qin, X.-M. (2012). A model for assessing the power variation of a wind farm considering the outages of wind turbines, *IEEE Transactions on Sustainable Energy* **3**(3): 432–444.
- Conradsen, K., Nielsen, L. and Prahm, L. (1984). Review of weibull statistics for estimation of wind speed distributions, *Journal of climate and Applied Meteorology* **23**(8): 1173–1183.
- de Jong, P., Kiperstok, A., Sánchez, A. S., Dargaville, R. and Torres, E. A. (2016). Integrating large scale wind power into the electricity grid in the northeast of brazil, *Energy* **100**: 401–415.
- Doucoure, B., Agbossou, K. and Cardenas, A. (2016). Time series prediction using artificial wavelet neural network and multi-resolution analysis: Application to wind speed data, *Renewable Energy* **92**: 202–211.
- Engel, Y., Mannor, S. and Meir, R. (2002). Sparse online greedy support vector regression, *Proceedings of the 13th European Conference on Machine Learning (ECML)*, Vol. 1, T. Elomaa and H. Mannila and H. Toivonen, Helsinki, Finland, pp. 84–96.
- Engel, Y., Mannor, S. and Meir, R. (2004). The kernel recursive least-squares algorithm, *IEEE Transactions on Signal Processing* **52**(8): 2275–2285.
- Gomes, S. L. (2017). *Estimativa de produção de energia eólica em aerogeradores utilizando métodos de regressão sobre a curva de potência e redes neurais recursivas para prever a velocidade do vento*, Dissertação de mestrado, Instituto Federal de Educação, Ciência e Tecnologia do Ceará, Programa de Pós-graduação em Energias Renováveis, Fortaleza, Ceará.
- Haykin, S. O. (2013). *Adaptive filter theory*, 5th edn, Prentice Hall, Upper Saddle River, NJ, USA.
- Jervell, J. T. (2008). *Estudo da influência das características do vento no desempenho de aerogeradores*, Master’s thesis, Faculdade de Engenharia da Universidade do Porto, Portugal.
- Lahouar, A. and Slama, J. B. H. (2017). Hour-ahead wind power forecast based on random forests, *Renewable energy* **109**: 529–541.
- Lei, M., Shiyan, L., Chuanwen, J., Hongling, L. and Yan, Z. (2009). A review on the forecasting of wind speed and generated power, *Renewable and Sustainable Energy Reviews* **13**(4): 915–920.
- Liu, W., Pokharel, P. and Príncipe, J. C. S. C. (2008). The kernel least mean square algorithm, *IEEE Transactions on Signal Processing* **56**(2): 543–554.

- Menezes-Júnior, J. M. P. (2012). *Contribuições ao problema de predição recursiva de séries temporais univariadas usando redes neurais recorrentes*, Tese de doutorado, Universidade Federal do Ceará, Departamento de Informática, Fortaleza.
- Rolik, Y. (2017). Risk management in implementing wind energy project, *Procedia Engineering* **178**: 278–288.
- Santamaría-Bonfil, G., Reyes-Ballesteros, A. and Gershenson, C. (2016). Wind speed forecasting for wind farms: A method based on support vector regression, *Renewable Energy* **85**: 790–809.
- Schölkopf, B. and Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*, 1st edn, MIT press, Cambridge, MA, USA.
- Widrow, B. and Hoff, M. E. (1960). Adaptive switching circuits, *IRE WESCON convention record*, Vol. 4, New York, pp. 96–104.
- Zolfaghari, S., Riahy, G. H. and Abedi, M. (2015). A new method to adequate assessment of wind farms power output, *Energy Conversion and Management* **103**: 585–604.