

## DESENVOLVIMENTO DE ESTRATÉGIAS COMPUTACIONAIS QUE COMBINAM MÁQUINAS DE VETORES DE SUPORTE, REDES NEURAIS ARTIFICIAIS E A TRANSFORMADA WAVELET NO PROGNÓSTICO DE SÉRIES TEMPORAIS DE RADIAÇÃO SOLAR

PEDRO HENRIQUE PEREIRA ALVES<sup>1\*</sup>; ARTHUR PONTES DE MIRANDA RAMOS SOARES<sup>2</sup>;  
LUCAS OLIVEIRA MENDES DA SILVA<sup>3</sup>; ELBER CAIO ANTHONY CADETE LOPES<sup>4</sup>; FREDERICO DE OLIVEIRA CARVALHO<sup>5</sup>

<sup>1</sup>Graduando em Engenharia Química, UFAL, Maceió-AL, pedro.pereira@ctec.ufal.br;

<sup>2</sup>Graduando em Engenharia Química, UFAL, Maceió-AL, eq.arthurpmrs@gmail.com;

<sup>3</sup>Graduando em Engenharia Química, UFAL, Maceió-AL, lucas.mendes@ctec.ufal.br;

<sup>4</sup>Graduando em Engenharia Química, UFAL, Maceió-AL, elbercaio@gmail.com;

<sup>5</sup>Doutor em Engenharia Química, Prof. Associado IV, UFAL, Maceió-AL, fredecarvalho@yahoo.com.br

Apresentado no  
Congresso Técnico Científico da Engenharia e da Agronomia – CONTECC'2018  
21 a 24 de agosto de 2018 – Maceió-AL, Brasil

**RESUMO:** Devido à crescente demanda por fontes renováveis, a energia proveniente do sol, por meio de radiação, vem aumentando em popularidade. No entanto, esta variável, como uma série temporal, possui difícil previsão devido ao seu comportamento altamente não estacionário e intermitente, dificultando possíveis investimentos nesta área. Assim, cada vez mais modelos matemáticos e sistemas inteligentes vêm sendo desenvolvidos para facilitar o diagnóstico e previsão dos níveis de radiação. Utilizando dados diários de radiação solar da cidade de Cascavel, PR, de 05 de Novembro de 1990 até 18 de Janeiro 1995, este trabalho busca comparar modelos empíricos de regressão de séries temporais e máquinas de aprendizado como as Máquinas de Vetores de Suporte (MVS) e Redes Neurais Artificiais (RNA's) a modelos híbridos decorrentes da junção Transformada *Wavelet* Discreta (TWD) e os próprios MVS e RNA. Com base nos parâmetros estatísticos *Mean squared normalized error* (MSE) e o coeficiente de correlação (R), os modelos híbridos mostraram-se superiores em relação aos modelos puros.

**PALAVRAS-CHAVE:** Radiação Solar; Prognóstico; TWD; MVS; RNA.

### DEVELOPMENT OF COMPUTATIONAL STRATEGIES COMBINING SUPPORT VECTOR MACHINE, ARTIFICIAL NEURAL NETWORKS AND WAVELET TRANSFORMED IN THE PROGNOSIS OF TEMPORARY SOLAR RADIATION'S SERIES

**ABSTRACT:** Due to the increasing demand of renewable energy sources, solar energy from radiation has been increasing in popularity. This kind of energy is a hard to predict variable due to its highly non-stationary behavior, as a consequence, a number of mathematical models and intelligent systems have been developed to facilitate the diagnosis and prediction of the radiation's levels. Using daily solar radiation data from the city of Cascavel, PR, from November 5, 1990 to January 18, 1995, this work aims to compare models such as Support Vector Machine (SVM) and Artificial Neural Networks (ANN) to hybrid models resulting from the conjunction of Discrete Wavelet Transform (DWT) with the SVM and ANN themselves. Through the statistic parameters *Mean squared normalized error* (MSE) and the correlation coefficient (R), the hybrid models has shown better results based on the comparison with the pure models.

**KEYWORDS:** Solar Radiation; Prognosis; DWT; SVM; ANN.

### INTRODUÇÃO

As fontes de energia elétrica provenientes de combustíveis fósseis são mais utilizadas até hoje, tanto devido ao preço como a disponibilidade. No entanto, com a crescente demanda energética o

homem vem buscando novas fontes, tais como energia eólica e a solar (ou fotovoltaica). Além de suprir esta demanda, estes tipos de fonte energética ainda possuem a vantagem de ser o que se chama de energia renováveis, pois são um tipo, teoricamente, inesgotável de energia, além de também contribuir com o aumento da oferta deste tipo de energia, para menores flutuações do preço de combustíveis como consequência do aumento da oferta de mercado, assim como estas fontes terem impacto ambiental muito menor (Santos, 2010).

Segundo Santos (2010), a energia elétrica produzida normalmente por centrais fotovoltaicas é altamente intermitente, este fato é consequência do sombreamento provocado pela presença de nuvens. Esta intermitência não é problema no cenário atual onde a energia elétrica produzida por este meio é baixa em relação a outros meios, no entanto, futuramente, a intermitência tem que ser contornada para poder expandir o uso da energia solar, visto que este fator provoca flutuações de tensão, degradação da qualidade da energia elétrica e problemas de estabilidade na rede elétrica, aumentando os riscos de danos e comprometendo a viabilidade econômica. (Deo *et al.*, 2016; Zhu *et al.*, 2016). A intermitência na produção da energia elétrica é consequência da mesma depender principalmente de variáveis climáticas, como a radiação solar.

Devido às características complexas e não estacionárias das séries temporais de radiação solar, torna-se necessária a utilização de métodos estatísticos ou de inteligência artificial específicos para a previsão da produção deste tipo de energia, possibilitando menos riscos no processo. (Zhu *et al.*, 2016; Saraiva *et al.*, 2014). Para solucionar o problema descrito, são citados na literatura alguns modelos de máquinas de aprendizado e técnicas de processamento de sinais, capazes de realizar o prognóstico de séries temporais que possuem tais características.

### **Maquinas de aprendizado com Redes Neurais Artificiais (RNA's)**

Como sugerido por Zhu *et al.* (2016) as redes neurais são muito eficientes no prognóstico de variáveis deste tipo. As RNA's são sistemas computacionais inteligentes inspiradas nos neurônios naturais, ou seja, no próprio cérebro humano e, portanto, foram aperfeiçoadas para terem a capacidade de se adaptar e de aprender a realizar certa tarefa, ou comportamento, a partir de um conjunto de dados. O cérebro possui capacidade de desenvolver suas próprias regras através da experiência, esta experiência cresce com o tempo, assim, as redes neurais consistem numa tentativa em trazer o que o nosso cérebro já, duma maneira muito mais avançada do qualquer computador existente no momento para o computador utilizando de neurônios artificiais, pesos sinápticos a serem ajustados, dados para treinamento (experiência do modelo), junções aditivas e funções de ativação que irão restringir a amplitude de saída dos neurônios (Haykin, 2001).

### **Maquinas de aprendizado com Máquinas de Vetores de Suporte (MVS)**

No trabalho de Deo, Wen e Qi (2016) a resposta de MVS foi mais rápida se comparado com RNA, assim viabilizando sua aplicação frente a RNA para algumas séries temporais. O modelo MVS é baseado na teoria do aprendizado estatístico proposta por Vapnik, 1995. Tal teoria adota os mínimos quadrados para a resolução do problema, através da minimização do risco estrutural de equações lineares. Quando o conjunto de dados é dito não linearmente separável, utiliza-se as chamadas funções de Kernel, estas por sua vez realizam a mudança do conjunto de dados de uma dimensão para uma maior, até que estes possam ser linearmente separáveis e, portanto, seja possível construir um hiperplano ótimo e o modelo em questão de regressão ser efetivo (Haykin, 2001).

### **Transformada Wavelet Discreta (TWD)**

Como já discutido, a série temporal de radiação solar possui comportamento altamente não estacionário e aleatório, onde a frequência do sinal varia ao longo de todo domínio do tempo. A Transformada *Wavelet* é método de análise espectral e consiste decompor o sinal em vários sinais, chamados de aproximação (baixa frequência) e detalhe (alta frequência), através de uma função característica chamada de *Wavelet*-mãe. A extração destes componentes de frequência do sinal original resulta nestas camadas de aproximação e detalhe. Assim, quando utilizados estes novos sinais na entrada do modelo de regressão, em um treinamento supervisionado, o modelo de regressão consegue extrair de maneira mais eficiente o padrão da série temporal e prevê-lo para certo tempo a frente em função de dados passados (Saraiva *et al.*, 2014).

Modelos híbrido partem da junção de 2 ou mais modelos e, por isso, acoplam a função de 2 modelos criando um novo, normalmente e o que se espera, mais eficiente que o modelo de regressão puro. Segundo Deo, Wen e Qi (2016) & Zhu *et al.* (2016) o poder preditivo das máquinas de aprendizado RNA's e MVS são potencializados quando estes métodos são utilizados em conjunção com a Transformada *Wavelet* Discreta.

O presente trabalho tem como objetivo comparar a viabilidade da utilização dos sistemas híbridos formado com as máquinas de aprendizado Máquinas de Vetores de Suporte-Transformada *Wavelet* Discreta e Redes Neurais Artificiais-Transformada *Wavelet* Discreta para previsão de dados da radiação solar da cidade de Cascavel, Paraná, Brasil, em comparação as técnicas de regressão puras e desta forma poder contribuir no desenvolvimento deste tipo de energia aqui no Brasil.

## METODOLOGIA

### Levantamento de Dados

Os dados diários utilizados na análise são referentes à cidade de Cascavel, PR. As medições foram realizadas pelo Instituto Agrônomo do Paraná (IAPAR), entre os dias 05 de Novembro de 1990 até 18 de Janeiro 1995, resultando num conjunto de dados com 1536 dias.

### Arquitetura dos Modelos

Neste artigo foram propostos quatro modelos para o prognóstico da série temporal de radiação solar na cidade de Cascavel, PR. O primeiro modelo utiliza somente uma rede neural artificial para previsão, o segundo utiliza uma conjunção de RNA com a transformada *Wavelet* discreta, metodologia utilizada por Zhu *et al.* (2016), o terceiro utiliza Máquinas de Vetores Suporte e o último modelo utiliza uma conjunção de MVS e a Transformada *Wavelet* Discreta, metodologia descrita por Deo *et al.* (2016), como mostra a Figura 1. Todos os modelos foram construídos em ambiente MATLAB.

Figura 1. Fluxograma da metodologia utilizada para os modelos puros e híbridos



Modelo 1 (Rede Neural Artificial): No primeiro modelo, não há pré-processamento de dados, portanto, os dados da série temporal são inseridos diretamente à rede. Neste modelo, 85% dos dados foram utilizados para treinamento e 15% para teste da rede. A estrutura da rede escolhida utiliza as funções padrão do MATLAB, função tangente sigmoide, para a camada escondida, e a função linear, para a camada de saída. O padrão de treinamento utilizado consiste em inserir três dados da série para prever o quarto dado. O algoritmo de aprendizagem utilizado foi Levenberg-Marquardt.

Modelo 2 (Conjunção Transformada *Wavelet* Discreta e Rede Neural Artificial): O segundo modelo proposto assemelha-se ao primeiro e difere somente no pré-processamento dos dados. É utilizada a transformada *Wavelet* discreta para decompor o sinal do domínio do tempo para o domínio do tempo-escala. Os componentes obtidos na decomposição são chamados de aproximação (A), componente de baixas frequências, e detalhe (D), componente de altas frequências.


O processo de decomposição do sinal pode ser repetido de maneira iterativa, resultando na chamada árvore de decomposição *Wavelet* (Figura 2). Segundo Nourani, Kisi e Komasi (2009), o número decomposições é determinado pela equação (1).

$$N^{\circ} \text{ de Decomposições} = \lceil \log(N^{\circ} \text{ de dados}) \rceil \quad (1)$$

Como a quantidade de dados utilizada é de 1536, o número de decomposições é igual a 3, resultando na árvore de decomposição *Wavelet* mostrada na Figura 2. Desta forma, os dados inseridos

na entrada da rede neural foram os componentes D1, D2, D3, A3 e a própria série original resultando no dado previsto de radiação solar, na saída da rede. A *Wavelet* mãe utilizada para decomposição dos dados foi a forma discreta da *Wavelet* de Meyer.

Figura 2. Árvore de Decomposição *Wavelet* para nível 3



Modelo 3 (Máquinas de Vetores Suporte): O terceiro modelo utiliza, somente, as Máquinas de Vetores Suporte para regressão dos dados da série temporal de radiação solar, sem pré-processamento. Para o treinamento, foram separados 85% dos dados, deixando 15% para teste do modelo. A função kernel utilizada para o treinamento supervisionado foi a função gaussiana ou RBF e o padrão de treinamento, semelhante ao dos modelos anteriores, utiliza três dados para prever o quarto.

Modelo 4 (Conjunção Transformada *Wavelet* Discreta e Máquinas de Vetores Suporte): Neste modelo é aplicada a transformada *Wavelet* discreta para pré-processamento de dados de forma semelhante ao modelo 2. O procedimento de decomposição é o mesmo, ou seja, são utilizados os mesmos critérios e a mesma *Wavelet* mãe, a diferença é que os sinais de decomposição, D1, D2, D3, A3 mais a série original, são agora inseridos de entrada no modelo de regressão MVS, obtendo como resultado o dado previsto de radiação solar. Vale ressaltar que os parâmetros utilizados na MVS deste modelo, são os mesmos utilizados no modelo 3.

## RESULTADOS E DISCUSSÃO

Para verificar a influência do pré-processamento de dados no prognóstico da série temporal de radiação solar na cidade de Cascavel, PR, foram construídos gráficos que comparam os dados reais observados, cor azul, com os dados simulados, cor vermelha, para os modelos construídos.

A Figura 3 mostra os gráficos dos dados reais em comparação com os dados simulados para os modelos RNA e RNA com *Wavelet* (RNA-W). Já a Figura 4 mostra os gráficos para os modelos de MVS e MVS com *Wavelet* (MVS-W).

Figura 3. Série de dados reais e simulados para os modelos RNA (Esquerda) e RNA-W (Direita)





Figura 4. Série de dados reais e simulados para os modelos MVS (Esquerda) e MVS-W (Direita)



Apesar de revelarem de forma qualitativa o afastamento dos dados simulados em relação aos dados reais, são necessários parâmetros estatísticos que validem a superioridade da utilização do pré-processamento em relação aos modelos puros.

Para que fosse realizada a comparação de forma mais objetiva, foram escolhidos os parâmetros *Mean squared normalized error (MSE)* e o coeficiente de correlação (R). Os resultados obtidos para os treinamentos e testes dos modelos estão listados nas Figura 5 e 6.

Figura 5. Erros associados às etapas de treinamento e teste para os modelos RNA e RNA-W

<b>Modelo</b>	<b>R</b>	<b>MSE</b>
<b>RNA (Treino)</b>	0,6292	8991,60
<b>RNA-W (Treino)</b>	0,9665	981,56
<b>RNA (Teste)</b>	0,5920	9602,01
<b>RNA-W (Teste)</b>	0,9579	1235,80

Figura 6. Erros associados às etapas de treinamento e teste para os modelos MVS e MVS-W

<b>Modelo</b>	<b>R</b>	<b>MSE</b>
<b>MVS (Treino)</b>	0,6564	8651,00
<b>MVS -W(Treino)</b>	0,9748	769,75
<b>MVS (Teste)</b>	0,5959	9798,70
<b>MVS-W (Teste)</b>	0,9406	1745,70

Observando os parâmetros estatísticos calculados para os modelos puros e em conjunção com a transformada *Wavelet*, nota-se uma significativa melhora na regressão para os modelos os quais utilizam o pré-processamento de dados, tanto para a Rede Neural Artificial, quanto para as Máquinas de Vetores Suporte. Em ambos os casos, o parâmetro MSE diminui consideravelmente e o coeficiente de correlação se aproxima de 1. Este resultado evidencia o aumento no desempenho da regressão proporcionado pela transformada *Wavelet*, para dados que apresentam alto caráter não estacionário, como as séries temporais de radiação solar.

## CONCLUSÃO

De acordo com os resultados obtidos, foi possível concluir que os modelos que utilizam as conjunções com a Transformada *Wavelet*, tanto para Redes Neurais, quanto para Máquinas de Vetores Suporte, obtêm melhores resultados no prognóstico de séries temporais que apresentam caráter não estacionário. As Figuras 5 e 6 mostram um significativo decréscimo no erro das previsões realizadas pelos modelos híbridos, em relação aos seus respectivos modelos puros.

## REFERÊNCIAS

- Deo, R. C.; Wen, X.; Qi, F.. A Wavelet-Coupled Support Vector Machine Model for Forecasting Global Incident Solar Radiation Using Limited Meteorological Dataset. **Revista Applied Energy**, Science Direct. 2016. DOI: 10.1016/j.apenergy.2016.01.130.
- Haykin, Simon. **Redes Neurais: Princípios e prática**. Porto Alegre RS:Bookman, 2001. p.27-41.
- Nourani, V.; Kisi, Ö.; Komasi, M. I. K.. Two Hybrid Artificial Intelligence Approaches for Modeling Rainfall-Runoff Process. **Journal of Hidrology**, 2011.
- Santos, B. A. O.. Previsão de Produção de Centrais Solares a Muito Curto Prazo. 74 f. Dissertação (Mestrado) - Engenharia Eletrotécnica e de Computadores, Faculdade de Engenharia da Universidade do Porto, 2010.
- Saraiva, S. V.; Amorim, R. F. C.; Carvalho, F. O.; Domingues, L.. Prognóstico de Radiação Solar Através de Modelos que Combinam Técnicas Wavelet e Redes Neurais. **Revista Brasileira de Geografia Física**, vol.07, n.05. 2015.
- Zhu, H.; Li, X.; Sun, Q.; Nie, L.; Yao, J.; Zhao, G.. A Power Prediction Method for Photovoltaic Power Plant Based on Wavelet Decomposition and Artificial Neural Networks. **Revista Energies**. 2016, 9, 11; DOI:10.3390/en9010011.