

ESTIMATIVA DA RADIAÇÃO GLOBAL HORÁRIA EM SUPERFÍCIE INCLINADA PARA O MUNICÍPIO DE BOTUCATU/SP/BRASIL USANDO MODELO ESTATÍSTICO E ARQUITETURAS DE REDES NEURAIAS ARTIFICIAIS MLP E GRNN

A. S. Marques¹, J. F. Escobedo², A. Dal Pai³

¹Instituto Federal de São Paulo - IFSP/Birigui/SP/Brasil

²Departamento de Engenharia Rural – FCA/UNESP – Botucatu/SP/Brasil

³Departamento de Bioprocesso e Biotecnologia – FCA/UNESP – Botucatu/SP/Brasil

Tel. + 55 (14) 99895-2481 e-mail: adriano.marques@ifsp.edu.br

Recibido 27/07/17, aceptado 28/09/17

RESUMO. Neste trabalho realizou-se um estudo com três modelos de estimativa para realizar a estimativa da irradiação global incidente em uma superfície com inclinação de $22,85^\circ$ (IG_β), a partir dos dados da irradiação solar global na superfície horizontal (IG_H) medidos na partição horária no período de abril de 1998 a agosto de 2001 na estação climatológica da Faculdade de Ciências Agrônomicas da UNESP no câmpus de Butucatu/SP/Brasil, sendo eles: o modelo estatístico (ME) (Liu & Jordan, 1963) e os modelos de redes neurais artificiais (RNA), Perceptron Multicamadas (*MultiLayer Perceptron* - MLP) utilizando algoritmo *Backpropagation* e Rede de Regressão Generalizada (*Generalized Regression Neural Network* - GRNN). O modelo clássico obtido por regressão e os modelos de rede treinados, foram validados em duas bases de dados classificadas como anos típicos (AT) e anos atípicos (AAT). Para o treinamento das redes, foram realizadas 8 combinações de variáveis astronômicas e geográficas, medidas e calculadas. Os índices estatísticos de avaliação de desempenho utilizados (r e $RMSE\%$) obtidos no modelo clássico foram: $r_{AT}=0,9927$, $RMSE\%_{AT}=6,5898$ e $r_{AAT}=0,9960$, $RMSE\%_{AAT}=4,8062$, os índices obtidos com a melhor combinação (RNA3) para a rede MLP foram: $r_{AT}=0,9941$, $RMSE\%_{AT}=5,9849$ e $r_{AAT}=0,9984$, $RMSE\%_{AAT}=3,0561$, e os índices obtidos com a melhor combinação (RNA3) para a rede GRNN foram: $r_{AT}=0,9975$, $RMSE\%_{AT}=3,8808$ e $r_{AAT}=0,9989$, $RMSE\%_{AAT}=2,6050$. Os resultados mostram que os três modelos apresentaram bons resultados nas estimativas da IG_β a partir dos dados medidos da IG_H , porém entre os modelos de RNA, destaca-se os resultados obtidos pela GRNN na estimativa da IG_β .

Palavras - chave: Radiação solar, Redes Neurais Artificiais; Estimativas.

INTRODUÇÃO

Os dados de radiação solar são importantes em diversas aplicações, as quais pode-se citar a engenharia, arquitetura, agricultura, no desenvolvimento de estudos e aplicações para geração de energia através de coletores fotovoltaicos e térmicos. Conhecer esses dados torna-se necessário para o entendimento do potencial solar disponível no Brasil, porém, por motivos de disponibilidade de recursos, a obtenção de dados de radiações incidentes em planos inclinados são restritas, sendo mais comum o monitoramento da radiação global no plano horizontal, fato que torna o uso das estimativas uma alternativa importante para realização de pesquisas e aplicações que necessitem de dados de radiações incidentes sobre um plano inclinado. De acordo com Souza (2011), na estimativa da radiação solar normalmente são aplicados os modelos estatísticos e paramétricos. Os modelos paramétricos necessitam de informações mais completas das condições atmosféricas locais. (Jiang, 2009). Os modelos estatísticos são executados por equações ajustadas por meio de regressão linear ou polinomial em correlações com as frações radiométricas.

¹ Engenheiro da Computação, Doutorando em Energia na Agricultura, FCA/UNESP/Botucatu.

² Físico, Prof. Dr. Departamento de Engenharia Rural, FCA/UNESP/Botucatu.

³ Físico, Prof. Dr. Departamento de Bioprocessos e Biotecnologia, FCA/UNESP/Botucatu.

Também deve-se destacar o uso das redes neurais artificiais (RNA) na estimativa de radiação solar, pois de acordo com Dahmani et al. (2013) e Notton et al. (2012) a estimativa da irradiação solar global em superfícies inclinadas torna mais complexa quanto menor for a partição de tempo, porém, as redes neurais artificiais vem se apresentando como uma solução interessante para realizar as estimativas nessas condições. Muitos estudos utilizando métodos estatísticos e redes neurais artificiais foram desenvolvidos para determinação da irradiação solar global em um plano inclinado (IG_{β}) a partir da irradiação solar global na horizontal (IG_H). Scola et al. (2004), realizaram um estudo de modelagem da irradiação total que incide sobre uma superfície inclinada, com face voltada para o norte na inclinação de $22,85^{\circ}$ e usando a partição diária. Com base nos modelos de estimativa definidos por Liu e Jordan (1960), Hay (1979) e Perez et al. (1986), os autores obtiveram um modelo com que utiliza somente a irradiação global para estimar a irradiação total na superfície inclinada. Muzathik et al. (2011) utilizou modelos empíricos para estimar a radiação solar global em superfícies horizontais e inclinadas com face para o sul. Para estimar a irradiação na superfície horizontal, foi utilizado o modelo Olmo et al. (1999), o qual requer apenas medidas da irradiação solar no plano horizontal. Souza et al. (2010) avaliou o desempenho de modelos isotrópicos de estimativa de irradiação incidente em superfícies inclinadas de $12,85^{\circ}$, $22,85^{\circ}$ e $32,85^{\circ}$, pelos modelos propostos por Liu e Jordan (1960), Revfeim (1978), Jimenez & Castro (1982), Koronakis (1986), a teoria Circunsolar, e a correlação entre os índices de claridade horizontais e inclinados, para diferentes condições de cobertura de céu, e propôs estimativas com base nas correlações entre os índices de claridade horizontais e inclinados nas diferentes condições de cobertura de céu no município de Botucatu/SP/Brasil. Souza et al. (2011) também avaliou equações estatísticas de estimativas (Liu e Jordan (1960); Turco e Rizzatti (2006); Notton et al. (2006); Jiang (2009). com agrupamentos de dados anuais e mensais para estimar as componentes global, direta e difusa da irradiação solar incidente em superfícies com inclinação de $12,85^{\circ}$, $22,85^{\circ}$ e $32,85^{\circ}$ com face voltada para o norte, a partir da irradiação global na horizontal. Razafiarison et al. (2011) utilizou redes neurais artificiais para estimar a irradiação solar global em uma superfície com inclinação de 30° , com dados na partição diária e mensal obtidos na estação de Fianarantsoa, Madagascar. O estudo utilizou arquitetura *Multilayer Perceptron* (MLP) para realizar as estimativas, aplicando como variáveis de entrada o índice de transmissividade atmosférica (KT), latitude (ϕ), longitude (L) e inclinação da superfície (β). Os resultados foram comparados com os modelos teóricos obtidos por Liu e Jordan. (1960) Notton et al. (2012) realizou um estudo na Universidade de Corsica com estimativas da irradiação solar global na partição mensal e horária usando redes neurais artificiais. O estudo utilizou uma rede neural de arquitetura *Multilayer Perceptron* (MLP), em diversas combinações de neurônios e camadas ocultas, sendo aplicada como variáveis de entrada a declinação (δ), hora(h), ângulo zenital (θ_z), irradiação no topo da atmosfera (I_0) e a irradiação global na horizontal (IG) para estimar a irradiação global nas inclinações de 45° e 60° . Dahmani et al. (2013) utilizou redes neurais artificiais para estimar a radiação em um plano inclinado na localidade de Bouzareah - Algeria. A estimativas foram realizadas com uma base de 2 anos de dados da irradiação em uma partição de 5 minutos para uma inclinação de $36,8^{\circ}$. As variáveis de entrada adotadas foram a declinação (δ), ângulo zenital (θ_z), azimute (α) irradiação no topo da atmosfera com partição de 5 minutos (I_0) e irradiação global horizontal na partição de 5 minutos (IG). A arquitetura de rede utilizada foi a MLP com 1 camada oculta e 8 neurônios.

Considerando a importância em diversas aplicações da estimativa de radiação no plano inclinado, o objetivo deste trabalho é definir um modelo com foco na simplicidade e desempenho para estimar a irradiação global em uma superfície inclinada (IG_{β}) para o município de Botucatu-SP/Brasil, usando as arquiteturas de redes neurais artificiais (RNA) *Multilayer Perceptron* (MLP) amplamente utilizada e a Rede de Regressão Generalizada (GRNN), a qual se apresenta como uma nova opção de estimativas a partir das medidas da irradiação global na superfície horizontal (IG) com os dados dessa localidade.

METODOLOGIA

Modelo Estatístico (ME)

Para gerar o modelo estatístico (ME) de estimativa de (IG_{β}), tomou-se como referência Liu e Jordan (1960). As variáveis utilizadas: irradiação no topo da atmosfera horizontal (I_0), irradiação no topo da atmosfera inclinada ($I_{0\beta}$), o índice de transmissividade da global no plano horizontal (KT). foram calculadas a partir da variável irradiação global no plano horizontal (IG) medida. Através do gráfico

(figura 1) da correlação entre índice de transmissividade da irradiação global incidente em um plano inclinado ($K_{T\beta}$) e o índice de transmissividade da global no plano horizontal (K_T), obteve-se a curva de ajustamento por regressão polinomial de quarto grau, com $R^2 = 0,8674$ (figura 1).




Figura 1: Correlação entre a fração da global na horizontal (K_T) e a fração da global no plano inclinado ($K_{T\beta}$), e a curva de ajuste por regressão polinomial obtida no período de 04/1998 a 08/2011.

$$K_{T\beta} = \frac{I_{G\beta}}{I_{0\beta}} = 0,020 + 0,179.K_T + 3,328.K_T^2 - 4,619.K_T^3 + 2,075.K_T^4 \dots\dots\dots(1)$$

Da equação 1 do ajuste, resultou o modelo para estimar $I_{G\beta}$ a partir de K_T e $I_{0\beta}$. (equação 2)

$$I_{G\beta} = (0,020 + 0,179.K_T + 3,328.K_T^2 - 4,619.K_T^3 + 2,075.K_T^4) \cdot I_{0\beta} \dots\dots\dots(2)$$

Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) podem ser descritas como modelos computacionais baseados no sistema neural dos seres humanos. Podem ser definidas como um conjunto de neurônios artificiais ligados por um conjunto de conexões denominadas sinapses (Silva et al. 2010).

Uma RNA é composta da seguinte estrutura:

- A camada de entrada que recebe dados;
- A camada de saída para enviar informações calculadas;
- E uma ou várias camadas ocultas que se ligam as camadas de entrada e saída.

De acordo com Krishnaiah et al (2007), o número de camadas ocultas e o número total de neurônios de cada camada depende do modelo específico, da velocidade de convergência, capacidade de generalização, o processo físico e os dados de treinamento que a rede irá treinar. O primeiro modelo de um neurônio artificial foi fruto do trabalho pioneiro de Warren McCulloch e Walter Pitts (McCulloch e Pitts, 1943), ilustrado na Fig. 2.

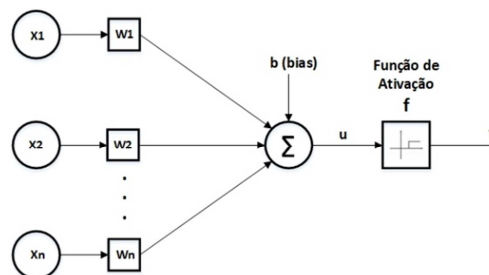


Figura 2: Modelo do neurônio artificial - McCulloch – Pitts (1943)

Durante o treinamento de uma rede neural, há a determinação e a correção dos pesos $w_{i,j}$ e dos $bias(b)$, para que a mesma resposta de forma desejada, minimizando o erro de saída para cada vetor de entrada. Como característica, a rede neural considera o conhecimento adquirido durante um treinamento, de forma a responder a novos dados de entrada da maneira mais assertiva, promovendo assim, uma generalização do problema.

Multilayer Perceptron (MLP)

A rede neural MLP (figura.3) consiste de um conjunto de neurônios que compõe a camada de entrada, uma ou mais camadas ocultas e uma camada de saída de neurônios computacionais, todas interligadas por ligações sinápticas com pesos variados. Pertence à arquitetura *feedforward* de múltiplas camadas com treinamento supervisionado e são amplamente utilizadas em modelagem para resolução de problemas complexos. De acordo com o programa SNNS - Stuttgart Neural Network Simulator (SNNS User Manual, 1995), a rede *feedforward* trabalha com a propagação do sinal “para frente”, entre células de camadas adjacentes, até a última camada (saída). Na fase de treinamento da rede, há a determinação e a correção dos pesos e dos bias (θ_i), para que a mesma responda de forma desejada, minimizando o erro de saída para cada vetor de entrada. A figura 3 demonstra a estrutura de uma rede MLP

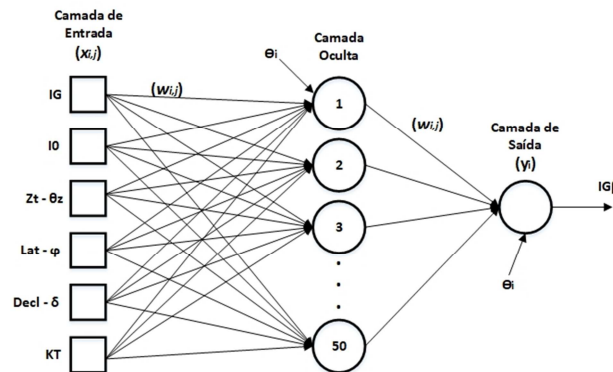


Figura 3: Diagrama da arquitetura da Rede Neural Multilayer Perceptron (MLP) utilizada.

Rede Neural de regressão Generalizada (GRNN)

A GRNN, proposta por Specht (1991), pode ser definida como uma Rede Neural Artificial (RNA) com estrutura do tipo *feedforward*, ou seja, não recorrente e requer treinamento supervisionado. Possui uma estrutura fixa, dada por uma camada de entrada, duas intermediárias denominadas de padrão e soma, e uma camada de saída na qual o número de neurônios de cada camada depende do número de entradas e saídas da rede. A GRNN é frequentemente usada para a aproximação de funções e tem como principal vantagem a velocidade com que pode ser treinada. O número de neurônios da camada padrão é igual ao número de amostras da entrada da rede, com uma função de ativação de base radial (Specht, 1991), conforme mostra a figura 4.

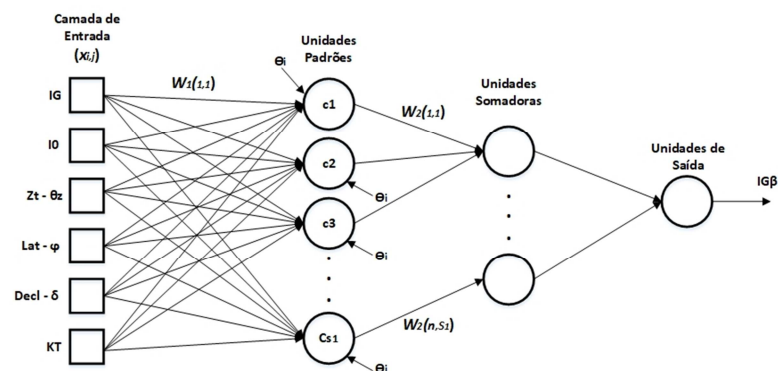


Figura 4. Diagrama mostrando a arquitetura utilizada da General Regression Neural Network (GRNN), adaptado de Specht (1991).

Aquisição da base de dados de treino

Os dados da irradiação global na superfície horizontal (IG_H) e da irradiação global no plano inclinado de $22,85^\circ$ (IG_β), ambos na partição horária, foram obtidos na Estação de Radiometria Solar na

Faculdade de Ciências Agrônômicas (FCA) da Universidade Estadual Paulista (UNESP) no período de 10/4/1998 a 31/08/2001. As medidas instantâneas da radiação global na horizontal foram obtidas com um piranômetro EPPLEY-PSP com fator de calibração de $7,45\mu\text{V}/\text{Wm}^{-2}$, linearidade de $\pm 0.5\%$ de 0 a 2800 Wm^{-2} , resposta para normalização do efeito cosseno de: $\pm 1\%$ para ângulo zenital (Z_T) de 0 a 70° e de $\pm 3\%$ para (Z_T) de 70 a 80° , tempo de resposta de 1s e resposta à temperatura de $\pm 1\%$ de 20°C a 40°C . As medidas instantâneas da radiação global no plano inclinado foram obtidas piranômetros CM3 da Kipp & Zonen, que possuem uma sensibilidade de resposta de $\pm 10\text{-}35\mu\text{V}/\text{Wm}^{-2}$, tempo de resposta de 18s, resposta a temperatura de $\pm 1,0\%$ para a faixa de -40°C a 80°C e desvios para o efeito cosseno de $\pm 2\%$ ($0 < Z_T < 80^\circ$). Os dados foram analisados e valores discrepantes provocados por erros de leitura na aquisição de dados foram eliminados. Os dados do índice de transmissividade (K_T) foram normalizados eliminando-se valores menores que 0 e maiores que 1; já os dados do ângulo zenital (Z_T) tiveram rejeitados os valores maiores que 80° , de forma a permanecer apenas os valores do foto período entre 7h30min e 17h30min; e os valores da irradiação global na superfície horizontal (I_{GH}) foram normalizados eliminando-se os valores maiores que $5,5\text{ MJ}/\text{m}^2$. A estação está instalada no município de Botucatu, estado de São Paulo/Brasil com coordenadas $22^\circ 53'\text{S}$ de latitude, $48^\circ 26'\text{W}$ na longitude e altitude de 786m; e de acordo com Teramoto e Escobedo (2012) a classificação climática de Köppen para o clima da região de Botucatu é Cwa, com verão quente e úmido e elevada precipitação, inverno frio e seco.

Softwares utilizados

A ferramenta utilizada para as análises estatísticas foi o Microcal Origin[®], e a ferramenta utilizada para as estimativas de ($I_{G\beta}$) com redes neurais foi a Matrix Laboratory denominada simplesmente Matlab[®].

Seleção das variáveis

O critério adotado para determinação das variáveis de entrada das redes neurais artificiais (RNA), foi com base na disponibilidade das variáveis e na influência que as mesmas podem proporcionar na estimativa, além das indicações apresentadas na bibliografia adotada. Tomou-se cuidado para evitar excesso de variáveis, de forma a prejudicar os resultados de desempenho da rede. Com base nesses critérios, as variáveis adotadas foram: a irradiação global no plano horizontal (I_G), declinação solar (δ), irradiação no topo da atmosfera horizontal (I_0), ângulo do zenital (θ_z), índice de claridade atmosférica ou fração da global horizontal (K_T) e latitude (ϕ). Destaca-se que todas as variáveis utilizadas foram calculadas a partir de (I_G).

Dentre as variáveis selecionadas para este estudo (tabela 1), destacamos a declinação (δ) que representa a posição da Terra a partir do Sol e depende do número do dia do ano. Essa variável tem relevância para estimativa da irradiação global no plano inclinado ($I_{G\beta}$), pois a posição do sol tem influência sobre a quantidade e a qualidade da irradiação solar, ou seja, quando o sol está alto no céu, o ângulo zenital é baixo, a irradiação solar é máxima (considerando céu claro) e como o caminho óptico é mínimo, portanto, a irradiação incidente é menos absorvida. Esta posição é caracterizada pelo ângulo do zenital (θ_z). O índice de claridade atmosférica ou fração da global (K_T) também é uma variável importante para o treino, pois dependendo das condições do céu, os valores de irradiação solar na superfície inclinada podem corresponder aos valores da irradiação solar na superfície horizontal, por esse motivo o índice (K_T) foi utilizado para considerar as condições de céu nas variáveis de treinamento. A irradiação no topo da atmosfera (I_0) também foi utilizada como variável de entrada, pois de acordo com Notton et al. (2012) esta variável deve ser considerada porque é usada como referência da irradiação máxima disponível em um determinado momento e também é utilizada em todos os modelos empíricos para estimar a irradiação solar.

Treinos das RNA

As redes neurais artificiais (RNA) foram treinadas nas arquiteturas MLP e GRNN. Os scripts de treinamento foram desenvolvidos no MATLAB. As variáveis de entrada foram distribuídas em 8 arranjos conforme mostra a tabela 1. As combinações dos arranjos foram determinadas de forma a promover uma avaliação da influência de cada variável nos resultados das estimativas.

| Modelos | Variáveis de Entrada | | | | | Variável Estimada |
|---------|----------------------|----------------------|------------|-----------|---------------|-------------------|
| | Variável Medida | Variáveis Calculadas | | | | |
| RNA1 | Ig | Io | | | | IG β |
| RNA2 | Ig | Io | θ_z | KT | | |
| RNA3 | Ig | Io | δ | KT | | |
| RNA4 | Ig | Io | φ | KT | | |
| RNA5 | Ig | Io | θ_z | φ | | |
| RNA6 | Ig | Io | θ_z | φ | δ | |
| RNA7 | Ig | Io | θ_z | φ | δ KT | |
| RNA8 | Ig | Io | θ_z | δ | KT | |

Tabela 1: Combinações de treinamento da RNA.

Treino da MLP

A MLP foi treinada usando o algoritmo de aprendizagem supervisionado Bayesiano Backpropagation (BP) implementado no Matlab. Neste algoritmo o valor de cada camada de saída é usado para atualizar o peso da camada anterior. O BP aprende de forma iterativa do processamento conjunto de exemplos de treinamentos de dados, que atualiza os valores de peso e dos *bias* de acordo com a otimização Bayesiano. O ajuste de peso na iteração depende da taxa de aprendizado. A taxa de aprendizagem durante cada interação controla o tamanho das mudanças do *bias*. Para determinar o número ideal de neurônios para este estudo, utilizou-se como parâmetro a obtenção do menor RMSE%. Os testes foram realizados iniciando com um pequeno número de neurônios e 1 camada, aumentando gradualmente o tamanho da rede até que a precisão desejada fosse alcançada. Após os testes determinou-se a melhor configuração para o treino da rede MLP com 1 camada oculta, 50 neurônios na camada e 50 épocas (tabela 2).

Destaca-se que algumas condições devem ser observadas para o treinamento da rede, sendo elas: a especificação do tamanho da rede ou o número de camadas e o número de neurônios em cada camada. Um número insuficiente de neurônios causa dificuldades de aprendizagem, enquanto um número excessivo pode levar a um tempo de treinamento desnecessário sem grandes melhorias nos resultados. (Alam et al. 2009).

| Arquitetura | Função Matlab® | Épocas | Camadas Ocultas | Neurônios |
|-------------|----------------|--------|-----------------|-----------|
| MLP | feedforwardnet | 50 | 1 | 50 |

Tabela 2: Parametrização da Rede MLP

Treino da GRNN

A parametrização da GRNN é basicamente definida por um parâmetro de ajuste (σ) (especificado no algoritmo do matlab como *spread*) deve ser determinado através de experimentação, variando seu valor de forma a chegar no melhor resultado de precisão %RMSE. O *spread* (σ) é um ajuste importante para o treinamento da rede GRNN, e deve se atentar nos resultados para evitar overfitting e underfitting da rede. Um valor de *spread* (σ) maior leva a uma área grande em torno do vetor de entrada onde os neurônios da camada 1 responderão com saídas significativas, porém um valor de *spread* (σ) muito pequeno torna a função de base radial muito íngreme, de modo que o neurônio com o vetor de peso mais próximo da entrada terá uma saída muito maior do que outros neurônios e dessa forma a técnica tende a responder com o vetor de saída associado ao vetor de entrada. Neste trabalho foi determinado através dos testes que o melhor valor de ajustamento do *spread* (σ) é igual a 0,1. (tabela 3)

| Arquitetura | Função Matlab® | Ajuste (σ) |
|-------------|----------------|---------------------|
| GRNN | newgrnn | 0.1 |

Tabela 3: Parametrização da Rede GRNN

Base de dados de validação

Para validação dos modelos treinados, foram geradas uma base de dados de 2 anos, denominadas de Ano Típico (AT) e Ano Atípico (AAT) com dados obtidos a partir da base de dados total (M. SILVA, 2016). A classificação dos anos típicos e atípicos, foi realizada seguindo um critério semelhante ao

processo de seleção do ano meteorológico típico definido pela *World Meteorological Organization* (WMO, 1981). Os resultados foram apresentados na tabela 4.

| | JAN | FEV | MAR | ABR | MAI | JUN | JUL | AGO | SET | OUT | NOV | DEZ |
|-----|------|------|------|------|------|------|------|------|------|------|------|------|
| AT | 2000 | 1999 | 2001 | 2001 | 1998 | 2000 | 1999 | 1999 | 1998 | 1998 | 1999 | 1999 |
| AAT | 1999 | 2001 | 2000 | 2000 | 2001 | 1998 | 2000 | 2001 | 1999 | 1999 | 2000 | 2000 |

Tabela 4. Ano Típico (AT) e Ano Atípico (AAT) obtido na base de dados de março de 1998 a agosto de 2001.

Indicativos Estatísticos

O desempenho dos modelos de estimativas estatístico e redes neurais artificiais foi determinado pela utilização de métodos estatísticos. Para avaliar a precisão dos dados estimados, os índices utilizados foram *Root Mean Square Error* (RMSE), *Relative Root Mean Square Error* (rRMSE) e coeficiente de correlação (R). Uma escala classificatória para os índice rRMSE foi desenvolvida por (Jameson et al., 1991; Li et al., 2013), a qual permite avaliar o desempenho dos modelos de estimativa utilizados: Excelente para $rRMSE < 10\%$; Bom se $10\% \leq rRMSE < 20\%$, aceitável se $20\% \leq rRMSE < 30\%$ e Ruim se $rRMSE \geq 30\%$.

RESULTADOS E DISCUSSÕES

Modelo Estatístico (ME)

Com base nas estimativas realizadas pelo modelo estatístico (ME), usando a equação 2, a qual é baseado na transmissividade atmosférica (K_T) para determinar os valores da irradiação global no plano inclinado ($I_{G\beta}$), e com validações realizadas nas bases de anos típicos (AT) e anos atípicos (AAT) no período de abril de 1998 a agosto de 2001 (mesmo período da estimativa) na partição horária, observa-se no gráfico da figura 5 que os índices de desempenho e precisão da estimativa pelo ME apresentaram resultados excelentes considerano o índice de classificação de (Jameson et al., 1991; Li et al., 2013).




Figura 5: Índices de desempenho estatístico da estimativa pelo modelo estatístico (ME).

Os gráficos de correlação da figura 6 apresenta os resultados das estimativas de $I_{G\beta}$ nas bases dos anos típicos e atípicos. A distribuição dos valores estimados de $I_{G\beta}$ pela equação 2 e dos valores de $I_{G\beta}$ medidos, apresentam concordância linear com a reta de 45° ($r=1$). As retas de ajustes linear em ambas as condições (figura 6a e 6b) demonstra que a equação de estimativa utilizada pode estimar $I_{G\beta}$ com bons valores para os coeficientes de determinação (próximo a 1), sendo eles: para AT: $r^2=0,9854$ e para AAT: $r^2=0,9920$.

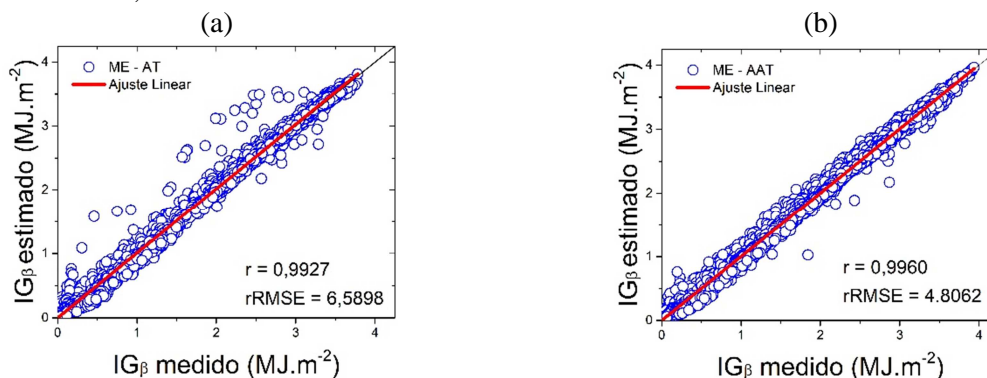


Figura 6: Correlação da estimativa pelo método estatístico para anos típicos e atípicos.

Redes Neurais Artificiais MLP

Nos treinos com a arquitetura de rede MLP, os índices RMSE% (figura 7) que determina a precisão da estimativa, mostram que as combinações RNA 3,6,7 e 8 na base de anos típicos (AT) apresentaram índices de precisão ótimos ou abaixo de 10% (figura 7a). Em todas essas combinações a variável comum é a declinação solar (δ). Na base de anos atípicos (AAT), as combinações RNA 2,3,5,6,7 e 8 apresentaram índices menores que 10% (figura 7b), porém as combinações RNA 3,6,7 e 8 destacam-se com valores de RMSE% abaixo de 4%, devido a inclusão da declinação solar (δ) como variável de entrada. Embora a combinação RNA 8 (5 variáveis de entrada) apresente os melhores resultados numéricos do RMSE% nas bases de anos típicos (RMSE%=5,8801) e atípicos (RMSE%=3,0445), a melhor combinação de treinamento considerando o critério de que uma rede neural artificial deve ter uma estrutura simples (mínimo de variáveis de entrada, mínimo número de camadas ocultas e de neurônios por camada possível), sugere-se que a combinação melhor ajustada é a RNA 3 (4 variáveis de entrada), pois esta apresentou ótimos resultados na estimativa do RMSE% na mesma base de anos típicos (RMSE%=5,9849) e anos atípicos (RMSE%=3,0561).


Para a combinação RNA 3, os indicativos de $r=0,9941$ nos anos típicos e $r=0,9984$ nos anos atípicos mostram que as medidas e as estimativas de $I_{g\beta}$ estão bem correlacionadas (figura 8a)

Redes Neurais Artificiais GRNN

Os resultados dos treinos realizados com a arquitetura GRNN apresentaram algumas diferenças. As combinações que apresentaram os valores de RMSE% abaixo de 10% foram RNA 2,3,5,6,7 e 8 nas bases de anos típicos e anos atípicos (Figuras 7c e 7d). Isso mostra a rede GRNN teve uma melhor capacidade de generalização dos dados estimados quando comparada à rede MLP. A influência da declinação solar (δ) também promoveu melhoras nos resultados com a rede GRNN. Podemos observar que as combinações RNA 3,6 e 7 apresentaram os melhores valores resultados de RMSE%, abaixo de 4% para a base de anos típicos (figura 7c) e abaixo de 3% para a base de anos atípicos (figura 7d). Com a mesma análise da MLP, a combinação que se apresenta como melhor solução para estimar usando GRNN é a RNA 3 que apresentou ótimos resultados na estimativa do RMSE% na base de anos típicos (RMSE%=3,8808) e de anos atípicos (RMSE%=2,6050).

Seguindo a mesma tendência da MLP, os indicativos de $r=0,9903$ para anos típicos e de $r=0,9911$ para anos atípicos mostram que para a GRNN as medidas e as estimativas de $I_{g\beta}$ também se mostram bem correlacionadas (figura 8b)

Esses resultados mostram uma influência da variável declinação solar (δ) nas estimativas da da irradiação global na superfície inclinada ($I_{g\beta}$) de $22,85^\circ$ na latitude de Botucatu/SP/Brasil, utilizando redes MLP e GRNN.






Figura 7: Indicativos estatísticos RMSE% para os anos típicos e atípicos.

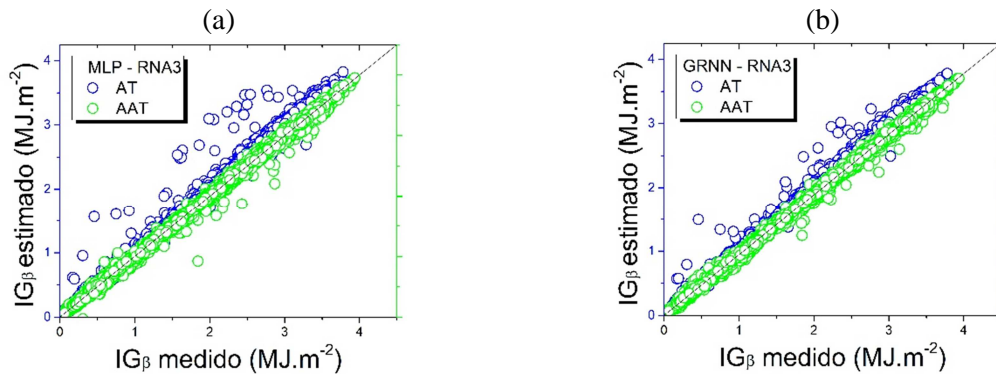


Figura 8: Correlação da estimativa pelas redes neurais artificiais.

Análise de desempenho dos modelo estatístico (ME) e redes MLP e GRNN

A tabela 5 apresenta os resultados das estimativas obtidos pelos modelos de redes neurais com melhor desempenho e os resultados obtidos pelo modelo estatístico.(ME). A arquitetura GRNN apresenta o melhor índice de desempenho RMSE% nas base de anos típicos e atípicos, conforme mostra o gráfico da figura 9. No gráfico da figura 9a observa-se uma diferença maior entre os resultados de RMSE% para os 3 modelos na base de anos típicos (AT). Essa diferença diminui entre os modelos de redes neurais, mas se mantém com relação aos resultados do modelo estatístico (figura 9b).

Os índices de correlação r (figura 9) são muito bons (próximos de 1) em todos os modelos, o que mostra que estão bem ajustados para a estimativa de IG_{β} considerando uma superfície inclinada de $22,85^{\circ}$ com dados de Botucatu-SP/Brasil.

| MODELO | AT (ANOS TÍPICOS) | | | | | | AAT (ANOS ATÍPICOS) | | | | | |
|-------------|-------------------|---------|--------|--------|--------|--------|---------------------|---------|---------|---------|--------|--------|
| | RMSE | RMSE(%) | MBE | MBE(%) | r2 | r | RMSE | RMSE(%) | MBE | MBE(%) | r2 | r |
| ESTATÍSTICO | 0.1235 | 6.5898 | 0.0166 | 0.8845 | 0.9854 | 0.9927 | 0.0931 | 4.8062 | 0.0038 | 0.1948 | 0.9920 | 0.9960 |
| MLP - RNA3 | 0.1114 | 5.9849 | 0.0085 | 0.4582 | 0.9883 | 0.9941 | 0.0588 | 3.0561 | -0.0075 | -0.3902 | 0.9969 | 0.9984 |
| GRNN - RNA3 | 0.0722 | 3.8808 | 0.0089 | 0.4799 | 0.9951 | 0.9975 | 0.0501 | 2.6050 | -0.0068 | -0.3555 | 0.9977 | 0.9989 |

Tabela 5. Índices estatísticos de desempenho para os modelos estatísticos e redes neurais artificiais.




Figura 9: Índices de desempenho estatístico RMSE% e r para os anos típicos e atípicos.

CONCLUSÕES

Considerando os resultados obtidos com o modelo de estimativa estatístico (ME), pôde-se observar que o modelo da equação de estimativa obtida por meio de regressão polinomial apresentou bons resultados nas estimativas. Os valores obtidos dos coeficientes de correlação mostram que o modelo estatístico pode estimar a irradiação global na superfície com inclinação de $22,85^\circ$ ($I_{G\beta}$) para Botucatu com altos coeficientes de determinação r^2 .

Os resultados obtidos com os treinos das redes neurais artificiais (RNA) nas arquiteturas *Multlayer Perceptron* (MLP) e *Generalized Regression Neural Network* (GRNN) se apresentaram com resultados melhores quando comparados aos resultados do modelo estatístico (ME). A bibliografia mostra que os resultados melhores nas estimativas usando RNA, são esperados, considerando uma série de fatores envolvidos para o treinamento das redes, entre os quais a série temporal, quantidade de variáveis de entrada e as possibilidades de ajustamento através da parametrização da estrutura das redes.

Entre os resultados obtidos com as redes GRNN e MLP, destaca-se a GRNN, pois esta apresentou resultados 35% melhores comparados aos da MLP. Resultados como esse mostram que a rede GRNN se apresenta como uma opção viável, e deve-se considerar também o custo computacional (necessidade de hardware vs. tempo de treinamento), onde a GRNN se destacou por ser mais rápida, com tempo de treinamento de 0,44 segundos para a combinação RNA3, quando comparada à MLP que registrou um tempo de treinamento de 11,07 segundos na mesma combinação, ambas em um hardware Intel® I7 com 8GB de memória RAM. Porém a GRNN ainda possui uma bibliografia reduzida em estimativas de variáveis de irradiação solar, e que esta deve ser mais explorada, ao contrário da MLP já está amplamente difundida e possui uma bibliografia farta com estimativas de variáveis da irradiação solar.

REFERÊNCIAS

- Alam S; Kaushik SC; Garg SN. Assessment of diffuse solar energy under general sky condition using artificial neural network. *Applied Energy* 2009;86: 554–64.
- Dahmani, Kahina et al. Estimation of 5-min solar global irradiation on tilted planes by ANN method in Bouzareah, Algeria. *International Conference On Nanoelectronics, Algeria*, set. 2013.
- Escobedo, J. F.; Teramoto, E. T.; Oliveira, A. P. et al. Equações de estimativa das frações solar direta (k_{dh}) e difusa (k_d) em função do índice de claridade (k_t) e razão de insolação (n/N), *Avances en y Medio Ambiente*, Vol. 16, 2012.
- Hay, J. E. Calculation of monthly mean solar radiation for horizontal and inclined surfaces. *Solar Energy*, Kidlington, v. 23, n. 4, p. 301-307, 1979.
- Iqbal M. An introduction to solar radiation. Canada: Academic Press; 1983 [ISBN 0-12-373752-4; 1983].
- Jamieson, P. D.; Porter, J. R.; Wilson, D. R. A test of the computer simulation model ARC - WHEAT1 on wheat crops grown in New Zealand. *Field Crops Research*, v.27, 337-350, 1991. LI, M.; TANG, X.; WU, W. et al. General models for estimating daily global solar radiation for different solar radiation zones in mainland China. *Energy Conversion and Management*, v.70, 139-148, 2013.
- Jiang, Y. (2009). Computation of monthly mean daily global solar radiation in China using artificial neural networks and comparison with other empirical models. *Energy*, v.34, p.1276-1283.
- Jimenez, J.I.; Castro, Y. Solar radiation on sloping surfaces with different orientations in Granada, Spain. *Solar Energy*, v.28, p.257-262, 1982.
- Koronakis, P.S. On the choice of the angle of tilt for south facing solar collectors in the Athens basin area. *Solar Energy*, v.36, p.217-225, 1986.
- Krishnaiah, T; Srinivasa, Rao S.; Madhumurthy, K; Reddy, K.S. . Neural Network Approach for Modelling Global Solar Radiation. *Journal of Applied Sciences Research*, 2007.
- Liu, B. Y. H.; Jordan, R. C. (1960). The interrelationship and characteristic distribution of direct, diffuse and total solar radiation. *Solar Energy*, v.3, p.1-19
- M. Silva, Maurício Bruno Prado da. Estimativa da irradiação solar global pelo método de angstrom-prescott e técnicas de aprendizado de máquinas. 2016. 86 f. Dissertação (mestrado) - curso de

- agronomia (irrigação em drenagem), Universidade Estadual Paulista “Júlio de Mesquita Filho” FCA-Botucatu, 2016.
- Muzathik AM, Ibrahim MZ, Samo KB, Wan Nik WB. Estimation of global solar irradiation on horizontal and inclined surfaces based on the horizontal measurements. *Energy* 2011;36:812e8.
- McCulloch, W. S.; Pitts, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. *Bulletin of Mathematical Biophysics*, New York, US, v. 5: p. 115 - 133, 1943.
- Notton, Gilles; Paoli, Christophe; Vasileva, Siyana; Nivet, Marie Laure; Canaletti, Jean-Louis; Cristofari, Christian. Estimation of hourly global solar irradiation on tilted planes from horizontal one using artificial neural networks. Elsevier - Scencedirect: *Energy*, Bulgaria, fev. 2012.
- Notton, G.; Cristofari, C.; Poggi, P. Performance evaluation of various hourly and daily slope irradiation models using Mediterranean experimental data of Ajaccio. *Energy, Conversion and Management*, v.47, p.147-173, 2006.
- Olmo FJ, Vida J, Foyo I, Castro-Diez Y, Alabos-Arboledas L. Prediction of global irradiance on inclined surfaces from horizontal global irradiance. *Energy* 1999;24:689e704.
- Perez, R.; Stewart, R.; Arbogast, C.; Seals, R.; Scott, T. An anisotropic hourly diffuse radiation model for sloping surfaces, description, performance, validation, site dependency evaluation. *Solar Energy*, Kidlington, v. 36, n. 6, p. 481-497, 1986.
- Razafiarison, I.A.J.; Andriazafimahazo, L.F.G; Ramamonjisoa, B.O.A; Zeghmati, B. . Using multilayered neural networks for determining global solar radiation upon tilted surface in Fianarantsoa Madagascar. *Energy, Conversion and Management*, v.47, p.147-173, 2006.
- Revfeim, K.J.A. A simple procedure for estimating global daily radiation on any surface. *Journal of Applied Meteorology*, v.17, p.1126-1131, 1978.
- Rehman. S.; Mohandes, M. Artificial neural network estimation of global solar radiations in air temperatura and relative humidity, *Energy Policy* 2008;36: 571–6.
- Scolar, José et al. Estimativa da Irradiação total sobre uma superfície inclinada a partir da irradiação global na horizontal. *Revista Brasileira de Geofísica*, Botucatu, v. 21, n. 1, p.249-258, mar. 2003.
- Souza, A.P. ; Escobedo, J. F. ; DAL PAI, A. ; GOMES, E. N. . Estimativas das componentes da radiação solar incidentes em superfícies inclinadas baseadas na radiação global horizontal. *Revista Brasileira de Engenharia Agrícola e Ambiental (Impresso)* , v. 15, p. 277-288, 2011.
- Silva, Ivan Nunes da; Spatti, Danilo Hernane; Flauzino, Rogério Andrade. *Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático*. São Paulo: Artliber Editora Ltda., 2010. 399 p.
- Souza, A.P. ; Escobedo, J. F. ; DAL PAI, A. ; GOMES, E. N. . Estimativa da radiação global incidente em superfícies inclinadas por modelos isotrópicos e índice de claridade . *Revista Pesquisa Agropecuária Brasileira*, Brasília , v. 45, n. 4, p. 339-350, abr 2010.
- Specht, Donald F. A General Regression Neural Network *IEEE TRANSACTIONS ON NEURAL NETWORKS*, Palo Alto Ca - US, v. 2, n. 6: p. 568 - 576, 11/1991.
- Turco, J.E.P.; Rizzatti, G.S. Avaliação de modelo matemático para estimar a radiação solar incidente sobre superfícies com diferentes exposições e declividades. *Engenharia Agrícola*, v.26, p.257-267, 2006.
- World Meteorological Organization. *Meteorological Aspects of the utilization of Solar Radiation as an Energy Source*. World Meteorological Organization Technical Note No. 172, WMO-No. 557, Geneva, pp. 298., 1981.

ESTIMATION OF HOURLY GLOBAL SOLAR IRRADIATION IN INCLINED SURFACE FOR THE BOTUCATU CITY IN SP / BRAZIL USING STATISTICAL MODEL AND ARTIFICIAL NEURAL NETWORK ARCHITECTURES MLP AND GRNN

ABSTRACT: In this work, a study was carried out with three estimation models to estimate the global irradiance incident on a slope surface of 22.85° (IG_β), from the data of the global solar irradiation on the horizontal surface (IG_H) measured in the hourly partition from April 1998 to August 2001 at the climatological station of the Faculty of Agronomic Sciences of UNESP in the Butucatu / SP / Brazil campus, being them: the statistical model (ME) (Liu & Jordan, 1963) and the artificial neural network (ANN) models, Perceptron Multicamadas (MultiLayer Perceptron - MLP) using Backpropagation and Generalized Regression Neural Network (GRNN) algorithms. The classical regression model and the trained network models were validated in two databases classified as typical years (AT) and atypical

years (AAT). For training of the networks, training sessions were carried out with 8 combinations of astronomical and geographic variables, measured and calculated. The statistical performance evaluation indices (rMSE%) obtained in the classic model were: $r_{AT} = 0.9927$, $RMSE\%_{AT} = 6.5898$ and $r_{AAT} = 0.9960$, $RMSE\%_{AAT} = 4.8062$, the indices obtained with the best combination (RNA3) for the MLP network were: $r_{AT} = 0.9941$, $RMSE\%_{AT} = 5.9849$ and $r_{AAT} = 0.9984$, $RMSE\%_{AAT} = 3.0561$, and the indices obtained with the best combination RNA3) for the GRNN network were: $r_{AT} = 0.9975$, $RMSE\%_{AT} = 3.8080$ and $r_{AAT} = 0.9989$, $RMSE\%_{AAT} = 2.6050$. The results show that the three models presented good results in the IG_{β} estimates from the measured data of the IG_H , but among the RNA models, the results obtained by the GRNN in the IG_{β} estimation stand out.

Keywords: Solar radiation, Artificial Neural Networks; Prediction