

## **ESTIMATIVA DA FRAÇÃO TRANSMITIDA DA IRRADIAÇÃO DIFUSA HORÁRIA POR MEIO DE MODELO ESTÁTISTICO E REDE NEURAL DO TIPO REGRESSÃO GENERALIZADA (GRNN).**

**E. L. Bassetto<sup>1</sup>, J. F. Escobedo<sup>2</sup> A. Dal Pai<sup>3</sup>.**

<sup>1</sup>Departamento de Engenharia Elétrica – UTFPR – Cornélio Procópio/PR/Brasil

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

<sup>3</sup>Departamento de Bioprocessos e Biotecnologia – FCA/UNESP – Botucatu/SP/Brasil

Tel. + 554399976-1739 e-mail: [bassetto@utfpr.edu.br](mailto:bassetto@utfpr.edu.br)

*Recibido 25/07/17, aceptado 26/09/17*

**RESUMO:** É proposto no trabalho dois modelos de estimativas para fração transmitida da irradiação difusa ( $K_d$ ) em função da transmissividade da irradiação global ( $K_t$ ) na partição horária: estatístico e a técnica de Redes Neurais Artificiais do tipo Regressão Generalizada (GRNN). O primeiro, usando somente  $K_t$  como referência e o segundo, uma combinação de seis variáveis astronômicas e meteorológicas. A base dos dados, medida no período de 2000 a 2006, foi utilizada para a obtenção da equação estatística e no treinamento da rede GRNN nas combinações propostas. Na validação dos modelos, foram utilizadas duas bases de dados da irradiação solar difusa, denominadas de anos típico (AT) e atípico (AAT), ambas obtidas a partir da base de dados total de anos. A equação de estimativa foi obtida por regressão polinomial de 4º ordem com coeficiente de correlação  $r = 0,90$ . Na comparação entre a estimativa e a medida do modelo estatístico, obteve-se os indicativos estatísticos das duas condições de validação:  $r_{AT}=0.90$  e  $r_{AAT}=0.89$ ;  $rRMSE_{AT} = 30.55\%$  e  $rRMSE_{AAT} = 27.97\%$ , respectivamente. O desempenho da rede GRNN foi melhor nas combinações 2 a 6 em função da entrada de cada variável astronômica e meteorológica, obtendo-se os indicativos estatísticos  $r_{AT}=0.92$  e  $r_{AAT}=0.91$ ;  $rRMSE_{AT} = 28.04\%$  e  $rRMSE_{AAT} = 26.00\%$  para combinação 2, até os valores de  $r_{AT}=0.99$  e  $r_{AAT}=0.99$ ;  $rRMSE_{AT} = 7.85\%$  e  $rRMSE_{AAT} = 8.21\%$  para combinação 6, nas duas condições de validação, respectivamente. A comparação dos indicativos estatísticos mostram que a rede GRNN a partir da combinação 2 que tem  $K_t$  e a irradiação de topo ( $H_0$ ) como entrada, possui melhor desempenho que o modelo estatístico em estimar  $K_d$ .

**Palavras - chave:** Radiação solar; Radiação difusa; Rede neural de regressão generalizada.

### **INTRODUÇÃO**

A radiação difusa é componente da radiação solar global, proveniente da interação da radiação solar com constituintes atmosféricos (vapor d'água, moléculas de gases e aerossóis). O seu conhecimento tem contribuição significativa em diversas áreas, tais como na climatologia e meteorologia, relacionada aos estudos adversos do clima, na agronomia, voltada ao desenvolvimento e produtividade de culturas e na engenharia, associada aos processos de conversão de energia. Para isto, informações das medidas da radiação difusa por meio de séries temporais e/ou modelos de estimativa, é importante pois possibilita a verificação de sua disponibilidade em função do tempo em uma determinada localidade (Escobedo et al. 2013b; Muneer, 2004; Ruiz-Arias et al. 2010; Teke et al. 2015).

A obtenção da radiação difusa pode ser da forma indireta ou direta. Indiretamente a radiação difusa é obtida pela diferença entre a radiação global e a radiação direta na horizontal. Diretamente, pode-se utilizar um sistema de rastreamento solar, onde um disco é posicionado acima de um sensor (piranômetro), sendo que, em uma das montagens, o disco translada, e na outra, o disco rotaciona no eixo da declinação solar, que tem a função de barrar toda radiação direta incidente (Drummond (1956)

---

<sup>1</sup> Engenheiro Eletricista, Doutorando em Energia na Agricultura, FCA/UNESP/Botucatu.

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

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

e Robinson e Stoch (1964)). Ou então, considerado o mais viável financeiramente, o anel de sombreamento, onde um sensor (piranômetro) é posicionado à sombra de um anel fixo, que translada paralelamente ao plano de horizonte local em uma base móvel (Melo e Escobedo, 1994; Dal Pai et al, 2016).

Apesar de sua importância, a radiação difusa é pouco medida quando comparada com outras variáveis meteorológicas. O custo de aquisição dos sensores, medidas diárias e manutenções periódicas são fatores determinantes e limitantes para a pouca disponibilidade de medidas (Bakirci, 2015; Khorasanizadeh et al. 2016; Jamil e Siddiqui, 2017). Com a escassez de medidas confiáveis de radiação difusa e ao elevado custo de aquisição, muitos pesquisadores tem avaliado e proposto modelos matemáticos capazes de estimar esta radiação, utilizando-se de medidas de radiação conhecidas, como a radiação global, que estão mais facilmente disponíveis nas estações meteorológicas.

São encontrados na literatura diversos modelos estatísticos de estimativa da radiação difusa, sendo de Liu e Jordan (1960) um dos primeiros trabalhos que relacionou a radiação difusa com a radiação global. O modelo correlaciona a fração da radiação difusa ( $K_d$ ) em função da fração da radiação global transmitida ( $K_t$ ) ou índice de claridade. Outros trabalhos relacionaram essas frações, através de modelos lineares e polinomiais, em partições horária, diária e mensal, utilizando uma variável como referência (Orgill e Hollands, 1977; Collares-Pereira e Rabl, 1979; Reindl et al. 1990; Oliveira et al. 2002; Jacovides et al. 2006; Souza et al. 2011), como também outros com mais de uma variável em seus modelos (Furlan et. al. 2102; Kuo et al. 2014a; Boland et al. 2001; Li et al. 2011).

Embora os modelos de estimativa, através da fração da radiação, possam normalizar as medidas e minimizar os efeitos astronômicos e da posição geográfica da origem dos modelos, recentemente outras técnicas de estimativa da radiação difusa estão sendo utilizadas, como as Redes Neurais Artificiais (RNA), Máquinas de Vetores de Suporte (SVM), Lógica Fuzzy e NeuroFuzzy (ANFIS). Essas técnicas permitem solucionar problemas complexos e de forma dinâmica estimar a radiação difusa, a partir de um conjunto de entrada com variáveis astronômicas, geográficas e meteorológicas, apresentando resultados satisfatórios comparados aos modelos tradicionais (Escobedo et al., 2006; Elminir et al. 2007; Jiang, 2008; Lazarevska e Trpovski, 2011; Yildiz et al. 2013; Khatib, 2015; Kumar et al. 2015; Wang et al. 2016; Azimi et al. 2016; Soares et al., 2004; Santos et al., 2016).

Diante das considerações e da importância na estimativa da fração da radiação difusa transmitida no plano horizontal, o objetivo deste trabalho é comparar dois modelos, o estatístico e a técnica de Rede Neural Artificial de Regressão Generalizada (GRNN) com base em dados astronômicos, geográficos e meteorológicos da cidade de Botucatu/SP.

## **MATERIAL E MÉTODO**

### *Local, instrumentação e medidas*

Os dados foram obtidos entre Janeiro/2000 a Dezembro/2006 na Estação Meteorológica do Lageado, do Departamento de Engenharia Rural da Faculdade de Ciências Agrônomicas da UNESP, campus Botucatu, São Paulo (latitude 22°50'48,14" S, longitude 48°25'53,52" W e altitude de 786 m). Pela classificação de Koppen, o clima é do tipo Cwa, temperado úmido, com inverno frio e seco (junho-agosto) e verão quente e úmido (dezembro-fevereiro) e elevada precipitação (Escobedo et al. 2011; Teramoto e Escobedo, 2012). Os dados utilizados compreendem medidas de radiação global, difusa e de ondas longas, além de valores calculados em função das medidas e de outros parâmetros geográficos e meteorológicos. As medições para radiação global foram realizadas por um piranômetro Eppley – PSP e da radiação difusa por um piranômetro Eppley-PSP com anel de sombreamento, método proposto por Melo e Escobedo (1994). As medidas de radiação de ondas longas foram realizadas através de um pirgeômetro, modelo CG1 da Kipp & Zonen e a aferição dos equipamentos foi realizada periodicamente pelo método comparativo. Após a medição dos dados, foi realizada uma análise de consistência e de valores discrepantes, adotando-se procedimentos similares aos praticados na literatura, como a limitação do ângulo zenital e da fração transmitida da radiação global e difusa (De Miguel et al. 2001; Lopez et al. 2004; Younes et al. 2005; Ruiz-Arias et al. 2010; Ihia et al. 2015; Pashiardis e Kalogirou et al. 2016).

### *Procedimento metodológico*

A metodologia está dividida em duas partes, sendo a primeira estimar  $K_d$  utilizando modelo estatístico baseado na proposta de Liu e Jordan (1960) tendo como referência  $K_t$  e a segunda parte, em estimar

$K_d$ , através da Rede Neural Artificial do tipo Regressão Generalizada utilizando como entrada, variáveis astronômicas e meteorológicas em seis combinações.

*Modelo estatístico (ME)*

O modelo estatístico proposto (ME) utiliza a relação entre  $K_d$  e  $K_t$ , sendo  $K_d = H_d/H_g$ , a fração da irradiação difusa transmitida, onde  $H_d$  é a irradiação difusa e  $H_g$  é a irradiação global e  $K_t = H_g/H_0$ , a fração da irradiação global transmitida, conhecida com índice de claridade ou transmissividade atmosférica, onde  $H_0$  é a irradiação de topo da atmosfera. Para estimativa de  $K_d$ , vários modelos foram desenvolvidos, sendo alguns de terceira e quarta ordem, com apenas uma variável (Oliveira et al. 2002 e Jacovides et al. 2006). Neste trabalho, na obtenção do modelo estatístico (ME) a equação de estimativa é ajustada por regressão polinomial na partição horária utilizando toda a base de dados.

*Rede Neural do Tipo Regressão Generalizada (GRNN)*

A rede neural do tipo Regressão Generalizada (GRNN) possui grande capacidade de generalização, assim como outras redes, com aplicação em diversos processos, como no ajuste de curvas ou aproximações de funções (Specht, 1991). A arquitetura da rede, similar a de um neurônio humano (Haykin, 2001), é composta de duas camadas, a primeira chamada de padrão e a segunda de somadora. 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 Figura 1. As entradas da rede ( $x$ ) fornecem à camada padrão as variáveis (vetor) de entrada da rede, que posicionam-se em um determinado centro (cluster), que, quando um novo vetor entra nesta rede, tem sua posição subtraindo-se do vetor que foi armazenado ao centro da função gaussiana (Equação 1).

$$a(i) = (x' - x_i)^T * (x' - x_i) \quad i = 1, \dots, n. \tag{1}$$

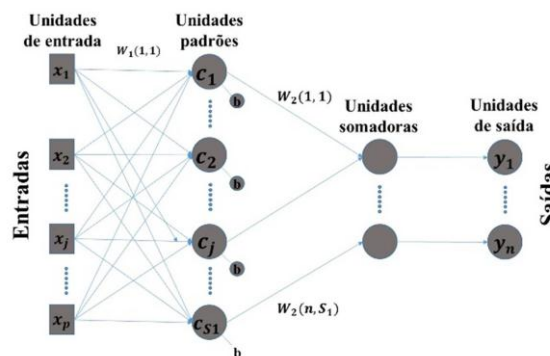


Figura 1: Arquitetura da GRNN. Adaptado de Specht, 1991.

Após o incremento dos vetores de entrada, os valores absolutos dessa diferença são somados e alimentados na função de ativação não linear (exponencial) na camada padrão (Equação 2).

$$b(i) = \exp\left(\frac{-0,8326^2 * a(i)}{a^2}\right) \quad i = 1, \dots, n. \tag{2}$$

Na sequência a saída desta camada é encaminhada para a camada somatória, que realizam o somatório do produto entre o vetor peso ( $d$ ) e o vetor obtido na saída da unidade padrão ( $b$ ) e o somatório dos pesos ( $d$ ). Equação 3 e 4.

$$c(i) = \sum_{j=1}^n y_{j,i} * b_i \quad i = 1, \dots, n. \text{ e } j = 1, \dots, ns. \tag{3}$$

$$d(i) = \sum_{i=1}^n b_i \quad i = 1, \dots, n. \tag{4}$$

Por fim, as saídas dividem cada resultado da camada da soma pelo somatório total de todas as unidades da soma (Equação 5).

$$\hat{y}(i) = \frac{c_i}{d} \quad j = 1, \dots, ns. \tag{5}$$

Mais detalhes da arquitetura e do funcionamento da rede podem ser obtidos na literatura em Specht (1991) e Hansen e Mersevy (1996).

Para rede neural do tipo Regressão Generalizada (GRNN) foi desenvolvido um algoritmo para treinamento e outro para validação da estimativa, e processado através do *software* MATLAB®.

Para treinamento da rede utilizou-se a função *newrgmn* do mesmo software de processamento, em que os parâmetros aplicados a rede são dependentes somente dos dados de entrada, de saída e do ajustamento ou *spread* ( $a$ ). Este parâmetro foi definido comparando-se as curvas de dispersão gerada pelos valores estimados da saída da rede GRNN, da curva gerada pelos valores estimados do modelo estatístico (ME), utilizando as mesmas variáveis de entrada ( $K_t$  e  $K_d$ ), e que apresentavam o menor erro quadrático médio, que neste caso foi de 0.1. Definido estes parâmetros, são propostas as combinações das variáveis de entrada conforme Tabela 1.

	Variáveis: Astronômica					Meteorológica	
	de entrada:					de saída	
	$K_t$	$H_0$	$H_g$	$H_{wa}$	decsol	nebul	$K_d$
1	$K_t$						$K_d$
2	$K_t$	$H_0$					$K_d$
3	$K_t$	$H_0$	$H_g$				$K_d$
4	$K_t$	$H_0$	$H_g$	$H_{wa}$			$K_d$
5	$K_t$	$H_0$	$H_g$	$H_{wa}$	decsol		$K_d$
6	$K_t$	$H_0$	$H_g$	$H_{wa}$	decsol	nebul	$K_d$

Tabela 1: Variáveis de entrada e combinações na partição horária

$K_t$ : fração transmitida da irradiação global;  $H_0$ : irradiação no topo da atmosfera;  $H_g$ : irradiação global;  $H_{wa}$ : irradiação de ondas longas atmosférica; decsol: declinação solar; nebul: nebulosidade; e  $K_d$ : fração transmitida da irradiação difusa.

Os dados de  $K_d$  e  $K_t$ , foram obtidos através de medidas realizadas das irradiações global ( $H_g$ ) e difusa ( $H_d$ ). A irradiação no topo da atmosfera ( $H_0$ ) foi calculada de acordo com equações descritas em Iqbal (1983), e utilizadas por vários pesquisadores (Souza et al, 2005; Duffie e Beckman, 2013; e Santos, 2016), assim como a declinação solar ( decsolar). Para calcular a nebulosidade (nebul) utiliza-se a equação (6), que expressa a fração do número de horas que o sol fica encoberto por nuvens no dia, onde  $n/N$  é a razão de insolação,  $n$  é o brilho solar e  $N$  é o fotoperíodo, intervalo entre o nascer e o por do sol:

$$\dots\dots\dots nebul = 1 - \frac{n}{N} \dots\dots\dots (6)$$

Nesse trabalho, para calcular a nebulosidade horária, foi necessário integrar as medidas da irradiância direta ( $I_b$ ) por hora, a partir de medidas feitas a cada cinco minutos, no período analisado.

A partir destas medidas, tiradas da média das medidas realizadas a cada 5 segundos pelo pireliômetro, foi possível calcular a proporcionalidade das medidas horária, da integração da irradiância dos valores abaixo de  $120 \text{ W/m}^2$ . Conforme a WMO (2008), em seu guia de instrumentos meteorológicos e métodos de observação, este valor foi adotado com limiar para o brilho do sol, ou seja, para valores inferiores a esse, considera-se sem insolação ou “nebuloso”.

*Base de dados organizadas para validação do modelo estatístico e da rede neural*

Para validação do modelo estatístico e da rede neural foram organizadas duas base de dados denominadas por Ano típico (AT) e Ano atípico (AAT). Na formação destas bases foram realizadas uma análise estatística, da média do valor e do intervalo de variação do desvio padrão da irradiação difusa de cada mês de toda a série (Escobedo et al. 2013a). Na sequência, foi selecionado para cada mês de toda a série os valores mais próximos da média tanto para cima com para baixo, como Ano típico (AT) e os mais afastados tanto para cima com para baixo, como Ano atípico (AAT). Conforme descrito, esta seleção dos meses que constituem um Ano Típico (AT) é similar ao processo de seleção de um Ano Meteorológico Típico (WMO, 1981). Na Tabela 2 são apresentados os meses que constituem um Ano típico (AT) e um Ano atípico (AAT) de toda a série.

		Meses											
		Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Ano	Típico	2003	2000	2001	2001	2000	2001	2005	2001	2006	2006	2005	2001
	Atípico	2002	2003	2000	2004	2004	2002	2004	2000	2005	2005	2001	2005

Tabela 2: Base que constitui o Ano típico (AT) e Ano atípico (AAT) de jan. 2000 a dez. de 2006

Observa-se na Tabela 2 em destaque, que para o mês de Janeiro, o AT foi 2003, enquanto que Julho foi 2005. Nestes dois meses os valores das irradiações médias entre os anos praticamente coincidiram com os valores das irradiações médias do ano, diferentemente do AAT, onde os valores das irradiações médias do ano estão mais distantes da média.

#### Indicativos Estatísticos

Para analisar os resultados encontrados com o modelo estatístico (ME) e a rede neural (GRNN) foram utilizados os indicadores **rRMSE**, raiz quadrada do erro quadrático médio (Root mean square error) e **r**, coeficiente de correlação (Willmott, 1981; Stone, 1993; Escobedo et al. 2011; Santos et al. 2014). Na avaliação do indicador rRMSE, uma escala classificatória foi proposta com diferentes intervalos como apresentado na Tabela 3 (Jameson et al., 1991; Heinemann et al., 2012).

Excelente se:	Bom se:	Aceitável se:	Pobre se:
$rRMSE < 10\%$	$10\% \leq rRMSE < 20\%$	$20\% \leq rRMSE < 30\%$	$rRMSE \geq 30\%$

Tabela 3: Escala classificatória do indicador estatístico

## RESULTADOS E DISCUSSÃO

### Modelo estatístico.

Por meio da dispersão dos pontos obtidos do modelo, é mostrada na Figura 2.a) uma correlação significativa entre a fração da irradiação difusa transmitida ( $K_d$ ) com a fração da irradiação global transmitida ( $K_t$ ) na partição horária. A correlação das frações transmitidas na partição horária, não é linear, sendo que a curva gerada apresenta uma similaridade em grande parte dos trabalhos (Erbs et al. 1982; Chandrasekaran e Kumar, 1994; Soares et al. 2004) . O modelo (ME) obtido, apresenta coeficiente de correlação de  $r = 0.90$ . A equação de estimativa (7) foi ajustada por regressão polinomial de 4º ordem entre as correlações de  $K_d$  e  $K_t$ , tendo em vista o ajuste dos pontos do gráfico apresentarem os melhores indicadores.

$$K_d = 0.92546 + 1.1164K_t - 4.90289K_t^2 + 1.46791K_t^3 + 1.67489K_t^4 \quad (7)$$




Figura 2: a) Curva de dispersão de  $K_t$  em relação a  $K_d$  com todos os dados; curva de dispersão de  $K_d$  com dados de validação e valor estimado para: b) Ano típico (AT); c) Ano atípico.

A validação com o Ano típico (AT) não mostrou-se satisfatória, como pode ser observado pelo seu indicador estatístico e apresentado na Tabela 4, onde o valor  $rRMSE_{MEAT} = 30.55\%$ , ser maior que o aceitável ( $rRMSE > 30\%$ ), mesmo com um coeficiente de correlação elevado com um valor de  $r_{MEAT} = 0.89$ .

Modelo	Variável de entrada	Variável de saída	Topologia e/ou ajustamento	Período de validação - jan/2000 a dez/2006			
Partição: HORÁRIA							
				Ano Típico - AT		Ano Atípico - AAT	
				rRMSE	r	rRMSE	r
<b>Modelo empírico</b>							
Modelo clássico - ME	Kt	Kd	Regressão linear	30.55	0.90	27.97	0.89
<b>Redes Neurais</b>							
<b>GRNN - Regressão Generalizada</b>				rRMSE	r	rRMSE	r
GRNN 1	Kt	Kd	0.1	31.86	0.89	29.38	0.88
GRNN 2	Kt Ho	Kd	0.1	28.04	0.92	26.00	0.91
GRNN 3	Kt Ho Hg	Kd	0.1	25.30	0.93	23.10	0.93
GRNN 4	Kt Ho Hg Hwa	Kd	0.1	24.12	0.94	22.38	0.93
GRNN 5	Kt Ho Hg Hwa decsol	Kd	0.1	15.70	0.97	14.32	0.97
GRNN 6	Kt Ho Hg Hwa decsol nebul	Kd	0.1	7.85	0.99	8.21	0.99

Tabela 4: Indicativos estatísticos do modelo clássico e da rede na partição horária

Isto mostra uma grande variabilidade da fração transmitida da radiação difusa ( $K_d$ ), para um mesmo valor da fração transmitida da radiação global ( $K_t$ ), como pode ser visto na Figura 2.b). Com esta mesma tendência, na validação com o Ano atípico (AAT), o resultado do  $rRMSE_{ME_{AAT}} = 27.97\%$ , mostra-se aceitável ( $20\% < rRMSE < 30\%$ ), e com coeficiente de correlação no valor de  $r_{ME_{AAT}} = 0.89$ , também com grande variabilidade da fração transmitida da radiação difusa ( $K_d$ ) para uma mesma fração transmitida da radiação global ( $K_t$ ) como pode ser observado na Figura 2.c). Na Figura 3 são apresentadas as curvas de correlação da fração transmitida da irradiação difusa ( $K_d$ ) medido e estimado, utilizadas para validação do modelo, com seus indicadores de correlação de Ano típico (AT) e Ano atípico (AAT).

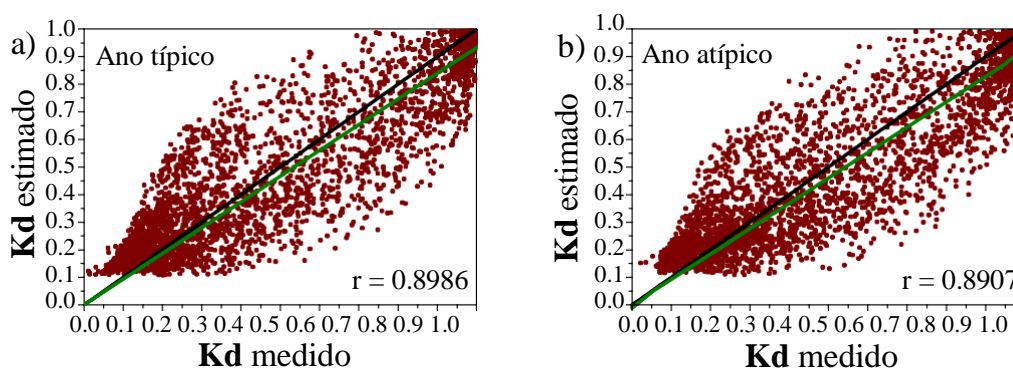


Figura 3: Curva de correlação da fração transmitida da irradiação difusa medida e estimada: a) Ano típico (AT); b) Ano atípico.

Observa-se na Figura 3 a) e b) as distribuições de valores estimados pela equação 7 do modelo ME e as medidas para duas condições de validação AT e AAT, além da proximidade da curva linear gerada (verde) com a reta ideal (negra em 45 °) com  $r = 1$  no ajuste da curva. Estas retas de regressão mostram que a equação 7 com os coeficientes de correlação de  $r_{AT} = 0.89$  e  $r_{AAT} = 0.89$  podem estimar a  $K_d$ .

Os valores encontrados para coeficiente de correlação na validação do modelo, tanto para Ano típico (AT) quanto para o Ano atípico (AAT), são próximos aos encontrados na literatura, seguindo a mesma tendência, considerando as peculiaridades da localização de origem dos modelos (Tabela 5).

Autores	Localidade	r	rRMSE %
Chandrasekaran and Kumar, (1994)	Madras/Índia	-	29.200
Oliveira et al. (2002)	São Paulo/São Paulo	0.9250	27.985
Jacovides et al. (2006)	Cyprus/ Grécia	0.9620	28.400
Furlan et al. (2012)	São Paulo/São Paulo	0.9640	-
Kuo et al. (2014b)	Tawian/China	-	8.4 a 17.34
Paulescu e Blaga ( 2016 )	Timissora/Romenia	0.9279	-
ME AT – Proposto 2017	Botucatu/São Paulo	0.8986	30.549
ME AAT – Proposto 2017	Botucatu/São Paulo	0.8907	27.966

Tabela 5: Indicativos estatísticos e suas localidades na partição horária. - Não informado pelos autores



### Rede Neural de Regressão Generalizada (GRNN)

Na primeira combinação da rede GRNN (Tabela 1), os resultados mostram valores maiores do erro quadrático médio aos encontrados no modelo clássico (Tabela 4), com um  $rRMSE_{GRNN1AT} = 31.86\%$  e  $rRMSE_{GRNN1AAT} = 29.38\%$  e conforme classificação dos indicadores estatísticos, um comportamento pobre para Ano típico e aceitável para Ano atípico. Os resultados deste comportamento podem ser visualizados nas Figuras 4.a) e 4.g), mostrando o comportamento da dispersão das duas bases de validação. A partir da segunda combinação, de GRNN2 a GRNN5, tanto para Ano típico quanto para Ano atípico, os valores de  $rRMSE$  diminuem aproximadamente 100% em comparação a GRNN1. Porém, com a inserção da variável meteorológica, essa redução é maior na GRNN6, chegando a um valor de  $rRMSE_{GRNN6AT} = 7.85\%$  para Ano típico e de  $rRMSE_{GRNN6AAT} = 8.21\%$  para Ano atípico, e conforme classificação dos indicadores, um comportamento excelente para validação. Os resultados deste comportamento pode ser visualizado nas Figuras 4.b) a 4.f) para Ano típico e 4.h) a 4.l) para Ano atípico, através do comportamento da dispersão das duas bases de validação.

Além das combinações avaliadas, outras foram realizadas, com a mesma quantidade de variáveis, alterando somente a ordem de entrada. Os resultados obtidos acompanharam a tendência de redução da correlação apresentadas na Tabela 4.

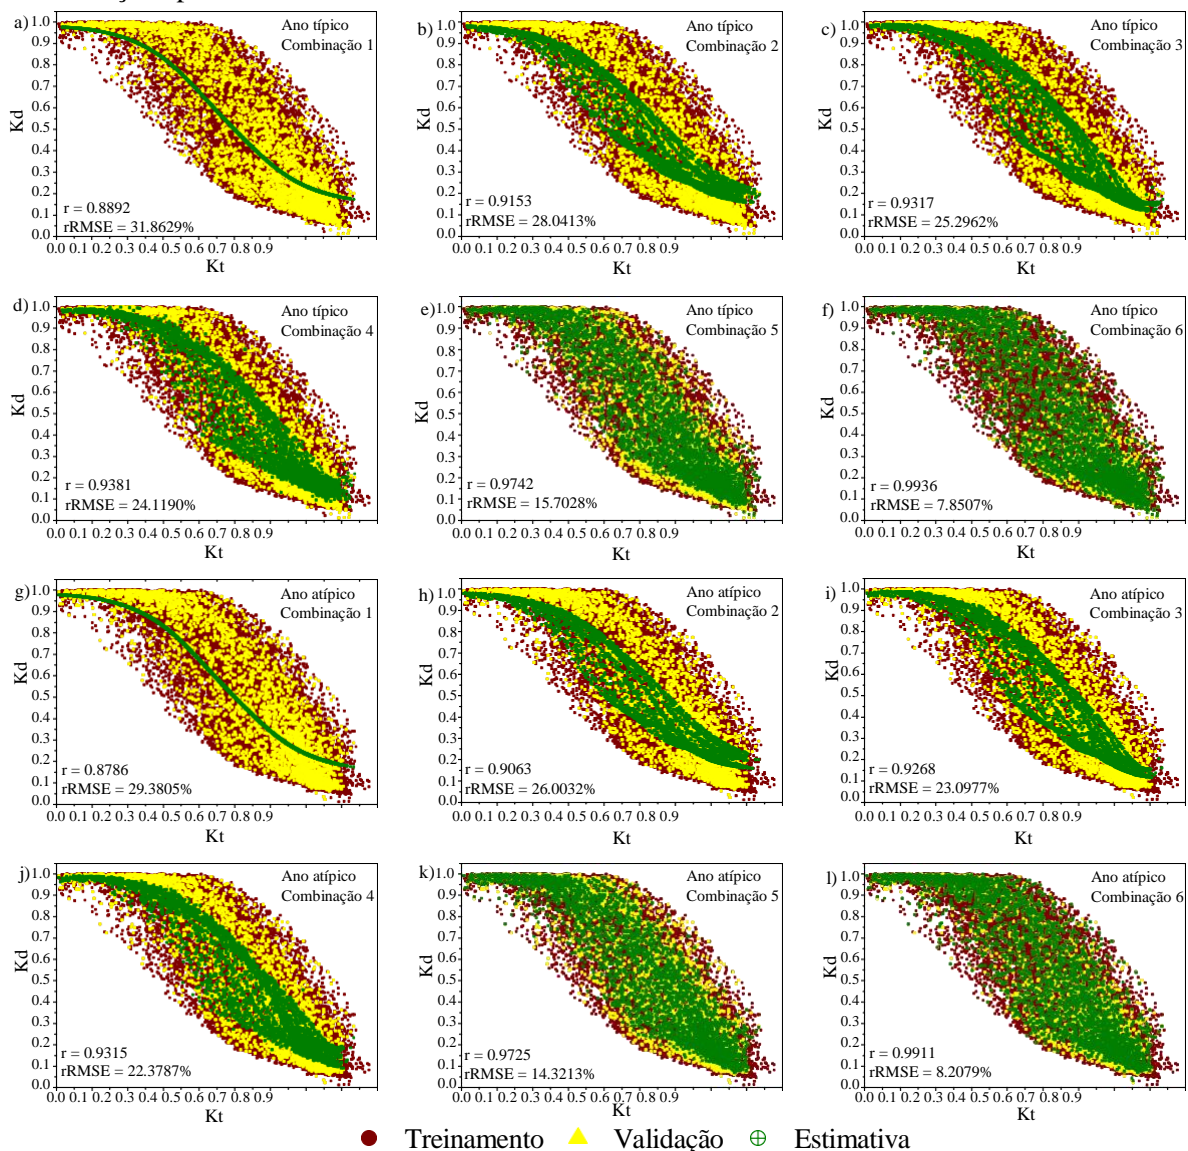


Figura 4: Curva de dispersão da estimativa de  $K_d$  calculada pela rede neural do tipo GRNN dos anos típico e atípico em função de  $K_t$ .

Apesar dessa tendência, o ajustamento (a) deve ser reavaliado e testado para se obter o menor valor de  $rRMSE$  entre os valores medidos e estimados com as novas combinações e assim verificar se a

redução permanece. Isto é importante pois este valor define a abertura da função de ativação fazendo com que os valores estimados fiquem próximos ou distantes dos valores medidos.

Fatores como o ajustamento, a quantidade de dados e a operacionalidade, merecem atenção quanto ao uso da GRNN. O ajustamento é importante pois define o desempenho da rede, a quantidade de dados, para verificar a adequação do número de dados, pois um número inadequado compromete a comparação realizada com os valores de saída, podendo resultar em valores não confiáveis e a operacionalidade, pois quanto maior o número de variáveis a ser utilizada, maior será o custo com equipamentos e implementação computacional.

Na Tabela 6 é apresentada a comparação do resultado encontrado do coeficiente de correlação ( $r$ ) e do valor de rRMSE da literatura com o melhor resultado da rede GRNN para partição horária.

Autores	Localidade	Variáveis de entrada	$r$	rRMSE
Khatib et al. (2012)	Kuala Lumpur/Malasia	Lat, Long, Temp, Brilho solar, Umidade, Mês, Dia e Hora.	-	Global média – 26.5% Difusa média – 5.8%
GRNN 6 AT	Botucatu/SP	Radiação de topo, global e de ondas longas, declinação solar, nebulosidade, umidade, temp. do ar, e fração da radiação global	0.9936	7.8507%
GRNN 6 AAT	Botucatu/SP	Radiação de topo, global e de ondas longas, declinação solar, nebulosidade, umidade, temp.do ar, e fração da radiação global	0.9911	8.2079%

*Tabela 6: indicativos estatísticos de autores e suas localidades e o melhor valor da rede proposta.*

Os indicadores estatísticos, tanto o coeficiente de correlação ( $r$ ) como o valor do rRMSE da validação, indicam que, com a inclusão da variável meteorológica juntamente com as variáveis astronômicas, o desempenho da rede foi melhor na estimativa de  $K_d$ .

Deve-se atentar que os valores encontrados neste trabalho são resultados das medidas e combinações sugeridas e validadas com a base (AT e AAT) criada para esta análise, sendo necessário realizar outros testes e combinações diferentes para treinamento e validação da rede GRNN. A rede GRNN apesar de sua dinâmica de treinamento, com apenas um parâmetro a ser definido ( $a$ ) e rapidez de seu tempo de treinamento e simplicidade, requer uma análise mais detalhada, tendo em vista as variáveis e equipamentos disponíveis.

## CONCLUSÃO

### *Dos resultados encontrados com o modelo clássico*

O modelo estatístico obtido neste trabalho por regressão polinomial para cidade de Botucatu/SP tem coeficiente de determinação da mesma ordem de grandeza dos trabalhos publicados na literatura, como também seus coeficientes de correlação obtidos em sua validação, que mostram que o modelo desenvolvido pode estimar a fração transmitida da radiação difusa.

Mesmo com valores de rRMSE estando próximos aos 30%, estes valores indicam que o modelo, pode ser utilizado, apesar da grande variabilidade dos valores em torno de apenas um valor de  $K_t$ .

Essa situação, da característica do próprio modelo, pode ser ainda mais elavada, dependendo da partição utilizada, que neste trabalho (partição horária), tende a aumentar em função da grande quantidade de dados e das mudanças que ocorrem na atmosfera. Outro fator que pode afetar o desempenho do modelo (ME) é o fato de que o índice de claridade ( $K_t$ ) pode não ser suficiente para estimar com eficiência a fração transmitida da radiação difusa.

### *Dos resultados encontrados com a rede neural de Regressão Generalizada*

A rede neural do tipo GRNN pode ser utilizada, neste caso específico, para estimar a fração da irradiação difusa transmitida, pois o valores da correlação foram superiores ao modelo estatístico, mesmo que a rede não seja utilizada com frequência na estimativa de  $K_d$ , tendo em vista poucos trabalhos na literatura, tanto na partição diária como na horária. Comparando-se os valores de rRMSE e da correlação ( $r$ ) na validação de ambos os modelos, estatístico e GRNN, conclui-se que a técnica da rede neural utilizada tem melhores resultados na estimativa da fração transmitida da irradiação difusa ( $K_d$ ).



## REFERÊNCIAS

- Azimi, R.; Ghayekhloo, M.; Ghofrani, M. (2016). A hybrid method based on a new clustering technique and multilayer perceptron neural networks for hourly solar radiation forecasting. *Energy Conversion and Management* 118, 331–344.
- Bakirci, K. (2015). Models for the estimation of diffuse solar radiation for typical cities in Turkey. *Energy* 82, 827 – 838.
- Boland, J.; Scott, L.; Luther, M. (2001). Modelling the diffuse fraction of global solar radiation on a horizontal surface. *Environmetrics* 12, 103 –117.
- Chandrasekaran, J.; Kumar, S. (1994). Hourly diffuse fraction correlationa at a tropical location. *Solar Energy* 53, 6, 505 – 510, 1994.
- Collares-Pereira, M.; Rabl, A. (1979). The average distribution of solar radiation -- correlations between diffuse and hemispherical and between daily and hourly insolation valuest. *Solar Energy* 22, 155 – 164.
- Dal Pai, A.; Escobedo, J. F.; Dal Pai, E.; Oliveira, A. P.; Soares, J. R.; Codato, G. (2016). MEO shadowing method for measuring diffuse solar irradiance: corrections based on sky cover. *Renewable Energy* 99, 754 - 76.
- De Miguel, A.; Bilbao, J.; Aguiar, R.; Kambezidis, H.; Negro, E. (2001). Diffuse solar irradiation model evaluation in the north Mediterranean belt area. *Solar Energy* 70, 2, 143 – 153.
- Drummond, A. J., (1956). On the measurements of sky radiation. *Archiv. fur Meteorologie. GeophysikBioklimatologie*, v.7, p.413-436.
- Duffie, J. A.; Beckam, W. A. (2013). *Solar Engineering of Thermal Processes*. Livro. Editora Wiley, Canadá.
- Elminir, H. K.; Azzam, Y. A.; Younes, F. I. (2007). Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. *Energy* 32, 1513 – 1523.
- Erbs, D.G.; Klein, S.A.; Duffie, J.A. (1982). Estimation of the diffuse radiation fraction for hourly, daily and monthly-average global radiation. *Solar Energy* 28, 293 – 302.
- Escobedo, J. F.; Dal Pai, A.; Lenz, L.C.; Prado, M. B. (2013b). Efeito da cobertura do céu no aumento das frações solar difusa e par-difusa em estufa de polietileno. *ASADES – Avances en Energia Renovables y Medio Ambiente* 17, 02.19 – 02.25.
- Escobedo, J. F.; Gomes, E. N.; Oliveira, A. P.; Soares, J. (2006). Radiações solares UV, PAR e IV: II- Estimativa das frações em função de kt. *Avances en Energías Renovables y Medio Ambiente*, 10.
- Escobedo, J. F.; Gomes, E. N.;Oliveira, A. P.; Soares, J. (2011). Ratios of UV,PAR and NIR components to global solar radiation measured at Botucatu site in Brazil. *Renewable Energy* 36, 169-178.
- Escobedo, J. F.; Santos, C. M.; Dal Pai, A.; Gomes, E. N. (2013a). Estimativa da irradiação solar direta na incidencia normal (Kb) em função da transmissividade atmosférica (Kt) em razão da insolação (n/N). *ASADES – Avances en Energia Renovables y Medio Ambiente* 17, 11.101 – 11.110.
- Furlan, C.; Oliveira, A. P.; Soares, J.; Codato, G.; Escobedo, J. F. (2012). The role of clouds in improving the regression model for hourly values of diffuse solar radiation. *Applied Energy*, 92, 240 – 254.
- Hansen, J.V.; Meservy, R. D.(1996). Learning experiments with genetic optimization of a generalized regression neural network. *Decision Support System*, vol. 18, p. 317 – 325.
- Haykin, S.(2001). *Redes neurais: princípios e prática*. 2.ed. Porto Alegre, Bookman.
- Heinemann, A. B.; Van Oort, P. A. J.; Fernandes, D. S.; Maia, A. H. N..(2012) Sensitivity of APSIM/ORYZA model due to estimation errors in solar radiation. *Bragantia*, vol. 71, n. 4, p. 572 - 582, 2012.
- Iqbal, M. (1983). *An introduction solar radiation*. Livro. Vancouver, Canada. Academic Press.
- Jacovides, C.P.; Tymvios, F. S.; Assimakopoulos, V. D.; Kaltsounides, N. A. (2006). Comparative study of various correlations in estimating hourly diffuse fraction of global solar radiation. *Renewable Energy* 31, 2492 – 2504.
- Jameson, P. D.; Porter, J. R.; Wilson, D. R. (1991). A test of the computer simulation model ARC-WHEAT1 on wheat crops grown in New Zealand. *Field Crops Research*, vol. 27, p.337-350, 1991.
- Jamil, B.; Siddiqui, A. (2017). Generalized models for estimation of diffuse solar radiation based on clearness index and sunshine duration in India: Applicability under different climatic zones. *Journal of Atmospheric and Solar–Terrestrial Physics* 157, 16 – 34.

- Jiang, Y. (2008). Prediction of monthly mean daily diffuse solar radiation using artificial neural networks and comparison with other empirical models. *Energy Policy* 36, 3833 – 3837.
- Khatib, T. (2015). A Novel Approach for Solar Radiation Prediction Using Artificial Neural Networks. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects* 37.
- Kahatib, T.; Mohamed, A.; Sopian, K.; Mahmoud, M. (2012). Assessment of Artificial Neural Networks for Hourly Solar Radiation Prediction. *International Journal of Photoenergy*, Volume 2012.
- Khorasanizadeh, H.; Mohammadi, K.; Goudarzi, N.(2016). Prediction of horizontal diffuse solar radiation using clearness index based empirical models: A case study. *International Journal of Hydrogen Energy* 41, 21888 – 21898.
- Kumar, R.; Aggarwal, R.K.; Sharma, J.D.(2015). Comparison of regression and artificial neural network models for estimation of global solar radiations. *Renewable and Sustainable Energy Reviews* 52, 1294 – 1299.
- Kuo, C.W., Chang, W.C., Chang, K.C.(2014a). Modeling the hourly solar diffuse fraction in Taiwan. *Renewable Energy* 66, 56–61.
- Kuo, C.W.; Chang, W.C.; Chang, K.C.(2014b). Distribution of solar diffuse fraction in Taiwan. *Energy Procedia* 57, 1120 - 1129.
- Lazarevska, E.; Tropovski, J. (2011). A neuro-fuzzy model of the solar diffuse radiation with relevance vector machine. [Electrical Power Quality and Utilisation \(EPQU\). 11th International Conference on Electrical Power Quality and Utilisation.](#)
- Li, H., Ma, W., Wang, X., Lian, Y., (2011). Estimating monthly average daily diffuse solar radiation with multiple predictors: a case study. *Renew. Energy* 36, 1944–1948.
- Liu, B. H. Y.; Jordan, R. C.(1960). The interrelationship and characteristic distribution of direct, diffuse and total solar radiation. *Solar Energy* 4, 1.
- Lopez, G.L.; Muneer, T.; Claywell, R.(2004). Assessment of four shadow band correction models using beam normal irradiance data from the United Kingdom and Israel. *Energy Conversion and Management* 45, 1963 – 1979.
- Melo, J. M. D., Escobedo, J. F., 1994. Medida da radiação solar difusa. In: *Energias Limpas em Progreso, VII Congresso Ibérico de Energia Solar*, Vigo, Espanha. *Anais International Solar Energy Society*, 1.
- Muneer, T.(2004). *Solar Irradiation and Daylight Models*. Second ed., Elsevier, Amsterdam, 345.
- Oliveira, A. P.; Escobedo, J. F.; Machado, A. J.; Soares, J.(2002). Correlation models of diffuse solar-radiation applied to the city of São Paulo, Brazil. *Applied Energy* 71, 59 – 73.
- Orgill, J. F.; Hollands, G.T.(1977). Correlation equation for hourly diffuse radiation on a horizontal surface. *Solar Energy* 9, 357 – 359.
- Paulescu, E.; Blaga, R. (2016). Regression models for hourly diffuse solar radiation. *Solar Energy* 125, 111 – 124.
- Pashiardis, S.; Kalogirou, S.A.(2016). Quality control of solar shortwave and terrestrial longwave radiation for surface radiation measurements at two sites in Cyprus. *Renewable Energy* 96, 1015 – 1033.
- Reindl, D. T.; Beckman W. A.; Duffie, J. A.(1990). Diffuse fraction correlations. *Solar Energy* 45, 1 – 7.
- Robinson, H., Stoch, L.. (1964). Sky radiation and measurements and corrections. *Journal of Applied Meteorology*, v.3, p.179-181
- Ruiz-Arias, J.A.; Alsamamra, H.; Tovar-Pescador, J.; Pozo-Vázquez, D.(2010). Proposal of a regressive model for the hourly diffuse solar radiation under all sky conditions.. *Energy Conversion and Management* 51, 881 – 893.
- Santos, C. M.; Escobedo, J. F.; Teramoto, E. T.; Silva, S. H. M. G.(2016). Assessment of ANN and SVM models for estimating normal direct irradiation (H<sub>b</sub>). *Energy Conversion and Management* 126, 826 – 836.
- Santos, C. M.; Souza, J. L.; Ferreira Junior, R. A.; Tiba, C.; Melo, R. O.; Lyra, G. B.; Teodoro, I.; Lyra, G.B.; Lemes, M. A. M.(2014). On modeling global solar irradiation using air temperature for Alagoas State, Northeastern Brazil. *Energy* 71, 388-398.
- Soares, J.; Oliveira, A. P.; Boznar, M. Z.; Mlakar, P.; Escobedo, J. F.; Machado, A. J. (2004). Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. *Applied Energy*, 79, 201 – 214.

- Souza, A. P.; Escobedo, J. F.; Dal Pai, A.; Gomes, E. N..(2011). Estimativas das componentes da radiação solar incidente em superfícies inclinadas baseadas na radiação global horizontal. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 15, 277 – 288.
- Souza, J. L.; Nicácio, R. M.; MOURA, M. A. L.(2005). Global solar radiation measurements in Maceió, Brasil. *Renewable Energy* 30, 1203-1220.
- Specht, D. F.(1991). A general regression neural network.. *IEEE Transactions on neural networks* 2, n o 6.
- Stone, R.J. (1993). Improved statistical procedure for the evaluation of solar radiation estimation models. *Solar Energy*, vol. 51,n o4, p. 289 – 291.
- Teke, A.; Yıldırım, H. B.; Celik, O.(2015). Evaluation and performance comparison of diferente models for the estimation of solar radiation. *Renewable and Sustainable Energy Reviews* 50, 1097 – 1107.
- Teramoto, E. T.; Escobedo, J. F.(2012). Análise da frequência anual das condições de céu em Botucatu, São Paulo. *Revista Brasileira Engenharia Agrícola Ambiental* 16, 985-992.
- Wang, L.; Kisi, O.; Zounemat-Kermani, M.; Salazar, G. A.; Zhu, Z.; Gong, W.(2016). Solar radiation prediction using different techniques: model evaluation and comparison. *Renewable and Sustainable Energy Reviews* 61, 384 – 397.
- Willmott, C. J. (1982). On the validation of models. *Physical Geography*, vol. 2, p. 184-194, 1982.
- WMO – World Meteorological Organization. Guide to meteorological Instruments and Methods of Observation (2008). WMO-n°8, Seventh Edition, 1 - 681.
- Yildiz, B. Y.; Şahin, M.; Şenkal, O.; Pestemalci, V.; Emrahoğlu, N.(2013). A comparison of two solar radiation models using artificial neural networks and remote sensing in Turkey. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects* 35:3, 209 – 217.
- Younes, S.; Claywell, R.; Muneer, T.(2005). Quality control of solar radiation data: Present status and proposed new approaches. *Energy* 30, 1533 – 1549.

## **ESTIMATION OF THE TRANSMITTED FRACTION OF HOURLY DIFFUSE IRRADIATION BY MEANS OF STATISTICAL MODEL AND GENERALIZED REGRESSION NEURAL NETWORK (GRNN).**

**ABSTRACT:** Two models of estimates for diffused radiation fraction ( $K_d$ ) as a function of the transmissivity of global radiation ( $K_t$ ) in the hourly partition: statistical and the technique of Artificial Neural Networks of the Generalized Regression type (GRNN) are proposed. The first, using only  $K_t$  as a reference and the second, a combination of six astronomical and meteorological variables. The data base, measured between 2000 and 2006, was used to obtain the statistical equation and GRNN training in the proposed combinations. In the validation of the models, two diffuse solar irradiation databases, called typical (AT) and atypical (AAT) years, were used, both obtained from the total database of years. The estimation equation was obtained by a 4 th order polynomial regression with a correlation if coefficient  $r = 0.89$ . In the comparison between the estimation and the measurement of the statistical model, we obtained the statistical indicatives of the two validation conditions:  $r_{AT} = 0.90$  and  $r_{AAT} = 0.89$ ;  $rRMSE_{AT} = 30.55\%$  and  $rRMSE_{AAT} = 27.97\%$ , respectively. The performance of the GRNN network was better in combinations 2 to 6 as a function of the input of each astronomical and meteorological variable, obtaining the statistical indicatives  $r_{AT} = 0.92$  and  $r_{AAT} = 0.91$ ;  $rRMSE_{AT} = 28.04\%$  and  $rRMSE_{AAT} = 26.00\%$  for combination 2, up to the values of  $r_{AT} = 0.99$  and  $r_{AAT} = 0.99$ ;  $rRMSE_{AT} = 7.85\%$  and  $rRMSE_{AAT} = 8.21\%$  for combination 6, under the two validation conditions, respectively. The comparison of the statistical indicatives shows that the GRNN network from the combination 2 that has  $K_t$  and the top ( $H_0$ ) irradiation as input, performs better than the statistical model in estimating  $K_d$ .

**Keywords:** Solar radiation; Diffuse radiation; Generalized regression neural network.