

ADRIANO DE SOUZA MARQUES

**MODELAGEM EM SUPERFÍCIES INCLINADAS DAS RADIAÇÕES GLOBAL E
DIFUSA USANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Botucatu

2018

ADRIANO DE SOUZA MARQUES

**MODELAGEM EM SUPERFÍCIES INCLINADAS DAS RADIAÇÕES GLOBAL E
DIFUSA USANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Tese apresentada à Faculdade de Ciências Agronômicas da Unesp Campus de Botucatu, para obtenção do título de Doutor em Agronomia (Energia na Agricultura).

Orientador(a): Prof. Dr. João Francisco Escobedo

**Botucatu
2018**

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO - DIRETORIA TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP - FCA - LAGEADO - BOTUCATU (SP)

M357m Marques, Adriano de Souza, 1975-
Modelagem em superfícies inclinadas das radiações global e difusa usando técnicas de aprendizado de máquina / Adriano de Souza Marques. - Botucatu: [s.n.], 2018
162 p.: fots. color., ils. color., grafs. color., tabs.

Tese (Doutorado)- Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2018
Orientador: João Francisco Escobedo
Inclui bibliografia

1. Irradiação solar. 2. Redes neurais artificiais. 3. ANFIS. 4. Estimativas. I. Escobedo, João Francisco. II. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Campus de Botucatu). Faculdade de Ciências Agrônômicas. III. Título.

Elaborada por Ana Lucia G. Kempinas - CRB-8:7310

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte"


CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: MODELAGEM EM SUPERFÍCIES INCLINADAS DAS RADIAÇÕES GLOBAL E DIFUSA
USANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA


AUTOR: ADRIANO DE SOUZA MARQUES

ORIENTADOR: JOÃO FRANCISCO ESCOBEDO


Aprovado como parte das exigências para obtenção do Título de Doutor em AGRONOMIA (ENERGIA
NA AGRICULTURA), pela Comissão Examinadora:




Prof. Dr. JOÃO FRANCISCO ESCOBEDO
Depto de Engenharia Rural / UNESP - Faculdade de Ciências Agrônômicas de Botucatu



Prof. Dr. ALEXANDRE DAL PAI
Departamento de Engenharia de Bioprocessos e Biotecnologia / Faculdade de Ciências Agrônômicas de
Botucatu - UNESP



Prof. Dr. JOSÉ ALFREDO COVOLAN ULSON
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Bauru - UNESP



Profa. Dra. VALERIA CRISTINA RODRIGUES SARNIGHAUSEN
Depto de Bioprocessos e Biotecnologia / UNESP - Faculdade de Ciências Agrônômicas de Botucatu



Prof. Dr. RENATO CORREIA DE BARROS
Depto de Informática / Instituto Federal de Educação, Ciência e Tecnologia de Birigui

Botucatu, 30 de maio de 2018

À minha amada família.

Cristiana, Heitor e Murilo

Dedico

AGRADECIMENTOS

A DEUS.

Aos meus queridos pais Rubens Marques (*in memorian*) e Rosa de Souza Marques.

À minha esposa Cristiana e meus filhos Heitor e Murilo. Obrigado por entender as ausências e por estarem sempre me apoiando.

Aos grandes amigos do grupo Edson Basseto, Jancer Destro e Maurício Prado. Muitas experiências trocadas e grandes aprendizados. Continuemos.

Ao grande amigo Marcos Bica pelas parcerias, inclusive nas jornadas à Botucatu.

Ao IFSP – Instituto Federal de São Paulo e aos colegas da área de Informática do Campus Birigui pela possibilidade de dedicação aos meus estudos.

Ao professor Dr. Alexandre Dal Pai por contribuir e estar sempre disposto a colaborar.

Ao inigualável MESTRE Prof. Dr. João Francisco Escobedo, pela paciência, compreensão e muitos ensinamentos. Obrigado por acreditar.

RESUMO

Neste trabalho é realizado um estudo para estimar a transmissividade da radiação global (Kt_{β^h}) e a fração difusa (Kd_{β^h}) incidentes em uma superfície com inclinação de $22,85^\circ$ na base horária utilizando técnicas de aprendizado de máquina (TAM), a partir de dados obtidos no período de 1998 a 2001 em Botucatu/SP/Brasil. As estimativas foram realizadas usando uma série de combinações de variáveis astronômicas e geográficas por meio de três técnicas de redes neurais artificiais (RNA) do tipo Perceptron Multicamadas (MLP), Função de Base Radial (RBF) e Regressão Generalizada (GRNN) e do Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS). Como referência foram elaborados modelos estatísticos (ME) de regressão linear e polinomial. No Capítulo 1 as estimativas de (Kt_{β^h}) foram realizadas por combinações de variáveis medidas e calculadas a partir da irradiação global na superfície horizontal (Hg_H) e nas estimativas de (Kd_{β^h}) utilizou-se combinações de variáveis medidas e calculadas a partir de (Hg_H) e da irradiação global na superfície inclinada (Hg_{β}). No Capítulo 2 as estimativas de (Kd_{β^h}) foram realizadas por combinações de variáveis medidas e calculadas a partir das irradiações difusa (Hd_H) e global (Hg_H) obtidas na superfície horizontal. Os indicadores estatísticos r (correlação), RMSE(%) (precisão) e MBE(%) (exatidão) foram utilizados para avaliar os resultados das estimativas. No capítulo 1 os melhores resultados nas estimativas de (Kt_{β^h}) a partir das combinações realizadas com (Hg_H) foram: MLP - RMSE=3,73%; RBF - RMSE=3,99%; GRNN - RMSE=5,27%; ANFIS - RMSE=3,78% e ME - RMSE=6,65%. Nesse caso os indicadores de precisão mostram uma redução de aproximadamente 44% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). Nas estimativas de (Kd_{β^h}) a partir das combinações de (Hg_H) os melhores resultados foram: MLP - RMSE=21,69%; RBF - RMSE=25,43%; GRNN - RMSE=29,39%; ANFIS - RMSE=23,08% e - ME - RMSE=35,35%. Da mesma forma os indicadores de precisão mostram uma redução de aproximadamente 39% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). E nas estimativas de (Kd_{β^h}) a partir das combinações realizadas com (Hg_{β}) os melhores resultados foram: MLP - RMSE=20,32%; RBF - RMSE=21,95%; GRNN - RMSE=29,11%; ANFIS - RMSE=21,75% e ME - RMSE=36,48%. Os indicadores de precisão mostram uma redução de aproximadamente 44% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). No capítulo 2 as melhores estimativas de (Kd_{β^h}) a partir das combinações realizadas com (Hd_H) foram: MLP - RMSE=4,03%; RBF - RMSE=5,84%; GRNN - RMSE=10,85%; ANFIS - RMSE=4,15% e ME - RMSE=12,42%. Os indicadores de precisão mostram uma redução de aproximadamente 67% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). Nas estimativas de (Kd_{β^h}) a partir de (Hg_H) os melhores resultados foram: MLP - RMSE=21,69%; RBF - RMSE=25,43%; GRNN - RMSE=29,39%; ANFIS - RMSE=23,08% e ME - RMSE=35,35%. Os indicadores de precisão mostram uma redução de aproximadamente 39% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). Os resultados mostram que a técnica de rede neural artificial MLP apresentou os melhores índices em todas as estimativas de (Kt_{β^h}) e (Kd_{β^h}) com

reduções significativas quando comparadas aos resultados obtidos com as estimativas obtidas com os modelos estatísticos. Pela análise dos resultados é possível observar que o uso das técnicas de aprendizado de máquina (TAM) nas combinações de variáveis propostas e com os dados obtidos de Botucatu/SP, se apresentam como alternativa aos modelos estatísticos (ME) para estimar as variáveis de (Kt_{β^h}) e (Kd_{β^h}) .

Palavras-chave: Irradiação solar, Redes Neurais Artificiais, ANFIS, Estimativas.

ABSTRACT

In this work, a study was carried out to estimate the transmissivity of the global radiation (Kt_{β}^h) and the diffuse fraction (Kd_{β}^h) incident on a surface with slope of 22.85° in the hourly basis using machine learning techniques (MLT), from data obtained from 1998 to 2001 in Botucatu / SP / Brazil. The estimates were made using a series of combinations of astronomical and geographic variables by means of three artificial neural network (ANN) techniques such as MultLayer Perceptron (MLP), Radial Basis Functions Networks (RBF) and Generalized Regression Neural Network (GRNN) Adaptive Neuro Fuzzy Inference System (ANFIS). Statistical models (SM) of linear and polynomial regression were elaborated as reference. In Chapter 1 estimates of (Kt_{β}^h) were performed by combinations of variables measured and calculated from global horizontal surface irradiation (Hg_H) and estimates of (Kd_{β}^h) combinations of variables measured and calculated from (Hg_H) and global radiation on the sloped surface (Hg_{β}). In Chapter 2 estimates of (Kd_{β}^h) were performed by combinations of variables measured and calculated from the diffuse (Hd_H) and global (Hg_H) irradiances obtained on the horizontal surface. The statistical indicators r (correlation), RMSE (%) (precision) and MBE (%) (accuracy) were used to evaluate the results of the estimates. In Chapter 1 the best results in the estimates of (Kt_{β}^h) from the combinations performed with (Hg_H) were: MLP - RMSE = 3.73%; RBF - RMSE = 3.99%; GRNN - RMSE = 5.27%; ANFIS-RMSE = 3.78% and SM - RMSE = 6.65%. In this case the precision indicators show a reduction of approximately 44% with the use of the technique (MLP) in comparison to the statistical model (SM). In the estimates of (Kd_{β}^h) from the combinations of (Hg_H) the best results were: MLP - RMSE = 21.69%; RBF - RMSE = 25.43%; GRNN - RMSE = 29.39%; ANFIS - RMSE = 23.08% and SM - RMSE = 35.35%. Likewise, the precision indicators show a reduction of approximately 39% with the use of the technique (MLP) in comparison to the statistical model (SM). And in the estimates of (Kd_{β}^h) from the combinations performed with (Hg_{β}) the best results were: MLP - RMSE = 20.32%; RBF - RMSE = 21.95%; GRNN - RMSE = 29.11%; ANFIS - RMSE = 21.75% and SM - RMSE = 36.48%. The precision indicators show a reduction of approximately 44% with the use of the technique (MLP) in comparison to the statistical model (SM). In Chapter 2 the best estimates of (Kd_{β}^h) from the combinations performed with (Hd_H) were: MLP - RMSE = 4.03%; RBF - RMSE = 5.84%; GRNN - RMSE = 10.85%; ANFIS - RMSE = 4.15% and SM - RMSE = 12.42%. The precision indicators show a reduction of approximately 67% with the use of the technique (MLP) in comparison to the statistical model (SM). In the estimates of (Kd_{β}^h) from (Hg_H) the best results were: MLP - RMSE = 21.69%; RBF - RMSE = 25.43%; GRNN - RMSE = 29.39%; ANFIS - RMSE = 23.08% and SM - RMSE = 35.35%. The precision indicators show a reduction of approximately 39% with the use of the technique (MLP) in comparison to the statistical model (SM). The results show that the artificial neural network MLP technique presented the best indexes in all estimates of (Kt_{β}^h) and (Kd_{β}^h) with significant reductions when compared to the results obtained with the estimates obtained with the statistical models. By the analysis of the results it is possible to observe that the use of the machine learning techniques (MLT) in the combinations of

proposed variables and the data obtained from Botucatu / SP, are presented as an alternative to the statistical models (SM) to estimate the variables of (Kt_{β^h}) and (Kd_{β^h}) .

Keywords: Solar Irradiation, Artificial Neural Networks, ANFIS, Estimates.

LISTA DE TABELAS

CAPÍTULO 1

Tabela 1.1 - Variáveis selecionadas para as estimativas com as técnicas de Modelagem de Máquina.....	41
Tabela 1.2 - Variáveis selecionadas para as estimativas com as técnicas de Aprendizado de Máquina	42
Tabela 1.3 - Modelos de treinamento da RNA e ANFIS.....	43
Tabela 1.4 - Arquiteturas para treinamento da Rede MLP	47
Tabela 1.5 - Arquiteturas para as estimativas com a Rede RBF.....	50
Tabela 1.6 - Arquiteturas para as estimativas com a Rede GRNN	53
Tabela 1.7 - Arquiteturas para as estimativas com o sistema híbrido ANFIS.....	57
Tabela 1.8 - Ano Atípico (AAT) obtido na base de dados total (março de 1998 a agosto de 2001).	59
Tabela 1.9 - Modelos obtidos das correlações da Figura 1.17	61
Tabela 1.10 - Indicativos de desempenho nas estimativas pelo modelo estatístico (ME)	63
Tabela 1.11 - Indicativos estatísticos e suas localidades na partição horária para Hg_{β}	66
Tabela 1.12 - Indicativos estatísticos e suas localidades na partição horária para Kd_{β}	66
Tabela 1.13 - Indicadores do Modelo Estatístico (ME), RNA e ANFIS para os anos atípicos (AAT) com destaque aos melhores resultados	67
Tabela 1.14 - Melhores Indicadores das RNA e ANFIS validadas na base de anos atípicos (AAT).	69

CAPÍTULO 2

Tabela 2.1 - Variáveis selecionadas para as estimativas com as técnicas de Modelagem de Máquina.....	99
Tabela 2.2 - Variáveis selecionadas para as estimativas com as técnicas de Aprendizado de Máquina	100
Tabela 2.3 - Modelos de treinamento da RNA e ANFIS.....	101
Tabela 2.4 - Arquiteturas para as estimativas com a Rede MLP	104

Tabela 2.5 - Arquiteturas para as estimativas com a Rede RBF	107
Tabela 2.6 - Arquiteturas para as estimativas com a Rede GRNN	109
Tabela 2.7 - Arquiteturas para as estimativas com o sistema híbrido ANFIS	111
Tabela 2.8 - Ano Atípico (AAT) obtido na base de dados total (março de 1998 a agosto de 2001).....	113
Tabela 2.9 - Modelos obtidos com as correlações das Figuras 2.17	115
Tabela 2.10 - Indicativos de desempenho nas estimativas pelo modelo estatístico (ME).....	116
Tabela 2.12 - Indicativos estatísticos e suas localidades na partição horária para Kd_{β}	117
Tabela 2.13 - Indicadores das Redes Neurais e ANFIS para os anos atípicos (AAT).	119
Tabela 2.14 - Melhores Indicadores das Redes Neurais e ANFIS para os anos atípicos (AAT).	121

LISTA DE FIGURAS

CAPÍTULO 1

Figura 1.1 - Modelo do neurônio artificial	31
Figura 1.2 - Arquitetura da Rede Neural Perceptron Multicamadas.	32
Figura 1.3 - Arquitetura da Rede Neural de Base Radial.	33
Figura 1.4 - Arquitetura da GRNN.	35
Figura 1.5 - Arquitetura da ANFIS	36
Figura 1.6 - Séries Climáticas (período: 1970-2008)	38
Figura 1.7 - Estrutura para medida das radiações global e difusa nos planos horizontal e inclinado.....	39
Figura 1.8 - Organização das radiações global e difusa nos planos horizontal e inclinado.	40
Figura 1.9 - Exemplo da estrutura do arquivo CSV	42
Figura 1.10 - Critério de Fletcher-Gloss para determinação do número de neurônios do treinamento.	45
Figura 1.11 - Curvas de treinamento da MLP	46
Figura 1.12 - Curva do EQM do Treinamento em função das combinações treinadas	48
Figura 1.13 - Curva do EQM do Treinamento em função das combinações testadas	52
Figura 1.14 - Curva do EQM do Treinamento em função das combinações testadas	55
Figura 1.15 - Curva do EQM do Treinamento em função das combinações testadas	58
Figura 1.16 - A) Exemplo da classificação dos anos atípicos para a base de validação B) Separação da base de treinamento e validação com Anos Atípicos (AAT) de março de 1998 a agosto de 2001.....	59
Figura 1.17 - Correlações entre: (A) Fração da global na superfície horizontal (K_{tH}) e a fração da global no plano inclinado ($K_{t\beta}$), (B) Fração da global na superfície horizontal (K_{tH}) e a fração da difusa no plano inclinado ($K_{d\beta}$). (C) Fração da global na superfície inclinada ($K_{t\beta}$) e a fração da difusa no plano inclinado ($K_{d\beta}$).....	62

Figura 1.18 - Correlações entre os valores medidos e estimados: (A) Fração da global na superfície inclinada ($K_{t\beta}$) medida e estimada, (B) Fração da difusa no plano inclinado ($K_{d\beta}$) medido e estimado, (C) Fração da difusa no plano inclinado ($K_{d\beta}$) medido e estimado	64
Figura 1.19(a) - Correlações entre valores medidos e estimados pelas técnicas MLP e RBF sendo nas colunas: (A) $K_{t\beta}$ medido e estimada, (B e C) $K_{d\beta}$ medidos e estimados.	71
Figura 1.19(b) - Correlações entre valores medidos e estimados pelas técnicas GRNN e ANFIS, sendo nas colunas: (A) $K_{t\beta}$ medido e estimada, (B e C) $K_{d\beta}$ medidos e estimados.	72
Figura 1.20(a) - Gráfico de dispersão das estimativas MLP e RBF: (A) $K_{t\beta}$ em função de K_{tH} medido (B) $K_{d\beta}$ em função de K_{tH} medido (C) $K_{d\beta}$ em função de $K_{t\beta}$ medido.	75
Figura 1.20(b) - Gráfico de dispersão das estimativas GRNN e ANFIS: (A) $K_{t\beta}$ em função de K_{tH} medido (B) $K_{d\beta}$ em função de K_{tH} medido (C) $K_{d\beta}$ em função de $K_{t\beta}$ medido.	75

CAPÍTULO 2

Figura 2.1 - Modelo do neurônio artificial.	89
Figura 2.2 - Arquitetura da Rede Neural Perceptron Multicamadas	90
Figura 2.3 - Arquitetura da Rede Neural de Base Radial	92
Figura 2.4 - Arquitetura da GRNN.....	93
Figura 2.5 - Arquitetura da ANFIS.....	94
Figura 2.6 - Séries Climáticas (período: 1970-2008): (a) Temperatura e Umidade Relativa, (b) Nebulosidade, (c) Precipitação, (d) Relação entre a evolução anual da Profundidade Ótica dos Aerossóis (POA) e Material Particulado (PM) em médias mensais (obtidas do satélite TERRA) no ano de 2001 a 2005.....	96
Figura 2.7 - Estrutura para medida das radiações difusa nos planos horizontal e inclinado	97
Figura 2.8 - Organização das estimativas da radiação difusa no plano inclinado...	98
Figura 2.9 - Exemplo da estrutura do arquivo CSV.....	100
Figura 2.10 - Critério de Fletcher-Gloss para determinação do número de neurônios do treinamento.....	102
Figura 2.11 - Curvas de treinamento da MLP	103

Figura 2.12 - Curva do EQM do Treinamento em função das combinações testadas	105
Figura 2.13 - Curva do EQM do Treinamento em função das combinações testadas	108
Figura 2.14 - Curva do EQM do Treinamento em função das combinações testadas	110
Figura 2.15 - Curva do EQM do Treinamento em função das combinações testadas	112
Figura 2.16 - A) Exemplo da classificação dos anos atípicos para a base de validação B) Separação da base de treinamento e validação com Anos Atípicos (AAT) de março de 1998 a agosto de 2001.....	113
Figura 2.17 - Correlações entre (A) fração medida da difusa no plano horizontal (K_{dH}) e inclinado ($K_{d\beta}$). (B) fração da global na superfície horizontal (K_{tH}) e a fração da difusa no plano inclinado ($K_{d\beta}$)	115
Figura 2.18 - Correlações entre fração da difusa no plano inclinado ($K_{d\beta}$) medido e estimado.....	116
Figura 2.19 - Correlações entre valores medidos e estimados de ($K_{d\beta}$) pelas técnicas MLP, RBF, GRNN e ANFIS.....	122
Figura 2.20 - Gráfico de dispersão das estimativas: (A) $K_{d\beta}$ em função de K_{dH} medido (B) $K_{d\beta}$ em função de K_{tH} medido.	124

LISTA DE ABREVIATURAS E SIGLAS

TAM	Técnicas de Aprendizado de Máquinas
ME	Modelo Estatístico
RNA	Redes Neurais Artificiais
MLP	Rede Neural Multilayer Perceptron
RBF	Rede Neural de Função de Base Radial
GRNN	Rede Neural de Regressão Generalizada
ANFIS	Sistema Adaptativo de Inferência Neuro Fuzzy
H_0	Irradiação solar no topo da atmosfera (MJm^{-2})
H_{gH}	Irradiação solar global na superfície horizontal (MJm^{-2})
$H_{g\beta}$	Irradiação solar global na superfície horizontal (MJm^{-2})
K_{tH}	Transmissividade da irradiação global em superfície horizontal (adimensional)
$K_{t\beta}^h$	Transmissividade da irradiação global em superfície inclinada com base horária
K_{dH}	Fração difusa da irradiação global em superfície horizontal (adimensional)
$K_{d\beta}^h$	Fração difusa da irradiação global em superfície inclinada com base horária
m_r	Massa ótica relativa do ar (adimensional)
RMSE	Root Mean Square Error
RMSE(%)	Relative Root Mean Square Error
MBE	Mean Bias Error
MBE(%)	Relative Mean Bias Error

EQM	Erro Quadrático Médio
R^2	Coeficiente de determinação
r	Coeficiente de correlação

SUMÁRIO

	INTRODUÇÃO GERAL.....	23
	CAPÍTULO 1 - ESTIMATIVAS DA RADIAÇÃO GLOBAL E DIFUSA EM SUPERFÍCIE INCLINADA USANDO TÉCNICAS DE REDES NEURAIS ARTIFICIAIS E ANFIS	25
1.1	INTRODUÇÃO	26
1.2	DESCRIÇÃO DAS TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)	29
1.2.1	REDES NEURAIS ARTIFICIAIS (RNA)	30
1.2.1.1	<i>Multilayer Perceptron (MLP)</i>	31
1.2.1.2	<i>Radial Basis Functions Networks (RBF)</i>	33
1.2.1.3	<i>Rede Neural de Regressão Generalizada (GRNN)</i>	34
1.2.2	ADAPTIVE NEURO FUZZY INFERENCE SYSTEM (ANFIS).....	35
1.3	MATERIAL E MÉTODOS.....	36
1.3.1	LOCALIZAÇÃO E CLIMA.....	36
1.3.2	OBTENÇÃO DA BASE DE DADOS	38
1.3.2.1	<i>Controle de qualidade da base de dados</i>	39
1.3.3	ORGANIZAÇÃO DAS ESTIMATIVAS	39
1.3.4	MODELO ESTATÍSTICO (ME)	40
1.3.5	TREINAMENTO DAS RNA E ANFIS	41
1.3.5.1	<i>Treinamento da MLP</i>	44
1.3.5.2	<i>Treinamento da RBF</i>	49
1.3.5.3	<i>Treinamento da GRNN</i>	53
1.3.6	TREINAMENTO DA ANFIS	56
1.3.7	BASE DE DADOS DE VALIDAÇÃO	59
1.3.8	INDICATIVOS ESTATÍSTICOS	60
1.4	RESULTADOS E DISCUSSÕES	61
1.4.1	EQUAÇÕES DE ESTIMATIVAS DO MODELO ESTATÍSTICO.....	61
1.4.1.1	<i>Validação das equações de estimativas</i>	63
1.4.2	REDES NEURAIS ARTIFICIAIS E ANFIS	66
1.5	CONCLUSÕES	77
	REFERÊNCIAS	78
	CAPÍTULO 2 - ESTIMATIVAS DA RADIAÇÃO DIFUSA HORÁRIA EM SUPERFÍCIE INCLINADA A PARTIR DAS MEDIDAS DA RADIAÇÃO DIFUSA E GLOBAL NA SUPERFÍCIE HORIZONTAL USANDO REDES NEURAIS E ANFIS.....	85
2.1	INTRODUÇÃO	86
2.2	DESCRIÇÃO DAS TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)	88
2.2.1	REDES NEURAIS ARTIFICIAIS (RNA)	88
2.2.1.1	<i>Multilayer Perceptron (MLP)</i>	90
2.2.1.2	<i>Radial Basis Functions Networks (RBF)</i>	91
2.2.1.3	<i>Rede Neural de Regressão Generalizada (GRNN)</i>	92
2.2.2	ADAPTIVE NEURO FUZZY INFERENCE SYSTEM (ANFIS).....	94
2.3	MATERIAL E MÉTODOS.....	95
2.3.1	LOCALIZAÇÃO E CLIMA.....	95

2.3.2	OBTENÇÃO DA BASE DE DADOS	96
2.3.2.1	<i>Controle de qualidade da base de dados.....</i>	97
2.3.3	ORGANIZAÇÃO DAS ESTIMATIVAS.....	97
2.3.4	MODELO ESTATÍSTICO (ME)	98
2.3.5	Treinamento das RNA e ANFIS	99
2.3.5.1	<i>Treinamento da MLP.....</i>	101
2.3.5.2	<i>Treinamento da RBF.....</i>	106
2.3.5.3	<i>Treinamento da GRNN</i>	108
2.3.6	TREINAMENTO DA ANFIS	110
2.3.7	BASE DE DADOS DE VALIDAÇÃO.....	112
2.3.8	INDICATIVOS ESTATÍSTICOS.....	113
2.4	RESULTADOS E DISCUSSÕES.....	114
2.4.1	EQUAÇÕES DE ESTIMATIVAS DO MODELO ESTATÍSTICO	115
2.4.1.1	<i>Validação das equações de estimativas</i>	116
2.4.2	REDES NEURAS ARTIFICIAIS E ANFIS.....	118
2.5	CONCLUSÕES.....	126
	REFERÊNCIAS	127
	CONSIDERAÇÕES FINAIS.....	133
	REFERÊNCIAS	131
	APÊNDICE A - Radiação Solar.....	139
	APÊNDICE B - Técnicas de Aprendizado de Máquina.....	144
	APÊNDICE C - Matrizes de Pesos e Limiares (<i>Bias</i>)	160

INTRODUÇÃO GERAL

Conhecer as intensidades das irradiações incidentes em superfícies inclinadas é de grande importância devido a sua ampla possibilidade de aplicações na engenharia, arquitetura e agronomia. Na engenharia e arquitetura a utilização dos dados da irradiação em superfícies inclinadas são essenciais para aplicações no desenvolvimento de projetos para captação de energia solar ativa (geração de energia elétrica por meio de painéis fotovoltaicos, aplicações voltadas para a eficiência energética, conforto térmico e sistemas de aquecimento) e passiva (projetos de iluminação natural de edificações) (Li et al., 2016; Vats et al., 2012; Alrubaih et al., 2013; Ghosal et al., 2005). Na agronomia o conhecimento dos dados da irradiação em superfícies inclinadas favorece o aperfeiçoamento do cultivo de culturas em topografias irregulares, pois as componentes da irradiação solar em superfícies inclinadas, estão diretamente associadas aos processos físicos, químicos e biológicos dos cultivos (Pezzopane et al., 2000; Casaroli et al., 2007; Silva et al., 2009; Weber, 2011; Escobedo et al 2009).

Consideradas as importâncias, os estudos dessas irradiações podem ser realizados com dados obtidos em séries temporais, as quais necessitam de medidas realizadas por um extenso período de tempo, o que as tornam mais restrita (Escobedo et al 2014), motivo pelo qual foram desenvolvidos diversos modelos estatísticos e por técnicas de aprendizado de máquina (TAM) para realizar estimativas de variáveis da radiação solar (Liu & Jordan, 1963; Hay, 1979; Temps & Coulson, 1977; Klucher, 1979, Perez et al. 1987; Kamali et al., 2005; Pandey et al., 2014).

Dentre as possibilidades de estimativas, os modelos estatísticos são os mais utilizados e são definidos por equações ajustadas por regressão linear ou polinomial em correlações com as frações radiométricas (Scolar, 2004; Jiang, 2009, Souza et al., 2011; Souza et al., 2013, Souza et al., 2012). Em sua maioria esses modelos consideram o comportamento isotrópico da radiação, sendo que os indicadores de precisão variam com a sazonalidade, base temporal e ângulo de inclinação da superfície (Liu e Jordan, 1960; Hay, 1979; Perez et al.,1986; Muzathik et al.,2011; Olmo et al.,1999; Pandey et al., 2014; El-Sebaii et al., 2010; Demain et al., 2013).

Os modelos por técnicas de aprendizado de máquina (TAM) do tipo Redes Neurais Artificiais (RNA) e Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS) se apresentam como método alternativo aos modelos estatísticos. Essas técnicas podem utilizar diferentes variáveis (astronômicas, geográficas e meteorológicas) em diversas combinações, sendo eficientes para tratar funções não-lineares tendendo a apresentar bons resultados nas estimativas, contudo no Brasil, atualmente predominam estudos por estimativas utilizando métodos estatísticos, não sendo comuns os estudos utilizando técnicas de aprendizado de máquinas (TAM). (Dahmani et al., 2011; Notton et al., 2012; Yadav et al., 2014; Sclar, 2004; Turco & Rizzatti, 2006; Souza et al., 2010; Souza et al., 2011; Beruski et al., 2015)

Como objetivo principal, este estudo visa analisar a eficiência das técnicas de aprendizado de máquina para estimativas de variáveis da radiação solar incidentes em superfície inclinada a partir de medidas na superfície horizontal, considerando que normalmente as estações meteorológicas medem com frequência estas variáveis.

Como objetivo específico, este estudo faz uma análise das técnicas de aprendizado de máquina (TAM) para realizar estimativas das irradiações global e difusa incidentes em uma superfície com inclinação de $22,85^\circ$ a partir de medidas da irradiação global e difusa incidentes na superfície horizontal. Os resultados são comparados aos obtidos com as estimativas usando modelos estatísticos (ME) clássicos.

CAPÍTULO 1

ESTIMATIVAS DA RADIAÇÃO GLOBAL E DIFUSA EM SUPERFÍCIE INCLINADA USANDO TÉCNICAS DE REDES NEURAIS ARTIFICIAIS E ANFIS

Adriano de Souza Marques; João Francisco Escobedo

RESUMO

Neste trabalho é realizado um estudo para estimar a transmissividade da radiação global (Kt_{β^h}) e a fração difusa (Kd_{β^h}) incidentes em uma superfície com inclinação de $22,85^\circ$ na base horária utilizando técnicas de aprendizado de máquina (TAM), a partir de dados obtidos no período de 1998 a 2001 em Botucatu/SP/Brasil. As estimativas foram realizadas usando uma série de combinações de variáveis astronômicas e geográficas por meio de três técnicas de redes neurais artificiais (RNA) do tipo Perceptron Multicamadas (MLP), Função de Base Radial (RBF) e Regressão Generalizada (GRNN) e do Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS). Como referência foram elaborados modelos estatísticos (ME) de regressão linear e polinomial. As estimativas de (Kt_{β^h}) foram realizadas por combinações de variáveis medidas e calculadas a partir da irradiação global na superfície horizontal (Hg_H) e nas estimativas de (Kd_{β^h}) utilizou-se combinações de variáveis medidas e calculadas a partir de (Hg_H) e da irradiação global na superfície inclinada (Hg_{β}). Os indicadores estatísticos r (correlação), RMSE(%) (precisão) e MBE(%) (exatidão) foram utilizados para avaliar os resultados das estimativas. Os melhores resultados nas estimativas de (Kt_{β^h}) a partir das combinações realizadas com (Hg_H) foram: MLP - RMSE=3,73%; RBF - RMSE=3,99%; GRNN - RMSE=5,27%; ANFIS - RMSE=3,78% e ME - RMSE=6,65%. Nesse caso os indicadores de precisão mostram uma redução de aproximadamente 44% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). Nas estimativas de (Kd_{β^h}) a partir das combinações de (Hg_H) os melhores resultados foram: MLP - RMSE=21,69%; RBF - RMSE=25,43%; GRNN - RMSE=29,39%; ANFIS - RMSE=23,08% e - ME - RMSE=35,35%. Da mesma forma os indicadores de precisão mostram uma redução de aproximadamente 39% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). E nas estimativas de (Kd_{β^h}) a partir das combinações realizadas com (Hg_{β}) os melhores resultados foram: MLP - RMSE=20,32%; RBF - RMSE=21,95%; GRNN - RMSE=29,11%; ANFIS - RMSE=21,75% e ME - RMSE=36,48%. Os indicadores de precisão mostram uma redução de aproximadamente 44% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). Os resultados mostram que a técnica de rede neural artificial MLP apresentou os melhores índices em todas as estimativas de (Kt_{β^h}) e (Kd_{β^h}) com reduções significativas quando comparadas aos resultados obtidos com as estimativas obtidas com os modelos estatísticos. Pela análise dos resultados é possível observar que o uso das técnicas de aprendizado de máquina (TAM) nas combinações de variáveis propostas e com os dados obtidos de Botucatu/SP, se apresentam como alternativa aos modelos estatísticos (ME) para estimar as variáveis de (Kt_{β^h}) e (Kd_{β^h}).

Palavras-chave: Irradiação solar, Redes Neurais Artificiais, ANFIS, Estimativas.

ABSTRACT

In this work, a study was carried out to estimate the transmissivity of the global radiation (Kt_{β}^h) and the diffuse fraction (Kd_{β}^h) incident on a surface with slope of 22.85° in the hourly basis using machine learning techniques (MLT), from data obtained from 1998 to 2001 in Botucatu / SP / Brazil. The estimates were made using a series of combinations of astronomical and geographic variables by means of three artificial neural network (ANN) techniques such as MultLayer Perceptron (MLP), Radial Basis Functions Networks (RBF) and Generalized Regression Neural Network (GRNN) Adaptive Neuro Fuzzy Inference System (ANFIS). Statistical models (SM) of linear and polynomial regression were elaborated as reference. Estimates of (Kt_{β}^h) were performed by combinations of variables measured and calculated from global horizontal surface irradiation (Hg_H) and estimates of (Kd_{β}^h) combinations of variables measured and calculated from (Hg_H) and global radiation on the sloped surface (Hg_{β}). The best results in the estimates of (Kt_{β}^h) from the combinations performed with (Hg_H) were: MLP - RMSE = 3.73%; RBF - RMSE = 3.99%; GRNN - RMSE = 5.27%; ANFIS - RMSE = 3.78% and SM - RMSE = 6.65%. In this case the precision indicators show a reduction of approximately 44% with the use of the technique (MLP) in comparison to the statistical model (SM). In the estimates of (Kd_{β}^h) from the combinations of (Hg_H) the best results were: MLP - RMSE = 21.69%; RBF - RMSE = 25.43%; GRNN - RMSE = 29.39%; ANFIS - RMSE = 23.08% and SM - RMSE = 35.35%. Likewise, the precision indicators show a reduction of approximately 39% with the use of the technique (MLP) in comparison to the statistical model (SM). And in the estimates of (Kd_{β}^h) from the combinations performed with (Hg_{β}) the best results were: MLP - RMSE = 20.32%; RBF - RMSE = 21.95%; GRNN - RMSE = 29.11%; ANFIS - RMSE = 21.75% and SM - RMSE = 36.48%. The precision indicators show a reduction of approximately 44% with the use of the technique (MLP) in comparison to the statistical model (SM). The results show that the artificial neural network MLP technique presented the best indexes in all estimates of (Kt_{β}^h) and (Kd_{β}^h) with significant reductions when compared to the results obtained with the estimates obtained with the statistical models. By the analysis of the results it is possible to observe that the use of the machine learning techniques (MLT) in the combinations of proposed variables and the data obtained from Botucatu / SP, are presented as an alternative to the statistical models (SM) to estimate the variables of (Kt_{β}^h) and (Kd_{β}^h).

Keywords: Solar Irradiation, Artificial Neural Networks, ANFIS, Estimates.

1.1 INTRODUÇÃO

O conhecimento das irradiações incidentes em superfícies inclinadas tem alcançado grande importância devido à crescente demanda por soluções de fontes alternativas de geração de energia, além de sua ampla possibilidade de aplicações em diversas áreas da engenharia, arquitetura e agronomia (Li et al., 2016; Vats et al., 2012; Alrubaih et al., 2013; Ghosal et al., 2005). Sendo assim, se faz necessário estudos da irradiação global e suas componentes direta e difusa avaliadas na superfície inclinada.

A irradiação global incidente em superfícies inclinadas (Hg_{β}) é composta pela soma das irradiações direta (Hb_{β}), difusa (Hd_{β}) e refletida (Hr_{β}) [$Hg_{\beta} = Hb_{\beta} + Hd_{\beta} + Hr_{\beta}$] com seu respectivo ângulo de inclinação da superfície (β) e orientação voltada para o norte (linha do equador).

As séries (medidas) dessas componentes devem ser obtidas por instrumentos como piranômetros, pireliômetros acoplados a dispositivos de rastreamento solar e piranômetros instalados sob mecanismos de sombreamento, respectivamente. Porém, devido aos custos dos equipamentos, necessidade de medidas contínuas no local com realizações das aferições periódicas, essas séries se tornam uma desvantagem e as tornam pouco comum nas estações de radiometria solar (Escobedo et al 2014), motivo pelo qual se justifica o uso das estimativas como uma alternativa para recomposição ou obtenção de dados para pesquisas e aplicações que necessitem dessas informações.

As técnicas mais comuns utilizadas para a realização de estimativas da irradiação solar são os modelos estatísticos e paramétricos. Os modelos paramétricos necessitam de informações mais completas das condições atmosféricas locais; os modelos estatísticos são executados por equações ajustadas por meio de regressão linear ou polinomial em correlações com as frações radiométricas, porém destaca-se cada vez mais o uso das técnicas de aprendizado de máquina (TAM) como as redes neurais artificiais (RNA) e ANFIS na realização de estimativas da irradiação solar global e difusa (Souza, 2011; Jiang, 2009; Dahmani et al., 2013; Notton et al., 2012).

Diversos estudos no país e também na FCA em Botucatu/SP utilizando modelos estatísticos (ME) foram desenvolvidos para determinação da irradiação solar

global (Hg_{β}) e difusa (Hd_{β}) em uma superfície inclinada a partir de dados da irradiação solar global medidos na superfície horizontal (Hg_H). Esses estudos foram realizados com base nos modelos de estimativa definidos por Liu e Jordan (1960), Hay (1979) e Perez et al. (1986) e com base nos modelos empíricos definido por Olmo et al. (1999). Estudos também avaliaram o desempenho de modelos isotrópicos de estimativa de irradiação incidente em superfícies com inclinações de 12,85°, 22,85° e 32,85°, pelos modelos propostos por Liu e Jordan (1960), Revfeim (1978), Jimenez & Castro (1982), Koronakis (1986), a teoria Circunsolar para diferentes condições de cobertura de céu, com o objetivo de propor 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. 2010; Sclar et al. 2004; Muzathik et al. 2011). Também foram realizados estudos 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°, 22,85° e 32,85°, a partir da irradiação global na horizontal usando equações estatísticas de estimativas de Liu e Jordan (1960), Turco e Rizzatti (2006); Notton et al. (2006); Jiang (2009) (Souza et al. 2011).

Em muitos países, predominantemente do hemisfério norte, é comum o uso de técnicas de RNA para estudos da radiação em diferentes inclinações de superfícies com bases horária, diária e mensal. Dentre as técnicas de RNA mais utilizadas está a *MultiLayer Perceptron* (MLP), devido a sua facilidade de implementação, parametrização e capacidade de otimização dos problemas (Elizondo et al., 1996; Bosch et al., 2008; Yadav et al., 2014; El-Sebaei et al., 2010, Razafiarison et al., 2011; 31,35, Notton et al., 2012; Dahmani et al., 2013; Rahoma et al., 2011). Outras técnicas de RNA como a (RBF) e (GRNN) além da técnica (ANFIS) são pouco exploradas para estimar variáveis da radiação solar (Elminir et al., 2007, Sumithira & Kumar, 2012).

A rede neural artificial foi utilizada 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, em Madagascar. O estudo utilizou arquitetura *MultiLayer Perceptron* (MLP) para realizar as estimativas, aplicando como variáveis de entrada o índice de transmissividade atmosférica (K_T), latitude (ϕ), longitude (L) e inclinação da superfície (β). Os resultados foram comparados com os modelos teóricos obtidos por Liu e Jordan. (1960) (Razafiarison et al. 2011). Outro estudo foi realizado 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 diversos modelos 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 (H_0) e a irradiação global na horizontal (H_g) para estimar a irradiação global nas inclinações de 45° e 60° . (Notton et al. 2012). As redes neurais artificiais também foram utilizadas para estimar a irradiação em um plano inclinado na localidade de Bouzareah - Argélia. As 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 (H_0) e irradiação global horizontal na partição de 5 minutos (I_g). A arquitetura de rede utilizada foi a MLP com 1 camada oculta e 8 neurônios. (Dahmani et al. 2013)

No Brasil existem poucos estudos de estimativas dessas variáveis utilizando RNA e ANFIS, sendo ainda mais escassos na literatura estimativas com a radiação global e difusa em superfícies inclinadas na base horária usando essas técnicas.

Considerando a importância de se entender o comportamento das radiações global e difusa em superfícies inclinadas com base horária, medições foram realizadas entre os anos de 1998 e 2001 das irradiações global (H_{gH^h}) e difusa (H_{dH^h}) na superfície horizontal e global ($H_{g\beta^h}$) e difusa ($H_{d\beta^h}$) em superfície com inclinação de $22,85^\circ$ voltada para o norte no município de Botucatu/SP. A partir dessas medidas o objetivo deste estudo é avaliar dentre as técnicas de aprendizado de máquina (TAM) - Redes Neurais Artificiais (RNA) e Sistema de Inferência Neuro Fuzzy (ANFIS) - um modelo para estimar radiações global e difusa em superfície inclinada a partir dos dados medidos da irradiação global (H_{gH^h}) na superfície horizontal e comparar seus resultados aos obtidos com o Modelo Estatístico (ME) baseado em Liu e Jordan (1962).

1.2 DESCRIÇÃO DAS TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)

O princípio de funcionamento das Técnicas de Aprendizado de Máquinas é similar ao processo de aprendizado do cérebro humano. A partir de um conjunto de


informações ou de experiências adquiridas (dados de entrada) é possível obter (aprender) uma série de resultados (dados de saída). Isso se deve ao fato de que as técnicas podem reconhecer padrões de diferentes grandezas, como dados meteorológicos ou climatológicos, e através de um algoritmo de aprendizagem estabelecer uma associação entre dados de entradas e dados de saídas para adquirir conhecimento de forma automática e produzir resultados coerentes em estimativas ou classificação de dados (Lorena et al., 2011)

Entre as técnicas de aprendizado de máquinas mais empregadas para estimar radiação solar em superfície horizontais ou inclinadas destacam-se as Redes Neurais Artificiais (RNA) e o Sistemas de Inferência Adaptativo Neuro-Fuzzy (ANFIS) (Yadav e Chandel, 2014; Lauret et al., 2015; Santos et. al, 2016; Silva et. al, 2017; Assouline et. al, 2017).

1.2.1 Redes Neurais Artificiais (RNA)

As RNA apresentam uma estrutura formada por um conjunto de elementos chamados neurônios distribuídos paralelamente. É composta por uma camada de entrada e uma de saída conectadas por uma ou mais camadas ocultas. O processamento de informações entre as camadas é realizado por um algoritmo capaz de analisar funções complexas e não lineares, o que nem sempre é possível com o uso de técnicas estatísticas convencionais. São utilizadas para o reconhecimento e classificação de padrões, agrupamento, previsão e estimativas.

A Figura 1.1 apresenta a estrutura básica de um neurônio artificial formado por um conjunto de conexões (*sinapses*) que recebem os valores de entrada ($x_1, x_2, \dots, x_i$) definidos pelos pesos sinápticos ($w_1, w_2, \dots, w_i$). Através de um combinador linear (Σ), executa a soma ponderada das entradas, produzindo uma saída chamada de potencial de ativação (u) que é então transformada por uma função de ativação (f), que gera a saída (y) limitada por um intervalo de valores definido pelo limiar de ativação (*bias* - b) (Marzouq et al. 2017).

Figura 1.1 - Modelo do neurônio artificial

Fonte: McCullochPitts (1943).

A principal característica de uma RNA está na capacidade de aprendizado proporcionado pela arquitetura e no processo de treinamento utilizado. O aprendizado é consequência das mudanças de valores dos pesos sinápticos, conectados aos neurônios entre as camadas com o objetivo de aproximar os valores da saída da rede (y) com os valores desejados. Esse processo é realizado por um algoritmo de treinamento que define aspectos importantes como o número de neurônios, número de camadas ocultas, função de ativação e conjunto de dados para treinamento e validação.

Os primeiros trabalhos envolvendo a radiação solar, usaram a RNA para realizar estimativas da irradiação solar global (Elizondo et. al, 1994; Mohandes et. al, 1998). As técnicas foram sendo aprimoradas e utilizadas para estimar outras irradiações como a direta e difusa (Bosch et al., 2008; El-Sebaai et al., 2010; Razafiarison et al., 2011; Rahoma et al., 2011; Notton et al., 2012; Dahmani et al., 2013; Yadav et al., 2014; Santos et al., 2016).

Entre as técnicas de RNA utilizadas para estimativa de radiação solar destacam-se a Rede *Perceptron Multicamadas* (MLP) amplamente utilizada na literatura em diversas áreas, a Rede de Função de Base Radial (RBF) proposta como alternativa à MLP e a Rede de Regressão Generalizada sendo uma otimização da RBF (Mohandes et. al, 1998; Alam et. al, 2009; Mellit et. al, 2010; Dorvlo et. al, 2012; Feng et. al, 2017; Citakoglu, 2017).


1.2.1.1 Multilayer Perceptron (MLP)

Caracterizada pela presença de pelo menos uma camada intermediária de neurônios localizada entre as camadas de entrada e a camada de saída. São

classificadas como redes do tipo *feedforward* (alimentação a frente) de camadas múltiplas. O treinamento é realizado de forma supervisionada, ou seja, para cada informação de entrada tem-se uma respectiva saída desejada (Alam et al. 2009).

A Figura 1.2 mostra a estrutura da rede MLP, onde o fluxo de treinamento tem início quando as variáveis de entrada (x) são aplicadas na camada de entrada, deslocando-se às camadas ocultas até a camada de saída finalizando o processamento por uma função de ativação (normalmente linear) na camada de saída (Rehman e Mohandes, 2008).

Figura 1.2 - Arquitetura da Rede Neural Perceptron Multicamadas.



Fonte: Yadav e Chandel (2014).

Durante o processo de treinamento, algoritmos procuram ajustar os pesos ($w_{i,j}$) entre os neurônios das entradas e a saída desejada. Algoritmos como o *backpropagation* (BP) otimizados por *Levenberg-Marquardt* ajustam os pesos através de taxas de aprendizagem (controle dos *bias* - Θ) e de taxas de convergências (controle de velocidade) tornando o processo de treinamento da rede mais rápido e eficiente (Kovács, 2006; Linares-Rodriguez et al., 2011; Azevedo et al., 2000; Braga et al. 2012).

Com arquitetura flexível e pouca complexidade, a rede MLP é mais utilizada na estimativa da irradiação solar, com diversos estudos realizados para estimar a irradiação global (H_g) (Elizondo et. al, 1994; Kalogirou, 2000; Tymvios et. al, 2005; Notton et. al, 2012; Kumar et. al, 2015; Yadav et al. 2014; Silva et. al, 2016), irradiação solar direta (H_b) (Alam et. al, 2006; Tomar et. al, 2012; Kaushina et. al, 2014; Santos et al., 2016), irradiação solar difusa (H_d) (Soares et. al, 2004; Alam et. al, 2009; Ihya et. al, 2015; Boznar et. al, 2017) e radiação PAR (P. Pankaew et. al, 2014; Jacovides, 2015; Wang, 2016). Esses estudos utilizaram como entrada diversas variáveis


climatológicas e geográficas, obtendo melhor precisão nas estimativas comparados aos métodos estatísticos convencionais.

1.2.1.2 Radial Basis Functions Networks (RBF)

A RBF é uma técnica de RNA utilizada em diversas aplicações como modelagem de séries temporais. Pode ser aplicada em quase todos os tipos de problemas pelos quais outras técnicas de RNA são utilizadas. A diferença está na composição de sua estrutura, das informações recebidas, do número de camadas e do número de neurônios da camada (Behrang et al., 2010; Wang et al., 2016).

É classificada como rede do tipo *feedforward* com treinamento realizado em duas fases distintas: a não supervisionada que consiste na identificação dos pesos (W_1) e a supervisionada (*backpropagation*) que consiste na identificação dos pesos (W_2). Sua estrutura é formada por três camadas, sendo estas, a camada de entrada; a camada intermediária que possui uma função de base radial como função de ativação (geralmente Gaussiana) e a camada de saída que realiza a soma dos pesos dos neurônios da camada intermediária e tem função de ativação linear (Figura 1.3.) (Crispim et. al, 2006; Braga et al. 2012; Behrang et al., 2010).

Figura 1.3 - Arquitetura da Rede Neural de Base Radial.



Fonte: Behrang et al.(2010).

A rede RBF é uma técnica de RNA com bons resultados nas estimativas de irradiação solar, tendo estudos desenvolvidos para estimativas da irradiação solar global (H_g) (Sfetsos, 2000; Dorvlo et al., 2002; Behrang et al., 2010; Benghanem e Mellit, 2010; Wang et al., 2016; Silva et. al, 2016), irradiação solar direta (H_d) (Yadav,

2014; Mishra et al. 2008; Mohandes, 2012; Santos et al., 2016) e irradiação solar difusa (H_d) (Soares et. al, 2004; Mehleri et al.,2010; Mohandes, 2012).


1.2.1.3 Rede Neural de Regressão Generalizada (GRNN)

Considerada uma otimização da rede neural RBF, a GRNN não requer um treinamento iterativo e consiste de duas camadas de processamento (padrão e somadora) além das camadas de entrada e saída (Figura 1.4). Foi desenvolvida como proposta alternativa ao algoritmo *backpropagation* para a rede neural *feedforward* (SPECHT, 1991). Possui grande capacidade de generalização, assim como outras redes, com aplicação também em diversos processos, como no ajuste de curvas ou aproximações de funções (Specht, 1991).

A GRNN pode ser definida como uma Rede Neural Artificial (RNA) com estrutura do tipo *feedforward*, ou seja, não recorrente e requer treinamento supervisionado.

A Figura 1.4 apresenta a estrutura da rede GRNN sendo sua arquitetura composta de duas camadas, a primeira chamada de padrão e a segunda de somadora, além das camadas de entrada e saída. A camada de entrada irá inserir os vetores de entrada ($x_{i,j}$) na rede que se posicionam em um determinado centro denominado cluster, o qual tem sua posição subtraindo-se do vetor que foi armazenado ao centro da função gaussiana (Cellik e Muneer, 2013). Os valores absolutos dessa diferença são somados e alimentados na função de ativação não linear (exponencial) na camada padrão (Cn). A saída da camada padrão é encaminhada para a camada somadora, que realizam o somatório do produto entre o vetor peso ($w_{i,j}$) e o vetor obtido na saída da unidade padrão, por fim, as saídas dividem cada resultado da camada somadora pelo somatório total de todas as unidades da soma (Specht, 1991).

Figura 1.4 - Arquitetura da GRNN.



Fonte: Adaptado de Specht (1991).

A técnica de aprendizado da GRNN difere das redes neurais mais utilizadas, pois possui um processo de aprendizado que não faz uso do ajuste iterativo para adquirir conhecimento no treinamento, porém, possui capacidade de aprender quase que instantaneamente com os dados apresentados na base de treinamento. O método simplesmente armazena os padrões de treinamento e os processa através de uma função não linear para determinar as funções componentes de densidade de probabilidade de saída (Specht, 1996).

Apesar de sua simplicidade as redes GRNN têm capacidade de estimar qualquer função não linear, mas os resultados podem ser afetados devido a uma série de fatores como a qualidade e quantidade de dados utilizados no treinamento. Este aspecto pode tornam as redes GRNN pouco utilizadas em estimativas da irradiação solar, porém com estudos recentes realizados para estimar a irradiação solar global (Şenkal et al., 2010; Şenkal et al., 2010A; Celik and Muneer, 2013; Wang et. al, 2016; Feng et. al, 2017).


1.2.2 Adaptive Neuro Fuzzy Inference System (ANFIS)

A ANFIS pode ser definida como a combinação das características de aprendizado de uma rede neural adaptativa (ANN) com a interpretação de um sistema de inferência fuzzy (FIS) (Jang, 1993; Zadeh, 1965; Takagy e Sugeno, 1985).

O ANFIS é capaz de aproximar qualquer função contínua real em um conjunto compacto de parâmetros para qualquer grau de precisão (Jang, 1997). Identifica um conjunto de parâmetros através de uma regra de aprendizado híbrida e possui duas abordagens para sistemas de inferência fuzzy (Mamdani, 1975) e (Sugeno, 1985).

A Figura 1.5 apresenta a estrutura ANFIS, composta de cinco camadas e duas funções de pertinência para cada entrada.

Figura 1.5 - Arquitetura da ANFIS



Fonte: Mohammadi et al. (2016).

No processo de treinamento híbrido a Lógica Fuzzy integra o conhecimento implícito (dados) e explícito (especialista) na definição das variáveis a serem utilizadas por meio de interações entre as camadas que acontecem em dois processos: *fuzzificação* e *defuzzificação* (Wang et al., 2009; Quej et al., 2017). Na primeira e segunda camadas se realiza o mapeamento das variáveis por meio da aplicação da função de pertinência que melhor retrata a distribuição dos dados (*fuzzificação*), na terceira camada ocorre a normalização das informações com o grau de ativação da regra anterior em relação às demais. Na quarta camada encontra-se a composição das regras, finalizando com o processo de defuzzificação e a totalização dos valores na quinta camada (saída) (Jang, 1993; Takagy e Sugeno, 1985; Wang et al., 2009; Quej et al., 2017).

A ANFIS é uma técnica de aprendizado de máquina cada vez mais presente em estudos de estimativas da radiação solar, porém tem sido utilizada com mais frequência para estimar a irradiação global (H_g) (Sfetsos, 2000; Mellit, 2007; Moghaddamnia, 2009; Rahoma et al. 2011; Landeras, 2012; Kumar, 2012; Olatomiwa et al., 2015; Mohammadi, 2015; Zou, 2017)

1.3 MATERIAL E MÉTODOS

1.3.1 Localização e Clima


Os dados utilizados neste estudo foram medidos na Estação de Radiometria Solar na Faculdade de Ciências Agronômicas – FCA/UNESP no município de Botucatu/SP/Brasil (22°53'S de latitude, 48°26'W na longitude e altitude de 786m). A

classificação climática de Köppen para o local é Cwa (Cepagri, 2012), temperado quente com verão quente e úmido e elevada precipitação, inverno frio e seco. (Teramoto e Escobedo, 2012).

As séries climáticas da temperatura, umidade relativa, nebulosidade e precipitação no período de 1970 a 2008 estão apresentadas nas Figuras 1.6 (a), (b) e (c), e a evolução anual das médias mensais da Profundidade Ótica dos Aerossóis (POA) e Material Particulado (PM) médias mensais no período de 2001 a 2005 estão apresentadas na Figura 1.6 (d), sendo que:

A Figura. 1.6(a) mostra a série anual da temperatura e umidade relativa e destaca fevereiro como o mês mais quente e julho o mais frio, bem como o mês de janeiro o mais úmido e o mês de agosto o menos úmido; A Figura 1.6(b) mostra que a nebulosidade $[f=1-(n/N)]$ é mais elevada nos meses de janeiro e menor nos meses de agosto; A Figura 1.6(c) mostra que a série anual da precipitação, acompanha a evolução da nebulosidade podendo ser classificada em período chuvoso (outubro a março) e seco (abril a setembro), onde o limite entre os limites é o valor da precipitação de aproximadamente 100mm; A Figura 1.6(d): mostra a evolução anual das médias mensais da profundidade ótica de aerossóis (POA) do período de 2000 a 2005 obtidas pelo satélite TERRA do período de 2000 a 2005 indicando que no período de queimadas da cana de açúcar (julho), a concentração de aerossóis aumenta consideravelmente atingindo valor máximo de 0.45 no mês de setembro. Esse valor corresponde a uma concentração de material particulado (PM_{10}) igual a $70.0\mu g.m^{-3}$ (Codato et al., 2008; Rossi, T., 2017)

Figura 1.6 - Séries Climáticas (período: 1970-2008): (a) Temperatura e Umidade Relativa, (b) Nebulosidade, (c) Precipitação, (d) Relação entre a evolução anual da Profundidade Ótica dos Aerossóis (POA) e Material Particulado (PM) em médias mensais (obtidas do satélite TERRA) no ano de 2001 a 2005



Fonte: Rossi, T.J. (2017).

1.3.2 Obtenção da Base de dados

Os dados das medidas instantâneas (irradiância – W/m^2) das radiações global e difusa nas superfícies horizontal e com inclinação de $22,85^\circ$ foram obtidos no período de 10/4/1998 a 31/08/2001 através de medidas realizadas a cada 5 segundos e posteriormente calculadas as médias de 5 minutos. Esses dados foram então integralizados em energia (irradiação – MJ/m^2) e separados em séries temporais na partição horária.

A irradiância global instantânea na horizontal foi medida com um pirômetro EPPLEY-PSP com fator de calibração de $7,45 \mu V/Wm^{-2}$ e linearidade de $\pm 0,5\%$ de 0 a $2800 Wm^{-2}$. As medidas da irradiância global no plano inclinado foram obtidas por pirômetros CM3 da Kipp & Zonen, que possuem uma sensibilidade de resposta de $\pm 10-35 \mu V/Wm^{-2}$. As radiações difusas na horizontal também utilizaram pirômetros EPPLEY-PSP, e no plano inclinado utilizou-se pirômetro Branco & Preto EPPLEY, ambos com anel de sombreamento proposto por Melo e Escobedo (1994). Figura 1.7.

Figura 1.7 - Estrutura para medida das radiações global e difusa nos planos horizontal e inclinado



Medidas na Horizontal



Medidas na Inclinada

Foram medidas as variáveis da irradiâncias global (I_g), difusa (I_d) ambas em superfície horizontal e inclinada, bem como as variáveis humidade relativa (Rh), temperatura do ar (Tar) e nebulosidade (Neb). As variáveis da irradiação no topo da atmosfera (H_0), ângulo zenital (θ_z), declinação solar (δ), transmissividade da global (Kt^h), fração difusa (Kd^h) e massa ótica (mr) foram calculadas.

1.3.2.1 Controle de qualidade da base de dados

Os dados foram analisados e os valores discrepantes ocorridos em função de erros de leitura foram eliminados. Após calculado, os dados da transmissividade da global ($Kt = H_g/H_0$) e fração da difusa ($Kd = H_d/H_g$) foram normalizados eliminando-se valores menores que 0 e maiores que 1; já os dados do ângulo zenital (θ_z) tiveram rejeitados os valores maiores que 80° ; os valores da irradiação no topo da atmosfera (H_0) foram normalizados eliminando-se os valores maiores que $5,0 \text{ MJ/m}^2$, valor obtido considerando a variação na intensidade da irradiação no topo da atmosfera ($4,91 \text{ MJ/m}^2 - I_{qbal}$, 1983) em função da excentricidade da órbita terrestre que varia $\pm 3\%$ no afélio e no periélio (Duffie e Beckman, 1991). Após a aplicação dos filtros houve uma redução de 7% na base de dados.


1.3.3 Organização das estimativas

Para realizar as estimativas a partir das medidas das irradiações H_{gH^h} e $H_{g\beta^h}$ em base horária, foram utilizadas as transmissividades global Kt_{H^h} e Kt_{β^h} de forma a minimizar os aspectos das variações temporais da radiação que oscilam com as

condições astronômicas, geográficas e climáticas (Iqbal, 1983; Liou, 2002; Varejão-Silva, 2006). A utilização das frações minimiza os efeitos astronômicos e geográficos, considerando que as componentes da radiação são obtidas no mesmo local e intervalo de tempo, já os efeitos climáticos são mantidos, principalmente em função a interação com vapor de água e aerossóis (Dal Pai, 2005).

As estimativas foram organizadas e nominadas de acordo com o diagrama da Figura (1.8).

Figura 1.8 - Organização das radiações global e difusa nos planos horizontal e inclinado.



Fonte: Elaborado pelo Autor.

Onde:

- (A) Estimar a transmissividade da radiação global na superfície inclinada (Kt_{β}^h) a partir das medidas da irradiação global na superfície horizontal (Hg_H^h);
- (B) Estimar a fração difusa da radiação global na superfície inclinada (Kd_{β}^h) a partir das medidas da irradiação global na superfície horizontal (Hg_H^h);
- (C) Estimar a fração difusa da radiação global na superfície inclinada (Kd_{β}^h) a partir das medidas da irradiação global na superfície com mesma inclinação (Hg_{β}^h).

1.3.4 Modelo Estatístico (ME)

Os modelos estatísticos de estimativa das irradiações baseados nas frações das radiações global e difusa, foram definidos conforme metodologias encontradas na literatura baseadas em Liu e Jordan (1960).

Os modelos modificados para estimar Kt_{β}^h e Kd_{β}^h em superfície inclinada na partição horária são definidas pelas relações definidas na Tabela 1.1:

Tabela 1.1 - Variáveis selecionadas para as estimativas com as técnicas de Modelagem de Máquina

Fig. 1.8	Estimativa	Modelo	Ajuste
(A)	$Kt_{\beta}^h = f(Kt_H^h)$	$y = a + b(x)$	Regressão linear
(B)	$Kd_{\beta}^h = f(Kt_H^h)$	$y = a + b.(x)^1 + c.(x)^2 + d.(x)^3$	Polinômio 3ª ordem
(C)	$Kd_{\beta}^h = f(Kt_{\beta}^h)$	$y = a + b.(x)^1 + c.(x)^2 + d.(x)^3 + e.(x)^4$	Polinômio 4ª ordem

1.3.5 Treinamento das RNA e ANFIS

Para as estimativas utilizando as redes neurais artificiais (RNA) com as técnicas MLP, RBF e GRNN e também pelo sistema híbrido ANFIS, foram realizados treinamentos usando o software MATLAB R2014a, o qual pode ser descrito como uma ferramenta computacional de alto desempenho com ampla aplicação nas áreas de engenharia e ciências. Possui linguagem de programação proprietária que permite o desenvolvimento de computação numérica de forma dinâmica. O uso do MATLAB para implementação de RNA e ANFIS, possui grande destaque devido a sua ampla disponibilidade de funções para este fim, bem como ampla documentação oficial disponível (Mathworks, 2017).

As variáveis de entrada merecem destaque quando se trata de estimativas usando técnicas de aprendizado de máquina (TAM). Deve-se considerar a natureza da radiação solar, onde diversos parâmetros podem influenciar na sua intensidade e na sua disponibilidade de maneira bastante complexa, o que pode dificultar o processo de estimativa através das TAM (Tymvios et al., 2005).

Dependendo da qualidade, quantidade e correlações existentes os resultados obtidos podem comprometer a generalização do problema estudado.

O critério adotado para determinação das variáveis foi com base na disponibilidade das variáveis medidas e calculadas, considerando a influência que cada uma possa proporcionar na estimativa, além das indicações apresentadas na bibliografia e as relações físicas existente entre as variáveis de entrada e a variável a ser estimada. Um número excessivo de variáveis deve ser evitado, pois isso pode prejudicar os resultados e desempenho da rede, pois aumenta seu tamanho e

complexidade. De forma contrária um número reduzido de variáveis de entrada pode tornar a rede incapaz de aprender devido à falta de informações.

As variáveis adotadas neste estudo com base nesse critério estão apresentadas na Tabela 1.2.

Tabela 1.2 - Variáveis selecionadas para as estimativas com as técnicas de Aprendizado de Máquina

Descrição	Variável	Medida	Calculada
Frações das radiações Global nas superfícies horizontal e inclinada	Kt_H^h		x
	Kt_β^h		x
Declinação Solar	δ		x
Irradiação no topo da atmosfera nas superfícies horizontal e inclinada	$H0_H^h$		x
	$H0_\beta^h$		
Ângulo Zenital	θ_z		x
Massa óptica	mr		x
Temperatura do ar	Tar	x	
Umidade Relativa	Rh	x	
Nebulosidade	Neb		x

As variáveis de entrada e saída foram organizadas em arranjos de combinações, separadas em arquivos no formato CSV (*Comma-Separated Values*) contendo os dados de treinamento conforme exemplo na Figura 1.9.

Figura 1.9 - Exemplo da estrutura do arquivo CSV

Variáveis de Entrada						Variável de Saída
KTh(Y)	H0h(Y)	Zt(Y)	Decl(Y)	Tar(Y)	Neb(Y)	KDI(Y)
0.55296	1.44995	67.49839	7.65552	18.91583	41.66667	0.42777
0.55815	2.46002	52.49877	7.65552	18.64833	0	0.417
0.42814	3.28509	37.49915	7.65552	18.4725	41.66667	0.67453
0.42317	3.8689	22.49955	7.65552	18.555	91.66667	0.71839
0.63803	4.17165	7.50012	7.65552	18.46917	25	0.48167
0.54904	4.1727	7.50012	7.65552	18.77	41.66667	0.54009
0.65412	3.87197	22.49955	7.65552	20.01833	0	0.30426
0.55130	3.28007	37.49915	7.65552	20.07833	41.66667	0.30002

Fonte: Elaborado pelo Autor.

As combinações dos arranjos foram determinadas de forma a promover uma avaliação da influência das variáveis selecionadas nos resultados das estimativas, conforme mostra a Tabela 1.3.

Tabela 1.3 - Modelos de treinamento da RNA e ANFIS.

(A)

ESTIMATIVAS DE $Kt_{\beta}^h = f(Kt_H^h)$							
Variáveis de Entrada							Variável Estimada
ME/M1	Kt_H^h						
M2	Kt_H^h	$H0_H^h$					
M3	Kt_H^h	$H0_H^h$	Θ_i				
M4	Kt_H^h	$H0_H^h$	Θ_i	δ			
M5	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar		Kt_{β}^h
M6	Kt_H^h	$H0_H^h$	Θ_i	δ	Rh		
M7	Kt_H^h	$H0_H^h$	Θ_i	Tar	Rh		
M8	Kt_H^h	$H0_H^h$	δ	Tar	Rh		
M9	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar	Rh	

(B)

ESTIMATIVAS DE $Kd_{\beta}^h = f(Kt_H^h)$							
Variáveis de Entrada							Variável Estimada
ME/M1	Kt_H^h						
M2	Kt_H^h	$H0_H^h$					
M3	Kt_H^h	$H0_H^h$	Θ_i				
M4	Kt_H^h	$H0_H^h$	Θ_i	δ			
M5	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar		Kd_{β}^h
M6	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar	mr	
M7	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar	Rh	
M8	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar	Neb	

(C)

ESTIMATIVAS DE $Kd_{\beta}^h = f(Kt_{\beta}^h)$							
Variáveis de Entrada							Variável Estimada
ME/M1	Kt_{β}^h						
M2	Kt_{β}^h	$H0_{\beta}^h$					
M3	Kt_{β}^h	$H0_{\beta}^h$	Θ				
M4	Kt_{β}^h	$H0_{\beta}^h$	Θ_i	δ			
M5	Kt_{β}^h	$H0_{\beta}^h$	Θ_i	δ	Tar		Kd_{β}^h
M6	Kt_{β}^h	$H0_{\beta}^h$	Θ_i	δ	Tar	mr	
M7	Kt_{β}^h	$H0_{\beta}^h$	Θ_i	δ	Tar	Rh	
M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_i	δ	Tar	Neb	

O índice Erro Quadrático Médio (EQM) foi utilizado como indicador de desempenho dos treinamentos da RNA e ANFIS. O EQM determina o erro médio entre os valores da saída obtidos com o treinamento da rede (E) e os valores desejados ou medidos (M), o parâmetro (x) é o número de amostras do treinamento (Equação 1.1).

$$EQM = \left[\frac{\sum_{i=1}^x (E-M)^2}{x} \right] \quad (1.1)$$

A parametrização para definição da arquitetura de treinamento deste estudo utilizou como referência a obtenção do menor valor do índice da Raiz do Erro Quadrático Médio relativo (RMSE%) que determina a precisão obtida com o treinamento da rede e a validação cruzada.

1.3.5.1 Treinamento da MLP

A MLP foi treinada com o algoritmo de aprendizagem *Levenberg-Marquadt* (função *trainlm*) implementado pela função *feedforwardnet* em um *script* desenvolvido no MATLAB R2014a, e parametrizada com o número de neurônios, número de camadas ocultas e número máximo de épocas de treinamento (neste estudo após testes realizados foi definido o número de 1000 épocas máxima para os treinamentos).

Outro algoritmo utilizado nos treinamentos foi o *Bayesiana* (função *trainbr*), o qual pode ser definida como uma função que atualiza os valores de peso e polarização de acordo com a otimização *Levenberg-Marquardt*. Esse algoritmo minimiza uma combinação de erros e pesos quadrados e em seguida determina a combinação correta para produzir uma rede que generalize bem (Mathworks, 2017), porém o desempenho da rede não apresentou resultados satisfatórios e foi desconsiderado.

A condição para determinação do número de neurônios e de camadas ocultas depende de uma série de fatores, como a quantidade de dados disponível, a qualidade dos dados e complexidade do problema (não-linear, descontínuo, etc.), mas de forma geral esses parâmetros são determinados de forma empírica com base na capacidade de generalização da rede. Fórmulas heurísticas também podem ajudar a determinar um valor inicial para o número de neurônios (Silva et al., 2010).

Neste estudo a determinação do número de neurônios para a MLP utilizou o método de Fletcher-Gloss (Equação 1.2) para determinar o número inicial de neurônios considerando apenas uma camada oculta:

$$2.\sqrt{n1} + n2 \leq n \leq 2.n1 + 1 \quad (1.2)$$

Onde $n1$ é o número de variáveis de entrada; $n2$ a quantidade de neurônios na camada de saída; n a quantidade de neurônios na camada oculta.

Figura 1.10 - Critério de Fletcher-Gloss para determinação do número de neurônios do treinamento.

Modelos	Fletcher-Gloss			Camada Oculta
M1	3	$\leq n \leq$	3	1
M2	4	$\leq n \leq$	5	
M3	4	$\leq n \leq$	7	
M4	5	$\leq n \leq$	9	
M5	5	$\leq n \leq$	11	
M6	5	$\leq n \leq$	11	
M7	5	$\leq n \leq$	11	
M8	5	$\leq n \leq$	11	
M9	6	$\leq n \leq$	13	

Fonte: Elaborado pelo Autor.

Os treinamentos foram realizados variando-se o número de neurônios de acordo com a Figura 1.10, em cada modelo de combinação (M1 a M9). Posteriormente cada modelo de combinação foram treinados consecutivamente obtendo-se 10 redes. Desse conjunto de treinamento foram calculadas as médias do EQM obtidos de forma a se escolher a rede (dentre as 10) que apresentou o menor valor da média dos erros, ou o melhor desempenho no treinamento.

Esse processo é repetido para cada incremento de 1 neurônio (Figura 1.10) até se obter o menor resultado do EQM em cada modelo de combinação (M1 a M8), de forma a se definir a arquitetura ideal para o treinamento das combinações dos modelos propostos.

Vale destacar que treinamentos com variações do número de camadas ocultas (de 1 a 5) e do número de neurônios (de 5 a 150 com incremento de 10) diferentes dos critérios da Equação 1.2 foram realizados, porém as arquiteturas especificadas na Tabela (1.4) apresentaram os melhores desempenhos.


A função de ativação utilizada foi a Tangente Hiperbólica (*tansig*), dada as características de dados das variáveis de entrada.

O critério de parada do treinamento da MLP foi a validação cruzada, sendo que no processo de treinamento os dados são separados aleatoriamente em 70% para treino, 15% para validação e 15% para teste. A cada ciclo (época) os erros da validação são avaliados, e enquanto continuar diminuindo significa que a rede continua aprendendo. Quando o erro da validação aumentar enquanto o erro do conjunto de treinamento continuar a cair, é sinal que a rede está com *overfitting*,


condição que indica o momento de parar o treinamento. Nessas condições o treinamento irá parar quando o erro da validação continuar aumentando durante 6 épocas sucessivas (Figura 1.11). Vale destacar que esse tipo de critério também minimiza o risco de *underfitting* da rede e acontece de forma automática com a utilização da função *feedforwardnet* no MATLAB.

Figura 1.11 – Curvas de treinamento da MLP


(A) $[Kt_{\beta}^h = f(Kt_H^h)]$ - Combinação M6 – 11 neurônios



(B) $[Kd_{\beta}^h = f(Kt_H^h)]$ – Combinação M8 – 8 neurônios



(C) $[Kd_{\beta}^h = f(Kt_{\beta}^h)]$ – Combinação M8 – 11 neurônios



Os gráficos da Figura 1.11 (A), (B) e (C) apresentam os resultados de desempenho nos treinamentos das redes com os melhores resultados do *EQM* com

base na Tabela 1.4. No treinamento de (A) [$Kt_{\beta}^h = f(Kt_H^h)$] a melhor rede convergiu com 89 épocas na combinação M6 contendo 5 variáveis de entrada. No treinamento de (B) [$Kd_{\beta}^h = f(Kt_H^h)$] a rede com melhor resultado demandou de um maior esforço computacional convergindo com 99 épocas na combinação M8 contendo 6 variáveis de entrada. No treinamento de (C) [$Kd_{\beta}^h = f(Kt_{\beta}^h)$] a melhor rede convergiu com 68 épocas na combinação M8 que contém 6 variáveis de entrada.

Após o processo de treinamento da MLP, as redes com os melhores resultados foram organizadas na Tabela 1.4.

Tabela 1.4 - Arquiteturas para treinamento da Rede MLP

(A)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Épocas	Solução Ótima	
										$Kt_{\beta}^h = f(Kt_H^h)$	
										N. Neurônios	CO
ME	Kt_H^h						Kt_{β}^h				
M1	Kt_H^h							1,84E-03	23	3	
M2	Kt_H^h	$H0_H^h$						1,50E-03	74	4	
M3	Kt_H^h	$H0_H^h$	Θ_z					8,08E-04	113	7	
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				6,84E-04	52	9	
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			6,65E-04	28	11	
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Rh			6,53E-04	89	11	
M7	Kt_H^h	$H0_H^h$	Θ_z	Tar	Rh			7,63E-04	45	11	
M8	Kt_H^h	$H0_H^h$	δ	Tar	Rh			7,48E-04	55	9	
M9	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		6,92E-04	35	10	

(B)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Épocas	Solução Ótima	
										$Kd_{\beta}^h = f(Kt_H^h)$	
										N. Neurônios	CO
ME	Kt_H^h						Kd_{β}^h				
M1	Kt_H^h							2,02E-02	10	3	
M2	Kt_H^h	$H0_H^h$						1,15E-02	171	5	
M3	Kt_H^h	$H0_H^h$	Θ_z					1,13E-02	9	4	
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				1,10E-02	11	7	
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			1,09E-02	5	7	
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		1,07E-02	13	6	
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		1,07E-02	21	8	
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		8,06E-03	99	8	


(C)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Épocas	Solução Ótima	
										$Kd_{\beta}^h = f(Kt_{\beta}^h)$	
ME	Kt_{β}^h						Kd_{β}^h			N. Neurônios	CO
M1	Kt_{β}^h							2,20E-02	8	4	1
M2	Kt_{β}^h	$H0_H^h$						1,35E-02	116	5	
M3	Kt_{β}^h	$H0_{\beta}^h$	Θ_z					1,26E-02	68	6	
M4	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ				8,96E-03	40	9	
M5	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar			8,88E-03	34	8	
M6	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	mr		8,97E-03	35	5	
M7	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Rh		8,91E-03	13	11	
M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Neb		7,05E-03	68	11	


Os gráficos da Figura 1.12 (A), (B) e (C) mostram uma avaliação do treinamento considerando o índice EQM em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 1.4 (A), (B) e (C) respectivamente. Os resultados mostram que os conjuntos e combinações de variáveis de entrada foram relevantes para o desempenho no treinamento da MLP.

Figura 1.12 - Curva do EQM do Treinamento em função das combinações treinadas


(A)



(B)



(C)



1.3.5.2 Treinamento da RBF

O MATLAB R2014a possui duas funções para implementação da rede RBF, sendo que a:

newrb cria uma rede iterativa. Uma quantidade fixa de neurônios é adicionada à camada oculta em cada época de treinamento até que se atinja o erro desejado ou o número de neurônios exceda o máximo especificado, baseado no valor do erro quadrático médio.

newrbe cria a rede com o número de neurônios igual ao número de vetores de entrada do treinamento. Após o treinamento é criada uma rede com erro zero, no que diz respeito aos vetores de treinamento.

Ambas as funções foram testadas, de onde se pode observar que o uso da função *newrb* demanda de um processo de parametrização mais dependente do

usuário além da mesma não apresentar um desempenho no treinamento que justificasse seu uso quando comparado aos resultados obtidos com a função *newrbe* utilizada neste estudo em termos de precisão, mesmo considerando um processo de treinamento mais custoso do ponto de vista do esforço computacional.

O treinamento da técnica RBF é definido pelo parâmetro de ajuste (σ) identificado como *spread*. O ajuste (σ) controla o raio de influência da função Gaussiana e seu valor é determinado de forma empírica (variando de 0.01 a 10000) objetivando-se obter o menor valor no índice de desempenho EQM. Com relação ao número de neurônios, a função *newrbe* escolhida inicia o treinamento com o número mínimo, sendo incrementado automaticamente a cada ciclo em função do erro. O processo é repetido até que se atinja o número máximo de neurônios da camada escondida.

Após o processo de treinamento, as redes com os melhores resultados classificados pelo menor índice do EQM em cada modelo de combinação foram organizadas na Tabela 1.5.

Tabela 1.5 - Arquiteturas para as estimativas com a Rede RBF

(A)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kt_p^h = f(Kt_H^h)$
ME	Kt_H^h						$Kt\beta^h$		spread (σ)
M1	Kt_H^h							1,84E-03	1,00E+01
M2	Kt_H^h	$H0_H^h$						1,53E-03	1,00E+01
M3	Kt_H^h	$H0_H^h$	Θ_z					7,90E-04	1,00E+01
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				7,50E-04	1,00E+02
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			7,92E-04	1,00E+03
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Rh			7,70E-04	1,00E+03
M7	Kt_H^h	$H0_H^h$	Θ_z	Tar	Rh			8,91E-04	1,00E+03
M8	Kt_H^h	$H0_H^h$	δ	Tar	Rh			9,60E-04	1,00E+03
M9	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		7,63E-04	1,00E+03

(B)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kd_{\beta}^h = f(Kt_H^h)$ spread (σ)
ME	Kt_H^h						Kd_{β}^h		
M1	Kt_H^h							2,03E-02	1,00E+01
M2	Kt_H^h	$H0_H^h$						1,16E-02	1,00E+01
M3	Kt_H^h	$H0_H^h$	Θ_z					1,34E-02	1,00E+03
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				1,28E-02	1,00E+03
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			1,28E-02	1,00E+03
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		6,20E-27	1,00E-03
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		1,25E-02	1,00E+03
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		1,00E-02	1,00E+03


(C)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kd_{\beta}^h = f(Kt_{\beta}^h)$ spread (σ)
ME	Kt_{β}^h						Kd_{β}^h		
M1	Kt_{β}^h							2,23E-02	1,00E+03
M2	Kt_{β}^h	$H0_H^h$						1,21E-02	1,00E+00
M3	Kt_{β}^h	$H0_{\beta}^h$	Θ_z					9,85E-03	1,00E+00
M4	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ				8,09E-03	1,00E+01
M5	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar			9,44E-03	1,00E+02
M6	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	mr		1,06E-02	1,00E+03
M7	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Rh		1,05E-02	1,00E+03
M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Neb		8,13E-03	1,00E+03


Os gráficos da Figura 1.13 (A), (B) e (C) mostram uma avaliação do treinamento considerando o índice EQM em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 1.5 (A), (B) e (C) respectivamente. Os resultados mostram que no treinamento da rede RBF, a maioria dos conjuntos e combinações de variáveis de entrada foram relevantes para o desempenho no treinamento, excetuando-se no modelo de estimativa (B) [$Kd_{\beta}^h = f(Kt_H^h)$] onde a combinação M6 não conseguiu generalizar o problema apresentando.

Figura 1.13 - Curva do EQM do Treinamento em função das combinações testadas


(A)



(B)



(C)



1.3.5.3 Treinamento da GRNN

A técnica de rede GRNN foi treinada por um algoritmo desenvolvido no MATLAB R2014a, que utiliza a função *newgrnn*. A parametrização da função é basicamente definida pelo parâmetro de ajuste (σ - *spread*) que controla o raio de influência da função Gaussiana, o qual deve ser determinado de forma empírica variando seu valor empiricamente (variação de 100 a 0,00001) de forma a se atingir o melhor resultado no índice de desempenho EQM e se evitar situações de *overfitting* e *underfitting* no treinamento 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.

Após o processo de treinamento, as redes com os melhores resultados classificados pelo menor índice de desempenho do EQM foram organizadas na Tabela 1.6.

Tabela 1.6 - Arquiteturas para as estimativas com a Rede GRNN

(A)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kt_p^h = f (Kt_H^h)$
ME	Kt_H^h						Kt_p^h		<i>spread</i> (σ)
M1	Kt_H^h							1,83E-03	1,00E-02
M2	Kt_H^h	$H0_H^h$						5,74E-04	1,00E-02
M3	Kt_H^h	$H0_H^h$	Θ_z					2,96E-04	1,00E-02
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				1,86E-03	1,00E-01
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			3,68E-02	1,00E+01
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Rh			3,62E-02	1,00E+01
M7	Kt_H^h	$H0_H^h$	Θ_z	Tar	Rh			3,82E-02	1,00E+01
M8	Kt_H^h	$H0_H^h$	δ	Tar	Rh			4,39E-02	1,00E+01
M9	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		3,61E-02	1,00E+01

(B)

Modelos	Variáveis de Entrada							Variável Estimada	EQM	Solução Ótima
										$Kd_{\beta}^h = f \left(Kt_H^h \right)$
										spread (σ)
ME	Kt_H^h							Kd_{β}^h		
M1	Kt_H^h								2,01E-02	1,00E-02
M2	Kt_H^h	$H0_H^h$					1,37E-02		1,00E-01	
M3	Kt_H^h	$H0_H^h$	Θ_z				1,31E-02		1,00E-01	
M4	Kt_H^h	$H0_H^h$	Θ_z	δ			7,38E-03		1,00E-01	
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar		8,09E-02		1,00E+05	
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr	8,09E-02		1,00E+03	
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh	8,09E-02		1,00E+03	
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	7,68E-03		1,00E+00	


(C)

Modelos	Variáveis de Entrada							Variável Estimada	EQM	Solução Ótima
										$Kd_{\beta}^h = f \left(Kt_{\beta}^h \right)$
										spread (σ)
ME	Kt_{β}^h							Kd_{β}^h		
M1	Kt_{β}^h								2,18E-02	1,00E-02
M2	Kt_{β}^h	$H0_H^h$					7,13E-03		1,00E-02	
M3	Kt_{β}^h	$H0_{\beta}^h$	Θ_z				6,73E-03		1,00E-02	
M4	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ			5,19E-03		1,00E-01	
M5	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar		8,10E-02		1,00E+05	
M6	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	nr	8,08E-02		1,00E+02	
M7	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Rh	7,57E-02		1,00E+01	
M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Neb	2,39E-02		1,00E+01	


Os gráficos da Figura 1.13 (A), (B) e (C) mostram uma avaliação do treinamento considerando o índice EQM em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 1.6 (A), (B) e (C) respectivamente. Os resultados mostram que no treinamento da rede GRNN, para o modelo (A) [$Kt_{\beta}^h = f(Kt_H^h)$] as combinações de M5 a M9 não foram relevantes com base no EQM para o desempenho no treinamento, da mesma forma nos modelos de estimativa (B) [$Kd_{\beta}^h = f(Kt_H^h)$] e (C) [$Kd_{\beta}^h = f(Kt_{\beta}^h)$] para as combinações M5, M6 e M7.

Figura 1.14 - Curva do EQM do Treinamento em função das combinações testadas.


(A)



(B)



(C)



1.3.6 Treinamento da ANFIS

Da mesma forma que as redes neurais artificiais (RNA) a ANFIS possui uma estrutura de parametrização que deve ser ajustada com o objetivo de se obter o melhor desempenho (menor erro quadrático médio) nas estimativas. O ajuste desses parâmetros é definido de forma empírica até que o erro desejado (solução ótima) seja alcançado para o problema estudado. O desempenho da ANFIS está diretamente relacionado aos parâmetros de ajuste, quantidade de regras e variáveis de entrada do sistema (Lezanski, 2001).

O treinamento adotado nas estimativas com a ANFIS foi realizado com o algoritmo de clusterização subtrativa implementado pela função *genfis2* do MATLAB R2014a, a qual gera uma estrutura *FIS* (*Fuzzy Inference System*) do tipo Sugeno e utiliza função de pertinência do tipo Gaussiana em todas as entradas. A utilização do método de clusterização subtrativa também contribuiu para um treinamento com baixo esforço computacional, comparado ao treinamento realizado pela função *genfis1* que demanda de um crescente custo computacional na medida que se aumenta a quantidade de variáveis de entrada.

Na função *genfis2* usa-se como parâmetro de ajuste do raio dos clusters o *radii* que pode ser definido como um vetor que especifica o alcance de influência de um centro de cluster em cada uma das dimensões de dados. Neste estudo foram criadas 9 *FIS* variando os valores do *radii* de 0,1 a 0,9.

Também se definiu o número de épocas de iteração, o qual é usado como critério de parada do treinamento. Os números de épocas foram variados de 100 a 500 épocas para cada *FIS* gerada.

Após o processo de treinamento, as ANFIS com os melhores resultados classificados pelo menor índice do *EQM* foram organizadas na Tabela 1.7.

Tabela 1.7 - Arquiteturas para as estimativas com o sistema híbrido ANFIS

(A)

Modelos	Variáveis de Entrada							Variável Estimada	EQM	Solução Ótima	
										$Kt_{\beta}^h = f (Kt_H^h)$	
										Épocas	radii
ME	Kt_H^h							Kt_{β}^h			
M1	Kt_H^h								1,84E-03	200	0,7
M2	Kt_H^h	$H0_H^h$							1,42E-03		0,1
M3	Kt_H^h	$H0_H^h$	Θ_z						7,99E-04		0,3
M4	Kt_H^h	$H0_H^h$	Θ_z	δ					6,54E-04		0,3
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar				7,99E-04		0,8
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Rh				7,57E-04		0,8
M7	Kt_H^h	$H0_H^h$	Θ_z	Tar	Rh				8,02E-04		0,5
M8	Kt_H^h	$H0_H^h$	δ	Tar	Rh				8,74E-04		0,7
M9	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh			7,77E-04		0,8

(B)

Modelos	Variáveis de Entrada							Variável Estimada	EQM	Solução Ótima	
										$Kd_{\beta}^h = f (Kt_H^h)$	
										Épocas	radii
ME	Kt_H^h							Kd_{β}^h			
M1	Kt_H^h								2,02E-02	200	0,6
M2	Kt_H^h	$H0_H^h$							1,14E-02		0,4
M3	Kt_H^h	$H0_H^h$	Θ_z						1,09E-02		0,6
M4	Kt_H^h	$H0_H^h$	Θ_z	δ					1,08E-02		0,7
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar				1,07E-02		0,9
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr			1,06E-02		0,9
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh			1,05E-02		0,8
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb			8,66E-03		0,9


(C)

Modelos	Variáveis de Entrada							Variável Estimada	EQM	Solução Ótima	
										$Kd_{\beta}^h = f (Kt_{\beta}^h)$	
										Épocas	radii
ME	Kt_{β}^h							Kd_{β}^h			
M1	Kt_{β}^h								2,21E-02	200	0,6
M2	Kt_{β}^h	$H0_H^h$							1,23E-02		0,1
M3	Kt_{β}^h	$H0_{\beta}^h$	Θ_z						1,20E-02		0,2
M4	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ					9,05E-03		0,2
M5	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar				8,99E-03		0,6
M6	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	mr			8,70E-03		0,5
M7	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Rh			9,06E-03		0,9
M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Neb			7,73E-03		0,5


Os gráficos da Figura 1.15 (A), (B) e (C) mostram uma avaliação do treinamento considerando o índice EQM em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 1.7 (A), (B) e (C) respectivamente. Os resultados mostram que os conjuntos e combinações de variáveis de entrada foram relevantes para o desempenho no treinamento da ANFIS.

Figura 1.15 - Curva do MSE do Treinamento em função das combinações testadas.


(A)



(B)




(C)



1.3.7 Base de dados de validação

Para validação dos modelos treinados, uma base contendo 12 meses de dados das irradiações horária denominada de Anos Atípicos (AAT) foi separada a partir da base de dados total (Figura 1.16A), por meio de análises estatísticas comparando para cada mês do ano os valores da irradiação média horária entre o intervalo de variação do desvio padrão da média total dos anos com o valor da irradiação média de cada ano. Um exemplo dessa classificação pode ser visualizado na Figura 1.16B.

Figura 1.16 - A) Exemplo da classificação dos anos atípicos para a base de validação B) Separação da base de treinamento e validação com Anos Atípicos (AAT) de março de 1998 a agosto de 2001



Fonte: Elaborado pelo Autor.

O critério utilizado é semelhante ao processo de seleção do ano meteorológico típico definido pela *World Meteorological Organization* (WMO, 1981). Os resultados da classificação foram apresentados na Tabela 1.8.

Tabela 1.8 - Ano Atípico (AAT) obtido na base de dados total (março de 1998 a agosto de 2001).

	Ano / Mês - Atípico (AAT)											
	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
Global	1999	1999	2000	1998	2001	1999	2001	1998	1998	2000	2000	2000
Difusa	1999	2001	2000	2000	2001	1998	2000	2001	1999	1999	2000	2000

1.3.8 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 *Relative Mean Bias Error* (MBE(%)), *Relative Root Mean Square Error* (RMSE(%)), o coeficiente de correlação (r), o coeficiente de determinação (R^2) (Santos et al., 2016; Escobedo et al. 2011; Willmott, 1981).

$$MBE(\%) = 100 \cdot \frac{\frac{\sum_{i=1}^x (E-M)}{x}}{\bar{X}} \quad (1.3)$$

$$RMSE(\%) = 100 \cdot \frac{\left[\frac{\sum_{i=1}^x (E-M)^2}{x} \right]^{\frac{1}{2}}}{\bar{X}} \quad (1.4)$$

$$r = \frac{\sum_{i=1}^x (M - \bar{M}) \cdot (E - \bar{E})}{\sqrt{\sum_{i=1}^x (M - \bar{M}) \cdot \sum_{i=1}^x (E - \bar{E})}} \quad (1.5)$$

$$R^2 = \frac{\sum_{i=1}^x (M - \bar{M})^2 \cdot \sum_{i=1}^x (E - \bar{E})^2}{\sum_{i=1}^x (M - \bar{M})^2} \quad (1.6)$$

onde, E são os valores estimados; M os valores medidos; $\bar{X} = \left(\frac{1}{x} \sum_{i=1}^x M \right)$ o valor médio das medidas e x o número de observações.

Os valores de MBE(%) representam o desvio das médias e provê informações quanto a desempenho dos modelos, quando positivos indicam superestimava e quando negativos indicam subestimativa. O RMSE(%) determina a precisão das estimativas em função dos dados medidos, também se observa nesse índice o grau de espalhamento obtido na correlação entre os valores estimados e medidos. O coeficiente de correlação r permite verificar o quanto o valor medido se aproxima do valor estimado, ou seja, a correlação existente entre eles. O R^2 permite identificar a relação linear entre os valores medidos e estimados; seus valores variam de 0 a 1 e quanto mais próximo de 1 melhor será o ajuste do modelo (Willmott, 1981; Stone, 1993; Escobedo et al. 2011).

Estes indicadores permitem identificar critérios como subestimativas ou superestimativas, o percentual de erro, espalhamento e correlação entre os valores medidos e estimados. Com base nesses critérios, é possível fazer análises entre os modelos e definir qual apresenta o melhor ajuste para generalizar o problema de estimar as variáveis Kt_{β}^h e Kd_{β}^h , pois qualquer erro na estimativa de recursos solares pode ter um efeito negativo sobre a simulação de projetos de energia solar (Gueymard:Ruiz-Arias, 2015).

1.4 RESULTADOS E DISCUSSÕES

Neste estudo as redes neurais artificiais (RNA) e o sistema híbrido (ANFIS) foram utilizados para estimar as frações da irradiação global (Kt_{β}^h) e da irradiação difusa (Kd_{β}^h) incidentes em uma superfície com inclinação de $22,85^\circ$ voltada para o norte a partir das medidas da irradiação global na superfície horizontal (Hg_H^h). Uma análise do desempenho desses modelos computacionais foi realizada comparando os resultados com os obtidos pelos modelos estatísticos (ME).

1.4.1 Equações de estimativas do modelo estatístico


As Figuras 1.17 A, B e C mostram as correlações entre os valores de Kt_H^h e Kt_{β}^h e entre Kt_H^h , Kt_{β}^h e Kd_{β}^h e suas respectivas curvas de regressão.

As equações obtidas das correlações são lineares para a estimativa de $[Kt_{\beta}^h = f(Kt_H^h)]$ e polinomiais de 3ª e 4ª ordem para as estimativas de $[Kd_{\beta}^h = f(Kt_H^h)]$ e $[Kd_{\beta}^h = f(Kt_{\beta}^h)]$ respectivamente, e estão apresentadas na Tabela 1.9:

Tabela 1.9 - Modelos obtidos das correlações da Figura 1.17

Figura 1.8	Estimativa	Regressão	Modelo	R ²	Equação
A	$Kt_{\beta}^h = f(Kt_H^h)$	Linear	$Kt_{\beta} = 1,26 * Kt_H$	0,94	1.7
B	$Kd_{\beta}^h = f(Kt_H^h)$	Polinomial 3ª Ordem	$Kd_{\beta}^h = 0,91 + 1,00 Kt_H - 5,51 Kt_H^2 + 3,80 Kt_H^3$	0,75	1.8
C	$Kd_{\beta}^h = f(Kt_{\beta}^h)$	Polinomial 4ª Ordem	$Kd_{\beta} = 0,93 + 0,38 Kt_{\beta}^1 - 3,01 Kt_{\beta}^2 + 2,69 Kt_{\beta}^3 - 0,87 Kt_{\beta}^4$	0,73	1.9

Figura 1.17 - Correlações entre: (A) Fração da global na superfície horizontal (K_{tH}) e a fração da global no plano inclinado ($K_{t\beta}$), (B) Fração da global na superfície horizontal (K_{tH}) e a fração da difusa no plano inclinado ($K_{d\beta}$). (C) Fração da global na superfície inclinada ($K_{t\beta}$) e a fração da difusa no plano inclinado ($K_{d\beta}$)



A Figura 1.17 A mostra a correlação linear entre $K_{t\beta}^h$ e K_{tH}^h , a qual resultou em um coeficiente de determinação de $R^2 = 0,94$ mostrando que os valores estão estatisticamente bem correlacionados.

As Figuras 1.17 B e C mostram as correlações K_{tH}^h , $K_{t\beta}^h$ e $K_{d\beta}^h$. As correlações tiveram ajustes polinomiais de 3ª ordem entre K_{tH}^h e $K_{d\beta}^h$ com coeficiente de determinação $R^2 = 0,75$, e 4ª ordem entre $K_{t\beta}^h$ e $K_{d\beta}^h$ com coeficiente de determinação $R^2 = 0,73$. Os valores mais baixos nos coeficientes de determinação são esperados na partição horária, tendo em vista que em partições temporais menores existe mais sensibilidade às variações instantâneas ocorridas na atmosfera (Dal Pai, 2005).

1.4.1.1 Validação das equações de estimativas


A Tabela 1.10 mostra os índices de desempenho estatísticos obtidos com a validação na base de dados dos Anos Atípicos (AAT) dos valores estimados pelas Equações 1.7, 1.8 e 1.9.

Tabela 1.10 - Indicativos de desempenho nas estimativas pelo modelo estatístico (ME)

Figura 1.8	MODELO	AAT (ANOS ATÍPICOS)				
		RMSE (MJ m ⁻²)	RMSE (%)	MBE (MJ m ⁻²)	MBE (%)	r
A	$Kt_{\beta}^h = f (Kt_H^h)$	0,047	6,65	-0,001	-0,20	0,98
B	$Kd_{\beta}^h = f (Kt_H^h)$	0,153	35,35	-0,023	-5,32	0,86
C	$Kd_{\beta}^h = f (Kt_{\beta}^h)$	0,157	36,48	-0,023	-5,36	0,85

Os gráficos das Figuras 1.18, A, B e C mostram a correlação entre os valores medidos e estimados pelas Equações 1.7, 1.8 e 1.9, onde na Figura 1.18 A apresenta a correlação entre os valores medidos de Kt_{β}^h e os valores estimados de Kt_{β}^h e nas Figuras 1.18 B e C apresentam-se as correlações entre os valores medidos de Kd_{β}^h e os estimados de Kd_{β}^h .

Figura 1.18 - Correlações entre os valores medidos e estimados: (A) Fração da global na superfície inclinada ($K_{t\beta}$) medida e estimada, (B) Fração da difusa no plano inclinado ($K_{d\beta}$) medido e estimado, (C) Fração da difusa no plano inclinado ($K_{d\beta}$) medido e estimado



Na Figura 1.18 A, a correlação entre os valores medidos e estimados mostra que para a estimativa da fração da global na superfície inclinada com base nas medidas da global na superfície horizontal $[K_{t\beta}^h = f(K_{tH}^h)]$ existe concordância da curva do ajuste com a reta de referência (1:1). O coeficiente de correlação $r=0,98$, indica que existe correlação entre os valores medidos e estimados pela Equação 1.7. O índice de desempenho $MBE=-0,20\%$ mostra que a Equação 1.7 tende a subestimar em 0,2% as estimativas. O índice de precisão $RMSE=6,65\%$ indica o espalhamento da Equação 1.7. Os índices obtidos com a estimativa da global na superfície inclinada ($K_{t\beta}^h$) a partir das medidas da global na superfície horizontal (K_{tH}^h), mostram que o

modelo da Equação 1.7 pode estimar Kt_{β}^h com valores próximos às medidas obtidas experimentalmente.

Os gráficos das Figuras 1.18 B e C apresentam as correlações entre os valores medidos (Kd_{β}^h) e os estimados (Kd_{β}^h). Ambas as correlações mostram que para a estimativa da fração da difusa na superfície inclinada a partir das medidas da global na superfície horizontal [$Kd_{\beta}^h = f(Kt_H^h)$] e na superfície inclinada [$Kd_{\beta}^h = f(Kt_{\beta}^h)$], não existe uma concordância da curva do ajuste com a reta de referência (1:1) indicando que a Equação 1.8 subestima as estimativas em 5,32%, conforme mostra o resultado do índice de desempenho $MBE = -5,32\%$, enquanto a Equação 1.9 subestima as estimativas em 5,36%, conforme mostra o resultado do índice de desempenho $MBE = -5,36\%$. Os coeficientes de correlação $r = 0,86$ e $r = 0,85$, indicam que existe correlação entre os valores medidos e estimados pelas Equações 1.8 e 1.9 respectivamente, porém menores em relação a função linear. Os índices de espalhamento $RMSE = 35,35\%$ para a Equação 1.8 e $RMSE = 36,48\%$ para a Equação 1.9 apresentaram valores elevados em relação a função linear e podem ser explicados pela partição de tempo utilizada (horária) e pela variação temporal causada por nuvens e aerossóis, pois nessas condições torna-se mais complexo gerar modelos de estimativas (Gueymard, 2010). Os índices obtidos com a estimativa da difusa na superfície inclinada (Kd_{β}^h) a partir das medidas da global na superfície horizontal (Kt_H^h) e da global na superfície inclinada (Kt_{β}^h), mostram que os modelos obtidos das Equações 1.8 e 1.9 podem estimar Kd_{β}^h , considerando a base horária.

Com base nos resultados da Tabela 1.10(B) e (C), também se observa que os índices das estimativas de Kd_{β}^h a partir de Kt_H^h e Kt_{β}^h podem ser considerados estatisticamente iguais, do que se pode concluir que a estimativa de Kd_{β}^h pode ser realizada a partir das medidas realizadas da global na horizontal.

As Tabelas 1.11 e 1.12 apresentam os valores dos coeficientes de correlação na validação de modelos encontrados na literatura para estimativas da irradiação global em superfície inclinada (Hg_{β}) da radiação difusa na superfície inclinada (Kd_{β}) por diversos métodos estatísticos, onde se observa que os valores obtidos neste estudo são condizentes com os diversos estudos disponíveis na bibliografia, considerando suas particularidades como base de dados envolvida, latitude e modelo de estimativas utilizado.

Tabela 1.11 - Indicativos estatísticos e suas localidades na partição horária para $H_{g\beta}$

Autores	Localidades	Latitudes	Inclinação	Partição	MBE		RMSE		r
		(°)			(MJ m ⁻²)	(%)	(MJ m ⁻²)	(%)	
Perez et al.(1987)				Horária		-3.9		8.3	0.99
Olmo et al.(1999)	Granada / Espanha	37.08°N	60	Horária		4.80		9.30	0.99
Gilles Notton et al.(2005)	Ajaccio - França	41°55' N	45	Horária		-2.33		8.11	0.99
			60			-2.11		10.71	
Padovan & Delcol (2010)	Pádua - Itália	45°24.48' N	20	Horária		6.00		6.40	
			30			7.00		8.70	
Souza - Ma and Iqbal	Botucatu/SP	-22,85° S	22.85	Horária	0.0502		0.11		
Adilson Pacheco et al. (2011)	Botucatu/SP	-22,85° S	22.85	Diária	-0.5570	-2.87	3.36	17.28	
Adilson Pacheco et al. (2010)	Botucatu/SP	-22,85° S	22.85	Mensal		3.09		6.27	
ME Proposto - $H_{g\beta}^h = [K_t^h] \cdot H_0^h$	Botucatu/SP	-22,85° S	22.85	Horária	0.0030	0.17	0.16	8.18	0.98

Tabela 1.12 - Indicativos estatísticos e suas localidades na partição horária para $K_{d\beta}$

Autores	Localidades	Latitudes	Inclinação	MBE		RMSE		r
		(°)		(MJ m ⁻²)	(%)	(MJ m ⁻²)	(%)	
Perez et al. (1986)	Genebra (Suíça)		30°		-4.50		9.70	
			45°		-2.90		9.20	
			60°		0.00		11.40	
Perez et al. (1986)	Albany (Estados Unidos)	42°42'N	43°		-5.37		8.34	
Perez et al. (1986)	Capentras (França)	44°05' N	45°		-8.02		11.91	
Kambezidis, Psiloglou e Synodinou (1990)	Atenas (Grécia)	37°58' N	50°		-2.63		8.49	
Reindl, Beckman e Duffie (1990)	2 (Estados Unidos)	42.7° - 29.5° N	90°		6.38		12.98	
Utrillas et al. (1991)	Valência (Espanha)		90°		-13.70		18.30	
Vartiainen (2000)	Turku (Finlândia)	60°27' N	30°		-7.20		12.60	
			60°		-8.70		16.80	
			90°		-12.50		22.60	
Bilbao et al. (2003)	13 (Espanha)				-3.09		11.97	
Norton et al. (2006)	Ajaccio (França)	41°55' N	45°		-8.90		12.77	
			60°		-6.46		12.67	
Noorian et al. (2006)	Karaj/Iran	35°55' N	45°				10.16 - 54.89	
			40°				30.71 - 63.63	
Evseev & Kudish (2009)	Beer Sheva (Israel)	31°15' N	40° S		-4.14		11.74	
Ruiz-Arias et al. (2010)	21 (EUA e Europa)				(-15) - 15		25 - 35	
Adilson Pacheco et al. (2012)	Botucatu/SP	22°53' S	22.85 Norte	(-0.164) - 0.118	(-23.21) - 24.10	0.213 - 0.623	39.31 - 100.21	
Adilson Pacheco et al. (2013)	Botucatu/SP	22°53' S	22.85 Norte	0.07		0.13		
Adilson Pacheco et al. (2014)	Botucatu/SP	22°53' S	22.85 Norte	(-0.0198) - 0.0722		0.1089 - 0.1302		
Demain et al. (2017)	Uccle (Bélgica)	50.79° Norte			(-10.34) - 5.89		5.29 - 14.24	
ME Proposto - $K_{d\beta}^h = f (K_t^h)$	Botucatu/SP	22°53' S	22.85 Norte	-0.023	-5.32	0.153	35.35	0.86
ME Proposto - $K_{d\beta}^h = f (K_t^h)$	Botucatu/SP	22°53' S	22.85 Norte	-0.023	-5.36	0.157	36.48	0.85

1.4.2 Redes Neurais Artificiais e ANFIS

O treinamento das RNAs e ANFIS foram realizados considerando critérios

Após os treinamentos e validações das RNA e ANFIS, os resultados foram organizados e apresentados na Tabela 1.13.

Tabela 1.13 - Indicadores do Modelo Estatístico (ME), RNA e ANFIS para os anos atípicos (AAT) com destaque aos melhores resultados

A)																		
ESTIMATIVAS DE $Kt_p^h = f (Kt_H^h)$																		
Variáveis de Entrada			ME			MLP			RBF			GRNN			ANFIS			
			RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	
ME/M1	Kt_H^h		6,65	-0,20	0,98	6,40	-0,99	0,98	6,41	-1,01	0,98	6,41	-0,96	0,98	6,41	-1,00	0,98	
M2	Kt_H^h	$H0_H^h$				5,65	-0,84	0,98	6,41	-1,01	0,98	6,33	-0,72	0,98	5,62	-0,88	0,98	
M3	Kt_H^h	$H0_H^h$	Θ_z			3,97	-0,78	0,99	3,99	-0,70	0,99	5,27	-0,49	0,99	4,00	-0,72	0,99	
M4	Kt_H^h	$H0_H^h$	Θ_z	δ		3,75	-0,71	0,99	4,22	-0,67	0,99	13,64	3,55	0,90	3,79	-0,74	0,99	
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	3,75	-0,59	0,99	4,28	-0,76	0,99	30,56	6,77	0,30	3,94	-0,59	0,99	
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Rh	3,73	-0,62	0,99	4,19	-0,77	0,99	30,57	7,47	0,30	3,83	-0,52	0,99	
M7	Kt_H^h	$H0_H^h$	Θ_z	Tar	Rh	3,87	-0,67	0,99	4,33	-0,55	0,99	31,07	7,34	0,24	4,06	-0,51	0,99	
M8	Kt_H^h	$H0_H^h$	δ	Tar	Rh	4,06	-0,48	0,99	4,58	-0,56	0,99	32,53	7,24	0,00	4,31	-0,48	0,99	
M9	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh	3,77	-0,62	0,99	4,17	-0,66	0,99	30,62	7,54	0,09	3,95	-0,58	0,99
B)																		
ESTIMATIVAS DE $Kd_p^h = f (Kt_H^h)$																		
Variáveis de Entrada			ME			MLP			RBF			GRNN			ANFIS			
			RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	
ME/M1	Kt_H^h		35,35	-5,32	0,86	35,36	-5,14	0,85	35,41	-5,36	0,85	35,54	-5,53	0,85	35,50	-5,43	0,85	
M2	Kt_H^h	$H0_H^h$				25,50	-3,32	0,93	25,44	-3,48	0,93	29,39	-5,73	0,90	25,41	-3,21	0,93	
M3	Kt_H^h	$H0_H^h$	Θ_z			25,49	0,17	0,93	32,47	-5,14	0,88	30,52	1,66	0,89	26,35	0,99	0,92	
M4	Kt_H^h	$H0_H^h$	Θ_z	δ		26,49	-9,37	0,92	43,82	-10,15	0,76	44,71	-7,28	0,75	26,80	-8,27	0,92	
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	25,01	-4,63	0,93	33,08	-7,88	0,87	67,79	-4,59	0,00	27,60	-3,68	0,91	
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr	25,06	-3,99	0,93	68,49	10,82	0,00	67,79	-4,59	0,00	26,99	1,24	0,92
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh	24,68	-3,15	0,93	39,56	-19,04	0,81	67,79	-4,59	0,00	27,24	-4,43	0,92
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	21,70	-3,32	0,95	35,08	6,67	0,85	51,12	2,98	0,65	23,08	0,15	0,94
C)																		
ESTIMATIVAS DE $Kd_p^h = f (Kt_p^h)$																		
Variáveis de Entrada			ME			MLP			RBF			GRNN			ANFIS			
			RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	
ME/M1	Kt_p^h		36,4825	-5,3579	0,84	36,93	-7,06	0,84	37,02	-7,62	0,84	37,12	-7,33	0,84	36,98	-7,40	0,84	
M2	Kt_p^h	$H0_p^h$				28,86	-5,26	0,90	27,83	-4,60	0,91	29,56	-4,26	0,90	28,07	-4,52	0,91	
M3	Kt_p^h	$H0_p^h$	Θ_z			27,70	-4,23	0,91	24,48	-3,46	0,93	29,11	-3,88	0,90	27,19	-4,18	0,92	
M4	Kt_p^h	$H0_p^h$	Θ_z	δ		22,55	-3,64	0,94	24,09	-3,51	0,93	32,89	-6,29	0,87	23,58	-3,68	0,94	
M5	Kt_p^h	$H0_p^h$	Θ_z	δ	Tar	22,82	-3,45	0,94	24,99	-6,88	0,93	67,78	-4,53	0,00	23,10	-4,05	0,94	
M6	Kt_p^h	$H0_p^h$	Θ_z	δ	Tar	mr	22,94	-4,58	0,94	25,12	-5,31	0,93	67,71	-4,63	0,00	23,14	-3,95	0,94
M7	Kt_p^h	$H0_p^h$	Θ_z	δ	Tar	Rh	23,01	-4,09	0,94	25,38	-5,58	0,93	66,17	-3,51	0,21	23,39	-4,05	0,94
M8	Kt_p^h	$H0_p^h$	Θ_z	δ	Tar	Neb	20,32	-2,54	0,95	21,95	-2,95	0,95	44,14	2,03	0,76	21,75	-2,21	0,95

A análise dos dados das estimativas da fração transmitida da global no plano inclinado (Kt_{β}^h) a partir das medidas da global no plano horizontal (Tabela 1.13 A) mostra que em todas as técnicas de estimativas aplicadas, os índices de correlação (r) atingiram valores elevados variando de 0,98 a 0,99 com a MLP, RBF e ANFIS; e de 0,00 a 0,99 com a GRNN mostrando que nesta técnica as estimativas com as combinações M8=0,00% e M9=0,09% não correlacionaram com os dados medidos. As combinações M5, M6 e M7 não apresentaram boas correlações entre os valores medidos e estimados, com valores variando de 0,24 a 0,30. Os índices de precisão RMSE apresentaram resultados 3,73% e 6,40% para a MLP, entre 3,99% e 6,40% para a RBF, entre 5,27% e 6,41% para a GRNN e entre 3,79% e 6,41% para a ANFIS. Os índices de exatidão MBE mostram que as estimativas realizadas com todas as técnicas subestimaram as medidas, porém com valores menores que 1%.

Para as estimativas da fração difusa no plano inclinado (Kd_{β}^h) a partir das medidas da global no plano horizontal (Tabela 1.13 B), os índices de correlação (r) mostram que em todas as técnicas de aprendizado aplicadas, os índices das correlações apresentaram valores elevados com variação de 0,85 a 0,95 na MLP, de 0,85 a 0,93 na RBF e de 0,85 a 0,94 na ANFIS. Na GRNN os valores de (r) variaram de 0,00 a 0,90 o que indica que as estimativas realizadas com as combinações M5, M6 e M7 não se correlacionaram com as medidas. Os índices de precisão RMSE apresentaram resultados variando entre 21,70% e 35,36% para a MLP, entre 25,44% e 35,41% para a RBF, entre 29,40% e 35,54% para a GRNN e 23,08% e 35,50% para a ANFIS. Os valores dos índices de exatidão MBE mostram que as estimativas com a MLP subestimam as medidas com valores entre -3,15% e -9,37% e superestimam apenas com a combinação M3=0,17%. As estimativas com a rede RBF resultaram em valores subestimados com valores entre -3,48% e -19,04% e valores superestimados nas combinações M6=10,82% e M8=6,67%. A rede GRNN superestimou as medidas obtidas com as estimativas das combinações M3=1,66% e M8=2,98% e subestimou nas demais combinações com valores entre M6=-4,59% e M2=-5,73. As estimativas realizadas com a ANFIS apresentaram resultados superestimados nas combinações M3=0,99%, M6=1,24% e M8=0,15% e subestimados nas demais combinações com valores entre M2=-3,21% e M1=-5,43%.

Para as estimativas da fração difusa no plano inclinado (Kd_{β}^h) a partir das medidas da global no plano inclinado (Tabela 1.13 C), os índices de correlação (r)

mostram que em todas as técnicas de aprendizado aplicadas, os índices das correlações apresentaram valores elevados com variação de 0.84 a 0.95 na MLP, RBF e ANFIS. Na GRNN os valores de (r) variaram de 0.00 a 0.90 indicando que as estimativas realizadas com as combinações M5 e M6 não se correlacionaram com as medidas. Os índices de precisão RMSE apresentaram resultados variando entre 20.3159% e 36.9268% para a MLP, entre 21,95% e 37,02% para a RBF, entre 29,11% e 67,79% para a GRNN e 21,76% e 36,98% para a ANFIS. Os valores dos índices de exatidão MBE mostram que as estimativas realizadas com todas as técnicas subestimam as medidas com valores entre -2,21% e -7,40% excetuando-se apenas a combinação M8 estimada com a GRNN que superestimou os valores em 2,03%.

Tabela 1.14 - Melhores Indicadores das RNA e ANFIS validadas na base de anos atípicos (AAT).

MODELO	COMBINAÇÕES							AAT (ANOS ATÍPICOS)		
A) $Kt_{\beta}^h = f \left(Kt_H^h \right)$								RMSE(%)	MBE(%)	r
ME	M1	Kt_H^h						6,65	-0,20	0,98
MLP	M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Rh		3,73	-0,62	0,99
RBF	M3	Kt_H^h	$H0_H^h$	Θ_z				3,99	-0,70	0,99
GRNN	M3	Kt_H^h	$H0_H^h$	Θ_z				5,27	-0,49	0,99
ANFIS	M4	Kt_H^h	$H0_H^h$	Θ_z	δ			3,79	-0,74	0,99
B) $Kd_{\beta}^h = f \left(Kt_H^h \right)$								RMSE(%)	MBE(%)	r
ME	M1	Kt_H^h						35,35	-5,32	0,86
MLP	M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	21,70	-3,32	0,95
RBF	M2	Kt_H^h	$H0_H^h$					25,44	-3,48	0,93
GRNN	M2	Kt_H^h	$H0_H^h$					29,39	-5,73	0,90
ANFIS	M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	23,08	0,15	0,94
C) $Kd_{\beta}^h = f \left(Kt_{\beta}^h \right)$								RMSE(%)	MBE(%)	r
ME	M1	Kt_{β}^h						36,48	-5,36	0,84
MLP	M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Neb	20,32	-2,54	0,95
RBF	M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Neb	21,95	-2,95	0,95
GRNN	M3	Kt_{β}^h	$H0_{\beta}^h$	Θ_z				29,11	-3,88	0,90
ANFIS	M8	Kt_{β}^h	$H0_{\beta}^h$	Θ_z	δ	Tar	Neb	21,75	-2,21	0,95

A Tabela 1.14 A, B e C destaca os melhores modelos de estimativas (classificados pelo RMSE(%)) usando as técnicas de RNA e ANFIS, considerando o quanto as variáveis de entrada adotadas foram relevantes para estimar as variáveis Kt_{β}^h e Kd_{β}^h , apresentando consideráveis melhorias em relação ao modelo clássico (ME). Nas estimativas da transmissividade da global para superfície inclinada (Kt_{β}^h) com base nas medidas da global na superfície horizontal (Tabela 1.14 A) observa-se no melhor modelo de RNA uma redução comparada ao modelo estatístico (ME) de 44% no índice RMSE. Nas estimativas da fração difusa na superfície inclinada (Kd_{β}^h)

com base nas medidas da global na superfície horizontal (Tabela 1.14 B) e inclinada (Tabela 1.14 C), também se observa nos melhores modelos de RNA uma redução no índice RMSE de 38,6% e 44.4% respectivamente, comparado ao modelo estatístico (ME).

Figura 1.19(a) - Correlações entre valores medidos e estimados pelas técnicas MLP e RBF sendo nas colunas: (A) Kt_{β} medido e estimada, (B e C) Kd_{β} medidos e estimados.





Figura 1.19(b) - Correlações entre valores medidos e estimados pelas técnicas GRNN e ANFIS, sendo nas colunas:

(A) Kt_{β} medido e estimada, (B e C) Kd_{β} medidos e estimados.



Nos gráficos da Figura 1.19 A, as correlações entre os valores medidos e estimados com as técnicas de rede MLP, RBF, GRNN e o sistema híbrido ANFIS, mostram que para a estimativa da fração da global na superfície inclinada (Kt_{β}^h) com base nas medidas da global na superfície horizontal existe concordância da curva do ajuste com a reta de referência (1:1). Os coeficientes de correlação $r=0.99$ para todas as estimativas, indicam que existe correlação entre os valores medidos e estimados pelas combinações utilizadas nos treinos. Os índices estatísticos da Tabela 1.14, mostram que de acordo com os valores de MBE as técnicas de RNA e ANFIS tendem a subestimar as estimativas com valores entre $MBE_{GRNN}=-0,49\%$ e $MBE_{ANFIS}=-0,74\%$. Os índices de precisão RMSE indicam um espalhamento maior na técnica de rede GRNN ($RMSE_{GRNN}=5,27\%$). Os resultados obtidos dos índices com as estimativas da fração da global na superfície inclinada (Kt_{β}^h) a partir das medidas da global na superfície horizontal, mostram que os modelos de rede adotados podem estimar Kt_{β}^h com precisão.

Nos gráficos da Figura 1.19 B, as correlações entre os valores medidos e estimados com as técnicas de rede MLP, RBF, GRNN e o sistema híbrido ANFIS, mostram que para a estimativa da fração da difusa na superfície inclinada (Kd_{β}^h) com base nas medidas da global na superfície horizontal os coeficientes de correlação entre $r_{GRNN}=0,90$ e $r_{MLP}=0,95$, indicam que existe boa correlação entre os valores medidos e estimados pelas combinações de variáveis utilizadas nos treinos. Os índices estatísticos da Tabela 1.14, mostram que de acordo com os valores de MBE as técnicas de RNA tendem a subestimar as estimativas com valores entre 3,32% e 5,73% e a ANFIS tendem a superestimar em 0,15% as estimativas. O índice de precisão RMSE apresentou o pior resultado com a técnica de rede GRNN ($RMSE_{GRNN}=29,39\%$). Os resultados obtidos dos índices com as estimativas da fração da difusa na superfície inclinada (Kd_{β}^h) a partir das medidas da global na superfície horizontal, mostram que os modelos de rede adotados podem estimar Kt_{β}^h , considerando a base horária.

Na análise dos gráficos da Figura 1.19 C, as correlações entre os valores medidos e estimados com as técnicas de rede MLP, RBF, GRNN e o sistema híbrido ANFIS, mostram que para a estimativa da fração da difusa na superfície inclinada (Kd_{β}^h) com base nas medidas da global na superfície inclinada os coeficientes de correlação entre $r_{GRNN}=0,90$ e $r_{MLP}=0,95$, indicam que existe boa correlação entre os valores medidos e estimados pelas combinações de variáveis utilizadas nos treinos.

Os índices estatísticos da Tabela 1.14, mostram que de acordo com os valores de MBE as técnicas de RNA e ANFIS tendem a subestimar as estimativas com valores entre 2,21% e 5,36%. O índice de precisão RMSE apresentou o pior resultado com a técnica de rede GRNN ($RMSE_{GRNN}=29,11\%$). Os resultados obtidos dos índices com as estimativas da fração da difusa na superfície inclinada (Kd_{β^h}) a partir das medidas da global na superfície inclinada, mostram que os modelos de rede adotados podem estimar Kd_{β^h} , considerando a base horária.

Figura 1.20(a) - Gráfico de dispersão das estimativas MLP e RBF: (A) $K_{t\beta}$ em função de K_{tH} medido (B) $K_{d\beta}$ em função de K_{tH} medido (C) $K_{d\beta}$ em função de $K_{t\beta}$ medido.

Base de Treino Base de Validação Estimativas





Figura 1.20(b) - Gráfico de dispersão das estimativas GRNN e ANFIS: (A) $K_{t\beta}$ em função de K_{tH} medido (B) $K_{d\beta}$ em função de K_{tH} medido (C) $K_{d\beta}$ em função de $K_{t\beta}$ medido.

⊕ Base de Treino ⊗ Base de Validação ● Estimativas



Os gráficos da Figura 1.20 mostram as curvas de dispersão das estimativas comparadas aos espalhamentos da base de dados de treinamento e validação. Destaca-se claramente que em todas as estimativas os melhores resultados foram das técnicas MLP e ANFIS, os quais apresentaram uma dispersão mais próximos dos valores da base de validação AAT. As técnicas RBF e GRNN apresentaram um bom resultado apenas nas estimativas de $[Kt_{\beta}^h = f(Kt_H^h)]$ – Figura 1.20 (A), pois como é possível observar no gráfico da Figura 1.20 (B) o espalhamento da RBF e GRNN é deficiente e possui pouca concordância com os valores medidos, consequência da combinação treinada com apenas duas variáveis de entrada.

Analisando a Tabela 1.14 observa-se que nas técnicas de AM utilizadas os melhores resultados são obtidos nas combinações que tem maior número de variáveis no treinamento incluindo as variáveis meteorológicas nebulosidade, temperatura (para estimar a difusa) e umidade (para estimar a global). Esse resultado indica que somente a variável Kt_H^h não consegue explicar o comportamento de Kt_{β}^h e Kd_{β}^h tendo em vista que o espalhamento se torna mais coincidente com a inclusão de outras variáveis.

Ao se analisar os resultados em conjunto com as informações de espalhamento da Figura 1.20, pode se identificar que dentre as técnicas testadas neste estudo a MLP e a ANFIS obtiveram os melhores índices estatísticos bem como um espalhamento mais ajustado aos dados medidos.

1.5 CONCLUSÕES

Dos resultados obtidos com os modelos de estimativas estatísticos (ME), pôde-se observar que os modelos das Equações 1.7, 1.8 e 1.9 apresentaram bons resultados estatísticos, podendo ser utilizadas para estimar as frações das radiações global (Kt_{β}^h) e difusa (Kd_{β}^h), ambas na superfície com inclinação de $22,85^\circ$ para os dados de Botucatu com coeficientes de determinação para AAT $R^2=0,94$, $R^2=0,75$ e $R^2=0,73$ respectivamente.

Os dados obtidos pelas estimativas com o método clássico serviram de referência para comparação com os resultados dos modelos de técnicas de aprendizado de máquina adotados neste estudo, pois sendo os modelos clássicos mais utilizados na literatura esperava-se que as redes pudessem apresentar um desempenho melhor para justificar seu uso. Para isso, as arquiteturas de RNA e

ANFIS tem a seu favor a possibilidade de realizar a estimativa combinando diversas variáveis que possam influenciar na generalização do problema, porém necessita de um trabalho considerável para determinação da melhor combinação de variáveis de entrada, e parametrização da rede.

Neste estudo, os resultados obtidos com os treinos das redes neurais artificiais (RNA) nas técnicas MLP, GRNN e RBF e também a ANFIS apresentaram resultados melhores se comparados aos resultados obtidos com os modelos estatísticos (ME) nas três estimativas com as mesmas bases de treinamento e validação.

As referências bibliográficas mostram que estimativas mais precisas usando RNA são esperadas, considerando uma série de fatores envolvidos para o treinamento das redes, entre os quais a quantidade de variáveis de entrada e as possibilidades de ajustamento através da parametrização da estrutura das redes. Por esse motivo uma comparação estatística entre os ME e as RNA e ANFIS não é muito adequada, mas pode servir para efeitos de referência.

Pode-se concluir com os resultados obtidos que de forma geral as técnicas de aprendizado de máquina adotadas conseguem estimar as radiações global e difusa incidentes em superfície inclinada a partir de medidas da radiação global na superfície horizontal, com RMSE < 10% para as estimativas de Kt_{β}^h e RMSE < 30% para as estimativas de Kd_{β}^h resultados estatísticos superiores aos do modelo estatístico clássico, destacando-se as técnicas MLP e ANFIS como mais adequadas para estimar a transmissividade da global e fração difusa em superfície inclinada a partir das medidas da radiação global na superfície horizontal, com dados de Botucatu-SP/Brasil.

REFERÊNCIAS

Alrubaih, M.s. et al. Research and development on aspects of daylighting fundamentals. Renewable And Sustainable Energy Reviews, [s.l.], v. 21, p.494-505, maio 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2012.12.057>.

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.

Beruski, Gustavo Castilho; Pereira, André Belmont; Sentelhas, Paulo Cesar. Desempenho de diferentes modelos de estimativa da radiação solar global em Ponta Grossa, PR. **Revista Brasileira de Meteorologia**, [s.l.], v. 30, n. 2, p.205-213, jun. 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0102-778620130097>.

Bosch, J.I.; López, G.; Batlles, F.J.. Daily solar irradiation estimation over a mountainous area using artificial neural networks. *Renewable Energy*, [s.l.], v. 33, n. 7, p.1622-1628, jul. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2007.09.012>.

Casaroli, Derblai et al. RADIAÇÃO SOLAR E ASPECTOS FISIOLÓGICOS NA CULTURA DE SOJA - UMA REVISÃO. *Revista da Fzva, Uruguaiana*, v. 14, n. 2, p.102-120, jan. 2007.

Demain, Colienne; JOURNÉE, Michel; BERTRAND, Cédric. Evaluation of different models to estimate the global solar radiation on inclined surfaces. **Renewable Energy**, [s.l.], v. 50, p.710-721, fev. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2012.07.031>.

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.

Dal Pai, A. Anisotropia da irradiância solar difusa medida pelo método de sombreamento Melo-Escobedo: fatores de correção anisotrópicos e modelos de estimativa. 2005. 87f. Tese (Doutorado em Agronomia – Energia na Agricultura), Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, 2005.

Duffie, J.A., Beckman, W.A., *Solar Engineering of Thermal Process*, Wiley - Interscience Publication, 1991.

Elminir, Hamdy K.; AZZAM, Yosry A.; YOUNES, Farag I.. Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. *Energy*, [s.l.], v. 32, n. 8, p.1513-1523, ago. 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2006.10.010>.

Escobedo, J. F.; Gomes, E. N.; Oliveira, A. P.; Soares, J.. Ratios of UV, PAR and NIR components to global solar radiation measured at Botucatu site in Brazil. *Renewable Energy*, v.36, p.169-178, 2011.

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.

El-Sebaei, A.a. et al. Global, direct and diffuse solar radiation on horizontal and tilted surfaces in Jeddah, Saudi Arabia. **Applied Energy**, [s.l.], v. 87, n. 2, p.568-576, fev. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.apenergy.2009.06.032>.

Finocchio, Marco Antonio Ferreira. NOÇÕES DE REDES NEURAIS ARTIFICIAIS. 2014. 29 f. - Curso de Engenharia Elétrica, Laboratório de Segurança, Iluminação e Eficiência Energética, Universidade Tecnológica Federal do Paraná, Cornélio Procopio, 2014.

Ghosal, M.k. et al. Modeling and comparative thermal performance of ground air collector and earth air heat exchanger for heating of greenhouse. *Energy And*

Buildings, [s.l.], v. 37, n. 6, p.613-621, jun. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.enbuild.2004.09.004>.

Gueymard, C. A.; Ruiz-Arias, J. A. Extensive worldwide validation and climate sensitivity analysis of direct irradiance predictions from 1-min global irradiance. **Sol. Energy** (2015), <http://dx.doi.org/10.1016/j.solener.2015.10.010>.

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.

Kamali, Gh. A.; Moradi, I.; Khalili, A.. Estimating solar radiation on tilted surfaces with various orientations: a study case in Karaj (Iran). *Theoretical And Applied Climatology*, [s.l.], v. 84, n. 4, p.235-241, 28 set. 2005. Springer Nature. <http://dx.doi.org/10.1007/s00704-005-0171-y>.

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.

Lam, J. C.; WAN, K. K. W.; Yang, L. Solar radiation modeling using ANNs for different climates in China. *Energy Conversion & Management*, v.49, 1080-1090, 2008b.

Li, Danny H.w. et al. Determining solar irradiance on inclined planes from classified CIE (International Commission on Illumination) standard skies. *Energy*, [s.l.], v. 101, p.462-470, abr. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2016.02.054>.

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

Lezanski, P. An intelligent system for grinding wheel condition monitoring. *Journal of Materials Processing Technology*, volume 109, 2001, pp. 258-263, 2001.

M. Hagan e M. Menhaj; "Training feedforward networks with the Marquardt algorithm"; IEEE Transaction on neural networks; 989-993; Novembro; 1994.

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. Bullentin 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 - Sciencedirect: 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.

Pandey, C.k.; Katiyar, A.k.. Hourly solar radiation on inclined surfaces. Sustainable Energy Technologies And Assessments, [s.l.], v. 6, p.86-92, jun. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.seta.2014.01.007>.

Pezzopane, E.M.; Ribeiro, A.; Reis, G.G.; Reis, M.G.F. Balanço de radiação em uma floresta em função da Declividade e Orientação das encostas. In: Congresso Brasileiro de Meteorologia, 11, 2000, Rio de Janeiro - RJ.

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.

Rehman S, Mohandes M. Splitting global solar radiation into diffuse and direct normal fractions using artificial neural networks. Energy Sources, Part A 2012;34:1326–36.

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.

Rahoma, W. A. et al. Application of Neuro-Fuzzy Techniques for Solar Radiation. *Journal Of Computer Science: Science Publications*, [s.l.], v. 7, n. 10, p.1-7, jan. 2011.

Rossi, T. J. Equações de Estimativas das Irradiações e Frações: Global, Difusa e Direta Infravermelha Em Botucatu/ Sp/Brasil. Dissertação (Mestrado em Agronomia – Energia na Agricultura), Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2017.

Simon Haykin. *Neural Networks and Learning Machines*. 3ª ed.. New York: Prentice Hall, 2008.

B. Mulgrew, “Applying Radial Basis Functions”, *IEEE SHGnal Processing Magazine*, pp 50-65, 1996.

Sumithira, T. R.; Kumar, A. Nirmal. Prediction of monthly global solar radiation using adaptive neuro fuzzy inference system (ANFIS) technique over the State of Tamilnadu (India): a comparative study. *Applied Solar Energy*, [s.l.], v. 48, n. 2, p.140-145, abr. 2012. Allerton Press. <http://dx.doi.org/10.3103/s0003701x1202020x>.

Souza, J. L.; Lyra, G. B.; Santos, C. M. et al. Empirical models of daily and monthly global solar irradiation using sunshine duration for Alagoas State, Northeastern Brazil. *Sustainable Energy Technologies and Assessment*, v. 14, p. 35-35, 2016.

Silva, Roberta A. e et al. Estudo da variabilidade da radiação solar no Nordeste do Brasil. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, v. 14, n. 5, p.501-509, 5 nov. 2009.

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. 2004.

Souza, A.P. ; Escobedo, J. F. ; Dal Pai, A. ; Gomes, E. N. . Estimativas das componentes da irradiação solar incidentes em superfícies inclinadas baseadas na irradiação global horizontal. *Revista Brasileira de Engenharia Agrícola e Ambiental (Impresso)* , v. 15, p. 277-288, 2011.

Souza, Adilson P. de et al. Annual evolution of global, direct and diffuse radiation and fractions in tilted surfaces. *Engenharia Agrícola*, [s.l.], v. 32, n. 2, p.247-260, abr. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-69162012000200005>.

Souza, A.p. et al. Estimativas da radiação global incidente em superfícies inclinadas com base na razão de insolação. *Revista Brasileira de Ciências Agrárias - Brazilian Journal Of Agricultural Sciences*, [s.l.], v. 8, n. 3, p.483-491, 21 set. 2013. *Revista Brasileira de Ciencias Agrarias*. <http://dx.doi.org/10.5039/agraria.v8i3a1894>.

Souza, A.P. ; Escobedo, J. F. ; Dal Pai, A. ; Gomes, E. N. . Estimativa da irradiação 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.

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.

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.

Stone, R.J.. Improved statistical procedure for the evaluation of solar radiation estimation models. **Solar Energy**, vol. 51,n º4, p. 289 – 291, 1993.

Tymvios, F.s. et al. Comparative study of Ångström's and artificial neural networks' methodologies in estimating global solar radiation. **Solar Energy**, [s.l.], v. 78, n. 6, p.752-762, jun. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.solener.2004.09.007>.

Turco, J.E.P.; Rizzatti, G.S. Avaliação de modelo matemático para estimar a irradiação solar incidente sobre superfícies com diferentes exposições e declividades. Engenharia Agrícola, v.26, p.257-267, 2006.

Vats, Kanchan; Tiwari, G.n.. Energy and exergy analysis of a building integrated semitransparent photovoltaic thermal (BISPVT) system. Applied Energy, [s.l.], v. 96, p.409-416, ago. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.apenergy.2012.02.079>.

Yadav, Amit Kumar; Chandel, S.s.. Solar radiation prediction using Artificial Neural Network techniques: A review. Renewable And Sustainable Energy Reviews, [s.l.], v. 33, p.772-781, maio 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2013.08.055>.

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.

Weber, Eliseu José. Estimativa e Mapeamento da Radiação Solar Incidente em Superfícies com Topografia Heterogênea na Zona de Produção Vitivinícola Serra Gaúcha. 2011. 166 f. Tese (Doutorado) - Curso de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

Willmott, C. J. On the validation of models. **Physical Geography**, vol. 2, p. 184-194, 1982.

CAPÍTULO 2

ESTIMATIVAS DA RADIAÇÃO DIFUSA HORÁRIA EM SUPERFÍCIE INCLINADA A PARTIR DAS MEDIDAS DA RADIAÇÃO DIFUSA E GLOBAL NA SUPERFÍCIE HORIZONTAL USANDO REDES NEURAIS E ANFIS

Adriano de Souza Marques; João Francisco Escobedo

RESUMO

Neste estudo estimou-se a fração difusa (Kd_{β^h}) incidente em uma superfície com inclinação de $22,85^\circ$ na base horária utilizando técnicas de aprendizado de máquina (TAM), a partir de dados obtidos no período de 1998 a 2001 em Botucatu/SP/Brasil. As estimativas foram realizadas usando uma série de combinações de variáveis astronômicas e geográficas por meio de três técnicas de redes neurais artificiais (RNA) do tipo Perceptron Multicamadas (MLP), Função de Base Radial (RBF) e Regressão Generalizada (GRNN) e do Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS). Como referência foram elaborados modelos estatísticos (ME) de regressão linear e polinomial. As estimativas de (Kd_{β^h}) foram realizadas por combinações de variáveis medidas e calculadas a partir das irradiações difusa (Hd_H) e global (Hg_H) obtidas na superfície horizontal. Os indicadores estatísticos r (correlação), RMSE(%) (precisão) e MBE(%) (exatidão) foram utilizados para avaliar os resultados das estimativas. As melhores estimativas de (Kd_{β^h}) a partir das combinações realizadas com (Hd_H) foram: MLP - RMSE=4,03%; RBF - RMSE=5,84%; GRNN - RMSE=10,85%; ANFIS - RMSE=4,15% e ME - RMSE=12,42%. Os indicadores de precisão mostram uma redução de aproximadamente 67% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). Nas estimativas de (Kd_{β^h}) a partir de (Hg_H) os melhores resultados foram: MLP - RMSE=21,69%; RBF - RMSE=25,43%; GRNN - RMSE=29,39%; ANFIS - RMSE=23,08% e ME - RMSE=35,35%. Os indicadores de precisão mostram uma redução de aproximadamente 39% com o uso da técnica (MLP) em comparação ao modelo estatístico (ME). Os resultados mostram que a técnica de rede neural artificial MLP apresentou os melhores índices em todas as estimativas de (Kd_{β^h}) com reduções significativas quando comparadas aos resultados obtidos com as estimativas obtidas com os modelos estatísticos. Pela análise dos resultados é possível observar que o uso das técnicas de aprendizado de máquina (TAM) nas combinações de variáveis propostas e com os dados obtidos de Botucatu/SP, se apresentam como alternativa aos modelos estatísticos (ME) para estimar as variáveis de (Kd_{β^h}).

Palavras - chave: Irradiação solar, Redes Neurais Artificiais, ANFIS, Estimativas.

ABSTRACT

This study estimated the diffuse fraction (Kd_{β^h}) incident on a surface with slope of 22.85° in the hourly basis using machine learning techniques (MLT), from data obtained from 1998 to 2001 in Botucatu / SP / Brazil. The estimates were made using a series of combinations of astronomical and geographic variables by means of three artificial neural network (ANN) techniques such as MultLayer Perceptron (MLP), Radial Basis Functions Networks (RBF) and Generalized Regression Neural Network (GRNN) Adaptive Neuro Fuzzy Inference System (ANFIS). Statistical models (SM) of linear and polynomial regression were elaborated as reference. Estimates of (Kd_{β^h}) were performed by combinations of variables measured and calculated from the diffuse (Hd_H) and global (Hg_H) irradiances obtained on the horizontal surface. The statistical indicators r (correlation), RMSE (%) (precision) and MBE (%) (accuracy) were used to evaluate the results of the estimates. The best estimates of (Kd_{β^h}) from the combinations performed with (Hd_H) were: MLP - RMSE = 4.03%; RBF - RMSE = 5.84%; GRNN - RMSE = 10.85%; ANFIS - RMSE = 4.15% and SM - RMSE = 12.42%. The precision indicators show a reduction of approximately 67% with the use of the technique (MLP) in comparison to the statistical model (SM). In the estimates of (Kd_{β^h}) from (Hg_H) the best results were: MLP - RMSE = 21.69%; RBF - RMSE = 25.43%; GRNN - RMSE = 29.39%; ANFIS - RMSE = 23.08% and SM - RMSE = 35.35%. The precision indicators show a reduction of approximately 39% with the use of the technique (MLP) in comparison to the statistical model (SM). The results show that the artificial neural network MLP technique presented the best indexes in all estimates (Kd_{β^h}) with significant reductions when compared to the results obtained with the estimates obtained with the statistical models. By the analysis of the results it is possible to observe that the use of the machine learning techniques (MLT) in the combinations of proposed variables and the data obtained from Botucatu / SP, are presented as an alternative to the statistical models (SM) to estimate the variables of (Kd_{β^h}).

Keywords: Solar Irradiation, Artificial Neural Networks, ANFIS, Estimates.

2.1 INTRODUÇÃO

As demandas pelo uso da energia solar têm crescido nos últimos anos, motivo pelo qual os países com maior incidência dessa energia podem ser beneficiados através do forte potencial de geração de energia elétrica e térmica e também para o desenvolvimento da agricultura. Dessa forma torna-se necessário conhecer medidas e modelos para se realizar estudos com estimativas da irradiação solar.

As medidas de componentes da radiação solar são obtidas por instrumentos como piranômetros, pireliômetros acoplados a dispositivos de rastreamento solar e piranômetros instalados sob mecanismos de sombreamento, que devido aos custos dos equipamentos e necessidade de medidas contínuas tornam-se uma desvantagem e as tornam pouco comuns nas estações de radiometria solar (Escobedo et al 2014), motivo pelo qual se justifica o uso de estimativas como uma alternativa para recomposição ou obtenção de dados para pesquisas e aplicações que necessitem dessas informações.

No Brasil predominam os estudos de estimativas por métodos estatísticos (Scolar, 2004; Turco & Rizzatti, 2006; Souza et al., 2010; Souza et al., 2011; Beruski et al., 2015), porém a utilização de técnicas de aprendizado de máquina (Redes Neurais Artificiais – RNA e Sistema Adaptativo de Inferência Neuro Fuzzy - ANFIS) para estimar radiação difusa em superfícies inclinadas se apresentam como métodos alternativos à complexidade dos modelos estatísticos e são eficientes para tratar funções não-lineares e conseqüentemente tendem a apresentar bons resultados nas estimativas dessas variáveis (Dahmani et al., 2011; Notton et al., 2012; Yadav et al., 2014), além de permitir a utilização de diferentes variáveis climatológicas e geográficas como variável independente.

Em muitos países as técnicas de RNA são utilizadas para estudos em diferentes inclinações de superfícies com bases horárias, diárias e mensais. Dentre as técnicas de RNA mais utilizadas está a *MultLayer Perceptron* (MLP), devido a sua facilidade de implementação, parametrização e capacidade de otimização dos problemas (Bosch et al., 2008; Yadav et al., 2014; El-Sebaei et al., 2010, Razafiarison et al., 2011; 31,35, Notton et al., 2012; Dahmani et al., 2013; Rahoma et al., 2011). Outras técnicas de RNA como a *Radial Basis Functions Networks* (RBF) e *Generalized Regression Neural Network* (GRNN) e *Adaptive Neuro Fuzzy Inference System* (ANFIS) são pouco exploradas para estimar variáveis da radiação solar (Elminir et al., 2007, Sumithira & Kumar, 2012;) e serão exploradas neste estudo.

Considerando a importância de se entender o comportamento da radiação difusa em superfícies inclinadas com base horária, medições foram realizadas entre os anos de 1998 e 2001 da irradiação difusa (H_{dH^h}) e global (H_{gH^h}) na superfície

horizontal e em superfície com inclinação de $22,85^\circ$ (Hd_{β^h}) com a face voltada para o norte no município de Botucatu/SP.

A partir dessas medidas o objetivo deste estudo é avaliar dentre as técnicas de Redes Neurais Artificiais (RNA) e Sistema de Inferência Neuro Fuzzy (ANFIS), um modelo para estimar a fração difusa da radiação global incidente em uma superfície inclinada a partir das combinações de variáveis medidas e calculadas a partir da irradiação difusa (Hd_{H^h}) e global (Hg_{H^h}) na superfície horizontal e comparar seus resultados aos obtidos com as estimativas dos Modelos Estatísticos (ME).

2.2 DESCRIÇÃO DAS TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)

O princípio de funcionamento das Técnicas de Aprendizado de Máquinas é similar ao processo de aprendizado do cérebro humano. A partir de um conjunto de informações ou de experiências adquiridas (dados de entrada) é possível obter (aprender) uma série de resultados (dados de saída). Isso se deve ao fato de que as técnicas podem reconhecer padrões de diferentes grandezas, como dados meteorológicos ou climatológicos, e através de um algoritmo de aprendizagem estabelecer uma associação entre dados de entradas e dados de saídas para adquirir conhecimento de forma automática e produzir resultados coerentes em estimativas ou classificação de dados (Lorena et al., 2011)


Entre as técnicas de aprendizado de máquinas mais empregadas para estimar radiação solar em superfície horizontais ou inclinadas destacam-se as Redes Neurais Artificiais (RNA) e o Sistemas de Inferência Adaptativo Neuro-Fuzzy (ANFIS) (Yadav e Chandel, 2014; Lauret et al., 2015; Santos et. al, 2016; Silva et. al, 2017; Assouline et. al, 2017).

2.2.1 Redes Neurais Artificiais (RNA)

As RNA apresentam uma estrutura formada por um conjunto de elementos chamados neurônios distribuídos paralelamente. É composta por uma camada de entrada e uma de saída conectadas por uma ou mais camadas ocultas. O processamento de informações entre as camadas é realizado por um algoritmo capaz de analisar funções complexas e não lineares, o que nem sempre é possível com o uso de técnicas estatísticas convencionais. São utilizadas para o reconhecimento e classificação de padrões, agrupamento, previsão e estimativas.

A Figura 2.1 apresenta a estrutura básica de um neurônio artificial formado por um conjunto de conexões (*sinapses*) que recebem os valores de entrada ($x_1, x_2, \dots, x_i$) definidos pelos pesos sinápticos ($w_1, w_2, \dots, w_i$). Através de um combinador linear (Σ), executa a soma ponderada das entradas, produzindo uma saída chamada de potencial de ativação (u) que é então transformada por uma função de ativação (f), que gera a saída (y) limitada por um intervalo de valores definido pelo limiar de ativação (*bias* - b) (Marzouq et al. 2017).

Figura 2.1 - Modelo do neurônio artificial.



Fonte: McCulloch e Pitts (1943)

A principal característica de uma RNA está na capacidade de aprendizado proporcionado pela arquitetura e no processo de treinamento utilizado. O aprendizado é consequência das mudanças de valores dos pesos sinápticos, conectados aos neurônios entre as camadas com o objetivo de aproximar os valores da saída da rede (y) com os valores desejados. Esse processo é realizado por um algoritmo de treinamento que define aspectos importantes como o número de neurônios, número de camadas ocultas, função de ativação e conjunto de dados para treinamento e validação.

Os primeiros trabalhos envolvendo a radiação solar, usaram a RNA para realizar estimativas da irradiação solar global (Elizondo et. al, 1994; Mohandes et. al, 1998). As técnicas foram sendo aprimoradas e utilizadas para estimar outras irradiações como a direta e difusa (Bosch et al., 2008; El-Sebaï et al., 2010; Razafiarison et al., 2011; Rahoma et al., 2011; Notton et al., 2012; Dahmani et al., 2013; Yadav et al., 2014; Santos et al., 2016)

Entre as técnicas de RNA utilizadas para estimativa de radiação solar destacam-se a Rede *Perceptron Multicamadas* (MLP) amplamente utilizada na


literatura em diversas áreas, a Rede de Função de Base Radial (RBF) proposta como alternativa à MLP e a Rede de Regressão Generalizada sendo uma otimização da RBF (Mohandes et. al, 1998; Alam et. al, 2009; Mellit et. al, 2010; Dorvlo et. al, 2012; Feng et. al, 2017; Citakoglu, 2017).

2.2.1.1 Multilayer Perceptron (MLP)

Caracterizada pela presença de pelo menos uma camada intermediária de neurônios localizada entre as camadas de entrada e a camada de saída. São classificadas como redes do tipo *feedforward* (alimentação a frente) de camadas múltiplas. O treinamento é realizado de forma supervisionada, ou seja, para cada informação de entrada tem-se uma respectiva saída desejada (Alam et al. 2009).

A Figura 2.2 mostra a estrutura da rede MLP, onde o fluxo de treinamento tem início quando as variáveis de entrada (x) são aplicadas na camada de entrada, deslocando-se às camadas ocultas até a camada de saída finalizando o processamento por uma função de ativação (normalmente linear) na camada de saída (Rehman e Mohandes, 2008).

Figura 2.2 - Arquitetura da Rede Neural Perceptron Multicamadas



Fonte: Adaptado de Yadav e Chandel, 2014.


Durante o processo de treinamento, algoritmos procuram ajustar os pesos ($w_{i,j}$) entre os neurônios das entradas e a saída desejada. Algoritmos como o *backpropagation* (BP) otimizados por *Levenberg-Marquardt* ajustam os pesos através de taxas de aprendizagem (controle dos *bias* - Θ) e de taxas de convergências (controle de velocidade) tornando o processo de treinamento da rede mais rápido e eficiente (Kovács, 2006; Linares-Rodriguez et al., 2011; Azevedo et al., 2000; Braga et al. 2012).

Com arquitetura flexível e pouca complexidade, a rede MLP é mais utilizada na estimativa da irradiação solar, com diversos estudos realizados para estimar a irradiação global (H_g) (Elizondo et. al, 1994; Kalogirou, 2000; Tymvios et. al, 2005; Notton et. al, 2012; Kumar et. al, 2015; Yadav et al. 2014; Silva et. al, 2016), irradiação solar direta (H_b) (Alam et. al, 2006; Tomar et. al, 2012; Kaushina et. al, 2014; Santos et al., 2016), irradiação solar difusa (H_d) (Soares et. al, 2004; Alam et. al, 2009; Ihya et. al, 2015; Boznar et. al, 2017) e radiação PAR (P. Pankaew et. al, 2014; Jacovides, 2015; Wang, 2016). Esses estudos utilizaram como entrada diversas variáveis climatológicas e geográficas, obtendo melhor precisão nas estimativas comparados aos métodos estatísticos convencionais.

2.2.1.2 Radial Basis Functions Networks (RBF)

A RBF é uma técnica de RNA utilizada em diversas aplicações como modelagem de séries temporais. Pode ser aplicada em quase todos os tipos de problemas pelos quais outras técnicas de RNA são utilizadas. A diferença está na composição de sua estrutura, das informações recebidas, do número de camadas e do número de neurônios da camada (Behrang et al., 2010; Wang et al., 2016).

É classificada como rede do tipo *feedforward* com treinamento realizado em duas fases distintas: a não supervisionada que consiste na identificação dos pesos (W_1) e a supervisionada (*backpropagation*) que consiste na identificação dos pesos (W_2). Sua estrutura é formada por três camadas, sendo estas, a camada de entrada; a camada intermediária que possui uma função de base radial como função de ativação (geralmente Gaussiana) e a camada de saída que realiza a soma dos pesos dos neurônios da camada intermediária e tem função de ativação linear (Figura 1.3.) (Crispim et. al, 2006; Braga et al. 2012; Behrang et al., 2010).

Figura 2.3 - Arquitetura da Rede Neural de Base Radial

Fonte: Behrang et al.(2010).

A rede RBF é uma técnica de RNA com bons resultados nas estimativas de irradiação solar, tendo estudos desenvolvidos para estimativas da irradiação solar global (H_g) (Sfetsos, 2000; Dorvlo et al., 2002; Behrang et al., 2010; Benghanem e Mellit, 2010; Wang et al., 2016; Silva et. al, 2016), irradiação solar direta (H_d) (Yadav, 2014; Mishra et al. 2008; Mohandes, 2012; Santos et al., 2016) e irradiação solar difusa (H_d) (Soares et. al, 2004; Mehleri et al.,2010; Mohandes, 2012).

2.2.1.3 Rede Neural de Regressão Generalizada (GRNN)


Considerada uma otimização da rede neural RBF, a GRNN não requer um treinamento iterativo e consiste de duas camadas de processamento (padrão e somadora) além das camadas de entrada e saída (Figura 1.4). Foi desenvolvida como proposta alternativa ao algoritmo *backpropagation* para a rede neural *feedforward* (SPECHT, 1991). Possui grande capacidade de generalização, assim como outras redes, com aplicação também em diversos processos, como no ajuste de curvas ou aproximações de funções (Specht, 1991).

A GRNN pode ser definida como uma Rede Neural Artificial (RNA) com estrutura do tipo *feedforward*, ou seja, não recorrente e requer treinamento supervisionado. Possui grande capacidade de generalização, assim como outras redes, com aplicação também em diversos processos, como no ajuste de curvas ou aproximações de funções (Specht, 1991).

A Figura 1.4 apresenta a estrutura da rede GRNN sendo sua arquitetura composta de duas camadas, a primeira chamada de padrão e a segunda de

somadora, além das camadas de entrada e saída. A camada de entrada irá inserir os vetores de entrada ($x_{i,j}$) na rede que se posicionam em um determinado centro denominado cluster, o qual tem sua posição subtraindo-se do vetor que foi armazenado ao centro da função gaussiana (Cellik e Muneer, 2013). Os valores absolutos dessa diferença são somados e alimentados na função de ativação não linear (exponencial) na camada padrão (Cn). A saída da camada padrão é encaminhada para a camada somadora, que realizam o somatório do produto entre o vetor peso ($w_{i,j}$) e o vetor obtido na saída da unidade padrão, por fim, as saídas dividem cada resultado da camada somadora pelo somatório total de todas as unidades da soma (Specht, 1991).

Figura 2.4 - Arquitetura da GRNN



Fonte: Specht (1991).

A técnica de aprendizado da GRNN difere das redes neurais mais utilizadas, pois possui um processo de aprendizado que não faz uso do ajuste iterativo para adquirir conhecimento no treinamento, porém, possui capacidade de aprender quase que instantaneamente com os dados apresentados na base de treinamento. O método simplesmente armazena os padrões de treinamento e os processa através de uma função não linear para determinar as funções componentes de densidade de probabilidade de saída (Specht, 1996).

Apesar de sua simplicidade as redes GRNN têm capacidade de estimar qualquer função não linear, mas os resultados podem ser afetados devido a uma série de fatores como a qualidade e quantidade de dados utilizados no treinamento. Este aspecto pode tornam as redes GRNN pouco utilizadas em estimativas da irradiação solar, porém com estudos recentes realizados para estimar a irradiação solar global

(Şenkal et al., 2010; Şenkal et al., 2010A; Celik and Muneer, 2013; Wang et. al, 2016; Feng et. al, 2017).


2.2.2 Adaptive Neuro Fuzzy Inference System (ANFIS)

A ANFIS pode ser definida como a combinação das características de aprendizado de uma rede neural adaptativa (ANN) com a interpretação de um sistema de inferência fuzzy (FIS) (Jang, 1993; Zadeh, 1965; Takagy e Sugeno, 1985).

O ANFIS é capaz de aproximar qualquer função contínua real em um conjunto compacto de parâmetros para qualquer grau de precisão (Jang, 1997). Identifica um conjunto de parâmetros através de uma regra de aprendizado híbrida e possui duas abordagens para sistemas de inferência *fuzzy* (Mamdani, 1975) e (Sugeno, 1985).

A Figura 2.5 apresenta a estrutura ANFIS, composta de cinco camadas e duas funções de pertinência para cada entrada.

Figura 2.5 - Arquitetura da ANFIS



Fonte: Mohammadi et al. (2016).

No processo de treinamento híbrido a Lógica Fuzzy integra o conhecimento implícito (dados) e explícito (especialista) na definição das variáveis a serem utilizadas por meio de interações entre as camadas que acontecem em dois processos: *fuzzificação* e *defuzzificação* (Wang et al., 2009; Quej et al., 2017). Nas primeira e segunda camadas se realiza o mapeamento das variáveis por meio da aplicação da função de pertinência (*fuzzificação*), na terceira camada ocorre a normalização das informações com o grau de ativação da regra anterior em relação às demais. Na quarta camada encontra-se a composição das regras, finalizando com o processo de defuzzificação e a totalização dos valores na quinta camada (saída) (Jang, 1993; Takagy e Sugeno, 1985; Wang et al., 2009; Quej et al., 2017).

A ANFIS é uma técnica de aprendizado de máquina cada vez mais presente em estudos de estimativas da radiação solar, porém tem sido utilizada com mais frequência para estimar a irradiação global (H_g) (Sfetsos, 2000; Mellit, 2007; Moghaddamnia, 2009; Rahoma et al. 2011; Landeras, 2012; Kumar, 2012; Olatomiwa et al., 2015; Mohammadi, 2015; Zou, 2017)

2.3 MATERIAL E MÉTODOS

2.3.1 Localização e Clima


Os dados utilizados neste estudo foram medidos na Estação de Radiometria Solar na Faculdade de Ciências Agronômicas – FCA/UNESP no município de Botucatu/SP/Brasil (22°53'S de latitude, 48°26'W na longitude e altitude de 786m). A classificação climática de Köppen para o local é Cwa (Cepagri, 2012), temperado quente com verão quente e úmido e elevada precipitação, inverno frio e seco. (Teramoto e Escobedo, 2012).

As séries climáticas da temperatura, umidade relativa, precipitação e nebulosidade no período de 1970 a 2008 está apresentada nas Figuras 2.6 (a), (b) e (c), e a evolução anual das médias mensais da Profundidade Ótica dos Aerossóis (POA) e Material Particulado (PM) médias mensais no período de 2001 a 2005 estão apresentadas na Figura 1.6 (d), sendo que:

A Figura. 2.6(a) mostra a série anual da temperatura e umidade relativa e destaca fevereiro como o mês mais quente e julho o mais frio, bem como o mês de janeiro o mais úmido e o mês de agosto o menos úmido; A Figura 2.6(b) mostra que a nebulosidade [$f=1-(n/N)$] é mais elevada nos meses de janeiro e menor nos meses de agosto; A Figura 2.6(c) mostra que a série anual da precipitação, acompanha a evolução da nebulosidade podendo ser classificada em período chuvoso (outubro a março) e seco (abril a setembro), onde o limite entre os limites é o valor da precipitação de aproximadamente 100mm e a Figura 2.6(d) mostra a evolução anual das médias mensais da profundidade ótica de aerossóis (POA) do período de 2000 a 2005 obtidas pelo satélite TERRA do período de 2000 a 2005 indicando que no período de queimadas da cana de açúcar (julho), a concentração de aerossóis aumenta consideravelmente atingindo valor máximo de 0,45 no mês de setembro. Esse valor

corresponde a uma concentração de material particulado (PM_{10}) igual a $70,0\mu g.m^{-3}$ (Codato et al., 2008; Rossi, T., 2017)

Figura 2.6 - Séries Climáticas (período: 1970-2008): (a) Temperatura e Umidade Relativa, (b) Nebulosidade, (c) Precipitação, (d) Relação entre a evolução anual da Profundidade Ótica dos Aerossóis (POA) e Material Particulado (PM) em médias mensais (obtidas do satélite TERRA) no ano de 2001 a 2005



Fonte: Rossi, T.J. (2017)

2.3.2 Obtenção da Base de dados

Os dados das medidas instantâneas (irradiância – W/m^2) das radiações global e difusa na superfície horizontal e difusa na superfície com inclinação de $22,85^\circ$ foram obtidos no período de 10/4/1998 a 31/08/2001 através de medidas realizadas a cada 5 segundos os quais tiveram suas médias calculadas de 5 minutos. Posteriormente esses valores foram integralizados para obtenção dos valores em energia (irradiação – MJ/m^2) e separados em séries temporais na partição horária.

As irradiâncias global e difusa instantâneas na horizontal foram medidas com um pirômetro EPPLEY-PSP com fator de calibração de $7,45\mu V/Wm^{-2}$ e linearidade de $\pm 0,5\%$ de 0 a $2800 Wm^{-2}$, sendo que para a difusa utilizou-se anel de sombreamento proposto por Melo & Escobedo (1994). Para as medidas da irradiância difusa no plano inclinado utilizou-se pirômetro Branco & Preto EPPLEY e anel de sombreamento Melo & Escobedo (1994) (Figura 2.7).

Figura 2.7 - Estrutura para medida das radiações difusa nos planos horizontal e inclinado



Medidas na Horizontal



Medidas na Inclinação

Foram realizadas medidas das irradiâncias difusa (I_d) na superfície horizontal e inclinada na latitude (22.85°), e irradiância global (I_g) na superfície horizontal, bem como as variáveis umidade relativa (Rh), temperatura do ar (Tar) e nebulosidade (Neb). As variáveis da irradiação do topo da atmosfera (H_0), ângulo zenital (θ_z), declinação solar (δ), transmissividade global (Kt^h), fração difusa (Kd^h) e massa ótica (mr) foram calculadas.

2.3.2.1 Controle de qualidade da base de dados


Os dados foram analisados e os valores discrepantes provocados por erros de leitura foram eliminados. Após calculado, os dados da transmissividade global ($Kt=H_g/H_0$) e fração difusa ($Kd=H_d/H_g$) foram normalizados eliminando-se valores menores que 0 e maiores que 1; já os dados do ângulo zenital (θ_z) tiveram rejeitados os valores maiores que 80° ; os valores da irradiação no topo da atmosfera (H_0) foram normalizados eliminando-se os valores maiores que $5,0 \text{ MJ/m}^2$, valor obtido considerando a variação na intensidade da irradiação no topo da atmosfera ($4,91 \text{ MJ/m}^2 - I_{qbal}$, 1983) em função da excentricidade da órbita terrestre que varia $\pm 3\%$ no afélio e no periélio (Duffie e Beckman, 1991). Após a aplicação dos filtros houve uma redução de 7% na base de dados.

2.3.3 Organização das estimativas

Para realizar as estimativas a partir das medidas das irradiações H_{gH^h} e H_{dH^h} em base horária, foram utilizadas a transmissividade da global (Kt_{H^h}) e fração da difusa (Kd_{H^h}) de forma a minimizar os aspectos das variações temporais da radiação que

oscilam com as condições astronômicas, geográficas e climáticas (Iqbal, 1983; Liou, 2002; Varejão-Silva, 2006). A utilização das frações minimiza os efeitos astronômicos e geográficos, considerando que as componentes da radiação são obtidas no mesmo local e intervalo de tempo, já os efeitos climáticos são mantidos, principalmente em função a interação com vapor de água e aerossóis (Dal Pai, 2005).

Figura 2.8 - Organização das estimativas da radiação difusa no plano inclinado



Fonte: Elaborada pelo Autor.

onde:

- (A) Estimar a fração difusa da radiação global na superfície inclinada (Kd_{β}^h) a partir das medidas da irradiação difusa na superfície horizontal (Hd_H^h);
- (B) Estimar a fração difusa da radiação global na superfície inclinada (Kd_{β}^h) a partir das medidas da irradiação global na superfície horizontal (Hg_H^h).

2.3.4 Modelo Estatístico (ME)

Os modelos estatísticos de estimativas baseados na transmissividade da radiação global e fração da difusa, foram definidos conforme metodologias encontradas na literatura baseadas em Liu e Jordan (1960).

Os modelos modificados para estimar as frações da difusa (Kd_{β}^h) em superfície inclinada na partição horária são definidas pelas relações definidas na Tabela 2.1:

Tabela 2.1 - Variáveis selecionadas para as estimativas com as técnicas de Modelagem de Máquina

Fig. 2.8	Estimativa	Modelo	Ajuste
(A)	$Kd_{\beta^h} = f(Kd_{H^h})$	$y = a + b(x)$	Regressão linear
(B)	$Kd_{\beta^h} = f(Kt_{H^h})$	$y = a + b.(x)^1 + c.(x)^2 + d.(x)^3$	Polinômio 3ª ordem

2.3.5 Treinamento das RNA e ANFIS

Para as estimativas utilizando as redes neurais artificiais (RNA) com as técnicas MLP, RBF e GRNN e também pelo sistema híbrido ANFIS, foram realizados treinamentos usando o software MATLAB R2014a, o qual pode ser descrito como uma ferramenta computacional de alto desempenho com ampla aplicação nas áreas de engenharia e ciências. Possui linguagem de programação proprietária que permite o desenvolvimento de computação numérica de forma dinâmica. O uso do MATLAB para implementação de RNA e ANFIS, possui grande destaque devido a sua ampla disponibilidade de funções para este fim, bem como ampla documentação oficial disponível (Mathworks, 2017).

As variáveis de entrada merecem destaque quando se trata de estimativas usando técnicas de aprendizado de máquina (TAM). Deve-se considerar a natureza da radiação solar, onde diversos parâmetros podem influenciar na sua intensidade e na sua disponibilidade de maneira bastante complexa, o que pode dificultar o processo de estimativa através das TAM (Tymvios et al., 2005).

Dependendo da qualidade, quantidade e correlações existentes os resultados obtidos podem comprometer a generalização do problema estudado.

O critério adotado para determinação das variáveis foi com base na disponibilidade das variáveis medidas e calculadas, considerando a influência que cada uma possa proporcionar na estimativa, além das indicações apresentadas na bibliografia e as relações físicas existente entre as variáveis de entrada e a variável a ser estimada. Um número excessivo de variáveis deve ser evitado, pois isso pode prejudicar os resultados e desempenho da rede, pois aumenta seu tamanho e complexidade. De forma contrária um número reduzido de variáveis de entrada pode tornar a rede incapaz de aprender devido à falta de informações.

As variáveis adotadas estão apresentadas na Tabela 2.2.

Tabela 2.2 - Variáveis selecionadas para as estimativas com as técnicas de Aprendizado de Máquina

Descrição	Variável	Medida	Calculada
Frações das radiações Global nas superfícies horizontal e inclinada	K_{tH}^h		x
Declinação Solar	δ		x
Irradiação no topo da atmosfera nas superfícies horizontal e inclinada	H_{0H}^h		x
	$H_{0\beta}^h$		
Ângulo Zenital	θ_z		x
Massa óptica	mr		x
Temperatura do ar	Tar	x	
Umidade Relativa	Rh	x	
Nebulosidade	Neb	x	

As variáveis de entrada e saída foram organizadas em arranjos de combinações, separadas em arquivos no formato CSV (*Comma-Separated Values*) contendo os dados de treino conforme exemplo na Figura 2.9.

Figura 2.9 - Exemplo da estrutura do arquivo CSV

Variáveis de Entrada						Variável de Saída
KDh[X]	H0h[Y]	Zt[Y]	Decl[Y]	Tar[Y]	Neb[Y]	KDi[Y]
0.47211	1.44995	67.49839	7.65552	18.91583	41.66667	0.42777
0.45002	2.46002	52.49877	7.65552	18.64833	0	0.417
0.72628	3.28509	37.49915	7.65552	18.4725	41.66667	0.67453
0.7591	3.8689	22.49955	7.65552	18.555	91.66667	0.71839
0.49423	4.17165	7.50012	7.65552	18.46917	25	0.48167
0.56226	4.1727	7.50012	7.65552	18.77	41.66667	0.54009
0.32227	3.87197	22.49955	7.65552	20.01833	0	0.30426
0.31635	3.28997	37.49915	7.65552	20.97833	16.66667	0.3092

As combinações dos arranjos foram determinadas de forma a promover uma avaliação da influência das variáveis nos resultados das estimativas, conforme mostra a Tabela 2.3.

Tabela 2.3 - Modelos de treinamento da RNA e ANFIS

(A)

ESTIMATIVAS DE $Kd_{\beta}^h = f(Kd_H^h)$						
Modelos	Variáveis de Entrada					Variável Estimada
<i>ME/M1</i>	Kt_H^h					Kd_{β}^h
<i>M2</i>	Kt_H^h	$H0_H^h$				
<i>M3</i>	Kt_H^h	$H0_H^h$	Hg_H^h			
<i>M4</i>	Kt_H^h	$H0_H^h$	Hg_H^h	Θ_z		
<i>M5</i>	Kt_H^h	$H0_H^h$	Hg_H^h	Θ_z	mr	
<i>M6</i>	Kt_H^h	$H0_H^h$	Hg_H^h	Θ_z	Rh	
<i>M7</i>	Kt_H^h	$H0_H^h$	Hg_H^h	Θ_z	Neb	

(B)

ESTIMATIVAS DE $Kd_{\beta}^h = f(Kt_H^h)$							
Variáveis de Entrada							Variável Estimada
<i>ME/M1</i>	Kt_H^h						Kd_{β}^h
<i>M2</i>	Kt_H^h	$H0_H^h$					
<i>M3</i>	Kt_H^h	$H0_H^h$	Θ_i				
<i>M4</i>	Kt_H^h	$H0_H^h$	Θ_i	δ			
<i>M5</i>	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar		
<i>M6</i>	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar	mr	
<i>M7</i>	Kt_H^h	$H0_H^h$	Θ_i	δ	Tar	Rh	
<i>M8</i>	Kt_H^h	$H0_H^h$	Θ	δ	Tar	Neb	

O índice Erro Quadrático Médio (EQM) foi utilizado como indicador de desempenho dos treinamentos da RNA e ANFIS. O EQM determina o erro médio entre os valores da saída obtidos com o treinamento da rede (E) e os valores desejados ou medidos (M), o parâmetro (x) é o número de amostras do treinamento (Equação 2.1).

$$EQM = \left[\frac{\sum_{i=1}^x (E-M)^2}{x} \right] \quad (2.1)$$

A parametrização para definição da arquitetura de treinamento deste estudo utilizou como referência a obtenção do menor valor do índice da Raiz do Erro Quadrático Médio relativo (RMSE%) que determina a precisão obtida com o treinamento da rede e a validação cruzada.

2.3.5.1 Treinamento da MLP

A MLP foi treinada com o algoritmo de aprendizagem *Levenberg-Marquadt* (*trainlm*) implementado pela função *feedforwardnet*, e parametrizada com o número de neurônios, número de camadas ocultas e número máximo de épocas de

treinamento (neste estudo foi definido o número de 1000 épocas máxima para os treinamentos).

A condição para determinação do número de neurônios depende de uma série de fatores, como a quantidade de dados disponível, a qualidade dos dados e complexidade do problema (não-linear, descontínuo, etc.), mas de forma geral o número de neurônios é determinado de forma empírica com base na capacidade de generalização da rede. Fórmulas heurísticas também podem ajudar a determinar um valor inicial para o número de neurônios (Silva et al., 2010).

Neste estudo a determinação do número de neurônios para a MLP utilizou o método de Fletcher-Gloss (Equação 2.2) para determinar o número inicial de neurônios considerando apenas uma camada oculta:

$$2.\sqrt{n_1} + n_2 \leq n \leq 2.n_1 + 1 \quad (2.2)$$

Onde n_1 é o número de variáveis de entrada; n_2 a quantidade de neurônios na camada de saída; n a quantidade de neurônios na camada oculta.

Figura 2.10 - Critério de Fletcher-Gloss para determinação do número de neurônios do treinamento.

Modelos	Fletcher-Gloss			Camada Oculta
M1	3	$\leq n \leq$	3	1
M2	4	$\leq n \leq$	5	
M3	4	$\leq n \leq$	7	
M4	5	$\leq n \leq$	9	
M5	5	$\leq n \leq$	11	
M6	5	$\leq n \leq$	11	
M7	5	$\leq n \leq$	11	
M8	5	$\leq n \leq$	11	

Os treinamentos foram realizados variando-se o número de neurônios de acordo com a Figura 2.10, em cada modelo de combinação (M1 a M8). Posteriormente cada modelo de combinação foram treinados consecutivamente obtendo-se 10 redes. Desse conjunto de treinamento foram calculadas as médias do EQM obtidos de forma a se escolher a rede (dentre as 10) que apresentou o menor valor da média dos erros, ou o melhor desempenho no treinamento.


Esse processo é repetido aumentando-se gradualmente o número de neurônios até se obter o menor resultado do EQM em cada modelo de combinação (M1 a M8) de forma a definir a arquitetura ideal para o treinamento das combinações propostas.


Vale destacar que treinamentos com variações do número de camadas ocultas (de 1 a 5) e do número de neurônios (de 5 a 150 com incremento de 10) diferentes dos critérios da Equação 2.2 foram realizados, porém as arquiteturas especificadas na Tabela (2.4) apresentaram os melhores desempenhos.

A função de ativação utilizada foi a Tangente Hiperbólica (*tansig*), dada as características de dados das variáveis de entrada. O critério de parada do treinamento da MLP foi a validação cruzada, sendo que no processo de treinamento os dados são separados aleatoriamente em 70% para treino, 15% para validação e 15% para teste. A cada ciclo (época) os erros da validação são avaliados, e enquanto continuar diminuindo significa que a rede continua aprendendo. Quando o erro da validação aumentar enquanto o erro do conjunto de treinamento continuar a cair, é sinal que a rede está com *overfitting*, condição que indica o momento de parar o treinamento. Nessas condições o treinamento irá parar quando o erro da validação continuar aumentando durante 6 épocas sucessivas (Figura 2.11). Vale destacar que esse tipo de critério também minimiza o risco de *underfitting* da rede e acontece de forma automática com a utilização da função *feedforwardnet* no MATLAB.

Figura 2.11 – Curvas de treinamento da MLP

(A) $[Kd_{\beta}^h = f(Kd_H^h)]$ – Combinação M8 – 5 neurônios





Os gráficos da Figura 2.11 A e B apresentam os resultados de desempenho nos treinamentos das redes com os melhores resultados do *EQM* com base na Tabela 2.4. No treinamento de (A) $[Kd_{\beta}^h = f(Kd_H^h)]$ a melhor rede convergiu com 149 épocas na combinação M8 contendo 6 variáveis de entrada. No treinamento de (B) $[Kd_{\beta}^h = f(Kt_H^h)]$ a rede com melhor resultado demandou de um menor esforço computacional convergindo com 99 épocas na combinação M8 contendo 6 variáveis de entrada.

Após o processo de treinamento da MLP, as redes com os melhores resultados foram organizadas na Tabela 2.4.

Tabela 2.4 - Arquiteturas para as estimativas com a Rede MLP

(A)

Modelos	Variáveis de Entrada		Variável Estimada	EQM	Épocas	Solução Ótima	
						$Kd_{\beta}^h = f(Kd_H^h)$	
ME	Kd_H^h		Kd_{β}^h			N. Neurônios	CO
M1	Kd_H^h			2,21E-03	26	3	1
M2	Kd_H^h	$H0_H^h$		1,37E-03	86	4	
M3	Kd_H^h	$H0_H^h$		3,70E-04	32	5	
M4	Kd_H^h	$H0_H^h$		3,51E-04	19	7	
M5	Kd_H^h	$H0_H^h$		3,48E-04	17	7	
M6	Kd_H^h	$H0_H^h$		3,43E-04	18	8	
M7	Kd_H^h	$H0_H^h$		3,34E-04	131	8	
M8	Kd_H^h	$H0_H^h$		3,48E-04	149	5	


(B)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Épocas	Solução Ótima	
										$Kd_p^h = f (Kt_H^h)$	
ME	Kt_H^h						Kd_p^h			N. Neurônios	CO
M1	Kt_H^h							2,02E-02	10	3	1
M2	Kt_H^h	$H0_H^h$						1,15E-02	171	5	
M3	Kt_H^h	$H0_H^h$	Θ_z					1,13E-02	9	4	
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				1,10E-02	11	7	
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			1,09E-02	5	7	
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		1,07E-02	13	6	
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		1,07E-02	21	8	
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		8,06E-03	99	8	


Os gráficos da Figura 2.12 A e B mostram uma avaliação do treinamento considerando o índice EQM em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 2.4 A e B respectivamente. Os resultados mostram que os conjuntos e combinações de variáveis de entrada foram relevantes para o desempenho no treinamento da MLP.

Figura 2.12 - Curva do EQM do Treinamento em função das combinações testadas

(A)



(B)



2.3.5.2 Treinamento da RBF

O MATLAB R2014a possui duas funções para implementação da rede RBF, sendo que a:

newrb cria uma rede iterativa. Uma quantidade fixa de neurônios é adicionada à camada oculta em cada época de treinamento até que se atinja o erro desejado ou o número de neurônios exceda o máximo especificado, baseado no valor do erro quadrático médio.

newrbe cria a rede com o número de neurônios igual ao número de vetores de entrada do treinamento. Após o treinamento é criada uma rede com erro zero, no que diz respeito aos vetores de treinamento.

Ambas as funções foram testadas, porém neste estudo foi utilizada para treinamento da RBF a função *newrbe*, pois a mesma apresentou resultados mais eficientes em termos de precisão, mesmo considerando um processo de treinamento mais custoso do ponto de vista do esforço computacional.

O treinamento da técnica RBF é definido pelo parâmetro de ajuste (σ) identificado como *spread*. O ajuste (σ) controla o raio de influência da função Gaussiana e seu valor é determinado de forma empírica com valores variado entre 0.01 a 10000 de forma a se obter menor valor no índice de desempenho EQM. Com relação ao número de neurônios, a função escolhida inicia o treinamento com o número mínimo, sendo incrementado automaticamente a cada ciclo em função do

erro. O processo é repetido até que se atinja o número máximo de neurônios da camada escondida.

Após o processo de treinamento, as redes com os melhores resultados classificados pelo menor índice do EQM em cada modelo de combinação foram organizadas na Tabela 2.5.

Tabela 2.5 - Arquiteturas para as estimativas com a Rede RBF

(A)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kd_{\beta}^h = f(Kd_H^h)$
ME	Kd_H^h						Kd_{β}^h		spread (σ)
M1	Kd_H^h							2,20E-03	1,00E+00
M2	Kd_H^h	$H0_H^h$						1,01E-03	1,00E+01
M3	Kd_H^h	$H0_H^h$	Θ_z					6,86E-04	1,00E+04
M4	Kd_H^h	$H0_H^h$	Θ_z	δ				4,42E-04	1,00E+03
M5	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar			4,36E-04	1,00E+03
M6	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		6,29E-04	1,00E+05
M7	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		4,16E-04	1,00E+03
M8	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		6,05E-04	1,00E+05


(B)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kd_{\beta}^h = f(Kt_H^h)$
ME	Kt_H^h						Kd_{β}^h		spread (σ)
M1	Kt_H^h							2,03E-02	1,00E+01
M2	Kt_H^h	$H0_H^h$						1,16E-02	1,00E+01
M3	Kt_H^h	$H0_H^h$	Θ_z					1,34E-02	1,00E+03
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				1,28E-02	1,00E+03
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			1,28E-02	1,00E+03
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		6,20E-27	1,00E-03
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		1,25E-02	1,00E+03
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		1,00E-02	1,00E+03


Os gráficos da Figura 2.13 A e B mostram uma avaliação do treinamento considerando o índice EQM em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 2.5 A e B respectivamente. Os resultados mostram que no treinamento da rede RBF, a maioria dos conjuntos e combinações de variáveis de entrada foram relevantes para o desempenho no treinamento, excetuando-se no modelo de estimativa (B) [$Kd_{\beta}^h = f(Kt_H^h)$] onde a combinação M6 não conseguiu generalizar o problema apresentado.

Figura 2.13 - Curva do EQM do Treinamento em função das combinações testadas

(A)



(B)



2.3.5.3 Treinamento da GRNN

A técnica de rede GRNN foi treinada por um algoritmo desenvolvido no MATLAB, o qual utiliza a função *newgrnn*. A parametrização da função é basicamente definida pelo parâmetro de ajuste (σ - *spread*), o qual deve ser determinado através de experimentação variando seu valor de 100 a 0,00001 de forma a se atingir o menor índice de desempenho EQM no treinamento 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.

Após o processo de treinamento, as redes com os melhores resultados classificados pelo menor índice de desempenho do EQM foram organizadas na Tabela 2.6.

Tabela 2.6 - Arquiteturas para as estimativas com a Rede GRNN

(A)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kd_{\beta}^h = f(Kd_H^h)$
ME	Kd_H^h						Kd_{β}^h		spread (σ)
M1	Kd_H^h							2,18E-03	1,00E-02
M2	Kd_H^h	$H0_H^h$						1,76E-03	1,00E-01
M3	Kd_H^h	$H0_H^h$	Θ_z					5,57E-05	1,00E-02
M4	Kd_H^h	$H0_H^h$	Θ_z	δ				4,96E-06	1,00E-02
M5	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar			9,47E-05	1,00E-01
M6	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		9,45E-05	1,00E-01
M7	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		5,93E-02	1,00E+01
M8	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		2,28E-02	1,00E+01


(B)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima
									$Kd_{\beta}^h = f(Kt_H^h)$
ME	Kt_H^h						Kd_{β}^h		spread (σ)
M1	Kt_H^h							2,01E-02	1,00E-02
M2	Kt_H^h	$H0_H^h$						1,37E-02	1,00E-01
M3	Kt_H^h	$H0_H^h$	Θ_z					1,31E-02	1,00E-01
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				7,38E-03	1,00E-01
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			8,09E-02	1,00E+05
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		8,09E-02	1,00E+03
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		8,09E-02	1,00E+03
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		7,68E-03	1,00E+00


Os gráficos da Figura 2.14 A e B mostram uma avaliação do treinamento considerando o índice EQM em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 2.6 A e B respectivamente. Os resultados mostram que no treinamento da rede GRNN, para o modelo (A) [$Kd_{\beta}^h = f(Kd_H^h)$] que as combinações M7 e M8 não foram relevantes para o desempenho no treinamento. As combinações de M3 a M6 apresentaram valores de erro muito próximos de zero, o que pode indicar que essa rede perdeu a capacidade de generalizar o problema. Nos modelos de estimativa (B) [$Kd_{\beta}^h = f(Kt_H^h)$] as combinações M5, M6 e M7 não foram relevantes para o desempenho no treinamento.

Figura 2.14 - Curva do EQM do Treinamento em função das combinações testadas

(A)



(B)



2.3.6 Treinamento da ANFIS

Da mesma forma que as redes neurais artificiais (RNA) a ANFIS possui uma estrutura de parametrização que deve ser ajustada com o objetivo de se obter o melhor desempenho (menor erro quadrático médio) nas estimativas. O ajuste desses parâmetros é definido de forma empírica até que o erro desejado (solução ótima) seja alcançado para o problema estudado. O desempenho da ANFIS está diretamente relacionado aos parâmetros de ajuste, quantidade de regras e variáveis de entrada do sistema (Lezanski, 2001).

O treinamento adotado nas estimativas com a ANFIS foi realizado com o algoritmo de clusterização subtrativa implementado pela função *genfis2*, a qual gera uma estrutura FIS (*Fuzzy Inference System*) do tipo Sugeno. A utilização do método

de clusterização subtrativa também contribuiu para um treinamento com baixo esforço computacional, comparado ao treinamento realizado pela função *genfis1* que demanda de um crescente custo computacional na medida que se aumenta a quantidade de variáveis de entrada. Na função *genfis2* usa como parâmetro de ajuste (*radii*) o qual é um vetor que especifica o alcance de influência de um centro de cluster em cada uma das dimensões de dados e o número de épocas de iteração, o qual é usado como critério de parada do treinamento.

Após o processo de treinamento, as ANFIS com os melhores resultados classificados pelo menor índice do *EQM* foram organizadas na Tabela 2.7.

Tabela 2.7 - Arquiteturas para as estimativas com o sistema híbrido ANFIS

(A)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima	
									$Kd_p^h = f (Kd_H^h)$	
									Épocas	<i>radii</i>
ME	Kd_H^h						Kd_p^h		200	
M1	Kd_H^h							2,21E-03		0,9
M2	Kd_H^h	$H0_H^h$						1,27E-03		0,5
M3	Kd_H^h	$H0_H^h$	Θ_z					3,79E-04		0,7
M4	Kd_H^h	$H0_H^h$	Θ_z	δ				3,49E-04		0,7
M5	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar			3,48E-04		0,9
M6	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		3,40E-04		0,7
M7	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		3,40E-04		0,9
M8	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		3,48E-04		0,9


(B)

Modelos	Variáveis de Entrada						Variável Estimada	EQM	Solução Ótima	
									$Kd_p^h = f (Kt_H^h)$	
									Épocas	<i>radii</i>
ME	Kt_H^h						Kd_p^h		200	
M1	Kt_H^h							2,02E-02		0,6
M2	Kt_H^h	$H0_H^h$						1,14E-02		0,4
M3	Kt_H^h	$H0_H^h$	Θ_z					1,09E-02		0,6
M4	Kt_H^h	$H0_H^h$	Θ_z	δ				1,08E-02		0,7
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar			1,07E-02		0,9
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr		1,06E-02		0,9
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh		1,05E-02		0,8
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb		8,66E-03		0,9


Os gráficos da Figura 2.15 A e B mostram uma avaliação do treinamento considerando o índice *EQM* em função das combinações de variáveis utilizadas nos treinamentos a partir dos parâmetros de treinamentos da Tabela 2.7 A e B respectivamente. Os resultados mostram que os conjuntos e combinações de variáveis de entrada foram relevantes para o desempenho no treinamento da ANFIS.

Figura 2.15 - Curva do EQM do Treinamento em função das combinações testadas

(A)




(B)



2.3.7 Base de dados de validação

Para validação dos modelos treinados, uma base contendo 12 meses de dados das irradiações horária denominada de Anos Atípicos (AAT) foi separada a partir da base total de dados (Figura 2.16A), por meio de análises estatísticas comparando para cada mês do ano os valores da irradiação média horária entre o intervalo de variação do desvio padrão da média total dos anos com o valor da irradiação média de cada ano. Um exemplo dessa classificação pode ser visualizado na Figura 2.16B.

Figura 2.16 - A) Exemplo da classificação dos anos atípicos para a base de validação B) Separação da base de treinamento e validação com Anos Atípicos (AAT) de março de 1998 a agosto de 2001



Fonte: Elaborada pelo Autor

O critério utilizado é similar ao processo de seleção do ano meteorológico típico definido pela *World Meteorological Organization* (WMO, 1981). Os resultados da classificação foram apresentados na Tabela 2.8.

Tabela 2.8 - Ano Atípico (AAT) obtido na base de dados total (março de 1998 a agosto de 2001).

	Ano / Mês - Atípico (AAT)											
	JAN	FEV	MAR	ABR	MAI	JUN	JUL	AGO	SET	OUT	NOV	DEZ
Global	1999	1999	2000	1998	2001	1999	2001	1998	1998	2000	2000	2000
Difusa	1999	2001	2000	2000	2001	1998	2000	2001	1999	1999	2000	2000

2.3.8 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 *Relative Mean Bias Error* (MBE(%)), *Relative Root Mean Square Error* (RMSE(%)), o coeficiente de correlação (r), o coeficiente de determinação (R^2) (Santos et al., 2016; Escobedo et al. 2011; Willmott, 1981).

$$MBE(\%) = 100. \frac{\sum_{i=1}^X (E-M)}{X} \quad (2.4)$$

$$RMSE(\%) = 100. \frac{\left[\frac{\sum_{i=1}^x (E-M)^2}{x} \right]^{\frac{1}{2}}}{\bar{X}} \quad (2.5)$$

$$r = \frac{\sum_{i=1}^x (M - \bar{M}) \cdot (E - \bar{E})}{\sqrt{\sum_{i=1}^x (M - \bar{M})^2 \cdot \sum_{i=1}^x (E - \bar{E})^2}} \quad (2.6)$$

$$R^2 = \frac{\sum_{i=1}^x (M - \bar{M})^2 \cdot \sum_{i=1}^x (E - \bar{E})^2}{\sum_{i=1}^x (M - \bar{M})^2} \quad (2.7)$$

Onde, E são os valores estimados; M os valores medidos; $\bar{X} = \left(\frac{1}{x} \sum_{i=1}^x M \right)$ o valor médio das medidas e x o número de observações.

Os valores de MBE(%) representam o desvio das médias e provê informações quanto a desempenho dos modelos, quando positivos indicam superestimava e quando negativos indicam subestimativa. O RMSE(%) determina a precisão das estimativas em função dos dados medidos, também se observa nesse índice o grau de espalhamento obtido na correlação entre os valores estimados e medidos. O coeficiente de correlação r permite verificar o quanto o valor medido se aproxima do valor estimado, ou seja, a correlação existente entre eles. O R^2 permite identificar a relação linear entre os valores medidos e estimados; seus valores variam de 0 a 1 e quanto mais próximo de 1 melhor será o ajuste do modelo.

Estes indicativos permitem identificar critérios como subestimativas ou superestimavas, o percentual de erro, espalhamento e correlação entre os valores medidos e estimados. Com base nesses critérios, é possível fazer análises entre as modelos e definir qual apresenta o melhor ajuste para generalizar o problema de estimar Kd_{β}^h , pois qualquer erro na estimativa de recursos solares pode ter um efeito negativo sobre a simulação de projetos de energia solar (Gueymard:Ruiz-Arias, 2015).

2.4 RESULTADOS E DISCUSSÕES


Neste estudo as redes neurais artificiais (RNA) e o sistema híbrido (ANFIS) foram utilizados para estimar a fração da irradiação difusa (Kd_{β}^h) incidentes em uma superfície com inclinação de 22,85° voltada para o norte a partir das medidas das irradiações global e difusa incidentes em superfície horizontal. Uma análise comparativa do desempenho desses modelos foi realizada com os resultados obtidos

com o modelo estatísticos (ME) através dos índices estatísticos obtidos com os métodos de estimativas utilizados.

2.4.1 Equações de estimativas do modelo estatístico

As Figuras 2.17 A e B mostram as correlações entre as frações Kd_H^h e Kd_β^h e entre Kd_H^h e Kt_β^h com suas respectivas curvas de regressão.

Figura 2.17 - Correlações entre (A) fração medida da difusa no plano horizontal (Kd_H) e inclinado (Kd_β). (B) fração da global na superfície horizontal (Kt_H) e a fração da difusa no plano inclinado (Kd_β)



As equações obtidas nas correlações é linear para a estimativa de $[Kd_\beta^h = f(Kd_H^h)]$ e polinomial de 3ª ordem para a estimativa de $[Kd_\beta^h = f(Kt_H^h)]$, e estão apresentadas na Tabela 2.9

Tabela 2.9 - Modelos obtidos com as correlações das Figuras 2.17

Figura 2.8	Estimativa	Regressão	Modelo	R ²	Equação
A	$Kd_\beta^h = f(Kd_H^h)$	Linear	$Kd_\beta^h = 0,9852 (Kd_H^h)$	0,96	2.8
B	$Kd_\beta^h = f(Kt_H^h)$	Polinomial 3ª Ordem	$Kd_\beta^h = 0,91 + 1,00 Kt_H - 5,51 Kt_H^2 + 3,80 Kt_H^3$	0,75	2.9

A correlação da Figura 2.17A resultou em um coeficiente de determinação de $R^2 = 0,96$ mostrando que os valores estão bem correlacionados estatisticamente. Na Figura 2.17B a correlação teve ajuste polinomial de 3ª ordem entre Kt_H^h e Kd_β^h com coeficiente de determinação $R^2 = 0,75$, valor esperado na partição horária, pois em partições temporais menores existe maior sensibilidade às variações instantâneas ocorridas na atmosfera (Dal Pai, 2005).

2.4.1.1 Validação das equações de estimativas


A Tabela 2.10 mostra os índices de desempenho estatísticos obtidos com a validação na base de dados dos Anos Atípicos (AAT) dos valores estimados pelas Equações 2.8 e 2.9.

Tabela 2.10: Indicativos de desempenho nas estimativas pelo modelo estatístico (ME)

Figura 1.8	MODELO	AAT (ANOS ATÍPICOS)				
		RMSE (MJ m ⁻²)	RMSE (%)	MBE (MJ m ⁻²)	MBE (%)	r
A	$Kd_{\beta}^h = f(Kd_H^h)$	0,049	12,42	-0,014	-3,54	0,98
B	$Kd_{\beta}^h = f(Kt_H^h)$	0,153	35,35	-0,023	-5,32	0,86

Os gráficos das Figuras 2.18 A e B mostram a correlação entre os valores medidos e estimados pelas Equações 2.8 e 2.9, onde na Figura 2.18 A apresenta a correlação entre os valores medidos de Kd_H^h e os valores estimados de Kd_{β}^h e na Figuras 2.18 B apresenta-se a correlação entre os valores medidos de Kt_H^h e o estimado de Kd_{β}^h .

Figura 2.18 - Correlações entre fração da difusa no plano inclinado (Kd_{β}) medido e estimado



No gráfico da Figura 2.18A, o índice de desempenho mostra que os valores estimados são subestimados em 0.014% (MBE=-0,014) e apresenta uma boa concordância linear com a reta referência (1:1). O índice de precisão obtido foi de RMSE=12,42% e o resultado para o coeficiente de correlação $r=0,98$, muito próximo

de 1, mostra que existe uma boa correlação entre os valores medidos e estimados e que o modelo obtido da Equação 2.8 pode estimar Kd_{β}^h .

O gráfico da Figura 1.18 B a correlação mostra que não existe uma concordância da curva do ajuste com a reta de referência (1:1) indicando que a Equação 2.9 subestima as estimativas em 5,32%, conforme mostra o resultado do índice de desempenho MBE=-5,32%. O coeficiente de correlação $r=0,86$ indica que existe boa correlação entre os valores medidos e estimados pela Equação 2.9. O índice de espalhamento RMSE=35,35% para a Equação 2.9 apresentou valor elevado e pode ser explicado pela partição de tempo utilizada (horária) e pela variação temporal causada por nuvens e aerossóis, pois nessas condições torna-se mais complexo gerar modelos de estimativas (Gueymard, 2010). Os índices obtidos com a estimativa da difusa na superfície inclinada (Kd_{β}^h) a partir das medidas da global na superfície horizontal (Kt_H^h), mostram que o modelo obtido da Equação 2.9 pode estimar Kd_{β}^h , considerando a base horária.

A Tabela 2.12 apresenta os valores estatísticos de modelos encontrados na literatura para estimativas da irradiação difusa na superfície inclinada.

Tabela 2.12 - Indicativos estatísticos e suas localidades na partição horária para Kd_{β}

Autores	Localidades	Latitudes	Inclinação	MBE		RMSE		r
		(°)		(MJ m ⁻²)	(%)	(MJ m ⁻²)	(%)	
Perez et al. (1986)	Genebra (Suíça)		30°		-4,50		9,70	
			45°		-2,90		9,20	
			60°		0,00		11,40	
Perez et al. (1986)	Albany (Estados Unidos)	42°42' N	43°		-5,37		8,54	
Perez et al. (1986)	Capentras (França)	44°05' N	45°		-8,02		11,91	
Kambezidis, Psiloglou e Synodinou (1990)	Atenas (Grécia)	37°58' N	50°		-2,63		8,49	
Reindl, Beckman e Duffie (1990)	2 (Estados Unidos)	42,7° - 29,5° N	90°		6,38		12,98	
Utrillas et al. (1991)	Valência (Espanha)		90°		-13,70		18,30	
Vartiainen (2000)	Turku (Finlândia)	60°27' N	30°		-7,20		12,60	
			60°		-8,70		16,80	
			90°		-12,50		22,60	
Bilbao et al. (2003)	13 (Espanha)				-3,09		11,97	
Norton et al. (2006)	Ajaccio (França)	41°55' N	45°		-8,90		12,77	
			60°		-6,46		12,67	
Noorian et al. (2006)	Karaj/Iran	35°55' N	45°				10,16 - 54,89	
			40°				30,71 - 63,63	
Evseev & Kudish (2009)	Beer Sheva (Israel)	31°15' N	40° S		-4,14		11,74	
Ruiz-Arias et al. (2010)	21 (EUA e Europa)				(-15) - 15		25 - 35	
Adilson Pacheco et al. (2012)	Botucatu/SP	22°53' S	22,85 Norte	(-0,164) - 0,118	(-23,21) - 24,10	0,213 - 0,623	39,31 - 100,21	
Adilson Pacheco et al. (2013)	Botucatu/SP	22°53' S	22,85 Norte	0,07		0,13		
Adilson Pacheco et al. (2014)	Botucatu/SP	22°53' S	22,85 Norte	(-0,0198) - 0,0722		0,1089 - 0,1302		
Demain et al. (2017)	Uccle (Bélgica)	50,79° Norte			(-10,34) - 5,89		5,29 - 14,24	
ME Proposto - $Kd_{\beta}^h = f (Kt_H^h)$	Botucatu/SP	22°53' S	22,85 Norte	-0,023	-5,32	0,153	35,35	0,86
ME Proposto - $Kd_{\beta}^h = f (Kd_H^h)$	Botucatu/SP	22°53' S	22,85 Norte	-0,014	-3,55	0,050	12,43	0,98

2.4.2 Redes Neurais Artificiais e ANFIS

Após os treinamentos e validações das RNA e ANFIS, os resultados foram organizados e apresentados na Tabela 2.13.

Tabela 2.13 - Indicadores das Redes Neurais e ANFIS para os anos atípicos (AAT).

(A)

ESTIMATIVAS DE $Kd_p^h = f (Kd_H^h)$																				
Variáveis de Entrada						ME			MLP			RBF			GRNN			ANFIS		
						RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r
ME/M1	Kd_H^h					12,43	-3,55	0,98	12,00	-1,69	0,98	12,01	-1,78	0,98	12,06	-1,76	0,98	12,00	-1,75	0,98
M2	Kd_H^h	HO_H^h							9,12	-0,94	0,99	8,98	-0,81	0,99	10,86	-1,65	0,99	8,91	-0,92	0,99
M3	Kd_H^h	HO_H^h	Θ_z						10,79	5,39	0,99	11,88	6,05	0,98	12,35	5,68	0,98	11,42	5,67	0,99
M4	Kd_H^h	HO_H^h	Θ_z	δ					4,40	0,52	0,99	11,01	5,64	0,99	29,00	-1,15	0,90	4,40	-0,41	0,99
M5	Kd_H^h	HO_H^h	Θ_z	δ	Tar				4,09	-0,17	0,99	9,39	3,87	0,99	65,17	-5,73	0,25	4,41	-1,10	0,99
M6	Kd_H^h	HO_H^h	Θ_z	δ	Tar	mr			4,07	-0,33	0,99	9,14	3,92	0,99	65,14	-5,60	0,25	4,84	-0,75	0,99
M7	Kd_H^h	HO_H^h	Θ_z	δ	Tar	Rh			4,12	0,23	0,99	9,24	2,00	0,99	65,03	-0,69	0,26	4,15	-0,19	0,99
M8	Kd_H^h	HO_H^h	Θ_z	δ	Tar	Neb			4,03	-0,29	0,99	5,84	-0,20	0,99	46,17	2,72	0,73	4,15	-0,63	0,99

(B)

ESTIMATIVAS DE $Kd_p^h = f (Kt_H^h)$																		
Variáveis de Entrada			ME			MLP			RBF			GRNN			ANFIS			
			RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	RMSE(%)	MBE(%)	r	
ME/M1	Kt_H^h		35,35	-5,32	0,86	35,36	-5,14	0,85	35,41	-5,36	0,85	35,54	-5,53	0,85	35,50	-5,43	0,85	
M2	Kt_H^h	$H0_H^h$				25,50	-3,32	0,93	25,44	-3,48	0,93	29,39	-5,73	0,90	25,41	-3,21	0,93	
M3	Kt_H^h	$H0_H^h$	Θ_z			25,49	0,17	0,93	32,47	-5,14	0,88	30,52	1,66	0,89	26,35	0,99	0,92	
M4	Kt_H^h	$H0_H^h$	Θ_z	δ		26,49	-9,37	0,92	43,82	-10,15	0,76	44,71	-7,28	0,75	26,80	-8,27	0,92	
M5	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar		25,01	-4,63	0,93	33,08	-7,88	0,87	67,79	-4,59	0,00	27,60	-3,68	0,91
M6	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	mr	25,06	-3,99	0,93	68,49	10,82	0,00	67,79	-4,59	0,00	26,99	1,24	0,92
M7	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Rh	24,68	-3,15	0,93	39,56	-19,04	0,81	67,79	-4,59	0,00	27,24	-4,43	0,92
M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	21,70	-3,32	0,95	35,08	6,67	0,85	51,12	2,98	0,65	23,08	0,15	0,94

A análise dos dados das estimativas da fração transmitida da difusa no plano inclinado (Kd_{β}^h) a partir das medidas da difusa no plano horizontal (Tabela 2.13A) mostra que nas técnicas MLP, RBF e ANFIS os índices de correlação (r) atingiram valores elevados variando de 0,98 a 0,99, porém nas estimativas com a GRNN os índices de correlação tiveram variações de 0,25 a 0,99, mostrando que nesta técnica as estimativas nas combinações M5, M6 e M7 entre os dados medidos e estimados. Os índices de precisão RMSE apresentaram resultados entre 4,00% e 12,00% para a MLP, entre 5,84% e 12,00% para a RBF, entre 10,85% e 65,17% para a GRNN e entre 4,09% e 11,99% para a ANFIS. Os índices de exatidão MBE(%) mostram que a maioria das estimativas com as combinações realizadas em todas as técnicas foram subestimadas.

Para as estimativas da fração transmitida da difusa no plano inclinado (Kd_{β}^h) a partir das medidas da global no plano horizontal (Tabela 2.13 B), os índices de correlação (r) mostram que em todas as técnicas de aprendizado aplicadas, os índices das correlações apresentaram valores elevados com variação de 0,85 a 0,95 na MLP, de 0,85 a 0,93 na RBF e de 0,85 a 0,94 na ANFIS. Na GRNN os valores de (r) variaram de 0,00 a 0,90 o que indica que as estimativas realizadas com as combinações M5, M6 e M7 não se correlacionaram com as medidas. Os índices de precisão RMSE apresentaram resultados variando entre 21,70% e 35,36% para a MLP, entre 25,44% e 35,41% para a RBF, entre 29,39% e 35,54% para a GRNN e 23,08% e 35,50% para a ANFIS. Os valores dos índices de exatidão MBE mostram que as estimativas com a MLP subestimam as medidas com valores entre -3,15% e -9,37% e superestimam apenas com a combinação M3=0,17%. As estimativas com a rede RBF resultaram em valores subestimados com valores entre -3,48% e -19,04% e valores superestimados nas combinações M6=10,82% e M8=6,67%. A rede GRNN superestimou as medidas obtidas com as estimativas das combinações M3=1,66% e M8=2,98% e subestimou nas demais combinações com valores entre M6=-4,59% e M2=-5,73. As estimativas realizadas com a ANFIS apresentaram resultados superestimados nas combinações M3=0,99%, M6=1,24% e M8=0,15% e subestimados nas demais combinações com valores entre M2=-3,21% e M1=-5,43%.


Tabela 2.14 - Melhores Indicadores das Redes Neurais e ANFIS para os anos atípicos (AAT).


MODELO	COMBINAÇÕES							AAT (ANOS ATÍPICOS)		
A) $Kd_{\beta}^h = f (Kd_H^h)$								RMSE(%)	MBE(%)	r
ME	M1	Kd_H^h						12,43	-3,55	0,98
MLP	M8	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	4,03	-0,29	0,99
RBF	M8	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	5,84	-0,20	0,99
GRNN	M2	Kd_H^h	$H0_H^h$					10,86	-1,65	0,99
ANFIS	M8	Kd_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	4,15	-0,63	0,99
B) $Kd_{\beta}^h = f (Kt_H^h)$								RMSE(%)	MBE(%)	r
ME	M1	Kt_H^h						35,35	-5,32	0,86
MLP	M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	21,70	-3,32	0,95
RBF	M2	Kt_H^h	$H0_H^h$					25,44	-3,48	0,93
GRNN	M2	Kt_H^h	$H0_H^h$					29,39	-5,73	0,90
ANFIS	M8	Kt_H^h	$H0_H^h$	Θ_z	δ	Tar	Neb	23,08	0,15	0,94

As Tabelas 2.14 A e B destacam os melhores modelos de estimativas (classificados pelo RMSE) usando as técnicas de RNA e ANFIS, considerando o quanto as variáveis de entrada adotadas foram relevantes para estimar Kd_{β}^h , apresentando consideráveis melhorias em relação ao modelo clássico (ME). Nas estimativas da difusa na superfície inclinada (Kd_{β}^h) com base nas medidas da difusa na superfície horizontal (Tabela 1.14 A) redução comparada ao modelo estatístico (ME) foi de 67% para a MLP e ANFIS, 52% RBF e 13% para a GRNN.

Nas estimativas da fração da difusa na superfície inclinada (Kd_{β}^h) com base nas medidas da global na superfície horizontal (Tabela 1.14 B) se observa nos melhores modelos de RNA uma redução no índice RMSE de 38,6% e 44,4% respectivamente, comparado ao modelo estatístico (ME).

Figura 2.19 - Correlações entre valores medidos e estimados de (Kd_β) pelas técnicas MLP, RBF, GRNN e ANFIS







Os gráficos das Figuras 2.19A mostram que as medidas de Kd_{β}^h estão bem correlacionadas para os modelos apresentados na Tabela 2.14A distribuição dos valores estimados e dos valores medidos, apresentam boa concordância linear com as retas de referência próximas ao ideal (1:1), o que mostra que Kd_{β}^h medido e estimado estão bem ajustados estatisticamente em todas as redes e ANFIS com coeficientes de correlação de $r=0,99$. Os valores de MBE mostram que as técnicas de RNA e ANFIS tendem a subestimar as estimativas com valores entre 0,20% e 1,65%. O índice de precisão RMSE apresentou o pior resultado com a técnica de rede GRNN ($RMSE_{GRNN}=10,86\%$). tendo um espalhamento mais irregular. Contudo as técnicas MLP, RBF e ANFIS podem ser utilizadas para estimar Kd_{β}^h com indicadores estatisticamente melhores que os obtidos com o modelo estatístico.

No gráfico da Figura 2.19 B, as correlações entre os valores medidos e estimados com as técnicas de rede MLP, RBF, GRNN e o sistema híbrido ANFIS, mostram que para a estimativa da fração da difusa na superfície inclinada Kd_{β}^h com base nas medidas da global na superfície horizontal os coeficientes de correlação entre $r_{GRNN}=0,90$ e $r_{MLP}=0,95$, indicam que existe boa correlação entre os valores medidos e estimados pelas combinações de variáveis utilizadas nos treinos. Os índices estatísticos da Tabela 2.14B, mostram que de acordo com os valores de MBE as técnicas de RNA tendem a subestimar as estimativas com valores entre 3,32% e 5,73% e a ANFIS tendem a superestimar em 0,15% as estimativas. O índice de precisão RMSE apresentou o pior resultado com a técnica de rede GRNN ($RMSE_{GRNN}=29,39\%$). Os resultados obtidos dos índices com as estimativas da fração da difusa na superfície inclinada (Kd_{β}^h) a partir das medidas da global na superfície

horizontal, mostram que os modelos de rede adotados podem estimar Kt_{β}^h , considerando a base horária.

Figura 2.20 - Gráfico de dispersão das estimativas: (A) Kd_{β} em função de Kd_H medido (B) Kd_{β} em função de Kt_H medido.





Os gráficos da Figura 2.20 mostram as curvas de dispersão das estimativas comparadas aos espalhamentos da base de dados de estimativa e validação. Destaca-se claramente que em todas as estimativas que os melhores resultados foram obtidos com as técnicas MLP e ANFIS, as quais apresentaram um espalhamento mais uniforme com boa concordância entre os valores medidos e estimados. A técnica RBF apresentou um bom espalhamento para a estimativa $[Kd_\beta^h = f(Kd_H^h)]$ com os valores estimados próximos aos medidos, porém na estimativa $[Kd_\beta^h = f(Kt_H^h)]$ a dispersão dos valores estimados não tivera concordância com os valores medidos, isso devido ao número de variáveis envolvidas no treinamento. A técnica GRNN apresentou um comportamento muito irregular no espalhamento, onde se observa claramente a não concordância dos valores estimados com os valores medidos também em função do número de variáveis utilizadas nos melhores treinamentos.

Analisando a Tabela 2.14 observa-se que nas técnicas de aprendizado de máquinas (TAM) utilizadas, os melhores resultados foram obtidos nas combinações que tinham presentes as variáveis meteorológicas nebulosidade e temperatura do ar. Essa condição ocorreu nas estimativas de $[Kd_\beta^h = f(Kd_H^h)]$ e $[Kd_\beta^h = f(Kt_H^h)]$ com as técnicas MLP e ANFIS, as quais apresentaram os melhores índices e uma dispersão mais próxima dos valores medidos. Esse resultado indica que somente as variáveis Kd_H^h e Kt_H^h não explicam o comportamento de Kd_β^h tendo em vista que o espalhamento se torna mais coincidente com a inclusão de outras variáveis.

Com os resultados apresentados é possível identificar que dentre as técnicas testadas neste estudo, a MLP e a ANFIS apresentaram os melhores índices

estatísticos e um espalhamento das estimativas mais ajustado aos dados medidos, o que as caracterizam como mais adequadas para estimar as frações difusa em superfície inclinada a partir das medidas da radiação difusa e global na superfície horizontal, com dados de Botucatu-SP/Brasil.

2.5 CONCLUSÕES

Considerando os resultados obtidos com os modelos de estimativa estatísticos (ME) com dados do município de Botucatu/SP pôde-se observar que os modelos das Equações 2.8 e 2.9 obtidas por meio de regressão apresentaram bons resultados e podem estimar a irradiação difusa na superfície com inclinação de $22,85^\circ$ (Kd_{β^h}) para Botucatu com coeficientes de determinação igual a $R^2=0,96$ a partir das medidas da irradiação difusa na horizontal e igual a $R^2=0,75$ a partir das medidas da irradiação global na horizontal.

As arquiteturas de RNA e ANFIS de forma geral apresentaram resultados estatísticos melhores comparados aos resultados obtidos com o modelo estatístico (ME). Essa condição é esperada, considerando uma série de fatores envolvidos para o treinamento das redes, tais como a quantidade de variáveis de entrada e as possibilidades de ajustamento através da parametrização. Porém as técnicas demandam um trabalho considerável para determinação das melhores combinações e definição dos parâmetros de ajustamento, e por esse motivo uma comparação estatística entre o ME e as técnicas de aprendizado de máquina não é adequada, mas pode ser feita apenas como referência dos resultados obtidos.

Pode-se concluir com base nos resultados obtidos que as técnicas de aprendizado de máquina adotadas que a rede MLP consegue estimar a irradiação difusa incidente em superfície inclinada a partir de combinações de variáveis medidas e calculadas com base na irradiação difusa horizontal com $RMSE < 5\%$, o que a qualifica como a técnica mais adequada para estimativa dessa variável utilizando a base de dados de Botucatu. O resultado é superior ao obtido com os modelos estatísticos de $RMSE = 12,43\%$.

Da mesma forma o estudo conclui também que a MLP também consegue índices melhores de desempenho nas estimativas de irradiação difusa incidente em superfície inclinada a partir de combinações de variáveis medidas e calculadas com base na irradiação global horizontal com $RMSE = 21,7\%$ comparado ao obtido pelo

método estatístico de RMSE=35,35%. Esses resultados mostram que as estimativas da irradiação difusa na superfície inclinada podem ser realizadas a partir das medidas da irradiação global na horizontal quando as medidas da irradiação difusa não estiverem disponíveis.

REFERÊNCIAS

Alrubaih, M.s. et al. Research and development on aspects of daylighting fundamentals. *Renewable And Sustainable Energy Reviews*, [s.l.], v. 21, p.494-505, maio 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2012.12.057>.

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.

Beruski, Gustavo Castilho; PEREIRA, André Belmont; SENTELHAS, Paulo Cesar. Desempenho de diferentes modelos de estimativa da radiação solar global em Ponta Grossa, PR. **Revista Brasileira de Meteorologia**, [s.l.], v. 30, n. 2, p.205-213, jun. 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0102-778620130097>.

Bosch, J.I.; López, G.; Batlles, F.j.. Daily solar irradiation estimation over a mountainous area using artificial neural networks. *Renewable Energy*, [s.l.], v. 33, n. 7, p.1622-1628, jul. 2008. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2007.09.012>.

B. Mulgrew, “Applying Radial Basis Functions”, *IEEE SHGnal Processing Magazine*, pp 50-65, 1996.

Casaroli, Derblai et al. RADIAÇÃO SOLAR E ASPECTOS FISIOLÓGICOS NA CULTURA DE SOJA - UMA REVISÃO. *Revista da Fzva, Uruguaiana*, v. 14, n. 2, p.102-120, jan. 2007.

Dal Pai, A. Anisotropia da irradiância solar difusa medida pelo método de sombreamento Melo-Escobedo: fatores de correção anisotrópicos e modelos de estimativa. 2005. 87f. Tese (Doutorado em Agronomia – Energia na Agricultura), Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2005.

Demain, Colienne; JOURNÉE, Michel; BERTRAND, Cédric. Evaluation of different models to estimate the global solar radiation on inclined surfaces. **Renewable Energy**, [s.l.], v. 50, p.710-721, fev. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2012.07.031>.

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.

Elminir, Hamdy K.; AZZAM, Yosry A.; YOUNES, Farag I.. Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. *Energy*, [s.l.], v. 32, n. 8, p.1513-1523, ago. 2007. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2006.10.010>.

Escobedo, J. F.; Gomes, E. N.; Oliveira, A. P.; Soares, J.. Ratios of UV, PAR and NIR components to global solar radiation measured at Botucatu site in Brazil. *Renewable Energy*, v.36, p.169-178, 2011.

Escobedo, J. F.; Teramoto, E. T.; Oliveira, A. P. et al. Equações de estimativa das frações solar direta (kdh) e difusa (kd) em função do índice de claridade (kt) e razão de insolação (n/N), *Avances en y Medio Ambiente*, Vol. 16, 2012.

El-Sebaii, A.a. et al. Global, direct and diffuse solar radiation on horizontal and tilted surfaces in Jeddah, Saudi Arabia. **Applied Energy**, [s.l.], v. 87, n. 2, p.568-576, fev. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.apenergy.2009.06.032>.

Finocchio, Marco Antonio Ferreira. NOÇÕES DE REDES NEURAIS ARTIFICIAIS. 2014. 29 f. - Curso de Engenharia Elétrica, Laboratório de Segurança, Iluminação e Eficiência Energética, Universidade Tecnológica Federal do Paraná, Cornélio Procopio, 2014.

Ghosal, M.k. et al. Modeling and comparative thermal performance of ground air collector and earth air heat exchanger for heating of greenhouse. *Energy And Buildings*, [s.l.], v. 37, n. 6, p.613-621, jun. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.enbuild.2004.09.004>.

Gueymard, C. A.; Ruiz-Arias, J. A. Extensive worldwide validation and climate sensitivity analysis of direct irradiance predictions from 1-min global irradiance. **Sol. Energy** (2015), <http://dx.doi.org/10.1016/j.solener.2015.10.010>.

Haykin, S. (2001) *Redes Neurais Princípios e Prática*. 2ª. ed, Bookman Porto Alegre-RS.

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.

Kamali, Gh. A.; Moradi, I.; Khalili, A.. Estimating solar radiation on tilted surfaces with various orientations: a study case in Karaj (Iran). *Theoretical And Applied Climatology*,

[s.l.], v. 84, n. 4, p.235-241, 28 set. 2005. Springer Nature. <http://dx.doi.org/10.1007/s00704-005-0171-y>.

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.

Lezanski, P. An intellHGent system for grinding wheel condition monitoring. *Journal of Materials Processing Technology*, volume 109, 2001, pp. 258-263, 2001.

Lam, J. C.; Wan, K. K. W.; Yang, L. Solar radiation modeling using ANNs for different climates in China. *EnergyConversion & Management*, v.49, 1080-1090, 2008b.

LI, Danny H.w. et al. Determining solar irradiance on inclined planes from classified CIE (International Commission on Illumination) standard skies. *Energy*, [s.l.], v. 101, p.462-470, abr. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2016.02.054>.

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

Mukherjee, I.; Routroy, S. Comparing the performance of neural networks developed by using Levenberg–Marquardt and Quasi-Newton with the gradiente descent algorithm for modelling a multiple response grinding process. *Expert Systems with Applications*, v. 39, n. 3, p. 2397 – 2407, 2012.

M. Hagan e M. Menhaj; “Training feedforward networks with the Marquardt algorithm”; *IEEE Transaction on neural networks*; 989-993; Novembro; 1994.

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. *Bullentin 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 - Sciencedirect: *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.

Pandey, C.k.; Katiyar, A.k.. Hourly solar radiation on inclined surfaces. *Sustainable Energy Technologies And Assessments*, [s.l.], v. 6, p.86-92, jun. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.seta.2014.01.007>.

Pezzopane, E.M.; Ribeiro, A.; Reis, G.G.; Reis, M.G.F. Balanço de radiação em uma floresta em função da Declividade e Orientação das encostas. In: *Congresso Brasileiro de Meteorologia*, 11, 2000, Rio de Janeiro - RJ.

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; Zeghmami, 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.

Rossi, T. J. Equações de Estimativas das Irradiações e Frações: Global, Difusa e Direta Infravermelha Em Botucatu/ Sp/Brasil. Dissertação (Mestrado em Agronomia – Energia na Agricultura), Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2017.

Rahoma, W. A. et al. Application of Neuro-Fuzzy Techniques for Solar Radiation. *Journal Of Computer Science: Science Publications*, [s.i.], v. 7, n. 10, p.1-7, jan. 2011.

Sumithira, T. R.; Kumar, A. Nirmal. Prediction of monthly global solar radiation using adaptive neuro fuzzy inference system (ANFIS) technique over the State of Tamilnadu (India): a comparative study. *Applied Solar Energy*, [s.l.], v. 48, n. 2, p.140-145, abr. 2012. Allerton Press. <http://dx.doi.org/10.3103/s0003701x1202020x>.

Silva, Roberta A. e et al. Estudo da variabilidade da radiação solar no Nordeste do Brasil. *Revista Brasileira de Engenharia Agrícola e Ambiental*, Campina Grande, v. 14, n. 5, p.501-509, 5 nov. 2009.

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. 2004.

Souza, A.P. ; Escobedo, J. F. ; DAL PAI, A. ; GOMES, E. N. . Estimativas das componentes da irradiação solar incidentes em superfícies inclinadas baseadas na irradiação global horizontal. *Revista Brasileira de Engenharia Agrícola e Ambiental (Impresso)* , v. 15, p. 277-288, 2011.

Souza, J. L.; Lyra, G. B.; Santos, C. M. et al. Empirical models of daily and monthly global solar irradiation using sunshine duration for Alagoas State, Northeastern Brazil. *Sustainable Energy Technologies and Assessment*, v. 14, p. 35-35, 2016.

Souza, Adilson P. de et al. Annual evolution of global, direct and diffuse radiation and fractions in tilted surfaces. *Engenharia Agrícola*, [s.l.], v. 32, n. 2, p.247-260, abr. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-69162012000200005>.

Souza, A.p. et al. Estimativas da radiação global incidente em superfícies inclinadas com base na razão de insolação. *Revista Brasileira de Ciências Agrárias - Brazilian Journal Of Agricultural Sciences*, [s.l.], v. 8, n. 3, p.483-491, 21 set. 2013. *Revista Brasileira de Ciencias Agrarias*. <http://dx.doi.org/10.5039/agraria.v8i3a1894>.

Souza, A.P. ; Escobedo, J. F. ; DAL PAI, A. ; GOMES, E. N. . Estimativa da irradiação 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.

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.

Simon Haykin. *Neural Networks and Learning Machines*. 3ª ed.. New York: Prentice Hall, 2008.

Stone, R.J.. Improved statistical procedure for the evaluation of solar radiation estimation models. *Solar Energy*, vol. 51,n o4, p. 289 – 291, 1993.

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.

Stone, R.J.. Improved statistical procedure for the evaluation of solar radiation estimation models. **Solar Energy**, vol. 51,n °4, p. 289 – 291, 1993.

Tymvios, F.s. et al. Comparative study of Ångström's and artificial neural networks' methodologies in estimating global solar radiation. **Solar Energy**, [s.l.], v. 78, n. 6, p.752-762, jun. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.solener.2004.09.007>.

Turco, J.E.P.; Rizzatti, G.S. Avaliação de modelo matemático para estimar a irradiação solar incidente sobre superfícies com diferentes exposições e declividades. *Engenharia Agrícola*, v.26, p.257-267, 2006.

Vats, Kanchan; TIWARI, G.n.. Energy and exergy analysis of a building integrated semitransparent photovoltaic thermal (BISPVVT) system. *Applied Energy*, [s.l.], v. 96, p.409-416, ago. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.apenergy.2012.02.079>.

Yadav, Amit Kumar; CHANDEL, S.s.. Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable And Sustainable Energy Reviews*, [s.l.], v. 33, p.772-781, maio 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2013.08.055>.

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.

Weber, Eliseu José. Estimativa e Mapeamento da Radiação Solar Incidente em Superfícies com Topografia Heterogênea na Zona de Produção Vitivinícola Serra Gaúcha. 2011. 166 f. Tese (Doutorado) - Curso de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

Willmott, C. J. On the validation of models. **Physical Geography**, vol. 2, p. 184-194, 1982.

CONSIDERAÇÕES FINAIS

O uso das Redes Neurais Artificiais (RNA) e do Sistema Híbrido (ANFIS) como técnica para realizar estimativas de variáveis da radiação solar se mostrou como uma importante solução para a generalização dos problemas propostos neste estudo.

Neste trabalho avaliou-se apenas as técnicas *Multilayer Perceptron* (MLP), *Generalized Regression Neural Network* (GRNN), *Radial Basis Functions Networks* (RBF) e *Adaptive Neuro Fuzzy Inference System* (ANFIS), considerando que estas estão mais presentes em problemas de generalização afins. Tais técnicas não se apresentam como uma solução definitiva, mas deve se observar que para as condições propostas os resultados mostram que a rede GRNN não consegue bons resultados nas estimativas, porém, a técnica de rede MLP e a ANFIS se destacam com os melhores resultados comparados aos obtidos com os modelos estatísticos utilizados e podem ser aplicadas sem restrições, desde que respeitadas as condições determinadas neste estudo. Para outras condições (outras combinações de variáveis) é importante um novo estudo de forma a garantir a eficácia das redes para realizar estimativas.

REFERÊNCIAS

- Alrubaih, M.s. et al. Research and development on aspects of daylighting fundamentals. *Renewable And Sustainable Energy Reviews*, [s.l.], v. 21, p.494-505, maio 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2012.12.057>.
- Beruski, Gustavo Castilho; Pereira, André Belmont; Sentelhas, Paulo Cesar. Desempenho de diferentes modelos de estimativa da radiação solar global em Ponta Grossa, PR. **Revista Brasileira de Meteorologia**, [s.l.], v. 30, n. 2, p.205-213, jun. 2015. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/0102-778620130097>.
- Casaroli, Derblai et al. RADIAÇÃO SOLAR E ASPECTOS FISIOLÓGICOS NA CULTURA DE SOJA - UMA REVISÃO. *Revista da Fzva, Uruguaiana*, v. 14, n. 2, p.102-120, jan. 2007.
- 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.
- Demain, Colienne; JOURNÉE, Michel; BERTRAND, Cédric. Evaluation of different models to estimate the global solar radiation on inclined surfaces. **Renewable Energy**, [s.l.], v. 50, p.710-721, fev. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.renene.2012.07.031>.
- Escobedo, J. F.; Gomes, E. N.; Oliveira, A. P.; Soares, J.. Ratios of UV, PAR and NIR components to global solar radiation measured at Botucatu site in Brazil. *Renewable Energy*, v.36, p.169-178, 2011.
- Escobedo, J. F.; Teramoto, E. T.; Oliveira, A. P. et al. Equações de estimativa das frações solar direta (kdh) e difusa (kd) em função do índice de claridade (kt) e razão de insolação (n/N), *Avances en y Medio Ambiente*, Vol. 16, 2012.
- El-Sebaii, A.a. et al. Global, direct and diffuse solar radiation on horizontal and tilted surfaces in Jeddah, Saudi Arabia. **Applied Energy**, [s.l.], v. 87, n. 2, p.568-576, fev. 2010. Elsevier BV. <http://dx.doi.org/10.1016/j.apenergy.2009.06.032>.
- Ghosal, M.k. et al. Modeling and comparative thermal performance of ground air collector and earth air heat exchanger for heating of greenhouse. *Energy And Buildings*, [s.l.], v. 37, n. 6, p.613-621, jun. 2005. Elsevier BV. <http://dx.doi.org/10.1016/j.enbuild.2004.09.004>.
- 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.
- 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.
- Kamali, Gh. A.; Moradi, I.; Khalili, A.. Estimating solar radiation on tilted surfaces with various orientations: a study case in Karaj (Iran). *Theoretical And Applied Climatology*,

[s.l.], v. 84, n. 4, p.235-241, 28 set. 2005. Springer Nature.
<http://dx.doi.org/10.1007/s00704-005-0171-y>.

Klucher TM. Evaluation of models to predict insolation on tilted surfaces. *Solar Energy* 1979;23(2):111e4.

Li, Danny H.w. et al. Determining solar irradiance on inclined planes from classified CIE (International Commission on Illumination) standard skies. *Energy*, [s.l.], v. 101, p.462-470, abr. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.energy.2016.02.054>.

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

Liu, B.Y.H., Jordan, R.C. The long term average performance flat plate solar energy collectors. *Solar Energy*, v.7, p.53-74, 1963.

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.

Nascimento, Paulo. (2015). Aplicação de Sistemas Inteligentes no Controle de um Sistema Atuado por Material SMA. 10.13140/RG.2.1.2046.5127.

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 - Sciencedirect: *Energy*,Bulgaria, fev. 2012.

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.

Pandey, C.k.; Katiyar, A.k.. Hourly solar radiation on inclined surfaces. *Sustainable Energy Technologies And Assessments*, [s.l.], v. 6, p.86-92, jun. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.seta.2014.01.007>.

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.

Pezzopane, E.M.; Ribeiro, A.; Reis, G.G.; Reis, M.G.F. Balanço de radiação em uma floresta em função da Declividade e Orientação das encostas. In: Congresso Brasileiro de Meteorologia, 11, 2000, Rio de Janeiro - RJ.

Souza, A.P. ; Escobedo, J. F. ; Dal Pai, A. ; Gomes, E. N. . Estimativa da irradiação 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.

Souza, A.P. ; Escobedo, J. F. ; Dal Pai, A. ; Gomes, E. N. . Estimativas das componentes da irradiação solar incidentes em superfícies inclinadas baseadas na

irradiação global horizontal. Revista Brasileira de Engenharia Agrícola e Ambiental (Impresso) , v. 15, p. 277-288, 2011.

Souza, Adilson P. de et al. Annual evolution of global, direct and diffuse radiation and fractions in tilted surfaces. Engenharia Agrícola, [s.l.], v. 32, n. 2, p.247-260, abr. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-69162012000200005>.

Souza, A.p. et al. Estimativas da radiação global incidente em superfícies inclinadas com base na razão de insolação. Revista Brasileira de Ciências Agrárias - Brazilian Journal Of Agricultural Sciences, [s.l.], v. 8, n. 3, p.483-491, 21 set. 2013. Revista Brasileira de Ciencias Agrarias. <http://dx.doi.org/10.5039/agraria.v8i3a1894>.

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. 2004.

Silva, Roberta A. e et al. Estudo da variabilidade da radiação solar no Nordeste do Brasil. Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, v. 14, n. 5, p.501-509, 5 nov. 2009.

Temps RC, Coulson KL. Solar radiation incident upon slopes of diferente orientation. Solar Energy 1977;19(2):179e84.

Turco, J.E.P.; Rizzatti, G.S. Avaliação de modelo matemático para estimar a irradiação solar incidente sobre superfícies com diferentes exposições e declividades. Engenharia Agrícola, v.26, p.257-267, 2006.

Vats, Kanchan; Tiwari, G.n.. Energy and exergy analysis of a building integrated semitransparent photovoltaic thermal (BISPVT) system. Applied Energy, [s.l.], v. 96, p.409-416, ago. 2012. Elsevier BV. <http://dx.doi.org/10.1016/j.apenergy.2012.02.079>.

Yadav, Amit Kumar; Chandel, S.s.. Solar radiation prediction using Artificial Neural Network techniques: A review. Renewable And Sustainable Energy Reviews, [s.l.], v. 33, p.772-781, maio 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2013.08.055>.

Weber, Eliseu José. Estimativa e Mapeamento da Radiação Solar Incidente em Superfícies com Topografia Heterogênea na Zona de Produção Vitivinícola Serra Gaúcha. 2011. 166 f. Tese (Doutorado) - Curso de Agronomia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

APÊNDICE A – Radiação Solar

1 Componentes da Radiação Solar


Radiação Solar pode ser definida como sendo a energia proveniente do Sol que incide sobre o planeta Terra, fenômeno que é diretamente responsável pelos fatores climáticos e meteorológicos do planeta (Dal Pai, 2014).

A análise dos elementos constituintes da radiação solar é realizada considerando duas grandezas distintas que relacionam a irradiância ou densidade de fluxo de radiação (instantânea) e a irradiação ou energia solar, conforme segue (Chaves e Escobedo, 2000).:

- A irradiância é definida como a potência incidente por unidade de área, sendo sua unidade no SI é W.m^{-2} .
- A irradiação representa a energia solar recebida por unidade de área em um determinado período, ou o valor da densidade de fluxo integrado no tempo (normalmente hora ou dia), e sua unidade no SI é J.m^{-2} , porém normalmente aplicado em MJ.m^{-2} .

A radiação solar extraterrestre, a qual percorre o espaço entre o sol e a Terra, é determinada pela constante solar $I_{sc} = 1367 \text{ W.m}^{-2}$. Ao entrar na atmosfera terrestre a radiação é atenuada, tendo sua intensidade alterada pelos processos físicos de reflexão, absorção e espalhamento, provocadas por moléculas de gases, vapor de água, poeira e outras partículas de aerossóis, e ao atingir a superfície do planeta a radiação solar recebe o nome de radiação solar global (H_g) (Iqbal, 1983).

Figura 1 – Distribuição da Radiação Solar



Fonte: Adaptado pelo Autor.

A radiação solar global (H_g) que atinge a superfície terrestre é composta pelas componentes Direta (H_b) - definida como a parcela da Global que não sofre interação com a atmosfera, atingindo uma superfície em um ângulo de incidência normal; e Difusa (H_d) - proveniente do espalhamento da Direta por gases e partículas suspensas na atmosfera (Figura 1) (Pereira et al., 2002).

Variações temporais da radiação solar são oriundas basicamente das condições de sazonalidade das radiações direta e difusa, as quais variam com as condições climáticas, geográficas e astronômicas. De forma a minimizar os efeitos geográficos e astronômicos, o comportamento das radiações é avaliado pelo uso da fração da difusa (K_d) e da transmissividade da global (K_t). Nessa técnica os efeitos climáticos são mantidos. (Iqbal, 1983).

A determinação mais adotada da transmissividade global (K_t) foi definida por Liu e Jordan (1960), a qual expressa a razão entre a radiação solar global (H_g) e a radiação incidente no topo da atmosfera (H_0). Por meio deste índice pode-se classificar o céu como nebuloso (baixos valores de K_t) e céu limpo (altos valores de K_t), além das condições intermediárias (Iqbal, 1983; Dal Pai; Escobedo, 2001; Teramoto; Escobedo, 2012).

$$K_t = \frac{H_g}{H_0} \quad (1)$$

Para determinar a fração difusa da radiação global (K_d), utiliza-se a relação que expressa a razão entre a radiação solar difusa (H_d) e a radiação solar global (H_g).

$$Kd = \frac{Hd}{Hg} \quad (2)$$

Os valores de Kt e Kd são adimensionais variam entre 0 e 1.

A determinação da irradiação no topo da atmosfera é definida na Equação (3).

$$H_0 = \frac{24}{\pi} \text{Isc. } E_0 \cdot \left[\frac{\pi}{180} \cdot \omega s \cdot (\text{sen } \delta \cdot \text{sen } \varphi) + (\cos \delta \cdot \cos \varphi \text{sen } \omega s) \right] \quad (3)$$

onde ISC é a constante solar com valor de $4.921 \text{ KJ m}^{-2} \text{ h}^{-1}$; E_0 fator de excentricidade da terra, calculada pela Equação (4); φ é a latitude local em graus; δ é a declinação solar em graus definida na Equação (6).

$$E_0 = 1,000110 + 0,034221 \cdot \cos \Gamma + 0,001280 \cdot \text{sen } \Gamma + 0,000719 \cdot \cos 2 \Gamma + 0,000077 \cdot \text{sen } 2 \Gamma \quad (4)$$

onde Γ é o ângulo diário e é definido pela Equação (5)

$$\Gamma = 2\pi \cdot \left(\frac{DJ-1}{366} \right) \quad (5)$$

$$\delta = 23,45 \cdot \text{sen} \cdot \left[\left(\frac{360}{365} \right) \cdot (DJ + 284) \right] \quad (6)$$

onde DJ é o Dia Juliano.

O ângulo zenital (θ_z) é definido pela Equação (7)


$$\cos \theta_z = [\text{sen}(\delta) \cdot \text{sen}(\varphi) + \cos(\delta) \cdot \cos(\varphi) \cdot \cos(\omega)] \quad (7)$$

1.1 Componentes da Radiação Solar Incidente em Superfícies Inclínadas

Em superfícies com inclinação de um ângulo (β) em relação à uma superfície horizontal, a irradiação solar global (H_g - MJ.m^{-2}) é determinada pela soma das irradiações direta ($H_{b\beta}$), difusa ($H_{d\beta}$) e refletida pela superfície ($H_{r\beta}$):

$$H_{g\beta} = H_{b\beta} + H_{d\beta} + H_{r\beta} \quad (8)$$

Figura 2 - Componentes da irradiação solar global em superfície inclinada



Fonte: Elaborada pelo autor.

A irradiação direta (Hb_{β}) que incide na superfície inclinada pode ser determinada pela Equação (9) que corrige a irradiação direta incidente na superfície horizontal (Hb_H), sendo $R_B = \cos(\Theta_{\beta})/\cos(\Theta_z)$. R_B é definido como um fator de correção relacionado à mudança do ângulo de incidência da radiação solar sobre a superfície com inclinação onde Θ_z é o ângulo zenital e Θ_{β} é o ângulo de incidência da radiação sobre a superfície inclinada (Iqbal, 1983).

$$Hb_{\beta} = Hb_H \cdot R_B \quad (9)$$

A componente refletida da radiação solar na superfície inclinada pode apresentar comportamento tanto isotrópico como anisotrópico (Iqbal, 1983). A componente anisotrópica pode ser utilizada somente em condições de dias com céu claro, pois nestes casos a reflexão tem comportamento uniforme, sendo assim, a fração refletida que incide na superfície inclinada pode ser estimada com bons resultados apenas pela componente isotrópica (Scolar et al., 2003; Souza, 2011).


Na condição isotrópica a fração que incide sobre a superfície inclinada é definida pela Equação (10).

$$Hr_{\beta} = Hg \cdot \rho \cdot [(1/2) (1 - \cos \beta)] \quad (10)$$

Onde ρ é o albedo da superfície e $[(1/2) \cdot (1 - \cos(\beta))]$ é a razão entre a radiação incidente na superfície inclinada e a radiação refletida. Hg é a radiação global.

A componente difusa incidente na superfície inclinada possui características anisotrópicas em função do espalhamento atmosférico avaliadas pelas subcomponentes circunsolar, brilho solar e difusa isotrópica (Figura 3), motivo pelo qual não seja plausível o uso de relações geométricas simplificadas para sua obtenção (Iqbal, 1983; Scola, 2004).

Figura 3 - Radiação difusa incidente em uma superfície inclinada



Fonte: Chwieduk (2009) *apud* Souza (2012).

A irradiância difusa proveniente da região ao redor do disco solar é denominada circunsolar, e é resultante predominantemente do espalhamento devido aos aerossóis da atmosfera. O aumento da intensidade da radiação difusa próximo ao horizonte é denominado de brilho horizontal, resultante do aumento da trajetória pela onda eletromagnética nas proximidades do plano de horizonte e também em função das múltiplas reflexões na atmosfera terrestre.

A difusa é isotrópica porque considera as condições de uniformidade do céu, sendo válida para condições de céu nublado, porém em condições de céu claro a difusa tem comportamento anisotrópico, sendo necessário que os modelos sejam corrigidos. Para a condição isotrópica, o cálculo da irradiação difusa que incide sobre uma superfície inclinada é definido na Equação (11) (Liu e Jordan, 1963; Iqbal, 1983).

$$H_{d\beta} = H_d [(1/2) (1 + \cos \beta)] \quad (11)$$

Onde $[(1/2) (1 + \cos \beta)]$ é a razão entre a radiação difusa incidente na superfície inclinada e a radiação difusa proveniente do céu. H_d é a difusa que incide na superfície com inclinação β .

APÊNDICE B - Técnicas de Aprendizado de Máquina

1 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.

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 (Krishnaiah et al , 2007).

O primeiro modelo de um neurônio artificial foi fruto do trabalho pioneiro de Warren McCulloch e Walter Pitts (McCulloch e Pitts, 1943), ilustrado na Figura (1).

Figura 1 - Modelo do neurônio artificial



Fonte: McCulloch e Pitts (1943)

Essa descrição matemática resultou em um modelo com n terminais de entrada $x_1, x_2, \dots, x_n$ que representam os dendritos, e apenas um terminal de saída y , que representa um axônio. Para simular o comportamento das sinapses, os terminais de entrada do neurônio são ponderados pelos pesos sinápticos dados por $w_1, w_2, \dots, w_n$, cujos valores podem ser positivos ou negativos.

O comportamento do neurônio artificial tem seu comportamento descrito pela Equação 1:





$$y = f. (\sum_{i=1}^n w_i . x_i + b) \quad (1)$$

onde: n é o número de entradas do neurônio; w_i é o peso sináptico; b é o limiar associado ao neurônio; x_i é a entrada do neurônio; $f(.)$ é a função de ativação do neurônio e y é a saída do neurônio.

Quando um sinal x é aplicado a entrada do neurônio, estes são multiplicados por um peso sináptico w o qual representará o grau de relevância na saída. Na sequência realiza-se a soma ponderada dos sinais que resulta em um valor, o qual excedido a um valor limite chamado *threshold* resultará na saída y .

A função de ativação é a parte na qual se faz o processamento das informações u recebidas pela RNA e então gera a saída (Silva et al. 2010). A escolha da função de ativação é de grande relevância para uma rede neural, considerando que os dados passam por um procedimento de normalização para então ser aplicados. Esse processo de normalização tem como objetivo preparar os dados de treinamento em limites mínimos e máximos para definição do menor erro de saída. A função de ativação limita o intervalo de saída a um valor finito. A Tabela 1 apresenta as principais funções de ativação disponível.

Tabela 1 - Funções de ativação

Degrau		$f(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases}$
Linear		$f(x) = \begin{cases} 1 & x \geq \frac{1}{2} \\ x & -\frac{1}{2} < x < \frac{1}{2} \\ 0 & x \leq -\frac{1}{2} \end{cases}$
Sigmóide		$f(x) = \frac{1}{1 + \exp(-\alpha x)}$
Tangente Hiperbólica		$f(x) = \frac{e^{\alpha x} - e^{-\alpha x}}{e^{\alpha x} + e^{-\alpha x}}$


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 responda 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 e evitar problemas de redes superdimensionadas (*overfitting*) e redes subdimensionadas (*underfitting*):

- *Overfitting*: Ocorre quando a rede memoriza os padrões de treinamento e perde a capacidade de generalizar. É provocado quando há um número excessivo de neurônios e/ou camadas ocultas ou por excesso do número de épocas no treinamento;

- *Underfitting*: Ocorre quando a rede não é treinada suficientemente para tornar-se capaz de generalizar o problema. É provocado quando o número de neurônios e/ou camadas ocultas é muito baixo ou por um número insuficiente de épocas de treinamento.

As redes neurais artificiais têm suas arquiteturas classificadas em redes *feedforward* de uma camada, redes *feedforward* de multicamadas, redes recorrentes e redes reticuladas (Figura 2):

Figura 2 - Arquitetura de Redes Neurais



Fonte: Clerice (2014)

a) As redes de uma camada se caracterizam por possuir uma camada de neurônios apenas que é a própria camada de saída. São comumente utilizadas para classificação de padrões e as principais redes que utilizam essa topologia são as redes *Perceptron* e *Adaline*;

b) As redes multicamadas se caracterizam por possuir uma ou mais camadas intermediárias. Nestas redes as informações são recebidas pela camada de entrada, processadas pelas camadas intermediárias e apresentadas pela camada de saída. As principais redes que utilizam este tipo de topologia são as redes *Perceptron Multicamadas* (MLP) e a *Função de Base Radial* (RBF e GRNN);

c) As redes recorrentes têm como característica que as saídas dos neurônios são realimentadas como sinais de entrada para outros neurônios. Essa característica a torna ideal para sistemas dinâmicos variantes no tempo, como por exemplo, previsão de séries temporais, entre outras. Pode-se citar a rede *Hopfield* e *Elman* como das principais nesta categoria;

d) As redes reticuladas têm como característica a disposição espacial dos neurônios, pois o processo de ajuste de seus pesos e limiares (bias) está relacionado às suas localizações espaciais. Tem como principais aplicações problemas de *clustering* (agrupamento), otimização de sistemas e reconhecimento de padrões. A principal rede que utiliza essa topologia é a *Kohonen*. (Spatti, 2011).

O treinamento de uma rede consiste em um processo de ajuste dos pesos sinápticos de forma que um conjunto de valores de entrada seja capaz de produzir valores de saída desejados. Os treinamentos podem ser:


- i) *Supervisionados* – Onde o treinamento gera respostas na saída através dos dados de entrada. As respostas da saída são então comparadas com os valores desejados gerando um valor de erro que é utilizado para fazer um novo ajuste nos pesos e limiares (bias) objetivando sempre minimizar o erro ao máximo;
- ii) *Não Supervisionados*. - Nesse tipo de treinamento não é feita a comparação dos resultados do treinamento com os valores desejados. No processo de treinamento a rede se auto organiza em relação a subconjuntos de valores de entrada que possuem características parecidas, a fim de ajustar os pesos e limiares (bias).

1.1 Multilayer Perceptron (MLP)

A rede neural MLP 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 (Haykin, 2008). Pertence à arquitetura *feedforward* de múltiplas camadas com treinamento supervisionado. 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 (w_i) e dos limiares (bias) (θ), 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, onde a primeira camada é a entrada ($x_{i,j}$), a segunda possui uma ou mais

camadas ocultas de nós computacionais com pesos de ligações ($w_{i,j}$) e a terceira camada corresponde à saída de nós computacionais (y_i), (Lyra et al., 2016). Os sinais de entrada são enviados para a camada oculta. Em seguida, as camadas ocultas e de saída multiplicam os sinais de entrada por um conjunto de pesos.

Figura 3 - Arquitetura da Rede Neural Perceptron Multicamadas.



Fonte: Yadav e Chandel (2014).

A saída dos neurônios é calculada pela aplicação de uma função de ativação que deve ser definida em função do problema a ser ajustado (Rehman e Mohandes, 2008).

Existem muitos algoritmos de aprendizado específicos para determinados modelos de redes neurais. A MLP tradicionalmente utiliza o algoritmo de aprendizagem supervisionado *Backpropagation* (BP). Neste algoritmo o valor de cada camada de saída é usado para atualizar o peso da camada anterior, processo executado em duas etapas: i) insere os dados de entrada da RNA, analisa e compara com o sinal da saída com o sinal desejado. ii) o erro produzido pela RNA é utilizado no processo de ajuste dos pesos ($w_{i,j}$) e limiares (bias) (θ_i).

O ajuste dos pesos ($w_{i,j}$) é feito, tendo-se calculado cada gradiente local com base no erro da camada de saída, pela Equação (2) Haykin (2001).

$$\Delta w_{i,j}(n) = \eta \cdot \delta_i(n) \cdot y_i(n) \quad (2)$$

Onde: η é a taxa de aprendizagem da rede; $\delta_i(n)$ é a propagação do erro nas camadas e $y_i(n)$ é a saída calculada pela rede neural.

Vale destacar que esse processo acontece de forma transparente durante o treinamento da rede.

O algoritmo *Backpropagation* é considerado de processamento lento além de exigir um alto custo computacional, motivo pelo qual variações para esse método foram propostas com o objetivo de aumentar a eficiência no processo de convergência. O algoritmo mais utilizado para essa proposta é o Levenberg-Marquardt que é um método gradiente de segunda ordem, baseado no método dos mínimos quadrados para modelos não lineares. Enquanto o *Backpropagation* é um método de descida do gradiente em função do erro quadrático, o algoritmo Levenberg-Marquardt é uma aproximação do método de Newton (Hagan e Menhaj, 1994).

O método de Levenberg-Marquardt, foi desenvolvido para ter velocidade de treinamento. Quando a função objetivo é a soma de quadrados, a matriz Hessiana pode ser aproximada como $H=J^T J$ e o gradiente como $g=J^T e$, sendo:

- i) J a matriz Jacobiana, contendo a primeira derivada dos erros da rede em relação ao peso
- ii) e o vetor dos erros da rede. O Jacobiano pode ser calculado via *backpropagation*, processo menos complexo que o cálculo da Hessiana.

O algoritmo Levenberg-Marquardt usa a aproximação da Hessiana do mesmo modo que o método de Newton, conforme Equação (3).

$$W^{i+1} = W^i - (J^T J + \mu I)^{-1} J^T e \quad (3)$$

O algoritmo começa com um valor arbitrário. Calcula-se o erro no instante e aplica-se a regra de atualização do peso. Um novo erro é então calculado, e caso tenha aumentado, deve-se desfazer a atualização e aumentar o fator de ajuste. Na sequência a interação é reiniciada e caso o erro tenha diminuído, se aceita a iteração e diminui o fator de ajuste. Assim conduz-se na direção do gradiente quanto mais distante se estiver do ponto mínimo. Ao chegar às proximidades dele, o algoritmo de Newton será predominante (MUKHERJEE; ROUTROY, 2012).


1.2 Radial Basis Functions Networks (RBF)

A RBF é uma rede *feedforward* com topologia de três camadas (entrada, intermediária e saída) (Figura 4) cujos neurônios possuem como função de ativação

uma função de base radial. Normalmente utiliza uma função de ativação Gaussiana e são utilizadas em aproximação de funções, predição de séries temporais e controle.

As funções de base radial (RBFs) são geralmente funções não-lineares cujo valor cresce ou decresce à medida que a distância do centro da função de base radial aumenta. Porém, o mapeamento da camada intermediária para a saída é linear, isto é, a soma dos pesos lineares da camada de saída onde o peso é o parâmetro ajustável da rede.

Figura 4 - Arquitetura da Rede Neural de Base Radial



Fonte: Behrang et al.(2010).

Considerando n entradas, m saídas e s neurônios na camada intermediária, o peso que conecta a camada de entrada e camada escondida é definido por W_1 ; o valor do limiar da camada intermediária é definido por b_1 ; o peso que conecta a camada intermediária com a camada de saída é W_2 ; a entrada da camada intermediária do M -ésimo neurônio é definida pela Equação (4).

$$r_M = \sqrt{\sum_i (W_1 - x_i) \cdot b_1} \quad (4)$$

A saída do M -ésimo neurônio da camada intermediária é definida na Equação (5).

$$c_M = \exp((-r_M)^2) = \exp(-(\|W_1 - x_i\| \cdot b_0)) \quad (5)$$

Onde $\|\cdot\|$ representa uma norma euclidiana.

A entrada da camada de saída promove a soma dos pesos dos neurônios de cada camada intermediária com função de ativação linear definida pela Equação (6).

$$Y_k = \sum_{M=1}^S c_M \cdot W_2 \quad (6)$$

O ajuste dos pesos (W_1) na primeira etapa é feito de forma não supervisionada, e na segunda etapa o ajuste dos pesos (W_2) ocorre de forma supervisionada. Uma questão importante para o treinamento da RBF está em se obter o número de neurônios na camada intermediária, o qual normalmente se inicia com zero neurônio e é incrementado automaticamente através da verificação do erro ($e = \sum_{k=1}^n (t_k - Y_k)^2$), o processo é repetido até que se obtenha o erro desejado, ou quando o número máximo de neurônios da camada intermediária é atingido.


1.3 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. Foi desenvolvida como uma alternativa ao algoritmo *backpropagation*. É capaz de aproximar qualquer função arbitrária, mesmo relações lineares ou não lineares entre as variáveis de entrada e a saída, criando a função de estimação de saída diretamente (Hyun; Nam, 1995).

A rede GRNN é relacionada com a rede neural probabilística (Specht, 1996) e realiza a regressão com a estimação da média dos mínimos quadrados de um conjunto de dados disponível. É baseada na estimação da função densidade de probabilidades da amostra observada usando uma janela de estimação Parzer (Parzer, 1962).

Possui uma estrutura fixa, dada por uma camada de entrada com n neurônios, duas intermediárias denominadas de padrão com n neurônios e soma composta por s neurônios do tipo numerador e um neurônio do tipo denominador e a camada de saída composta por s neurônios. O número de neurônios da camada padrão é igual ao número de vetores da entrada da rede e utiliza função de ativação de base radial. Na GRNN os valores obtidos no treinamento tornam-se vetores de pesos nas camadas intermediárias (Specht, 1991) (Figura 5).

A função de transferência da GRNN é uma função gaussiana onde o parâmetro σ define a abertura desta função ou número de padrões a serem levados em consideração para a estimação de uma variável.

Figura 5 - Arquitetura da GRNN

Fonte: Specht (1991).

A técnica de aprendizado da GRNN difere das outras redes, pois seu processo de aprendizado não utiliza uma abordagem de ajuste iterativo para adquirir informação sobre o treinamento, mas aprende quase que instantaneamente com os dados apresentados para o treinamento.

Essa técnica armazena padrões de treinamento e os processa utilizando uma função de suavização não linear para determinar as funções componentes de densidade de probabilidade de saída.

No processo de treinamento da GRNN as unidades de entrada fornecem as variáveis X para todos os neurônios da camada padrão. A unidade padrão pode ser um exemplar ou um centro do cluster. Quando um novo vetor X entra na mesma rede ele é subtraído do vetor armazenado representando cada centro do cluster (Equação 7).

$$a(i) = \|X - Xi\| \quad i = 1, \dots, n \quad (7)$$

Tanto o quadrado como os valores absolutos dessas diferenças são somados e alimentam uma função ativação não linear, normalmente a exponencial, na camada padrão (Equação 8).

$$b(i) = \exp\left(\frac{a(i)^2}{2\sigma^2}\right) \quad i = 1, \dots, n \quad (8)$$

A saída da camada padrão é enviada para a camada de soma, onde as unidades somadoras realizam a somatória do produto entre um vetor peso e um vetor

obtido na saída da unidade padrão (Equação 9) e o Somatório dos pesos (Equação 10).

$$c(j) = \sum_{i=1}^n y_{j,i} * b_i \quad j = 1, \dots, s. \quad (9)$$

$$d = \sum_{i=1}^n b_i \quad j = 1, \dots, n \quad (10)$$

As unidades de saída dividem cada resultado da camada de soma pelo somatório total de todas as unidades de soma (Equação 11) para então determinar a saída Y (Equação 12).

$$\hat{y}(j) = \frac{c_j}{d} \quad j = 1, \dots, n. \quad (11)$$

$$\hat{Y} = [\hat{y}_1 \dots \hat{y}_j \dots \hat{y}_n]^T \quad (12)$$

Mais detalhes da arquitetura e do funcionamento da rede podem ser obtidos na literatura de Specht, 1991 e Hansen et al (1996).


2 Adaptive Neuro Fuzzy Inference System (ANFIS)

2.1 Definição geral da Lógica Fuzzy

A teoria dos conjuntos *Fuzzy* ou Lógica *Fuzzy* foi definida por Zadeh (1965). Ela aborda uma classe de elementos com graus contínuos de pertinência capaz de traduzir informações imprecisas e as converter de uma linguagem natural em termos matemáticos, generalizando de forma que ela possa assumir um número infinito de valores no intervalo $[0,1]$. Sendo assim, um conjunto fuzzy A em um universo (X) é definido por uma função de pertinência $(\mu_A(x))$: $X \rightarrow [0,1]$ e representado por um conjunto de pares ordenados $A = \{\mu_A(x)/x\} \mid x \in X$, onde $\mu_A(x)$ indica o quanto x é compatível com o conjunto A .

Os conjuntos fuzzy tem como importante propriedade a capacidade de expressar transições graduais entre a pertinência e a não pertinência. Tem como principais funções a gaussiana, triangular e trapezoidal (Shaw & Simões, 1999) (Figura 6).

Figura 6: Funções de pertinência Fuzzy (a) triangular (b) trapezoidal (c) gaussiana (d) sino generalizada



Fonte: Nascimento, Paulo. (2015).

A modelagem *fuzzy* pode ser então definida como um método que permite descrever as características de um sistema usando regras de inferência *fuzzy* (Takagi e Sugeno, 1985).

O modelo de um sistema de inferência *Fuzzy* (FIS) é definido em 5 etapas:


1 – Fuzzificação – responsável por adaptar as informações da entrada em conjuntos *Fuzzy*;

2 – Base de conhecimento (regras) – contém as regras elaboradas pelo especialista (SE, ENTÃO);

3 – Base de conhecimento (dados) – contém as funções de pertinência do conjunto *fuzzy* usados nas regras.

4 – Método de Inferência para a saída *Fuzzy*.

5 – Defuzzificação – responsável por converter os valores *fuzzy* em valores da saída.

Figura 7 - Etapas do Sistema de Inferência Fuzzy

Fonte: Adaptado de Jang (1993)

A literatura apresenta vários tipos de Sistema de Inferência *Fuzzy* (FIS), sendo aqui classificados em três tipos: FIS Mamdani (1975), FIS Tsukamoto (1979) e FIS Takagi e Sugeno (1985).


2.2 Redes Neurais Adaptativas e Sistema de Inferência Neuro-Fuzzy

O termo *Neuro-Fuzzy* é relacionado a um modelo de um sistema de inferência fuzzy empregado na estrutura de uma RNA *Fuzzy* adaptativa, ou seja, um sistema híbrido proposto por Jang (1993) que potencializa as características destes dois importantes paradigmas. Utilizam a interpretabilidade *Fuzzy* o aprendizado das RNA para gerar as regras de inferência de um sistema Fuzzy (Lee *et. al*, 2005).

O sistema híbrido tem como proposta obter um sistema com maior capacidade de interpretação, aprendizado, estimativa e generalização (Silva et al. 2010).

A ANFIS é um sistema híbrido baseado em sistemas neuro-fuzzy foi proposto por Jang (1993). Se baseia no método fuzzy do tipo Takagi e Sugeno (1985) e implementa uma arquitetura baseada em redes adaptativas funcionalmente equivalente. O desenvolvimento deste sistema foi motivado pela inexistência de técnicas para transformar o conhecimento humano em regras *fuzzy* com funções de pertinência apropriadas e pela ausência de métodos que permitissem otimizar funções de pertinência para minimizar o erro e melhorar a performance (Jang, 1993).

A estrutura da ANFIS é composta por cinco camadas, cada qual com finalidades específicas. (Figura 8).

Figura 8 - Arquitetura da ANFIS

Fonte: Jang (1993).

As camadas podem ser descritas como:

Camada 1

Realiza o cálculo do grau de pertinência das entradas x e y , de acordo com o tipo de função escolhida para os nós ($A1$, $A2$, $B1$, $B2$). Normalmente, a função de pertinência dos antecedentes é gaussiana:

$$\mu_{A_i}(x), \mu_{B_i}(y), i=1, 2. \quad (13)$$

Camada 2

Nessa etapa o operador conjuntivo fuzzy produto agrega as saídas das camadas anteriores. Nesta camada e na camada 3 está presente a clausula 'Se' das regras do sistema responsável pela ativação ou não da camada 4. Cada nó dessa camada é uma regra fuzzy do sistema.

$$w_i = (\mu_{A_i}(x), \mu_{B_i}(y)), i = 1, 2 \quad (14)$$

Camada 3

Os nós da camada 3 funcionam como operador de normalização do nível de disparo das regras.

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \quad (15)$$

Camadas 4

Calcula o produto entre as saídas da camada 3 e os valores de entrada (x e y), ponderados pelos valores (p, q e r). A saída dessa camada representa a contribuição de cada regra na saída final.

$$\bar{w}_i z_i = \bar{w}_i (p_i x + q_i y + r_i), \quad i = 1, 2 \quad (16)$$

Camada 5

Calcula a saída precisa do sistema e juntamente com os nós das camadas 4, realizam a fase de defuzzificação do sistema. Composta por apenas um nó que realiza o somatório das saídas da camada 4.

$$\sum \bar{w}_i z_i = \frac{\sum w_i z_i}{\sum w_i}, \quad i = 1, 2 \quad (17)$$

O desempenho do ANFIS ocorre em função do número inicial de parâmetros, quantidades de regras e entradas. Esses parâmetros são determinados de forma empírica, criando-se um modelo com funções de pertinência (Lezanski, 2001). Esse método nem sempre pode ser eficiente, pois não apresenta quantos grupos relevantes de entrada podem existir.

O algoritmo de clusterização subtrativa é utilizado para identificar centros da distribuição de dados (definidos pelos pontos que melhor representem a “vizinhança”). Nesses pontos são centradas as curvas de pertinência que conseqüentemente passa a ter pertinência igual a 1.

No algoritmo de clusterização, define-se como parâmetros de entrada o número de cluster que se deseja identificar ou o raio de atuação do cluster e o número de épocas de iteração. Em cada execução do algoritmo, tenta-se identificar um ponto que minimize o somatório do potencial com os pontos do raio de atuação do cluster. Esse potencial é medido como a distância euclidiana do centro até cada elemento do possível cluster (agrupamento) (Equação 27) (Chiu, 1996).

$$\rho_i = \sum_{j=i}^n \exp\left(-\frac{4}{r_a^2} \cdot \|x_i - x_j\|^2\right) \quad (18)$$

Sendo: ρ_i o potencial do cluster; x_i o centro do cluster e x_j cada ponto do raio de atuação do cluster agrupado a ele; n o número de pontos do raio de atuação do cluster e r_a o raio de atuação do cluster.

APÊNDICE C – Matrizes de Pesos e Limiares (*Bias*)

Capítulo 1

MLP – Combinação M6 – (A)[$Kt_{\beta}^h = f(Kt_H^h)$]

Bias (b1) =	-1,4163	Pesos (w1) =	1,0477	-1,3020	-0,1139	-0,3728	-0,0185	Bias (b2) =	0,9412	Pesos (w2) =	-2,3541
	1,8473		-1,7376	2,3827	0,2177	-0,0422	-0,0863				-0,3793
	-0,2268		1,1427	0,3030	0,5002	0,4779	1,2055				0,1931
	-1,3061		1,6428	-0,1728	-0,0096	0,2400	0,1022				0,6696
	1,8149		-0,5403	-0,0892	-1,0978	0,0551	0,0327				-2,4948
	-0,1152		0,4919	0,3540	0,3404	0,1684	0,8726				-0,3882
	-0,0550		-0,9979	-0,4289	-0,1164	-0,0212	-0,0497				-0,8251
	1,7036		-0,9305	0,5572	0,4029	1,3472	-0,2374				-0,2230
	1,2793		1,8184	0,0472	0,2096	0,3034	0,9707				0,1461
	2,9531		1,6699	2,1222	-1,0144	0,0774	0,0890				0,1242
	-2,3348		-2,1793	-0,5390	-0,5018	0,7436	-0,7601				0,0328

MLP - Combinação M6 – (B)[$Kd_{\beta}^h = f(Kt_H^h)$]

Bias (b1) =	0,6748	Pesos (w1) =	-1,1575	0,4279	-0,0357	0,0488	-0,1274	-0,3859	Bias (b2) =	0,0918	Pesos (w2) =	-1,8987
	1,1924		-1,8649	0,6847	0,1520	0,1652	-0,1664	0,2491				2,6165
	2,5286		-3,1194	0,2350	-0,2066	-0,0574	-0,1460	-2,0628				0,5091
	0,8636		-2,3265	1,6801	0,1662	0,2758	-0,2171	0,1600				2,1218
	-0,7945		1,6468	-1,0651	-0,1737	-0,1988	0,1627	-0,2903				4,8445
	0,0335		1,2433	-0,5363	-0,0155	0,0183	0,1102	-0,1822				-1,7774
	-1,5495		1,1088	-1,8639	-0,0385	0,1734	0,2468	-0,2356				-0,4601
	-2,4362		-0,9376	-0,4802	-0,5426	-1,3396	2,5036	0,7075				-0,0966

MLP - Combinação M6 – (C)[$Kd_{\beta^h} = f(Kt_{\beta^h})$]

Bias (b1) =	0,4760	Pesos (w1) =	-0,8076	-0,0254	0,0658	-0,3784	-0,0049	-0,5835	Bias (b2) =	-1,3961	Pesos (w2) =	1,6831
	-2,8631		4,0377	-0,1063	0,2806	0,2096	0,2218	-0,0609				-0,2829
	0,6758		-1,9232	0,7223	-0,0078	-0,5144	-0,0913	-0,2541				1,5608
	0,1801		1,2894	-3,4520	-2,0977	-1,2406	-0,0913	0,6390				-0,1791
	0,2811		-1,5011	0,5338	-0,3366	-0,7486	-0,0908	-0,1584				-0,8973
	0,0222		-0,8921	0,3187	0,1347	-0,1850	-0,0298	-0,4237				-3,8032
	2,9858		-0,0181	2,7522	-1,2150	0,3618	1,5865	-0,6717				0,0692
	-2,2157		-0,4543	1,5393	2,2772	0,6025	0,0619	-0,2026				-1,5244
	-0,6710		-1,5575	0,0805	-0,2723	-0,5625	-0,0489	-0,1475				3,1041
	-0,9053		-1,9119	-0,4373	-0,7685	-0,9852	0,0188	-0,1166				-1,4441
	2,7849		1,7730	-0,4733	-1,1224	0,2007	0,1252	2,2252				-0,4408

Capítulo 2

MLP – Combinação M8 – (A)[$Kd_{\beta^h} = f(Kd_H^h)$]

Bias (b1) =	-0,5442	Pesos (w1) =	0,4613	0,2601	-0,0128	-0,3349	0,0143	-0,0022	Bias (b2) =	0,9865	Pesos (w2) =	1,1533
	0,7050		0,5608	0,7967	-0,0896	-0,2672	0,0229	-0,0219				0,8507
	0,4114		0,3085	1,2459	-0,0723	-0,0952	0,0203	-0,0236				-0,4620
	2,2271		-0,7228	0,0828	-0,0423	-0,5849	0,0452	-0,0747				-1,4710
	0,7818		0,4210	-0,3058	0,0405	0,2814	-0,0230	0,0052				1,0930

MLP – Combinação M6 – (B)[$Kd_{\beta^h} = f(Kt_H^h)$]

Bias (b1) =	0,6748	Pesos (w1) =	-1,1575	0,4279	-0,0357	0,0488	-0,1274	-0,3859	Bias (b2) =	0,0918	Pesos (w2) =	-1,8987
	1,1924		-1,8649	0,6847	0,1520	0,1652	-0,1664	0,2491				2,6165
	2,5286		-3,1194	0,2350	-0,2066	-0,0574	-0,1460	-2,0628				0,5091
	0,8636		-2,3265	1,6801	0,1662	0,2758	-0,2171	0,1600				2,1218
	-0,7945		1,6468	-1,0651	-0,1737	-0,1988	0,1627	-0,2903				4,8445
	0,0335		1,2433	-0,5363	-0,0155	0,0183	0,1102	-0,1822				-1,7774
	-1,5495		1,1088	-1,8639	-0,0385	0,1734	0,2468	-0,2356				-0,4601
	-2,4362		-0,9376	-0,4802	-0,5426	-1,3396	2,5036	0,7075				-0,0966