



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Botucatu



EDSON LUIS BASSETTO

**ESTIMATIVA DA FRAÇÃO DIFUSA DA IRRADIAÇÃO SOLAR GLOBAL POR
MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA**

Botucatu

2018

EDSON LUIS BASSETTO

**ESTIMATIVA DA FRAÇÃO DIFUSA DA IRRADIAÇÃO SOLAR GLOBAL POR
MEIO DE 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: 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)

B319e Bassetto, Edson Luis, 1966-
Estimativa da fração difusa da irradiação solar global por meio de técnicas de aprendizado de máquina / Edson Luis Bassetto.- Botucatu: [s.n.], 2018
126 p.: fots. color., grafs. color., ils. color., tabs.

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

1. Radiação solar difusa. 2. Modelos de estimativa. 3. Aprendizado de Máquina. 4. Radiação solar - Medição. I. Escobedo, João Francisco. II. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Câmpus de Botucatu). Faculdade de Ciências Agrônomicas. 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: ESTIMATIVA DA FRAÇÃO DIFUSA DA IRRADIAÇÃO SOLAR GLOBAL POR MEIO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA

AUTOR: EDSON LUIS BASSETTO

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
Engenharia Rural / UNESP - Faculdade de Ciências Agrônômicas de Botucatu



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



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



Prof. Dr. RENATO CORREIA DE BARROS
Computação / Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - Campus Birigui



Prof. Dr. RODRIGO HENRIQUE CUNHA PALACIOS
Computação / Universidade Tecnológica Federal do Paraná - Campus Cornélio Procopio

Botucatu, 12 de dezembro de 2018

À minha grande e maravilhosa família.

Andrea, Lucas e Rafael

Dedico

AGRADECIMENTOS

A DEUS.

Aos meus queridos pais Deolino Bassetto e Lindalva da Silva Bassetto (*in memoriam*).

À minha esposa Andrea e meus filhos Lucas e Rafael. Obrigado por entender as ausências, chatices e por estarem sempre me apoiando.

A todos os meus irmãos Wilson, Rosana, Rosilene, Victor e esposa de meu pai Lídia que independente da distância sempre oraram e torceram por mim.

Aos amigos do grupo, Jancer Destro, Adriano Marques, Maurício Prado e Marcos Bica. Muitos encontros e experiências compartilhadas. Continuemos o nosso trabalho.

A UTFPR – Universidade Tecnológica Federal do Paraná e a Fundação Araucária/CAPES (Chamada Pública 18/2015).

A todos os colegas da UTFPR em especial ao Departamento da Elétrica do Campus Cornélio Procopio pela possibilidade de dedicação aos meus estudos.

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

Ao meu grande orientador Prof. Dr. João Francisco Escobedo, pela paciência, compreensão e muitos ensinamentos. Obrigado por acreditar.

RESUMO

Neste trabalho são desenvolvidos modelos de estimativa para fração difusa da radiação global (K_d) nas partições horárias e diária: o Modelo Estatístico (ME) clássico e com Técnicas de Aprendizado de Máquina (TAM). Estas técnicas são do tipo Redes Neurais Artificiais (RNA), Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS) e Máquina de Vetores de Suporte (SVM). O modelo ME utiliza como referência somente a transmissividade atmosférica (K_T) e as TAM um conjunto de combinações de oito variáveis astronômicas, geográficas e meteorológicas. Na elaboração dos modelos ME e TAM foram utilizadas uma base de dados de sete anos (2000-2006) de medidas obtidas na Estação Meteorológica e de Radiometria Solar de Botucatu/SP. Para validação dos modelos ME e TAM foram elaboradas, a partir das medidas obtidas, duas bases anuais denominadas de Ano Típico (AT) e Ano Atípico (AAT). No Capítulo 1 foram desenvolvidos os modelos na partição horária com ME, com as RNA do tipo: Perceptron Multicamadas (MLP), Função de Base Radial (RBF) e Regressão Generalizada (GRNN), e a ANFIS. No Capítulo 2 foram desenvolvidos os modelos na partição diária com o ME, a rede MLP, que apresentou os melhores resultados do Capítulo 1 e a SVM. Os indicadores estatísticos mostram que entre as TAM, o melhor desempenho nas partições horária e diária foi obtido com a técnica MLP, com desempenho (RMSE) superior ao modelo ME em aproximadamente 56% na partição horária e 20% na partição diária, nas duas bases de validação na estimativa de (K_d). Os resultados denotam que ao inserir as variáveis de forma progressiva no treinamento das técnicas, a precisão entre os valores estimados e medidos, asseguram um desempenho superior, comparados ao modelo ME o que torna as técnicas uma alternativa para estimativa da fração difusa (K_d) com as condições de treinamento e validação utilizadas neste estudo.

Palavras-chave: Radiação solar difusa; Modelos de estimativa; Técnicas de Aprendizado de Máquina.

ABSTRACT

In this work, we develop models for the estimation of the fraction of diffuse solar irradiance (K_d) in the hourly and daily partitions: the Statistical Model (SM) and Machine Learning Techniques (MLT) of the type Artificial Neural Networks (ANN), Adaptive Inference System Neuro Fuzzy (ANFIS) and Support Vector Machine (SVM). The statistical model (MS) uses as reference only the transmitted fraction of global irradiation (K_T) and (MLT) a set of combinations of eight astronomical and meteorological variables. The models use a base of seven years (2000-2006) of measurements obtained at the Solar Radiometry Station of Botucatu/SP, being part to elaborate the (SM) and training of the (MLT) and another to validate the models reorganized in two bases known as the Typical Year (TY) and the Atypical Year (AY). In Chapter 1 the models are developed in the hourly partition with (MS), the (ANN) with Multilayer Perceptron (MLP), Radial Base Function (RBF) and Generalized Regression (GRNN) and (ANFIS) models. Chapter 2 models are developed in the daily partition with the (SM) and (ANN/MLP) and the technique (SVM). The statistical indicators show that the performance of the (MLT) in both hourly and daily partitions was obtained with the performance (RMSE) in relation to the model (SM) of approximately 56% in the hourly partition and 20% in the daily partition in the validation (TY) and (AY) in the estimation of (K_d). These results indicate that when entering astronomical and meteorological variables in model, the precision between the estimated and measured values, ensure a better performance compared to the statistical model (SM), which makes the techniques an alternative for estimating the fraction of diffuse solar irradiance (K_d) with the conditions used.

Keywords: Solar radiation; Estimation models; Machine Learning Techniques.

LISTA DE TABELAS

CAPÍTULO 1

Tabela 1.1 - Controle de qualidade	40
Tabela 1.2 - Base do Ano Típico (AT) e Ano Atípico (AAT)	41
Tabela 1.3 - Dados para elaboração e validação do modelo estatístico	41
Tabela 1.4 - Combinações e variáveis de entrada	42
Tabela 1.5 - Dados para elaboração e validação das redes	43
Tabela 1.6 - Valores para parametrização da rede MLP	43
Tabela 1.7 - Valores do ajustamento da função da rede RBF	44
Tabela 1.8 - Valores do ajustamento da função da rede GRNN	45
Tabela 1.9 - Valores do ajustamento da função para ANFIS.	45
Tabela 1.10 - Índices estatísticos – ME.....	47
Tabela 1.11 – Índices estatísticos - outras localidade e ME para Botucatu	49
Tabela 1.12 - Indicadores e configurações das redes MLP, RBF, GRNN e ANFIS ..	50
Tabela 1.13 – Índices estatísticos - outras localidade e TAM para Botucatu	58

CAPÍTULO 2

Tabela 2.1 - Controle de qualidade	77
Tabela 2.2 - Dados para elaboração e validação modelo estatístico	77
Tabela 2.3 - Base do Ano Típico (AT) e Ano Atípico (AAT)	78
Tabela 2.4 - Dados para elaboração e validação das redes.	79
Tabela 2.5 - Combinações e variáveis de entrada	79
Tabela 2.6 - Valores para parametrização da rede MLP	80
Tabela 2.7 - Valores para parametrização da SVM.....	81
Tabela 2.8 – Índices estatísticos do ME.....	83
Tabela 2.9 – Índices estatísticos - outras localidades e ME para Botucatu.....	83
Tabela 2.10 - - Indicadores e configurações das redes MLP e SVM.....	85
Tabela 2.11 – Índices estatísticos - outras localidade e TAM para Boutcatu	88

LISTA DE FIGURAS

CAPÍTULO 1

Figura 1.1 - Modelo do neurônio artificial	29
Figura 1.2 - Ilustração de uma rede MLP	31
Figura 1.3 - Ilustração de uma rede RBF	33
Figura 1.4 - Ilustração de uma rede GRNN.....	34
Figura 1.5 - Ilustração de uma rede ANFIS.....	36
Figura 1.6 - Localização - Botucatu e Estação Meteorológica	37
Figura 1.7 - a) Piranômetro; b) Piranômetro com anel de sombreamento	38
Figura 1.8 - Média entre anos e desvio dos meses de janeiro e julho (AT).....	41
Figura 1.9 - a) Curva de dispersão de $K_d \times K_T$ e validação b) AT; c) AAT	47
Figura 1.10 - Curva de correlação ME de $K_d \times K_T$: a) AT b) AAT.....	48
Figura 1.11 - Curva de desempenho do treinamento da rede MLP.....	52
Figura 1.12 - Curva do EQM no treinamento	53
Figura 1.13 - Curva de dispersão $K_d \times K_T$ - melhores combinações de AT e AAT....	56
Figura 1.14 - Curva de correlação de $K_{dmedido} \times K_{destimado}$	56

CAPÍTULO 2

Figura 2.1 - Modelo do neurônio artificial	72
Figura 2.2 - Localização – Botucatu	74
Figura 2.3 - (a) Temperatura e Umidade; (b) Nebulosidade, (c) Precipitação	75
Figura 2.4 - (a) Piranômetro; (b) Piranômetro com anel de sombreamento	76
Figura 2.5 - Média entre anos e desvio dos meses de janeiro e julho (AT).....	78
Figura 2.6 - a) Curva de dispersão ME e validação para: b) AT; c) ATT	83
Figura 2.7 - Curva de desempenho do treinamento da rede MLP.....	86
Figura 2.8 - Curva do EQM no treinamento	86
Figura 2.9 - Curva de dispersão de $K_d \times K_T$ - melhores combinações de AT e AAT.....	87

LISTA DE ABREVIATURAS E SIGLAS

TAM	Técnicas de Aprendizado de Máquina
ME	Modelo Estatístico
RNA	Rede Neural Artificial
MLP	Rede Neural Perceptron Multicamadas
RBF	Rede Neural de Função de Base Radial
GRNN	Rede Neural de Regressão Generalizada
FIS	Sistema de Inferência Fuzzy
ANFIS	Sistema Adaptativo de Inferência Neuro Fuzzy
SVM	Máquina de Vetores de Suporte
I_g	Irradiância global na superfície horizontal (W/m^2)
I_d	Irradiância difusa na superfície horizontal (W/m^2)
I_b	Irradiância direta na superfície horizontal (W/m^2)
I_{wa}	Irradiância de ondas longas atmosféricas (W/m^2)
H_0	Irradiação no topo da atmosfera (MJ/m^2)
H_g	Irradiação global na superfície horizontal (MJ/m^2)
H_d	Irradiação difusa na superfície horizontal (MJ/m^2)
H_b	Irradiação direta na superfície horizontal (MJ/m^2)
H_{wa}	Irradiação de ondas longas atmosférica (MJ/m^2)
K_T	Transmissividade atmosférica (adimensional)
K_d	Fração difusa da irradiação global (adimensional)
RMSE	Raiz Quadrada do Erro Quadrático Médio (%)
EQM	Erro Quadrático Médio
R^2	Coefficiente de determinação
r	Coefficiente de correlação

SUMÁRIO

INTRODUÇÃO GERAL	21
CAPÍTULO 1 - ESTIMATIVAS DA FRAÇÃO DIFUSA HORÁRIA DO MUNICÍPIO DE BOTUCATU/SP/BRASIL UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA	24
1.1 INTRODUÇÃO	26
1.2 TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)	28
1.2.1 REDE NEURAL ARTIFICIAL (RNA)	29
1.2.1.1 Rede Perceptron Multicamadas (MLP).....	30
1.2.1.2 Rede Função de Base Radial (RBF).....	32
1.2.1.3 Rede Regressão Generalizada (GRNN).....	33
1.2.2 SISTEMA ADAPTATIVO DE INFERÊNCIA NEURO FUZZY (ANFIS)	35
1.3 MATERIAL E MÉTODOS	37
1.3.1 LOCALIZAÇÃO E CLIMA	37
1.3.2 OBTENÇÃO E CONTROLE DE QUALIDADE DAS MEDIDAS	38
1.3.3 MODELO ESTATÍSTICO (ME)	40
1.3.4 TÉCNICAS DE APRENDIZADO DE MÁQUINA	41
1.3.4.1 Treinamento da MLP.....	43
1.3.4.2 Treinamento da RBF.....	44
1.3.4.3 Treinamento da GRNN.....	44
1.3.4.4 Treinamento da ANFIS.....	45
1.3.5 INDICATIVOS ESTATÍSTICOS	46
1.4 RESULTADOS E DISCUSSÃO	47
1.4.1 MODELO ESTATÍSTICO	47
1.4.2 TÉCNICAS MLP, RBF, GRNN E ANFIS	49
1.5 CONCLUSÃO	59
REFERÊNCIAS	59
CAPÍTULO 2 - REDE PERCEPTRON MULTICAMADAS (MLP) E MÁQUINA DE VETORES DE SUPORTE (SVM) NA ESTIMATIVA DA FRAÇÃO DIFUSA DIÁRIA NO MUNICÍPIO DE BOTUCATU/SP/BRASIL	67
2.1 INTRODUÇÃO	68
2.2 TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)	70
2.2.1 REDES NEURAS ARTIFICIAIS (RNA/MLP)	71
2.2.2 MÁQUINA DE VETORES DE SUPORTE (SVM)	73
2.3 MATERIAL E MÉTODOS	74
2.3.1 LOCALIZAÇÃO E CLIMA	74

2.3.2	OBTENÇÃO E CONTROLE DE QUALIDADE DA BASE DE DADOS.....	75
2.3.3	MODELO ESTATÍSTICO (ME).....	77
2.3.3.1	Elaboração e Validação do Modelo Estatístico.....	77
2.3.4	TÉCNICAS DE APRENDIZADO DE MÁQUINA.....	78
2.3.4.1	Treinamento da MLP.....	79
2.3.4.2	Treinamento da SVM.....	81
2.3.5	INDICATIVOS ESTATÍSTICOS.....	81
2.4	RESULTADOS E DISCUSSÃO.....	82
2.4.1	MODELO ESTATÍSTICO.....	82
2.4.2	TÉCNICAS RNA/MLP E SVM.....	84
2.5	CONCLUSÃO.....	89
	REFERÊNCIAS.....	90
	CONSIDERAÇÕES FINAIS.....	97
	REFERÊNCIAS.....	99
	APÊNDICE A – REVISÃO BIBLIOGRÁFICA – RADIAÇÃO SOLAR E TÉCNICAS DE APRENDIZADO DE MÁQUINA.....	101
	APÊNDICE B – MATRIZES DE PESOS E LIMIARES (BIAS).....	123

INTRODUÇÃO GERAL

A energia solar é um dos recursos naturais mais importante para vida na Terra e por ser uma energia limpa e disponível em abundância, diversos estudos científicos e tecnológicos vem sendo realizados nas áreas da engenharia, arquitetura e agronomia. Na engenharia, os conversores fotovoltaicos ou térmicos para produção de energia tem se tornado uma possível solução para problemas energéticos. Na arquitetura, a concepção de projetos envolvendo o uso racional através da energia solar passiva tem proporcionado uma redução no consumo de eletricidade. Na agronomia, o desenvolvimento de cultivares mais resistentes, protegidos e com maior absorção da energia solar, tem proporcionado um aumento significativo na produtividade agrícola (Kambezidis et al., 2017; Marques Filho et al. 2016; Burnett et al., 2014).

Esses avanços são possíveis, principalmente, pelo conhecimento da disponibilidade da radiação solar e de seus componentes na superfície terrestre, seja por meio de medidas (séries temporais e espaciais) disponíveis em centros meteorológicos e institutos de pesquisas ou por meio de modelos de estimativas. Embora, medidas de componentes da radiação solar, como a irradiância global (I_g , W/m^2), estejam disponíveis em várias localidades, outras regiões não possuem medidas contínuas e a longo prazo de outros componentes, como a irradiância direta (I_b - W/m^2) e a irradiância difusa (I_d - W/m^2), dificultando a realização eficiente de estudos e projetos que abrangem essas radiações (Jamil e Siddiqui, 2017). Geralmente (I_b) é obtida pela diferença entre (I_g) e (I_d) por meio da relação ($I_b = I_g - I_d$), tendo em vista que, a obtenção de medidas de (I_b) apresentam custos elevados de equipamentos e operação (Santos et al., 2016a; Dal Pai et al., 2016), ao contrário de medidas de (I_d) que possuem custos menores.

Neste contexto, estas medidas (séries temporais e espaciais) permitem conhecer a disponibilidade da irradiação difusa (H_d - MJ/m^2) em função do tempo, mas são escassos no Hemisfério Sul, como no Brasil, país com elevada disponibilidade de recurso solar (Silva et al., 2008; Marques Filho et al., 2016). Uma das desvantagens de se medir, além dos custos relacionados a equipamentos e manutenção, é a necessidade de um longo tempo de medidas. Desigualmente das séries, os modelos de estimativa, requerem outras medidas da superfície terrestre ou atmosféricas, casos dos modelos estatísticos, que são os mais utilizados e/ou de

técnicas de aprendizado de máquina (Escobedo et al., 2014; Santos et. al, 2016; Rossi et al., 2018).

Os primeiros modelos estatísticos correlacionaram a fração difusa da irradiação global diária (K_d) com a transmissividade atmosférica (K_T) na superfície (Liu e Jordan, 1960). Teoricamente nestes modelos o uso da fração minimiza a dependência do dia e do local das medidas, ficando (K_d) dependente das condições climáticas do local das medidas. Outros modelos foram desenvolvidos em partições horárias e mensais, através de equações polinomiais ajustadas por regressões com uma ou mais variáveis de referência (Collares-Pereira e Rabl, 1979; Chandrasekaran e Kumar, 1994; Jacovides e Tymousy, 2006; Furlan et al., 2012). Apesar do grande número de modelos e variáveis, a desvantagem desses modelos está na limitação da disponibilidade de variáveis medidas e do longo tempo de monitoramento.

Os modelos de estimativa por meio de Técnicas de Aprendizado de Máquina (TAM), tipo Redes Neurais Artificiais (RNA), (Voyant et al., 2017), de técnicas híbridas que utilizam as RNA's e Sistema de Inferência Fuzzy (FIS), chamada de ANFIS (Lazarevska e Trpovski, 2011), e os chamados Máquina de Vetores de Suporte (SVM), são também utilizados nas estimativas de (K_d), mas com várias variáveis climatológicas de referência, com desempenho superiores aos modelos estatísticos tradicionais (Elizondo et al., 1994; Soares et al., 2004; Elminir et al., 2007; Jiang, 2008; Alam et al., 2009; Behrang et al., 2010; Ihya et al., 2014; Kumar et al., 2015; Wang et al., 2016; Santos et al., 2016; Bolznar et al., 2017). A vantagem destas técnicas está em analisar informações complexas, não lineares e na utilização de diversas variáveis. Tem a desvantagem, assim como os modelos estatísticos, de serem utilizadas somente para os locais onde as medidas são obtidas (Soares et al., 2004; Elminir et al., 2007; Ihya et al., 2015; Mohammadi et al., 2016b; Feng et al., 2017).

Na prática, a escolha de modelos estatísticos é limitada pela disponibilidade de variáveis disponíveis e medidas, diferentemente das TAM que possibilitam inserir e combinar um conjunto de variáveis climatológicas com resultados mais eficientes, se comparados aos modelos clássicos tradicionais (Khatib et al., 2012; Paulescu e Blaga, 2016). Diante disso, o objetivo deste trabalho é, a partir de medidas astronômicas, meteorológicas e geográficas, obtidas da cidade de Botucatu/SP, no período de 2000 a 2006, avaliar as TAM através de seus indicadores de desempenho, a raiz quadrada do erro quadrático médio (RMSE) e do coeficiente de correlação (r) na estimativa de

(K_d) e compará-las ao modelo ME. Os objetivos principais do trabalho são: 1 – obter um modelo estatístico da fração difusa na partição horária e diária para o município de Botucatu/SP e validar para uma base de dados anuais e independente; 2 – definir e parametrizar as TAM; 3 – realizar o treinamento e validar as TAM; 4 - comparar o desempenho das TAM; e 5 – analisar e comparar o desempenho do ME e das TAM.

A pesquisa foi desenvolvida no município de Botucatu/SP/BRASIL e está dividida em uma **Introdução Geral**, um capítulo intitulado **Estimativa da fração difusa horária no município de Botucatu/SP/Brasil utilizando técnicas de aprendizado de máquina**, um segundo capítulo intitulado **Rede Perceptron Multicamadas (MLP) e Máquina de Vetores de Suporte (SVM) na estimativa da fração difusa diária no município de Botucatu/SP/Brasil** e ao final, o Apêndices, que descrevem sobre: A) Radiação Solar – Conceitos e Definições; e Descrição das Técnicas de Aprendizado de Máquina – Conceito e Definições; e B) Matrizes de limiares e pesos do: a) Capítulo 1 e b) Capítulo 2.

CAPÍTULO 1

ESTIMATIVA DA FRAÇÃO DIFUSA HORÁRIA NO MUNICÍPIO DE BOTUCATU/SP/BRASIL UTILIZANDO TÉCNICAS DE APRENDIZADO DE MÁQUINA

Autor: Edson Luis Bassetto

RESUMO

Neste estudo foi proposto o uso de técnicas de aprendizado de máquina (TAM) para estimativa da fração difusa da irradiação global (K_d) em função de variáveis climatológicas na partição horária e comparar com modelo estatístico clássico (ME). Foram utilizadas dois tipos de TAM, a Rede Neural Artificial (RNA) com o uso de três modelos de redes (Perceptron Multicamadas (MLP), Função de Base Radial (RBF) e de Regressão Generalizada (GRNN)) e uma técnica híbrida chamada de Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS). Essas técnicas utilizaram uma combinação de variáveis astronômicas, geográficas e meteorológicas, medidas no período de 2000 a 2006, na Estação Meteorológica e de Radiometria da Faculdade de Ciências Agrônomicas da Universidade Estadual Paulista, da cidade de Botucatu/SP/Brasil. Para validação dos modelos ME e das TAM foram elaboradas a partir de medidas obtidas, duas bases de dados anuais denominadas de Ano Típico (AT) e Ano Atípico (AAT). O modelo ME, gerado por regressão polinomial, apresentou equação de 4ª ordem, com coeficiente de determinação (R^2) de 0,7999. A equação polinomial foi validada e na comparação entre os valores estimados e medidos, apresentou os seguintes indicadores estatísticos: coeficiente de correlação (r) igual a $r_{AT} = 0,8986$ e $r_{AAT} = 0,8907$; e raiz quadrada do erro quadrático médio (RMSE) igual a $RMSE_{AT} = 30,58\%$ e $RMSE_{AAT} = 28,12\%$. Na validação das TAM para a mesma condição do modelo ME (somente K_T com variável independente), obteve-se os indicadores estatísticos para o melhor desempenho igual a $RMSE_{AT} = 30,42\%$ e $RMSE_{AAT} = 27,86\%$ com a rede MLP e para o pior desempenho igual a $RMSE_{AT} = 88,44\%$ e $RMSE_{AAT} = 88,40\%$ com a rede RBF. Com a inserção progressiva das variáveis astronômicas, geográficas e meteorológicas na modelagem com as TAM, houve um aumento crescente no desempenho dos modelos. A técnica que apresentou o melhor indicador foi obtido com a rede MLP quando oito variáveis climatológicas participaram da modelagem com coeficiente de correlação igual a $r_{AT} = 0,9553$ e $r_{AAT} = 0,9511$ e de desempenho no ordem de $RMSE_{AT} = 19,59\%$ e $RMSE_{AAT} = 18,75\%$. Os resultados de desempenho, mostram que o uso das TAM com a mesma variável de

entrada (K_T), são similares ou superiores ao modelo ME e entre as técnicas com mais de uma variável a rede MLP apresentou a melhor eficiência, sendo por tanto indicada como um método alternativo para estimativa da fração difusa da irradiação global (K_d) com precisão.

Palavras-chave: Radiação solar; Modelos de estimativa; Técnicas de Aprendizado de Máquina.

ABSTRACT

In this study it was proposed the use of machine learning techniques (MLT) to estimate the diffuse fraction of global irradiation (K_d) as a function of climatological variables in the hourly partition and to compare with the classical statistical model (SM). Two types of TAM, the Artificial Neural Network (ANN) using three network models (Perceptron Multicamadas (MLP), Radial Base Function (RBF) and Generalized Regression (GRNN)) were used and a hybrid technique called Adaptive Fuzzy Neural Inference System (ANFIS). These techniques used a combination of astronomical, geographic and meteorological variables, measured from 2000 to 2006, at the Meteorological and Radiometric Station of the Faculty of Agronomic Sciences of Paulista State University, in the city of Botucatu / SP / Brazil. For the validation of the ME and TAM models, two annual databases, called the Typical Year (TY) and the Atypical Year (AY), were elaborated from the obtained measurements. The ME model, generated by polynomial regression, presented a 4th order equation, with determination coefficient (R^2) of 0.7999. The polynomial equation was validated and, in the comparison between the estimated and measured values, presented the following statistical indicators: correlation coefficient (r) equal to $r_{AT} = 0.8986$ and $r_{AAT} = 0.8907$; and square root mean square error (RMSE) equal to $RMSE_{AT} = 30.58\%$ and $RMSE_{AAT} = 28.12\%$. In the validation of the TAM for the same condition of the ME model (only K_T with independent variable), the statistical indicators were obtained for the best performance equal to $RMSE_{AT} = 30.42\%$ and $RMSE_{AAT} = 27.86\%$ with the MLP network and for the worst performance equal to $RMSE_{AT} = 88.44\%$ and $RMSE_{AAT} = 88.40\%$ with the RBF network. With the progressive insertion of the astronomical, geographic and meteorological variables in the modeling with the MLT, there was an increasing increase in the performance of the models. The technique that presented the best indicator was obtained with the MLP network when eight climatological variables

participated in the modeling with correlation coefficient equal to $r_{AT} = 0.9553$ and $r_{AAT} = 0.9511$ and performance in the order of $RMSE_{AT} = 19.59\%$ and $RMSE_{AAT} = 18.75\%$. The performance results show that the use of MLT with the same input variable (K_T), are similar or superior to the ME model and among the techniques with more than one variable the MLP network showed the best efficiency and therefore is indicated as an alternative method for estimating the diffuse fraction of global irradiation (K_d) with precision.

Keywords: Solar radiation; Estimation models; Machine Learning Techniques.

1.1 INTRODUÇÃO

Informações sobre a irradiância solar difusa (I_d - W/m^2) ou irradiação solar difusa na superfície horizontal (H_d - MJ/m^2) ou inclinada, por meio de medidas (séries temporais e espaciais) ou por modelos de estimativas, é de fundamental importância para a elaboração de projetos de conversão de energia solar (Kambezidis et al., 2017; Simón-Martin et al., 2017), de produção de biomassa, energia passiva (Oteiza e Perez-Burgos, 2012) e de cultivos protegidos (Weiss e Normam, 1985; Escobedo et al., 2013 e 2011). Os dados de (I_d) ou (H_d), são também importantes em estudos de modelos de simulações espaciais, elaboração de atlas solarimétricos e calibração de satélites (Boznar et al., 2016; Viana et al., 2011; Eissa et al., 2012; Tiepolo et al., 2018; Zagouras et al., 2013; Ineichen, 2014; Aguiar et al., 2015).

A maior vantagem de conhecer (I_d) é econômica, pois permite o cálculo da irradiância solar direta na horizontal (I_b - W/m^2) quando medidas da irradiância solar global (I_g - W/m^2) e (I_d) são realizadas no mesmo local e superfície. Geralmente (I_b) é obtida pela diferença entre (I_g) e (I_d) por meio da relação ($I_b = I_g - I_d$), pois a obtenção de medidas de (I_b) apresentam custos elevados de equipamentos, manutenção e operação (Santos et al., 2016a; Dal Pai et al., 2016). Diferentemente das medidas de (I_d), que possuem custos menores, como na montagem alternativa proposto por Melo e Escobedo (1994) realizada através do método de sombreamento. Nesta proposta a montagem do anel de sombreamento, tem seu eixo central fixo a um eixo na horizontal e inclinado na latitude local, paralelo a direção polar. Nesta configuração é proposto um fator de correção isotrópico (Equação 2) para compensar a parcela da (I_d) que é obstruída pelo próprio anel (Oliveira et al., 2002 a e b). As correções proporcionam

um aumento da precisão e a realização de uma análise mais eficiente das séries temporais e espaciais.

As séries temporais e espaciais permitem conhecer a disponibilidade da (H_d) em função do tempo, contudo estudos sobre a (H_d) ainda são escassos no Hemisfério Sul, com poucas informações disponíveis, como no Brasil, país com grande extensão continental e com elevada disponibilidade de recurso solar. (Silva et al., 2008; Marques Filho et al., 2016). Diferentemente das séries, os modelos de estimativa necessitam de medidas da superfície terrestres e/ou atmosférica, casos dos modelos estatísticos e/ou de técnicas de aprendizado de máquina (Escobedo et al., 2014; Santos et. al, 2016b).

O primeiro modelo estatístico correlacionou a fração difusa (K_d) com a transmissividade atmosférica (K_T) na superfície da atmosfera (Liu e Jordan, 1960). Outras propostas foram desenvolvidas em partições horárias e mensais através de equações polinomiais ajustadas por regressões com uma ou mais variáveis de referência (Collares-Pereira e Rabl, 1979; Chandrasekaran e Kumar, 1994; Ruiz-Arias et al., 2010; Furlan et al., 2012). No modelo estatístico teoricamente são minimizados a dependência do dia e do local das medidas, ficando (K_d) dependente das condições climáticas do local. A desvantagem do modelo é a eficiência restrita somente para os locais das medidas. Outra desvantagem do modelo estatístico é apresentarem valores de desempenho (RMSE) próximo ou superiores a 30% (De Miguel et al., 2001; Jacovides e Tymousy, 2006; Kambezidis et al., 2017; Marques Filho et al., 2016) que é considerado elevado quando comparado com valores de desempenho de outras radiações e modelos (Escobedo et al., 2011; El Mghouchi et al., 2014; Quej et al., 2016; Silva et al., 2017).

Os modelos de estimativa por meio de Técnicas de Aprendizado de Máquina (TAM), tipo Redes Neurais Artificiais (RNA), (Voyant et al., 2017) e Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS) (Lazarevska e Trpovski, 2011), são também utilizados nas estimativas de (K_d), mas com várias variáveis climatológicas de referência e com desempenho similares ou superiores aos modelos estatísticos (Elminir et al., 2007; Ihya et al., 2015; Mohammadi et al., 2016b; Feng et al., 2017). Estas técnicas possuem as seguintes vantagens: habilidade em aprender a partir de informações conhecidas e desejadas; não conhecer o comportamento matemático dos dados de entrada; interpretar falsas informações sem alterar os resultados; estimar resultados a partir de conhecimento prévio de variáveis de grandezas físicas

diferentes; e ajustar (pesos) os valores das variáveis de entrada de acordo com o valor desejado. Contudo tem a desvantagem em definir a parametrização e ajustes ideais das redes que dependem principalmente da variável, do número de amostras utilizadas e de serem utilizadas somente nos locais das medidas.

No Brasil o uso das TAM é recente para estimativas da radiação solar, principalmente da radiação difusa (Soares et al., 2004; Marques Filho et al., 2017; Santos et al., 2016b; Silva et al., 2017), com a necessidade de mais estudos e informações disponíveis em outros locais para a otimização de trabalhos espaciais e de informações de medidas com radiação solar no país. Diante da importância da utilização da radiação solar difusa em diversos projetos de conversão, nesse trabalho é proposto um estudo comparativo entre os modelos ME e TAM (MLP, RBF, GRNN e ANFIS) a partir de medidas da radiação difusa e global obtidas no município de Botucatu/SP. Os objetivos principais deste estudo foram: 1 – obter um modelo estatístico da fração difusa (K_d) horária para Botucatu/SP e validar para uma base de dados independente; 2 – selecionar e parametrizar as TAM; 3 – realizar o treinamento e validar as TAM; 4 – comparar o desempenho das TAM; e 5 – comparar o desempenho entre os modelo ME e TAM.

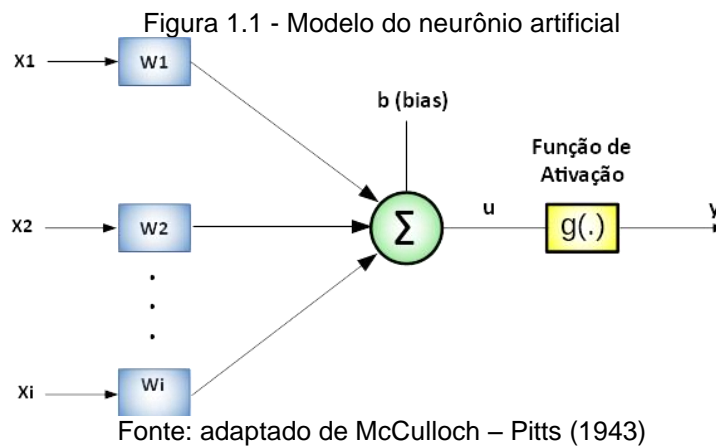
1.2 TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)

O princípio de funcionamento das Técnicas de Aprendizado de Máquina 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 futuros (dados de saída). Essa relação pode tornar-se mais eficiente em função de uma nova informação ou experiência adquirida. Isto acontece pois as técnicas reconhecem padrões de diferentes grandezas, como os dados meteorológicos, e através de algoritmos de otimização e/ou agrupamento estabelecer uma associação entre dados de entradas e saídas.

Entre as Técnicas de Aprendizado de Máquina utilizados para estimar radiação solar em superfícies horizontais ou inclinadas, destacam-se as Redes Neurais Artificiais e os Sistemas Adaptativos de Inferência Neuro Fuzzy (Yadav e Chandel, 2014; Lauret et al., 2015; Santos et al., 2016b; Silva et al., 2017; Assouline et al., 2017). Na sequência uma descrição resumida destas técnicas.

1.2.1 Redes Neurais Artificiais (RNA).

As RNA apresentam uma estrutura formada por um conjunto de elementos chamados neurônios. É composta por camadas, que através do processamento de informações entre elas são capazes de mapear funções complexas e não lineares. São utilizadas para o reconhecimento e classificação de padrões, agrupamento, previsão e recentemente na estimativa de variáveis astronômicas. 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), multiplicados por pesos sinápticos (w_1, w_2, \dots, w_i) que servem para ponderar as variáveis de entrada. Um combinador linear (Σ) executa a soma das entradas, limitada por um intervalo de valores definido pelo limiar de ativação (*bias* - b) produzindo uma saída chamada de potencial de ativação (u) que é então transformada por uma função de ativação (g , que gera a saída (y)) (Haykin, 2001).



As Equações (1) e (2) representam o comportamento matemático de um neurônio artificial:

$$u_j(k) = \sum_{i=1}^n x_i * w_i + b \dots \dots \dots (1)$$

$$y_j(k) = g_j(u(k)) \dots \dots \dots (2)$$

onde: x_i é a i –ésima variável de entrada do neurônio; w_i é o peso associado com a i –ésima variável de entrada; b é o limiar (*bias*) associado ao neurônio; $g(k)$ é a resposta (soma da junção) do neurônio j –ésimo em relação ao instante k ; $g(.)$ é a função de ativação do neurônio j –ésimo; $y_i(k)$ é a variável de saída do j –ésimo neurônio em relação ao instante k .

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 que procuram aproximar os valores da saída da rede ($y_i(k)$) com os valores desejados. Esse processo é realizado por algoritmos de treinamento que são dependentes da composição da estrutura, do número de neurônios, das camadas ocultas, da função de transferência e do conjunto de dados. Estes aspectos influenciam os pesos e consequentemente a capacidade de generalização.

Entre as técnicas de RNA utilizadas para estimativa de radiação solar destacam-se a *Perceptron Multicamadas* (MLP), amplamente utilizada na literatura e em diversas áreas, a Função de Base Radial (RBF) proposta como alternativa às RNA e de Regressão Generalizada que é uma otimização da RBF (Mohandes et al., 1998; Alam et al., 2009; Mellit et al., 2010b; Dorvlo et al., 2012; Feng et al., 2017; Citakoglu, 2015).

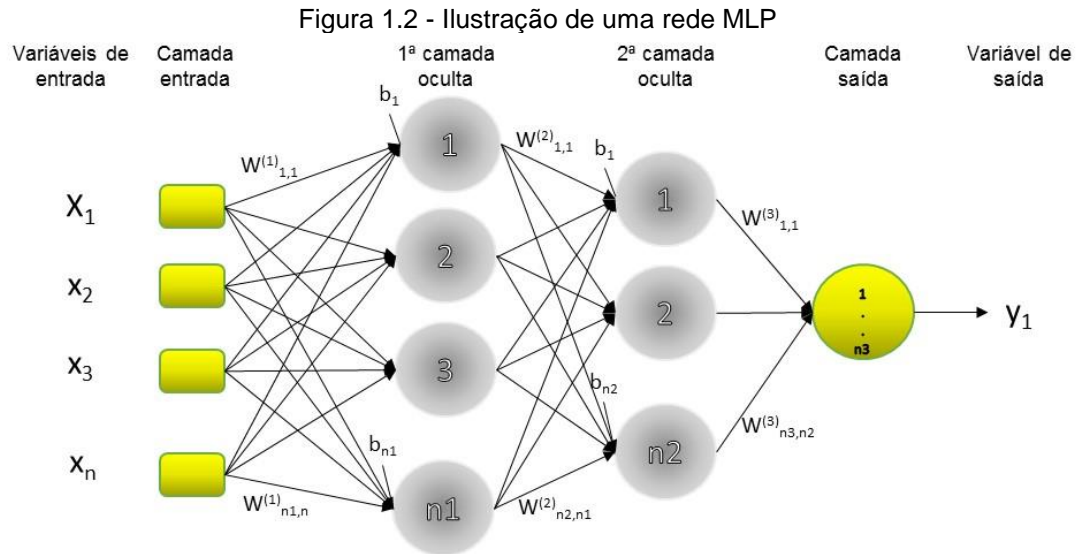
Além destas, outras RNA como a Redes recorrentes de Hopfield, as Redes auto-organizáveis de Kohonen, a Rede LVQ e *counter propagation* e as Redes ART são utilizadas para outros fins, mas não para estimativas de radiação solar. Como exemplo, as redes de Hopfield que podem ser utilizadas quando falta dados ou o banco de informações está incompleto, ou mesmo a Quantificação Vetorial por Aprendizagem (LVQ) mais utilizada em classificação de padrão e a ART (Teoria da Ressonância Adaptativa) que tem a habilidade de aprender novos padrões através de sistema não flexíveis.

São descritas na sequência as redes utilizadas neste trabalho para estimativa de fração difusa da irradiação global.

1.2.1.1 Rede *Perceptron Multicamadas* (MLP)

Caracterizada pela presença de pelo menos uma camada intermediária, localizada entre a entrada e a saída. Classificada como redes do tipo *feedforward* (alimentação a frente ou única direção) de camadas múltiplas (Figura 1.2).

O treinamento é realizado de forma supervisionada onde o algoritmo realiza o treinamento da rede em duas fases. Na primeira fase as informações de entrada e respectivos pesos iniciais se propagam e comparam com as informações de saída, e a segunda fase de forma inversa onde a partir da saída os respectivos pesos se propagam para entrada (Alam et al. 2009).



Na fase de treinamento da rede, há a determinação e a correção dos pesos (w_{n1n}) e dos limiares (bias) (θ_{b1}), para que a mesma responda a um valor desejado, minimizando o erro de saída para cada vetor de entrada. A primeira camada é a entrada (x_n), a segunda possui uma ou mais camadas ocultas de nós computacionais com pesos de ligações (w_{n1n}) e a terceira camada corresponde à saída de nós computacionais (y_j), (Lyra et al., 2016). Os sinais de entrada são enviados para a camada oculta e em seguida, as camadas ocultas e de saída multiplicam os sinais de entrada por um conjunto de pesos. 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).

O algoritmo para este processamento é conhecido como *backpropagation*, porém existem outras versões otimizadas deste algoritmo que procura diminuir o tempo de resposta no processo de convergência. O algoritmo de *Levenberg-Marquardt (LM)*, que diferentemente do *backpropagation* que ajusta os pesos na direção oposta do gradiente da função erro-quadrático (método de descida do gradiente), o LM é baseado no método dos mínimos quadrados que proporciona maior rapidez de convergência nestes ajustes. O erro produzido neste processo é utilizado para ajustar os parâmetros internos (pesos e limiares). O ajuste dos pesos (w_j) associado ao j - ésimo neurônio de saída é calculado pelo erro $e_j(k)$ associado k - ésima interação ou ao k - ésimo vetor de entrada. O erro é obtido por meio da Equação (3).

$$e_j(k) = d_j(k) - y_j(k) \dots \dots \dots (3)$$

onde: $d_j(k)$ é a resposta desejada para o j – ésimo neurônio de saída e $y_j(k)$ se refere a resposta encontrada na saída do neurônio a j – ésima interação de k .

Como critério de desempenho e parada no processo de treinamento são utilizados as funções do erro quadrático $E(k)$ que fornece o valor instantâneo da soma dos erros quadráticos de todos os neurônios de saída em relação ao k – ésimo vetor de entrada dado pela Equação (4) e o erro quadrático médio E_M que é obtido a partir da soma dos erros quadráticos relativos a todas as entradas dado pela Equação (5).

$$E(k) = \frac{1}{2} \sum_{j=1}^n (d_j(k) - y_j(k))^2 \dots\dots\dots(4)$$

onde: n especifica o número de neurônios de saída.

$$E_M = \frac{1}{p} \sum_{k=1}^n E(k) \dots\dots\dots(5)$$

onde: p especifica a quantidade de vetores de entrada.

O processo de aprendizagem tem como objetivo ajustar os pesos da rede a fim de reduzir o erro quadrático médio.

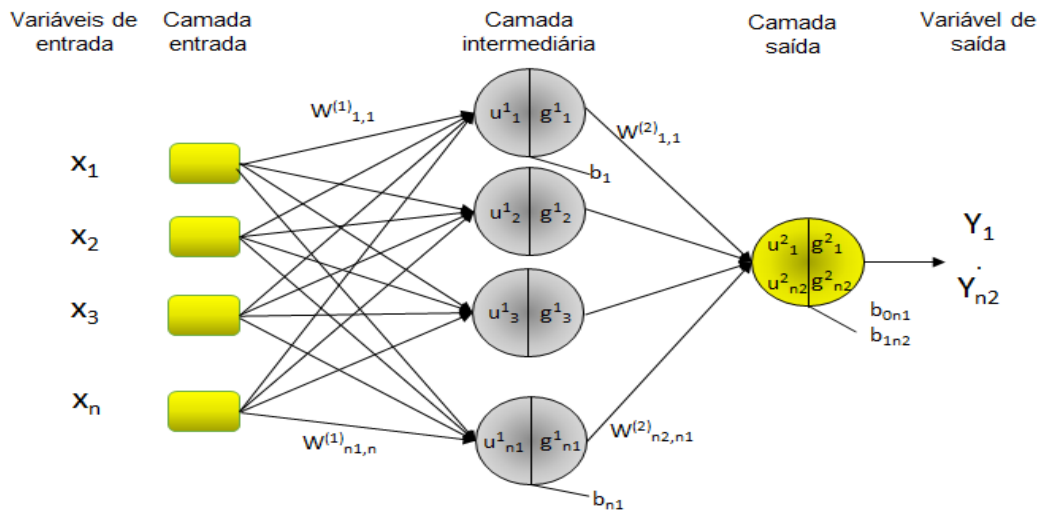
Essas redes são mais utilizadas na estimativa da (H_g) (Elizondo et al., 1994; Kalogirou, 2000; Tymvios et al., 2005; Kumar et al., 2015; Silva et al., 2017), com diversas variáveis climatológicas e geográficas como variáveis de entrada. Para (H_b) poucos trabalhos são encontrados na literatura (Alam et al., 2006; Tomar et al., 2012; Kaushika et al., 2014; Santos et al., 2016b), assim como para (H_d) (Soares et al., 2004; Alam et al., 2009; Ihya et al., 2015; Boznar et al., 2016).

1.2.1.2 Rede Função de Base Radial (RBF)

A estrutura da rede RBF é formada por apenas uma camada oculta e tem como particularidade a estratégia de treinamento. Os neurônios pertencentes à camada oculta (intermediária) são iguais ao número de amostras e a camada constituída de funções de base radial, geralmente as gaussianas (Figura 1.3).

Classificada como rede do tipo *feedforward* com treinamento realizado em duas fases distintas. A primeira fase é não supervisionada e está relacionada somente aos dados de entrada com a alocação da função de ativação. A segunda fase supervisionada, onde se realiza o ajuste dos pesos dos neurônios com a camada de saída, sendo similar ao processo de treinamento da rede MLP (Crispim et. al, 2006).

Figura 1.3 - Ilustração de uma rede RBF



Fonte: Adaptado de Crispim et al., (2006)

Nesta estrutura a Equação (6) representa o comportamento matemático da rede:

$$y_k(x) = \sum_{i=1}^M w_{ki} * g_i(x) + b \dots \dots \dots (6)$$

onde: b é o limiar de ativação (*bias*).

A expressão da função de ativação $g(.)$ é representada pela expressão matemática da Equação (7).

$$g(u) = e^{\frac{-(u-c)^2}{2*\sigma^2}} \dots \dots \dots (7)$$

onde: c é o centro da função gaussiana e associado ao próprio peso, a σ^2 a variância pela qual indica a dispersão do potencial de ativação $\{u\}$ em relação ao centro de c .

A saída de cada neurônio j da camada oculta é representada pela Equação (8).

$$g_j(x) = e^{-\left(\frac{\sum_{i=1}^n (x_i - w_{ji})^2}{2*\sigma_j^2}\right)} \dots \dots \dots (8)$$

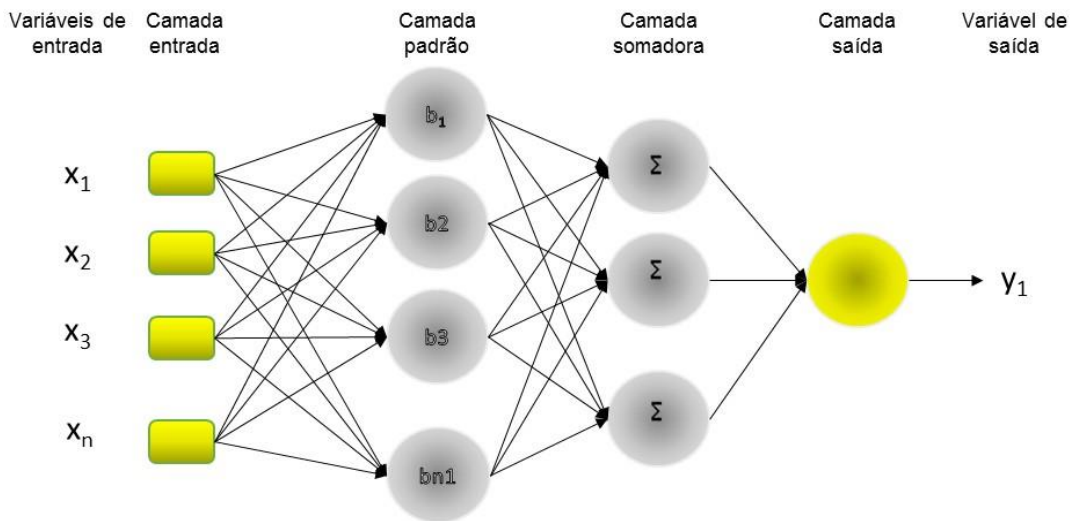
onde: n representa o número de amostras e $j = 1, \dots, n$.

As redes RBF é restrita a poucas referências para estimativa de irradiação solar (Behrang et al., 2010; Benghanem e Mellit, 2010; Wang et al., 2016).

1.2.1.3 Rede Regressão Generalizada (GRNN)

A rede GRNN é uma otimização da RBF, e não requer um treinamento iterativo. Consiste de duas camadas (padrão e somadora) além da camada de entrada e saída (Figura 1.4).

Figura 1.4 - Ilustração de uma rede GRNN.



Fonte: Adaptado de Khatib e Elmenreich, (2015)

Nesta estrutura o número de neurônio da camada padrão é igual ao número de amostras da camada de entrada. A camada padrão é conectada a camada somadora que funcionam juntas para normalizar os valores de saída. Os dados de entrada (vetores) são posicionados em um centro qualquer denominado de *cluster* no qual tem sua posição subtraindo-se do vetor que foi armazenado ao centro da função gaussiana (distância euclidiana) (Equação (9)) (Cellik e Muneer, 2013).

$$a(i) = \|x - x_i\| \quad i = 1, \dots, n \dots \dots \dots (9)$$

Nesta estrutura, a saída da rede tem seu comportamento matemático representado pela Equação (10).

$$y_j = \frac{\sum_{i=1}^n y_{j,i} * b_i}{\sum_{i=1}^n b_i} \dots \dots \dots (10)$$

onde: $b(i)$ é a função de ativação que neste caso exponencial é dada pela Equação (11) e $y_{j,i}$ o vetor peso de cada saída da camada padrão.

$$b(i) = \exp\left(-\frac{a(i)^2}{2\sigma^2}\right) \text{ onde } i = 1, \dots, n = \text{amostras} \dots \dots \dots (11)$$

Difere de outras redes pois possui um processo de aprendizado que não faz uso dos ajustes simultâneos para adquirir conhecimento no treinamento, porém possui capacidade de aprender quase que instantaneamente com os dados apresentados na base de treinamento (Hansen e Meservy, 1996). 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).

Devido a sua característica de treinamento, não requerem algoritmos complexos e têm capacidade de estimar qualquer função não linear, mas depende muito da quantidade de dados. Quanto maior o conjunto de treinamento, menor o erro na estimativa. Com estes aspectos a GRNN tem se mostrado pouco eficiente para estimar variáveis da radiação solar (Wang et. al, 2016; Feng et al., 2017).

1.2.2 Sistema Adaptativo de Inferência Neuro (ANFIS)

A lógica de processamento desta técnica consiste em utilizar a forma de interpretação da Lógica Fuzzy e as características de aprendizado da RNA compondo um sistema híbrido. A Figura 1.5 apresenta a estrutura da ANFIS para duas variáveis de entrada, uma saída e duas regras, sendo os nós adaptativos representados por quadrados e os fixos por círculos e divididos em interações entre cinco camadas que acontecem em dois processos: fuzzificação e defuzzificação (Zadeh, 1968; Jang, 1993; Takagy e Sugeno, 1985; Wang et al., 2009; Quej et al., 2017).

Na primeira camada (fuzzificação) se realiza o cálculo do grau de pertinência das entradas (x e s), de acordo com o tipo de função escolhida para os nós (A_i e B_i), como por exemplo a função gaussiana representada pela Equação (12) e (13).

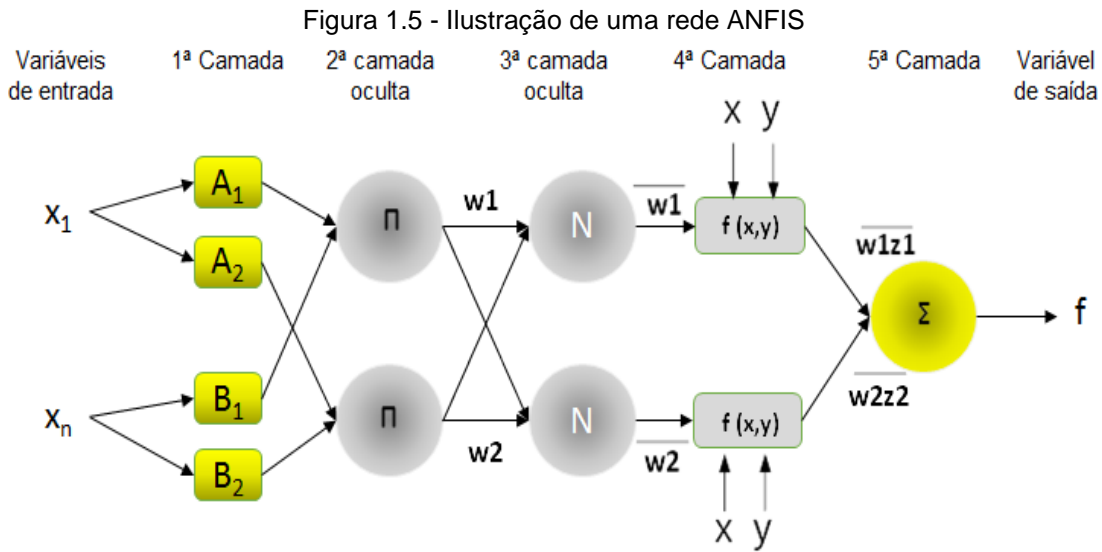
$$\mu_{A_i}(x) = e^{-\frac{(x-c)^2}{2*\sigma^2}} \dots\dots\dots(12)$$

$$\mu_{B_i}(s) = e^{-\frac{(s-c)^2}{2*\sigma^2}} \dots\dots\dots(13)$$

onde: c é o centro da função gaussiana e associado ao próprio peso, a σ^2 é a variância pela qual indica a dispersão da função de pertinência em relação ao centro de c . As funções podem assumir outras formas linguísticas (bom ou ruim; pequeno ou grande) ou funções como triangular e trapezoidal.

Na segunda camada (produto) o operador conjuntivo *fuzzy* é aplicado agrupando os dados de entrada em subgrupos, associando os valores aos subgrupos correspondentes ou com características semelhantes para obter uma saída que represente as saídas das camadas anteriores (Equação (14)). Nesta camada e na camada 3 está presente a cláusula ‘Se’ das regras do sistema responsável pela ativação ou não da camada 4. Cada nó dessa camada é uma regra fuzzy do sistema. Nestas duas 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.

$$w_i = (\mu_{A_i}(x) * \mu_{B_i}(y)) \text{ sendo } i= 1 \text{ e } 2 \dots\dots\dots(14)$$



Fonte: Adaptado de Jang, (1993)

Na terceira camada (normalizada) é realizada a normalização das informações ou dos pesos com o grau de ativação da regra anterior em relação às outras, ou seja, se calcula a razão entre a força do disparo da regra (w_i) aplicada e a soma de todas as regras (Equação (15)).

$$\acute{w}_i = \frac{w_i}{w_1+w_2} \quad i= 1 \text{ e } 2 \dots\dots\dots(15)$$

Na quarta camada (defuzzificação) encontram-se a composição das regras onde se calcula o produto de cada função linear entre a saída da camada 3 e os valores de entrada (x e y), ponderados pelos vetores gerados no processo de treinamento (p, q e r), calculada pela Equação (15). Nesta camada encontra-se a composição das regras. Os parâmetros são otimizados através de algoritmo de regressão de mínimos quadrados e retorna (propagação reversa) com os erros (soma da diferença quadrática entre os valores medidos e estimados). Estes parâmetros são atualizados por algoritmos de gradiente descendente, finalizando com a totalização dos valores na quinta camada (Equação (16)) (Jang, 1993; Takagy e Sugeno, 1985; Wang et al., 2009; Quej et al., 2017).

$$\acute{w}_i z_i = \acute{w}_i (p_i x + q_i y + r_i) \quad i= 1 \text{ e } 2 \dots\dots\dots(16)$$

onde: \acute{w}_i é a saída da camada 3 e os parâmetros são os coeficientes da combinação linear no sistema de inferência Sugeno.

Ao final, na camada 5 (saída) composta por apenas um nó, se realiza o somatório (Σ) das saídas da camada 4 (Equação (17)).

$$\Sigma \acute{w}_i z_i = \frac{\Sigma w_i z_i}{\Sigma w_i}, i = 1, 2, \dots (17)$$

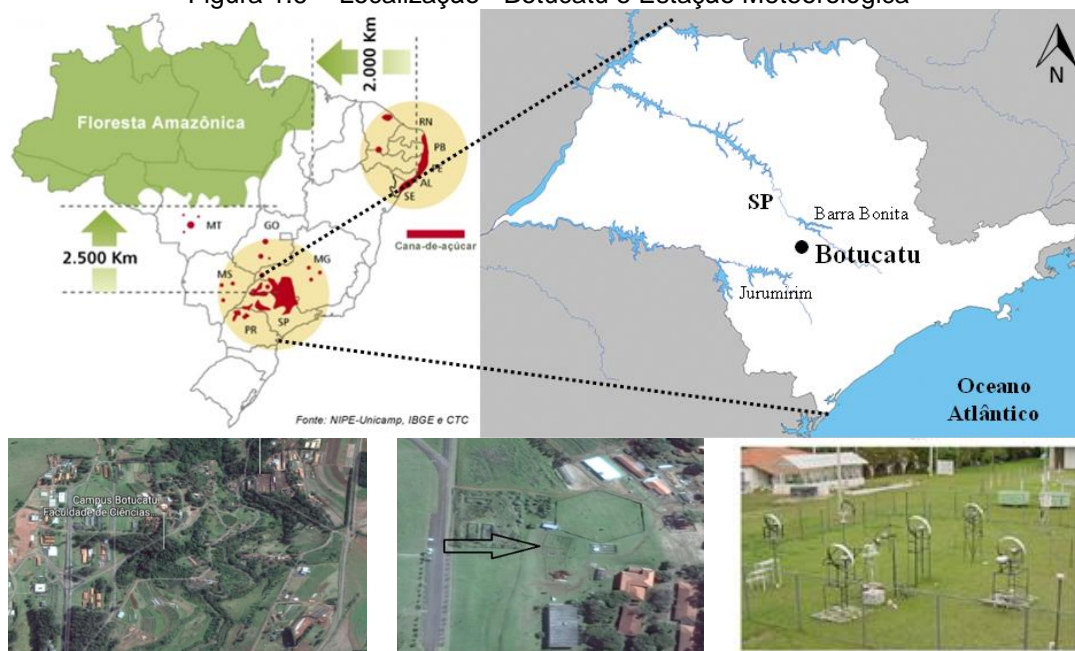
A ANFIS é uma técnica cada vez mais presente em estudos de estimativas da radiação solar, porém tem sido utilizada com mais frequência para estimar (H_g) (Sfetsos e Coonick, 2000; Landeras, 2012; Mohammadi, 2016c).

1.3 MATERIAL E MÉTODOS

1.3.1 Localização e Clima

Nesse estudo os dados foram obtidos entre os anos de 2000 a 2006, na Estação Meteorológica e Radiométrica do Departamento de Engenharia Rural da Faculdade de Ciências Agrônômicas, que está localizada no campus da UNESP – Universidade Estadual Paulista em Botucatu/SP/Brasil (Figura 1.6), (latitude 22,85°S, longitude 48,45°W e altitude 786m).

Figura 1.6 - Localização - Botucatu e Estação Meteorológica



Fonte: Rossi et al., 2018 e Google Earth.


De acordo com a classificação de Koppen, o clima é do tipo Cwa com bioma de cerrado e de mata atlântica, temperado úmido com inverno frio e seco (junho-agosto) e verão quente e úmido (dezembro-fevereiro) com elevada precipitação. Temperatura do ar média anual de aproximadamente 21°C, sendo o mês mais quente fevereiro (22,5°C) e mais frio julho (16,70°C). Os meses de janeiro e agosto são mais

e o menos úmidos com percentuais de 76,5% e 61,20% respectivamente. A nebulosidade é mais elevada no verão (61%) e menor no inverno (28%). O maior número de horas de brilho solar ocorre em agosto e o menor em fevereiro com totais aproximadamente de 229h e 176h, respectivamente (Escobedo et al., 2011; Teramoto e Escobedo, 2012; Rossi et al., 2018). A precipitação segue as evoluções da temperatura e da nebulosidade sendo constituída de dois intervalos distintos. O período chuvoso (outubro a março/primavera e verão) com maior precipitação no mês de janeiro (304 mm) e o período seco (abril a setembro/outono e inverno) com menor precipitação no mês de agosto (38 mm).

1.3.2 Obtenção e controle de qualidade das medidas

As medidas instantâneas (irradiância - W/m²) da radiação global (*I_g* - W/m²) foram obtidas com um piranômetro *Eppley-PSP* (Figura 1.7.a) e para medidas da radiação difusa (*I_d* - W/m²) um piranômetro *Eppley-PSP* (Figura 1.7.b) com anel de sombreamento (Melo e Escobedo, 1994) com as seguintes especificações: 80 cm de diâmetro, 10 cm de largura e 1mm de espessura.

Figura 1.7 - a) Piranômetro; b) Piranômetro com anel de sombreamento



Os valores da (*I_d*) foram corrigidos através de um fator de correção isotrópico (FC) dado pela Equação 18, para compensar a parcela da (*I_d*) obstruída pelo próprio anel, os quais dependem de parâmetros geométricos como largura e raio, geográficos como latitude e os astronômicos como a declinação solar (Oliveira et. al, 2002 a e b).

$$FC = \left[1 - \left(\frac{Hd'}{Hd} \right) \right]^{-1} \dots\dots\dots(18)$$

onde: (*H_d*) é a irradiação difusa (MJ/m²) de referência, obtida pelo método indireto, enquanto que (*Hd'*) é a irradiação difusa (MJ/m²) interceptadas durante o dia pelo anel de sombreamento. A razão (*H d' / Hd*) é calculada pela Equação 19.

$$\frac{Hd'}{Hd} = \left(\frac{2b}{\pi R} \right) * \cos(\delta) * \left[\frac{\cos(\phi + \delta)}{\cos \phi} \right]^2 * \int_0^\omega \cos \theta z * (d\omega) \dots\dots\dots(19)$$

onde: (b) e R são a largura e raio do anel, (δ) é a declinação solar (Equação 20), (ϕ) é a latitude local, (θ_z) é o ângulo zenital (Equação 21) e (ω_s) é o ângulo horário do sol (Equação 22), variando do nascer até o pôr do sol.

$$\delta = 23,45 * \sin[(360 * (Dj + 284))/365] \dots\dots\dots(20)$$

onde Dj é dia juliano.

$$\theta_z = \ar \cos (\sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega_s) \dots\dots\dots(21)$$

$$\omega_s = \cos^{-1}[-\tan(\phi) * \tan(\delta)] \dots\dots\dots(22)$$

Em geral as medidas da (I_d) realizadas pelos métodos de sombreamento são aplicadas somente correção isotrópica (Oliveira et al., 2002a e b; Soares et al., 2004; Codato et al., 2008; Kambezidis et al., 2017; Marques Filho et al., 2016) apesar da aplicação de correções anisotrópicas proporcionarem medidas mais eficazes (Simón-Martin et al., 2016 e 2017; Dal Pai et al., 2016). Neste estudo as correções anisotrópicas não foram aplicadas.

As medidas obtidas foram armazenadas em um sistema de aquisição de dados automáticos “*Datalogger*” *Campbell Cr23X* da *Campbell Scientific*. Estas medidas são digitalizados a cada 5 segundos, sendo armazenadas e transmitidas somente as médias realizadas após 5 minutos para um computador através de um módulo de armazenamento SM – 192. Após obtenção das medidas instantaneamente (irradiância - W/m^2) os dados foram integralizados em partições energéticas (irradiação - MJ/m^2) e separados em séries temporais horárias e diária (Chaves e Escobedo, 2000). Todos os equipamentos utilizados para as medidas foram aferidos pelo método comparativo a cada um ano, através de instrumentos adicionais específicos para esta finalidade.

A fração difusa (K_d) e a transmissividade atmosférica (K_T) foram calculadas pelas relações das medidas da irradiação difusa (H_d), irradiação global (H_g) e calculada da irradiação no topo da atmosfera (H_0) dadas pelas Equações 23 e 24.

$$K_d = H_d/H_g \dots\dots\dots(23)$$

$$K_T = H_g/H_0 \dots\dots\dots(24)$$

Os dados foram submetidos a uma análise de consistência para determinação dos valores a serem removidos, como valores discrepantes e com aplicação de filtros para limitação de (ω_s), da (H_g) em função de (H_0), de (K_T) e (K_d) conforme Tabela 1.1,

resultando em uma redução de aproximadamente 7% dos dados (De Miguel et al. 2001; Lopez et al. 2004; Younes et al., 2005; Ruiz-Arias et al. 2010; Ihya et al., 2015; Pashiardis et al., 2016). Deve-se observar que a limitação da fração difusa (K_d) para valores acima de um (1), refere-se aos valores obtidos em função da correção isotrópica que eleva os valores da fração difusa em condições de céu totalmente nublado.

Tabela 1.1 - Controle de qualidade

Tipo	Filtro
Ângulo horário (ω_s)	1. Limitação: Ângulo $\leq 10^\circ$
Irradiação global (H_g)	2. Limitação: $H_g \leq H_0$
Transmissividade atmosférica e fração difusa (K_T e K_d)	3. Limitação: $0 \leq K_T \leq 1$ e $0 \leq K_d \leq 1$

1.3.3 Modelo Estatístico (ME)

Para as estimativas com modelo estatístico foi utilizada a metodologia proposta por Liu e Jordan (1960) que relaciona (K_d) e (K_T) na partição horária, respectivamente, resultando em equações de estimativa ajustadas por regressão. O modelo estatístico foi elaborado e validado a partir de toda a base de dados que foi reorganizada conforme apresentado na Tabela 1.3. Para geração e validação destes modelos, aplicou-se uma técnica onde parte dos dados são utilizados para treinar o modelo (sem os dados de validação) e parte para validação.

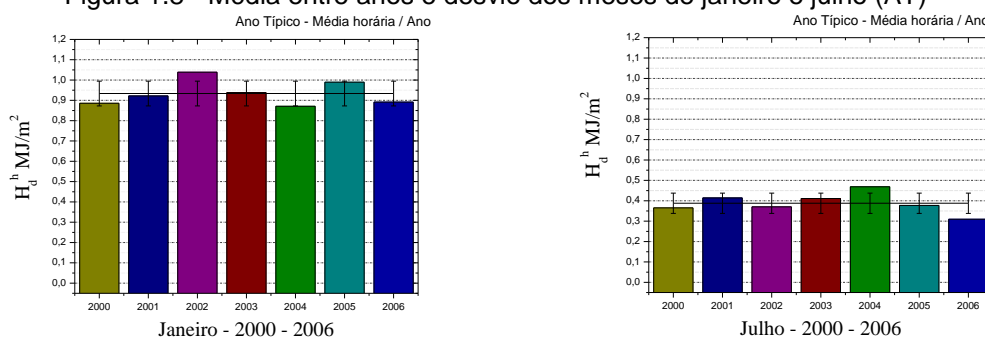
Para validação separou-se por médias de (H_d) um ano ideal, chamado de Ano Típico (AT), ou seja, a média dos meses de cada ano com valores mais próximos a média geral e os mais afastados da média geral de Ano Atípico (AAT). Essa reorganização possibilita validar os modelos com os dois extremos dos dados obtidos.

A reorganização foi realizada através de análises estatísticas, da média do valor de (H_d) de cada mês de toda a série, assim como o intervalo de variação do desvio padrão. Após análise, comparou-se para cada mês do ano o valor de (H_d), a média horária entre os anos, considerando o intervalo de variação do desvio padrão da média total do valor de (H_d), a média de cada ano. Na sequência foram selecionados para cada mês de toda a série, os valores mais próximos da média (acima ou abaixo), como Ano Típico (AT) e os mais afastados (acima ou abaixo), como Ano Atípico (AAT).

A Figura 1.8, apresenta os gráficos com a média e o intervalo do desvio padrão, para seleção dos meses, onde colunas representam a (H_d) horária média de cada ano e as linhas contínuas representam a (H_d) horária média entre os anos e o seu desvio padrão.

Conforme descrito, esta seleção dos meses que constituem um Ano Típico (AT), é similar ao processo de seleção de um Ano Meteorológico Típico (WMO, 1981).

Figura 1.8 - Média entre anos e desvio dos meses de janeiro e julho (AT)



A Tabela 1.2, apresenta os meses que constituem um Ano Típico (AT) com destaque para os meses de Janeiro/2003 e Julho/2005 onde os valores das irradiações médias entre os anos praticamente coincidiram com os valores das irradiações médias do ano.

Tabela 1.2 - Base do Ano Típico (AT) e Ano Atípico (AAT)

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
AT	2003	2000	2001	2001	2000	2001	2005	2001	2006	2006	2005	2001
AAT	2002	2003	2000	2004	2004	2002	2004	2000	2005	2005	2001	2005

Ao contrário o Ano Atípico (AAT), para os meses de Janeiro/2002 e Julho/2004, os valores das irradiações médias estão mais distantes da média.

O quantitativo de dados reorganizados para elaboração do modelo estatístico e validação é apresentado na Tabela 1.3.

Tabela 1.3 - Dados para elaboração e validação do modelo estatístico

Total de dados (2000 – 2006) 23.664 (100%)	Total de dados para elaboração do modelo estatístico	
	17.042 – 72,01%	
	Total de dados para validação das redes	
	Dados - Ano Típico (AT)	Dados - Ano Atípico (AAT)
	3.387 – 14,31%	3.236 – 13,67%

1.3.4 Técnicas de Aprendizado de Máquina (TAM)

Para estimativas com as TAM foram elaborados *scripts* de treinamento e validação usando o *software* MATLABR2014a e para implementação das técnicas foi necessário definir as variáveis e arranjos empregados no treinamento e validação.

A definição dos arranjos depende da quantidade de variáveis e amostras que podem limitar o aprendizado. Um número reduzido de variáveis e amostras de entrada pode não ser suficiente para aprendizado da rede por falta de informações não generalizando o problema. Com um número excessivo, principalmente de variáveis, o

treinamento pode ficar comprometido para algumas redes, pois aumenta a complexidade do aprendizado e o tempo de processamento, principalmente para as redes que são dependentes do número de amostras.

Neste estudo optou-se em utilizar variáveis considerando sua disponibilidade, importância, período de medidas e características físicas em relação a variável a ser estimada. Não foi realizada uma análise estatística para reduzir ou eliminar sobreposições de valores, nem para verificar as mais representativas ou preponderantes. Para o treinamento das redes é importante destacar a normalização dos valores medidos a fim de que todas as variáveis, independentemente de sua grandeza física, tenha a mesma dimensão.

Foi definida uma sequência de arranjos (Tabela 1.5) de variáveis medidas na Estação ou calculadas como entrada para as redes. Os valores medidos das variáveis da Tabela 1.4 consistem em valores da irradiação global (H_g - MJ/m²), irradiação de ondas longas atmosférica (H_{wa} - MJ), umidade (umid - %) e temperatura (tar - °C) e calculados como irradiação no topo da atmosfera (H_0 - MJ/m²), a transmissividade atmosférica (K_T), da declinação solar ($decsol$ - °C) e nebulosidade ($nebul$, - %). A nebulosidade ($nebul$ - %) foi calculada em função da proporcionalidade das medidas horárias da (I_b - W/m²) abaixo de 120 W/m². Conforme a WMO (2008), em seu guia de instrumentos meteorológicos e métodos de observação, este valor é adotado com limiar para o brilho do sol, ou seja, para valores inferiores a esses, considera-se sem insolação. Outros arranjos foram analisados, porém em função das condições de seleção das variáveis, os mesmos não foram utilizados.

Tabela 1.4 - Combinações e variáveis de entrada

Variáveis de:		
Combinações	Entrada	Saída
combinação 1	Kt	K _d
combinação 2	Kt, H ₀	
combinação 3	Kt, H ₀ , H _g	
combinação 4	Kt, H ₀ , H _g , H _{wa}	
combinação 5	Kt, H ₀ , H _g , H _{wa} , decsol	
combinação 6	Kt, H ₀ , H _g , H _{wa} , decsol, nebul	
combinação 7	Kt, H ₀ , H _g , H _{wa} , decsol, nebul, umid	
combinação 8	Kt, H ₀ , H _g , H _{wa} , decsol, nebul, umid, tar	

Assim como no ME para TAM a base de dados foi reorganizada a fim de retirar os dados para treinamento e validação do modelo conforme apresentado na Tabela 1.5.

Tabela 1.5- Dados para elaboração e validação das redes

Total de dados (2000 – 2006) 23.664 (100%)	Total de dados para treinamento das redes	
	Dados - Ano Típico (AT)	Dados - Ano Atípico (AAT)
	20.277 - 85,68%	20.428 - 86,32%
	Total de dados para validação das redes	
	Dados - Ano Típico (AT)	Dados - Ano Atípico (AAT)
	3.387 - 14,31%	3.236 - 13,67%

Definidas as combinações para treinamento das redes (Tabela 1.5), apresenta-se na sequência a metodologia para treinamento de cada rede.

1.3.4.1 Treinamento da MLP

O treinamento da rede MLP foi realizado com o algoritmo *Levenberg-Marquadt* (*trainlm*) a fim de tornar o processo de convergência mais eficiente. No processamento da rede foi utilizada a função *feedforwardnet* e parametrizado pelo número de camadas ocultas, pelo número de neurônios, da quantidade máxima de épocas de treinamento e das funções de ativação das camadas ocultas e de saída. A definição do número de camadas foi realizada em duas fases, sendo a primeira com uma camada escondida (n_1) e a segunda inserindo-se mais uma camada (n_2). O número de neurônios iniciais para cada camada escondida foram definidas em partes atendendo os valores mínimos, proposto por Fletcher e Gloss (1993) e apresentados na Tabela 1.6.

O número máximo de épocas foi fixado em mil (1.000) interações e a função de ativação das camadas ocultas a tangente hiperbólica (*tansig*) definida conforme as características dos dados de entrada e na saída uma função linear. A parametrização da primeira fase foi idêntica à segunda fase.

Tabela 1.6- Valores para parametrização da rede MLP

Topologias	1	2	3	4	5	6
nº de neurônios	5	10	20	40	80	160

Nas duas fases são realizados dez (10) treinamentos para cada combinação (Tabela 1.4) testando todas as topologias da Tabela 1.6. O critério de treinamento é a validação cruzada (70% treinamento, 15% para validação e 15% para teste). Em cada interação (épocas) os erros (EQM – Erro quadrático médio) entre os valores estimados e medidos da validação são avaliados e se forem diminuindo significa que a rede está aprendendo até que este erro comece a aumentar durante uma sequência de seis (6) interações (épocas) sucessivas. Caso este erro da validação no treinamento aumentar, enquanto do treinamento continuar caindo, é provável que a rede esteja

com *overfitting*, condição que indica a parada do treinamento. Este critério minimiza o risco de *underfitting* da rede.

Sendo definida a melhor rede em cada treinamento (menor EQM do treinamento) todas as combinações são validadas com os dados reorganizados (Tabela 1.5) em cada fase e escolhida a fase e a combinação que apresentar o melhor desempenho na validação.

1.3.4.2 Treinamento da RBF

Nesta arquitetura, o treinamento utilizou a função *newrbe* onde com este algoritmo todos os parâmetros aplicados a rede são dependentes dos dados de entrada, do ajuste dos pesos e que está associado ao posicionamento das funções gaussianas e de sua largura.

O treinamento da rede acontece em duas fases, sendo a primeira não supervisionada e a segunda supervisionada. Todas as combinações (Tabela 1.4) são testadas com todos os valores definidos na parametrização do intervalo do ajustamento (Tabela 1.7). Este ajustamento (σ) controla o raio de influência da função Gaussiana e seu valor é determinado de forma empírica a fim de se obter o menor valor no índice de precisão da validação cruzada. Em relação a quantidade de neurônios, a função escolhida inicia o treinamento com o mínimo incrementado automaticamente a cada interação em função do erro. Este processo é repetido até que se atinja o número máximo de neurônios da camada escondida, ou seja, o número de amostra das variáveis de entrada. São definidos os valores de ajustamento para cada combinação e para validação aquelas com menor EQM em seu treinamento.

A melhor combinação é definida por aquela que apresentar o menor valor da raiz do erro quadrático médio (RMSE) da validação. O critério de parada da rede RBF é o número de épocas fixado em 200 épocas.

Tabela 1.7 - Valores do ajustamento da função da rede RBF

Ajustamento (spread)	20	10	5	1	0.5	0.1	0.01
----------------------	----	----	---	---	-----	-----	------

1.3.4.3 Treinamento da GRNN

O treinamento da rede do tipo GRNN utiliza a função *newrgrnn* e sua parametrização acontece definindo-se os dados de entrada, de saída e do ajustamento, que define a abertura da função de ativação que nesta arquitetura a gaussiana. Destaca-se que a abertura define o quanto de unidades ou neurônios serão levados em consideração para estimativa.

O ajuste do parâmetro *spread* foi realizado testando-se um conjunto de valores (Tabela 1.8) definido empiricamente para cada combinação (Tabela 1.4) sendo o melhor aquele com menor EQM no treinamento. Importante destacar que nesta arquitetura o treinamento acontece de forma não supervisionada, tornando-a instável dependendo dos valores de ajustamento. Nesta técnica, conforme se aumenta o ajustamento (σ) aumenta-se a área em torno do vetor de entrada onde os neurônios da primeira camada respondam com saídas significativas, porém quando se reduz o ajustamento (σ) torna a função de base radial íngreme fazendo com que o neurônio com o vetor de peso mais próximo da entrada tem uma saída muito maior do que outros neurônios tendendo a responder com o vetor de saída muito próximo ao vetor de entrada.

Tabela 1.8 - Valores do ajustamento da função da rede GRNN

Ajustamento (spread)	5	3	1	0.3	0.1	0.07	0.05	0.03	0.01
----------------------	---	---	---	-----	-----	------	------	------	------

A melhor combinação é aquela que apresentar o menor valor da raiz do erro quadrático médio (RMSE) da validação. O critério de parada do treinamento da rede é o número de época definido na parametrização fixado em 200 interações.

1.3.4.4 Treinamento da ANFIS

No *script* para treinamento da rede ANFIS utilizou-se a função *genfis2* que utiliza um algoritmo de clusterização substrativa pela qual gera uma estrutura FIS (*Fuzzy Inference System*) do tipo Takagi e Sugeno (1985). Este método proporciona um treinamento, a princípio, com baixo esforço computacional em relação a outros algoritmos quando se aumenta o número de variáveis. Na parametrização da rede deve-se definir o ajustamento que neste estudo foi testado conforme Tabela 1.9 com todas as combinações (Tabela 1.4). A melhor combinação é aquela com o ajuste de menor EQM do treinamento. Este ajuste (*radii*) define qual é o vetor que especifica o alcance de influência do centro do *cluster* em cada dimensão de dados e o número de épocas de interação. Importante também definir o número e o tipo de funções de pertinência que neste treinamento foi fixado em duas funções e a função, do tipo gaussiana. O desempenho da rede ANFIS está relacionado aos parâmetros de ajuste, quantidade de regras (funções de pertinências tipo gaussiana) e variáveis de entrada (Lezanski, 2001).

Tabela 1.9 - Valores do ajustamento da função para ANFIS.

Ajustamento (radii)	0.2	0.3	0.4	0.5	0.6	0.7	0.8	0.9	1
---------------------	-----	-----	-----	-----	-----	-----	-----	-----	---

A melhor combinação é aquela que apresentar o menor valor da raiz do erro quadrático médio (RMSE) da validação. O critério de parada do treinamento da ANFIS neste caso é o número de épocas fixado em 200 interações.

1.3.5 Indicativos Estatísticos

Os indicativos estatísticos do treinamento das redes foram o EQM - Erro Quadrático Médio (*Mean Square Error*) que indica o erro médio entre os valores estimados e medidos, quanto menores, melhores os resultados. Os indicativos de validação foram o RMSE, Raiz Quadrada do Erro Quadrático Médio (*Root Mean Square Error*) que permitem verificar a proporção do valor real do erro produzido pelo modelo, sendo os valores menores indicando um desempenho melhor para os modelos gerados, testados ou treinados e validados, ou seja, mostra o desempenho do modelo quanto ao seu espalhamento. O R^2 , coeficiente de determinação que permite verificar o quanto a variação da variável dependente é explicada pela variação da variável independente através da equação do modelo, e r , coeficiente de correlação que permite verificar o quanto o valor medido se aproxima do valor estimado, ou seja, a correlação existente entre eles. Valor mais próximos de 1 são aqueles onde os valores estimados são próximos aos valores medidos (Stone, 1993; Escobedo et al. 2011). Os indicadores são obtidos pelas seguintes relações:

$$EQM = \left[\frac{\sum_{i=1}^N (Ei - Mi)^2}{N} \right]$$

$$RMSE = 100 * \frac{[\frac{\sum_{i=1}^N (Ei - Mi)^2}{N}]^{1/2}}{\bar{M}}$$

$$R^2 = \left(\frac{\sum_{i=1}^N (Mi - \bar{M})^2 * \sum_{i=1}^N (Ei - \bar{E})^2}{\sqrt{\sum_{i=1}^N (Mi - \bar{M})^2} * \sqrt{\sum_{i=1}^N (Ei - \bar{E})^2}} \right)^2$$

$$r = \left(\frac{\sum_{i=1}^N (Mi - \bar{M}) * \sum_{i=1}^N (Ei - \bar{E})}{\sqrt{\sum_{i=1}^N (Mi - \bar{M})^2} * \sqrt{\sum_{i=1}^N (Ei - \bar{E})^2}} \right)$$

onde: Ei são os valores estimados, \bar{E} , é a média dos valores estimados, Mi são os valores medidos, \bar{M} é a média dos valores medidos, N é o número de observações.

Na sequência são apresentados os resultados e discussões do modelo estatístico e das técnicas de aprendizado de máquina na estimativa de (K_d).

1.4 RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados e as discussões obtidas para estimativa de (K_d) do modelo ME com uma variável de referência a (K_T) e por meio das Técnicas de Aprendizado de Máquina: MLP, RBF, GRNN e ANFIS, com variáveis astronômicas, meteorológicas e geográficas (K_T , H_o , H_g , H_{wa} , $decsolar$, $nebul$, $umid$ e tar). Ao final, indicadores encontrados em trabalhos similares da literatura.


1.4.1 Modelo Estatístico

O modelo ME elaborado a partir das medidas calculadas de (K_d) e (K_T) é representado pela Equação (25) obtida e ajustada por regressão polinomial de 4ª ordem com um coeficiente de determinação na ordem de $R^2 = 0,7999$ o que demonstra que (K_d) está correlacionado com (K_T) estatisticamente.

$$K_d = 0,9249 + 1,117642 * K_T - 5,34748 * K_T^2 + 2,28867 * K_T^3 + 1,22483 * K_T^4 \dots\dots\dots(25)$$

Outros equações de ordem inferior e superior foram geradas mas não resultaram em melhorias do coeficiente de determinação. A Figura 1.9 (a) mostra a curva de regressão gerada e as curvas de validação (Figura 1.9 (b) e (c)).

Figura 1.9 - a) Curva de dispersão de (K_d) x (K_T); validação b) AT; c) AAT



Os indicativos estatísticos RMSE e o r para Ano típico (AT) e Ano atípico (AAT) resultantes da análise na validação dos modelos ME são apresentados na Tabela 1.10.

Tabela 1.10 - Índices estatísticos – ME

Partição Horária		Indicadores estatísticos			
Variáveis de:					
Entrada	Saida	Ano típico (AT)		Ano atípico (AAT)	
Modelo Estatístico - ME		RMSE (%)	r	RMSE (%)	r
K_t	K_d	30.58	0.8984	28.12	0.8894

A curva obtida (Figura 1.9 (a)) de (K_d) em função de (K_T) ilustra uma dependência da fração difusa com as condições de cobertura total de céu e que estão

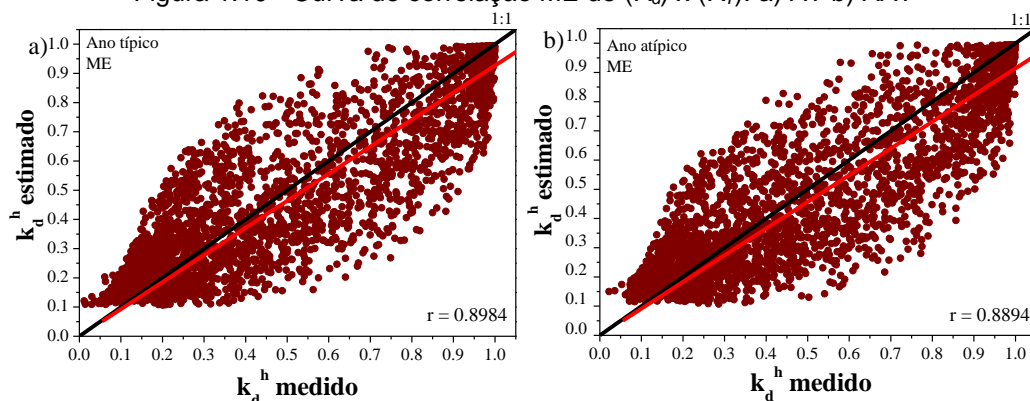
relacionados com as variações de constituintes atmosféricos como nuvens, vapor de água e aerossóis.

Observa-se uma variabilidade de (K_d) para um mesmo valor de (K_T) elevado na maioria das condições de cobertura de céu ($0 < K_T < 1$). Para cada valor de (K_T) há um largo intervalo de variação em valores (K_d) . Este espalhamento ocorre pois há uma variação das concentrações dos constituintes atmosféricos que absorvem e espalham as radiações, diferentemente com maior ou menor intensidade em função da sazonalidade, para mesmos valores de (K_T) . Além disto, é possível observar também que os valores de (K_d) decrescem lentamente no sentido do aumento de (K_T) . Isto se justifica em função do aumento ou da diminuição da quantidade destes constituintes onde os valores de (K_d) são maiores para cobertura nebulosa (valores de (K_T) menores) e menores na condição de céu aberto (valores de (K_T) maiores).

O desempenho do modelo estatístico é apresentado na Figura 1.9 (b) e 1.9 (c) através das curvas de dispersão geradas na validação para Ano típico (AT) e atípico (AAT), com os valores dos dados medidos, de validação e da estimativa.

O modelo estatístico na base AT apresenta uma correlação na ordem de $r = 0.8984$ e raiz quadrada do erro quadrático médio $RMSE = 30.59\%$ assim como na base de validação AAT, com uma correlação $r = 0.8894$ e raiz quadrada do erro quadrático médio $RMSE = 28.12\%$. A Figura 1.10 (a) e 1.10 (b) mostra as curvas de correlação de cada validação. Nas figuras, as retas de correlação (apresentam uma distribuição uniforme com a reta ideal 45°) dos valores estimados pelos medidos nas duas bases de validação, com coeficiente de correlação $r_{AT} = 0.8984$ e $r_{AAT} = 0.8894$, mostrando que a Equação (25) gerada pelo modelo estatístico pode ser utilizada na estimativa da (K_d) na partição horária.

Figura 1.10 - Curva de correlação ME de $(K_d) \times (K_T)$: a) AT b) AAT



A dispersão existente entre os valores medidos e estimados é resultante das mudanças atmosféricas, que em partições de tempo menores são mais sensíveis, pois acontecem ao longo do dia e da hora, fazendo com que (K_d) tenha uma variação maior para um mesmo valor de (K_T), reforçando o descrito por Paulescu e Blaga (2016) e Furlan et al. (2012) que justificam a importância de (K_T) na estimativa da fração difusa.

Na Tabela 1.11 são apresentados alguns indicadores encontrados do r e/ou de RMSE de alguns modelos apresentados na literatura para estimativa de (K_d) e o melhor resultado obtido do modelo ME para partição horária nas duas bases de validação. Os resultados demonstram uma similaridade dos indicadores independentemente do local das medidas, o que os tornam eficazes para estimativa da fração difusa. A maioria dos modelos utiliza somente a transmissividade atmosférica (K_T) como variável de referência o que a torna um importante parâmetro para estimativa de (K_d). Outros modelos que incluem mais de um parâmetro de referência apresentam resultados próximos aos praticados com uma variável.

Tabela 1.11 – Índices estatísticos - outras localidade e ME para Botucatu

Autores	Localidade	r	RMSE %
Chandrasekaran and Kumar, (1994)	Madras/Índia	-	29,20
Oliveira et al. (2002a)	São Paulo/São Paulo	0,92	27,98
Jacovides e Tymvios. (2006)	Cyprus/ Grécia	0,96	28,40
Furlan et al. (2012)	São Paulo/São Paulo	0,96	-
Kuo et al. (2014b)	Tawian/China	-	8,4 a 17,34
Paulescu e Blaga (2016)	Timissora/Romenia	0,93	-
ME AT – Proposto 2018	Botucatu/São Paulo	0,89	30,58
ME AAT – Proposto 2018	Botucatu/São Paulo	0,88	28,12

1.4.2 Técnicas MLP, RBF, GRNN e ANFIS

São apresentados na Tabela 1.12 os melhores indicativos estatísticos após treinamento e validação das redes MLP, RBF, GRNN e ANFIS de cada arranjo da Tabela 1.4. Todas as técnicas foram treinadas com as combinações propostas como entradas e ajustadas conforme as parametrizações sugeridas. Importante destacar que os resultados encontrados referem-se às condições de treinamento e validação com os dados obtidos para este estudo.

Tabela 1.12 - Indicadores e configurações das redes MLP, RBF, GRNN e ANFIS

Configuração e parametrização das Técnicas de Aprendizado de Máquinas - Partição horária																
REDE MLP																
Para Ano típico (AT)				Indicadores estatísticos					Para Ano Atípico (AAT)				Indicadores estatísticos			
	Função de ativação	Camada: 1/2 ou ajustamento	Épocas	Treinamento		Validação			Função de ativação	Camada: 1/2 ou ajustamento	Épocas	Treinamento		Validação		
				MSE	RMSE (%)	MSE	RMSE (%)	r				MSE	RMSE (%)	MSE	RMSE (%)	r
Combinação 1	Tang. Hiperb.	n1:80/n2:10	4	0.0185	30.52	0.0193	30.42	0.8996	Tang. Hiperb.	n1:5/n2:80	11	0.0184	31.05	0.0203	27.86	0.8916
Combinação 2	Tang. Hiperb.	n1:20/n2:5	14	0.0124	24.98	0.0131	25.03	0.9332	Tang. Hiperb.	n1:20/n2:80	5	0.0122	25.30	0.0135	22.70	0.9295
Combinação 3	Tang. Hiperb.	n1:40/n2:5	10	0.0124	24.94	0.0130	24.99	0.9334	Tang. Hiperb.	n1:10/n2:80	5	0.0123	25.37	0.0135	22.70	0.9294
Combinação 4	Tang. Hiperb.	n1:40/n2:10	15	0.0117	24.21	0.0123	24.26	0.9374	Tang. Hiperb.	n1:20/n2:5	25	0.0116	24.59	0.0128	22.07	0.9335
Combinação 5	Tang. Hiperb.	n1:20/n2:5	30	0.0113	23.85	0.0123	24.25	0.9374	Tang. Hiperb.	n1:10/n2:5	44	0.0114	24.38	0.0126	21.91	0.9345
Combinação 6	Tang. Hiperb.	n1:20/n2:10	21	0.0092	21.46	0.0095	21.34	0.9519	Tang. Hiperb.	n1:20/n2:10	21	0.0089	21.57	0.0101	19.63	0.9477
Combinação 7	Tang. Hiperb.	n1:10/n2:10	12	0.0088	20.97	0.0093	21.11	0.9530	Tang. Hiperb.	n1:20/n2:5	23	0.0085	21.05	0.0097	19.28	0.9496
Combinação 8	Tang. Hiperb.	n1:20/n2:20	23	0.0075	19.47	0.0088	19.59	0.9553	Tang. Hiperb.	n1:20/n2:5	23	0.0078	20.15	0.0095	18.75	0.9511
REDE RBF																
Combinação 1	Gaussiana	1	200	0.0187	30.63	0.2348	88.44	0.0000	Gaussiana	20	200	0.0186	31.20	0.2346	88.40	0.0000
Combinação 2	Gaussiana	20		0.0132	25.75	0.2346	88.40	0.0000	Gaussiana	1		0.0123	25.33	0.0138	22.92	0.9280
Combinação 3	Gaussiana	5		0.0126	25.18	0.0133	25.28	0.9318	Gaussiana	1		0.0122	25.22	0.0138	22.93	0.9279
Combinação 4	Gaussiana	20		0.0121	24.71	0.0139	25.79	0.9289	Gaussiana	5		0.0118	24.82	0.0132	22.45	0.9310
Combinação 5	Gaussiana	20		0.0117	24.22	0.0156	27.32	0.9198	Gaussiana	20		0.0116	24.60	0.0139	23.06	0.9271
Combinação 6	Gaussiana	s indicador		s indicador	s indicador	s indicador	s indicador	s indicador	Gaussiana	20		0.0079	20.30	0.0303	34.03	0.8331
Combinação 7	Gaussiana	s indicador		s indicador	s indicador	s indicador	s indicador	s indicador	Gaussiana	0,1		0.0000	0.00	0.8744	182.65	0.0000
Combinação 8	Gaussiana	s indicador		s indicador	s indicador	s indicador	s indicador	s indicador	Gaussiana	0,1		0.0000	0.00	0.8911	184.38	0.0000
REDE GRNN																
Combinação 1	Gaussiana	0,01	200	0.0184	31.02	0.0193	30.42	0.8995	Gaussiana	0,01	200	0.0184	31.02	0.0204	27.90	0.8912
Combinação 2	Gaussiana	0,03		0.0118	24.31	0.0134	25.33	0.9315	Gaussiana	0,03		0.0116	24.67	0.0143	23.35	0.9251
Combinação 3	Gaussiana	0,05		0.0116	24.19	0.0133	25.26	0.9319	Gaussiana	0,07		0.0120	25.07	0.0141	23.22	0.9261
Combinação 4	Gaussiana	0,07		0.0107	23.22	0.0127	24.64	0.9353	Gaussiana	0,07		0.0106	23.51	0.0138	22.96	0.9277
Combinação 5	Gaussiana	0,1		0.0046	15.16	0.0185	29.79	0.9039	Gaussiana	0,1		0.0046	15.43	0.0194	27.24	0.8967
Combinação 6	Gaussiana	0,3		0.0070	18.71	0.0196	30.63	0.8981	Gaussiana	0,3		0.0067	18.67	0.0225	29.33	0.8790
Combinação 7	Gaussiana	5		0.0281	37.56	0.0306	38.32	0.8350	Gaussiana	3		0.0234	35.01	0.0317	34.80	0.8246
Combinação 8	Gaussiana	5		0.0271	36.91	0.0307	38.34	0.8348	Gaussiana	5		0.0269	37.50	0.0317	34.79	0.8247
REDE ANFIS																
Combinação 1	Gaussiana	0.4	200	0.0186	30.60	0.0193	30.43	0.8995	Gaussiana	0.2	200	0.0185	31.06	0.0204	27.90	0.8912
Combinação 2	Gaussiana	0.4		0.0125	25.02	0.0131	25.05	0.9331	Gaussiana	0.5		0.0124	25.47	0.0136	22.80	0.9288
Combinação 3	Gaussiana	0.4		0.0124	25.00	0.0131	25.02	0.9332	Gaussiana	0.4		0.0124	25.43	0.0136	22.80	0.9288
Combinação 4	Gaussiana	0.6		0.0119	24.46	0.0124	24.34	0.9369	Gaussiana	0.4		0.0117	24.76	0.0129	22.18	0.9327
Combinação 5	Gaussiana	0.7		0.0119	24.44	0.0127	24.70	0.9350	Gaussiana	0.6		0.0119	24.90	0.0133	22.52	0.9306
Combinação 6	Gaussiana	0.8		0.0102	22.66	0.0106	22.49	0.9464	Gaussiana	0.8		0.0100	22.85	0.0112	20.71	0.9417
Combinação 7	Gaussiana	0.7		0.0100	22.47	0.0104	22.33	0.9472	Gaussiana	0.6		0.0100	22.84	0.0115	20.93	0.9403
Combinação 8	Gaussiana	0.8		0.0100	22.37	0.0106	22.58	0.9460	Gaussiana	0.9		0.0100	22.81	0.0109	20.38	0.9435

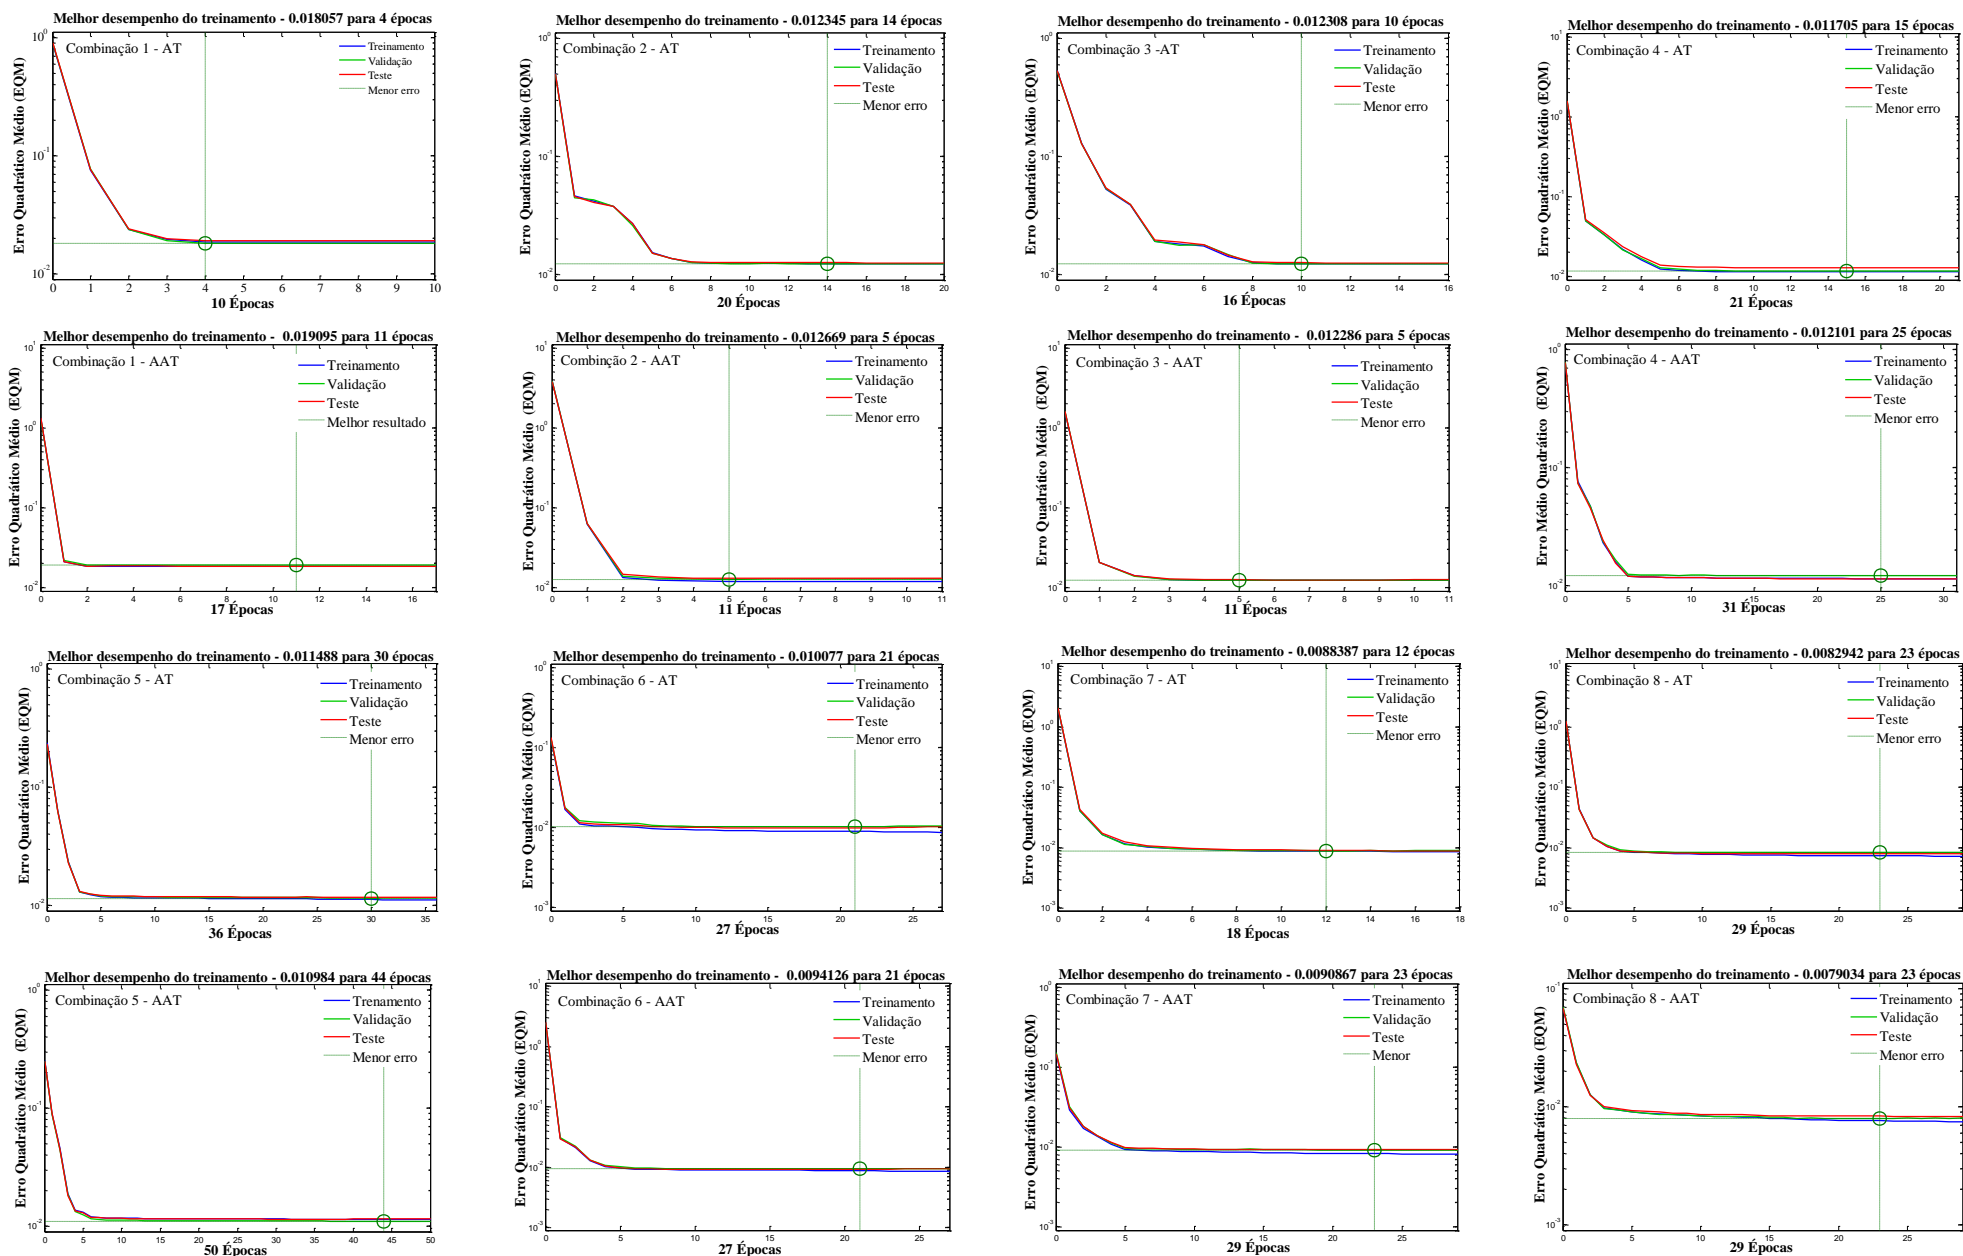
Analisando os dados dos indicadores estatísticos da (K_d) (Tabela 1.12) observa-se que o índice de correlação (r) nas duas bases de validação com a rede MLP variando entre 0,8916 a 0,9553, com a rede RBF entre 0 a 0,9318, com a rede GRNN entre 0,8247 a 0,9353 e com a ANFIS entre 0,8912 a 0,9472 apresentaram, a princípio, uma correlação próxima ao valor ideal (1) em todas as combinações das redes MLP, GRNN e ANFIS. Já a rede RBF apresentou limitações com algumas combinações. Uma boa correlação com as combinações 3, 4 e 5 para AT e 2, 3, 4, 5 e 6 para AAT, mostrando que a técnica não assegura sempre uma boa eficiência e que a inserção de variáveis não proporciona melhores correlação apesar da influência individual de cada variável para radiação difusa. Esta situação pode estar relacionada principalmente ao número de amostras como também na quantidade de variáveis utilizadas como entrada.

Já os índices de desempenho RMSE, em ambas bases de validação para as técnicas MLP, variou de 18,75% a 30,42%, para rede GRNN entre 22,96 a 38,34% e para ANFIS entre 20,38% a 30,43%. Para rede RBF este indicador variou entre 25,28% a 27,3% para as combinações 3, 4 e 5 para AT e de 22,45% a 34,03% para as combinações 2, 3, 4, 5 e 6 para AAT e as demais combinações, em ambas as bases, variando entre 88,40% a 184,38%, seguindo a mesma tendência do coeficiente de correlação o que a torna uma rede instável para estimativa da fração difusa.

Analisando as técnicas é possível verificar que a rede MLP apresenta os melhores resultados de validação quando todas as variáveis de entrada (combinação (8)) participam do treinamento. Com função de ativação tangente hiperbólica para camada oculta e linear para camada de saída. Nesta arquitetura foram utilizadas duas (2) camadas escondidas e dez (10) treinamentos realizados para cada combinação. A melhor combinação foi aquela que apresentou o menor EQM no treinamento. Outros arranjos foram experimentados, mas não resultaram em melhorias dos indicadores.

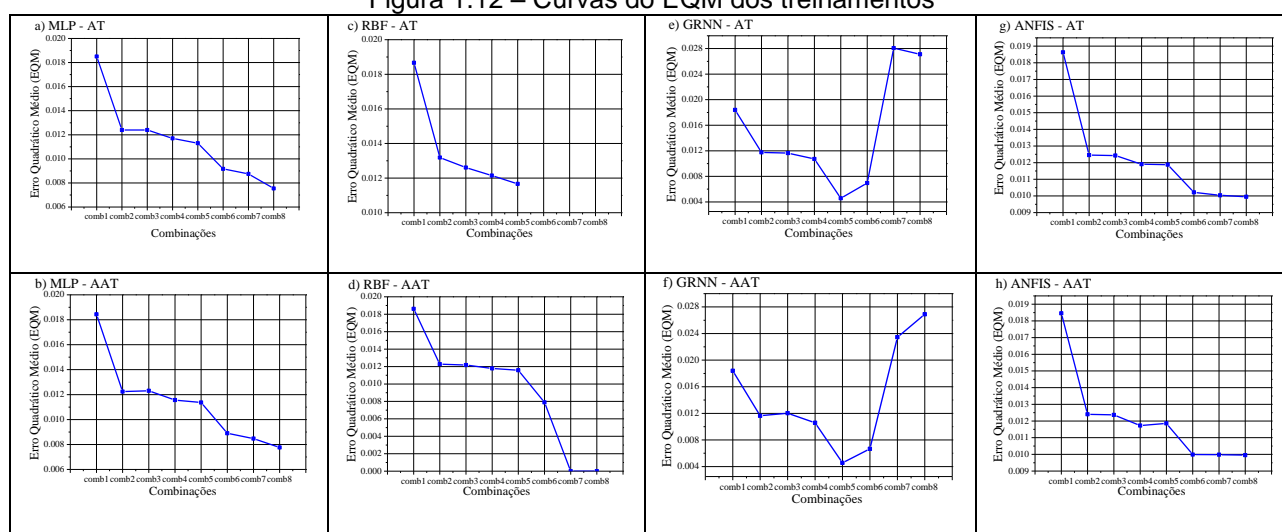
Os gráficos da Figura 1.11 apresentam o comportamento das melhores curvas do EQM e o número de épocas utilizadas em todas as combinações treinadas pela rede MLP. Observa-se, no destaque (linha tracejada e círculo verde), os pontos com o menor erro do treinamento. Além disto a forma com que os gráficos se apresentam (Figura 1.11) através das curvas (amortecimento suave) e da quantidade de épocas caracterizam um treinamento sem dificuldades e complexidade de aprendizagem causados, principalmente, pelas características numéricas e de comportamento das variáveis de entrada.

Figura 1.11 - Curva de desempenho do treinamento da rede MLP



São apresentadas na Figura 1.12 (a) a (h) as curvas do EQM geradas de cada combinação, o que mostra a importância de outras variáveis participarem do treinamento. Conforme a inserção de variáveis na entrada ocorre uma redução progressiva do EQM na maioria das redes. Essa característica mostra que as redes estão aprendendo com o treinamento. A rede GRNN apresentou a partir da combinação (5) uma instabilidade no treinamento que pode ser causada pelas características físicas da variável ou da quantidade de amostra.

Figura 1.12 – Curvas do EQM dos treinamentos



Para rede RBF foi utilizada como função de ativação a gaussiana em todas as combinações e ajustes sugeridos (Tabela 1.7). Os melhores resultados na validação foram com as combinações 3 para base AT e 4 para base AAT. Observa-se no gráfico da Figura 1.12 (c), base AT, que a inserção das variáveis de entrada não promoveu a generalização do problema a partir da combinação (5) do que se pode concluir que não houve capacidade de aprendizado nas combinações (6, 7 e 8), mesmo testando todos os ajustamentos da Tabela 1.7. Para base de validação AAT (Figura 1.12 (d)) a partir da combinação (6) a inserção das variáveis de entrada promoveu o *overfitting* da rede. A partir dos arranjos (7 e 8) a rede perdeu a capacidade de aprendizado e em consequência a generalização do problema. Esta situação é provocada quando há um número excessivo de neurônios ou pelo excesso de épocas no treinamento. Foram realizados treinamentos com uma quantidade maior de interação, mas não resultaram em melhoria dos indicadores estatísticos.

A rede GRNN utilizou como função de ativação a gaussiana e seu treinamento realizado em tempo bem menor que as redes MLP e RBF. Isto acontece em função do treinamento que é realizado de forma não supervisionada. Isto faz com que essa

arquitetura seja mais instável principalmente na definição do ajustamento que acontece de forma empírica. Esta instabilidade faz com que a rede reconheça os dados estimados iguais aos medidos. Esta arquitetura apresentou os melhores resultados na validação com quatro (4) variáveis de entrada (combinação (4)) em ambas as bases AT e AAT. Diferentemente da rede anterior (RBF) apresentou *underfitting* a partir da combinação (5), como pode ser observado através dos gráficos da Figura 1.12 (e) e (f). A partir da combinação (6) o EQM começou a aumentar não sendo capaz de generalizar o problema. Neste caso específico, esta situação pode estar relacionada com número insuficiente de neurônios utilizados no treinamento.

Com a técnica ANFIS foram definidos o tipo e a quantidade de função de pertinência (gaussiana). Outras funções como a triangular e a trapezoidal também foram testadas, mas não proporcionaram resultados melhores e demandou de um tempo maior de processamento. Não foi possível realizar o treinamento com um número maior de funções, pois demandava também de um esforço computacional e maior tempo de processamento. Os melhores resultados na validação com a base AT e AAT foram quando sete (7) e oito (8) variáveis participaram do treinamento. Conforme as variáveis de entrada são introduzidas no treinamento o EQM diminui promovendo (Figura 1.12 (g) e (h)) a generalização do problema para este caso e parametrização específico. Outras parametrizações de ajustamento e de funções de pertinências foram testadas, mas não resultaram em melhoria dos indicadores.

Analisando os indicadores da Tabela 1.12 em relação aos indicadores apresentados na Tabela 1.10 (indicadores de correlação e desempenho do modelo estatístico), todas as técnicas utilizadas apresentaram um desempenho superior. Em média uma redução do RMSE para rede MLP de aproximadamente 53%, para rede RBF de 25%, para rede GRNN 23% e para ANFIS de 37%.

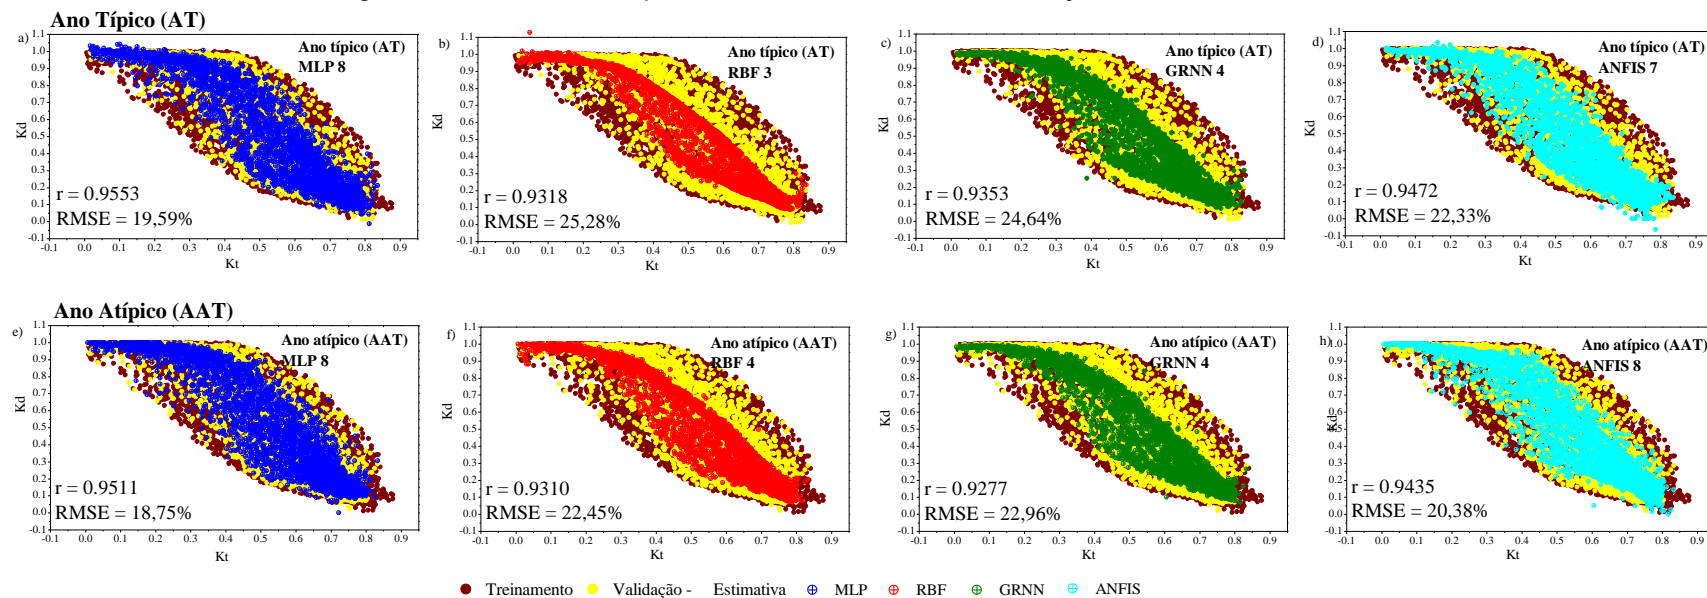
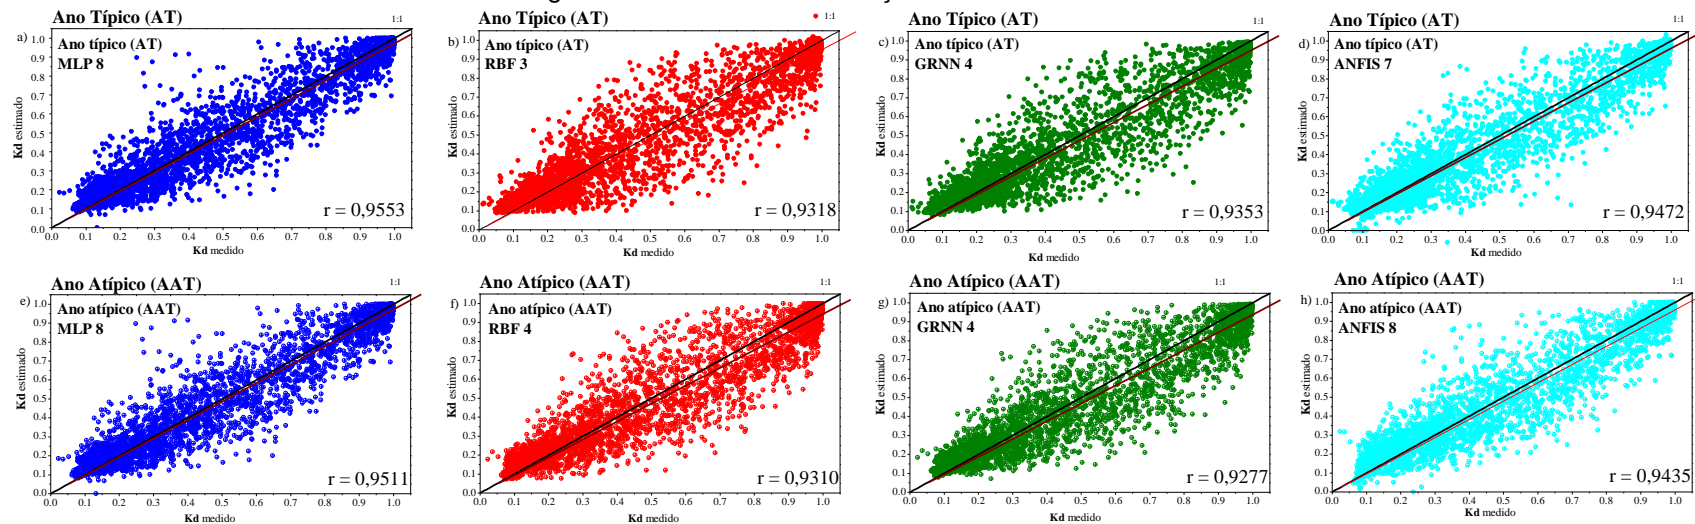
Para rede MLP e ANFIS, a inserção de outras variáveis no treinamento proporcionaram os melhores resultados de validação (Figura 1.12 (a), (b), (g) e (h)) com a diminuição do EQM após a inserção das variáveis no treinamento. Uma vantagem na utilização da rede MLP está principalmente na parametrização e no tempo de treinamento. Diferentemente da ANFIS que é dependente do número de funções de pertinência e do número de variáveis demandando de tempo de treinamento e esforço computacional maior. Estes aspectos estão relacionados com as características de treinamento (supervisionado), das variáveis e da quantidade de dados utilizados.

Com as redes RBF e GRNN nem todas as combinações proporcionaram resultados menores, sendo características da forma de treinamento e da parametrização realizada. Apesar da rede RBF possuir dois estágios de treinamento, tem a desvantagem na sua parametrização, restrita ao ajustamento da abertura da função gaussiana e do número de neurônios que depende da quantidade de amostra a ser utilizado. A rede GRNN apesar da rapidez de seu treinamento e dos resultados encontrados tem como desvantagem a falta de um treinamento supervisionado e a forma pela qual seu ajustamento acontece que pode resultar em valores estimados iguais aos valores medidos.

As Figuras 1.13 e 1.14 mostram a dispersão dos valores estimados e a correlação entre os valores estimados e medidos da fração difusa gerados pelas redes MLP, RBF, GRNN e ANFIS com as duas bases de validação (AT e AAT).

Na Figura 1.13, as curvas obtidas também apresentam uma variabilidade de (K_d) em função de (K_T) ilustrando uma dependência da fração difusa com as condições de cobertura total de céu, porém com valores próprios de (K_d) para cada valor de (K_T). Esta afirmação é percebida no espalhamento dos pontos estimados quando as variáveis são inseridas no treinamento principalmente da nebulosidade. A nebulosidade pode estar relacionada com as nuvens, vapor de água e aerossóis que são constituintes atmosféricos que influenciam a componente difusa da radiação solar global.

Observa-se na dispersão dos valores, que quanto melhor os indicadores mais próximos os valores estimados se aproximam dos valores medidos. Os valores apresentados na Tabela 1.12 indicam, em relação ao modelo estatístico, um desempenho relativamente superior para redes MLP, RBF, GRNN e ANFIS. Além da percepção gráfica do desempenho das redes apresentadas na Figura 1.13, as retas de regressão linear da Figura 1.14, apresentam distribuições relevantes e próximas de uma reta ideal (45°) mostrando uma correlação próxima ao ideal ($r = 1$) dos valores estimados com os medidos.

Figura 1.13 - Curva de dispersão $K_d \times K_T$ - melhores combinações de AT e AATFigura 1.14 - Curva de correlação de $K_{d\text{medido}} \times K_{d\text{estimado}}$ 

Analisando a Tabela 1.12 verifica-se entre as combinações de todas as redes, que os melhores resultados surgem quando todas as variáveis, principalmente as meteorológicas como nebulosidade, umidade e temperatura são inseridas progressivamente nas combinações. Apesar de não assegurar um bom desempenho com a inserção, há uma diminuição do erro quadrático médio e uma redução significativa principalmente na rede MLP. Contudo não se pode afirmar que outras variáveis do arranjo não influenciaram os resultados, com se pode verificar nas redes RBF e GRNN onde os resultados foram melhores com um número menor de variáveis de entrada (combinação (4)).

Importante destacar que apesar do aumento significativo no desempenho de algumas redes, deve-se atentar a parametrização e ao tempo computacional utilizada para treinamento e validação. Por exemplo, na parametrização da rede MLP onde se define as variáveis de entrada, o número de camadas e a quantidade de neurônios que pode definir a velocidade do treinamento. Além disto, existe a possibilidade do uso de outros algoritmos de treinamento. Estes algoritmos permitem alterar a taxa de aprendizagem o que ocasiona um aumento dos indicadores estatísticos e do termo *momentum* que acelera a convergência ao menor erro quadrático médio entre o valor medido e estimado. Na parametrização das redes RBF e GRNN a dificuldade está na definição do ajustamento da abertura da função gaussiana e na quantidade da amostra a ser utilizada. Estas definições podem interferir no desempenho e no tempo computacional para treinamento e validação. Na rede ANFIS, a parametrização depende da escolha adequada das variáveis mais relevantes para entrada da rede, da função de pertinência e do ajustamento a ser utilizado no treinamento, assim como na rede RBF e GRNN, onde este parâmetro deve ser experimentado para diversos valores.

Na Tabela 1.13 são apresentados alguns indicadores do coeficiente de correlação (r) e o valor da raiz quadrada do erro quadrático médio (RMSE) da literatura com o melhor resultado deste trabalho de cada rede na partição horária. Os resultados principalmente de correlação são similares aos encontrados na literatura mesmo com a diferença das variáveis de entrada utilizadas no treinamento. Isto mostra a importância de relacionar variáveis no treinamento que possuem relevância para radiação e o local a ser estudado. O conjunto de variáveis proporcionam características individuais e únicas de cada treinamento.

Tabela 1.13 – Índices estatísticos - outras localidade e TAM para Botucatu

Autores	Localidade	Técnicas	Variáveis de entrada	r	RMSE (%)
Soares et. al (2004)	São Paulo/SP	Perceptron	Radiação de topo, global e de ondas longas, ângulo de elevação solar, zenital, azimute, umidade relativa, temp. do ar, vapor d'água e transmissividade da radiação global	0,94	
Elminir et. al (2007)	Cairo/Egito	Perceptron	Radiação global e topo, mês do ano, dia juliano, hora do dia,	0,94 – 0,97	
Alam et. al (2009)	India	Perceptron	Radiação de ondas longas, latitude, longitude, altitude, hora, mês, temperatura do ar, umidade relativa, velocidade do vento, precipitação	0,92 – 0,95	1,1 – 8,8
Mellit et. al (2010 ^a)	Arabia Saudita	Perceptron	Temperatura do ar, brilho solar	0,98	
Ihya et. al (2015)	Marrocos	Perceptron	Angulo de elevação solar, hora do dia	0,94	19,73
Khatib et al. (2012)	Malasia	Perceptron	Lat, Long, Temp, Brilho solar, Umidade, Mês, Dia e Hora.		Média – 21,9
Bolznar et. al (2017)	Slovenia	Perceptron	Dia juliano, angulo elevação solar, azimute, declinação solar, hora do dia	0,9 – 0,95	
Modelo MLP (AAT)	Botucatu/SP	MLP	Transmissividade da irradiação global, Radiação no topo da atmosfera, Global e de Ondas longas, declinação solar, nebulosidade, umidade e temperatura.	0,9511	18,75
Modelo RBF (AAT)	Botucatu/SP	RBF	Radiação no topo da atmosfera, Radiação Global, Radiação de ondas longas, declinação solar.	0,9310	22,45
Modelo GRNN(AAT)	Botucatu/SP	GRNN	Radiação no topo da atmosfera, Radiação Global, Radiação de ondas longas, declinação solar.	0,9277	22,96
Modelo ANFIS (AAT)	Botucatu/SP	ANFIS	Transmissividade da irradiação global, Radiação no topo da atmosfera, Radiação Global, Radiação de ondas longas, declinação solar, nebulosidade, umidade e temperatura.	0,9435	20,38

Deve-se ressaltar que os resultados encontrados são exclusivos para combinações da Tabela 1.6 e que outras devem ser testadas a fim de verificar o comportamento das variáveis conforme vão participando do treinamento da rede. Além disso, outras parametrizações como a inclusão de novas variáveis, escolha do número de camadas, da quantidade de neurônios, da função de ativação e do ajustamento devem ser realizadas e testadas. Não foi objeto desse estudo verificar as variáveis mais significativas, mas se o uso da técnica contribui com desempenho para estimativa da (K_d) que podem ser utilizadas como alternativa na modelagem.

Diante dos resultados apresentados pode-se afirmar que a rede MLP mostrou-se a mais indicada das técnicas para estimativa da fração difusa (K_d) com o uso de variáveis astronômicas, meteorológicas e geográficas, com os dados obtidos na

cidade de Botucatu/Sp/Brasil, apresentando resultados melhores entre as TAM utilizadas e o ME.

1.5 CONCLUSÃO

Do que foi apresentado e discutido no presente trabalho é conclusivo que:

1) a equação polinomial de 4º (Eq. 9) com $R^2 = 0.7999$ pode ser utilizada para estimar a fração difusa da irradiação global com valores de validação de $RMSE_{AT} = 30,59\%$ e $RMSE_{AAT} = 28,12\%$ similares aos encontrados na literatura;

2) as técnicas MLP e ANFIS selecionadas para estimativa da fração difusa mostraram baixos valores do erro quadrático médio (EQM) nos treinamentos em todas as combinações e as técnicas RBF e GRNN apresentaram limitações do erro (EQM) com inserções de variáveis.

3) as parametrizações propostas para as arquiteturas foram adequadas para redução do erro quadrático médio (EQM) do treinamento e da raiz do erro quadrático médio (RMSE) da validação além de minimizar o tempo e esforço computacional no treinamento.

4) a validação das TAM mostraram resultados (valores de RMSE) similares ou superiores aos apresentados na literatura pesquisada;

5) a validação das TAM mostraram resultados (valores de RMSE) similares ou superiores ao ME na mesma condição de entrada (K_T);

6) a validação das TAM (MLP, RBF, GRNN e ANFIS) com a inserção das variáveis astronômicas, meteorológicas e geográficas melhoraram significativamente o desempenho das técnicas na forma sequencial nas arquiteturas propostas;

7) o desempenho (RMSE) das técnicas MLP, RBF, GRNN e ANFIS é superior ao modelo estatístico na maioria das combinações utilizadas com limitações para as redes RBF e GRNN.

Neste contexto entende-se que as técnicas de aprendizado de máquina ora estudado tem o desempenho melhor e pode auxiliar no processo de estimativa da fração difusa da irradiação global.

REFERÊNCIAS

AGUIAR, L. M. et al. Use of satellite data to improve solar radiation forecasting with Bayesian Artificial Neural Networks. **Solar Energy**, vol. 122, p. 1309–1324, 2015.

ALAM, S.; KAUSHIK, S. C.; GARG, S. N. Computation of beam solar radiation at normal incidence using artificial neural network. **Renewable Energy**. v.31, p.1483 – 1491, 2006.

ALAM, S.; KAUSHIK, S. C.; GARG, S. N. Assessment of diffuse solar energy under general sky condition using artificial neural network. **Applied Energy**. vol. 86, p. 554 – 564, 2009.

ASSOULINE, D.; MOHAJERI, N.; SCARTEZZINI, J.L. Quantifying rooftop photovoltaic solar energy potential: A machine learning approach. **Solar Energy**, vol. 141, p. 278 – 296, 2017.

BEHRANG, M. A. et al. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. **Solar Energy**, vol. 84, p. 1468 -1480, 2010.

BENGHANEM, M.; MELLIT, A. Radial Basis Function Network-based prediction of global solar radiation data: Application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia. **Energy**. vol. 35, p. 3751 – 3762, 2010.

BOZNAR, L. et al. Solar radiation prediction using different techniques: model evaluation and comparison. **Renewable and Sustainable Energy Reviews**, vol. 61, p. 384 – 397, 2016.

BOZNAR, M. Z. et al. Spatially transferable regional model for half-hourly values of diffuse solar radiation for general sky conditions based on perceptron artificial neural networks. **Renewable Energy**, vol. 103, p. 794 – 810, 2017.

CELLIK, A.N.; MUNEER, T. Neural network based method for conversion of solar radiation data. **Energy Conversion and Management**, vol 67, p. 117–124, 2013.

CHANDRASEKARAN, J.; KUMAR, S. Hourly diffuse fraction correlationa at a tropical location. **Solar Energy**, vol. 53, n° 6, p. 505 – 510, 1994.

CHAVES, M.; ESCOBEDO, J. F. A software to process daily solar radiation data, **Renewable Energy**, vol.19(1), p. 339 – 344, 2000.

CITAKOGLU, H. Comparison of artificial intelligence techniques via empirical equations for prediction of solar radiation. **Computers and Electronics in Agriculture**, vol. 118, p. 28 – 37, 2015.

CODATO, G. et al. Global and diffuse solar irradiances in urban and rural areas in southeast Brazil. **Theoretical and Applied Climatology** , vol. 93, p. 57 – 73, 2008.

COLLARES-PEREIRA, M.; RABL, A. The average distribution on solar radiation – correlations between diffuse and hemispherical and between daily and hourly insolation values. **Solar Energy**, vol. 22, p. 155 - 164, 1979.

CRISPIM, E. M.; FERREIRA, P. M.; RUANO, A. E. Solar radiation prediction using RBF Neural Networks and cloudiness indices. **International Joint Conference on Neural Networks**. Vancouver, Canada, 2006.

DAL PAI, A. et al. MEO shadowring method for measuring diffuse solar irradiance: corrections based on sky cover. **Renewable Energy**, vol. 99, p.754 - 76, 2016.

DE MIGUEL, A. et al. Diffuse solar irradiation model evaluation in the north Mediterranean belt area. **Solar Energy**. vol. 70, nº. 2, p. 143 – 153, 2001.

DORVLO, A. S. S.; JERVASE, J. A.; AL-LAWATI, A. Solar radiation estimation using artificial neural networks. **Applied Energy**, vol. 71, p. 307–319, 2012.

EISSA, Y.; CHIESA, M.; GHEDIRA, H. Assessment and recalibration of the Heliosat-2 method in global horizontal irradiance modeling over the desert environment of the UAE. **Solar Energy**, vol. 86, p. 1816–1825, 2012.

EL MGHOUCHI, Y. et al. New model to estimate and evaluate the solar radiation Y. **International Journal of Sustainable Built Environment**, vol. 3, p. 225–234, 2014.

ELIZONDO, D.; HOOGENBOOM, G.; MCCLENDON, R. W. Development of a neural network model to predict daily solar radiation. **Agricultural and Forest Meteorology**, vol. 71, p. 115 – 132, 1994.

ELMINIR, H. K.; AZZAM, Y. A.; YOUNES, F. I. Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. **Energy**, vol. 32, p. 1513 – 1523, 2007.

ESCOBEDO J. F. et al. Ratios of UV,PAR and NIR components to global solar radiation measured at Botucatu site in Brazil. **Renewable Energy**, vol. 36, 169-178, 2011.

ESCOBEDO, J. F. et al. Efeito da cobertura do céu no aumento das frações solar difusa e par-difusa em estufa de polietileno. **Avances en Energías Renovables y Medio Ambiente**, vol. 17, p.02.19-02.25, 2013.

ESCOBEDO, J. F. et al. Diurnal and Annual Evolution of UV, PAR and NIR Irradiations in Botucatu/Brazil. **Energy Procedia**, vol. 57, p. 1130 - 1139, 2014.

FENG, P. Y. et al. Comparison of artificial intelligence and empirical models for estimation of daily diffuse solar radiation in North China. **International Journal of Hydrogen Energy**, p. 1 – 11, 2017.

FLETCHER, D. S.; GOSS, E. Forecasting with neural network: an application using bankruptcy data. **Information Management**, vol.24, p.159–67, 1993.

FURLAN, C. et al. The role of clouds in improving the regression model for hourly values of diffuse solar radiation. **Applied Energy**, vol. 92, p. 240 – 254, 2012.

HANSEN, J.V.; MESERVY, R. D. Learning experiments with genetic optimization of a generalized regression neural network. **Decision Support System**, vol. 18, p. 317 – 325, 1996.

HAYKIN, S. *Redes neurais: princípios e prática*. 2.ed. Porto Alegre, Bookman, 2001.

IHYA, B. et al. Prediction of hourly and daily diffuse solar fraction in the city of Fez (Morocco). **Theor Applied Climatology**, vol. 120, p.737 – 749, 2015.

INEICHEN, P. Long term satellite global, beam and diffuse irradiance validation. **Energy Procedia**, vol. 48, p. 1586 – 1596, 2014.

JACOVIDES, C. P. et al. Comparative study of various correlations in estimating hourly diffuse fraction of global solar radiation. **Renewable Energy**, vol. 31, p. 2492 – 2504, 2006.

JANG, J. S. ANFIS: Adaptive Network Based Fuzzy Inference System. **IEEE Transactions on systems, man, and cybernetics**, vol. 23, no 3, May/June, 1993.

KALOGIROU, S. **Applied Energy**, vol. 67, p .17 – 35, 2000.

KAMBEZIDIS, H. D. et al. Meteorological Radiation Model (MRM v6.1): Improvements in diffuse radiation estimates and a new approach for implementation of cloud products. **Renewable and Sustainable Energy Reviews**, vol. 74, p. 616 – 637, 2017.

KAUSHIKA, N. D.; TOMAR, R. K.; KAUSHIK, S. C. Artificial neural network model based on interrelationship of direct, diffuse and global solar radiations. **Solar Energy**, vol. 103, p. 327–342, 2014.

KHATIB, T.; ELMENREICH; W. A Model for Hourly Solar Radiation Data Generation from Daily Solar Radiation Data Using a Generalized Regression Artificial Neural Network. **International Journal of Photoenergy**, vol. 2015, 1 – 13, 2015.

KHATIB, T. et al. Assessment of Artificial Neural Networks for Hourly Solar Radiation Prediction. **International Journal of Photoenergy**, vol. 2012, p. 1 - 8, 2012.

KUMAR, R.; AGGARWAL, R. K.; SHARMA, J. D. Comparison of regression and artificial neural network models for estimation of global solar radiations. **Renewable and Sustainable Energy Reviews**. Vol. 52, p. 1294 – 1299, 2015.

KUO, C.W.; CHANG, W.C.; CHANG, K. C. Distribution of solar diffuse fraction in Taiwan. **Energy Procedia**, vol. 57, p. 1120 - 1129, 2014b.

LANDERAS, G. et al. Comparison of Gene Expression Programming with neuro-fuzzy and neural network computing techniques in estimating daily incoming solar radiation in the Basque Country (Northern Spain). **Energy Conversion and Management**, vol. 62, p. 1 – 13, 2012.

LAURET, P. et al. A benchmarking of machine learning techniques for solar radiation forecasting in an insular context. **Solar Energy**, vol. 112, p. - 446–457, 2015.

LAZAREVSKA, E.; TRPOVSKI, J. Neuro-Fuzzy Model of the Solar Diffuse Radiation With Relevance Vector Machine. **IEEE Xplore Digital Library**, 2011.

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

LIU, B. H. Y.; JORDAN, R. C. The interrelationship and characteristic distribution of direct, diffuse and total solar radiation. **Solar Energy**, vol. 4, p. 1, 1960.

LOPEZ, G.L.; MUNEER, T.; CLAYWELL, R. Assessment of four shadow band correction models using beam normal irradiance data from the United Kingdom and Israel. **Energy Conversion and Management**, vol. 45, p.1963 – 1979, 2004.

MARQUES FILHO, E. P. et al. Global, diffuse and direct solar radiation at the surface in the city of Rio de Janeiro: Observational characterization and empirical modeling. **Renewable Energy**, vol. 91, p. 64 – 74, 2016.

MCCULLOCH, W. S; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, vol. 5, p. 115 – 133, 1943.

MELLIT, A.; PAVAN A. M. A 24-h forecast of solar irradiance using artificial neural network: application for performance prediction of a grid-connected PV plant at Trieste, Italy. **Solar Energy**, vol. 84, p. 807 – 821, 2010b.

MELLIT, A. et al. An adaptive model for predicting of global, direct and diffuse hourly solar irradiance. **Energy Conversion and Management**, vol. 51, p. 771-782, 2010a.

MELO, J. M. D.; ESCOBEDO, J. F. Medida da radiação solar difusa. In: Energias Limpas em progresso. **VII Congresso Ibérico de Energia Solar**, Vigo, Espanha. Anais **International Solar Energy Society**, vol. 1, 1994.

MOHAMMADI, K. et al. Identifying the most significant input parameters for predicting global solar radiation using an ANFIS selection procedure. **Renewable and Sustainable Energy Reviews**, vol. 63, p.423 – 434, 2016b.

MOHAMMADI, K. et al. Determining the most important variables for diffuse solar radiation prediction using adaptive neuro-fuzzy methodology; case study: City of Kerman, Iran. **Renewable and Sustainable Energy Reviews**, vol. 53, p. 1570 – 1579, 2016c.

MOHANDES, M.; REHMAN, S.; HALAWANI, O. T. Estimation of global solar radiation using artificial neural networks. **Renewable Energy**, vol. 14, p. 179-184, 1998.

OLIVEIRA, A. P. et al. Correlation models of diffuse solar-radiation applied to the city of São Paulo, Brazil. **Applied Energy**, vol. 71, p. 59 – 73, 2002a.

OLIVEIRA, A. P.; ESCOBEDO, J. F.; MACHADO, A. J. A new shadow-ring device for measuring diffuse solar radiation at surface. **Journal Atmos. Ocean. Technol.** Vol.19, p. 698 – 708, 2002b.

OTEIZA, P.; PEREZ-BURGOS, A. Diffuse illuminance availability on horizontal and vertical surfaces at Madrid, Spain, **Energy Conversion Management**, vol. 64, p. 313 – 319, 2012.

PASHIARDIS, S.; KALOGIROU, S.A. Quality control of solar shortwave and terrestrial longwave radiation for surface radiation measurements at two sites in Cyprus. **Renewable Energy**, vol. 96, p. 1015 – 1033, 2016.

PAULESCU, E.; BLAGA, R. Regression models for hourly diffuse solar radiation. **Solar Energy**, vol. 125, p. 111 – 124, 2016.

QUEJ, V. H. et al. Empirical models for estimating daily global solar radiation in Yucatán Peninsula, Mexico. **Energy Conversion and Management**, vol. 110, p. 448 – 456, 2016.

QUEJ, V. H. et al. SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment. **Journal of Atmospheric and Solar–Terrestrial Physics**, vol. 155, p. 62 – 70, 2017.

ROSSI, T. J. et al. Global, diffuse and direct solar radiation of the infrared spectrum in Botucatu. **Renewable and Sustainable Energy Reviews**, vol. 82, p. 448 – 459, 2018.

RUIZ-ARIAS, J. A. et al. Proposal of a regressive model for the hourly diffuse solar radiation under all sky conditions. **Energy Conversion and Management**, vol. 51, p. 881 – 893, 2010.

SANTOS, C. M.; ESCOBEDO J. F. Temporal variability of atmospheric turbidity and DNI attenuation in the sugarcane region, Botucatu/SP. **Atmospheric Research**, vol. 181, p. 312 – 321, 2016a.

SANTOS, C. M. et al. Assessment of ANN and SVM models for estimating normal direct irradiation (H_b). **Energy Conversion and Management**, vol. 126, p. 826 – 836, 2016b.

SFETSOS, A.; COONICK, A. H. Univariate and multivariate forecasting of hourly solar radiation with artificial intelligence techniques. **Solar Energy**, vol. 68, p. 169 – 178, 2000.

SILVA, F. R.; OLIVEIRA, H. S. M.; MARINHO, G. S. Análise das componentes global e difusa da radiação solar em Natal-RN entre 2007 e 2008. **II Congresso Brasileiro de Energia Solar e III Conferência Regional Latino-Americana da ISES** - Florianópolis, 18 a 21 de novembro de 2008

SILVA, M. B. P. et al. Performance of the Angstrom-Prescott Model (A-P) and SVM and ANN techniques to estimate daily global solar irradiation in Botucatu/SP/Brazil. **Journal of Atmospheric and Solar–Terrestrial Physics**, vol. 160, p. 11–23, 2017.

SIMÓN-MARTÍN, M.; ALONSO-TRISTÁN, C.; DíEZ-MEDIAVILLAB, M. Diffuse solar irradiance estimation on building's façades: Review, classification and benchmarking of 30 models under all sky conditions. **Renewable and Sustainable Energy Reviews**, vol. 77, p. 783–802, 2017.

SIMÓN-MARTÍN, M.; DíEZ-MEDIAVILLA, M.; ALONSO-TRISTÁN, C. Shadow-band radiometer measurement of diffuse solar irradiance: Calculation of geometrical and total correction factors. **Solar Energy**, vol. 139, p. 85–99, 2016.

SOARES, J. et al. Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. **Applied Energy**, vol. 79, p. 201-214, 2004.

SPECHT, D. F. A general regression neural network. **IEEE Transactions on neural networks**, vol. 2, nº 6, 1991.

STONE, R. J. Improved statistical procedure for the evaluation of solar radiation estimation models. **Solar Energy**, vol. 51, nº 4, p. 289 – 291, 1993.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **IEEE Transactions System, Man, Cybernetics**, vol. 15, p. 116-132, 1985.

TERAMOTO, E. T.; ESCOBEDO, J. F. Análise da frequência anual das condições de céu em Botucatu, São Paulo. **Revista Brasileira Engenharia Agrícola Ambiental**. v.16, n. 9, p.985-992, 2012.

TIEPOLO, G. M. et al. Atlas de energia solar do estado do paran  – resultados. **VII Congresso Brasileiro de Energia Solar**, 2018.

TOMAR, R. K.; KAUSHIKA, N. D., KAUSHIK, S. C. Artificial neural network based computational model for the prediction of direct solar radiation in Indian zone. **Journal of Renewable and Sustainable Energy**. Vol. 4, p.063 – 146, 2012.

TYMVIOS, F. S. et al. Comparative study of Ångstr m's and artificial neural networks' methodologies in estimating global solar radiation. **Solar Energy**, vol. 78, p. 752-762, 2005.

VIANA, T. S. et al. Assessing the potential of concentrating solar photovoltaic generation in Brazil with satellite-derived direct normal irradiation. **Solar Energy**, vol. 85 p. 486–495, 2011.

VOYANT, C. et al. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, vol. 105, p.569 – 582, 2017.

WANG, L. et al. Solar radiation prediction using different techniques: model evaluation and comparison. **Renewable and Sustainable Energy Reviews**, vol. 61, p. 384 – 397, 2016.

WANG, W. C. et al. A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series. **Journal of Hydrology**, vol. 374, p. 294 – 306, 2009.

WEISS, A.; NORMAN, J. M. Partitioning solar radiation into direct and diffuse, visible and near-infrared components. **Agricultural and Forest Meteorological**, vol. 34, p. 205-213, 1985.

WMO – World Meteorological Organization. Guide to meteorological Instruments and Methods of Observation. **WMO-n 8, 7 edi o**, Geneva, Switzerland, 2008, 681 p.

WMO - 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, p. 298, 1981.

YADAV, A. K.; CHANDEL, S. S. Solar radiation prediction using Artificial Neural Network techniques: a review. **Renewable and Sustainable Energy Reviews**, vol. 33, p. 772–781, 2014.

YOUNES, S.; CLAYWELL, R.; MUNEER, T. Quality control of solar radiation data: Present status and proposed new approaches. **Energy**, vol. 30, p. 1533 – 1549, 2005.

ZADEH, L. A. Fuzzy algorithms, **Info. e Ctl.** vol. 12, p. 94-102, 1968.

ZAGOURAS, A. et al. Determination of measuring sites for solar irradiance, based on cluster analysis of satellite-derived cloud estimations. **Solar Energy**, vol. 97, p. 1 -11, 2013

CAPÍTULO 2

REDE PERCEPTON MULTICAMADAS (MLP) E MÁQUINA DE VETORES DE SUPORTE (SVM) NA ESTIMATIVA DA FRAÇÃO DIFUSA DA IRRADIAÇÃO GLOBAL NA PARTIÇÃO DIÁRIA

Autor: Edson Luis Bassetto

RESUMO

Este trabalho propõe a utilização de Técnicas de Aprendizado de Máquina (TAM) para realizar a estimativa da fração difusa da irradiação global (K_d) a partir de um conjunto de combinações de variáveis climatológicas na partição diária e comparar com o modelo estatístico clássico (ME) que utiliza somente a transmissividade atmosférica (K_T) como variável de referência. As técnicas são as Redes Neurais Artificiais (RNA/MLP) e Máquina de Vetores de Suporte (SVM). Os dados para ME e TAM foram obtidos no período de 2000 a 2006 na Estação Meteorológica da Faculdade de Ciências Agrônômicas da Universidade Estadual Paulista, campus Botucatu/SP. Para validação dos modelos ME e das TAM foram elaborados, a partir das medidas obtidas, duas bases de dados anuais denominadas de Ano Típico (AT) e Ano Atípico (AAT). O modelo ME elaborado por regressão apresentou equação de 4ª ordem com coeficiente de determinação (R^2) de 0,91626. O índice de desempenho do modelo estatístico (ME) na validação com as duas bases (AT e AAT) foi de $RMSE_{AT} = 19,95\%$ e $RMSE_{AAT} = 18,66\%$ e coeficiente de correlação de $r_{AT}=0,9533$ e $r_{AAT}=0,9490$. Na validação das TAM o melhor resultado foi apresentado pela rede MLP com um $RMSE_{AT} = 17,34\%$ e $RMSE_{AAT} = 15,56\%$ e coeficiente de correlação de $r_{AT}=0,9649$ e $r_{AAT}=0,9649$. Estes indicadores mostram que ambas as técnicas (ME e TAM) as correlações são próximas mostrando que as variáveis estão bem correlacionadas. No desempenho das TAM a precisão dos valores estimados em relação aos valores medidos apresentaram resultados mais significativos justificando assim a utilização das técnicas como alternativa para as estimativas da fração difusa (K_d) com as condições de treinamento utilizadas neste estudo.

Palavras-chave: Radiação Difusa; Perceptron Multicamadas; Máquina de Vetores de Suporte

ABSTRACT

This work proposes the use of Machine Learning Techniques (TAM) to estimate the diffuse fraction of global irradiance (K_d) from a set of combinations of climatological

variables in the daily partition and compare it with the classical statistical model (ME) which uses only atmospheric transmissivity (K_T) as the reference variable. The techniques are Artificial Neural Networks (RNA / MLP) and Support Vector Machines (SVM). Data for ME and TAM were obtained from 2000 to 2006 at the Meteorological Station of the Faculty of Agronomic Sciences of Paulista State University, Botucatu / SP campus. For the validation of the ME and TAM models, two annual databases, called the Typical Year (AT) and the Atypical Year (AAT), were prepared from the obtained measurements. The regression model ME presented a 4th order equation with coefficient of determination (R^2) of 0.91626. The performance index of the statistical model (ME) in the validation with the two bases (AT and AAT) was $RMSE_{AT} = 19.95\%$ and $RMSE_{AAT} = 18.66\%$ and correlation coefficient of $r_{AT} = 0.9533$ and $r_{AAT} = 0.9490$. In the validation of TAM the best result was presented by the MLP network with a $RMSE_{AT} = 17.34\%$ and $RMSE_{AAT} = 15.56\%$ and correlation coefficient of $r_{AT} = 0.9649$ and $r_{AAT} = 0.9649$. These indicators show that both techniques (ME and TAM) correlations are close showing that the variables are well correlated. In the performance of the TAM, the accuracy of the estimated values in relation to the measured values presented more significant results justifying the use of the techniques as an alternative for the estimation of the diffuse fraction (K_d) with the training conditions used in this study.

Keywords: Diffuse Radiation; Perceptron Multi-Layered; Support Vector Machine.

2.1 INTRODUÇÃO

A radiação solar é considerada uma das formas de energia mais limpa, sustentável e abundante na superfície terrestre e países com grande incidência dessa energia como o Brasil, são beneficiados com a utilização desta fonte em diversas áreas científicas e tecnológicas (Bakirci, 2015; Teke et al., 2015). No entanto, para um aproveitamento eficiente desta radiação é importante quantificar ou estimar este potencial através de medidas (séries temporais ou espaciais) ou por meio de modelos de estimativa.

Dos componentes da radiação solar, a irradiância global ($I_g - W/m^2$) ou a irradiância solar global ($H_g, MJ/m^2$) é a energia mais monitorada nas estações solarimétricas, diferentemente de seus componentes, a irradiância direta ($I_b - W/m^2$) ou a irradiância direta ($H_b, MJ/m^2$), importante em projeto de conversão térmica e fotovoltaico () e a irradiância difusa ($I_d - W/m^2$) ou a irradiância difusa ($H_d, MJ/m^2$),

importante em estudos de energia passiva e biomassa (Gueymard, 2008; Dal Pai et al., 2016) e no desenvolvimento de cultivares protegidos (). Contudo as medidas da (I_b) que demandam de equipamentos custosos geralmente são calculadas pelo método da diferença entre a (I_g) e a (I_d) pela relação ($I_b = I_g - I_d$). As medidas da (I_d) também não são comuns mas tem sido monitoradas e obtidas com custos menores de equipamentos, operação e manutenção (Dal Pai et al., 2016).

No Brasil as medidas da (H_d) são realizadas em algumas regiões (Marques Filho et al., 2016; Drechmer e Ricieri 2006; Codato et al., 2008; Furlan, et al., 2012; Soares et al., 2004) através de sistemas com baixo custo. A proposta do sistema elaborada por Melo e Escobedo (1994) está em uma montagem simples com anel de sombreamento. O anel é fixo a um eixo no plano horizontal e inclinado na latitude local, e o eixo central do anel paralelo à direção polar, diferente de outras montagens (Drummond, 1956 e Robinson e Stoch, 1964; Martinez e Cúnsulo, 2017) que possuem restrições operacionais, de manutenção e custos elevados.

Apesar da importância, medidas ou estimativas da (I_d) ainda são escassas e com poucas informações disponíveis, principalmente no Brasil, país com elevada disponibilidade de recurso solar. (Silva et al. 2008; Oliveira et al., 2002 a e b; Santos et al., 2016). Diferentemente das medidas (séries temporais ou espaciais), os modelos de estimativa necessitam de informações de outras medidas na superfície terrestre ou atmosférica, como os modelos estatísticos e as técnicas de aprendizado de máquina. (Jamil e Akhatar, 2017; Khorasanizadeh et al., 2016; Ruiz-Arias et al., 2010).

Vários modelos para estimar (H_d) são estatísticos e relacionam a fração difusa ($K_d = H_d/H_g$) com a transmissividade atmosférica ou índice de claridade ($K_T = H_g/H_0$) onde (H_0 , MJ/m²) é a irradiação no topo da atmosfera. O primeiro modelo (Liu e Jordan, 1960) correlacionou estas frações a partir de dados na partição diária. Modelo com uma variável de referência é utilizado na literatura em partições horária e mensal (Orgill e Hollands, 1977; Collares-Pereira e Rabl, 1979; Chandrasekaran and Kumar, 1994; Oliveira et al., 2002b; Jacovides et al., 2006; Paleuscu e Blaga, 2016) e outros com mais de uma variável (Reindl et al., 1990; Boland et al., 2001; Furlan et. al., 2102; Kuo et al., 2014a e b). Uma das desvantagens destes modelos é a restrição ao uso em outros locais de medidas como também outros modelos apresentarem desempenho (RMSE) superiores (Bortolini et al., 2013; Kambezidis et al., 2017) com outras estimativas de radiações.

Outras técnicas recentemente utilizadas nas estimativas são as realizadas por Técnicas de Aprendizado de Máquina (TAM) do tipo Redes Neurais Artificiais (RNA), Máquina de Vetores de Suporte (SVM), e de técnicas híbridas com uso das RNA's e Sistema de Inferência Fuzzy (FIS), entre outras. Estas técnicas têm as seguintes vantagens: habilidade em aprender a partir de informações conhecidas e desejadas; não conhecer o comportamento matemático dos dados; interpretar falsas informações sem alterar os resultados; estimar resultados a partir de conhecimento previamente conhecido de variáveis de grandezas físicas diferentes; e ajustar (pesos) os valores das variáveis de entrada de acordo com o valor desejado. Contudo, tem a desvantagem em definir a parametrização e ajustes ideais das redes que dependem principalmente da variável e do número de amostras utilizadas.

O uso das TAM para estimativas da radiação solar no Brasil é recente, principalmente a radiação difusa (Soares et al., 2004; Marques Filho et al., 2017; Santos et al., 2016b; Silva et al., 2017), sendo necessária a realização de mais estudos e informações disponíveis para a otimização de trabalhos espaciais com radiação no país. Diante da importância de se conhecer a irradiação solar difusa em diversos projetos e estudos de conversão é proposto neste trabalho um estudo comparativo de duas técnicas não convencionais de estimativa, a RNA/MLP e SVM e prever a fração difusa da irradiação global na partição diária como base em dados astronômicos, meteorológicos e geográficos obtidos na cidade de Botucatu/SP e comparar com o modelo estatístico (ME). Os objetivos principais deste estudo são: 1. elaborar modelo estatístico da fração difusa da irradiação global para Botucatu/SP e validar para uma base de dados independente; 2. definir e parametrizar as técnicas RNA/MLP e SVM; 3. treinar e validar as técnicas RNA/MLP e SVM; 4. comparar o desempenho das técnicas RNA/MLP e SVM; e 5. comparar o desempenho do três modelo o ME e as RNA/MLP e SVM.

2.2 TÉCNICAS DE APRENDIZADO DE MÁQUINA (TAM)

Problemas envolvendo resultados, decisões, incertezas e imprecisões de uma situação real têm sido resolvidos com o conceito de aprendizado através do treinamento a partir de um conjunto de informações ou de experiências adquiridas ao longo do tempo.

Este conceito é a base do princípio de funcionamento das Técnicas de Aprendizado de Máquina que é similar ao processo de aprendizado do cérebro

humano onde através de um conjunto de informações ou de experiências adquiridas (dados de entrada) é possível obter, através de treinamentos (aprendizado), uma série de resultados futuros (dados de saída).

Essa relação torna-se mais eficiente quando uma nova informação ou experiência é adquirida. Isto acontece pois, as técnicas reconhecem padrões de diferentes complexidades e grandezas e através de algoritmos de aprendizagem estabelecem uma associação continua e construtiva entre as informações ou dados de entradas e saídas. Geralmente, as situações de aprendizado estão relacionadas em aproximar um conjunto de informações conhecidas (x_i , entrada) a um conjunto de informações desejado (y_i , saída).

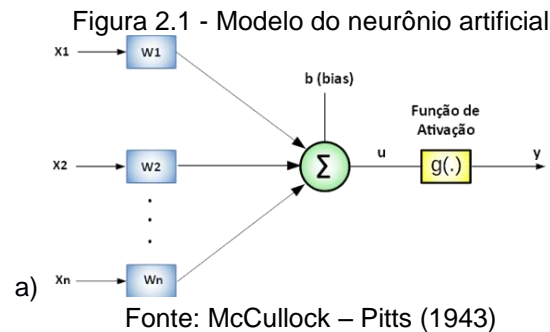
Entre as Técnicas de Aprendizado de Máquina (TAM) utilizadas para estimar radiação solar em superfícies horizontais ou inclinadas destacam-se as Redes Neurais Artificiais (RNA) amplamente utilizadas na literatura, Máquina de Vetores de Suporte (SVM) que vem se destacando como uma alternativa, além de outras como Sistema Adaptativo de Inferência Neuro – Fuzzy (ANFIS) (Yadav e Chandel, 2014; Lauret et al., 2015; Santos et. al, 2016; Assouline et. al, 2017).

Na sequência estão descritos os princípios e conceitos básicos da rede MLP e SVM para estimativa da fração difusa na partição diária.

2.2.1 Rede Neurais Artificiais (RNA/MLP)

As técnicas de RNA's são modelos computacionais que apresentam uma estrutura formada por um conjunto de elementos chamados neurônios, similar as do cérebro humano, distribuídos paralelamente e composta por camadas de entrada, de saída e camadas ocultas interligadas entre si por conexões.

Modeladas matematicamente e através de algoritmos de aprendizado são capazes de analisar funções complexas e não lineares que adquirem a capacidade de aprendizado e adequação de conhecimento. São utilizadas para o reconhecimento e classificação de padrões, agrupamento, previsão e nas estimativas de variáveis astronômicas. A estrutura básica de uma rede neural é o neurônio artificial ilustrado pela Figura 2.1.



É formada por um conjunto de conexões (*sinapses*) que recebem os valores de entrada (x_1, x_2, \dots, x_i) definidos por pesos sinápticos (w_1, w_2, \dots, w_i) que através de um combinador linear (Σ) executa a soma ponderada de suas entradas, produzindo uma saída chamada de potencial de ativação (u). Na sequência é 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)) (Haykin, 2001).

Neste capítulo a Rede Neural a ser utilizada é a Perceptron Multicamadas (MLP) caracterizada pela presença de pelo menos uma camada intermediária de neurônios, localizada entre as camadas de entrada e a camada de saída e são classificadas como redes do tipo *feedforward* (alimentação a frente ou única direção) de camadas múltiplas (Moustris et al., 2008) e treinada com o algoritmo *Levenberg/Marquadt* (Çelik et al., 2016).

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 com os valores desejados (Alam et al. 2009).

Para utilização da RNA/MLP é importante a composição da estrutura, a definição do número de neurônios, das camadas ocultas, do algoritmo de treinamento, da função de transferência e do conjunto de dados que podem influenciar os pesos sinápticos e resultados. Com uma arquitetura flexível e pouca complexidade em seus algoritmos de treinamento e parametrização, são as mais utilizadas na estimativa da irradiação solar. Na estimativa da irradiação global (H_g) (Elizondo et. al, 1994; Kalogirou, 2000; Tymvios et. al, 2005; Kumar et. al, 2015; Silva et. al, 2017), com diversas variáveis climatológicas e geográficas como variáveis de entrada. Na irradiação solar direta (H_b) poucos trabalhos são encontrados na literatura (Alam et.

al, 2006; Tomar et. al, 2012; Kaushika et al., 2014; Santos et al., 2016), assim como para irradiação solar difusa (H_d) (Soares et. al, 2004; Alam et. al, 2009; Ihya et. al, 2014; Boznar et. al, 2017).

2.2.2 Máquina de Vetores de Suporte (SVM)

A técnica SVM foi desenvolvida para resolver problemas de classificação, regressão e estimativas com grande capacidade de generalização, introduzida por Vapnik (1995). É diferenciada dos modelos estatísticos por utilizar o princípio da minimização do erro estrutural ao invés de minimizar o erro empírico (Antonanzas-Torres et al., 2015; Santos et al., 2016).

O conceito básico da técnica é realizar o treinamento para aprendizagem da rede através de algoritmos de otimização matemática envolvendo poucos parâmetros de ajuste em seus algoritmos de treinamento que depende da sua utilização e consequentemente do algoritmo de treinamento a serem utilizados.

A proposta de uma SVM é realizar o mapeamento dos dados de entrada e do treinamento em um espaço de dimensões maiores, via funções de *kernel* (linear, polinomial, gaussiana e sigmoide), construindo um hiperplano com uma margem de separação máxima entre os dados. Com isto a programação irá encontrar um peso (w) e um linear (b) capaz de otimizar as margens destes dados a fim de assegurar uma boa classificação ou regressão. Matematicamente a SVM elabora este hiperplano de separação ideal considerando um conjunto de variáveis chamados de vetores de entrada (x_i) e seus respectivos vetores de saída (y_i) normalizados (Belaid e Mellit, 2016).

Essa característica de maximização de espaço através das funções de *Kernel* é que podem fazer com que as técnicas SVM sejam viáveis para abordar estudos com irradiação solar que por natureza são grandezas não lineares, como a irradiação global (H_g) (Mohammadi et al., 2015a e b; Antonanzas-Torres et al., 2015; Belaid e Mellit, 2016; Chen et al., 2015) e a irradiação difusa (Shamshirband et al., 2016). Apesar de pouco utilizada em estimativas de irradiação solar, no Hemisfério Sul vem sendo introduzida na estimativa da irradiação solar direta (H_b) (Santos et al., 2016), na irradiação global (H_g) (Silva et al., 2016) e irradiação solar UV (Teramoto et. al., 2016).

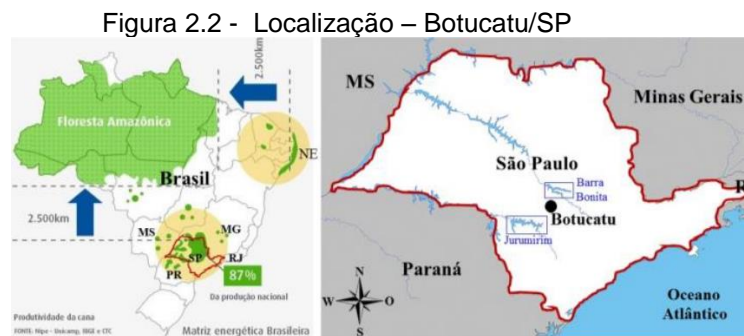
Neste capítulo a Máquina de Suporte de Vetores utiliza o algoritmo SMOreg – Otimização Mínima Sequencial, proposto por Platt (1998) para resolver o problema de

programação quadrática que surge durante o treinamento da SVM. Para aprofundamento e maiores detalhes da teoria e da evolução da SVM podem ser encontrados em VAPNIK (1998).

2.3 MATERIAL E MÉTODOS


2.3.1 Localização e Clima

A Estação Meteorológica do Lageado está localizada no campus da UNESP – Universidade Estadual Paulista em Botucatu/SP/Brasil (latitude 22,85°S, longitude 48,45°O) e está a 786 m do nível do mar. Está inserida em uma região com duas grandes represas e com grandes áreas de plantações de eucaliptos e cana de açúcar (Figura 2.2.) o que provoca um aumento na concentração do vapor d'água e na nebulosidade (Rossi et al., 2018a).



Fonte: Rossi et al. 2018b.

De acordo com a classificação de Koppen, o clima é do tipo Cwa, com bioma de cerrado e mata atlântica, temperado úmido, com inverno frio e seco (junho-agosto), verão quente e úmido (dezembro-fevereiro) com elevada precipitação (Escobedo et al. 2011; Teramoto e Escobedo, 2012). A caracterização do clima de Botucatu é apresentada pelos gráficos da Figura 2.3 através das séries climáticas anuais da temperatura, umidade relativa, precipitação, nebulosidade entre os anos de 1970 a 2008 (Rossi et al. 2018b). A temperatura do ar média anual é de 20,46°C, onde o mês mais quente é fevereiro (22,5°C) e o mais frio julho (16,7°C). A umidade relativa do ar varia de 61,20% (agosto) a 76,5% (janeiro). A evolução da nebulosidade segue a variação da temperatura sendo mais elevada no verão (61%) e menor no inverno (28%). O maior número de horas de brilho solar ocorre em agosto e o menor fevereiro com totais de aproximadamente de 229h e 176h, respectivamente A precipitação segue as evoluções da temperatura e da nebulosidade sendo constituída de dois intervalos distintos.



Fonte - Rossi, et al., 2018b

O período chuvoso (outubro a março/primavera e verão) com maior precipitação no verão com média total de 304mm e o período seco (abril a setembro/outono e inverno) com menor valor no inverno com média de 38mm..

2.3.2 Obtenção e Controle de Qualidade da Base de dados

As medidas instantâneas (irradiância - W/m^2) da irradiância global ($I_g - W/m^2$) foram obtidas com um piranômetro *Eppley-PSP* (Figura 1.7.a) e para medidas da irradiância difusa ($I_d - W/m^2$) foi utilizado um piranômetro *Eppley-PSP* (Figura 1.7.b) com anel de sombreamento (Melo e Escobedo, 1994) com as seguintes especificações: 80 cm de diâmetro, 10 cm de largura e 1mm de espessura. Os valores da (I_d) foram corrigidos através de um fator de correção isotrópico (FC) dado pela Equação 1, para compensar a parcela da (I_d) obstruída pelo próprio anel, as quais depende de parâmetros geométricos como largura e raio, geográficos como latitude e os astronômicos como a declinação solar (Oliveira et. al, 2002b).

$$FC = [1 - \left(\frac{Hd'}{Hd}\right)]^{-1} \dots\dots\dots(1)$$

onde (H_d) é a irradiação solar difusa (MJ/m^2) de referência, obtida pelo método indireto, enquanto que (H_d') é a irradiação solar difusa (MJ/m^2) interceptadas durante o dia pelo anel de sombreamento. A razão (Hd' / Hd) é calculada pela Equação 2.

$$\frac{Hd'}{Hd} = \left(\frac{2b}{\pi R}\right) * \cos(\delta) * \left[\frac{\cos(\phi+\delta)}{\cos \phi}\right]^2 * \int_0^\omega \cos \theta_z * (d\omega) \dots\dots\dots(2)$$

onde (b) e (R) são a largura e raio do anel, (δ) é a declinação solar (Equação 3), (ϕ) é a latitude local, (θ_z) é o ângulo zenital (Equação 4) e (ω) é o ângulo horário do sol (Equação 5), variando do nascer até o pôr do sol.

$$\delta = 23,45 * \sin[(360 * (Dj + 284))/365] \dots\dots\dots(3)$$

onde Dj é dia juliano.


$$\theta z = \ar \cos (\sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega s) \dots \dots \dots (4)$$

$$\omega s = \cos^{-1}[-\tan(\phi) * \tan(\delta)] \dots \dots \dots (5)$$

Em geral as medidas da (I_d) realizadas pelos métodos de sombreamento são aplicadas somente correção isotrópica (Oliveira et al., 2002b; Soares et al., 2004; Codato et al., 2008; Kambezidis et al., 2017; Marques Filho et al., 2016) apesar da aplicação de correções anisotrópicas serem mais eficazes (Simón-Martin et al., 2016 e 2017; Dal Pai et al., 2016). Neste estudo não foram aplicadas correções anisotrópicas.

As medidas obtidas foram armazenadas em um sistema de aquisição de dados automáticos “*Datalogger*” *Campbell Cr23X* da *Campbell Scientific*. Estes valores são digitalizados a cada 5 segundos, sendo armazenadas e transmitidas somente as médias realizadas após 5 minutos para um computador através de um módulo de armazenamento SM – 192. Após obtenção das medidas instantaneamente (irradiância - W/m^2) os dados foram integralizados em energia (irradiação - MJ/m^2) e separados em séries temporais horárias (Chaves e Escobedo, 2000). Todos os equipamentos utilizados para as medidas foram aferidos pelo método comparativo a cada dois anos, através de instrumentos adicionais específicos para esta finalidade.

Figura 2.4 - a) Piranômetro; b) Piranômetro com anel de sombreamento



Fonte: Dal Pai et al., 2016

A fração da irradiação difusa (K_d) e da transmissividade da irradiação global (K_T) foram calculadas pelas relações das medidas da irradiação difusa (H_d), irradiação global (H_g) e irradiação no topo da atmosfera (H_0) dadas pelas Equações 6 e 7.

$$Kd = Hd/Hg \dots \dots \dots (6)$$

$$KT = Hg/H0 \dots \dots \dots (7)$$

Os dados foram submetidos a uma análise de consistência para determinação dos valores a serem removidos com aplicação de filtros na limitação de (ω_s), da (H_g) em função de H_0 , de (K_T) e (K_d) conforme Tabela 2.1, resultando em uma redução de aproximadamente 7% dos dados (De Miguel et al. 2001; Lopez et al. 2004; Younes et

al., 2005; Ruiz-Arias et al. 2010; Ihya et al., 2015; Pashiardis et al., 2016). Deve-se observar que a limitação da fração difusa (K_d) para valores acima de um (1), refere-se aos valores obtidos em função da correção isotrópica que eleva os valores da fração difusa em condições de céu totalmente nublado.

Tabela 2.1 - Controle de qualidade

Tipo	Filtro
Elevação solar (α)	1. Ângulo $\leq 10^\circ$
Fração da irradiação global e difusa (K_T e K_d)	2. Limitação: $0 \leq K_T \leq 1$ e $0 \leq K_d \leq 1$
Irradiação global (H_g)	3. Limitação: $H_g \leq H_0$

2.3.3 Modelo Estatístico (ME)

Na elaboração do modelo estatístico, os valores da fração difusa (K_d) e da transmissividade atmosférica (K_T) calculados a partir de dados experimentais medidos foram correlacionados (Liu e Jordan, 1960) e suas equações de estimativa foram ajustadas por regressão polinomial entre as frações com uma parte maior dos dados e validadas com o restante do conjunto da mesma base e descritos no item 2.3.3.1.

2.3.3.1 Elaboração e validação do Modelo Estatístico (ME)

Na concepção do ME os dados foram reorganizadas retirando-se uma parte para elaboração e outra para validação do modelo de acordo com Tabela 2.2. Para validação do modelo, os dados foram reorganizados em duas bases anuais e independentes denominadas de Ano Típico (AT) e Ano Atípico (AAT) para irradiação difusa (H_d).

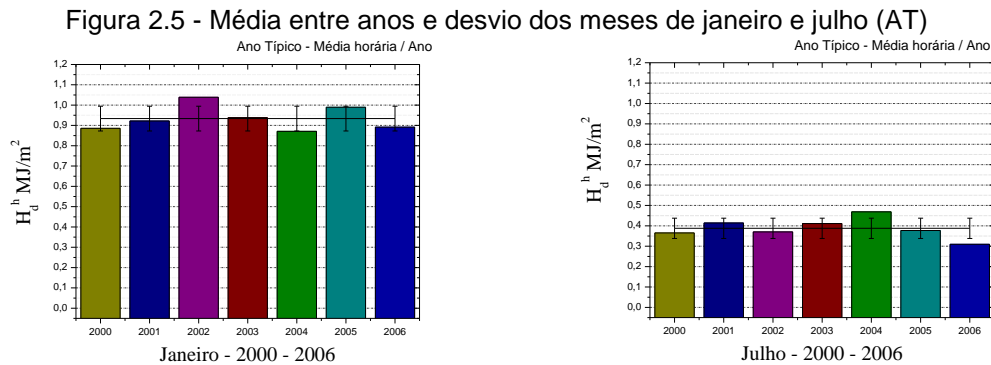
Esta reorganização foi realizada através de relação estatística da média do valor de (H_d) de cada mês de toda a série assim como o intervalo de variação do desvio padrão. Na sequência, comparou-se para cada mês de cada ano o valor de (H_d), a média horária entre os anos, considerando o intervalo de variação do desvio padrão da média total com o valor de (H_d), da média de cada ano.

Tabela 2.2 - Dados para elaboração e validação modelo estatístico

Total de dados (2000 – 2006)	Total de dados para elaboração do modelo estatístico	
2.348 (100%)	1.703 – 72,53%	
	Dados para validação do modelo estatístico	
	Total de dados da base AT	Total de dados da base AAT
	324 – 13,79%	321 – 13,67%

Após análise, selecionou-se para cada mês da série (janeiro/2000 - dezembro/2006) os valores próximos a média (acima ou abaixo), como Ano Típico (AT) e mais afastados (acima ou abaixo), como Ano Atípico (AAT). A Figura 2.5

apresenta a média e o intervalo do desvio padrão na seleção dos meses onde as colunas representam a média horária de (H_d) de cada ano e as linhas contínuas representam média horária de (H_d) entre os anos e seu desvio padrão.



Como descrito, a seleção dos meses que constituem um Ano Típico (AT) é similar ao processo de seleção do Ano Meteorológico Típico (WMO, 1981). A Tabela 2.3 apresenta os meses e os anos que constituem um Ano Típico (AT) e um Ano Atípico (AAT) dos dados analisados da (H_d).

No destaque da Tabela 2.3, para o mês de janeiro, o AT foi 2003, enquanto Julho foi 2005. Nestes dois meses, os valores das irradiações médias entre os anos praticamente coincidiram com os valores das irradiações médias do ano. Diferentemente do AAT, os valores das irradiações médias do ano estão mais distantes (acima ou baixo) dos valores das irradiações médias entre os anos. Assim para os mesmos meses, o mês de Janeiro, o AAT foi 2002, e Julho foi 2004.

Tabela 2.3 - Base Ano Típico (AT) e Ano Atípico (AAT)

	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
AT	2003	2000	2001	2001	2000	2001	2005	2001	2006	2006	2005	2001
AAT	2002	2003	2000	2004	2004	2002	2004	2000	2005	2005	2001	2005

Realizada a fase de organização da base de dados, descreve-se na sequência a metodologia utilizada para treinamento e validação das técnicas RNA/MLP e SVM e suas parametrizações.

2.3.4 Técnicas de aprendizado de máquina

No treinamento das técnicas de aprendizado de máquina foram desenvolvidos um *script's* para treinamento e outro para validação, com diferentes funções e parametrização para cada tipo de técnica utilizada. A validação foi realizada com a base de dados denominada de Ano típico (AT) e Atípico (AAT) descrito no item 2.3.3.1 e quantificados de acordo com apresentado na tabela 2.4.

Diferentemente do modelo estatístico, que utiliza um conjunto de dados com as variáveis (K_T) e (K_d) para modelagem, no treinamento das técnica são definidos uma

sequência de combinações (arranjos) com variáveis climatológicas determinadas a partir dos dados medidos e ou calculados, disponíveis como entrada para as redes de acordo com Tabela 2.5.

Tabela 2.4 - Dados para elaboração e validação das redes.

Total de dados (2000 – 2006)	Total dados de treinamento – AT	Total dados de treinamento - AAT
2.348 (100%)	2.024 – 86,20%	2.027 - 86,33%
	Dados para validação das redes	Dados para validação das redes
	Total de dados da base AT	Total de dados da base AAT
	324 – 13,80%	321 – 13,68%

As variáveis da Tabela 2.5 consistem em valores medidos de (H_g) irradiação global (MJ/m^2), de (H_{wa}) irradiação de ondas longas atmosféricas (MJ/m^2), ($umid$), umidade (UR , %) e (tar), temperatura (T , °C) e calculados como (H_0) irradiação no topo da atmosfera (MJ/m^2), da transmissividade atmosférica ou índice de claridade (K_T) Eq. (6) e fração difusa (K_d) Eq. (7), ($decsol$), declinação solar (°C) Eq. (5) e ($nebul$), nebulosidade (%) calculada em função da proporcionalidade das medidas da irradiância direta ($I_b - W/m^2$) dos valores abaixo de $120 W/m^2$. Conforme a WMO (2008), em seu guia de instrumentos meteorológicos e métodos de observação, este valor foi adotado com limiar para o brilho do sol, ou seja, para valores inferiores a esses, considera-se sem insolação. Outros arranjos foram analisados, porém em função das condições de seleção das variáveis, as mesmas não foram utilizadas.

Tabela 2.5 - Combinações e variáveis de entrada

Combinações	Variáveis de: Entrada								Saída
combinação 1	Kt								K _d
combinação 2	Kt	H ₀							
combinação 3	Kt	H ₀	H _g						
combinação 4	Kt	H ₀	H _g	H _{wa}					
combinação 5	Kt	H ₀	H _g	H _{wa}	decsol				
combinação 6	Kt	H ₀	H _g	H _{wa}	decsol	nebul			
combinação 7	Kt	H ₀	H _g	H _{wa}	decsol	nebul	umid		
combinação 8	Kt	H ₀	H _g	H _{wa}	decsol	nebul	umid	tar	

medido/calculado
 calculado
 medido

Definidas as combinações das variáveis de entrada apresentam-se na sequência a metodologia para treinamento das redes.

2.3.4.1. Treinamento da MLP

Na implementação da técnica MLP os conjuntos de dados foram submetidos para execução no software MATLAB R2014 que pode ser descrito como uma

ferramenta computacional com aplicação em diversas áreas. Permite o desenvolvimento e análise de sistemas matemáticos, estatísticos, de otimização e controle, com uma linguagem de programação dinâmica e uma ampla disponibilidade de funções para serem implementadas nas técnicas de aprendizado de máquina. O treinamento da rede MLP foi realizado com o algoritmo *Levenberg-Marquadt* (*trainlm*) e implementado pela função *feedforwardnet*. Foi parametrizado pelo número de camadas ocultas, do número de neurônios, da quantidade máxima de épocas de treinamento e das funções de ativação. A definição do número de camadas foi realizada em duas fases, sendo a primeira com uma camada escondida (n_1) e a segunda inserindo-se mais uma camada (n_2). O número de neurônios iniciais para cada camada escondida foram definidas em partes atendendo aos valores mínimos proposto por Fletcher e Gloss (1993) e apresentados na Tabela 2.6.

Tabela 2.6 - Valores para parametrização da rede MLP

Topologias	1	2	3	4	5	6
nº de neurônios	5	10	20	40	80	160

O número máximo de épocas foi fixado em mil (1.000) interações e a função de ativação nas camadas ocultas à tangente Hiperbólica (*tansig*) definida conforme as características dos dados de entrada e linear na camada de saída. A parametrização da primeira fase foi idêntica à segunda fase.

Nas duas fases são realizados dez (10) treinamentos para cada combinação (Tabela 2.5) testando todas as topologias da Tabela 2.6. O critério do treinamento é a validação cruzada (70% treinamento, 15% para validação e 15% para teste). Em cada interação (épocas), os erros (EQM – Erro quadrático médio) entre os valores estimados e medidos da validação são avaliados e se forem diminuindo significa que a rede está aprendendo até que este erro comece a aumentar durante uma sequência de seis (6) interações (épocas) sucessivas. Caso este erro da validação no treinamento aumente enquanto do treinamento continuar caindo é provável que a rede esteja com *overfitting*, condição que indica a parada do treinamento. Este critério minimiza o risco de *underfitting* da rede. Sendo definida a melhor rede em cada treinamento (menor EQM do treinamento) todas as combinações são validadas com os dados reorganizados (AT e AAT) em cada fase e escolhida a fase e a combinação que apresentar o melhor desempenho.

2.3.4.2 Treinamento da SVM

Na implementação da técnica SVM o conjunto de dados foram submetidos para execução no software da *Waiko Environment for Knowledge Analysis - WEKA* (Hall et al., 2009), ferramenta *KDD – Knowledge Discovery in Databases*, que agrega uma série de algoritmos de preparação de dados, aprendizagem e de validação de resultados de forma interativa. No treinamento e teste foi utilizado o algoritmo de regressão SVM/SMO – Otimização Mínima Sequencial com função de transformação de base radial (RBF) de *Kernel* com método de validação cruzada e submetido a validação de acordo com o conjunto de combinações e dados apresentados na Tabela 2.4. Os parâmetros da configuração básica do método SVM/SMO como o parâmetro de margem (C) que determina o ponto de equilíbrio entre a maximização da margem e minimização do erro e que controla a influência de cada vetor, o parâmetro (γ) que controla a flexibilidade da função de *Kernel* e verifica seu ajustamento (*overfitting* e *underfitting*) e o parâmetro (ϵ) erros de tolerância são definidos testando-se todos os valores de acordo com a Tabela 2.7 e determinados empiricamente.

Tabela 2.7 - Valores para parametrização da SVM.

(C)	1.0	10.0	50.0	100.0	200.0	300.0
(γ)	0.1	0.2	0.3	0.4	0.5	0.6
(ϵ)	0.05	0.05	0.05	0.05	0.05	0.05

2.3.5 Indicativos Estatísticos

Para analisar os resultados dos indicadores de treinamento das redes foi utilizado o EQM - erro quadrático médio (*Mean Square Error*) que indica o erro médio entre os valores estimados e medidos, sendo os melhores resultados aqueles com desvios menores mais próximos dos valores desejados. Os indicadores de validação utilizados são: o RMSE, raiz quadrada do erro quadrático médio (*Root Mean Square Error*), que permite verificar o valor do erro produzido pelo modelo, sendo que valores menores, indicam um desempenho satisfatório para os modelos gerados, testados ou treinados e validados, ou seja, mostra o desempenho do modelo quanto ao seu espalhamento; e o R^2 , coeficiente de determinação, que permite verificar o quanto a variação da variável dependente é explicada pela variação da variável independente através da equação do modelo, e r , coeficiente de correlação que permite verificar o quanto o valor medido se aproxima do valor estimado, ou seja, a correlação existente entre as variáveis (Stone, 1993; Escobedo et al. 2011).

Os indicadores são obtidos pelas seguintes relações:

$$EQM = \left[\frac{\sum_i^N (Ei - Mi)^2}{N} \right]$$

$$RMSE = 100 * \frac{[\frac{\sum_i^N (Ei - Mi)^2}{N}]^{1/2}}{\bar{M}}$$

$$R^2 = \left(\frac{\sum_{i=1}^N (Mi - \bar{M}i)^2 * \sum_{i=1}^N (Ei - \bar{E}i)^2}{\sqrt{\sum_{i=1}^N (Mi - \bar{M}i)^2} * \sqrt{\sum_{i=1}^N (Ei - \bar{E}i)^2}} \right)^2$$

$$r = \left(\frac{\sum_{i=1}^N (Mi - \bar{M}i) * \sum_{i=1}^N (Ei - \bar{E}i)}{\sqrt{\sum_{i=1}^N (Mi - \bar{M}i)^2} * \sqrt{\sum_{i=1}^N (Ei - \bar{E}i)^2}} \right)$$

onde Ei são os valores estimados, $\bar{E}i$, é a média dos valores estimados, Mi são os valores medidos, $\bar{M}i$ é a média dos valores medidos, N é o número de observações.

2.4 - RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados e discussões para estimativa de (K_d), utilizando modelagem estatística com uma variável, os resultados obtidos por meio das Rede Neural/MLP e SVM com variáveis climatológicas de referência e por último uma análise de desempenho dos modelos estatístico e das redes. Ao final alguns indicadores encontrados em trabalhos similares da literatura.

2.4.1 Modelo Estatístico


O modelo estatístico elaborado da correlação de (K_d) em função de (K_T) (Figura 2.6 (a)) é similar as curvas encontradas na literatura, assim como as equações de estimativa (Equação 8) ajustada por regressão polinomial de 4ª ordem e com coeficiente de determinação na ordem $R^2 = 0.9162$ o que demonstra que (K_d) está correlacionado com (K_T) estatisticamente. Outras equações de ordens polinomiais foram elaboradas, mas apresentando coeficiente de determinação menores.

$$Kd = 0,981 + 0,0894 * KT - 0,462 * KT^2 - 5,881KT^3 + 5,585 * KT^4 \dots\dots\dots(8)$$

São apresentadas na Figura 2.6 (b) e (c) as curvas de dispersão geradas na validação do modelo ME para Ano típico (AT) e atípico (AAT), com os valores dos dados medidos (marrom), dos dados de validação (amarelo) e da estimativa (vermelho).

Os indicadores estatísticos RMSE e o r para Ano típico (AT) e atípico (AAT) resultantes da análise na validação dos modelos ME são apresentados na Tabela 2.8.

Figura 2. 6 - a) Curva de dispersão ME e validação para: b) AT; c) ATT



O modelo ME na base AT apresentou uma correlação satisfatória ($r = 0.953$) e um erro quadrático aceitável (RMSE = 19.95%) assim como na base de validação AAT, que também apresentou uma correlação satisfatória ($r = 0.949$) e um erro quadrático bom (RMSE = 18.66%), mostrando que ambos os modelos podem ser utilizados na estimativa da fração difusa na partição diária, considerando a variável disponível na maioria das estações meteorológicas.

Diferentemente de uma análise na partição horária, que é mais sensível às mudanças atmosféricas, na partição diária essas mudanças são dispersas ao longo do dia, fazendo com que essa variação seja menor.

Tabela 2.8 – Índices estatísticos do ME.

Partição DIARIA					
Variáveis de:		Indicadores estatísticos			
Entrada	Saida	Ano típico (AT)		Ano atípico (AAT)	
Modelo Estatístico - ME		RMSE (%)	r	RMSE (%)	r
K_t	K_d	19.95	0.9533	18.66	0.9490

Na tabela 2.9 é apresentada a comparação do resultado encontrado do r e de RMSE da literatura com o melhor resultado do modelo estatístico para partição diária.

Tabela 2.9 – Índices estatísticos - outras localidades e ME para Botucatu

Autores	Localidade	r	RMSE %
Khorasanizadeh et al. 2016	Irã	0,8767	
Bortolini et al. 2013	Madri	0,9628	
Shamshirband et al. 2016	Irã	0,8156	
Oliveira et al. 2002a	São Paulo	0,9000	
ME AT – Proposto 2017	Botucatu/São Paulo	0,9533	19,95
ME AAT – Proposto 2017	Botucatu/São Paulo	0,9490	18,66

Os resultados mostram valores similares ou até superiores em indicadores de correlação entre os modelos, indicando que podem ser utilizados na estimativa da

fração difusa, tendo em vista que a elaboração dos modelos seguem as mesmas características construtivas.

2.4.2 Técnicas RNA/MLP e SVM

Os indicadores das combinações das técnicas MLP e SVM são apresentados na Tabela 2.10 com os melhores resultados experimentados na parametrização e seus indicadores estatísticos após treinamento e validação realizados pelas redes MLP e SVM com as duas bases de validação.

Observa-se através dos indicadores de (K_d) que o índice de correlação (r) entre os valores medidos e estimados nas duas bases de validação com a rede MLP variou entre 0,9531 a 0,9649 e com a SVM entre 0,9497 a 0,9608, mostrando, a princípio, uma boa correlação em ambas as técnicas.

No treinamento da rede MLP o erro quadrático médio (EQM) foi bem menor do que a rede SVM em todas as combinações. Isto pode estar relacionado ao algoritmo de treinamento das técnicas. Com a rede MLP o algoritmo do tipo *LM* proporciona um melhor ajustamento dos pesos diferentemente da técnica SVM com o algoritmo SMO que depende do ajustamento das margens dos vetores de suporte que regula a quantidade de vetores e conseqüentemente do número de amostras e variáveis que participam do treinamento.

Após realizados todos os treinamentos com as topologias indicadas, tem-se, na tabela 2.10, a configuração e parametrização das melhores combinações e topologias. São apresentadas as funções de ativação escolhida, o número de neurônios da primeira e segunda camada, o número de época do melhor desempenho no treinamento, o termo de maximização das margens entre os vetores de suporte, o erro de tolerância e de desvio e os indicadores estatísticos dos valores estimados em função dos valores medidos na validação.

Os índices de desempenho (RMSE) nas duas bases de validação das técnicas MLP variaram entre os valores 15,56% a 19,98% e para a SVM entre os valores 16,62% a 20,04% entre todas as combinações.

Observa-se que a rede MLP apresentou os melhores resultados de validação na base AT quando sete variáveis de entrada (combinação (7)) participaram do treinamento, e quando foram utilizadas duas (2) camadas escondidas. Porém, após os dez (10) treinamentos realizados, a melhor combinação não foi a que apresentou o menor EQM de treinamento.

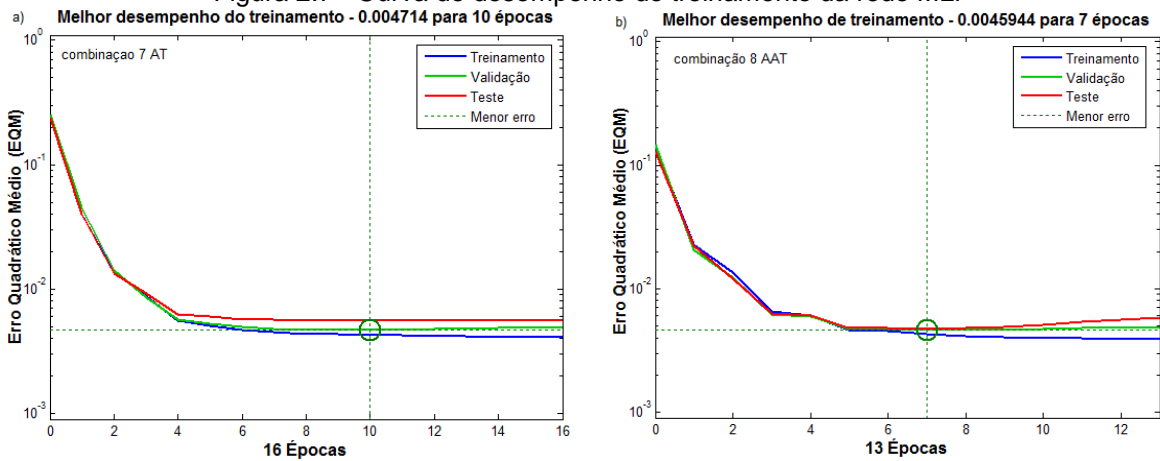
Tabela 2.10 - - Indicadores e configurações das redes MLP e SVM

Configuração e parametrização das Técnicas de Aprendizado de Máquinas - Partição diária																
TÉCNICA MLP																
	Para Ano típico (AT)			Indicadores estatísticos					Para Ano típico (AAT)			Indicadores estatísticos				
	Função de ativação	Camada:1/2	Épocas	Treinamento		Validação			Função de ativação	Camada:1/2	Épocas	Treinamento		Validação		
				MSE	RMSE (%)	MSE	RMSE (%)	r				MSE	RMSE (%)	MSE	RMSE (%)	r
Combinação 1	tansig	n1-5/n2-10	19	0.0058	19.29	0.0066	19.98	0.9531	tansig	n1-5/n2-40	5	0.0057	19.56	0.0067	18.30	0.9510
Combinação 2	tansig	n1-5/n2-40	4	0.0054	18.68	0.0066	19.87	0.9537	tansig	n1-5/n2-10	7	0.0054	18.99	0.0065	18.01	0.9526
Combinação 3	tansig	n1-10/n2-40	4	0.0054	18.71	0.0065	19.77	0.9541	tansig	n1-5/n2-40	4	0.0054	19.03	0.0064	17.92	0.9531
Combinação 4	tansig	n1-20/n2-10	4	0.0054	18.66	0.0064	19.66	0.9547	tansig	n1-5/n2-10	8	0.0054	18.91	0.0063	17.79	0.9538
Combinação 5	tansig	n1-5/n2-20	7	0.0054	18.60	0.0063	19.44	0.9557	tansig	n1-20/n2-5	5	0.0053	18.78	0.0067	18.28	0.9511
Combinação 6	tansig	n1-5/n2-20	43	0.0043	16.60	0.0052	17.70	0.9634	tansig	n1-10/n2-10	10	0.0045	17.25	0.0055	16.59	0.9599
Combinação 7	tansig	n1-5/n2-20	10	0.0045	17.12	0.0050	17.34	0.9649	tansig	n1-10/n2-10	17	0.0044	17.02	0.0056	16.65	0.9596
Combinação 8	tansig	n1-40/n2-10	7	0.0039	15.91	0.0051	17.48	0.9643	tansig	n1-10/n2-5	7	0.0044	17.10	0.0048	15.56	0.9649

TÉCNICA SVM																
	Para Ano típico (AT)			Indicadores estatísticos					Para Ano atípico (AAT)			Indicadores estatísticos				
	Coeficiente de parametrização			Treinamento		Validação			Coeficiente de parametrização			Treinamento		Validação		
	C	γ	ε	MSE	RMSE (%)	MSE	RMSE (%)	r	C	γ	ε	MSE	RMSE (%)	MSE	RMSE (%)	r
Combinação 1	100	0.2	0.05	0.2860	30.32	0.0067	20.04	0.9528	200	0.2	0.05	0.2881	30.55	0.0069	18.53	0.9497
Combinação 2	200	0.2	0.05	0.2835	29.78	0.0065	19.69	0.9545	300	0.2	0.05	0.2862	30.15	0.0067	18.30	0.9510
Combinação 3	300	0.2	0.05	0.2835	29.80	0.0065	19.70	0.9545	300	0.2	0.05	0.2864	30.20	0.0067	18.33	0.9509
Combinação 4	100	0.2	0.05	0.2825	29.55	0.0064	19.54	0.9552	300	0.2	0.05	0.2853	29.99	0.0066	18.20	0.9516
Combinação 5	100	0.2	0.05	0.2832	29.72	0.0064	19.66	0.9546	300	0.2	0.05	0.2835	29.81	0.0067	18.34	0.9508
Combinação 6	100	0.2	0.05	0.2793	28.90	0.0061	19.12	0.9572	300	0.2	0.05	0.2796	28.97	0.0060	17.29	0.9564
Combinação 7	100	0.2	0.05	0.2791	28.86	0.0061	19.08	0.9573	300	0.2	0.05	0.2795	28.93	0.0059	17.18	0.9570
Combinação 8	300	0.2	0.05	0.2733	27.69	0.0056	18.32	0.9608	50	0.1	0.05	0.2728	27.38	0.0055	16.62	0.9598

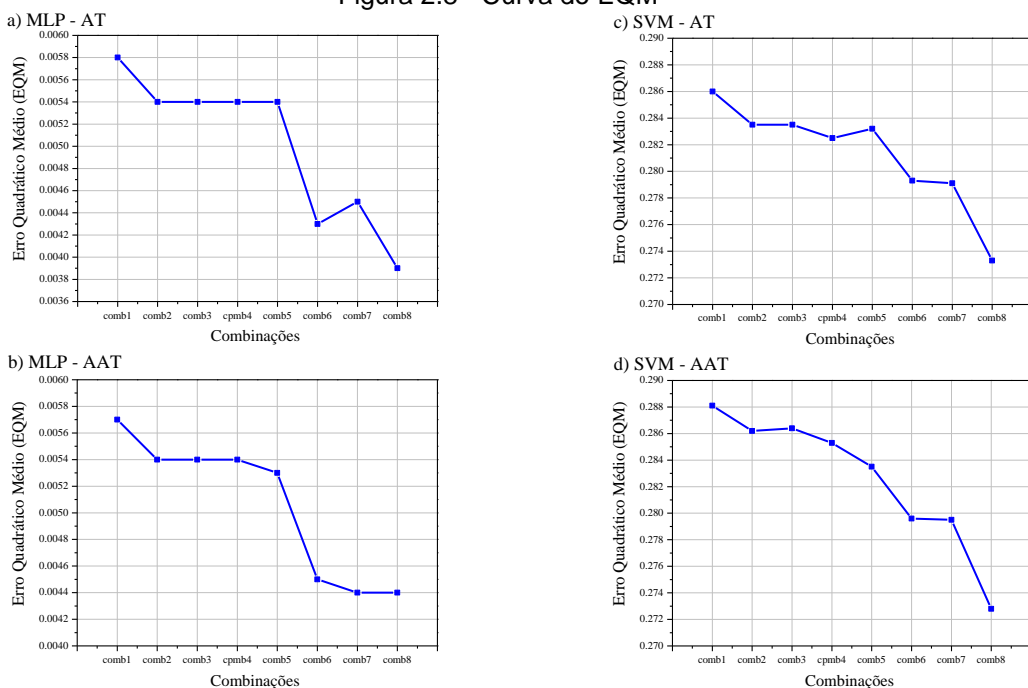
Os gráficos da Figura 2.7 (a) e (b) demonstram o comportamento das curvas do EQM e o número de épocas utilizadas na melhor combinação da validação para base AT e AAT de treinamento da rede MLP. Em destaque (linha tracejada e círculo verde), o ponto com o menor erro após o treinamento. O amortecimento suave das curvas e a quantidade de épocas caracterizam um treinamento com pouca dificuldade e baixa complexidade de aprendizagem. Estas características devem-se principalmente pelo comportamento físico das variáveis de entrada.

Figura 2.7 - Curva de desempenho do treinamento da rede MLP



Através dos gráficos da Figura 2.8 (a) e (b) é possível verificar a importância de outras variáveis de entrada no treinamento tendo em vista que com a inserção de outras variáveis no treinamento das redes há uma diminuição do EQM e consequentemente um melhor desempenho no treinamento.

Figura 2.8 - Curva do EQM



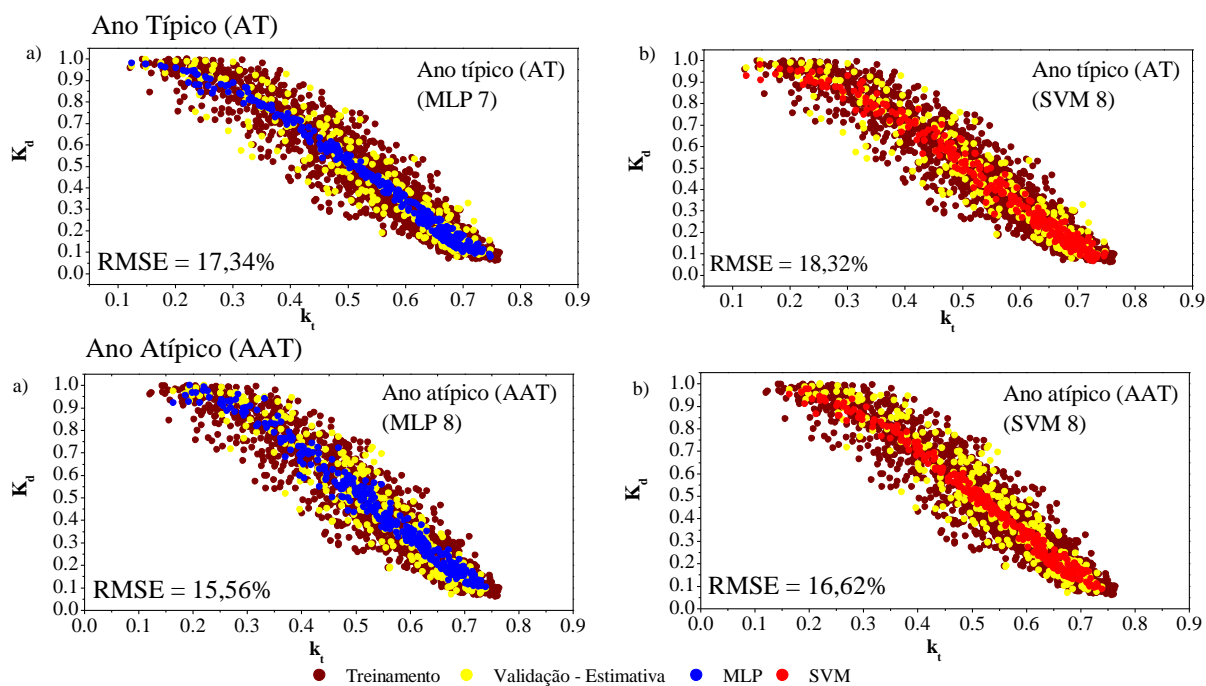
Com a técnica SVM, os melhores resultados na validação com a base AT e AAT foram quando oito (8) variáveis de entrada participaram do treinamento. Observa-se através dos gráficos da Figura 2.8 (c) e (d) que conforme as variáveis de entrada são introduzidas no treinamento o EQM diminui promovendo a capacidade de generalização do problema para este caso e parametrização específico. Outras parametrizações de ajustamento foram testadas, mas não resultaram em melhoria dos indicadores.

Analisando os indicadores da Tabela 2.10 em relação aos indicadores apresentados na Tabela 2.8 (indicadores de correlação e desempenho do modelo estatístico), as duas técnicas utilizadas apresentaram um desempenho melhor. Em média uma redução para rede MLP de aproximadamente 17,5% e para SVM de 10%.

Na rede MLP e SVM a inserção de outras variáveis no treinamento contribuí para um melhor desempenho conforme pode ser observado na Figura 2.8 (a) e (b) com uma diminuição do EQM de treinamento com vantagem para utilização da técnica MLP principalmente pela sua parametrização.

Para um melhor entendimento de exatidão entre os valores medidos e estimados, a Figura 2.9 (a), (b), (c) e (d) mostra a dispersão apresentada com as duas técnicas e suas melhores combinações para estimativa da fração difusa nas duas bases AT e AAT.

Figura 2.9 - Curva de dispersão de (K_d) x (K_T) - melhores combinações de AT e AAT



Importante ressaltar que os resultados encontrados referem-se às combinações proposta e que a alteração dos parâmetros de entrada e da quantidade podem influenciar na configuração das parametrizações e dos indicadores de desempenho das técnicas, como no ajustamento dos parâmetros da técnica SVM com o algoritmo SMO.

Neste caso, o parâmetro C que determina o ponto de equilíbrio entre a maximização da margem dos vetores de suporte e a minimização do erro que controla a influência de cada vetor, assim como na técnica MLP, que dependendo do algoritmo de treinamento parâmetros, como taxa para aprendizagem do termo momentum que visa acelerar a convergência ao menor erro entre o valor medido e estimado.

São apresentados na Tabela 2.11 alguns indicadores do coeficiente de correlação (r) e/ou do valor da raiz quadrado do erro quadrático médio (RMSE) de alguns trabalhos da literatura que utiliza de TAM e o melhor resultado de cada rede para partição diária encontrado neste trabalho. Deve-se ressaltar que mesmo com as variáveis de entrada para treinamento das técnicas não serem as mesmas existem uma forte correlação entre elas.

Tabela 2.11 – Índices estatísticos - outras localidade e TAM para Boutcatu

Autores	Localidade	Técnicas	Variáveis de entrada	r	RMSE(%)
Elminir et. al (2007)	Cairo/Egito	Perceptron	Radiação global e extraterrestre e brilho solar.		2,52 – 5,96
Xue (2017)	Chengdu China	Perceptron	Mês do ano, duração da luz do sol, temperatura média, precipitação, velocidade do vento, umidade relativa e radiação solar global diária	0,9340	
Ihya et. al (2014)	Marrocos	Perceptron	Transmissividade da irradiação global e fotoperíodo	0,9596	18,73
Jiang (2008)	Zhengzhou, China	Perceptron	Índice de claridade	0,9591	
Modelo MLP (AAT)	Botucatu/SP	MLP	Transmissividade irradiação global, Radiação no topo da atmosfera, Global e de Ondas longas, declinação solar, nebulosidade, umidade e temperatura.	0,9649	15,56
Modelo SVM (AAT)	Botucatu/SP	SVM	Transmissividade da irradiação global, Radiação no topo da atmosfera, Radiação Global, Radiação de ondas longas, declinação solar, nebulosidade, umidade e temperatura.	0,9598	16,40

Os resultados encontrados são para as combinações e variáveis da Tabela 2.5 sendo que outras combinações podem ser testadas verificando o comportamento e desempenho das técnicas em seus treinamentos. Com estas mudanças também são necessárias outras parametrizações, como na escolha do número de camadas, de

neurônios, da função de ativação e ajustamento. Com estas mudanças é possível avaliar se a inserção de cada variável irá impactar no desempenho da rede com valores mais significativos para estimativa de (K_d).

Com os resultados apresentados, a rede MLP mostrou-se a mais indicada das Técnicas de Aprendizado de Máquina na estimativa da fração difusa (K_d) com o uso de variáveis climatológicas e meteorológicas, como também superior aos resultados apresentados pelo modelo estatístico.

2.5 CONCLUSÃO

Do que foi apresentado e discutido no presente trabalho é conclusivo que:

1. a equação polinomial de 4º (Eq. 9) com $R^2 = 0.9163$ pode ser utilizada para estimar a fração difusa da irradiação global com valores de validação de $RMSE_{AT} = 19,95\%$ e $RMSE_{AAT} = 18,66\%$ similares aos encontrados na literatura;

2. as técnicas MLP e SVM selecionadas para estimativa da fração difusa mostraram baixos valores do erro quadrático médio (EQM) nos treinamentos em todas as combinações com inserções de variáveis.

3. as parametrizações propostas para as arquiteturas foram adequadas para redução do erro quadrático médio (EQM), do treinamento e da raiz do erro quadrático médio (RMSE) da validação além de minimizar o tempo e esforço computacional no treinamento.

4. a validação das TAM mostraram resultados (valores de RMSE) similares ou superiores aos apresentados na literatura pesquisada;

5. a validação das TAM mostraram resultados (valores de RMSE) similares ou superiores ao ME na mesma de condição de entrada (K_T);

6. a validação das TAM (MLP e SVM) com a inserção das variáveis astronômicas, meteorológicas e geográficas melhoraram o desempenho das técnicas na forma sequencial nas arquiteturas propostas;

7. o desempenho (RMSE) das técnicas MLP e SVM é superior ao modelo estatístico na maioria das combinações utilizadas.

Neste contexto, entende-se que as técnicas de aprendizado de máquina, ora estudadas, tem o desempenho melhor e pode auxiliar no processo de estimativa da fração difusa da irradiação global.

REFERÊNCIAS

ALAM, S.; KAUSHIK, S. C.; GARG, S. N. Computation of beam solar radiation at normal incidence using artificial neural network. **Renewable Energy**. v.31, p.1483–1491, 2006.

ALAM, S.; KAUSHIK, S.C.; GARG, S. N. Assessment of diffuse solar energy under general sky condition using artificial neural network. **Applied Energy**, vol. 86, p. 554–564, 2009.

ANTONANZAS-TORRES, F. et al. Generation of daily global solar irradiation with support vector machines for regression. **Energy Conversion and Management**, vol. 96, p. 277–286, 2015.

ASSOULINE, D.; MOHAJERI, N.; SCARTEZZINI, J. L. 2017. Quantifying rooftop photovoltaic solar energy potential: A machine learning approach. , vol. 141, p. 278 – 296, 2017.

BAKIRCI, K. Models for the estimation of diffuse solar radiation for typical cities in Turkey. **Energy**. vol. 82, p. 827 – 838, 2015.

BELAID, S.; MELLIT, A. Prediction of daily and mean monthly global solar radiation using support vector machine in an arid climate. **Energy Conversion and Management**, vol. 118, p. 105–118, 2016.

BOLAND, J.; SCOTT, L.; LUTHER, M. Modelling the diffuse fraction of global solar radiation on a horizontal surface. **Environmetrics**, vol. 12, p. 103 –117, 2001.

BORTOLINI, M. et al. Multi-location model for the estimation of the horizontal daily diffuse fraction of solar radiation in Europe. **Energy Conversion and Management**, vol. 67, p. 208–216, 2013.

BOZDAR, M. Z. et al. Spatially transferable regional model for half-hourly values of diffuse solar radiation for general sky conditions based on perceptron artificial neural networks. **Renewable Energy**, vol. 103, p. 794 – 810, 2017.

ÇELİK, O. et al. The optimized artificial neural network model with Levenberge Marquardt algorithm for global solar radiation estimation in Eastern Mediterranean. **Journal of Cleaner Production**, vol. 116, p. 1 -12, 2016.

CHANDRASEKARAN, J.; KUMAR, S. Hourly diffuse fraction correlationa at a tropical location. **Solar Energy**, vol. 53, n° 6, p. 505 – 510, 1994.

CHAVES, M.; ESCOBEDO, J. F. A software to process daily solar radiation data, **Renewable Energy**, vol.19(1), p. 339 – 344, 2000.

CHEN, J. L. et al. Assessing the transferability of support vector machine model for estimation of global solar radiation from air temperature. **Energy Conversion and Management**, vol. 89, p. 318–329, 2015.

CODATO, G. et al. Global and diffuse solar irradiances in urban and rural areas in southeast Brazil. **Theoretical and Applied Climatology**, vol. 93, p. 57–73, 2008.

COLLARES-PEREIRA, M.; RABL, A. The average distribution on solar radiation – correlations between diffuse and hemispherical and between daily and hourly insolation values. **Solar Energy**, vol. 22, p. 155 - 164, 1979.

DAL PAI, A. et al. MEO shadowing method for measuring diffuse solar irradiance: corrections based on sky cover. **Renewable Energy**, vol. 99, p.754 - 76, 2016.

DE MIGUEL, A. et al. Diffuse solar irradiation model evaluation in the north Mediterranean Belt Area. **Solar Energy**, vol. 70, n. 2, p. 143 – 153, 2001.

DRECHMER, P. A. O.; RICIERI, R. P. Irradiação global, direta e difusa, para a região d Irradiação global, direta e difusa, para a região de para a região de Cascavel, Estado e Cascavel, Estado do Paraná do Paraná. **Acta Scientiarum Technology**, vol. 28, n. 1 p. 73 – 77, 2006.

DRUMMOND, A. J. Serie B. vol. 7, Issue 3 - 4, p. 413 – 436, 1956.

ELIZONDO, D.; HOOGENBOOM, G.; MCCLENDON, R. W. Development of a neural network model to predict daily solar radiation. **Agricultural and Forest Meteorology**, vol. 71, p. 115 - 132, 1994.

ELMINIR, H. K.; AZZAM, Y. A.; YOUNES, F. I. Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. **Energy**, vol. 32, p. 1513 – 1523, 2007.

ESCOBEDO, J. F. et al. Efeito da cobertura do céu no aumento das frações solar difusa e par-difusa em estufa de polietileno. **Avances en Energías Renovables y Medio Ambiente**, Vol. 17, p.02.19-02.25, 2013.

ESCOBEDO, J. F. et al. 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.

FLETCHER, D. S., GOSS, E. Forecasting with neural network: an application using bankruptcy data. **Information Management**, vol.24, p.159–67, 1993.

FURLAN, C. et al. The role of clouds in improving the regression model for hourly values of diffuse solar radiation. **Applied Energy**, vol. 92, p. 240 – 254, 2012.

GUEYMARD, C. REST2: high-performance solar radiation model for cloudless sky irradiance, illuminance, and photosynthetically active radiation e validation with a benchmark dataset, **Solar Energy**, vol. 82, p. 272 – 285, 2008.

HALL, M. et al. The WEKA data mining software: an update; **SIGKDD Explorations**, vol. 11, Issue 1; 2009.

HAYKIN, S. Redes neurais: princípios e prática. 2.ed. Porto Alegre, Bookman, 2001.

IHYA, B. et al. Prediction of hourly and daily diffuse solar fraction in the city of Fez (Morocco). **Theor Appl Climatol**, vol. 120, p.737 – 749, 2014.

JACOVIDES, C. P. et al. Comparative study of various correlations in estimating hourly diffuse fraction of global solar radiation. **Renewable Energy**, vol. 31, p. 2492 – 2504, 2006.

JAMIL, B.; AKHTAR, N. Estimation of diffuse solar radiation in humid-subtropical climatic region of India: Comparison of diffuse fraction and diffusion coefficient models. **Energy**, vol. 131, p. 149 – 164, 2017.

KALOGIROU, S. **Applied Energy**, vol. 67, p. 17 – 35, 2000.

KAMBEZIDIS, H. D. et al. Meteorological Radiation Model (MRM v6.1): Improvements in diffuse radiation estimates and a new approach for implementation of cloud products. **Renewable and Sustainable Energy Reviews**, vol. 74, p. 616 – 637, 2017.

KAUSHIKA, N. D.; TOMAR, R. K.; KAUSHIK, S. C. Artificial neural network model based on interrelationship of direct, diffuse and global solar radiations. **Solar Energy**, vol. 103, p. 327–342, 2014.

KHATIB, T. et al. Assessment of Artificial Neural Networks for Hourly Solar Radiation Prediction. **International Journal of Photoenergy**, vol. 2012, p. 1 - 8, 2012.

KHORASANIZADEH, H.; MOHAMMADI, K.; GOUDARZI, N. Prediction of horizontal diffuse solar radiation using clearness index based empirical models: A case study. **International Journal of Hydrogen Energy**, vol. 41, p. 21888 – 21898, 2016.

KUMAR, R.; AGGARWAL, R. K.; SHARMA, J. D. Comparison of regression and artificial neural network models for estimation of global solar radiations. **Renewable and Sustainable Energy Reviews**, vol. 52, p. 1294 – 1299, 2015.

KUO, C. W.; CHANG, W. C.; CHANG, K. C. Modeling the hourly solar diffuse fraction in Taiwan. **Renewable Energy** 66, 56–61. 2014a.

LAURET, P. et al. A benchmarking of machine learning techniques for solar radiation forecasting in an insular context. **Solar Energy**, vol. 112, p. - 446–457, 2015.

LIU, B. H. Y.; JORDAN, R. C. The interrelationship and characteristic distribution of direct, diffuse and total solar radiation. **Solar Energy**, vol. 4, p. 1, 1960.

LOPEZ, G. L.; MUNEER, T.; CLAYWELL, R. Assessment of four shadow band correction models using beam normal irradiance data from the United Kingdom and Israel. **Energy Conversion and Management**, vol. 45, p.1963 – 1979, 2004.

MARQUES FILHO, E. P. et al. Global, diffuse and direct solar radiation at the surface in the city of Rio de Janeiro: Observational characterization and empirical modeling. **Renewable Energy**, vol. 91, p. 64 – 74, 2016.

MARTINEZ, C.; CÚNSULO, M. Seguidor automático para bloqueador de radiación solar. **Avances en Energías Renovables y Medio Ambiente**, 2017.

MCCULLOCH, W.; S; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, vol. 5, p. 115 – 133, 1943.

MELO, J. M. D.; ESCOBEDO, J. F. Medida da radiação solar difusa. In: Energias Limpas em progresso. VII Congresso Ibérico de Energia Solar, Vigo, Espanha. Anais **International Solar Energy Society**, vol. 1, 1994.

MOHAMMADI, K. et al. Support vector regression based prediction of global solar radiation on a horizontal surface. **Energy Conversion and Management**, vol. 91, p. 433–441, 2015a.

MOHAMMADI, K. et al. Determining the most important variables for diffuse solar radiation prediction using adaptive neuro-fuzzy methodology; case study: City of Kerman, Iran. **Renewable and Sustainable Energy Reviews**, vol. 53, p. 1570–1579, 2016.

MOHAMMADI, K. et al. A new hybrid support vector machine–wavelet transform approach for estimation of horizontal global solar radiation. **Energy Conversion and Management**, vol. 92, p. 162–171, 2015b.

MOUSTRIS, K. et al. Use of neural networks for the creation of hourly global and diffuse solar irradiance data at representative locations in Greece. **Renewable Energy**, vol. 33, p. 928 – 932, 2008.

OLIVEIRA, A. P. et al. Correlation models of diffuse solar-radiation applied to the city of São Paulo, Brazil. **Applied Energy**, vol. 71, p. 59 – 73, 2002a.

OLIVEIRA, A. P., ESCOBEDO, J. F., MACHADO, A. J. A new shadow-ring device for measuring diffuse solar radiation at surface. **Journal Atmos. Ocean. Technol.** Vol.19, p. 698 – 708, 2002b.

ORGILL, J. F.; HOLLANDS, G. T. Correlation equation for hourly diffuse radiation on a horizontal surface. **Solar Energy**, vol. 9, p. 357 – 359, 1977.

PASHIARDIS, S.; KALOGIROU, S. A. Quality control of solar shortwave and terrestrial longwave radiation for surface radiation measurements at two sites in Cyprus. **Renewable Energy**, vol. 96, p. 1015 – 1033, 2016.

PAULESCU, E.; BLAGA, R. Regression models for hourly diffuse solar radiation. **Solar Energy**, vol. 125, p. 111 – 124, 2016.

PLATT, J. C. Sequential Minimal Optimization: A Fast Algorithm For Training Support Vector Machines. **Technical Report Note**. Msr-tr-98-14. Microsoft Research. Seattle. 1998.

QUEJ, V. H. et al. Empirical models for estimating daily global solar radiation in Yucatán Peninsula, Mexico. **Energy Conversion and Management**, vol. 110, p. 448 – 456, 2016.

REINDL, D. T.; BECKMAN W. A.; DUFFIE, J. A. Diffuse fraction correlations. **Solar Energy**, v.45, p.1 – 7, 1990.

ROBINSON, H., STOCH, L. Sky radiation and measurements and corrections. **Journal of Applied Meteorology**, v.3, p.179-81, 1964.

ROSSI, T. J. et al. Global, diffuse and direct solar radiation of the infrared spectrum in Botucatu. **Renewable and Sustainable Energy Reviews**, vol. 82, p. 448 – 459, 2018b.

ROSSI, T. J. et al. Estimativas das frações solares g nir) e difusa (d nir) infravermelha em função das frações (K_T) e (K_d) do espectro total. **VII Congresso Brasileiro de Energia Solar** – Gramado, 17 a 20 de abril de 2018a.

RUIZ-ARIAS, J. A. et al. Proposal of a regressive model for the hourly diffuse solar radiation under all sky conditions. **Energy Conversion and Management**, vol. 51, p. 881 – 893, 2010.

SANTOS C. M.; ESCOBEDO J. F. Temporal variability of atmospheric turbidity and DNI attenuation in the sugarcane region, Botucatu/SP. **Atmospheric Research**, vol. 181, p. 312- 321, 2016.

SANTOS, C. M. et al. Assessment of ANN and SVM models for estimating normal direct irradiation (H_b). **Energy Conversion and Management**, vol. 126, p. 826–836, 2016.

SHAMSHIRBAND, S. et al. Estimating the diffuse solar radiation using a coupled support vector machine–wavelet transform model. **Renewable and Sustainable Energy Reviews**, vol. 56, p.428–435, 2016.

SILVA, F. R.; OLIVEIRA, H. S. M.; MARINHO, G. S. Análise das componentes global e difusa da radiação solar em Natal-RN entre 2007 e 2008. **II Congresso Brasileiro de Energia Solar e III Conferência Regional Latino-Americana da ISES** - Florianópolis, 18 a 21 de novembro de 2008

SILVA, M. B. P. et al. Performance of the Angstrom-Prescott Model (A-P) and SVM and ANN techniques to estimate daily global solar irradiation in Botucatu/SP/Brazil. **Journal of Atmospheric and Solar–Terrestrial Physics**, vol. 160, p. 11–23, 2017.

SIMÓN-MARTÍN, M.; DÍEZ-MEDIAVILLA, M.; ALONSO-TRISTÁN, C. Shadow-band radiometer measurement of diffuse solar irradiance: Calculation of geometrical and total correction factors. **Solar Energy**, vol. 139, p. 85 – 99, 2016.

SOARES, J. et al. Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. **Applied Energy**, vol. 79, p. 201-214, 2004.

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

TEKE, A.; YILDIRIM, H. B.; CELIK, O. Evaluation and performance comparison of diferente models for the estimation of solar radiation. **Renewable and Sustainable Energy Reviews**, vol. 50, p. 1097 – 1107, 2015.

TERAMOTO, E. T.; ESCOBEDO, J. F. Análise da frequência anual das condições de céu em Botucatu, São Paulo. **Revista Brasileira Engenharia Agrícola Ambiental**. v.16, n. 9, p.985-992, 2012.

TERAMOTO, E. T. et al. Uso de modelos estatísticos e de máquina de vetores de suporte na estimativa da radiação solar global diária em Iguape, Vale do Ribeira, São Paulo. **Avances en Energías Renovables y Medio Ambiente**, vol. 20, p. 11.17-11.24, 2016.

TOMAR, R. K.; KAUSHIKA, N. D.; KAUSHIK, S. C. Artificial neural network based computational model for the prediction of direct solar radiation in Indian zone. **Journal of Renewable and Sustainable Energy**. Vol. 4, p.063 – 146, 2012.

TYMVIOS, F. S. et al. Comparative study of Ångström's and artificial neural networks' methodologies in estimating global solar radiation. **Solar Energy**, vol. 78, p. 752-762, 2005.

VAPNIK, C. N. Support-vector networks. **Mach Learn**, vol.20, p. 3 – 273, 1995.

VAPNIK, V. N. Statistical learning theory. New York: Wiley, 1998.

WMO – World Meteorological Organization. Guide to meteorological Instruments and Methods of Observation. **WMO-nº8, Seventh Edition**, p.1 - 681, Geneva, Switzerland, 2008.

WMO - 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, p. 298, 1981.

XUE, X. Prediction of daily diffuse solar radiation using artificial neural networks. **International Journal of Hydrogen Energy**. vol. 42, p. 28214 – 28221, 2017.

YADAV, A. K.; CHANDEL, S. S. Solar radiation prediction using Artificial Neural Network techniques: A review. **Renewable and Sustainable Energy Reviews**, vol, 33, p. 772 – 781, 2014.

YOUNES, S.; CLAYWELL, R.; MUNEER, T. Quality control of solar radiation data: Present status and proposed new approaches. **Energy**, vol. 30, p. 1533 – 1549, 2005.

CONSIDERAÇÕES FINAIS

A partir dos resultados apresentados sobre estimativas de (K_d) por meio de (TAM) na partição horária (Capítulo 1) do tipo MLP, RBF, GRNN e ANFIS e diária (Capítulo 2) do tipo MLP e SVM, pode-se afirmar que as técnicas proporcionaram resultados mais satisfatórios comparados aos modelos estatísticos (ME) possuindo validade em aplicações de estimativa somente para o local de origem das medidas e com as variáveis utilizadas. Há grande vantagem na utilização das técnicas, principalmente na utilização de diversas variáveis climatológicas de diferentes grandezas na estimativa. Isso é possível pela forma com que são calculados os ajustes dos pesos de cada variável. Para cada interação realizada no treinamento das técnicas, os valores de entrada se ajustam a fim de aproximar os valores de entrada à saída desejada. Apesar da grande variabilidade de (K_d) na partição horária, ocasionada principalmente pelas mudanças dos constituintes atmosféricos que acontecem ao longo do dia, é possível determinar um único valor de (K_d), como pode ser observado pelos gráficos de espalhamento dos valores de (K_d) em função de (K_T). Diferentemente do modelo estatístico, elaborado com uma variável independente e que resulta em um valor de (K_d) que na prática proporcionam incerteza em suas estimativas conforme a dispersão apresentada.

Na partição diária (Capítulo 2) os resultados também mostraram que diferentemente da técnica utilizada (MLP e SVM), os valores indicam uma redução significativa dos índices de precisão, o que mostra que as técnicas, independentemente da partição utilizada, é uma alternativa na estimativa de (K_d). Assim como na partição horária, há diminuição da variabilidade de (K_d) em relação às mudanças dos constituintes atmosféricos ao longo do dia, é possível também determinar um único valor de (K_d) em função das variáveis utilizadas no treinamento. Importante ressaltar que, através das TAM não se pode afirmar com certeza qual a variável que mais ou menos influenciou na estimativa.

Entre algumas desvantagens e dificuldades encontradas com as TAM nos capítulos 1 e 2, destacam-se: a determinação das variáveis a serem utilizadas no treinamento, os arranjos das combinações e ajustes a serem realizados na parametrização das redes. Porém, tem como grande vantagem a de suprir a necessidade de informações de medidas de radiações com maior eficiência e que não

são monitoradas com frequência, contribuindo também com estudos espaciais e no monitoramento realizado por satélite.

Por fim a análise realizada por meio das TAM permitiu a determinação de estimativas com maior precisão e eficiência mais próximas aos valores medidos o que mostra a importância do uso destas técnicas. Estes resultados mostram que as técnicas podem ser utilizadas como alternativa aos modelos de estimativas utilizados na literatura.

Sugestão para trabalhos futuros:

- Introduzir outras variáveis climatológicas;
- Avaliar variáveis individualmente;
- Realizar uma análise de componentes principais;
- Propor outros arranjos;
- Utilizar outras arquiteturas de RNA;
- Testar outras parametrizações das TAM.
- Estimar com outras técnicas de aprendizado de máquina;
- Considerar medidas anisotrópicas e de referência;
- Testar as redes com dados medidos de outras localidades; e
- Embarcar o treinamento das técnicas em outras localidades para estimativa da irradiação difusa.

REFERÊNCIAS

- ALAM, S.; KAUSHIK, S.C.; GARG, S. N. Assessment of diffuse solar energy under general sky condition using artificial neural network. **Applied Energy**, vol. 86, p. 554–564, 2009.
- BEHRANG, M. A. et al. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. **Solar Energy**, vol.84, p. 1468 – 1480, 2010.
- BOZNAR, M. Z. et al. Spatially transferable regional model for half-hourly values of diffuse solar radiation for general sky conditions based on perceptron artificial neural networks. **Renewable Energy**, vol. 103, p. 794 – 810, 2017.
- BURNETT, D.; BARBOUR, E.; HARRISON, G. P. The UK solar energy resource and the impact of climate change. **Renewable Energy**, vol. 71, p. 333 – 343, 2014.
- CHANDRASEKARAN, J.; KUMAR, S. Hourly diffuse fraction correlationa at a tropical location. **Solar Energy**, vol. 53, nº 6, p. 505 – 510, 1994.
- COLLARES-PEREIRA, M.; RABL, A. The average distribution on solar radiation – correlations between diffuse and hemispherical and betwenn daily and hourly insolation values. **Solar Energy**, vol. 22, p. 155 - 164, 1979.
- DAL PAI, A. et al. MEO shadowring method for measuring diffuse solar irradiance: corrections based on sky cover. **Renewable Energy**, vol. 99, p.754 - 76, 2016.
- ELIZONDO, D.; HOOGENBOOM, G.; MCCLENDON, R. W. Development of a neural network model to predict daily solar radiation. **Agricultural and Forest Meteorology**, vol. 71, p. 115 - 132, 1994.
- ELMINIR, H. K.; AZZAM, Y. A.; YOUNES, F. I. Prediction of hourly and daily diffuse fraction using neural network, as compared to linear regression models. **Energy**, vol. 32, p. 1513 – 1523, 2007.
- FENG, P. Y. et al. Comparison of artificial intelligence and empirical models for estimation of daily diffuse solar radiation in North China. **International Journal of Hydrogen Energy**, p. 1 – 11, 2017.
- FURLAN, C. et al. The role of clouds in improving the regression model for hourly values of diffuse solar radiation. **Applied Energy**, vol. 92, p. 240 – 254, 2012.
- HAYKIN, S. Redes neurais: princípios e prática. 2.ed. Porto Alegre, Bookman, 2001.
- IHYA, B. et al. Prediction of hourly and daily diffuse solar fraction in the city of Fez (Morocco). **Theor Appl Climatol**, vol. 120, p.737 – 749, 2014.
- JACOVIDES, C. P. et al. Comparative study of various correlations in estimating hourly diffuse fraction of global solar radiation. **Renewable Energy**, vol. 31, p. 2492 – 2504, 2006.
- JAMIL, B.; SIDDIQUI, A. T. Generalized models for estimation of diffuse solar radiation basedon clearness index and sunshine duration in India: Applicability under different

climatic zones. **Journal of Atmospheric and Solar–Terrestrial Physics**, vol. 157–158, p. 16 – 34, 2017.

JIANG, Y. Prediction of monthly mean daily diffuse solar radiation using artificial neural networks and comparison with other empirical models. **Energy Policy**, vol. 36, p. 3833 – 3837, 2008.

KAMBEZIDISA, H. D. et al. Meteorological Radiation Model (MRM v6.1): Improvements in diffuse radiation estimates and a new approach for implementation of cloud Products. **Renewable and Sustainable Energy Reviews**, vol. 74, p.616 – 637, 2017.

KUMAR, R.; AGGARWAL, R.K.; SHARMA, J. D. Comparison of regression and artificial neural network models for estimation of global solar radiations. **Renewable and Sustainable Energy Reviews**, vol. 52, p. 1294 – 1299, 2015.

KUO, C. W.; CHANG, W. C.; CHANG, K. C. Modeling the hourly solar diffuse fraction in Taiwan. **Renewable Energy** 66, p. 56–61. 2014

LAZAREVSKA, E.; TRPOVSKI, J. Neuro-Fuzzy Model of the Solar Diffuse Radiation With Relevance Vector Machine. **IEEE Xplore Digital Library**, 2011.

LIU, B. H. Y.; JORDAN, R. C. The interrelationship and characteristic distribution of direct, diffuse and total solar radiation. **Solar Energy**, vol. 4, p. 1, 1960.

MARQUES FILHO, E. P. et al. Global, diffuse and direct solar radiation at the surface in the city of Rio de Janeiro: Observational characterization and empirical modeling. **Renewable Energy**, vol. 91, p. 64 – 74, 2016.

MOHAMMADI, K. et al. Identifying the most significant input parameters for predicting global solar radiation using an ANFIS selection procedure. **Renewable and Sustainable Energy Reviews**, vol. 63, p.423 – 434, 2016b.

SANTOS, C. M. et al. Assessment of ANN and SVM models for estimating normal direct irradiation (H_b). **Energy Conversion and Management**, vol. 126, p. 826–836, 2016.

SILVA, F. R.; OLIVEIRA, H. S. M.; MARINHO, G. S. Análise das componentes global e difusa da radiação solar em Natal-RN entre 2007 e 2008. **II Congresso Brasileiro de Energia Solar e III Conferência Regional Latino-Americana da ISES** - Florianópolis, 18 a 21 de novembro de 2008

SOARES, J. et al. Modeling hourly diffuse solar-radiation in the city of São Paulo using a neural-network technique. **Applied Energy**, vol. 79, p. 201-214, 2004.

VOYANT, C. et al. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, vol. 105, p.569 – 582, 2017.

WANG, L.; et al. Solar radiation prediction using different techniques: model evaluation and comparison. **Renewable and Sustainable Energy Reviews**, vol. 61, p. 384 – 397, 2016.

APÊNDICE A – REVISÃO BIBLIOGRÁFICA

1. Radiação Solar

Considerada como uma das principais fontes de energia em diversos processos atmosféricos e terrestres, a radiação solar é um termo generalizado da energia emitida pelo Sol resultante de uma conversão química com a emissão de 62.000 kW/m^2 de energia. Deste total uma pequena parte conhecida como Constante Solar ($I_{sc} = 1367 \text{ W/m}^2$) atinge o topo da atmosfera terrestre e ao incidir na atmosfera recebe o nome de radiação solar extraterrestre.

A radiação solar extraterrestre pode ser definida como potência incidente por unidade de área (W/m^2) e denominada irradiância solar extraterrestre (I_0 , W/m^2) (Equação A.1) quando calculada instantaneamente e integradas nas partições horárias e diárias recebe o nome de irradiação solar extraterrestre (H_0 , MJ/m^2) (Iqbal, 1983, Chaves e Escobedo, 2000).

$$I_0 = I_{sc} \cdot E_0 \cdot \cos \theta_z \dots \dots \dots (A.1)$$

onde E_0 (adimensional) é fator de correção da excentricidade da Terra (Equação A.2), θ_z (0 Celsius) é ângulo entre a vertical e a linha do sol conhecida como ângulo zenital (Equação A.3).

$$E_0 = 1,000110 + 0,034221 \cdot \cos \Gamma + 0,001280 \cdot \sin \Gamma + 0,000719 \cdot \cos 2 \Gamma + 0,000077 \cdot \sin 2 \Gamma \dots (A.2)$$

onde Γ (radianos) é definido como sendo o ângulo diário da irradiação solar extraterrestre dado pela Equação (A.4)

$$\theta_z = \arccos(\sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega_s) \dots \dots \dots (A.3)$$

onde ϕ (0 Celsius) a latitude local, δ (0 Celsius) o ângulo da declinação solar (Equação A.5), e ω_s (radianos) o ângulo horário (Equação A.6).

$$\Gamma = 2\pi \left(\frac{Dj-1}{365} \right) \dots \dots \dots (A.4)$$

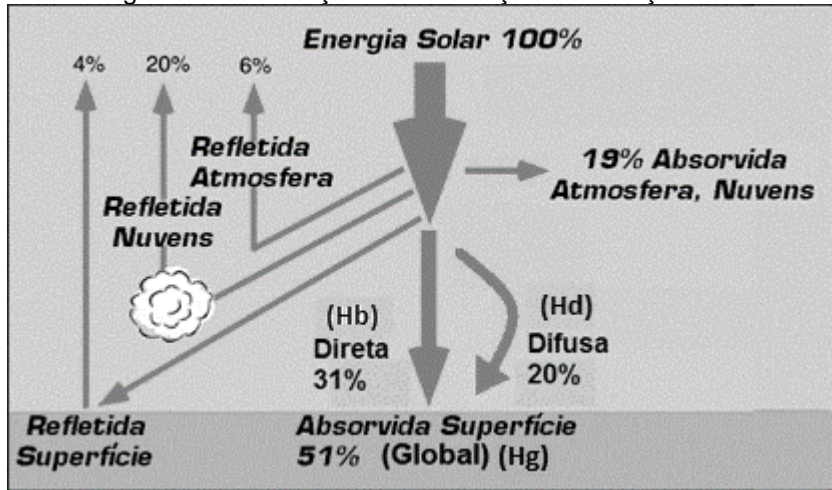
onde Dj é o dia juliano (para primeiro de janeiro, $Dj = 1$, e para 31 de dezembro, $Dj = 365$).

$$\delta = 23,45 \cdot \sin \left[\frac{360 \cdot (Dj + 284)}{365} \right] \dots \dots \dots (A.5)$$

$$\omega_s = \cos^{-1}[-\tan(\phi) \cdot \tan(\delta)] \dots \dots \dots (A.6)$$

Mesmo que a atmosfera seja percebida como transparente somente uma parte (51%) dessa energia é absorvida pela superfície da Terra. O restante (69%) é ou refletida pela superfície (4%) ou pelas nuvens (20%) ou pela atmosfera (6%) de volta para o espaço e absorvida (19%) pela atmosfera ou nuvens. A Figura A.1 apresenta a distribuição da radiação solar incidente na atmosfera.

Figura A1 – Ilustração da distribuição da radiação solar



Fonte: adaptado de Marques (2108)

Ao atingir a superfície terrestre a irradiação solar extraterrestre (H_0 , MJ/m²) recebe o nome de irradiância solar global (I_g , W/m²) para valores instantâneos e irradiação solar global (H_g , MJ/m²) para valores integrados.

A irradiância solar global é composta por duas componentes: a irradiação solar direta (I_b , W/m²) e a irradiação solar difusa (I_d , W/m²) dada pela relação ($I_g = I_b + I_d$).

A irradiância solar direta (I_b , W/m²) para valores instantâneos ou irradiação solar direta (H_b , MJ/m²) para valores integrados é definida como a parcela da irradiação no topo (H_0) que ao incidir na atmosfera não sofre interação com nenhum constituinte atmosférico como aerossóis e vapor d'água, atingindo uma superfície em um ângulo de incidência normal e convertida para irradiância solar direta na horizontal (I_b) por meio da Equação (A.7).

$$I_b = I_b n \cdot \cos\theta_z \dots\dots\dots(A.7)$$

onde θ_z é o ângulo zenital (graus) Equação (A.3).

A irradiância solar difusa (I_d , W/m²) para valores instantâneos ou irradiação solar difusa (H_d , MJ/m²) para valores integrados é proveniente do espalhamento da irradiação direta (I_b ou H_b) que interage com os constituintes atmosféricas como gases, aerossóis e vapor d'água e das multireflexões ocorridas neste trajeto.

As medidas de (I_g) são realizadas diretamente através de um piranômetro e as medidas de (I_{bn}) por um pireliômetro acoplado a um rastreador solar. Para medidas de (I_d) são utilizados um piranômetro com anel de sombreamento (Melo e Escobedo, 1994) com as seguintes especificações: 80 cm de diâmetro, 10 cm de largura e 1mm de espessura. Os valores da (I_d) foram corrigidos por um fator de correção isotrópico (FC) dado pela Equação A.8, para compensar a parcela da (I_d) obstruída pelo próprio anel, as quais dependem de parâmetros geométricos como largura e raio, geográficos como latitude e os astronômicos como a declinação solar (Oliveira et. al, 2002 a e b).

$$FC = \left[1 - \left(\frac{Hd'}{Hd} \right) \right]^{-1} \dots\dots\dots(A.8)$$

onde (H_d) é a irradiação solar difusa (MJ/m^2) de referência, obtida pelo método indireto, enquanto que (H_d') é a irradiação solar difusa (MJ/m^2) interceptadas durante o dia pelo anel de sombreamento. A razão ($H d' / Hd$) é calculada pela Equação A.9.

$$\frac{Hd'}{Hd} = \left(\frac{2b}{\pi R} \right) * \cos(\delta) * \left[\frac{\cos(\phi+\delta)}{\cos \phi} \right]^2 * \int_0^\omega \cos \theta_z * (d\omega) \dots\dots\dots(A.9)$$

onde (b) e (R) são a largura e raio do anel, (δ) é a declinação solar (Equação A.10), (ϕ) é a latitude local, (θ_z) é o ângulo zenital (Equação A.11) e (ω_s) é o ângulo horário do sol (Equação A.12), variando do nascer até o pôr do sol.

$$\delta = 23,45 * \sin[(360 * (Dj + 284))/365] \dots\dots\dots(A.10)$$

onde Dj é dia juliano.

$$\theta_z = \ar \cos (\sin \phi \sin \delta + \cos \phi \cos \delta \cos \omega_s) \dots\dots\dots(A.11)$$

$$\omega_s = \cos^{-1}[-\tan(\phi) * \tan(\delta)] \dots\dots\dots(A.12)$$

Para compensar o efeito da nebulosidade sobre a correção isotrópica (Equação A.8) que aumenta a radiação difusa e também o efeito anisotrópico da radiação difusa que também é barrada pelo anel de sombreamento, mas diminui esses valores no sentido crescente de céu parcialmente nublado para céu aberto, foi proposto (Dal Pai et al., 2014 e 2016) um segundo fator de correção em função da transmissividade atmosférica e apresentado na Tabela 1.1.

Tabela 1.1 - Fatores de correção anisotrópica

Cobertura de céu	Equação de Correção Anisotrópica	R ²
Nublado	$I_{dani} = 0,973 * I_{diso}$	0,994
Parcialmente nublado	$I_{dani} = 1,045 * I_{diso}$	0,989
Aberto	$I_{dani} = 1,125 * I_{diso}$	0,984

I_{dani} = Irradiância anisotrópica (W/m^2) e I_{diso} = Irradiância isotrópica (W/m^2). Fonte: Dal Pai et al., 2016

Esses fatores tem se mostrado eficientes na correção da irradiância difusa isotrópica, aproximando a medida do anel de sombreamento em menos de 1% da medida de referência dada pelo método da diferença ($I_d = I_g - I_b$) (Dal Pai et al., 2016). Assim como neste trabalho a maioria das medidas da (I_d) realizadas pelos métodos de sombreamento são aplicadas somente correção isotrópica (Oliveira et al., 2002a e b; Soares et al., 2004; Codato et al., 2008; Marques Filho et al., 2016). A imprecisão da medida da irradiação solar difusa pelo piranômetro no anel de sombreamento é da ordem de 8,7%, sendo 4,1% do piranometro PSP da Eppley (Reda et al., 2008) e 4,6% do efeito anisotrópico para cobertura total de céu (Dal Pai et al. 2016).

O conhecimento dos valores integrados da radiação permite a realização de vários estudos quanto ao comportamento das variações ocorridas em função da hora e do dia da radiação solar e para um bom aproveitamento é imprescindível conhecer a disponibilidade da radiação solar em uma determinada localidade. Isto é possível através do monitoramento periódico e com isto levantar o potencial de radiação solar de uma região tendo em vista as diversas mudanças que podem ocorrer em função da variação sazonal principalmente das radiações direta e difusa.

Para atenuar essas variações é proposto o emprego das frações ou índices radiométricos (razão entre as componentes da radiação solar) permitindo assim minimizar os efeitos astronômicos e geográficos da radiação solar considerando a possibilidade das componentes da radiação solar serem obtidas no mesmo local e tempo. Importante destacar que os efeitos decorrentes dos constituintes atmosféricos permanecem e podem afetar a evolução das medidas obtidas ao longo do tempo.

Os primeiros a correlacionarem as frações transmitidas da irradiação global com a fração da irradiação difusa foi proposto 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 de outras condições intermediárias propostas (Iqbal, 1983; Dal Pai; Escobedo, 2001; Teramoto; Escobedo, 2012).

As frações da irradiação solar difusa (K_d) e da irradiação solar global (K_T) foram calculadas pelas relações das medidas da irradiação difusa (H_d), irradiação global (H_g) e irradiação no topo da atmosfera (H_0) dada pelas Equações A.13 e A.14.

$$K_d = H_d/H_g \dots\dots\dots(A.13)$$

$$K_t = H_g/H_0 \dots\dots\dots(A.14)$$

onde H_0 é a irradiação solar no topo da atmosfera (MJ/m^2).

2. Técnicas de Aprendizado de Máquina

Problemas envolvendo resultados, decisões, incertezas e imprecisões de uma situação real têm sido resolvido em anos recentes com o conceito de aprendizado através do treinamento a partir de um conjunto de informações ou de experiências adquiridas ao longo do tempo. A solução destes problemas pode ser realizada de forma estática onde informações conhecidas são utilizadas para estimativa ou de forma dinâmica onde além de características conhecidas outras medidas em tempos reais são utilizadas na previsão.

Este conceito é a base do princípio de funcionamento das Técnicas de Aprendizado de Máquina que é similar ao processo de aprendizado do cérebro humano onde através de um conjunto de informações ou de experiências adquiridas (dados de entrada) é possível obter, através de treinamentos (aprendizado), uma série de resultados futuros (dados de saída).

Essa relação tornar-se mais eficiente quando uma nova informação ou experiência é adquirida. Isto acontece pois as técnicas reconhecem padrões de diferentes complexidades e grandezas e através de algoritmos de aprendizagem estabelecer uma associação continua e construtiva entre as informações ou dados de entradas e saídas. Geralmente as situações de aprendizado estão relacionadas em aproximar um conjunto de informações conhecidas (x_i , entrada) há um conjunto de informações desejados (y_i , saída).

Entre as Técnicas de Aprendizado de Máquina (TAM) utilizadas para estimar radiação solar em superfícies horizontais ou inclinadas destacam-se as Redes Neurais Artificiais (RNA) amplamente utilizadas na literatura, Máquina de Vetores de Suporte (SVM) que vem se destacando com uma alternativa, além de outras como Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS) (Yadav e Chandel, 2014; Lauret et al., 2015; Santos et. al, 2016; Assouline et. al, 2017).

Na sequência são descritos os princípios e conceitos básicos das Técnicas de Aprendizado de Máquina para estimativa da fração difusa na partição diária.

2.1. Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) podem ser descritas como modelos computacionais baseados no sistema neural dos seres humanos. São definidas como

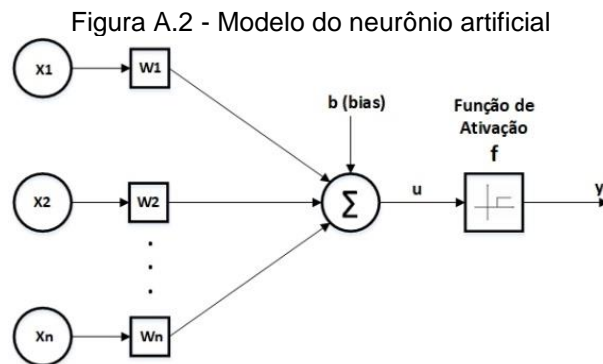
um conjunto de neurônios artificiais ligados por um conjunto de conexões denominadas sinapses (Silva et al. 2010).

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 dependem 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 proposto por Warren McCulloch e Walter Pitts (McCulloch e Pitts, 1943), ilustrado na Figura (A.2).



Fonte: adaptado de McCulloch e Pitts (1943)

Essa ilustração matemática resultou em um modelo com n terminais de entrada x_1, x_2, \dots, x_n que representam os dendritos, e 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.

As Equações (A.15) e (A.16) sintetizam o comportamento matemático de um neurônio artificial:

$$u_j(k) = \sum_{i=1}^n x_i * w_i + b \dots \dots \dots (A.15)$$

$$y_j(k) = g_j(u(k)) \dots \dots \dots (A.16)$$

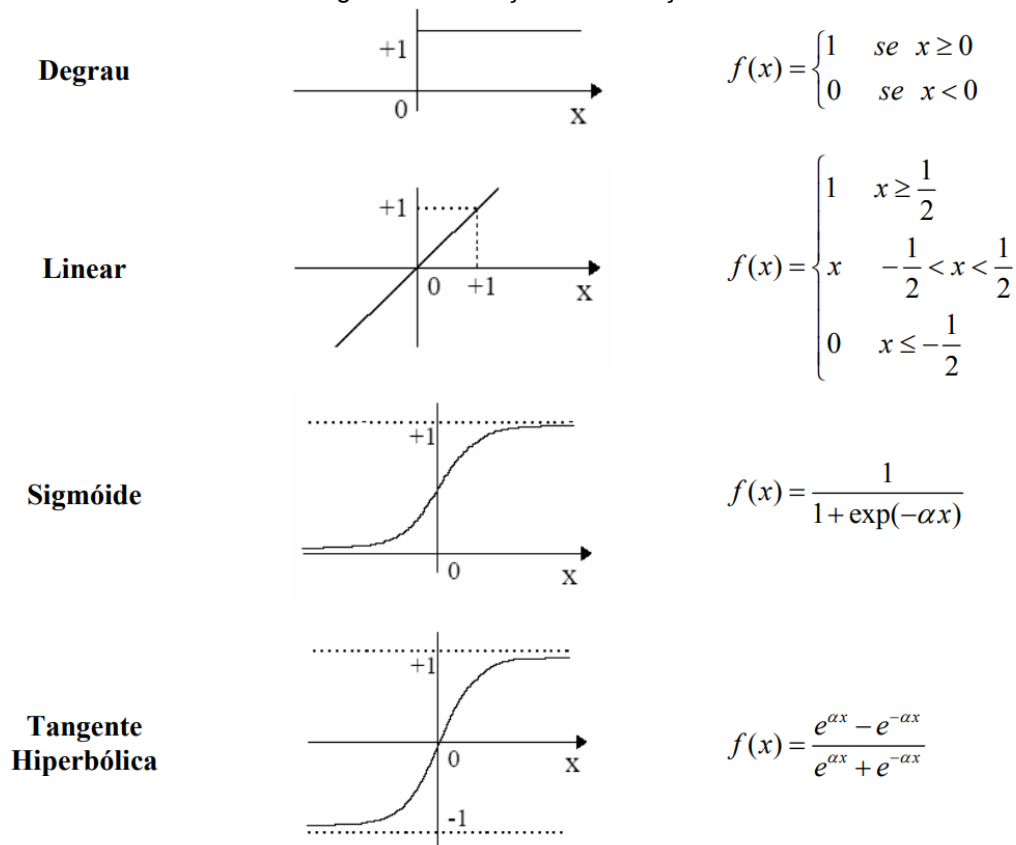
onde n é o número de variáveis de entradas do neurônio; x_i é a i –ésima variável de entrada do neurônio; w_i é o peso associado com a i –ésima variável de entrada; b é o limiar associado ao neurônio; $g(k)$ é a resposta ponderada (soma da junção) do

neurônio j –ésimo em relação ao instante k ; $g(.)$ é a função de ativação do neurônio j –ésimo; $y_i(k)$ é a variável de saída do j –ésimo neurônio em relação ao instante k .

Quando um sinal x_i é aplicado a entrada do neurônio, estes são multiplicados por um peso sináptico w_i 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 $u(k)$ 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. Geralmente os dados são normalizados no intervalo de $[0$ a $1]$ ou $[-1$ a $1]$ tendo em vista que todas as variáveis de entrada estejam num mesma ordem de magnitude. A Figura (A.3) apresenta as principais funções de ativação disponível.

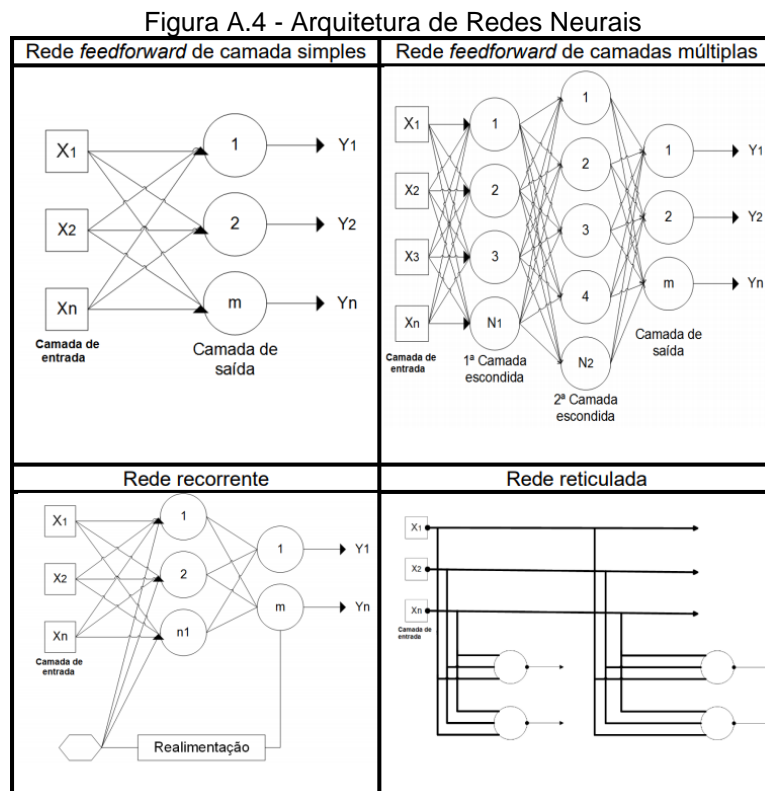
Figura A.3 - Funções de ativação



Durante o treinamento de uma rede neural, há a determinação e a correção dos pesos ($w_{n1,n}$) e dos limiares (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 A.4):



Fonte: Clerice (2014)

a) As redes de uma camada se caracterizam por possuir uma camada de neurônios 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).

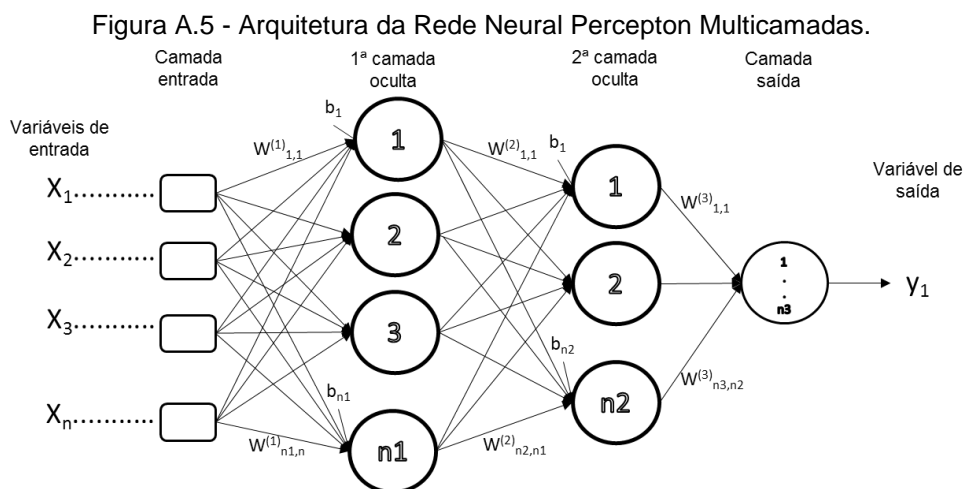
O treinamento de uma rede consiste em um processo de ajuste dos pesos sinápticos de forma que um conjunto de valores de entrada seja capaz de produzir valores de saída desejados. Os treinamentos podem ser:

- *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 dos pesos e limiares (bias) objetivando sempre minimizar o erro ao máximo;
- *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).

2.1.1. Perceptron Multicamadas (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_{n1n}) e dos limiares (bias) (θ_{b1}), para que a mesma responda de forma desejada, minimizando o erro de saída para cada vetor de entrada.

A Figura (A.5) apresenta a estrutura de uma rede MLP, onde a primeira camada é a entrada (x_n), a segunda possui uma ou mais camadas ocultas de nós computacionais com pesos de ligações (w_{n1n}) 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.



Fonte: adaptado de 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 alguns 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, este 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_{n1n}) e limiares (bias) (θ_j).

O ajuste dos pesos (w_{n1n}) é feito, tendo-se calculado cada gradiente local com base no erro da camada de saída, dado pela Equação (A.17) Haykin (2001).

$$\Delta w_{i,j}(n) = \eta \cdot \delta_i(n) \cdot y_j(n) \dots\dots\dots (A.17)$$

onde η é a taxa de aprendizagem da rede; $\delta_i(n)$ é a propagação do erro nas camadas e $y_j(n)$ 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:

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

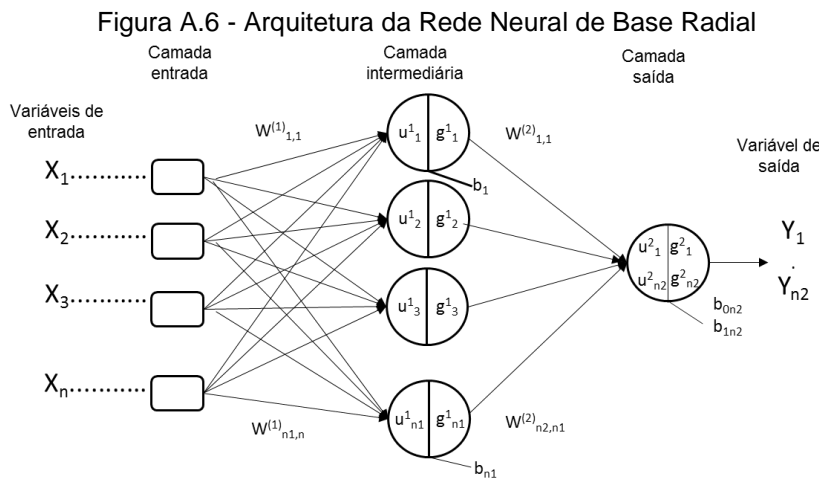
O algoritmo *Levenberg-Marquardt* usa a aproximação da Hessiana do mesmo modo que o método de *Newton*, conforme Equação (A.18).

$$W^{i+1} = W^i - (J^T J + \mu I)^{-1} J^T e \dots\dots\dots (A.18)$$

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 interação 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).

2.1.2 Rede Função de Base Radial (RBF)

A estrutura da rede RBF é formada por somente uma camada oculta e tem como particularidade a estratégia de treinamento onde os neurônios pertencentes à camada oculta (intermediária) são constituídos de funções de base radial geralmente as gaussianas (Figura A6). Classificada como rede do tipo *feedforward* com treinamento realizado em duas fases distintas, o não supervisionado, e está relacionado somente aos dados de entrada com a alocação da função de ativação e o supervisionado, onde se realiza o ajuste dos pesos dos neurônios com a camada de saída e similar ao processo de treinamento da rede MLP (Crispim et. al, 2006).



Fonte: adaptado de Behrang et al.(2010).

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.

A primeira fase acontece com o ajuste dos neurônios da camada intermediária constituídos de funções de ativação $g(.)$ e geralmente representada pela expressão matemática da Equação (A.19).

$$g(u) = e^{\frac{-(u-c)^2}{2*\sigma^2}} \dots\dots\dots(A.19)$$

onde c é o centro da função gaussiana e associado ao próprio peso e a σ^2 a variância pela qual indica a dispersão do potencial de ativação $\{u\}$ em relação ao centro de c .

O ajuste de cada neurônio $n1$ da camada intermediária é representado pela Equação (A.20).

$$g_j^1(u_j^1) = g_j^1(x) = e^{-\left(\frac{\sum_{i=1}^n (x_i - w_{ji}^1)^2}{2 * \sigma_j^2}\right)} \dots\dots\dots(A.20)$$

onde w_{ji}^1 e σ_j^2 são os pesos e as variâncias dos neurônios da camada intermediária e $j = 1, \dots, n_1$ (número de neurônios).

Realizada a primeira fase (não supervisionada) tem na sequência o ajuste de pesos dos neurônios da camada de saída (segunda fase) que acontece similarmente às redes MLP (supervisionado) constituídos por pares de entrada e saída desejados, onde as entradas serão as respostas produzidas na fase anterior.

Nesta estrutura a Equação (A.21) sintetiza o comportamento matemático da rede na segunda fase.

$$u_j^2 = \sum_{i=1}^{n_1} w_{ji}^2 * g_i^1 * u_i^1 + b_j \dots\dots\dots(A.21)$$

onde w_{ji}^2 e b_j são os pesos e limiares de ativação (bias) dos neurônios da camada de saída e g_i^1 e u_i^1 obtidos na primeira fase de treinamento e $j = 1, \dots, n_2$ (número de neurônios).

Finalizando a resposta produzida pelos neurônios de saída é dada pela Equação A.22:

$$y_j = g_j^2(u_j^2) = u_j^2 \dots\dots\dots(A.22)$$

onde $j = 1, \dots, n_2$ (número de saídas).

Uma questão importante para o treinamento da RBF está em se obter o numero de neurônios na camada intermediária, no qual normalmente se inicia com zero neurônio e é incrementado automaticamente através da verificação do erro $e_j(k)$ onde o processo é repetido até que se obtenha o erro desejado, ou quando o número máximo de neurônios da camada intermediária é atingido. O erro é obtido por meio da Equação (A.23).

$$e_j(k) = d_j(k) - y_j(k) \dots\dots\dots(A.23)$$

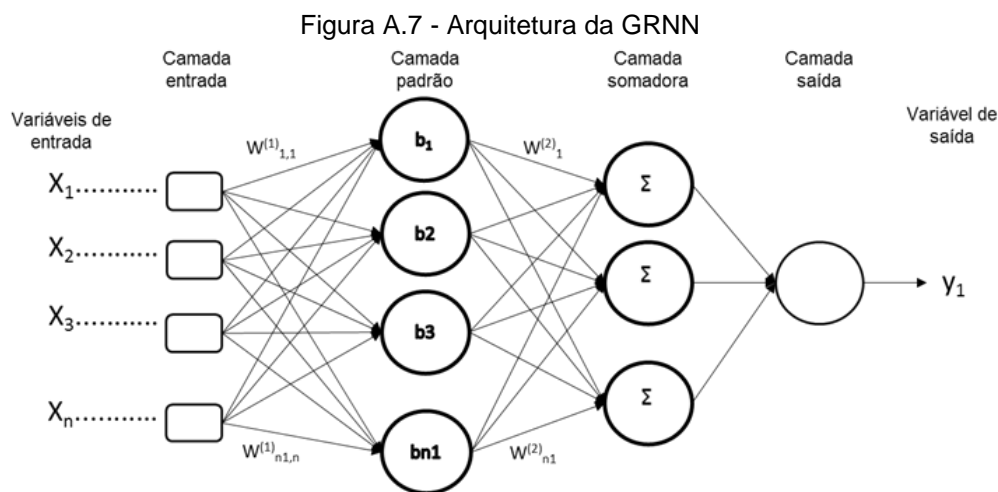
onde $d_j(k)$ é a resposta desejada para o j – ésimo neurônio de saída e $y_j(k)$ se refere a resposta encontrada na saída do neurônio a j – ésima interação de k e caso o erro se torna inalcançável pode-se utilizar o número de época como critério de parada.

2.1.3 Rede 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 A.7).



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.

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 A.24).

$$a(i) = \|X - Xi\| \quad i = 1, \dots, n \dots\dots\dots(A.24)$$

Tanto o quadrado como os valores absolutos dessas diferenças são somados e alimentam uma função de ativação não linear, normalmente a exponencial, na camada padrão (Equação A.25).

$$b(i) = \exp\left(\frac{a(i)^2}{2\sigma^2}\right) \quad i = 1, \dots, n \dots\dots\dots(A.25)$$

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 A.26) e o Somatório dos pesos (Equação A.27).

$$c(j) = \sum_{i=1}^n y_{j,i} * bi \quad j = 1, \dots, s \dots\dots\dots(A.26)$$

$$d = \sum_{i=1}^n bi \quad j = 1, \dots, n \dots\dots\dots(A.27)$$

As unidades de saída dividem cada resultado da camada de soma pelo somatório total de todas as unidades de soma (Equação A.28) para então determinar a saída Y (Equação A.29).

$$\hat{y}(j) = \frac{c_j}{d} \quad j = 1, \dots, n. \dots\dots\dots(A.28)$$

$$\hat{Y} = [\hat{y}_1 \dots \hat{y}_j \dots \hat{y}_n]^T \dots\dots\dots(A.29)$$

Apesar de sua simplicidade não requerem algoritmos de propagação reversa, e têm capacidade de estimar qualquer função não linear, mas depende muito da quantidade de dados. Quanto maior o conjunto de treinamento, menor o erro na estimativa. Este aspecto pode tornar as redes GRNN pouco utilizadas na estimativa

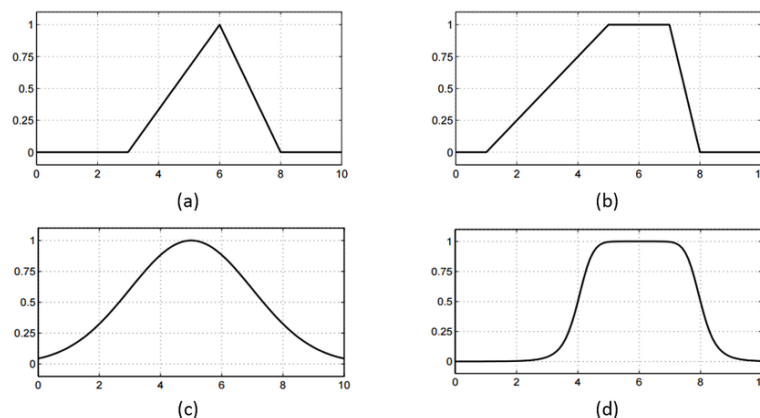
da irradiação solar, com poucos trabalhos somente para irradiação solar global (Wang et. al, 2016; Feng et al., 2017).

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

2.2 Sistema Adaptativo de Inferência Neuro Fuzzy (ANFIS)

A teoria dos conjuntos *Fuzzy* ou *Lógica Fuzzy* foi definida por Zadeh (1965). Geralmente são utilizados para procurar soluções onde a modelagem matemática é de difícil implementação ou não tem solução, pois trabalha com imprecisão ou incertezas. 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 A.8).

Figura A.8: Funções de pertinência Fuzzy (a) triangular (b) trapezoidal (c) gaussiana (d) seno generalizada



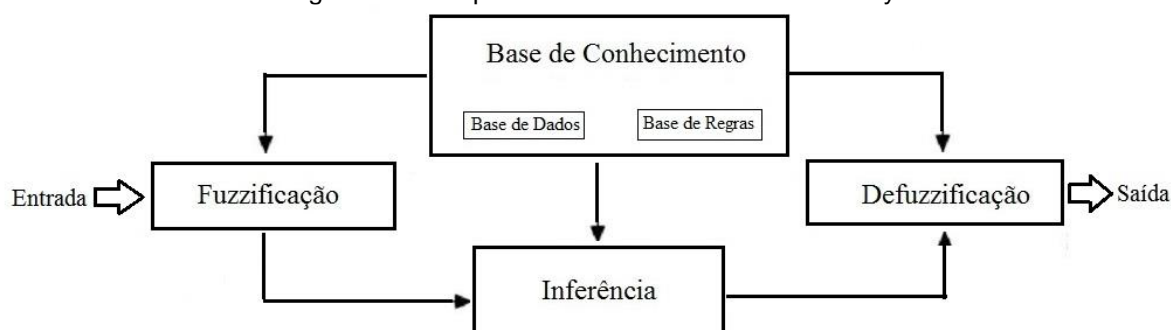
Fonte: Nascimento, Paulo. (2015).

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 conforme apresentado na Figura A.8:

- 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 A.9 - 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).

2.1.2 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).

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 figura A.10 apresenta a estrutura da ANFIS para duas variáveis de entrada, uma saída e duas regras sendo os nós adaptativos representados por quadrados e o fixos por círculos e divididos em interações entre cinco camadas que acontecem em dois processos: fuzzificação e defuzzificação (Zadeh, 1968; Jang, 1993; Takagy e Sugeno, 1985; Wang et al., 2009; Quej et al., 2017).

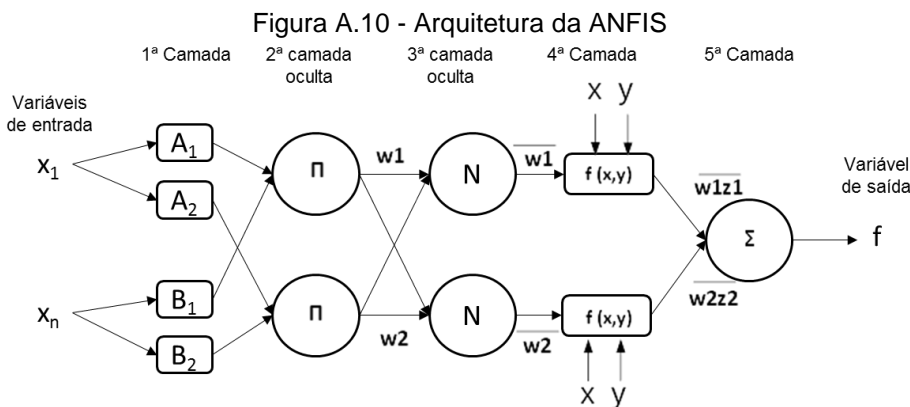
Na primeira camada (fuzzificação) se realiza o cálculo do grau de pertinência das entradas (x e s), de acordo com o tipo de função escolhida para os nós (Ai e Bi) como por exemplo, a função gaussiana representada pelas Equações (A.30) e (A.31).

$$\mu_{A_i}(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \dots\dots\dots(A.30)$$

$$\mu_{B_i}(s) = e^{-\frac{(s-c)^2}{2\sigma^2}} \dots\dots\dots(A.31)$$

onde *c* é o centro da função gaussiana e associado ao próprio peso a σ^2 a variância pela qual indica a dispersão da função de pertinência em relação ao centro de *c*.

As funções podem assumir outras formas linguísticas (bom ou ruim; pequeno ou grande) ou funções como triangular e trapezoidal. Na segunda camada (produto) o operador conjuntivo fuzzy é aplicado, agrupando os dados de entrada em subgrupos associando os valores aos subgrupos correspondentes ou com características semelhantes para obter uma saída que represente as saídas das camadas anteriores (Equação (A.32)).



Fonte: adaptado de Jang (1993).

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. Nestas duas 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.

$$w_i = (\mu_{A_i}(x) * \mu_{B_i}(y)) \text{ sendo } i= 1 \text{ e } 2 \dots\dots\dots (A.32)$$

Na terceira camada (normalizada) é realizada a normalização das informações ou dos pesos com o grau de ativação da regra anterior em relação às outras, ou seja, se calcula a razão entre a força do disparo da regra (w_i) aplicada e a soma de todas as regras (Equação (A.33)).

$$\acute{w}_i = \frac{w_i}{w_1+w_2} \quad i= 1 \text{ e } 2 \dots\dots\dots (A.33)$$

Na quarta camada (desfuzzificação) encontram-se a composição das regras onde se calcula o produto de cada função linear entre a saída da camada 3 e os valores de entrada (x e y), ponderados pelos vetores gerados no processo de treinamento (p , q e r), calculada pela Equação (A.34). Nesta camada encontra-se a composição das regras onde os parâmetros são otimizados através de algoritmo de regressão de mínimos quadrados e retorna (propagação reversa) com os erros (soma da diferença quadrática entre os valores medidos e estimados) onde estes parâmetros são atualizados por algoritmos de gradiente descente, finalizando com a totalização dos valores na quinta camada (Equação (A.35)) $y = \sum_{i=1}^N w_i \phi_i(x)$ (Jang, 1993; Takagy e Sugeno, 1985; Wang et al., 2009; Quej et al., 2017).

$$\acute{w}_i z_i = \acute{w}_i (p_i x + q_i y + r_i) \quad i = 1 \text{ e } 2 \dots\dots\dots (A.34)$$

onde \acute{w}_i é a saída da camada 3 e os parâmetros são os coeficientes da combinação linear no sistema de inferência Sugeno. Ao final na camada 5 (saída) composta por apenas um nó realiza o somatório (Σ) das saídas da camada 4 (Equação (A.35)).

$$\Sigma \acute{w}_i z_i = \frac{\sum w_i z_i}{\sum w_i}, \quad i = 1, 2 \dots\dots\dots (A.35)$$

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 define-se como os 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 (A.36)) (Chiu, 1996).

$$\rho_i = \sum_{j=i}^n \exp\left(-\frac{4}{r_a^2} \cdot \|x_i - x_j\|^2\right) \dots \dots \dots (A.36)$$

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.

A ANFIS é uma técnica cada vez mais presente em estudos de estimativas da radiação solar, porém tem sido utilizada com mais frequência para estimar (H_g) (Sfetsos e Coonick, 2000; Landeras, 2012; Olatomiwa et al., 2015; Mohammadi, 2016c).

2.3 Máquina de Vetores de Suporte (SVM)

A técnica SVM foi introduzida por Vapnik (1995) e desenvolvida para resolver problemas de classificação, mas aplicável também para regressão (geralmente chamada de Regressão por Vetores de Suporte) e estimativas. É diferenciada dos modelos estatísticos por utilizar o princípio da minimização do erro estrutural para minimizar o erro empírico e o intervalo de confiança com grande capacidade de generalização (Antonanzas-Torres et al., 2015; Santos et al., 2016).

O conceito básico da técnica é realizar o treinamento para aprendizagem da máquina através de algoritmos de otimização matemática envolvendo poucos parâmetros de ajuste em seus algoritmos de treinamento que depende da sua utilização e conseqüentemente do algoritmo de treinamento a serem utilizados (supervisionado).

A proposta de uma SVM é criar uma margem e maximizá-la para realizar o mapeamento dos dados de entrada e do treinamento em um espaço de dimensões maiores via funções de *kernel* que ajudam o algoritmo a ficar mais eficiente, construindo um hiperplano com uma margem de separação máxima entre os dados.

Matematicamente a SVM elabora um hiperplano de separação ideal considerando um conjunto de dados (x_i, y_i) chamados de vetores de entrada (x_i) e seus respectivos vetores de saída (y_i) normalizados (Belaid e Mellit, 2016) em um

espaço através de uma função não linear $\varphi(x)$ e na sequência encontrar uma função de regressão conforme Equação A.37.

$$f(x) = w \cdot \varphi(x) + b \dots \dots \dots (A.37)$$

onde (w) e (b) são os parâmetros da função de regressão chamados respectivamente de vetor de ponderação (pesos) e valor de tendência (bias) e $\varphi(x)$ como função de mapeamento não linear.

Com isto a programação irá encontrar um peso (w) e um linear (b) capaz de otimizar as margens destes dados ou seja aproximar a saída (y) com um tolerância de erro ε a fim de assegurar uma boa classificação ou regressão ou seja, o menor erro da $\varphi(x)$. A SVM calcula o hiperplano de separação ideal por meio do seguinte problema de otimização dado pela Equação (A.38):

$$R(\xi, \omega, b) = \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \dots \dots \dots (A.38)$$

$$\text{sujeito a: } y_i(\omega^t \varphi(x_i) + b) \leq 1 - \xi_i$$

sendo $\xi_i \geq 0, i = 1, \dots, N$ as variáveis de folga utilizados para reduzir o erro de classificação do conjunto de treinamento, C o parâmetro de custo que determina o grau do erro empírico no problema de otimização que é escolhido pelo usuário. As variáveis de folga também possibilitam à SVM tratar de problemas não lineares. Sem o emprego das variáveis de folga a SVM é chamada de "SVM de margens rígidas", com as variáveis de folga passa a se chamar de "SVM de margens flexíveis".

Para resolver problemas de otimização ou de programação quadrática o Multiplicadores de Lagrange ($\alpha \geq 0, i = 1, \dots, N$) são incorporados às equações de condição e pode ser escrita de forma dual dado pela Equação (A.39):

$$R(\alpha) = \sum_{i=1}^n (y_i * \alpha_i) - \varepsilon \sum_{i=1}^n (\alpha_i) - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (\alpha_i) * (\alpha_j) k(x_i, x_j) \dots \dots \dots (A.39)$$

$$\text{sujeito a: } \sum_{i=1}^n (\alpha) = 0 \dots \dots \dots 0 \leq \alpha \leq C, i = 1, \dots, N.$$

onde α_i, α_j são os multiplicadores de Langrange a serem calculados, $k(x_i, x_j)$ são chamados de função de *Kernel* de mapeamento entre a amostragem x_i e o vetor de suporte x_j e é calculado através de $k(x_i, x_j) = \varphi(x_i) \varphi(x_j)$. A função de Kernel permite que a SVM tenha a capacidade de modelar hiperplanos de separação complicados, ou seja, forme limites não lineares. Após serem calculados os multiplicadores de Lagrange um vetor de pesos desejado do hiperplano é encontrado conforme Equação (A.40):

$$w = \sum_{i=1}^n (\alpha) * \varphi(x) \dots \dots \dots (A.40)$$

Reescrevendo a Equação 1 tem-se a Equação (A.41):

$$f(x, \alpha) = \sum_{i=1}^n (\alpha) * k(x_i, x_j) + b \dots \dots \dots (A.41)$$

onde n é o número de vetores de suporte, α são os multiplicadores de Langrange, $k(x_i, x_j)$ é a função de Kernel no espaço de entrada e b limiar ou bias e é calculado a partir de amostras do treinamento. De forma geral a função básica do processo de aprendizagem da SVM é dada pela Equação (A.42):

$$y = f(x) = \sum_{i=1}^M (\alpha) * \varphi(x) = w\varphi(x) \dots \dots \dots (A.42)$$

onde y é a soma ponderada de M . A função de decisão da SVM é representada conforme a Equação (A.43).

$$y = f(x) = \{ \sum_{i=1}^N (\alpha) * k(x_i, x_j) \} + b \dots \dots \dots (A.43)$$

A Tabela A.1 apresenta algumas funções básicas do Kernel a ser utilizada tendo em vista que uma escolha adequada permite que o conjunto de dados se torne separável mesmo sendo inseparável no espaço original.

Tabela A.1 – Funções de Kernel

Função de Kernel	Equação
Base Radial	$\frac{-\gamma}{(\ \omega\ ^2)}, \gamma > 0$ $k(x_i, x_j) = exp$
Polinomial	$k(x_i, x_j) = (\gamma x_i \cdot x_j + r)^d, \gamma > 0$
Linear	$k(x_i, x_j) = x_i \cdot x_j$
Sigmoide	$\frac{\gamma x_i \cdot x_j + r}{()}, \gamma > 0$ $k(x_i, x_j) = tan$

x_i, x_j são vetores do espaço de entrada, d, r e γ são parâmetros da função de Kernel.

Essa característica de maximização de espaço através das funções de *Kernel* é que podem fazer com que a técnica SVM sejam viável para abordar estudos com irradiação solar que por natureza são grandezas não lineares, como a irradiação global (H_g) (Mohammadi et al., 2015a e b; Antonanzas-Torres et al., 2015; Belaid e Mellit, 2016; Chen et al., 2015) e a irradiação difusa (Shamshirband et al., 2016). Apesar de pouco utilizada em estimativas de irradiação solar, no Hemisfério Sul vem sendo introduzida na estimativa da irradiação solar direta (H_b) (Santos et al., 2016), na irradiação global (H_g) (Silva et al., 2016) e irradiação solar UV (Teramoto et. al., 2016).

Capítulo 1: MLP – Combinação 8 Ano Típico (AT)

b1=	w 1=	1.9821	-0.1533	1.3271	0.4874	-0.9845	0.9072	0.7294	-1.1065	-0.1426												
		1.5250	-0.6843	0.9890	0.4565	-0.9775	-0.0470	0.5395	0.4721	1.1851												
		1.7593	-1.3892	0.9920	-1.2035	-0.0541	-0.0561	0.6832	0.1860	-0.3805												
		1.1331	-1.5748	-0.4314	0.5479	-0.8969	0.7355	-0.5445	0.0754	0.0547												
		-1.2082	0.0327	0.4759	-0.8726	1.6552	0.1703	-0.2883	0.5339	-0.0502												
		-1.2681	0.1000	-0.5516	-1.1958	0.4992	-0.2527	0.9308	0.5381	0.0461												
		0.8247	0.1916	0.1799	0.1157	1.3304	-1.1194	0.7514	-0.0661	0.1656												
		0.5343	-1.4934	0.3898	0.0956	-0.5027	-0.7498	-0.8404	-0.2059	0.8179												
		-0.3596	1.4275	-0.0439	-1.0955	0.9006	-0.2742	-0.6982	0.3530	0.0941												
		-0.3186	1.5474	0.4707	-0.9046	0.1529	0.5563	-0.1318	-0.9076	0.1205												
		-0.6391	-0.3607	-0.9778	0.8411	2.0527	-0.0499	-0.7116	-0.6320	-1.0072												
		0.3583	1.3018	-0.7414	-0.2318	-1.8776	-0.1129	0.0408	-0.1140	1.3197												
		-0.3046	-1.3552	0.9866	0.1229	-1.2423	-0.0029	-0.4430	-0.5327	-0.2975												
		-0.2834	-0.5684	0.1363	0.2499	1.4680	0.0879	0.8489	0.0956	-1.3952												
		-1.1706	-0.3969	-0.4747	1.6649	0.3565	0.1301	0.8414	1.2357	0.9617												
		-1.0328	2.0508	-1.7148	1.1673	0.0920	0.1230	0.4141	0.2046	-0.2776												
		-1.2574	-0.4882	-0.6715	-0.7618	0.7614	0.0378	0.8318	-1.1987	0.0290												
		2.0584	0.9572	0.7245	1.4123	-0.1107	-0.3936	-0.5513	-0.5920	-0.9067												
		-1.3503	0.1335	0.1889	-0.6352	0.8837	0.3253	0.9743	0.2283	-1.3489												
		2.0119	-0.4144	-0.6292	-0.7123	-0.7313	0.2805	0.0324	-0.9671	0.0359												
b2=	w 2=	1.6752	-0.2930	-0.1568	-0.4203	-0.0173	-0.3379	0.1668	-0.6432	0.2074	0.0690	0.0131	0.3520	0.3221	-0.1372	-0.4616	-0.3088	-0.3387	-0.8504	-0.3352	0.3909	0.5590
		-1.0119	0.2739	0.4442	0.0686	0.1294	-1.0431	-0.2222	-0.5388	0.0729	-0.3674	-0.6688	-0.7629	0.7763	-0.9906	-0.9657	-0.1119	-0.3954	-0.3783	-0.2153	0.4294	0.3722
		0.9899	0.0758	-0.2984	-0.3273	-0.6292	0.3144	0.1859	0.5329	0.1887	-0.2759	0.5028	-0.2019	0.0457	-0.3146	-0.3750	-0.3118	0.6261	0.2868	-0.2026	-0.0797	0.1778
		1.4761	-0.1382	-0.6119	0.5439	0.1309	-0.2713	0.1938	-0.6880	-0.3562	0.3419	-0.5006	-0.0801	-0.8356	0.3110	0.3886	-0.3165	0.0006	-0.6897	0.4000	-0.3821	0.3776
		1.4738	-0.4189	-1.0077	-1.2982	-0.0316	-0.6313	-0.1354	0.3009	0.0247	0.5110	0.2337	-0.7825	0.4839	-0.4566	-0.3020	-0.0500	1.5818	-0.0004	-0.2629	-0.0872	-0.5645
		-0.7487	-0.0434	-0.3522	-0.4142	0.1036	0.8722	-0.1251	-0.0365	0.4682	-0.1678	0.4994	-0.5745	-0.1919	-0.4236	-0.5409	-0.0445	-0.2789	0.1361	0.0310	0.4130	-0.4157
		-0.6134	0.5209	-0.5452	0.3292	-0.6095	0.1802	-0.2157	0.7121	-0.0176	0.0881	-0.0515	-0.2700	0.2348	-0.1360	-0.4010	0.1588	-0.8002	0.3612	-0.3774	-0.2522	0.4651
		-0.4001	0.3121	-0.3906	0.0442	0.3177	0.0728	-0.1908	-0.1925	-0.0340	0.5007	0.2766	0.1646	0.4538	-0.5382	0.4612	0.0753	0.1994	0.4069	0.0347	-0.0319	0.3188
		-0.4535	-0.3555	0.2130	0.0480	0.7710	-0.4504	-0.5715	-0.1083	-0.5656	1.0720	0.1403	0.6806	0.2748	0.9451	-0.0989	0.7108	0.4678	-0.1778	-0.3709	0.0008	-0.6522
		-0.0818	-0.4042	0.4637	0.1757	-0.7066	0.2133	0.3703	-0.0413	0.0414	-0.1384	0.8755	0.9007	0.3318	0.1695	0.2840	0.1538	0.8732	-0.0363	0.6518	0.7399	-0.1367
		0.1098	0.5022	0.2914	0.5809	0.3297	-0.4205	0.0639	-0.1407	0.2362	-0.4022	-0.5055	-0.8146	0.4993	-0.2903	-0.4732	-0.3386	-0.6010	-0.1429	-0.4489	0.1546	0.1626
		0.5611	0.4285	-0.5597	-0.2536	-0.4965	0.1461	-0.0767	0.1429	0.2388	-0.2408	0.0521	-0.6843	0.5782	-0.1387	-0.0190	0.2350	0.4979	0.2079	-0.1768	0.2707	0.4606
		-0.2076	-0.0303	-0.5675	0.0280	-0.7564	-0.7853	-0.0911	-0.1941	-0.1237	0.3283	0.7642	-0.5849	0.6314	-0.4524	-0.4403	1.4776	0.3210	0.4067	0.3897	0.2589	0.4182
		0.6449	0.2801	0.2612	-0.0734	0.7445	-0.5364	-0.7237	-0.5153	0.1924	0.0458	-0.5787	-0.1103	-0.2379	0.1640	0.3662	-0.4749	0.0318	-0.1661	-0.1718	0.3149	-0.4822
		-0.9729	-0.7284	0.1868	0.0272	0.2440	0.0492	0.2748	-0.3379	0.0335	-0.3541	0.6744	-0.0269	0.0233	-0.5806	-0.1901	-0.4636	-0.9618	-0.0623	0.0329	-0.0421	0.1883
		-0.9395	-0.1871	-0.4187	-0.2900	-0.0259	0.0782	0.1507	0.4200	0.6780	0.5556	-0.2822	0.2695	0.2432	-0.2135	0.3313	0.2160	0.3384	0.2323	0.4770	0.1248	-0.4661
		-0.9986	-0.1564	-0.0089	0.6485	-0.1580	-0.6234	-0.0225	-0.9829	-0.4380	-0.4376	0.3835	0.4519	-0.1754	0.1063	-0.0301	0.1857	0.1254	-0.4008	-0.4574	-0.1956	-0.0728
		-1.2701	-0.1205	0.1601	-0.4735	-0.3206	-0.7380	0.2169	-0.1151	0.4462	-0.2481	-0.4672	0.4146	-0.1675	0.3486	-0.1972	-0.3765	-0.0893	-0.2450	0.4676	0.0944	0.3633
		-1.4902	-0.2614	-0.7166	-0.3191	-0.0280	0.4527	-0.2284	-0.3768	-0.2403	-0.4062	-0.1439	-0.2069	0.3311	0.3507	0.6024	0.4091	0.0162	0.5769	-0.0309	0.4851	0.2176
		-1.5871	-0.0512	0.0127	-0.2225	-0.2565	0.4567	0.3627	-0.5331	-0.0745	-0.0745	0.3093	-0.3855	-0.5602	0.1110	0.0659	0.7144	-0.4182	0.2528	-0.7331	-0.3728	-0.0411
b3=	0.22341	w 3=	0.32081	-0.52394	-0.64404	-0.43652	-0.28559	-0.76260	0.50743	-0.29177	1.09275	0.59173	0.54474	0.95268	-0.54728	0.33717	0.44747	0.48245	-0.56923	-0.55351	0.72781	-0.15817

Capítulo 2: MLP – Combinação 7 Ano Típico (AT)

b1=	-1.8887	w 1=	-0.2734	0.6661	-0.9515	-0.1334	0.2728	0.2485	0.7802													
	0.7948		-1.1468	0.0432	0.2799	-0.0464	-0.1801	0.2454	-0.1351													
	0.5782		0.7760	0.2440	1.0623	-0.2588	0.2206	1.3013	-0.3102													
	-1.0283		-1.2410	-0.7435	0.8159	0.5215	-0.0165	-1.7451	0.2559													
	-2.5795		0.2521	-0.5722	0.7422	0.3764	0.0090	0.7320	-0.3537													
b2=	-2.5590	w 2=	0.1445	-1.6642	0.6676	1.7939	-0.2021															
	-2.2790		1.7110	-0.2047	-1.4453	0.8253	0.8720															
	2.0155		-0.3009	0.8466	0.8470	-1.4275	-1.7166															
	-2.0007		1.4136	-0.9689	-0.8604	0.6184	-1.2437															
	-1.4533		1.6770	0.4947	-0.2236	-0.9074	-1.5611															
	1.2641		-0.1591	-0.9597	-0.0563	1.5843	1.6343															
	1.0318		-1.4886	-1.0926	0.7623	-0.7582	-1.3522															
	0.6432		-0.0093	-0.5000	-1.4987	-0.8472	-1.8306															
	-0.0509		0.5823	2.1867	-0.9106	0.3832	-1.5114															
	0.2171		-0.6717	-1.2512	-0.3633	1.5040	-0.9742															
	0.1044		-0.8434	-1.1898	-0.1025	0.4576	-1.9477															
	-0.2745		-1.3629	0.7161	-1.4196	-1.4375	1.2006															
	-0.3718		-1.3869	-1.1910	-1.3896	0.9870	-1.1046															
	0.8892		1.3892	0.1056	0.4237	1.6946	1.3815															
	1.1332		1.8868	0.077753	0.084317	1.724	0.45019															
	-1.9062		-0.8654	-1.2045	1.7472	0.8740	-0.9321															
	1.9122		1.1538	0.5509	-0.3027	0.7961	-2.0584															
-1.9225	-1.4339	1.3076	1.3060	0.2479	1.2092																	
2.2286	0.8826	-0.5866	0.1911	0.2627	2.3485																	
-2.5902	-1.2881	0.9285	-0.3413	1.4244	1.2187																	
b3=	-0.4565	w 3=	0.4951	-0.4636	-1.0528	0.7700	-0.0080	-0.4363	0.6273	0.2093	0.2312	-1.3002	-0.0578	-0.4859	0.8980	0.6744	0.0821038	-0.34740	0.68034	-0.41328	-0.03770	-0.59425

Capítulo 2: MLP – Combinação 8 Ano Típico (AAT)

b1=	-1.8851	w 1=	0.2176	0.8846	-0.8426	0.7877	0.2611	0.8652	-0.6014	0.0748		
	1.7830		-0.5379	-0.9092	-0.5412	-0.8751	0.1083	0.7089	-0.7223	-0.4573		
	-1.1403		0.5542	-0.1136	0.5926	0.6559	-1.2183	-1.0674	0.0735	0.5261		
	-0.4120		0.9771	0.5055	0.1447	-1.1084	-0.6831	0.9862	0.8119	0.4796		
	-0.0270		0.2585	0.0936	0.4638	0.5262	1.1522	0.6093	-0.8566	-0.0962		
	-0.7028		1.4911	-0.4290	0.9836	-0.8943	0.3569	0.5484	-0.0051	0.2796		
	-0.4676		-1.2193	0.1457	0.1503	0.0691	-0.0737	0.7525	-0.0428	-0.2135		
	1.1904		0.0006	0.5827	0.2842	-0.3105	0.3458	-1.4532	0.2349	-0.8983		
	1.8567		1.0869	-0.5108	0.5472	-0.5276	0.9980	1.1885	0.3822	0.3688		
	1.5335		0.6078	-1.1066	-0.1459	0.6221	0.4883	0.7394	-0.3411	-0.4511		
b2=	1.4918	w 2=	-0.7267	0.4720	0.5541	-0.5160	0.2425	0.6892	0.5823	0.9077	0.0121	0.3532
	-0.8761		0.3549	0.1959	0.2875	1.0399	0.6830	-0.3616	0.1872	0.4927	0.7057	-0.1442
	0.3705		0.1860	0.3214	0.2927	0.7283	0.3100	-0.6440	1.0653	0.4547	0.1600	0.3367
	0.7242		0.4225	-0.5113	1.1187	0.5626	0.3334	0.6873	-0.0308	0.6821	0.8753	-0.4812
	-1.6847		-0.3093	-0.5127	0.1419	0.9216	0.1270	-0.5850	0.5882	-0.3041	0.7532	0.5944
b3=	-0.2920	w 3=	-0.6490	-0.8672	1.2300	-0.0649	-0.0146					