



PREVISÃO DA RADIAÇÃO GLOBAL HORIZONTAL E ILUMINÂNCIA UTILIZANDO REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso

Engenharia da Computação

Rafael Lopes Mendonça

Orientador: Prof. Dr. Mêuser Jorge Silva Valença

Coorientador: Prof. Dr. Francisco Jaime Bezerra Mendonça



**UNIVERSIDADE
DE PERNAMBUCO**

**Universidade de Pernambuco
Escola Politécnica de Pernambuco
Graduação em Engenharia de Computação**

RAFAEL LOPES MENDONÇA

**PREVISÃO DA RADIAÇÃO GLOBAL
HORIZONTAL E ILUMINÂNCIA
UTILIZANDO REDES NEURAIS
ARTIFICIAIS**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, dezembro de 2014.

Rafael Lopes Mendonça

MONOGRAFIA DE FINAL DE CURSO

Avaliação de defesa (cópia do aluno)

No dia 15 de 12 de 2014, às 9:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente **RAFAEL LOPES MENDONÇA**, orientado pelo professor **Mêuser Jorge Silva Valença**, sob título **Previsão de Radiação Global Horizontal e Iluminância Utilizando Redes Neurais Artificiais**, a banca composta pelos professores:

Sérgio Murilo Maciel Fernandes

Mêuser Jorge Silva Valença

Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:

Aprovada Aprovada com Restrições* Reprovada

e foi-lhe atribuída nota: 10 (DEF)

*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O discente terá 07 dias para entrega da versão final da monografia a contar da data deste documento.

Comentários da banca

Execução das modificações num período de 7 dias.

SÉRGIO MURILO MACIEL FERNANDES

MÊUSER JORGE SILVA VALENÇA

Dedico este trabalho à minha família, em especial a minha mãe Maria Genisete e ao meu pai Jaime Mendonça, e à todos aqueles que fizeram e fazem parte da minha trajetória.

Agradecimentos

Agradeço a Deus por me dar cada segundo da minha vida.

Agradeço todo o apoio e dedicação incondicional que recebi, em toda minha vida, dos meus pais. Que sempre me incentivaram a seguir minha carreira acadêmica e desejam que eu siga em frente para atingir degraus ainda mais altos. E eles, sem dúvidas, foram fundamentais para que eu conseguisse ingressar em duas Universidades públicas. Só tenho que agradecer aos meus pais e nunca esquecer dos ensinamentos que eles me deram.

Apesar de ter estudado grande parte da minha vida escolar para as ciências humanas, decidi no ano do vestibular fazer Engenharia. Para mim é uma grande felicidade poder estar concluindo a minha graduação, no curso de Engenharia da Computação.

Tenho muito que agradecer também aos meus amigos de Universidade, sem os quais estes 6 anos de graduação, com certeza, não seriam tão bem aproveitados academicamente, profissionalmente e pessoalmente.

Em particular agradeço também aos meus irmãos que servem de exemplos para que eu trilhe o meu caminho tão bem quanto os deles. Ao meu padrinho que me incentivou desde a infância a estudar informática, me oferecendo cursos e inclusive sendo meu professor em um deles.

Agradeço a todos que de alguma forma me ajudaram a seguir em frente para que eu não desistisse dos meus objetivos, e principalmente não deixasse de sonhar e acreditar na minha capacidade em torná-los realidade.

Resumo

Devido ao crescimento industrial, a obtenção de recursos energéticos se tornou um dos grandes problemas econômicos e ambientais. Para aliar o desenvolvimento a preservação, é necessário o incentivo a fontes de energia renováveis que causem o menor impacto ambiental. O Brasil possui um grande potencial para a obtenção da energia solar ainda pouco explorado, principalmente na região Nordeste. Até o ano de 2013, a energia solar no país não possuía preço de referência, já que o seu uso se restringe ainda, à pesquisa e a sistemas residenciais isolados. Como incentivo aos produtores de energia, o estado de Pernambuco realizou o primeiro leilão de energia solar em dezembro de 2013. O próprio estado comprou um volume de energia correspondente a 18% do total consumido pelo governo. O uso de RNAs (Redes Neurais Artificiais) para prever as variáveis radiométricas e meteorológicas pode auxiliar a obtenção de um maior aproveitamento dessa fonte de energia. Sendo assim este trabalho tem como objetivo utilizar RNAs para prever a radiação global horizontal e a iluminância na estação solarimétrica e anemométrica da rede SONDA (Sistema de Organização Nacional de Dados Ambientais) em Petrolina, Pernambuco. As RNAs utilizadas são a *Radial Basis Function Network* (RBFN) e a *Multi-Layer Perceptron* (MLP), as quais irão prever a radiação global horizontal e a iluminância futura a partir dos valores anteriores. Os resultados obtidos serão comparados com o modelo de Persistência para analisar qual das redes apresentou o melhor desempenho.

Palavras-Chave: Previsão da radiação global horizontal e iluminância, RBFN, MLP, energia solar

Abstract

Due to the industrial growth, to obtain energy resources has become a major economic and environmental problems. To ally the development with the preservation is necessary to encourage renewable energy sources that cause the least environmental impact. Brazil has a large solar potential still unexplored, especially in the Northeast. By the year 2013 the solar energy in the country did not have a reference price, since its use is restricted to research and isolated residential systems. As an incentive for energy producers, the state of Pernambuco held the first auction of solar power on December 2013. Pernambuco bought an amount of energy that corresponds 18% of the total consumed by the government. The use of ANNs (Artificial Neural Networks) to provide radiometric and meteorological variables can help to achieve a better use of this energy source. Thus, this work aims to use ANN to predict the global horizontal radiation and the illuminance in the solarimetric and anemometer station of SONDA network (National Organization System of Environmental Data - Sistema de Organização Nacional de Dados Ambientais in portuguese) in Petrolina, Pernambuco. The ANNs used are Radial Basis Function Network (RBFN) and Multilayer Perceptron (MLP) and both will predict the future global horizontal radiation and illumiance from previous values. The results will be compared with the Persistence model to analyze which of the networks has the best performance.

Keywords: Prediction of global horizontal radiation and illuminance, RBFN, MLP, solar energy

Sumário

Capítulo 1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.1.1 Objetivo geral	2
1.1.2 Objetivos específicos	2
1.3 Estrutura da monografia	2
Capítulo 2 Fundamentação Teórica	4
2.1 Energia Solar	4
2.1.1 Iluminância	5
2.1.2 Radiação global horizontal	7
2.1.3 Energia Solar no Brasil	9
2.1.4 Projeto SONDA	9
2.2 Redes Neurais	11
2.2.1 Multi-Layer Perceptron	14
2.2.2 Algoritmo Backpropagation	15
2.2.3 Critério de parada	17
2.2.4 Radial Basis Function Network	18
2.2.4.1 Estrutura da Rede RBFN	19
2.2.4.2 Treinamento da Rede RBFN	20
2.2.5 Modelo de Persistência	20
Capítulo 3 Metodologia	22
3.1 Aquisição e Tratamento dos Dados	22
3.2 Simulação com a MLP	24
Rafael Lopes Mendonça	viii

3.2.1	Simulações com a MLP para radiação	26
3.2.1	Simulações com a MLP para iluminância	27
3.3	Simulação com a RBFN	29
3.4	Análise Estatística	31
3.4.1	Teste Shapiro-Wilk	32
3.4.2	Teste F	32
3.4.3	Teste T-Student	33
3.4.4	Teste da soma dos Postos de Wilcoxon	34
Capítulo 4	Resultados	35
4.1	Resultados da Radiação Global Horizontal	35
4.2	Resultados da Iluminância	37
4.2.1	Determinar a melhor configuração para a rede MLP	37
4.2.2	Comparação entre as redes neurais utilizadas	40
Capítulo 5	Conclusão e Trabalhos Futuros	42
5.1	Conclusões	42
5.2	Trabalhos Futuros	43
Bibliografia		44
Apêndice A		46
Estudo da Quantidade	de Neurônios na Camada Escondida e	
	Topologias MLP Para Dados de Iluminância	46

Índice de Figuras

Figura 1.	Sensibilidade média do olho humano para diferentes comprimentos de onda. 6
Figura 2.	Mapa com a média anual do total diário de radiação solar global incidente no Brasil8
Figura 3.	Distribuição das estações da rede SONDA no território brasileiro 10
Figura 4.	Variáveis medidas pelas estações do projeto SONDA..... 11
Figura 5.	Ilustração do neurônio biológico e do neurônio artificial 12
Figura 6.	Arquitetura MLP com quatro camadas 15
Figura 7.	Ponto de parada do treinamento da rede utilizando validação cruzada. .18
Figura 8.	Topologia da rede RBFN..... 19
Figura 9.	Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,2$ e $\beta = 0,6$28
Figura 10.	Topologia para a configuração da MLP com $\alpha = 0,2$ e $\beta = 0,6$28
Figura 11.	Estudo do <i>spread</i> e da quantidade de neurônios na camada escondida para os dados de iluminância.....30
Figura 12.	Estudo do EMQ para as 48 configurações utilizadas na MLP com os dados de radiação global horizontal.....36
Figura 13.	Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,2$ e $\beta = 0,8$46
Figura 14.	Topologia para a configuração da MLP com $\alpha = 0,2$ e $\beta = 0,8$47
Figura 15.	Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,4$ e $\beta = 0,6$47
Figura 16.	Topologia para a configuração da MLP com $\alpha = 0,4$ e $\beta = 0,6$47
Figura 17.	Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,4$ e $\beta = 0,8$47
Figura 18.	Topologia para a configuração da MLP com $\alpha = 0,4$ e $\beta = 0,8$47

Índice de Tabelas

Tabela 1.	Iluminâncias por classe de tarefas visuais	6
Tabela 2.	Estudo de correlação linear das variáveis de radiação global horizontal e iluminância em tempos anteriores.....	24
Tabela 3.	EMQs médios obtidos pela simulação dos dados de radiação na MLP ..	26
Tabela 4.	Teste Shapiro-Wilk para as configurações utilizadas na MLP com os dados de radiação.....	36
Tabela 5.	Teste Wilcoxon para as configurações utilizadas na MLP com os dados de radiação.....	37
Tabela 6.	Teste Shapiro-Wilk para as configurações utilizadas na MLP com os dados de iluminância.....	38
Tabela 7.	Teste F para as configurações utilizadas na MLP com os dados de iluminância	38
Tabela 8.	Teste Wilcoxon para as configurações utilizadas na MLP com os dados de iluminância	39
Tabela 9.	Teste Shapiro-Wilk para as redes neurais MLP e RBFN utilizando os dados de iluminância.....	40
Tabela 10.	Teste Wilcoxon para as redes neurais MLP e RBFN utilizando os dados de iluminância.....	40

Tabela de Símbolos e Siglas

ABNT – Associação Brasileira de Normas Técnicas

BSRN – *baseline Surface Radiation Network*

CPTEC – Centro de Previsão do Tempo e Estudos Climáticos

EMQ – Erro Médio Quadrático

IDE – *Integrated Development Environment* (Ambiente integrado de desenvolvimento)

INPE – Instituto Nacional de Pesquisas Espaciais

Matlab – *Matrix laboratory*

MLP – *Multi-Layer Perceptron*

NBR – Norma Brasileira

PPG-EC – Programa de Pós-Graduação *stricto sensu* em Engenharia de Computação

RNAs – Redes Neurais Artificiais

RNA – Rede Neural Artificial

RBFN – *Radial Basis Neural Network*

SONDA – Sistema de Organização Nacional de Dados Ambientais

Capítulo 1

Introdução

Este capítulo aborda a motivação e os objetivos deste trabalho, além da estrutura organizacional dos conteúdos a serem discutidos.

1.1 Motivação

Cada vez mais a consciência ecológica e a preocupação com o meio ambiente vem aumentando, sendo um dos temas mais recorrentes da sociedade moderna. Nesse sentido, a busca por fontes energéticas renováveis e que causem o menor impacto no meio ambiente tem sido essencial para a garantia de um futuro melhor.

A disponibilidade e o uso da energia se relaciona diretamente com o desenvolvimento da sociedade e da nação [1]. Dessa forma, para que haja desenvolvimento econômico é necessário um maior consumo de energia e para aliar o desenvolvimento a preservação do meio ambiente é necessário recorrer a fontes que não sejam combustíveis fósseis ou não renováveis de forma geral.

O Brasil hoje possui como matriz energética a energia proveniente de usinas hidroelétricas, além de parques eólicos e estações de energia solar. Porém essas últimas fontes de energia ainda são pontuais e não representam uma parcela significativa da produção energética do país. O incentivo à pesquisa nas áreas de previsão de recursos energéticos eólicos e solar tem sido aliados no desenvolvimento de projetos pelo país. Tais pesquisas fornecem dados que permitem o aproveitamento desses recursos ainda pouco explorados [2].

Agindo dessa forma o Brasil deixará de ser dependente de uma única fonte de energia e assim não sofrerá em períodos de estiagem, como tem acontecido neste ano de 2014, na região Sudeste do país.

A produção de energia solar cresce 50% ao ano no mundo, mas ainda representa cerca de 1% da matriz energética mundial, e no Brasil representa apenas 0,01% do total. As dificuldades para o uso da energia solar ainda está no custo para

a captação da energia por meio das células fotovoltaicas e a previsão da disponibilidade dos recursos energéticos solares da região onde será instalada a estação [6].

1.2 Objetivos

1.1.1 Objetivo geral

Este trabalho tem como objetivo geral realizar a configuração de RNAs (Redes Neurais Artificiais) com arquiteturas MLP (*Multi-Layer Perceptron*) e RBFN (*Radial Basis Neural Network*) para prever a radiação global horizontal e a iluminância na estação solarimétrica e anemométrica da cidade de Petrolina, Pernambuco. A previsão tem como base valores anteriores de radiação global horizontal e de iluminância da mesma estação. A avaliação dos resultados obtidos é realizada através da comparação entre ambas arquiteturas e com os resultados obtidos pelo Modelo de Persistência.

1.1.2 Objetivos específicos

1. Tratar os dados de entrada;
2. Normalizar os dados de entrada;
3. Realizar diferentes combinações dos parâmetros das arquiteturas MLP e RBFN para obter o melhor resultado;
4. Validar os resultados obtidos;
5. Comparar os resultados das arquiteturas entre si e com o Modelo de Persistência.

1.3 Estrutura da monografia

Este trabalho está dividido em 5 capítulos: Introdução, Fundamentação Teórica, Metodologia, Análise dos Resultados e Considerações Finais. O capítulo 2, Fundamentação Teórica, descreve os conceitos necessários para o entendimento deste trabalho, energia solar e redes neurais artificiais, com destaque para as arquiteturas MLP e RBFN.

O capítulo 3, Metodologia, descreve os procedimentos utilizados para a realização deste trabalho, desde a coleta e tratamento dos dados até a análise estatística.

O capítulo 4, Análise dos Resultados, apresenta os resultados obtidos após as simulações e as comparações entre as arquiteturas e o Modelo de Persistência.

Por fim, no capítulo 5, de Considerações Finais, são apresentados todos os resultados obtidos, conclusões e propostas para trabalhos futuro.

Capítulo 2

Fundamentação Teórica

Este capítulo apresenta uma breve explicação dos assuntos necessários para o entendimento do trabalho proposto.

2.1 Energia Solar

Existem três principais meios de transformação da energia solar em energia: Sistema Solar Térmico, Sistema Solar Fotovoltaico e o Sistema Termossolar.

A energia solar térmica é captada por painéis solares térmicos, denominados coletores solares. Estes são os sistemas mais simples e econômicos os quais são utilizados para o aquecimento da água, de ambientes ou de processos industriais. Esses painéis são simples e sua função é transferir o calor da radiação solar para a água ou óleo que estão armazenados no seu interior, os quais serão utilizados como fonte de calor.

A energia solar fotovoltaica é captada por sistemas capazes de gerar energia elétrica através das células fotovoltaicas, as quais são distribuídas em módulos ou painéis solares fotovoltaicos. Estes sistemas são capazes de transformar a radiação solar diretamente em energia elétrica através do efeito fotovoltaico, presente em alguns materiais, sendo o silício o mais usado.

A energia termosolar ou energia solar concentrada é captada através de sistemas que inicialmente produzem calor utilizando conjuntos de espelhos, ou concentradores, que tem como objetivo concentrar a radiação solar e transformar o calor em energia elétrica. Essa forma é um tipo de energia solar térmica com o objetivo principal de gerar energia elétrica. Esta é a maneira menos utilizada para explorar a energia solar, devido ao alto custo e complexidade.

Fazendo uma comparação dos sistemas supracitados, a energia solar térmica é a mais eficiente e mais econômica, porém restrita à energia térmica, ou seja, não produz energia elétrica. A energia fotovoltaica é a mais utilizada, inclusive em satélites, pois é a mais confiável e a mais versátil das três. No entanto, ainda

apresenta um alto custo de implantação e dificuldades em armazenar a energia elétrica produzida. Já a energia solar concentrada é indicada para grandes instalações devido ao alto custo de implantação. [11]

Além da produção de energia elétrica, a energia solar pode ser utilizada para a redução do consumo desta através do uso da iluminação natural. Pesquisas mostram que 20 a 30% do consumo de energia elétrica em estabelecimentos comerciais são decorrentes do uso da iluminação artificial. [10]

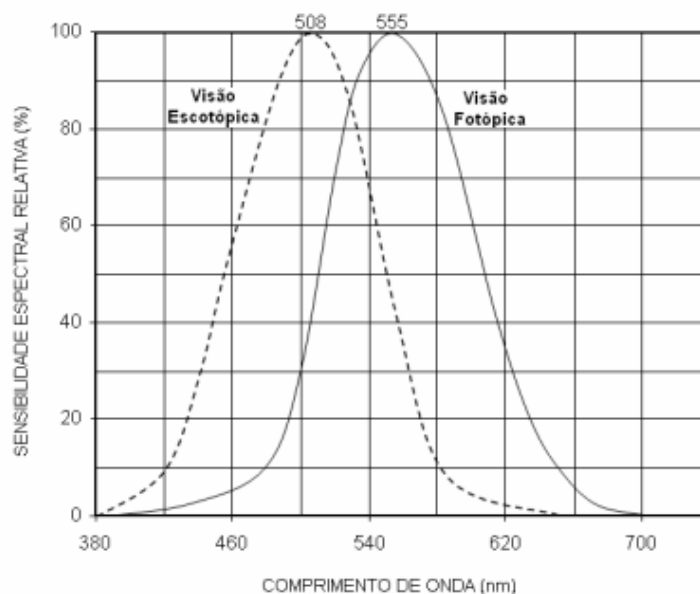
Para que o uso da iluminação natural reduza o consumo da energia elétrica é necessário o conhecimento da iluminância da região e que os projetos arquitetônicos sejam baseados nestes dados. Através do estudo da iluminância esses projetos precisam determinar o melhor posicionamento e dimensionamento das janelas, para que se obtenha um sistema de iluminação natural eficiente e que este não prejudique o sistema de refrigeração do local.

2.1.1 Iluminância

A iluminância ou iluminamento está relacionada à quantidade de luz visível, ou seja, que o olho humano é capaz de perceber. Sendo a iluminância a relação entre o fluxo luminoso, que é a potência luminosa total irradiada por uma fonte de luz, e a superfície sobre a qual este fluxo incide [5]. A unidade de medida da iluminância é o lux (lx), é a relação de um fluxo luminoso de 1 lúmen, gerado por uma fonte de luz pontiforme, que incide em uma área de $1m^2$.

O olho humano possui dois tipos de células sensíveis à luz, que são os bastonetes e os cones. O primeiro detecta os níveis de luminosidade e é responsável pela visão noturna, visão denominada escotópica. O segundo, os cones, fornecem a capacidade de percepção das cores e são responsáveis pela visão diurna, visão denominada fototópica. A sensibilidade do olho humano está diretamente relacionada à variação do comprimento de onda. Ele é capaz de perceber apenas uma faixa do espectro eletromagnético, que compreende o intervalo de comprimento de onda entre 380 e 780 nanômetros, tendo como valor máximo para comprimentos de onda próximos a $508nm$ para os bastonetes, e $555nm$ para os cones.

Na figura 1 está representada a sensibilidade do olho humano desde altos níveis de iluminância, visão fotópica, até baixos níveis de iluminância, visão escotópica.



Sensibilidade média do olho humano para diferentes comprimentos de onda.

[Fonte: [5]]

De acordo com a Norma Brasileira (NBR) 5413, da Associação Brasileira de Normas Técnicas (ABNT), para cada tipo de ambiente deve ser fornecido um determinado nível de iluminância ideal, que está relacionado ao tipo de atividade realizada no local. A seguir na Tabela 1 estão representados os níveis de iluminância e o tipo de ambiente que este nível está relacionado.

Tabela 1. Iluminâncias por classe de tarefas visuais

[Fonte: Retirada do site: <http://www.labcon.ufsc.br/anexos/13.pdf>]

	Iluminância (lux)	TIPO DE AMBIENTE/ATIVIDADE
CLASSE A (áreas de uso contínuo e/ou execução de tarefas simples)	20 – 30 – 50	Áreas públicas com arredores escuros
	50 – 75 – 100	Orientação simples para permanência curta
	100 – 150 – 200	Recintos não usados para trabalho contínuo; depósitos

CLASSE B (áreas de trabalho em geral)	200 – 300 – 500	Tarefas com requisitos visuais limitados, trabalho bruto de maquinaria, auditório
	500 – 750 – 1.000	Tarefas com requisitos visuais normais, trabalho médio de maquinaria, escritórios
	1.000 – 1.500 – 2.000	Tarefas com requisitos especiais: gravação manual, inspeção, indústrias de roupas
CLASSE C (áreas dom tarefas visuais minuciosas)	2.000 – 3.000 – 5.000	Tarefas visuais exatas e prolongadas, eletrônica de tamanho pequeno
	5.000 – 7.500 – 10.000	Tarefas visuais muito exatas, montagem de microeletrônica
	10.000 – 15.000 – 20.000	Tarefas visuais muito especiais, cirurgia

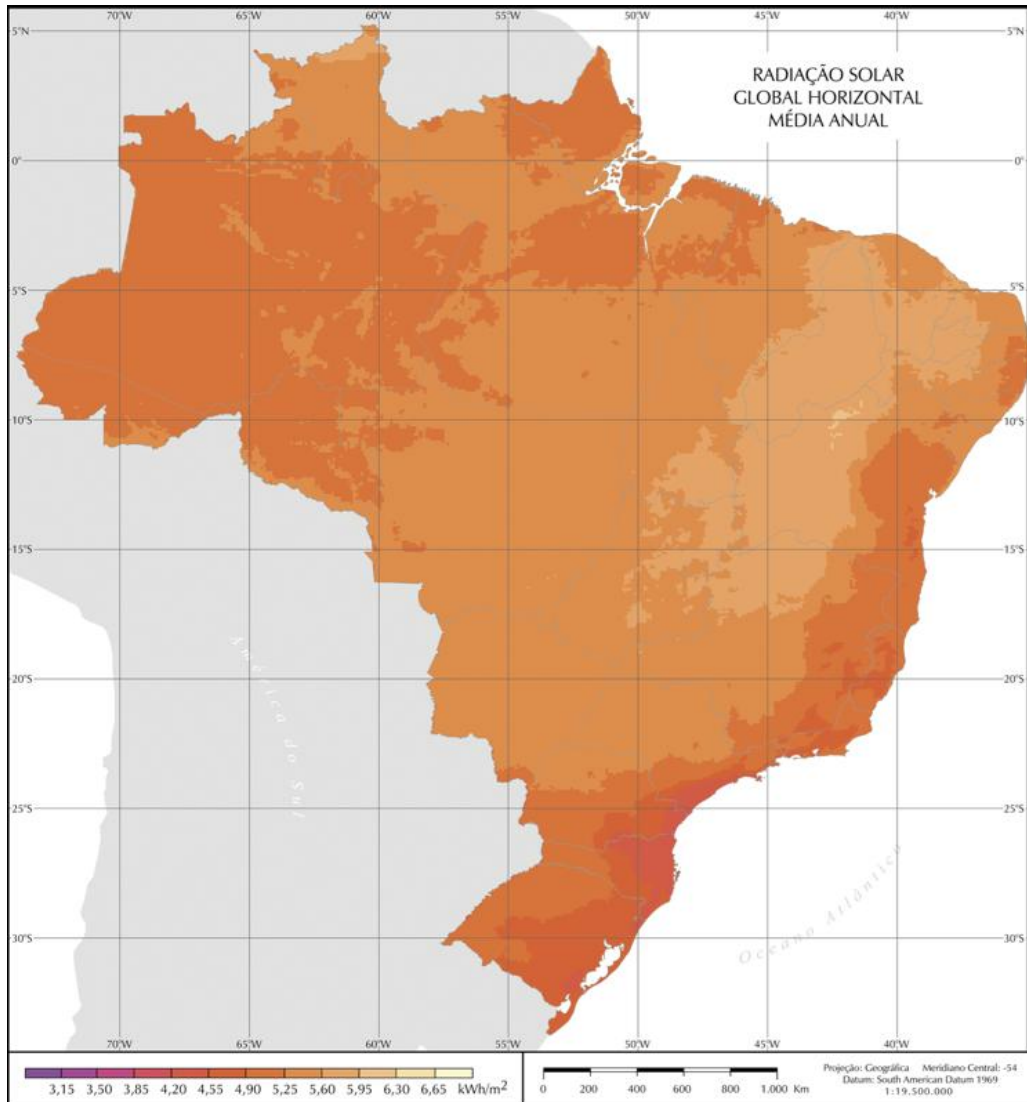
2.1.2 Radiação global horizontal

A radiação representa a energia disponível aos processos físicos e biológicos que ocorrem na superfície terrestre. É a diferença entre os fluxos totais da radiação incidente e a emitida e/ou refletida pela superfície medida, normalmente em plano horizontal. Durante o dia o saldo de radiação em uma superfície qualquer tende a ser positivo, pois representa o período de brilho solar no qual os fluxos incidentes, global e atmosférico são superiores às frações refletidas e/ou emitidas. Da mesma forma, durante à noite normalmente o saldo de radiação é negativo, já que o fluxo incidente passa a ser apenas atmosférico e a energia emitida pela superfície é superior a este, gerando um saldo de radiação negativo. [6][11]

Apesar do território brasileiro possuir regiões com características climáticas distintas, a média anual da radiação global é distribuída com uniformidade no país, apresentando médias anuais relativamente altas. O valor médio máximo de $6,5 \text{ kWh/m}^2$ é registrado no norte do estado da Bahia, região de clima semi-árido com baixa precipitação ao longo do ano e com a menor média anual de cobertura de nuvens do Brasil. Já a menor média anual de radiação solar global, $4,5 \text{ kWh/m}^2$ é registrada no litoral norte de Santa Catarina, região que possui chuvas bem distribuídas ao longo do ano. Os valores de radiação solar global incidente em qualquer região do território brasileiro são superiores aos da maioria dos países da União Européia, como Alemanha, França e Espanha, onde projetos de aproveitamento de recursos solares são amplamente disseminados. [6]

Os valores da radiação global horizontal obtidos no projeto SONDA (Sistema de Organização Nacional de Dados Ambientais) tem periodicidade de 1 min e representam a média da radiação global horizontal medidas em *Watts* por metro quadrado (Wm^{-2}).

A Figura 2 apresenta um mapa com a média anual do total diário de radiação solar global incidente no território brasileiro.



Mapa com a média anual do total diário de radiação solar global incidente no Brasil

[Fonte: Atlas Brasileiro de Energia Solar [1]]

2.1.3 Energia Solar no Brasil

Localizado na sua maior parte na região intertropical, o Brasil possui grande potencial para geração de energia solar durante o ano todo. A utilização da energia solar traz benefícios a longo prazo para o país, possibilitando o desenvolvimento de regiões isoladas onde o custo para inserção da rede elétrica convencional é extremamente alto, e de baixo retorno financeiro do investimento.

Nas regiões Sul e Sudeste do país, devido a característica climática, o principal uso da energia solar até o momento é para realizar o aquecimento de água em estabelecimentos residenciais e comerciais. Nestas regiões uma parcela significativa do consumo de energia elétrica é destinada ao aquecimento de água, principalmente nas residências, o que tem contribuído para o crescimento do aproveitamento da energia solar. Já a região Norte e Nordeste, apresenta como principal uso da energia solar a geração fotovoltaica de energia elétrica, visando principalmente o atendimento de comunidades isoladas da rede de energia elétrica e ao desenvolvimento regional. [2]

O fomento ao desenvolvimento de técnicas e sistemas para o aproveitamento da energia solar no país conta com o apoio técnico, científico e financeiro de instituições brasileiras, além do suporte de organismos internacionais. É um incentivo para o uso sustentável dos recursos naturais e manutenção do desenvolvimento econômico do país, principalmente de regiões que antes não tinham acesso a energia elétrica.

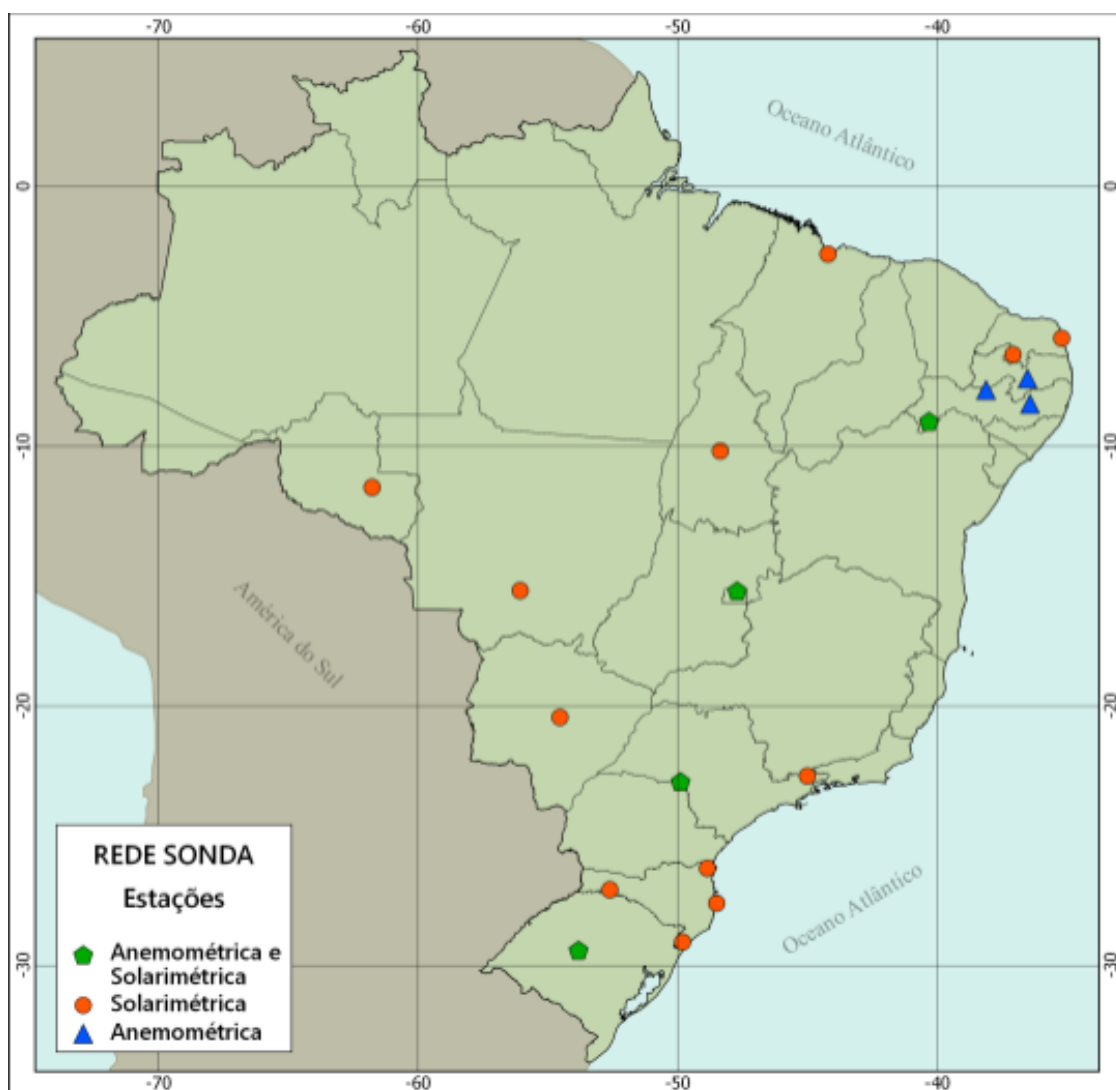
2.1.4 Projeto SONDA

Sistema de Organização Nacional de Dados Ambientais (SONDA) é um projeto implantado e gerenciado pelo Centro de Previsão do Tempo e Estudos Climáticos (CPTEC), do Instituto Nacional de Pesquisas Espaciais (INPE). Ele tem como objetivo principal implementar uma infraestrutura física e de recursos humanos destinada à montagem e melhoramento da base de dados de superfície necessária ao levantamento dos recursos de energia solar e eólica no Brasil e o consequente planejamento de seu uso. [13]

Segundo o INPE, a falta de investimento em larga escala nas fontes de energias renováveis solar e eólica se deve à falta de informações precisas e

confiáveis sobre a disponibilidade e variabilidade desses recursos. Desta forma o projeto SONDA tem como objetivo suprir essa necessidade, fornecendo um banco de dados e ferramentas para o uso apropriado pelo setor de energia.

Para coletar essas informações o projeto possui uma rede de estações distribuídas por todo território brasileiro, sendo classificadas como Solarimétricas, Anemométricas ou Solarimétricas e Anemométricas. Cada tipo de estação mede um conjunto de variáveis distintas. A Figura 3 apresenta um mapa do Brasil com a localização das estações do projeto.



Distribuição das estações da rede SONDA no território brasileiro

[Fonte : Retirada do site: <http://sonda.ccst.inpe.br/index.html>]

Além dos dados medidos pelos sensores o projeto conta com uma etapa de validação dos dados que garante a sua confiabilidade, visto que fatores ambientais

Rafael Lopes Mendonça

ou mesmo acidentais podem interferir na medição dos sensores. O processo de validação realizado pelo projeto está de acordo com a estratégia de controle de qualidade de dados adotada pela *Baseline Surface Radiation Network* (BSRN), para os dados de radiação, e de acordo com a *Webmet.com* para os dados Meteorológicos e anemométricos.

A Figura 4 apresenta as variáveis medidas pelas estações do projeto SONDA.



Variáveis medidas pelas estações do projeto SONDA

[Fonte : Retirada do site : <http://sonda.ccst.inpe.br/basedados/index.html>]

2.2 Redes Neurais

As Redes Neurais Artificiais (RNAs) são técnicas computacionais que apresentam modelos matemáticos inspirados no comportamento e funcionamento do cérebro humano. Elas tem como base as redes neurais biológicas as quais apresentam 10 bilhões de neurônios interconectados capazes de processar milhares de informações simultaneamente [15].

Os neurônios biológicos são formados pelos dendritos, conjunto de terminais de entrada pelos quais recebem os sinais, pelo corpo central no qual a informação é processada, e pelos axônios que são os terminais de saída.

Os neurônios possuem um limiar excitatório que define se a intensidade do estímulo recebido é suficiente ou não para disparar o impulso nervoso. Sendo assim caso o estímulo recebido tenha sido menor que o limiar excitatório, o impulso nervoso não ocorrerá. De forma contrária, caso o estímulo seja maior, o impulso nervoso será gerado e será o mesmo, independente da intensidade do estímulo recebido.

Em 1943 McCulloch e Pitts propuseram os neurônios artificiais, unidade da rede neural artificial (RNA) com o objetivo de realizar as mesmas funções do neurônio biológico. Ao contrário do cérebro humano, as grandes RNAs apresentam apenas centenas ou milhares de neurônios artificiais.

A figura 5 ilustra os dois tipos de neurônios supracitados.

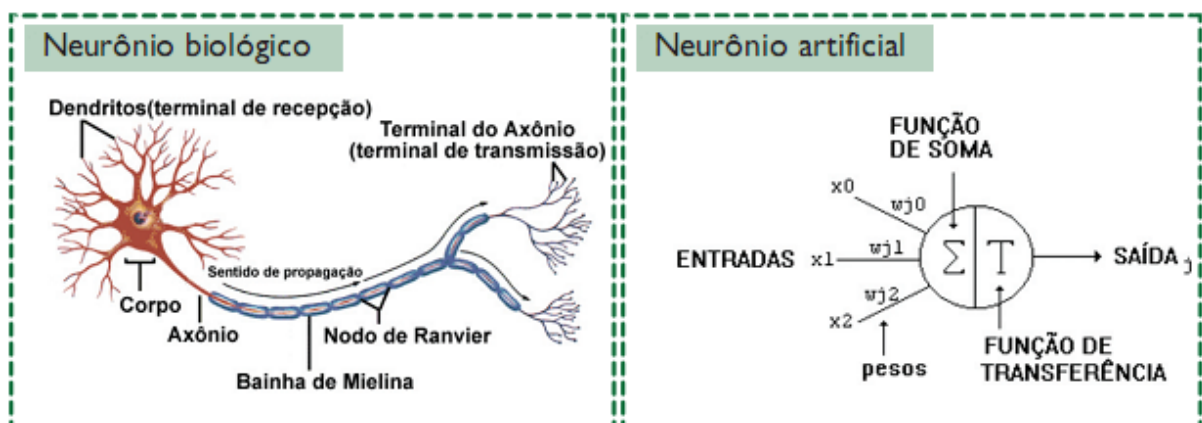


Ilustração do neurônio biológico e do neurônio artificial

[Fonte: Retirada do site: http://meus-projetos.blogspot.com.br/2010/05/redes-neurais-artificiais-2_03.html]

O modelo proposto por McCulloch e Pitts é formado pelo conjunto de entradas x_i (dendritos), pela unidade de processamento Σ e T (corpo celular) e pela saída j (axônio), sendo o produto de cada entrada x_i e o seu peso associado W_i o equivalente a sinapse do neurônio biológico. O peso representa a importância de cada entrada associada ao neurônio. Sendo assim, quanto maior a importância da entrada, maior será o seu peso. O somatório de todos os produtos, isto é, das

sinapses, é usado como parâmetro para a função de ativação $f(net)$, expressa pela Equação 1.

$$net_i = \sum_{i=0}^n x_i \times W_i \quad (1)$$

Sendo net_i utilizado para encontrar a saída de cada neurônio, que é calculada de acordo com a função de ativação utilizada. Há diversas funções de ativação que podem ser usadas nas RNA propostas na literatura, sendo as mais recorrentes a função linear, sigmóide logística e a tangente hiperbólica [15]. As Equações 2, 3 e 4 representam as funções de ativação supracitadas, na mesma ordem.

$$f(net_i) = net_i \quad (2)$$

$$f(net_i) = \frac{1}{1 + e^{-net_i}} \quad (3)$$

$$f(net_i) = \frac{e^{net_i} - e^{-net_i}}{e^{net_i} + e^{-net_i}} \quad (4)$$

A saída calculada da rede neural depende dos valores dos pesos de cada neurônio, uma vez que a saída é obtida pela multiplicação dos valores de entrada e o seu peso associado. Dessa forma é fundamental para o sucesso da RNA a correta escolha dos pesos que a constitui [15] e eles devem ser ajustados através de algoritmos de aprendizagem. Este aprendizado pode ser supervisionado (quando a resposta do problema é conhecida pela rede), não supervisionado (quando a rede não conhece a resposta do problema), ou por reforço (quando um supervisor externo avalia a resposta fornecida pela rede) podendo esse algoritmo ser executado ao fim de cada iteração do treinamento da rede, ou em lote, ao fim do treinamento inteiro da rede [4].

A partir da união de neurônios artificiais em uma ou mais camadas, é possível a construção das RNAs. As primeiras arquiteturas destas redes foram a *Perceptron* e a *Adaline*, sendo os dois modelos capazes de solucionar apenas problemas linearmente separáveis, onde o primeiro modelo lida apenas com saídas discretas, enquanto o segundo permite respostas no universo contínuo. Tal diferença se deve

à função de ativação escolhida pelos modelos propostos, uma função linear para a arquitetura *Perceptron* e uma função sigmóide para a *Adaline*.

Essas duas arquiteturas foram fundamentais para o estudo das Redes Neurais Artificiais (RNAs) futuras, como o *Multi-Layer Perceptron* (MLP) e *Radial Basis Neural Network* (RBFN), que serão abordados na sequência.

2.2.1 Multi-Layer Perceptron

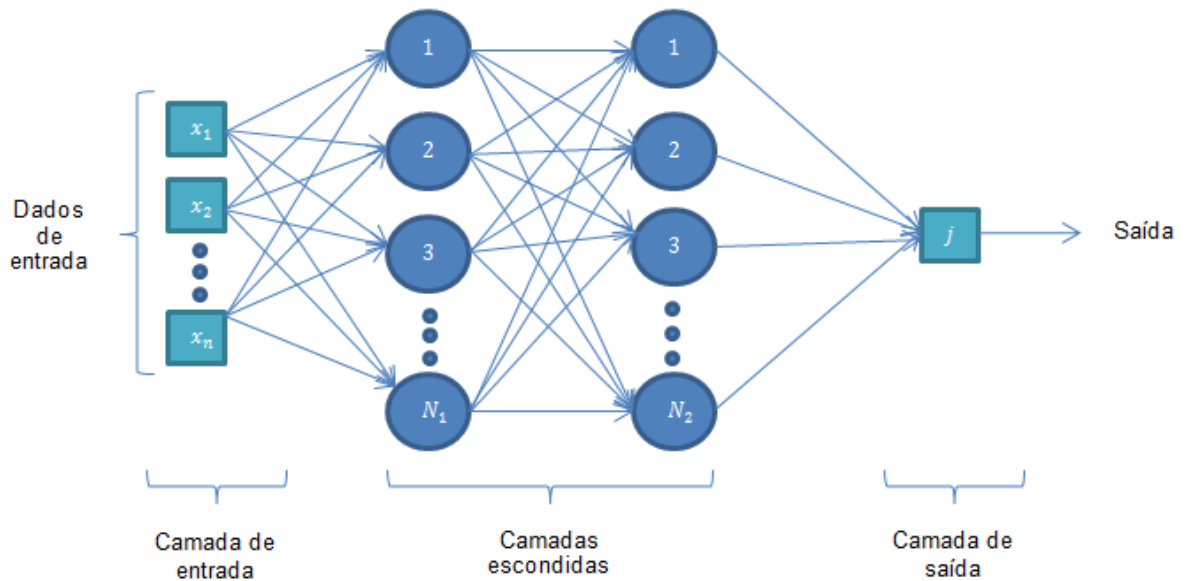
É uma das redes neurais mais encontradas na literatura. A MLP é uma rede de propagação unidirecional baseada na rede *Perceptron*, porém apresenta pelo menos uma camada de neurônios intermediária ou escondida. As camadas são conjuntos de neurônios que executam no mesmo nível de hierarquia. Sendo assim, a MLP apresenta no mínimo três camadas, a camada de entrada onde os neurônios representam as variáveis de entrada do problema, a camada intermediária ou escondida que é responsável pela solução de problemas não linearmente separáveis, sendo possível a aproximação de qualquer função matemática [3] e a camada de saída que representa a resposta da rede e é onde se encontra a variável desejada.

Os neurônios da camada escondida possuem geralmente uma função de ativação sigmoide que pode ser a logística ou a tangente hiperbólica. Já a camada de saída, além da função de ativação sigmoide, também podem apresentar a função de ativação linear.

A rede MLP é do tipo *feedforward*, ou seja, as informações das camadas são transmitidas em uma única direção. Sempre da camada de entrada para a camada escondida e, posteriormente, da camada escondida para a camada de saída.

Os neurônios da rede MLP são conectados através de ligações com pesos, que são inicialmente aleatórios, e que ao longo do treinamento são otimizados. Desta forma, a MLP, assim como outras arquiteturas de rede neural, precisa de um algoritmo de treinamento para calcular os seus pesos ótimos. Por apresentarem uma ou mais camadas escondidas, a complexidade do treinamento das redes MLP é diretamente proporcional à quantidade de camadas escondidas.

A Figura 6 representa uma rede MLP com duas camadas escondidas.



Arquitetura MLP com quatro camadas

[Fonte: elaboração própria]

O aprendizado das redes MLP é feito de forma supervisionada. Sendo assim, é possível calcular o erro na saída da rede e corrigir os pesos para que a rede se aproxime do valor esperado. Porém não se conhece o erro nas camadas intermediárias, o que dificulta na correção dos pesos dos neurônios desta camada [8].

O algoritmo de treinamento mais encontrado na literatura é o *Backpropagation* desenvolvido por Paul Werbos em 1974 [16]. Este algoritmo utiliza a retropropagação do erro encontrado na saída.

2.2.2 Algoritmo Backpropagation

O algoritmo backpropagation é dividido em duas fases: a fase *forward*, na qual a propagação do sinal é progressiva - da camada de entrada para a camada de saída - e os valores dos pesos não são alterados. Apenas a partir da saída da rede é calculado o erro encontrado. O erro é calculado pela diferença entre o valor calculado pela rede e o valor desejado. Nesse momento é iniciada a segunda fase

do algoritmo, a fase *backward*, na qual a propagação do sinal é regressiva - da camada de saída à camada de entrada - e os pesos são ajustados de acordo com a regra delta generalizada.

O *backpropagation* utiliza os parâmetros de taxa de aprendizado α e o momento β , sendo a taxa de aprendizado correspondente ao tamanho do passo em direção à correção do erro, e o momento é o parâmetro de convergência da rede, o qual diminui a incidência de mínimos locais [15].

A Equação 5 apresenta o cálculo realizado para reajustar os pesos.

$$W_{i,j}^m(t+1) = W_{i,j}^m(t) + \alpha \delta_i^m f^{m-1}(net_j^{m-1}) + \beta \Delta W_{i,j}^m(t-1) \quad (5)$$

Onde $W_{i,j}^m(t+1)$ é o novo valor atribuído ao i -ésimo peso do neurônio j , $W_{i,j}^m(t)$ é o valor atual do i -ésimo peso do neurônio j no instante t , e δ_i^m mede a sensibilidade do neurônio ao qual o peso em questão liga o neurônio j .

- δ : A sensibilidade é calculada segundo a Equação 6 para os neurônios da camada de saída, e de acordo com a Equação 7 para os neurônios das outras camadas:

Sensibilidade na camada de saída,

$$\delta_i^m = (d_i - y_i) f'(net_i) \quad (6)$$

Onde d_i é a saída desejada, y_i é a saída encontrada após o treinamento da rede e $f'(net_i)$ é a derivada da função de ativação da camada de saída.

Sensibilidade nas outras camadas,

$$\delta_j^{m-1} = f'^{m-1}(net_i^{m-1}) \sum_{i=l}^N W_{ij}^m \delta_i^m \quad (7)$$

Onde δ_i^m é a sensibilidade propagada pelo i -ésimo neurônio da camada imediatamente à frente, W_{ij}^m é o peso j do neurônio i e N é o número de neurônios na camada de saída.


2.2.3 Critério de parada

Durante o treinamento de uma rede neural artificial (RNA) dois problemas podem ocorrer, problemas ocasionados pela quantidade de épocas de treinamento. São eles o *overfitting* e o *underfitting*. O primeiro se deve ao treinamento excessivo da rede, fazendo com que esta decore os padrões e perca a sua capacidade de generalização. O segundo problema se deve ao treinamento insuficiente da rede, fazendo com que a rede não aprenda com os padrões fornecidos e assim não possa generalizar. O número de épocas é uma variável do treinamento que depende necessariamente do problema na qual a RNA é submetida.

Sendo assim é necessário determinar um critério de parada que evite os dois problemas supracitados, e um dos critérios de parada mais utilizados é a validação cruzada. Para a validação cruzada é necessário dividir a base de dados do problema em três partes: treinamento, validação e teste. O conjunto de treinamento é utilizado para ajustar os pesos da rede, de acordo com o algoritmo de treinamento escolhido. Após cada época, a rede previamente treinada, com os pesos ajustados, o conjunto de dados de validação cruzada é inserido na RNA e é feita a verificação da diferença entre a saída encontrada e a saída desejada. Sendo os pesos mantidos fixos nessa etapa, sendo eles inéditos a cada época para o conjunto de validação. Enquanto o erro de validação cruzada estiver diminuindo, a rede continuará generalizando.

No momento em que o erro de validação cruzada começar a aumentar enquanto o de treinamento continuar a diminuir, isto pode sugerir que a rede está começando a decorar os padrões presentes no conjunto de dados de treinamento, sendo este o ponto de parada para o treinamento dos dados. Em seguida é inserido o conjunto de teste na RNA para realizar a avaliação do desempenho que esta obteve.

A Figura 7 apresenta um gráfico no qual é possível visualizar o momento que deve ser realizada a parada do treinamento da rede.



Ponto de parada do treinamento da rede utilizando validação cruzada.

[Fonte : elaboração própria]

O algoritmo de treinamento utilizado neste trabalho é o algoritmo *Backpropagation*.

2.2.4 Radial Basis Function Network

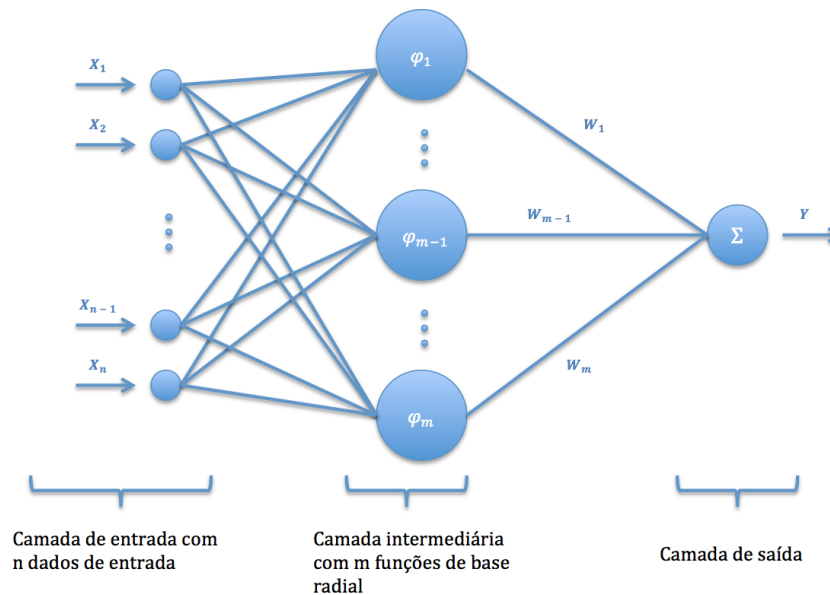
As Redes de Funções de Base Radial (*Radial Basis Function Network* - RBFN) são redes neurais provenientes da Análise Numérica, que tem por finalidade a aproximação de funções utilizando como função de ativação as funções de base radial. Sua origem remete ao ano de 1988, desenvolvida com o intuito de realizar a interpolação de dados em espaços multidimensionais, sendo consideradas aproximadoras universais de funções [14]. Apresenta similaridade com a arquitetura MLP, porém a RBFN consiste em uma camada de entrada, apenas uma camada intermediária e uma camada de saída. Essas redes são capazes de solucionar problemas não linearmente separáveis, pois apresentam uma camada intermediária e utilizam a função de ativação de base radial não linear. As funções de base radial são funções que recebem números reais como entrada, que dependem apenas da distância a partir da origem, ou sobre algum ponto definido como o centro, tendo o seu valor máximo quando a distância for zero. Para calcular a distância supracitada, a função normalmente utilizada é a função euclidiana definida na Equação 8.

$$d_E(P, Q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (8)$$

Onde p_i e q_i são os pontos nos quais a distância entre eles são calculadas.

2.2.4.1 Estrutura da Rede RBFN

As RBFN são unidirecionais e apresentam funções de ativação não lineares da camada de entrada para a camada intermediária, e funções de ativação lineares da camada intermediária para a camada de saída. A camada de entrada realiza a interface entre o modelo e o meio. A Figura 8 representa a topologia da rede RBFN.



Topologia da rede RBFN.

[Fonte : elaboração própria]

A cada dado de entrada da rede será calculada a sua distância a cada neurônio da camada intermediária, sendo a camada de saída responsável pela construção do padrão de saída da rede. Nas RBFN a generalização ocorre durante a interpolação de pontos não pertencentes ao conjunto de dados de treino, mas que estejam em sua vizinhança em uma superfície multidimensional.

A função de ativação mais utilizada é a Gaussiana, descrita na Equação 9. Esta é a função de base radial utilizada como função de ativação na transformação da camada de entrada para a camada intermediária.

$$\phi_j(x) = \exp\left(-\frac{\|x - \mu_j\|^2}{2\sigma_j^2}\right) \quad (9)$$

Onde x são os dados de entrada da rede, μ_j e σ_j são o centro e a dispersão da i -ésima função de base radial.

2.2.4.2 Treinamento da Rede RBFN

O tipo de treinamento mais comumente encontrado na literatura para as redes RBFN é do tipo híbrido, o qual possui duas fases:

- Não supervisionada, que ocorre na definição dos parâmetros das funções de base radial da camada intermediária;
- Supervisionada, momento em que os pesos que ligam a camada intermediária à camada de saída são ajustados.

Na primeira fase normalmente são usados algoritmos de *clusterização*, por exemplo o k -médias, para identificar os pontos centrais das funções radiais. O conjunto de pontos centrais reflete com precisão a distribuição dos dados, dessa forma o algoritmo divide os dados de entrada em subconjuntos S , com o objetivo de minimizar a função F definida na Equação 10.

$$F = \sum_{i=1}^K \sum_{j \in S} \|x_j - \mu_i\|^2 \quad (10)$$

Onde μ_i é a média dos pontos pertencentes ao conjunto S calculado de acordo com a Equação 11.

$$\mu_i = \frac{1}{N_i} \sum_{j \in S} x_j \quad (11)$$

2.2.5 Modelo de Persistência

O modelo de persistência é um modelo no qual o dado a ser previsto possui o mesmo valor do resultado da observação imediatamente anterior ao dado de entrada. A Equação 12 define o modelo de Persistência.

$$Y(t) = Y(t - 1) \quad (12)$$

A utilidade deste modelo é servir de referência para previsões de curto prazo, onde não ocorrem grandes variações dos dados em um curto espaço de tempo. O

modelo de Persistência é usado como critério de avaliação dos resultados obtidos pelas redes neurais. Este modelo pode apresentar, para previsões de poucas horas à frente, desempenho melhor que o obtido pelas RNAs [8].

Capítulo 3

Metodologia

Neste capítulo serão apresentadas as etapas de desenvolvimento deste trabalho, aquisição e tratamento dos dados, além da definição dos parâmetros das arquiteturas MLP e RBFN.

3.1 Aquisição e Tratamento dos Dados

Os dados de radiação global horizontal e de iluminância foram retirados do projeto SONDA (Sistema de Organização Nacional de Dados Ambientais), um projeto implantado e gerenciado pelo Centro de Previsão do Tempo e Estudos Climáticos (CPTEC), do Instituto Nacional de Pesquisas Espaciais (INPE). Os dados escolhidos foram coletados na estação Solarimétrica e Anemométrica da cidade de Petrolina, Pernambuco. Foram coletados os dados de Janeiro de 2013 à Julho de 2014, o que representa uma amostra de um pouco mais de ano e meio de dados. Os sensores coletam a radiação global horizontal e a iluminância a cada 1 minuto, ou seja, 830.880 valores coletados pelos sensores, para cada variável.

Para cada mês é gerado uma planilha com os dados solarimétricos da estação do projeto SONDA. Foram adquiridos 19 arquivos com estes dados da estação de Petrolina. Os valores de radiação global e iluminância foram retirados dos 19 arquivos e inseridos em planilhas separadas, uma para cada variável, representando dessa forma uma série temporal para os dados escolhidos.

Em alguns momentos os sensores por motivos adversos não foram capazes de mensurar o valor, sendo representados por N/A para os valores inválidos. Estes valores foram substituídos pela média dos dois valores acima somados aos dois valores abaixo do que estava inválido. Esta substituição é representada pela Equação 13.

$$N/A_i = \frac{C_{i-2} + C_{i-1} + C_{i+1} + C_{i+2}}{4} \quad (13)$$

Onde i representa o índice na série temporal do valor coletado e C representa um valor válido medido pelo sensor.

Além destes valores o projeto SONDA realiza uma análise dos dados, feita a cada mês, que é disponibilizada junto com o arquivo dos dados adquiridos pelos sensores. De acordo com a análise, menos de 5% dos valores obtidos podem ser considerados incorretos ou suspeitos, os quais têm a possibilidade de estarem incorretos. Sendo assim, os dados foram utilizados desconsiderando essa pequena taxa de incerteza dos dados obtidos.

Os dados de radiação possuem uma enorme variação, tendo como valor máximo $999,000 \text{ Wm}^{-2}$ e como valor mínimo $-62,160 \text{ Wm}^{-2}$. Os valores negativos de radiação se devem ao fato que durante à noite normalmente o fluxo incidente passa a ser apenas atmosférico, e a energia emitida pela superfície é superior a este fluxo, o que representa um saldo negativo de radiação.

Já os dados de iluminância estão compreendidos entre $16,72633 \text{ klux}$ e $38,46866 \text{ klux}$.

Para que os dados fiquem compreendidos em um intervalo menor é necessário utilizar uma função de normalização dos dados, representada pela Equação 14.

$$y = \left((b - a) \times \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) \right) + a \quad (14)$$

Onde a e b representam os limites máximos e mínimos que os dados podem alcançar após a normalização. Neste trabalho foi utilizado o valor de $-0,85$ para a e $0,85$ para b , para os dados de radiação, e $0,15$ para a e $0,85$ para b , para os dados de iluminância.

Após a normalização dos dados foi realizada a transformação da série temporal para um série que apresenta valores a cada 30 min, ao invés de dados a cada um minuto como foram obtidos do projeto SONDA. Para tanto, foi feita a média a cada conjunto de 30 valores da série. Dessa forma a quantidade de linhas nas planilhas de dados foi reduzida evitando problemas de uso excessivo da memória.

Em seguida foi realizada a defasagem dos dados em 48 colunas, para que seja feito o estudo de correlação linear dos valores das colunas em relação a

primeira coluna, que contém os dados que serviram de base para a defasagem. A partir dos valores obtidos pela correlação será definida a quantidade de colunas de entrada para a RNA. De acordo com a correlação realizada as 12 primeiras colunas possuem uma correlação relevante para a radiação, e as 14 primeiras para a iluminância, sendo essas as quantidades máximas de variáveis selecionadas para o arquivo de entrada. A Tabela 2 apresenta o resultado obtido com o estudo da correlação linear realizado.

Tabela 2. Estudo de correlação linear das variáveis de radiação global horizontal e iluminância em tempos anteriores

T	T- 30min	T- 1h	T- 1h30min	T- 2h	T- 2h30min	T- 3h	T- 3h30min	T- 4h	T- 4h30	T- 5h	T- 5h30min	T- 6h	T- 6h30
Radiação global horizontal													
1	0,92	0,84	0,76	0,69	0,61	0,53	0,45	0,36	0,28	0,20	0,13	0,05	-0,01
Iluminância													
1	0,99	0,96	0,92	0,86	0,80	0,72	0,64	0,56	0,47	0,38	0,29	0,20	0,11

3.2 Simulação com a MLP

Para realizar a previsão da radiação global horizontal utilizando a arquitetura MLP (*Multi-Layer Perceptron*) é necessária a definição de alguns parâmetros utilizados pela RNA (Rede Neural Artificial). Entre os parâmetros configuráveis da MLP estão:

- Dados de entrada da rede neural;
- Dados de *Target* (alvo);
- Número de neurônios na camada de entrada;
- Número de camadas intermediárias e a quantidade de neurônios em cada uma delas;
- Número de neurônios na camada de saída;

- Função de ativação da camada de entrada para camada intermediária;
- Função de ativação da camada intermediária para a camada de saída;
- Critérios de parada;
- Equação para o cálculo do erro.

Para este trabalhos alguns parâmetros foram previamente definidos:

- Apenas uma camada intermediária;
- Função tangente hiperbólica como a função de ativação da camada de entrada para camada intermediária;
- Função linear com a função de ativação da camada intermediária para a camada de saída;
- Erro médio quadrático para o cálculo do erro.

A função de ativação tangente hiperbólica tem como limite inferior -1 e 1 como superior. A Equação 15 apresenta esta função.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (15)$$

O critério de parada tem como objetivo minimizar o risco de ocorrência de overfitting da rede. O Erro Médio Quadrático (EMQ) será utilizado para auxiliar na parada do treinamento. Caso ocorram 6 aumentos do EMQ da validação, o treinamento será interrompido mesmo que haja redução do EMQ do conjunto de treinamento. A Equação 16 define o Erro médio Quadrático.

$$EMQ = \frac{\sum_{i=1}^n (Y_{ti} - Y_{pi})^2}{n} \quad (16)$$

Onde Y_{ti} é o valor médio para o instante i , e Y_{pi} é o valor previsto para o instante i .

A definição da quantidade de neurônios na camada intermediária foi baseada na análise do EMQ obtido pela simulação da rede com valores de neurônios entre 2 e 105, simulados de forma iterativa. Dessa forma foram realizadas simulações para diversos valores de neurônios na camada escondida e foi escolhida a rede que apresentou o menor EMQ.

A quantidade de neurônios na camada de saída é definida pela previsão que se deseja realizar. Devido à periodicidade dos dados de entrada serem de 30 minutos, para que se possa prever 1 hora adiante é necessário utilizar dois neurônios na camada de saída. Para que seja possível prever 1 hora à frente são necessárias duas colunas de dados como *Target*.

A partir dos dados de entrada são gerados aleatoriamente os conjuntos de dados de treinamento, teste e validação. Neste trabalho foram utilizados 50% dos dados de entrada para gerar o conjunto de dados de treinamento, 25% para o conjunto de dados de validação e 25% dos dados de entrada para gerar o conjunto de dados de teste. Os pesos também são gerados aleatoriamente a cada simulação da rede.

Foram realizadas 30 simulações e ao final de cada simulação foi gerado um arquivo contendo os valores das duas colunas de dados previstos tanto para as simulações feitas para a radiação global horizontal, quanto para a iluminância, sendo para cada coluna a previsão dos dados 30 minutos à frente.

3.2.1 Simulações com a MLP para radiação

Os dados de radiação foram simulados através da ferramenta *Neural Toolbox* da IDE do *software* Matlab, para configurações diferentes entre si devido a taxa de aprendizagem α e o momento β . Porém os resultados obtidos para o estudo da média dos EMQs dos valores desnormalizados foram extremamente altos. A Tabela 3 apresenta os resultados obtidos no estudo da média dos EMQs para os valores de radiação simulados em uma configuração usada na MLP e a comparação com o modelo de persistência.

Tabela 3. EMQs médios obtidos pela simulação dos dados de radiação na MLP

Valores desnormalizados		Valores normalizados	
MLP com $\alpha = 0,2$ e $\beta = 0,6$	Persistência	MLP com $\alpha = 0,2$ e $\beta = 0,6$	Persistência
1,9155E+48	2,7854E+10	0,111726	0,06471

Sendo assim, foi necessário a utilização de outra ferramenta de simulação para a validação dos resultados obtidos. Para tanto foi utilizado o simulador implementado na linguagem JAVA pelos alunos de mestrado do Programa de Pós-Graduação *stricto sensu* em Engenharia de Computação (PPG-EC) da Universidade de Pernambuco.

Os resultados obtidos nesse simulador foram similares aos obtidos no MatLab, sendo utilizados apenas os valores normalizados para a análise dos resultados obtidos. Os dados de radiação global horizontal foram simulados no projeto desenvolvido em JAVA em 48 configurações diferentes para a MLP, e não foram feitas simulações na rede RBFN. Estas configurações além de variarem a taxa de aprendizado α e o momento β , também apresentam diferentes valores para a quantidade de neurônios na camada de entrada e na camada escondida.

3.2.1 Simulações com a MLP para iluminância


Foram definidas quatro configurações diferentes para simular os dados de iluminância com a MLP. Estas configurações possuem variações na taxa de aprendizado α e o momento β , e para cada uma foi feito o estudo da melhor quantidade de neurônios na camada escondida. Porém todas as configurações apresentam 12 neurônios na camada de entrada e 2 na camada de saída, o que representa 12 valores de entrada para a previsão de 1 hora à frente.

As configurações utilizadas foram:

- $\alpha = 0,2$ e $\beta = 0,6$;
- $\alpha = 0,2$ e $\beta = 0,8$;
- $\alpha = 0,4$ e $\beta = 0,6$;
- $\alpha = 0,4$ e $\beta = 0,8$;

O estudo da quantidade de neurônios na camada escondida realiza simulações da rede, variando a quantidade de neurônios na camada escondida de 2 a 105. A cada iteração são adicionados dois neurônios a camada escondida. O valor da taxa de performance é armazenado a cada iteração, para que se possa definir qual quantidade de neurônios apresentou o melhor desempenho.


A Figura 9 apresenta o resultado obtido para a primeira configuração, $\alpha = 0,2$ e $\beta = 0,6$.



Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,2$ e $\beta = 0,6$.

[Fonte : elaboração própria]

Como pode ser observado na Figura 9, 4 foi a quantidade de neurônios que apresentou o menor erro médio quadrático, sendo esta a quantidade utilizada para esta primeira configuração. Desta forma a topologia dessa configuração foi definida como mostra a Figura 10.



Topologia para a configuração da MLP com $\alpha = 0,2$ e $\beta = 0,6$.

[Fonte : MatLab]

Foram realizados os mesmos estudos para as outras três configurações. Os resultados obtidos para as outras configurações foram:

- $\alpha = 0,2$ e $\beta = 0,8$: 6 neurônios na camada escondida;
- $\alpha = 0,4$ e $\beta = 0,6$: 4 neurônios na camada escondida;
- $\alpha = 0,4$ e $\beta = 0,8$: 10 neurônios na camada escondida;

O Apêndice A contém os gráficos e a topologia de cada configuração.

3.3 Simulação com a RBFN

Da mesma forma que foram definidos os parâmetros para a MLP, a Rede com Função Base Radial (RBFN) também precisa ser configurada para que o melhor desempenho da rede seja obtido. Alguns dos parâmetros da RBFN são:

- Quantidade de neurônios na camada de entrada;
- Quantidade de neurônios na camada intermediária;
- Quantidade de neurônios na camada de saída;
- Função de ativação de base radial;
- Critérios de parada;
- *Spread*, valor de dispersão.

A quantidade de neurônios nas camadas de entrada e de saída deve ser a mesma utilizada na rede MLP, para que seja possível realizar a comparação das arquiteturas utilizadas.

Para a simulação na rede RBFN foi preciso gerar arquivos separados para o treinamento e testes da rede, diferente da rede MLP, na qual o próprio algoritmo gerava aleatoriamente os conjuntos de treinamento, testes e validação, seguindo os percentuais definidos para cada conjunto. Sendo assim, foram gerados 30 arquivos para treinamento, sendo um para cada iteração do algoritmo da rede RBFN, e um arquivo de teste.

As RBFN utilizam funções gaussianas como função de ativação da camada intermediária, e uma função de ativação linear na camada de saída. A Equação 17 define a função gaussiana.

$$f(\theta_{in}) = e^{-\theta_{in}^2} \quad (17)$$

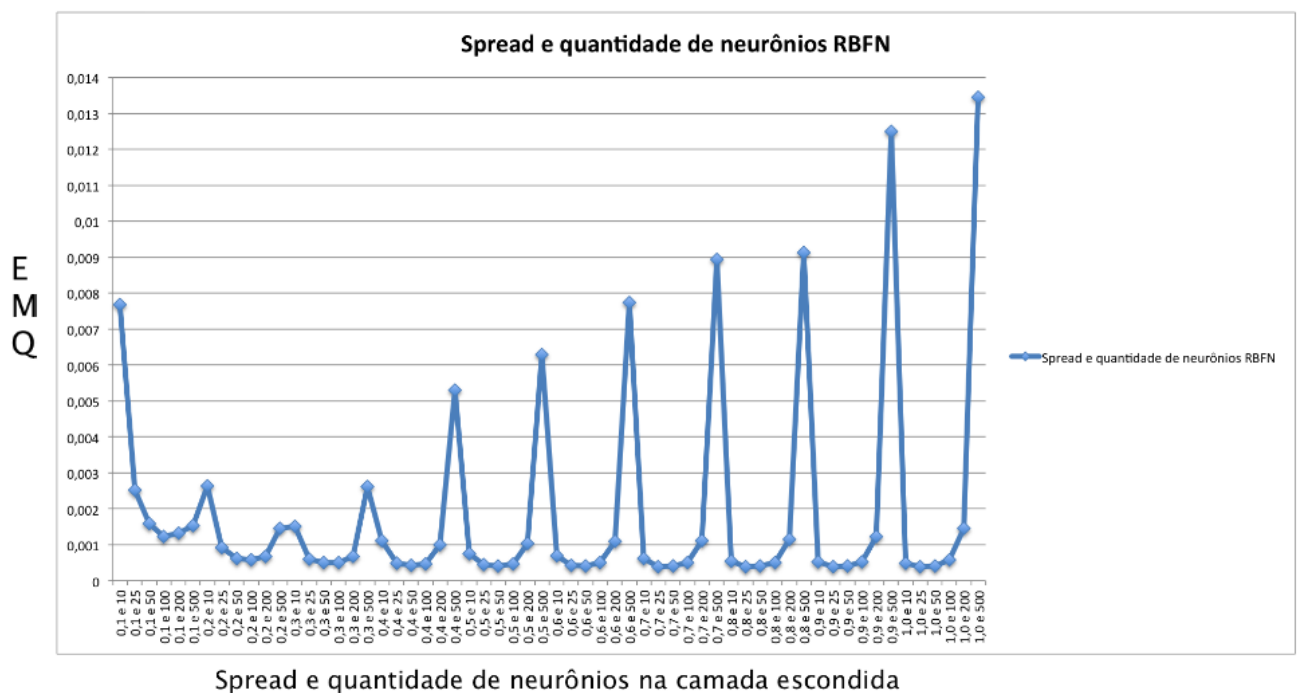
Onde θ_{in} é o valor de entrada do neurônio.

Esta função tem o seu valor máximo no centro e este valor decresce a medida que se afasta do centro. É possível ajustar os resultados alterando o valor de dispersão da função. Valores de dispersão maiores fazem com que a aproximação da função seja mais suave. Um valor de dispersão baixo fará com que uma quantidade menor de neurônios seja necessária para aproximar a função que varia

rapidamente, porém para uma função de curva suave será necessária uma quantidade maior de neurônios, o que acarretará problemas de generalização.

Para definir o valor de dispersão foi realizado um estudo a partir da simulação da rede RBFN de forma iterativa. Através da ferramenta *Neural Toolbox* da IDE do software Matlab é possível executar um algoritmo no qual o valor do *spread* é testado iterativamente para diferentes quantidades de neurônios, até que um critério de parada seja atingido. Através desse estudo é escolhida a melhor taxa de dispersão e a quantidade de neurônios na camada escondida. As simulações realizadas pelo estudo variou a taxa de dispersão de 0,1 a 1, para 10, 25, 50, 100, 200 e 500 neurônios na camada intermediária. Foi selecionada a configuração que obteve o melhor desempenho.

A Figura 11 apresenta o resultado obtido para o estudo do *spread* e da quantidade de neurônios na camada escondida para os dados de iluminância.



Estudo do *spread* e da quantidade de neurônios na camada escondida para os dados de iluminância.

[Fonte : Elaboração própria]

De acordo com o estudo foi selecionado o valor 0,9 para o *spread* e 25 neurônios na camada escondida.

Apenas os dados de iluminação foram simulados com a RBFN, pois os dados de radiação apresentaram resultados não satisfatórios para o erro médio quadrático com os valores desnormalizados.

3.4 Análise Estatística

Após a simulação das redes os resultados foram salvos em arquivos que contém as duas colunas de valores de radiação global horizontal, sendo a primeira coluna referente ao valor 30 minutos à frente, e a segunda coluna referente ao valor da radiação 1 hora à frente.

Para que seja possível realizar as comparações entre as redes simuladas e a análise estatística, os dados precisam ser desnormalizados, para que sejam comparados aos valores originais. A Equação 18 é utilizada para desnormalizar os dados.

$$y = \frac{(x_i - l_{inf})(x_{max} - x_{min})}{(x_{max} - x_{min})} + x_{min} \quad (18)$$

Onde:

- y é o valor desnormalizado;
- x_i é o valor do elemento atual;
- x_{min} é o valor mínimo de x no conjunto original;
- x_{max} é o valor máximo de x no conjunto original;
- l_{inf} é o limite inferior, neste trabalho o valor inferior é -0,85;
- l_{sup} é o limite superior, neste trabalho o valor superior é 0,85;

Após gerar os arquivos com os dados desnormalizados, estes valores são comparados com os valores originais para que se possa obter o EMQ de cada resultado obtido. Dessa forma para cada arquitetura foram coletados 30 EMQs, e para que se possa identificar o desempenho da rede é calculado a média dos 30 EMQs.

Também foi calculado o EMQ para o modelo de Persistência, sendo este utilizado como um métrica de análise dos resultados obtidos nas redes MLP e RBFN. Ou seja, estas duas redes devem apresentar uma performance superior ao desempenho do modelo de Persistência, para que possam ser consideradas eficientes e necessárias.

Além da comparação das redes utilizando o a média dos 30 EMQs foram realizados testes estatísticos que avaliam qual arquitetura possui o melhor desempenho na previsão da radiação global horizontal. Os testes estatístico utilizaram os 30 EMQs de cada arquitetura como entrada para realizar a análise de desempenho. Para realizar esta análise utilizou-se o *software* matemático R, pois este possui ferramentas prontas para realizar todos os testes utilizados. Este *software* utiliza como padrão um nível de significância α previamente definido com o valor de 0,05.

As próximas seções descrevem cada teste realizado, quais os objetivos de cada um e como cada um analisa os resultados encontrados.

3.4.1 Teste Shapiro-Wilk

O objetivo do Teste Shapiro-Wilk é verificar se os dados estão normalmente distribuídos. Para que se possa avaliar as premissas supracitadas, é necessária a formulação das hipóteses nula e alternativa da seguinte forma:

- Hipótese nula: a amostra provém de uma população Normal;
- Hipótese alternativa: a amostra não provém de uma população Normal.

Para cada conjunto de teste executado deve-se analisar o *p-value* encontrado e comparar com o nível de significância previamente definido como 0,05. Caso o *p-value* seja menor que α , a hipótese nula deve ser rejeitada e a amostra não deve ser considerada normalmente distribuída.

3.4.2 Teste F

O objetivo do Teste F é verificar se as variâncias entre dois conjuntos de dados são estatisticamente iguais, ou seja, provenientes de uma mesma população.

Da mesma forma que foram definidas as hipóteses para o teste anterior é necessária a formulação para este teste também, feita da seguinte forma:

- Hipótese nula: as amostras possuem variâncias estatisticamente iguais;
- Hipótese alternativa: as amostras não possuem variâncias estatisticamente iguais.

Para cada conjunto de teste executado deve-se verificar o *p-value* calculado, e caso este seja menor que o nível de significância α a hipótese nula deve ser rejeitada e as amostras não possuem variâncias estatisticamente iguais.

Com os resultados deste teste, como descrito na seção anterior é possível determinar se o conjunto de dados pode ser utilizado por testes paramétricos. Para tanto o conjunto de dados necessita ter suas amostras normalmente distribuídas e com variâncias estatisticamente iguais, caso contrário deve-se aplicar testes não paramétricos.

3.4.3 Teste T-Student

O teste T-Student realiza a análise das médias dos valores de duas amostras independentes, e tem como objetivo verificar se as médias de cada uma das amostras são estatisticamente iguais, ou se há alguma diferença entre elas. Caso haja alguma diferença entre elas, a amostra que tiver a maior média, será considerada como a de melhor desempenho.

Este teste é paramétrico e dessa forma deve ser aplicado somente se os resultados dos testes anteriores obtiverem como resposta que a amostra é normalmente distribuída e que elas pertencem a uma mesma população, ou seja, suas variâncias são estatisticamente iguais.

Assim como os outros testes, para analisar o resultado obtido é necessário ter formulado previamente as hipóteses nulas e alternativas.

- Hipótese nula: as médias das amostras analisadas são estatisticamente iguais;
- Hipótese alternativa: as médias das amostras analisadas não são estatisticamente iguais.

Caso o *p-value* encontrado seja menor que o nível de significância α , a hipótese nula é rejeitada e a amostra que tiver a maior média é considerada a de melhor desempenho.

Neste trabalho serão comparadas as arquiteturas utilizadas, MLP e RBFN, e caso a hipótese nula seja rejeitada, a topologia que apresentar a maior média de taxa de acerto será considerada a de melhor desempenho para a previsão da radiação global horizontal.

3.4.4 Teste da soma dos Postos de Wilcoxon

Teste não paramétrico que utiliza as posições que os valores dos dados amostrais de duas populações independentes ocupam, quando colocados em ordem crescente, com o objetivo de verificar a hipótese nula de que as amostras provêm de populações com medianas iguais. A hipótese alternativa é a que as duas populações tem medianas diferentes.

- Hipótese nula: as medianas das amostras analisadas são estatisticamente iguais;
- Hipótese alternativa: as medianas das amostras analisadas não são estatisticamente iguais.

Apesar de ser um teste não paramétrico, este teste é útil para comprovar os resultados e determinar se estes não são normais ou não possuem variâncias estatisticamente iguais.

Da mesma forma que os testes anteriores, é calculado o *p-value* e este deve ser comparado com o nível de significância α . Caso esse valor seja menor que α , a hipótese nula deve ser rejeitada, o que determina que há diferença significativa entre as duas amostras.

Capítulo 4

Resultados

Neste capítulo, serão apresentados os resultados obtidos nas simulações das Redes Neurais Artificiais para as variáveis de radiação global horizontal e iluminância, e a comparação com o modelo de persistência. Além disso, será feita uma análise estatística, realizada com os valores dos erros médios quadráticos de cada configuração utilizada para as arquiteturas escolhidas, isto é, *Multi-Layer Perceptron* (MLP) e *Radial Basis Function Network* (RBFN).

4.1 Resultados da Radiação Global Horizontal

Os resultados apresentados a seguir foram obtidos com o uso dos dados da variável de radiação normalizados, de acordo com a Seção 3.1. Isto se deve ao fato de que os resultados obtidos com os dados desnormalizados não foram satisfatórios, o que pode representar uma necessidade de utilização de outras variáveis para que se possa prever os valores futuros de radiação global horizontal.

Sendo assim, foi determinado um conjunto de 48 configurações diferentes para serem simuladas na rede neural MLP, as quais possuem variações na quantidade de neurônios na camada de entrada e intermediária, além de valores diferentes para a taxa de aprendizagem e momento.

Para cada configuração foi calculado o erro médio quadrático, e para configurações com a mesma quantidade de neurônios na camada de entrada e intermediária foi calculado o erro médio absoluto EMA. As configurações que apresentaram o melhor desempenho foram hachuradas com a cor azul.

A Figura 12 apresenta o resultado obtido pelo estudo do EMQ das configurações utilizadas.

Configuração		EMQ	Avaliação Erro médio quadrático (EMQ)		Configuração		EMQ	
MLP_E4_A02_B08_N4		0,47974059	MLP_E6_A02_B08_N4	0,47924693	MLP_E12_A02_B08_N4		0,48206611	
MLP_E4_A02_B06_N4		0,47718142	MLP_E6_A02_B06_N4	0,47894073	MLP_E12_A02_B06_N4		0,47791421	
MLP_E4_A04_B08_N4		0,48097478	MLP_E6_A04_B08_N4	0,48801156	MLP_E12_A04_B08_N4		0,48646811	
MLP_E4_A04_B06_N4		0,48118372	MLP_E6_A04_B06_N4	0,47933609	MLP_E12_A04_B06_N4		0,47342505	
	Média:	0,47977013		Média:	0,481383828		Média:	0,47996837
MLP_E4_A02_B08_N8		0,48505769	MLP_E6_A02_B08_N8	0,48023477	MLP_E12_A02_B08_N8		0,47928196	
MLP_E4_A02_B06_N8		0,47764616	MLP_E6_A02_B06_N8	0,47844601	MLP_E12_A02_B06_N8		0,47566493	
MLP_E4_A04_B08_N8		0,48211729	MLP_E6_A04_B08_N8	0,48140681	MLP_E12_A04_B08_N8		0,48104175	
MLP_E4_A04_B06_N8		0,47748838	MLP_E6_A04_B06_N8	0,47718335	MLP_E12_A04_B06_N8		0,48029332	
	Média:	0,48057738		Média:	0,479317735		Média:	0,47907049
MLP_E4_A02_B08_N12		0,48041273	MLP_E6_A02_B08_N12	0,47675905	MLP_E12_A02_B08_N12		0,48000926	
MLP_E4_A02_B06_N12		0,47919153	MLP_E6_A02_B06_N12	0,4730445	MLP_E12_A02_B06_N12		0,47724869	
MLP_E4_A04_B08_N12		0,47631863	MLP_E6_A04_B08_N12	0,48347949	MLP_E12_A04_B08_N12		0,48663021	
MLP_E4_A04_B06_N12		0,47859044	MLP_E6_A04_B06_N12	0,47922145	MLP_E12_A04_B06_N12		0,48046045	
	Média:	0,47862833		Média:	0,478126123		Média:	0,48108715
MLP_E4_A02_B08_N16		0,4814904	MLP_E6_A02_B08_N16	0,48351634	MLP_E12_A02_B08_N16		0,48634504	
MLP_E4_A02_B06_N16		0,4793536	MLP_E6_A02_B06_N16	0,47468567	MLP_E12_A02_B06_N16		0,4771983	
MLP_E4_A04_B08_N16		0,48758779	MLP_E6_A04_B08_N16	0,482324893	MLP_E12_A04_B08_N16		0,48116992	
MLP_E4_A04_B06_N16		0,47706741	MLP_E6_A04_B06_N16	0,47445184	MLP_E12_A04_B06_N16		0,47133587	
	Média:	0,4813748		Média:	0,478744686		Média:	0,47901228

Legenda: E Entradas
A Alpha
B Beta
N Neurônios

Exemplo: MLP_E4_A02_B08_N4 4 Entradas, Alpha = 0.2, Beta = 0.8 e 4 Neurônios na camada escondida

* Os resultados grifados em amarelo são as médias dos EMQs para cada conjunto de configurações com mesmo número de neurônios na camada escondida.
* Os resultados grifados em azul são as configurações que tiveram o melhor desempenho.

Estudo do EMQ para as 48 configurações utilizadas na MLP com os dados de radiação global horizontal.

[Fonte : elaboração própria]

Com a definição das três melhores configurações, pode ser feita a análise estatística dos dados. O primeiro teste realizado foi o de Shapiro-Wilk para verificar se as amostras podem ser consideradas normalmente distribuídas. A Tabela 4 apresenta o resultado obtido por esse teste.

Tabela 4. Teste Shapiro-Wilk para as configurações utilizadas na MLP com os dados de radiação

	<i>p-value</i>	<i>p-value < 0,05</i>
MLP_E4_A04_B08_N12	3,362E-08	Sim
MLP_E6_A02_B06_N12	1,586E-08	Sim
MLP_E12_A04_B06_N16	2,354E-08	Sim

De acordo com os resultados obtidos, as amostras não são normalmente distribuídas. Sendo assim a análise das amostras deve ser feita por um teste não paramétrico. Neste trabalho o teste utilizado foi o teste da Soma dos Postos de Wilcoxon. As hipóteses para este teste foram determinadas da seguinte forma:

- Hipótese nula: o desempenho das redes neurais com as duas configurações utilizadas são consideradas estatisticamente iguais;
- Hipótese alternativa: o desempenho da rede neural com a configuração à direita, denominada por Y, é melhor que a configuração à esquerda, denominada por X.

A Tabela 5 apresenta o resultado obtido por esse teste.

Tabela 5. Teste Wilcoxon para as configurações utilizadas na MLP com os dados de radiação

X	Y	<i>p-value</i>
MLP_E4_A04_B08_N12	MLP_E6_A02_B06_N12	1.542e-08
MLP_E4_A04_B08_N12	MLP_E12_A04_B06_N16	1.285e-07
MLP_E6_A02_B06_N12	MLP_E12_A04_B06_N16	4.242e-06

Como pode ser observado na Tabela 5, os valores dos *p-values* são inferiores ao nível de significância previamente determinado com o valor 0,05. A configuração que apresentou melhor desempenho foi a MLP_E6_A02_B06_N12, que tem 6 neurônios de entrada, taxa de aprendizagem $\alpha = 0,2$, momento $\beta = 0,2$ e 12 neurônios na camada escondida.

4.2 Resultados da Iluminância

4.2.1 Determinar a melhor configuração para a rede MLP

Para cada conjunto de 30 simulações na rede MLP, para uma mesma configuração, foi realizado o teste de Shapiro-Wilk. A Tabela 6 apresenta o *p-value* obtido para cada configuração utilizada.

Tabela 6. Teste Shapiro-Wilk para as configurações utilizadas na MLP com os dados de iluminância

	<i>p-value</i>	<i>p-value</i> < 0,05
MLP_02_06	0,1734	Sim
MLP_02_08	0,3078	Sim
MLP_04_06	0,4388	Sim
MLP_04_08	0,3078	Sim

Como pode ser observado na Tabela 6, as amostras não são normalmente distribuídas, pois todas apresentam o *p-value* menor que a taxa de significância previamente definida com o valor de 0,05.

Com esse resultado as amostras não podem ser analisadas por testes paramétricos, já visto que, para tanto, é necessário que as amostras sejam normalmente distribuídas e que possuam variâncias estatisticamente iguais. Para verificar se as amostras possuem variâncias estatisticamente iguais é realizado o teste F. A Tabela 7 apresenta o resultado obtido por este teste.

Tabela 7. Teste F para as configurações utilizadas na MLP com os dados de iluminância

		<i>p-value</i>	<i>p-value</i> < 0,05
MLP_02_06	MLP_02_08	0,003219	Sim
MLP_02_06	MLP_04_06	3,26E-06	Sim
MLP_02_06	MLP_04_08	2,17E-09	Sim
MLP_02_08	MLP_04_06	0,05535	Não
MLP_02_08	MLP_04_08	0,000482	Sim
MLP_04_06	MLP_04_08	0,09537	Não

Como pode ser observado na Tabela 7, apenas dois testes com as amostras apresentaram variâncias estatisticamente iguais. São as duas linhas que não possuem o *p-value* menor que a taxa de significância, previamente definida com o valor de 0,05.

Desta forma as amostras não serão analisadas pelo teste T de Student, sendo realizada a análise pelo teste da Soma dos Postos de Wilcoxon. As hipóteses para este teste foram determinadas da seguinte forma:

- Hipótese nula: o desempenho das redes neurais com as duas configurações utilizadas são consideradas estatisticamente iguais;
- Hipótese alternativa: o desempenho da rede neural com a configuração à direita, denominado por Y, é melhor que a configuração à esquerda, denominada por X.

A Tabela 8 apresenta o resultado obtido por esse teste.

Tabela 8. Teste Wilcoxon para as configurações utilizadas na MLP com os dados de iluminância

X	Y	<i>p-value</i>
MLP_02_06	MLP_02_08	0,000479
MLP_02_06	MLP_04_06	0,001356
MLP_02_06	MLP_04_08	4,253E-11
MLP_02_08	MLP_04_06	0,5165
MLP_02_08	MLP_04_08	2,03E-6
MLP_04_06	MLP_04_08	8,97E-10

Como pode ser observado na Tabela 8, a configuração que utiliza a taxa de aprendizado $\alpha = 0,4$ e o momento $\beta = 0,8$ apresentou o menor *p-value*. Sendo assim, é a que apresentou o melhor desempenho é definida como a melhor configuração para a MLP utilizando os dados de iluminância. O próximo passo é realizar a análise desta rede neural com a RBFN.

4.2.2 Comparação entre as redes neurais utilizadas

Para realizar a análise estatística das duas arquiteturas, são realizados os mesmos testes que foram feitos para analisar as diferentes configurações da rede MLP. Desta forma é realizado o teste Shapiro-Wilk com os valores das duas redes. O resultado deste teste está representado na Tabela 9.

Tabela 9. Teste Shapiro-Wilk para as redes neurais MLP e RBFN utilizando os dados de iluminância

	<i>p-value</i>	<i>p-value < 0,05</i>
MLP_04_08	0,003483	Sim
RBFN	0,2452	Sim

Como pode ser observado na Tabela 9, as amostras não são normalmente distribuídas, pois todas apresentam o *p-value* menor que a taxa de significância previamente definida com o valor de 0,05. Sendo assim, a análise das duas redes neurais foi realizada utilizando apenas o teste da Soma dos Postos de Wilcoxon. As hipóteses para este teste foram determinadas da seguinte forma:

- Hipótese nula: o desempenho das redes neurais com as arquiteturas MLP e RBFN são consideradas estatisticamente iguais;
- Hipótese alternativa: o desempenho da rede neural com a arquitetura RBFN é melhor do que com a arquitetura MLP.

A Tabela 10 apresenta o resultado obtido pelo teste Wilcoxon para as redes neurais utilizadas.

Tabela 10. Teste Wilcoxon para as redes neurais MLP e RBFN utilizando os dados de iluminância

		<i>p-value</i>
RBFN	MLP_04_08	<i>p-value < 2,2E-16</i>

O resultado, como pode ser visto na Tabela 10, apresenta um *p-value* muito menor do que o nível de significância. Desta forma, a Rede com Função Base Radial (RBFN) apresentou um melhor desempenho comparado a *Multi-Layer Perceptron* (MLP).

Capítulo 5

Conclusão e Trabalhos Futuros

5.1 Conclusões

A energia solar é uma fonte de energia renovável ainda pouco explorada, sendo necessário o desenvolvimento de projetos e pesquisas que auxiliem no crescimento do uso desse recurso natural. Essa fonte de energia pode ser diretamente transformada em energia elétrica através de painéis solares com células fotovoltaicas, assim como pode auxiliar na redução do consumo de energia elétrica, utilizando a iluminação natural como fonte de calor para aquecimento de água e ambientes.

Este trabalho de conclusão de curso teve como objetivo utilizar duas arquiteturas de redes neurais artificiais para prever a radiação global horizontal e a iluminância para 1 hora à frente, e comparar os resultados obtidos para determinar qual das arquiteturas obteve o melhor resultado. Tanto a radiação quanto a iluminância são variáveis que auxiliam no estudo e desenvolvimento de projetos que utilizam a energia solar como fonte de energia. Desta forma, este trabalho sugere o incentivo ao desenvolvimento de pesquisas que proporcionem conhecimentos necessários para a implantação desses projetos.

A base de dados utilizada foi obtida no projeto SONDA (Sistema de Organização Nacional de Dados Ambientais), e a estação de coleta dos dados escolhida está localizada na cidade de Petrolina, no estado de Pernambuco.

Os resultados obtidos pelas simulações das RNAs com os dados de radiação global horizontal apresentaram valores muito altos para os dados desnormalizados. Esse resultado sugere que, para que seja possível prever essa variável, é necessário o uso de outras variáveis em conjunto. Porém, para este trabalho foram utilizados os valores de radiação normalizados, os quais foram simulados apenas na

arquitetura *Multi-Layer Perceptron* (MLP). Foram utilizadas 48 configurações diferentes para a simulação dessa variável na MLP.

Através dos testes estatísticos, foi possível determinar que a configuração da MLP, para a variável de radiação que apresentou o melhor desempenho foi a MLP_E6_A02_B06_N12. Esta configuração tem 6 neurônios de entrada, taxa de aprendizagem $\alpha = 0,2$, momento $\beta = 0,2$ e 12 neurônios na camada escondida.

Para as simulações realizadas com os dados de iluminância, o resultado obtido se apresentou coerente para os valores desnormalizados e foi possível utilizar as duas arquiteturas previamente definidas. Foram utilizadas 4 configurações diferentes para as simulações dessa variável na MLP, que foram comparadas com o desempenho obtido pela Rede com Função Base Radial (RBFN).

A partir dos testes estatísticos foi, comprovado que a RBFN apresentou melhor desempenho que as 4 configurações escolhidas para a MLP.

5.2 Trabalhos Futuros

Como trabalhos futuros, pretende-se a realização de um estudo mais aprofundado da predição da radiação global horizontal, como a definição de quais variáveis auxiliam na previsão, estudo do uso de outras arquiteturas de redes neurais, e outras configurações para os parâmetros utilizados por esse trabalho. Desta forma será possível determinar quais fatores influenciam de forma positiva para a predição da radiação.

Bibliografia


- [1] ATLAS BRASILEIRO DE ENERGIA SOLAR. Disponível em: <http://sonda.ccst.inpe.br/publicacoes/atlas_solar.html> Acesso em: 11 de outubro de 2014.
- [2] ATLAS DE ENERGIA ELÉTRICA DO BRASIL – ANEEL. Disponível em: <www.aneel.gov.br/aplicacoes/atlas/pdf/03-Energia_Solar%283%29.pdf> Acesso em: 23 de novembro de 2014.
- [3] BRAGA, A. de P.; CARVALHO, A. P. de Leon Filho; LUDEMIR, T. Redes Neurais Artificiais: Teoria e Aplicações. Rio de Janeiro: LTC, 2000.
- [4] CARVALHO, André Ponce de Leon F.. Redes Neurais Artificiais. Disponível em: <www.icmc.usp.br/pessoas/andre/research/neural> Acesso em: 11 de outubro de 2014.
- [5] DA SILVA LEAL, SÉRGIO; TIBA, CHIGUERU. Medidas e modelagem da iluminância para diversas condições de céu no Nordeste do Brasil. 2006. Dissertação (Mestrado). Programa de Pós-Graduação em Tecnologias Energéticas e Nucleares, Universidade Federal de Pernambuco, Recife, 2006.
- [6] GALVANI, EMERSON; ESCOBEDO, JOÃO FRANCISCO; PEREIRA, ANDRÉ BELMONT. Balanço de radiação e fluxo de calor no solo em ambiente natural e protegido cultivado com pepineiro. Bragantina, Campinas, v.60, n. 2, 2001. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0006-87052001000200010&lng=en&nrm=iso> Acesso em: 11 de outubro de 2014.
- [7] GEIGER, R. Manual de microclimatologia: o clima da camada de ar junto ao solo. 3.ed. Lisboa: Fundação Calouste Gulbenkian, 1961. 556p.
- [8] HAYKIN, S. Redes Neurais: Princípios e Práticas. Bookman, 2007.
- [9] Jornal do Comércio. Governo de Pernambuco compra energia solar. Disponível em: <<http://jconline.ne10.uol.com.br/canal/economia/pernambuco/noticia/2014/09/09/governo-de-pernambuco-compra-energia-solar-144627.php>> Acesso em: 22 de setembro de 2014.

- [10] LAM, J. C. And LI, D. H., (1999) An analysis of daylighting and solar heat for cooling dominated office buildings, *Solar Energy*, Vol. 64, No. 4, pp. 251-262.
- [11] MONTEITH, J.L; UNSWORTH, M.H. *Principles of environmental physics*. 2.ed. London: Edward Arnald, 1990. 291p.
- [12] NEO SOLAR ENERGIA. Energia solar. Disponível em: <<http://www.neosolar.com.br/aprenda/saiba-mais/energia-solar>> Acesso em 11 de outubro de 2014.
- [13] REDE SONDA. Sobre o projeto SONDA. Disponível em: <http://sonda.ccst.inpe.br/infos/sobre_projeto.html> Acesso em: 11 de outubro de 2014.
- [14] SOUZA, Rodrigo C. T. de. *Previsão de Séries Temporais Utilizando Rede Neural Treinada por Filtro de Kalman e Evolução Diferencial*. 2008. Dissertação de Mestrado (Mestrado em Engenharia de Produção e Sistemas) – Pontifícia Universidade Católica do Paraná – PUCPR, Curitiba, 2008
- [15] VALENÇA SILVA, J. M. *Fundamentos das Redes Neurais*. [S.I.]: Livro Rapido, 2011.
- [16] WERBOS J., P. *Beyond Regression: New tools for prediction and analysis in behavioral sciences*. Tese (Doutorado) Havard University, 1974.

Apêndice A

Estudo da Quantidade de Neurônios na Camada Escondida e Topologias MLP Para Dados de Iluminância


Para a MLP_02_08 o resultado para o teste da quantidade de neurônios na camada escondida apresentou o seguinte resultado:



Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,2$ e $\beta = 0,8$.

[Fonte : elaboração própria]


Como pode ser observado, a quantidade de neurônios que apresentou o melhor desempenho foi 6. Portanto, a topologia para esta configuração da MLP, para valores de iluminância, foi a representada pela Figura 14.



Topologia para a configuração da MLP com $\alpha = 0,2$ e $\beta = 0,8$.

[Fonte : *MatLab*]


Para a MLP_04_06 o resultado para o teste da quantidade de neurônios na camada escondida apresentou o seguinte resultado:



Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,4$ e $\beta = 0,6$.

[Fonte : elaboração própria]

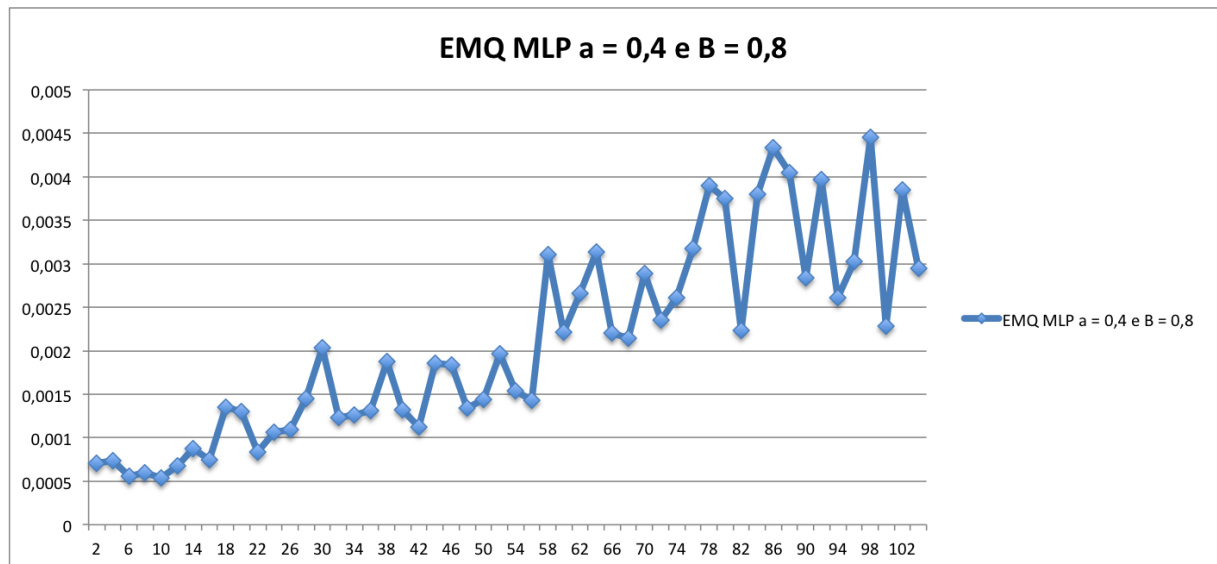
Como pode ser observado, a quantidade de neurônios que apresentou o melhor desempenho foi 4. Portanto a topologia para esta configuração da MLP, para valores de iluminância, foi a respresentada pela Figura 16.



Topologia para a configuração da MLP com $\alpha = 0,4$ e $\beta = 0,6$.

[Fonte : *MatLab*]


Para a MLP_04_08 o resultado para o teste da quantidade de neurônios na camada escondida apresentou o seguinte resultado:



Estudo do EMQ por número de neurônios na camada escondida para $\alpha = 0,4$ e $\beta = 0,8$.

[Fonte : elaboração própria]

Como pode ser observado, a quantidade de neurônios que apresentou o melhor desempenho foi 10. Portanto, a topologia para esta configuração da MLP, para valores de iluminação, foi a representada pela Figura 18.



Topologia para a configuração da MLP com $\alpha = 0,4$ e $\beta = 0,8$.

[Fonte : *MatLab*]