

**UNIVERSIDADE ESTADUAL DE PONTA GROSSA
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO APLICADA**

RODRIGO VIECHENESKI

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NO TRATAMENTO DE DADOS
AGROMETEOROLÓGICOS VISANDO A CORREÇÃO DE SÉRIES TEMPORAIS**

**PONTA GROSSA
2012**

RODRIGO VIECHENESKI

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NO TRATAMENTO DE DADOS
AGROMETEOROLÓGICOS VISANDO A CORREÇÃO DE SÉRIES TEMPORAIS**

Dissertação apresentada para obtenção
do título de Mestre na Universidade Esta-
dual de Ponta Grossa, Área de Computa-
ção Aplicada.

Orientador: Prof. Dr. Ivo Mário Mathias

**PONTA GROSSA
2012**

Ficha Catalográfica Elaborada pelo Setor Tratamento da Informação Bicen/UEPG

V634a Viecheneski, Rodrigo
Aplicação de redes neurais artificiais no tratamento de dados agrometeorológicos visando a correção de séries temporais / Rodrigo Viecheneski. Ponta Grossa, 2012.
85 f.

Dissertação (Mestrado em Computação Aplicada - área de concentração Computação Aplicada a Agricultura), Universidade Estadual de Ponta Grossa. Orientador: Prof. Dr. Ivo Mário Mathias.

1. Sistema computacional. 2. Perceptron de múltiplas camadas. 3. Variáveis agrometeorológicas. 4. Backpropagation. I. Mathias, Ivo Mário. II. Universidade Estadual de Ponta Grossa. Mestrado em Computação Aplicada. III. T.

CDD: 006.32

RODRIGO VIECHENESKI

**APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NO TRATAMENTO DE DADOS
AGROMETEOROLÓGICOS VISANDO A CORREÇÃO DE SÉRIES TEMPORAIS**

Dissertação apresentada para obtenção do título de Mestre na Universidade Estadual de Ponta Grossa, Área de Computação Aplicada.

Ponta Grossa (PR), 24 de setembro de 2012.

Prof. Dr. Ivo Mário Mathias – Orientador
Doutor em Agronomia
Universidade Estadual de Ponta Grossa

Prof. Dr. Roberto H. Herai
Doutor em Genética e Biologia Molecular
Universidade da Califórnia San Diego, USA

Prof. Dr. Ariangelo Hauer Dias
Doutor em Agronomia
Universidade Estadual de Ponta Grossa

Dedico este trabalho a minha querida esposa Juliana Pinto Viecheneski

AGRADECIMENTOS

Agradeço primeiramente a Deus, que sempre está em todas as coisas que faço.

Aos meus pais Divonir e Eunice pelo imenso carinho e pelo verdadeiro amor dedicado ao meu crescimento, educação e formação como homem.

Ao meu orientador Ivo Mário Mathias por sua compreensão e pela sua impecável orientação a este trabalho.

Ao meu amigo Luiz Antônio Zanlorensi, obrigado pelo companheirismo e colaboração no desenvolvimento desta dissertação, por compartilhar seus conhecimentos que foram de grande valor para o meu trabalho.

Agradeço à Fundação ABC, na pessoa do Engenheiro Agrônomo Rodrigo Yoti Tsukahara, que forneceu a base de dados utilizada neste trabalho e contribuiu com orientações técnicas muito importantes.

Aos meus amigos e colegas do Mestrado em Computação Aplicada, obrigado pela força e incentivo durante este tempo de convívio.

Agradeço ao Prof. Dr. Roberto H. Herai e ao Prof. Dr. Ariangelo Hauer Dias pelas valiosas sugestões que contribuíram para o aprimoramento deste trabalho.

À Capes, pelo auxílio financeiro durante o Mestrado.

RESUMO

Esta dissertação apresenta o desenvolvimento de um sistema computacional denominado Sistema para Tratamento de Séries Temporais Agrometeorológicas (STST Agrometeorológicas), com o objetivo de tratar dados agrometeorológicos visando a correção de séries temporais. Para o desenvolvimento dos estudos foram utilizados dados de estações agrometeorológicas disponibilizados pela Fundação ABC, situada no estado do Paraná, nas cidades de Ponta Grossa (long -49.95025733, lat -25.30156819) e Castro (long -49.8672, lat -24.6752). O sistema computacional proposto fez uso da tecnologia de Redes Neurais Artificiais do tipo Perceptron de Múltiplas Camadas e do algoritmo *backpropagation* de treinamento de retropropagação do erro. E foi desenvolvido com a linguagem de programação Object Pascal, utilizando o ambiente de desenvolvimento integrado Embarcadero Delphi 2009. Para validar o método proposto, foram realizados seis estudos de caso, dentre os quais, o que apresentou o melhor resultado para variável agrometeorológica temperatura média foi o estudo de caso 1 da estação agrometeorológica de Castro, com um percentual de acerto entre os registros tratados e os registros sem falha de 96,5%, um coeficiente de correlação de Pearson de 0,98 e uma média simples entre os erros obtidos nos treinamentos da rede neural de 0,026406. A média dos erros das redes neurais foi calculada entre os valores dos erros obtidos em cada treinamento, durante a correção de um determinado período de falha. Para variável agrometeorológica umidade relativa do ar, o melhor resultado encontrado foi o estudo de caso 5 da estação agrometeorológica de Castro, com um percentual de acerto de 95,7%, um coeficiente de correlação de Pearson de 0,97 e a média simples dos erros da rede neural de 0,094298. Diante desse contexto, foi possível perceber que o STST Agrometeorológicas é uma alternativa viável no tratamento das variáveis agrometeorológicas temperatura média e umidade relativa do ar, uma vez que, houve resultados com percentual de acerto superior a 95% no tratamento de falhas das séries temporais estudadas.

Palavras-chave: Sistema Computacional. Perceptron de múltiplas camadas. Variáveis Agrometeorológicas. *Backpropagation*.

ABSTRACT

This dissertation presents the development of a computational system called System for Treatment of Agrometeorological weather Series (STST Agrometeorológicas), with the objective of treating agrometeorological data in order to correct time weather. For the development of the study some data were collected from the agrometeorological stations, provided by Fundação ABC. The stations were located in the state of Paraná, in the cities of Ponta Grossa (long - 49.95025733, lat - 25.30156819) and Castro (long -49.8672, lat -24.6752). The computational system that has been suggested made use of the technology of Artificial Neural Networks on the type of Multilayer Perceptron and the backpropagation training algorithm of backpropagation error. It was developed with the Object Pascal programming language, using the integrated development environment Embarcadero Delphi 2009. To validate the proposed method we conducted six case studies, and the one which presented the best result for agrometeorological variable average temperature was the first case study of Castro's weather station, with a hit percentage between the treated registers and the registers without failure of 96.5%, a Pearson correlation coefficient of 0.98 and a simple average of the errors obtained from the training the neural network of 0.026406. The average errors of the neural networks was calculated between the values of errors obtained in each training during a period of correction failure. For the agrometeorological variable relative humidity, the best result was found in the case study 5 of Castro's weather station, with a hit percentage of 95.7%, a Pearson correlation coefficient of 0.97 and the simple average of the errors obtained from the training the neural network of 0,094298. Given this context, it was revealed that the STST Agrometeorological is a viable alternative in the treatment of meteorological variables such as temperature and relative humidity, since there were results with hit percentage greater than 95% in the treatments of fails of the weather series studied.

Keywords: Computational System. Multilayer Perceptron. Agrometeorological Variables. Backpropagation.

LISTA DE FIGURAS

Figura 1 - Esquema do neurônio biológico	22
Figura 2 - Modelo matemático do neurônio biológico de McCulloch & Pitts (1943) . .	23
Figura 3 - Modelo de neurônio base para projetos de RNA.	23
Figura 4 - Gráfico função sigmoide.....	26
Figura 5 - RNA representada na forma de grafo	26
Figura 6 - Arquitetura de uma rede neural recorrente	28
Figura 7 - Graus de envolvimento do supervisor	30
Figura 8 - Separabilidade linear.....	32
Figura 9 - Fluxo de treinamento de uma MLP com <i>backpropagation</i>	34
Figura 10 - Gráfico erro global x peso	36
Figura 11 - Estação climatológica	37
Figura 12 - Datalogger	39
Figura 13 - Esquema de transmissão de dados de EA	40
Figura 14 - ST com horizontes de previsão.....	40
Figura 15 - Janela de previsão e horizonte igual a um	44
Figura 16 - Fragmento com dados de treinamento	48
Figura 17 - ST com vales e picos irregulares	48
Figura 18 - ST de duas estações agrometeorológicas	49
Figura 19 - Diagrama de Caso de Uso - STST Agrometeorológicas	51
Figura 20 - Diagrama de Sequência do - STST Agrometeorológicas.....	51
Figura 21 - Etapas do desenvolvimento da RNA.....	51
Figura 22 - Metodologia de treinamento da RNA aplicada a ST.....	55
Figura 23 - Resultados obtidos no tratamento dos registros	56
Figura 24 - Média de Erro da Rede.....	58
Figura 25 - Resultados obtidos pela RNA no tratamento de ST	59

Figura 26 - ST tratada e ST sem falhas	59
Figura 27 - Estudo de Caso 1 - Temperatura, Castro.....	60
Figura 28 - Estudo de Caso 1 - Temperatura, Ponta Grossa	61
Figura 29 - Estudo de Caso 2 - Temperatura, Castro.....	62
Figura 30 - Estudo de Caso 2 - Temperatura, Ponta Grossa	62
Figura 31 - Estudo de Caso 3 - Temperatura, Castro.....	64
Figura 32 - Estudo de Caso 3 - Temperatura, Ponta Grossa	64
Figura 33 - Estudo de Caso 4 - Temperatura, Castro.....	65
Figura 34 - Estudo de Caso 4 - Temperatura, Ponta Grossa	66
Figura 35 - Estudo de Caso 5 - Umidade relativa, Castro.....	67
Figura 36 - Estudo de Caso 5 - Umidade relativa, Ponta Grossa	67
Figura 37 - Estudo de Caso 6 - Umidade relativa, Castro.....	68
Figura 38 - Estudo de Caso 6 - Umidade relativa, Ponta Grossa	69
Figura 39 - Tela de apresentação do Sistema Computacional	81
Figura 40 - Tela principal do sistema.....	81
Figura 41 - Menu principal do sistema	82
Figura 42 - Informações encontradas na opção Sobre do menu principal.....	83
Figura 43 - Configuração dos parâmetros da RNA	84
Figura 44 - Tela Carregar ST sem falha.....	84
Figura 45 - Gráfico do erro do treinamento da RNA	85
Figura 46 - Gráfico comparando ST tratada com ST sem falha	85

LISTA DE TABELAS

Tabela 1 - Composição parcial da base de dados de TMéd	47
Tabela 2 - Composição parcial da base de dados de UR.....	47
Tabela 3 - Fragmento base de dados com falhas	49
Tabela 4 - Resultado: Estudo de Caso 1	61
Tabela 5 - Resultado: Estudo de Caso 2	63
Tabela 6 - Resultado: Estudo de Caso 3	64
Tabela 7 - Resultado: Estudo de Caso 4	66
Tabela 8 - Resultado: Estudo de Caso 5	68
Tabela 9 - Resultado: Estudo de Caso 6	69
Tabela 10 - Parâmetros da RNA para cada ST tratada.....	73

LISTA DE SIGLAS

<i>Adalaine</i>	<i>Adaptive Linear Element</i>
AM	Aprendizado de Máquina
BP	<i>Backpropagation</i>
CMCD	Centro de Missão de Coleta de Dados
CPTEC	Centro de Previsões do Tempo e Estudos Climáticos
CSV	<i>Comma Separed Value</i>
DARPA	<i>Defense Advanced Research Projects Agency</i>
EA	Estações Agrometeorológicas
IA	Inteligência Artificial
IAPAR	Instituto Agrônômico do Paraná
IDE	<i>Integrated Development Environment</i>
MLP	<i>Multi Layer Perceptron</i>
PCD	Plataforma de Coleta de Dados
PG	Ponta Grossa
PIB	Produto Interno Bruto
RNA	Rede Neural Artificial
SGBD	Sistema Gerenciador de Banco de Dados
ST	Séries Temporais
STST	Sistema para Tratamento de Séries Temporais
TM	Temperatura Média
TMG	Tempo Médio de Greenwich
TMLP	<i>Training Multilayer Perceptron</i>
UR	Umidade Relativa do ar

SUMÁRIO

1	INTRODUÇÃO	14
1.1	OBJETIVO GERAL	16
1.2	OBJETIVOS ESPECÍFICOS	17
1.3	ESTRUTURA DO TRABALHO	17
2	REVISÃO BIBLIOGRÁFICA	18
2.1	INTELIGÊNCIA ARTIFICIAL	18
2.2	REDES NEURAIS ARTIFICIAIS	21
2.2.1	Neurônio artificial e a RNA	21
2.2.2	Modelo de um neurônio	23
2.2.3	Tipos de funções de ativação	25
2.2.4	Arquitetura de RNAs	27
2.2.5	Processo de aprendizagem	28
2.2.6	Modelos de aprendizagem	31
2.2.7	Perceptron de camada única	32
2.2.8	Algoritmo de retropropagação de erro (<i>backpropagation</i>)	33
2.3	ESTAÇÕES AGROMETEOROLÓGICAS	37
2.4	SÉRIES TEMPORAIS	40
3	MATERIAIS E MÉTODOS	46
3.1	BASES DE DADOS	46
3.2	METODOLOGIA COMPUTACIONAL	50
3.3	DESENVOLVIMENTO DO MODELO COM RNA	52
3.3.1	Definição do problema	52
3.3.2	Coleta de dados	52
3.3.3	Pré-processamento dos dados	52
3.3.4	Projeto da RNA	53

3.3.5 Treinamento da RNA	54
3.3.6 Teste e Validação da RNA	56
3.3.7 Pós- Processamento	58
4 RESULTADOS E DISCUSSÕES	60
4.1 RESULTADOS	60
4.1.1 Estudo de caso 1	60
4.1.2 Estudo de caso 2	61
4.1.3 Estudo de caso 3	63
4.1.4 Estudo de caso 4	65
4.1.5 Estudo de caso 5	66
4.1.6 Estudo de caso 6	68
4.2 DISCUSSÕES	70
5 CONCLUSÕES E TRABALHOS FUTUROS	74
REFERÊNCIAS	75
APÊNDICE - O sistema computacional	81

1 INTRODUÇÃO

Novas maneiras de pensar e conviver inserem-se no mundo das telecomunicações e da informática. O homem e sua inteligência são reféns das constantes mudanças de dispositivos informacionais de todos os tipos, como por exemplo, computadores, notebooks, celulares (LÉVY, 1993).

A evolução da tecnologia da informação tem sido responsável por transformações organizacionais em geral, e, em particular, no desenvolvimento de aplicações computacionais destinadas às mais diversas áreas profissionais. Nesse contexto, insere-se o cenário agrícola, a informática tem fundamental importância em todas as fases do processo produtivo e organizacional (MATHIAS, 2006).

Uma das áreas da computação que traz contribuições ao contexto agrícola é a Inteligência Artificial (IA). Os estudos acerca dela tiveram seu início logo após o fim da segunda guerra mundial, mais precisamente em 1956, abrangendo várias áreas como: aprendizado e percepção, demonstração de teoremas matemáticos, criação de poesias e diagnósticos de doenças, entre outros. A IA busca sistematizar e automatizar atividades intelectuais que, por sua vez, são potencialmente utilizáveis no desenvolvimento de qualquer atividade intelectual humana (RUSSEL; NORVIG, 2004).

Uma das áreas da IA é representada pelo aprendizado de máquina (AM), que tem por objetivo desenvolver técnicas computacionais de aprendizado construindo sistemas capazes de adquirir automaticamente conhecimento, por meio de programas de computador que com o aprendizado, são capazes de tomar decisões, baseando-se em experiências acumuladas na solução bem sucedida de problemas anteriores (REZENDE, 2005).

Por sua vez, o AM caracteriza-se por diferentes algoritmos que procuram potencializar o resultado da aplicação desses algoritmos, levando em consideração o tipo de problemática a ser resolvida. As Redes Neurais Artificiais (RNAs) fazem parte desses algoritmos, e podem ser definidas como modelos matemáticos dotados de capacidade computacional de aprendizado e generalização assemelhando-se com a estrutura neural biológica (BRAGA; CARVALHO; LUDIMIR; 2000).

A Rede Neural Artificial é uma tecnologia originada a partir de disciplinas como a Neurociência, Matemática, Estatística, Física, Ciência da Computação e Engenharia. As aplicações das RNAs ocorrem nos mais variados campos, destacando-

se a modelagem, análise de séries temporais, reconhecimento de padrões e processamento de sinais e controle (HAYKIN, 2001).

Quando as RNAs são utilizadas em séries temporais (ST), que são definidas como um conjunto aleatório de observações ordenadas no tempo (MENDENHALL, 1993; MORETTIN; TOLOI, 1985; SOUZA, 1989), seu uso pode ser realizado para fazer previsões futuras, descobrir tendências e corrigir falhas. As séries temporais estão presentes em categorias, tais como fenômenos relacionados à Biologia, Física, Meteorologia, Agricultura, dentre outros (MORETTIN; TOLOI, 1985; SOUZA, 1989).

Na área agrícola, as ST são obtidas por Estações Agrometeorológicas (EA), posicionadas em locais estratégicos, geralmente em áreas agrícolas. As EAs possuem instrumentos específicos para cada variável climática monitorada, e o horário adotado para realização das observações agrometeorológicas depende das imposições da pesquisa a ser conduzida (VAREJÃO-SILVA 2006). As leituras realizadas pelas EAs são enviadas para um equipamento chamado *datalogger*, que controla um sistema de aquisição para comunicação e processamento de dados (BÍSCARO, 2007). A coleta dos dados pode ocorrer de diversas formas: por processo manual de coleta dos dados a campo e também pela comunicação através de Internet banda larga, modem telefônico, internet sem fio (rádio, satélite), que permitem a transmissão dos dados agrometeorológicos em tempo real, para uma unidade centralizadora (servidor), (IAPAR, 2012).

Uma ST agrometeorológica isenta de falhas é importante para o estudo e gestão dos processos que conduzem à produção agrícola. A construção de ST agrometeorológicas, fenológicas, do solo e informações agronômicas é, inevitavelmente, prioridade para pesquisas e programas operacionais agrícolas (RAYMOND, 2010). As ST com falhas diárias, mensais e anuais, geralmente inviabilizam a utilização dessas séries. As falhas nas ST ocorrem geralmente pela ausência do observador, falhas nos mecanismos de registro, perda das anotações ou das transcrições dos registros pelos operadores e encerramento das transcrições dos registros pelos operadores. Entretanto, como existe a necessidade de se trabalhar com séries contínuas, essas falhas necessitam ser preenchidas (STRECK *et al.*, 2009; OLIVEIRA *et al.*, 2010).

Segundo Chibana *et al.* (2005), vários métodos podem ser utilizados para preencher falhas em ST agrometeorológicas, como a utilização de médias de dados

observados ou dados sintéticos obtidos por sistemas geradores de dados. Para Oliveira *et al.* (2010), os métodos mais utilizados são: ponderação regional, regressão linear, regressão potencial, regressão múltipla, ponderação regional com base em regressões lineares e vetor regional.

De acordo com Filho, Leite e Cataneo (2005), a tendência experimental integrada ao avanço tecnológico, ocorrida em muitos países, contribuiu para que os pesquisadores passassem a implementar ferramentas computacionais, voltadas para o gerenciamento e simulação de dados climáticos.

A literatura apresenta alguns trabalhos que utilizam simuladores com técnicas de RNA na predição de ST climática. Dentre eles destacam-se o trabalho de Dias *et al.* (2007), que utiliza redes neurais com topologia *Multilayer Perceptron* (MLP) na simulação da radiação solar, e Tampelini (2008), que utiliza redes neurais na predição de séries temporais, na vazão fluvial, a fim de facilitar a modelagem da relação Chuva-Vazão.

Também são encontrados trabalhos que utilizam métodos matemáticos para corrigir ST com falhas como é o caso de Chibana *et al.* (2005), que implementam um aplicativo para importar, armazenar e avaliar métodos de preenchimento de falhas em dados meteorológicos e comparam seu aplicativo com os aplicativos WGEN (Richardson; Wright, 1984) e SIMMETEO (Geng *et al.*, 1999), em que as metodologias utilizadas para correção da ST foram a média normal, média histórica, média simétrica e ST de outras estações. Oliveira *et al.* (2010) propuseram em seu trabalho comparar as metodologias de preenchimento de falhas de ST disponíveis na literatura. Dentre elas estão a ponderação regional, regressão linear, regressão potencial, regressão múltipla, ponderação regional com base em regressões lineares e vetor regional. Outros trabalhos como de Streck *et al.*, (2009) e Buriol *et al.*, (2006), também utilizaram métodos matemáticos como por exemplo, a regressão linear, em seus estudos para corrigir falhas em ST.

1.1 OBJETIVO GERAL

Desenvolver um sistema computacional utilizando técnicas de RNAs para correção de séries temporais agrometeorológicas com falhas em um determinado período de tempo.

1.2 OBJETIVOS ESPECÍFICOS

- Verificar a eficiência das RNAs na correção de ST de variáveis agrometeorológicas;
- Tratar os dados com falhas nas variáveis agrometeorológicas, temperatura média e umidade relativa do ar.

1.3 ESTRUTURA DO TRABALHO

O presente trabalho foi estruturado da seguinte forma: O primeiro capítulo apresenta uma breve contextualização do tema, o problema de pesquisa e seus objetivos. O segundo capítulo traz um panorama sobre inteligência artificial, redes neurais artificiais, estações agrometeorológicas e séries temporais.

No capítulo três delinea-se o caminho metodológico percorrido e o detalhamento das etapas do trabalho. O quarto capítulo apresenta os resultados e discussões e, por fim, o capítulo cinco traz as conclusões e o apontamento de proposições para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

Este capítulo trata dos pressupostos teóricos que darão subsídios à realização da pesquisa, a saber: inteligência artificial, redes neurais artificiais, estações agrometeorológicas e séries temporais.

2.1 INTELIGÊNCIA ARTIFICIAL

Desenvolver tecnologias que capacitem construir inteligência sintética é um dos mais cobiçados desafios de cientistas e profissionais da área tecnológica. Nessa intenção, logo após a segunda guerra mundial mais precisamente em 1956 originou-se o paradigma de IA, “um cruzamento” das cognições da neurociência e da informática, com o objetivo de compreender o pensamento e o comportamento humano para reproduzi-los artificialmente (PESSIS-PASTERNAK, 1993; RUSSEL; NORVIG, 2004).

De acordo com Russel e Norvig (2004), e Cawsey (1998), existem várias definições sobre IA, Coppin (2010) afirma que devido à complexidade do problema a ser resolvido, é difícil encontrar uma definição que consiga abranger a completude da IA.

Para Turban *et al.* (2002), as definições de IA estão relacionadas a duas ideias básicas. A primeira envolve o processo de pensamento humano, enquanto a segunda procura representar esse processo por meio de uma máquina. Turban *et al.* (2002), define IA como, “aquele comportamento de máquina que, se desempenhado por um ser humano, seria classificado de inteligente”. Trata-se de comportamento inteligente, quando apresenta as seguintes características:

- Aprender ou compreender algo pela experiência;
- Compreender o significado de mensagens ambíguas ou contraditórias;
- Reagir rapidamente e com êxito a uma nova situação;
- Usar o raciocínio para solucionar problemas e direcionar as ações de forma eficiente;
- Resolver situações complexas;
- Compreender e fazer deduções de uma forma racional e comum;

- Utilizar conhecimento para manipular o ambiente;
- Reconhecer a importância relativa de diferentes elementos em uma situação.

Alan Turing, em 1950, apresentou o teste de Turing que propunha desenvolver uma definição operacional satisfatória de inteligência por meio de um teste no qual um computador pode ser considerado inteligente apenas se um interlocutor humano, ao conversar com outro ser humano e com um computador, sem visualizá-los, não notar se as respostas estão sendo fornecidas pelo ser humano ou pelo computador (RUSSEL; NORVIG, 2004).

Segundo Russel e Norvig (2004), para que um programa de computador tenha a capacidade para passar no teste de Turing, são necessárias as seguintes habilidades que juntas compõem a disciplina de IA em quase sua totalidade:

- Processamento de linguagem natural: permitindo a comunicação com o idioma natural;
- Representação de conhecimento: armazena o que sabe e ouve;
- Raciocínio automatizado: utiliza as informações armazenadas para responder e tirar novas conclusões;
- Aprendizado de máquina: adaptação a novas situações, detectar e extrapolar padrões;
- Visão de computador: perceber objetos;
- Robótica: manipulação de objetos e movimentação.

De acordo com Coppin (2010), a IA é fragmentada em duas partes por seus seguidores: a IA forte, estabelece que possuindo um computador com capacidade de processamento e fornecendo a ele suficiente inteligência, ele poderá pensar e ser consciente da mesma forma que um ser humano, e a IA fraca defende que uma visão de comportamento inteligente pode ser modelada e utilizada em um computador para resolver problemas complexos. Esse segundo ponto de vista defende que mesmo que o computador haja inteligentemente, isso não prova que ele seja verdadeiramente inteligente.

Turban *et al.* (2002), fazendo um comparativo entre a IA e a inteligência natural humana, perceberam que a IA apresenta inúmeras vantagens comerciais importantes, mas possui limitações. Dentre os principais benefícios encontram-se:

- Melhorar a velocidade e a consistência em procedimentos de resolução de problemas que sejam difíceis de serem solucionados, quando utilizada a computação convencional;
- Auxiliar na resolução de problemas referentes a dados incompletos ou imprecisos;
- Gerenciar excesso de informação, resumindo, interpretando, auxiliando pesquisas com grandes volumes de dados;
- Melhorar consideravelmente a produtividade no desempenho de inúmeras tarefas;
- Tornar amigável o uso de diversos aplicativos computacionais.

Fazendo um comparativo entre a computação convencional e a utilizada na IA, pode-se definir que a computação convencional é baseada em algoritmos (fórmulas matemáticas ou procedimentos que levam a uma solução). Esses algoritmos são convertidos em programas de computador que, quando executados, fazem uso de dados como números, letras ou palavras, em ordem definida, para resolver problemas. Já um software de IA é baseado no processamento simbólico do conhecimento, onde um símbolo pode ser uma letra, palavra ou um número, representando um objeto, um processo e suas relações (TURBAN *et al.*, 2002).

Apesar da IA possuir duas linguagens de programação específicas que apresentam características que as tornam adequadas no desenvolvimento de projetos: as linguagens PROLOG e LISP (RABUSKE, 1995; COPPIN, 2010), as mais comuns para desenvolver sistemas de IA são C++ e Java por se tratarem de linguagens mais conhecidas dos cientistas da computação (COPPIN, 2010).

As tecnologias que compõem a IA são encontradas em aplicações como: sistemas especialistas, processamento de linguagem natural, reconhecimento de padrões, robótica, bases de dados inteligentes, provas de teoremas, jogos entre outros (RABUSKE, 1995).

Segundo Rezende (2005), a construção de aplicações que solucionem problemas de aproximação, predição, classificação, categorização e aproximação estão relacionadas a uma ramificação da IA, as Redes Neurais Artificiais, que serão abordadas na próxima seção.

2.2 REDES NEURAIS ARTIFICIAIS

Como o cérebro humano tem a capacidade de processar informações, essa característica motivou pesquisadores a desenvolver modelos computacionais que reproduzam o comportamento desse órgão (aprender, errar, produzir conhecimento) (MORETO, 2005).

Silva (2001) afirma que a habilidade das RNAs em resolver problemas complexos e variados as tornam interessantes e com grande aplicabilidade nas diversas áreas científicas e comerciais.

Autores como, Tampelini, (2008); Moreto, (2005); Silva, (2006); Rosa; Luz, (2009) fazem uso em seus trabalhos da definição de Haykin (2001, p.28), para expressar as principais características do que é uma RNA:

Um processador maciçamente paralelo distribuído constituído de unidades de processamento simples que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

A habilidade de aprender a partir de seu ambiente e com isso melhorar seu desempenho é a propriedade mais importante das RNAs. Isso ocorre através do processo de aprendizagem, que é um processo iterativo de ajustes, aplicado a seus pesos sinápticos, o algoritmo de treinamento. Esse aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe do problema (MATHIAS, 2006).

2.2.1 Neurônio artificial e a RNA

Apoiado em Shepherd e Koch (1990), Haykin (2001) afirma que há aproximadamente 10 bilhões de neurônios no córtex humano e 60 trilhões de conexões sinápticas. A ideia é que a RNA simule o comportamento do neurônio biológico (suas interconexões e funcionalidades).

Partindo de conceitos biológicos, fundamentados em Santiago Ramón e Cajal (1911), foi introduzida a ideia de neurônios como estrutura básica do cérebro (Figura 1), cujo funcionamento pode ser resumido do seguinte modo:

- Os dendritos recebem sinais de entrada oriundos de outras células;
- O corpo celular e os dendritos integram e processam estes sinais;
- A informação é transmitida ao longo do axônio para outros neurônios por meio das sinapses, que são ligações entre os dendritos de neurônios diferentes.

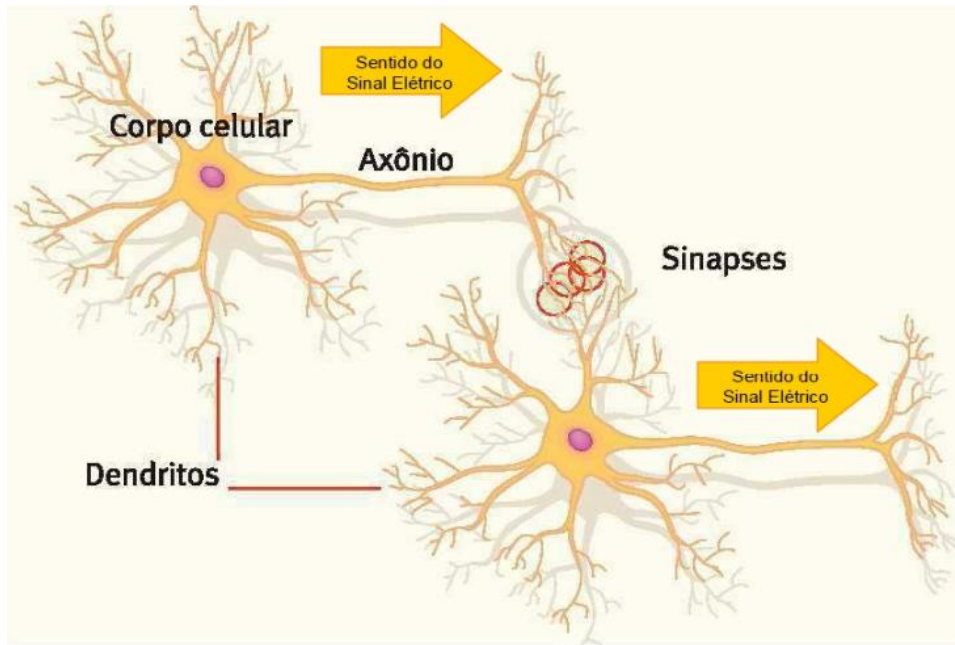


Figura 1 - Esquema do neurônio biológico

Em 1943, o psiquiatra e neurofisiologista McCulloch e o matemático Pitts apresentaram matematicamente o funcionamento de um neurônio biológico. O modelo de McCulloch & Pitts, Figura 2, onde i determina a quantidade de entradas (dendritos) X_1, X_2, \dots, X_i e a saída (axônio) é definida por Y . A entrada de cada neurônio possui um peso W_1, W_2, \dots, W_i e seus valores podem ser positivos ou negativos (sinapse). Os pesos W_i armazenam o conhecimento e definem a intensidade da contribuição de cada entrada no resultado do neurônio. A soma dos valores do produto das entradas com seus respectivos pesos emula o corpo celular, $X_i W_i$, e, se a soma for maior ou igual ao seu limiar (*threshold*) a sua saída, Y , é ativada com valor 1. Matematicamente a ativação do neurônio se dá quando:

$$\sum_{i=1}^m X_i W_i \geq \theta \quad (1)$$

O símbolo m são as entradas do neurônio, W_i é o peso associado à entrada X_i e θ é o limiar do neurônio.




Figura 2 - Modelo matemático do neurônio biológico de McCulloch & Pitts (1943).
Fonte: Braga *et al.* (2000).

Variações do modelo proposto por McCulloch & Pitts foram desenvolvidas ao longo dos anos, sendo que a função de ativação (função que determina o estado de ativação da saída do neurônio) e o Bias (inserção de um neurônio ou entrada especial), foram as contribuições mais significativas, pois melhoraram a adaptação da RNA pelo conhecimento a ela fornecido. Essa adaptação pode ser considerada um ajuste fino da rede.

2.2.2 Modelo de um neurônio

Haykin (2001), identifica três elementos básicos de um modelo neuronal (Figura 3).

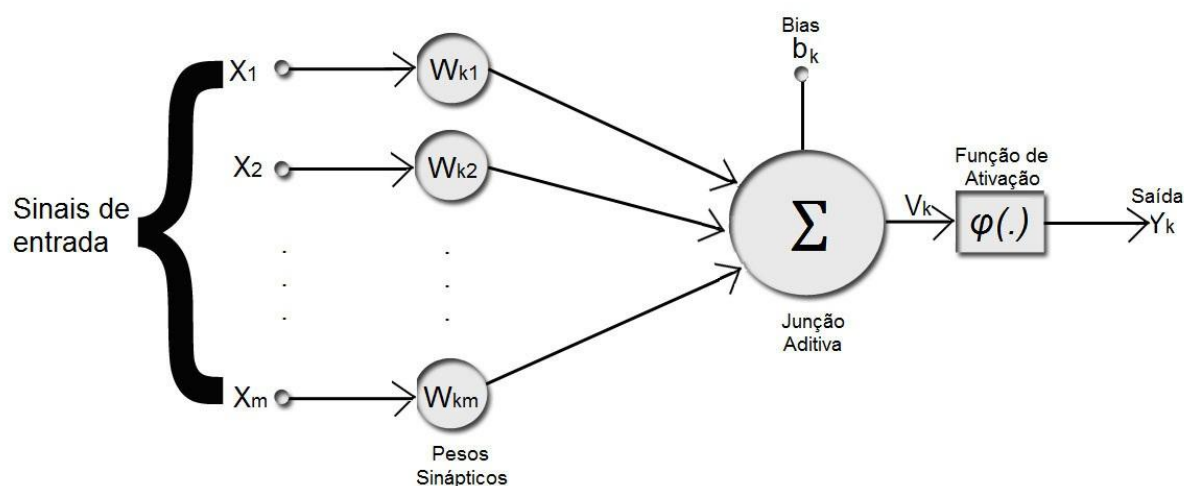


Figura 3 - Modelo de neurônio base para projetos de RNA.
Fonte: Haykin (2001).

1. *Sinapses* ou *elos de conexão* - cada uma constituída por peso ou força própria, onde um sinal X_j na entrada da sinapse j conectada ao neurônio k é multiplicada pelo peso sináptico W_{kj} .

2. *Somador (Junção aditiva)* - soma os sinais de entrada, ponderados pelas sinapses do neurônio, formando um combinador linear através de suas operações.
3. *Função de ativação* - restringe a amplitude da saída Y_k de um neurônio, por limitar o intervalo permissível de amplitude do sinal de saída a um valor finito, também é chamada função restritiva. O intervalo normalizado da amplitude da saída de um neurônio geralmente possui intervalo unitário fechado $[0, 1]$ ou $[-1, 1]$.

O modelo de Haykin também é constituído de um bias que apresenta o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se o bias for positivo ou negativo.

Ao comparar-se o modelo de McCulloch & Pitts com o modelo de Haykin, os neurônios possuem similaridade nas entradas da rede, nos pesos sinápticos, e no somador dos valores do produto de suas entradas com respectivos pesos. Haykin afirma que o diferencial está na função de ativação que permite apenas a ativação da saída do neurônio com valor 1, ou a não ativação com valor 0, e também na falta de um bias.

A equação do neurônio k é descrita:

$$u_k = \sum_{j=1}^m W_{kj} X_j \quad (2)$$

$$y_k = \varphi(u_k + b_k) \quad (3)$$

onde X_1, X_2, \dots, X_m são os sinais de entrada; $W_{k1}, W_{k2}, \dots, W_{km}$ são os pesos sinápticos do neurônio k , u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o bias; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal da saída do neurônio. O uso do bias b_k tem o efeito de aplicar uma transformação compatível com a saída u_k do combinador linear, demonstrado na equação 4 e 5.

$$v_k = u_k + b_k \quad (4)$$

$$Y_k = \varphi(v_k) \quad (5)$$

2.2.3 Tipos de funções de ativação

A função de ativação definida por $\Phi(\mathbf{v})$ representa a saída de um neurônio pela indução local de “ v ”. Haykin (2001) identifica três tipos básicos de funções de ativação.

A primeira é a função limiar que, segundo a literatura de engenharia, é chamada de função de Heaviside. É a função utilizada no modelo de McCulloch & Pitts (1943), definida como um modelo pioneiro em que a saída de um neurônio assume o valor 1, se o campo local induzido daquele neurônio é não-negativo, e 0 referindo-se ao oposto. Essa função descreve a propriedade tudo-ou-nada do modelo de McCulloch & Pitts.

A função linear por partes assume que o fator de amplificação dentro da região linear da operação é a unidade. Sendo a segunda das três funções, esta pode ser vista como uma aproximação de um amplificador não-linear, e é representada por duas formas especiais da função linear por partes. Inicialmente, com o surgimento de um combinador linear, caso a região linear da operação seja mantida sem entrar em saturação e também quando a função linear por partes for reduzida à função de limiar, o fator de amplificação da região linear é feito infinitamente grande.

Finalmente, a função sigmoide que constrói um gráfico na forma de S (Figura 4), e é a função de ativação mais comum quando trata-se de projetos de redes neurais artificiais, conceitua-se como uma função estritamente crescente que apresenta um balanceamento adequado entre comportamento linear e não-linear, sendo ainda estritamente crescente. Um exemplo de função sigmoide é a função logística, demonstrada na equação 5.

$$\varphi(v) = \frac{1}{1 + \exp(-av)} \quad (6)$$

Onde, a representa o parâmetro de inclinação da função sigmoide. Com a variação de a , diferentes inclinações são observadas nessa função.




Figura 4 - Gráfico função sigmoide

As RNAs podem ser representadas através de grafos direcionados, já que uma rede neural é uma estrutura de processamento de informações distribuídas paralelamente. Um grafo $D=(V,E)$ denomina-se direcionado ou dirigido (dígrafo) se ele é constituído de um conjunto finito não vazio V (os vértices) e um conjunto E (as arestas orientadas) de pares ordenados de vértices. Portanto, em um dígrafo cada aresta (v,w) possui uma única direção de v para w (Szwarcfiter, 1986). Em tal representação, os neurônios são definidos como os nós do grafo e as arestas ou conexões são as sinapses, às quais são atribuídos os pesos. Estruturalmente as redes neurais são representadas pelas camadas de entrada, uma ou mais camadas ocultas (intermediárias) e a camada de saída, que estão ilustradas na Figura 5 (MATHIAS, 2006).




Figura 5 - RNA representada na forma de grafo

2.2.4 Arquitetura de RNAs

Uma rede neural é formada por um conjunto de neurônios interligados, cuja forma na qual esses neurônios são conectados, define qual é o tipo de arquitetura da rede, levando em consideração o número de camadas de neurônios e o tipo de conexão entre elas. Haykin (2001) define três classes de arquitetura de RNA.

A rede alimentada adiante (*feedforward*) ou acíclica (com camada única) representa a arquitetura mais simples de RNA, onde os neurônios são organizados em uma única camada e a saída de cada neurônio é uma saída da rede. O termo “alimentada adiante” ou “*feedforward*” ou ainda “acíclica” se dá pela camada de nós fonte (camada de entrada), fornecer os sinais de entrada para a camada de saída, e não vice-versa, o que impossibilita laços de realimentação. Já a camada única refere-se ao fato de apresentar apenas uma camada de nós, ou seja, não possui camadas ocultas.

As redes alimentadas diretamente (*feedforward*) ou acíclica (com múltiplas camadas), distinguem-se da arquitetura acíclica com camada única por apresentar uma ou mais camadas de nós entre a camada de entrada e a camada de saída. Essa camada é intitulada camada oculta ou camada intermediária e tem em seu conteúdo neurônios ocultos.

Segundo Nascimento e Yoneyama (2004), a RNA do tipo *feedforward* independente de ter ou não camadas ocultas, implementa um mapeamento estático do seu espaço de entrada para o seu espaço de saída.

Os nós da camada de entrada fornecem os elementos do padrão de ativação (vetor de entrada) formando os sinais de entrada aplicados aos neurônios na segunda camada (primeira camada oculta). Os sinais de saída da segunda camada são utilizados como entradas para terceira camada (segunda camada oculta) e assim por diante até o resto da RNA. Os conjuntos de sinais de saída dos neurônios da camada de saída formam a resposta global da RNA para o padrão de ativação fornecido pelos nós da camada de entrada (primeira camada) (HAYKIN, 2004).

A arquitetura intitulada rede recorrente ou *feedback* difere da arquitetura de rede neural alimentada adiante, por apresentar ao menos um laço de realimentação. A Figura 6 representa essa arquitetura que contém um neurônio oculto (NO) e dois neurônios de saída.

Para Nascimento e Yoneyama (2004), o tipo de rede *feedback* geralmente é um sistema dinâmico não linear. Nesse último caso, a estabilidade da rede torna-se um tópico importante.

Uma aplicação típica de RNA tipo *feedback* é como uma memória endereçada por conteúdo, onde a informação que deve ser gravada, corresponde a pontos estáveis de equilíbrio estável da rede (NASCIMENTO; YONEYAMA, 2004).




Figura 6 - Arquitetura de uma rede neural recorrente
Fonte: Haykin (2001).

2.2.5 Processo de aprendizagem

Guimarães (2005) afirma que sob a ótica da computação, o objetivo do aprendizado de máquina é tentar fazer com que os programas de computador aprendam, a partir dos dados estudados. O aprendizado ocorre quando se obtém decisões distintas com base nas características dos dados referidos, fazendo uso da estatística em conceitos fundamentais e da IA, na adição de heurísticas avançadas em seus algoritmos com a finalidade de alcançar seus objetivos.

Haykin (2001, p.75), define aprendizagem como:

Um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre.

Essa definição implica na seguinte sequência de eventos:

1. A rede neural é estimulada por um ambiente;
2. A rede neural sofre modificações nos seus parâmetros livres como resultado dessa estimulação;
3. A rede neural responde de maneira nova ao ambiente, devido às modificações ocorridas na sua estrutura interna.

A habilidade em aprender, baseando-se em um ambiente, é a propriedade mais importante das redes neurais e tem como objetivo melhorar seu desempenho. Isso ocorre por meio de um processo iterativo de ajustes aplicados aos pesos sinápticos da rede (treinamento). Esse aprendizado se dá quando a rede neural atinge uma solução generalizada para uma determinada classe do problema. O treinamento ocorre levando em consideração regras definidas pelo modelo de redes neurais como, por exemplo, o ajuste dos pesos de suas conexões sinápticas por meio de padrões apresentados, ou seja, a rede aprende por meio de exemplos provenientes de casos reais conhecidos (MORETO, 2005).

Segundo Osório e Bittencourt (2000), os métodos de aprendizado neural podem ser divididos em três grandes classes, segundo o grau de controle dado ao usuário:

- Aprendizado supervisionado - o usuário domina um comportamento de referência preciso, que ele deseja ensinar para rede. Com isso a rede deve ter a capacidade de medir a diferença entre seu comportamento atual e seu comportamento de referência, visando a correção dos pesos e conseqüentemente reduzindo o erro (desvio de comportamento em relação aos exemplos de referência).
- Aprendizado semi-supervisionado - o usuário não tem um domínio preciso (sucesso ou insucesso da rede) sobre o comportamento final desejado.
- Aprendizado não-supervisionado - as modificações dos pesos da rede acontecem em função de critérios internos, tais como, a repetição de padrões de ativação em paralelo a vários neurônios. As características desse tipo de aprendizado são comparadas com técnicas de análise de dados aplicadas na estatística (*clustering*).

Para Nascimento e Yoneyama (2004), os métodos de aprendizado podem ser classificados de acordo com a intensidade de participação do supervisor no pro-

cesso de aprendizado. Quando a intensidade é muito forte, o supervisor fornece diretamente para a RNA os valores dos pesos (pesos fixos), como é o caso, da rede de Hopfield.

Quando a intensidade da supervisão é forte, fornece-se um conjunto de treinamento para RNA, ou seja, um conjunto de entradas e suas respectivas saídas desejadas. A ideia é que a RNA imite o supervisor ajustando seus pesos de forma a produzir para cada entrada do conjunto de treinamento, a saída desejada pelo supervisor. É o caso da RNA tipo *feedforward* treinada com algoritmo de correção de erro, como o *Backpropagation* que para cada entrada do conjunto de treinamento a saída produzida pela RNA é comparada com a saída fornecida pelo supervisor e os pesos são alterados de forma a diminuir a diferença.

Em um nível de supervisão menor, denominada supervisão fraca, o supervisor é apenas um crítico que fornece uma avaliação superficial da saída da RNA (certo ou errado, sucesso ou fracasso, erro grande ou erro pequeno) ao invés de fornecer a saída desejada. São exemplos desse nível os algoritmos de aprendizado por reforço (*reinforcement learning*) ou de punição e recompensa (*reward punishment*).

Na supervisão com menor grau, a supervisão muito fraca (aprendizado não supervisionado), o algoritmo de RNA tenta descobrir categorias dos dados de entrada, e o supervisor apenas fornece os rótulos para o agrupamento. Mesmo assim, o supervisor tem uma pequena participação no processo de aprendizado. A RNA de Kohonen é um exemplo.

Na Figura 7 encontram-se os graus de envolvimento do supervisor nas diferentes formas de treinamento de RNAs.

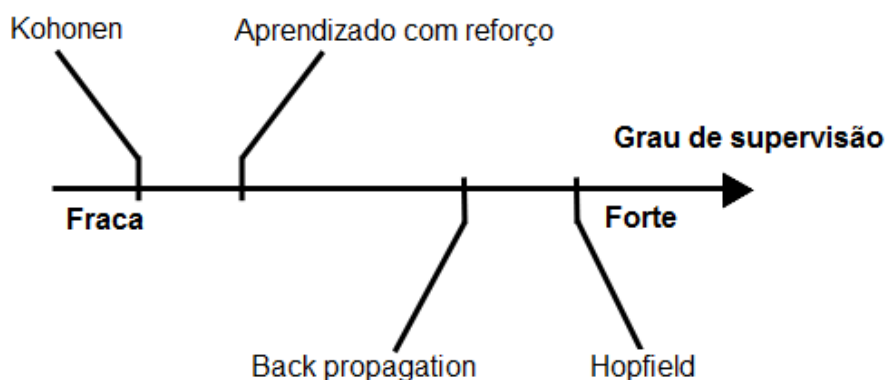


Figura 7 - Graus de envolvimento do supervisor
Fonte: Nascimento e Yoneyama (2004)

Mathias (2006), apoiado em Rohn e Mine (2003) afirma que o aprendizado não requer um conhecimento detalhado sobre as relações das variáveis envolvidas no sistema, porém a quantidade de dados históricos deve ser considerável, visto que o objetivo é conseguir extrair satisfatoriamente as características relevantes existentes no conjunto de dados. Treinando a rede corretamente, além de ela ser capaz de aproximar qualquer função, ela também generaliza, fazendo com que se obtenham saídas corretas para entradas não apresentadas anteriormente.

Segundo Mathias (2006), a generalização é a capacidade de um modelo em aprender corretamente os exemplos que lhe são apresentados, sem que esses estejam presentes na base de aprendizado. Um modelo com boa generalização é aquele que responde corretamente aos exemplos contidos na base de aprendizado, e também a outros exemplos diferentes daqueles da base de aprendizado que estão inseridos na base de teste. As tarefas que envolvem aprendizado têm como característica principal a capacidade de generalizar. Entretanto, no seu processo de generalização, uma rede neural pode apresentar um problema de aprendizado chamado super aprendizado (*over-training / over-fitting*), quando o número de camadas ou quantidade de neurônios for muito grande. Por outro lado, a rede pode não generalizar se o número de camadas e a quantidade de neurônios for muito pequena ocasionando um problema chamado sub ajuste (*under-fitting*).

2.2.6 Modelos de aprendizagem

Um modelo de aprendizagem é um conjunto predeterminado de normas definidas que resolvem problemas de aprendizagem. São vários os modelos de aprendizagem utilizados em projetos de RNA. Esses modelos apresentam diferenças, tanto, no método em que é construído o ajuste dos pesos sinápticos de um neurônio, como também na forma pela qual uma RNA é constituída, por um conjunto de neurônios interconectados que interagem com o seu meio ambiente (HAYKIN, 2001). Os modelos mais utilizados de acordo com Ribeiro (2003) e Ozorio & Bittencourt (2000) são:

- Aprendizagem por Correção de Erro - o vetor de entrada e a saída esperada estimulam a rede, a regra de ajuste detecta o erro subtraindo a resposta desejada com a resposta da rede, por meio do cálculo do gradiente descendente da função do erro.

- Aprendizagem Baseada em Memória - utiliza uma arquitetura de RNA com alimentação de uma única camada e aprendizado supervisionado. Grande parte das amostras de treino é armazenada na memória de exemplos de entrada-saída. Esse modelo de aprendizagem é utilizado no caso do vizinho mais próximo, cujo funcionamento se dá com a rede fazendo uma classificação de acordo com a distância euclidiana entre os pesos dos vetores de treino.
- Aprendizagem competitiva - nesse modelo o neurônio vencedor é aquele que tiver maior valor discriminante, quando na camada de saída da rede, após receber as características dos objetos na camada de entrada, os neurônios competem entre si.

2.2.7 Perceptron de camada única

Tomando por base o modelo do neurônio artificial de McCulloch & Pitts de 1943, Frank Rosenblatt propôs em 1958, o perceptron como o primeiro modelo para aprendizagem supervisionada (HAYKIN, 2001). Esse modelo é um combinador linear seguido por um limitador abrupto fazendo com que o neurônio produza uma saída igual a +1 se o campo local induzido for positivo, e -1 se este for negativo (MORETO, 2005).

Segundo Haykin (2001), o perceptron só funciona adequadamente se as duas classes C_1 e C_2 estiverem linearmente separadas (Figura 8). Isso significa que a superfície de decisão necessita de um hiperplano e os padrões classificados necessitam estar separados entre esse hiperplano para que o modelo seja eficiente.

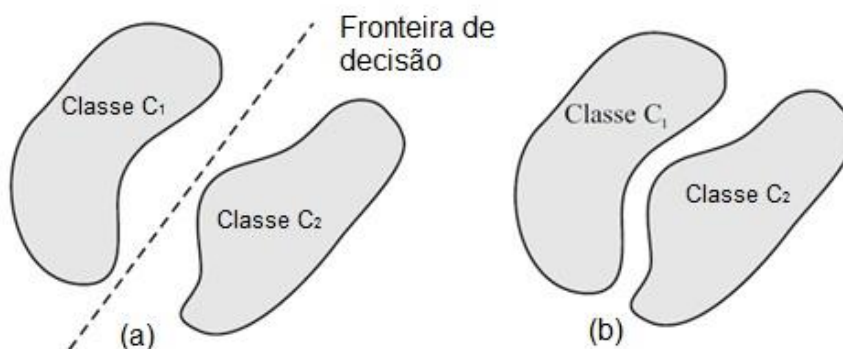


Figura 8 - Separabilidade linear
Fonte: Haykin (2001)

Com o desenvolvimento do perceptron de múltiplas camadas, resolveu-se o problema da limitação do perceptron de uma camada, de apenas classificar padrões linearmente separáveis. O *Multilayer Perceptron* (MLP) tem, em sua estrutura, uma ou mais camadas intermediárias (camadas ocultas) de neurônios entre a camada de entrada e a camada de saída. Com isso o MLP tornou-se capaz de resolver problemas complexos e não-linearmente separáveis. Um exemplo de problema que o MLP resolve é a função lógica XOR ou (ou exclusivo), que o perceptron de única camada não tem capacidade para resolver (MORETO, 2005).

O MLP tem sido utilizado com sucesso na resolução de problemas complexos com o treinamento supervisionado por meio do algoritmo *backpropagation* (HAYKIN, 2001). Em Medeiros (2001), a utilização de RNAs com o *backpropagation* ocorre no reconhecimento de padrões, reconhecimento de caracteres, processamento de sinais e previsões. Trabalhos utilizando treinamento do MLP com o algoritmo de treinamento *backpropagation* (BP) são encontrados em Mathias (2006), Dias *et al.* (2007), Tampelini (2008), Moreto (2005), Rosa (2009) e Silva (2006).

2.2.8 Algoritmo de retropropagação de erro (*backpropagation*)

O algoritmo *backpropagation* surgiu em meados da década de 1980 para resolver problemas com grau elevado de complexidade, que necessitassem de treinamento de RNAs com múltiplas camadas. O termo *backpropagation* origina-se do fato que o algoritmo se baseia na retropropagação dos erros para realizar os ajustes de pesos das camadas intermediárias. A maneira de calcular as derivadas parciais do erro de saída em relação a cada um dos pesos da rede é que caracteriza o *backpropagation* (REZENDE, 2005).

Mathias (2006) apoiado em Haykin (2001), Medeiros (2006), Paula (2000), Pessoa e Freire (1998) e Ribeiro (2003) descreve as principais características do algoritmo de aprendizagem BP no treinamento de redes MLP.

O método de aprendizado BP aplica-se a qualquer RNA que utilize uma função de ativação diferencial e aprendizado supervisionado. A regra delta minimiza a soma dos quadrados dos erros da saída, considerando sua média sobre o conjunto de treinamento, usando uma busca baseada na otimização do gradiente descendente, que ajusta os pesos para reproduzir o erro da rede minimizado (NASCIMENTO; YONEYAMA, 2004).

No treinamento, os sinais de entrada são apresentados à RNA e propagados a diante na rede, camada após camada, até chegar a camada de saída. O sinal de entrada produzido até a chegada, na camada de saída é comparado com uma saída desejada, o que determina o valor do erro da RNA. O erro da RNA é então utilizado na realimentação para as conexões, ocorrendo o ajuste dos pesos sinápticos de cada camada da RNA em um sentido oposto à propagação dos sinais de treinamento (MATHIAS, 2006).

No algoritmo BP, os pesos das camadas ocultas são ajustados levando em consideração suas camadas subsequentes, fazendo com que os erros calculados na camada de saída sejam utilizados para ajustar os pesos entre a última camada oculta e a camada de saída. Desse modo, o erro calculado de uma camada oculta ajustará os pesos da camada oculta anterior. Esse processo se repete até que a primeira camada oculta seja ajustada, retropropagando os erros por todas as camadas até obter a correção (processo repetitivo).

O BP apresenta duas fases durante o treinamento, cada uma percorre um sentido da rede. A fase chamada propagação (*forward*), define a saída da rede, em relação a um padrão de dados de entrada. A retropropagação (*backward*) utiliza a saída esperada e a saída fornecida pela última camada da rede para ajustar os pesos sinápticos da RNA. Na Figura 9, demonstra-se um esquema da direção destes dois fluxos básicos de sinais em uma rede MLP.

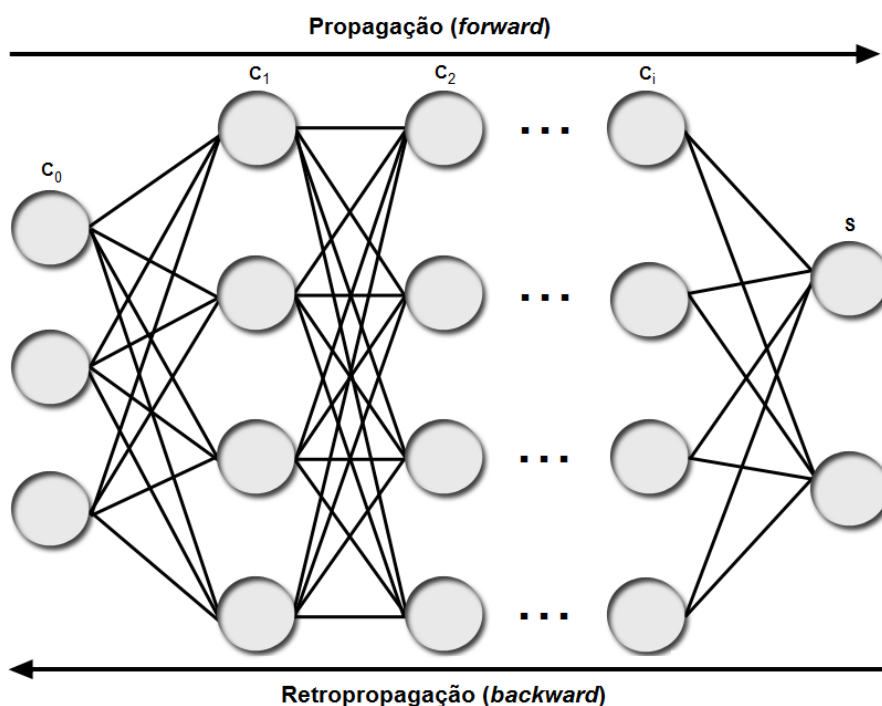


Figura 9 - Fluxo de treinamento de uma MLP com *backpropagation*

Segundo Braga, Ludemir e Carvalho (2000), a fase *forward* envolve os seguintes passos:

1. A entrada é apresentada à primeira camada da rede, a camada C_0 .
2. Para cada camada C_i a partir da camada de entrada
 - 2.1 Após os nós da camada C_i ($i > 0$) calcular seus sinais de saída, estes servem como entrada para a definição das saídas produzidas pelos nós da camada C_{i+1} .
3. As saídas produzidas pelos nós da última camada são comparadas às saídas desejadas.

A fase *backward* envolve as etapas a seguir:

1. A partir da última camada, até chegar a camada de entrada:
 - 1.1 Os nós da camada atual ajustam seus pesos de forma a reduzir seus erros.
 - 1.2 O erro de um nó das camadas intermediárias é calculado utilizando os erros retropropagados dos neurônios que pertencem às camadas seguinte conectado a ele, ponderados pelos pesos das conexões entre eles.

O algoritmo BP pode ser representado pelos seguintes passos:

Inicializa os pesos e parâmetros;

repita

para cada padrão de treinamento X **faça**

Define a saída da rede por meio da fase *forward*;

Compara as saídas produzidas com as saídas pré-definidas;

Atualiza os pesos dos nós por meio da fase *backward*;

fim para

até o erro ser mínimo **ou** a realização de um dado número de ciclos

Os pesos sinápticos no algoritmo BP podem ser atualizados levando em consideração parâmetros com variância entre 0 (zero) e 1 (um), chamados de taxa de aprendizagem, que determina quanto o valor atual da sinapse será alterado na próxima época. Quanto menor for esse parâmetro, menores serão as variações dos

pesos sinápticos da RNA, de uma iteração para outra, e mais suave será a trajetória no espaço de pesos (HAYKIN, 2001).

Podem-se também atualizar os pesos não utilizando uma taxa fixa, mas variável. O algoritmo pode ser orientado para que, quanto mais próximo estiver do valor ideal do peso, menor a taxa de aprendizagem. Como opcional, atualizam-se os pesos com uma parcela proporcional à atualização anterior, chamada momento ou inércia (MEDEIROS, 2006).

O algoritmo BP é baseado no gradiente descendente (*descending gradient*) que diminui o erro da rede baseando-se no erro existente entre o resultado ideal ou desejado e o resultado obtido. O algoritmo calcula a direção do menor erro no espaço de pesos para fazer a relação do erro existente e os pesos, mas não atualiza de uma vez, e sim, em pequenas diferenças (positivas ou negativas). Essas diferenças são retropropagadas na rede, atualizando para cada par de amostra o resultado apresentado. Utilizando o conjunto de treinamento por várias épocas de treinamento, a tendência é que o erro diminua gradativamente. Se o erro diminui, a obtenção de dados próximos aos desejados é a consequência e a rede fica apta a executar o processo para o qual foi projetada (MEDEIROS, 2006).

Medeiros (2006) demonstra graficamente como acontece o processo de convergência dos pesos para um valor de mínimo erro. Na Figura 10, o eixo vertical representa o erro global E (diferença média quadrática entre as saídas desejadas e saídas calculadas). O eixo horizontal representa os valores em que um peso W pode assumir, obtendo como resultado, a curva referente ao erro apresentado, em consonância com o valor do peso.




Figura 10 - Gráfico erro global x peso
Fonte: Medeiros (2006)

O processo da descida de gradiente direciona o valor do peso em direção ao erro mínimo e, assim, o algoritmo executa passo a passo a atualização do valor do peso até aonde o erro minimiza (E_{mim}). Na ilustração, a convergência do valor do peso é representada como W_{inicial} para chegar próximo a W_{final} , as setas ao lado da curva representam a direção do gradiente, dando o sentido do erro mínimo global.

Nas próximas seções deste capítulo, serão abordados temas relacionados à área agrônômica, utilizadas nesta dissertação.

2.3 ESTAÇÕES AGROMETEOROLÓGICAS

Para que uma estação agrometeorológica ou climatológica (Figura 11) tenha capacidade de observar com maior exatidão os fenômenos meteorológicos, obter as características do estado instantâneo da atmosfera ou classificar o clima de uma região é necessário que estas estações apresentem localização adequada, com área gramada, equipamentos padronizados e corretamente calibrados. Também é importante que as informações sejam obtidas utilizando padrões rígidos de horários de observações e no tratamento das informações coletadas (BÍSCARO, 2007).



Figura 11 - Estação climatológica
Fonte: Biscaro (2007)

Segundo Bísvaro (2007), além das estações climatológicas, existem outros tipos de estações como:

- Estações agrometeorológicas que são utilizadas para fins agrícolas, fazendo relação entre informações meteorológicas e as atividades agrícolas;
- Estações meteorológicas aeronáuticas, utilizadas em aeroportos para fornecer informações necessárias à segurança de voos;
- Estações sinópticas utilizadas para a atividade de previsão do tempo. Usam o horário padrão Tempo Médio de Greenwich (TMG). Todas as observações são realizadas simultaneamente, independentes de sua localização e, quando juntas em um mapa, formam a carta sinóptica;
- Estações diferenciadas são aquelas que apresentam características específicas, como as estações ozonométricas, micrometeorológicas, actinométricas, estação de radar, dentre outras.

Bísvaro (2007) apoiado no Instituto Agrônomo do Paraná (IAPAR) afirma que as primeiras estações meteorológicas do Paraná foram instaladas no início do século XX pelo Instituto Nacional de Meteorologia, ligado ao Ministério da Agricultura. A primeira rede agrometeorológica estadual foi projetada em 1959, pelo convênio entre os governos de São Paulo e do Paraná. A partir da década de 70, foram instaladas 22 estações meteorológicas. Em 1975, a IAPAR assumiu a rede agrometeorológica estadual. Nos anos 80, a IAPAR já contava com 33 estações com o objetivo de cobrir todas as variações de latitude e relevo do estado.

De acordo com Bísvaro (2007), os principais instrumentos utilizados em estações meteorológicas são:

- Psicrômetro - utilizado para medir as variações da umidade;
- Geotermômetro - mede a temperatura do solo;
- Geotermógrafo - mede e registra a temperatura do solo;
- Pluviômetro - mede a quantidade de chuva;
- Pluviógrafo - mede e registra a quantidade de chuva;
- Anemômetro - mede a direção e força do vento;
- Anemógrafo universal - mede e registra a direção e força dos ventos;
- Barômetro - mede as variações da pressão da atmosfera;

- Barógrafo - mede e registra as variações da pressão atmosférica;
- Evaporímetro - mede a evaporação;
- Evapotranspirômetro - mede a evapotranspiração;
- Actinógrafo - mede os raios luminosos;
- Heliógrafo - mede as horas de brilho solar e sem nuvens.

As estações meteorológicas automáticas diferem das estações convencionais por possuírem sistemas automatizados de monitoramento dotados de sensores que captam por meio do *datalogger* (Figura 12), todo o sistema de aquisição, comunicação e processamento dos dados coletados.



Figura 12 - Datalogger
Fonte: Biscaro (2007)

Para transmitir as informações armazenadas pelo *datalogger* (Figura 13), tem-se a Plataforma de Coleta de Dados (PCD), um sistema automatizado de monitoramento, dotado de sensores que utilizam energia elétrica ou solar. As PCD estão conectadas diretamente a computadores por meio de cabeamento de rede ou a satélites coletores de informações, que recebem os dados coletados e armazenados pelo *datalogger*. Segundo o Centro de Previsão do Tempo e Estudos Climáticos (CPTEC, 2012), o sistema de coleta de dados é constituído por um conjunto de satélites e por diversas plataformas de coletas de dados espalhadas pelo território nacional. A função do satélite é ser um retransmissor de mensagens, fazendo a comunicação entre uma PCD e as estações de recepção. Posteriormente, esses dados são enviados para o Centro de Missão de Coleta de Dados (CMCD), onde são processados, armazenados e divulgados.

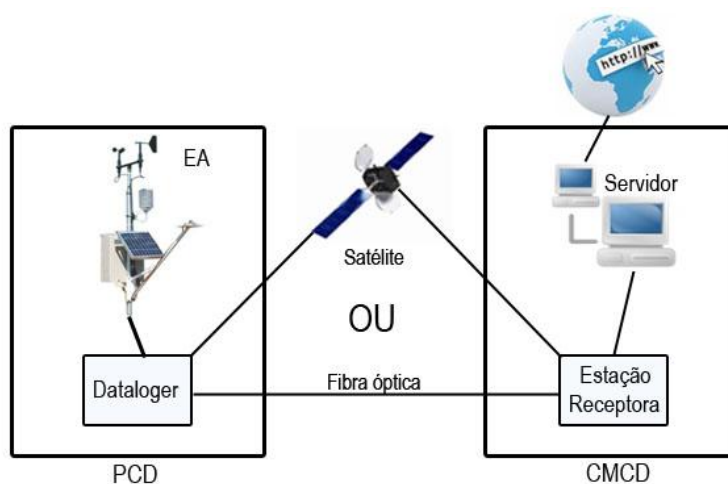


Figura 13 - Esquema de transmissão de dados de EA

2.4 SÉRIES TEMPORAIS

Pode-se afirmar que uma série temporal é um conjunto aleatório de observações ordenadas no tempo (MENDENHALL, 1993), (MORETTIN; TOLOI, 1985), (SOUZA, 1989). As ST estão presentes em categorias, dentre elas fenômenos relacionados à biologia, física, meteorologia. (MORETTIN; TOLOI, 1985), (SOUZA, 1989). Matematicamente uma ST pode ser expressa por:

$$Z_t = \{Z_t \in \mathcal{R} \mid t = 1, 2, 3 \dots N\} \quad (7)$$

Onde t é um índice temporal, e N o número de observações. Supondo que existam observações de uma ST até o instante t , e se queira prever o valor da série no instante $t+h$, denota-se por $\hat{Z}(h)$, onde a origem é t e o alvo a ser previsto é o h . A previsão $\hat{Z}(t+1), \hat{Z}(t+2), \hat{Z}(t+3), \dots, \hat{Z}(t+h)$ está representada na Figura 14.




Figura 14 - ST com horizontes de previsão
Fonte: Morettin; Tolo (2006)

Uma característica importante das ST é que as observações vizinhas são, em geral, dependentes. Portanto, um modo simples de se estudar o comportamento dessas séries é a partir da análise e da modelagem dessas dependências (EHLERS, 2007).

Segundo Souza (2008), o estudo de ST requer o uso de técnicas específicas. Algumas características são próprias das ST, como:

- Observações correlacionadas são mais difíceis de analisar e requerem técnicas específicas;
- A ordem temporal das observações deve ser considerada;
- Fatores complicadores, tais como a presença de tendências e a variação sazonal ou cíclica podem ser difíceis de estimar ou remover;
- A seleção de modelos pode ser complicada, e as ferramentas podem ser de difícil interpretação;
- É difícil lidar com observações perdidas e com dados discrepantes devido à sua natureza sequencial.

Uma série temporal é dita contínua quando as observações são realizadas continuamente no tempo, ou discretas quando as observações são realizadas em tempos específicos, geralmente equiespaçados. As ST discretas podem surgir de várias formas como, por exemplo, quando séries contínuas são “discretizadas”, isto é, seus valores são registrados em certos intervalos de tempo. Também podem surgir com séries de valores agregados ou acumulados em intervalos de tempo, como por exemplo, exportações medidas mensalmente ou a quantidade de chuva medida diariamente, e finalmente, algumas séries são inerentemente discretas, por exemplo, os dividendos pagos por uma empresa aos seus acionistas em anos sucessivos (SOUZA, 2008).

Mendenhall (1993) define em sua abordagem de componentes não observáveis que as séries temporais se dão pela junção de quatro componentes: tendência, cíclica, sazonal e erro.

A tendência produz mudanças graduais a longo prazo, elas são normalmente provocadas, como por exemplo, o crescimento constante da população, o Produto Interno Bruto (PIB), ou fatores que conduzem a falhas ao tentar gerar mudanças repentinas, produzindo alterações com gradatividade e regularidade ao longo do tempo.

A componente cíclica apresenta oscilação suave e repetitiva na série. Geralmente os efeitos cíclicos em uma série temporal ocorrem pela mudança na demanda do produto e em particular, pela inabilidade de suprir as necessidades do consumidor.

A sazonalidade de uma série temporal são oscilações que ocorrem em um determinado período do ano, mês, semana ou dia. A diferença entre a componente sazonal e a componente cíclica se dá pela sazonalidade apresentar movimentos facilmente previsíveis. Já a componente cíclica apresenta-se irregular, geralmente faz parte de períodos com muitos anos.

Por fim, o componente de erro, produz movimentos ascendentes e descendentes na série temporal, de modo geral após o efeito de uma componente de tendência cíclica ou sazonal. Esse componente de erro aparece como flutuações de períodos curtos, com deslocamento inexplicável e muitas vezes são causadas por oscilações climáticas imprevisíveis.

Na construção de modelos de ST, o analista pode optar por dois enfoques: paramétricos e não-paramétricos. Em ambos, o objetivo é construir um modelo para as ST com propósito determinado. No que se refere ao primeiro, é realizada uma análise no domínio temporal. No segundo, uma análise no domínio de frequência (MORETTIN; TOLOI, 1985).

Segundo Morettin e Tolo (1985), o objetivo de uma série temporal obtida de $Z(t_1), \dots, Z(t_n)$, mostradas nos instantes t_1, \dots, t_n , pode ser utilizada para:

- a) pesquisar o mecanismo gerador da série temporal;
- b) prever valores futuros da ST;
- c) buscar periodicidades relevantes nos dados;
- d) traçar o comportamento da ST.

Os modelos probabilísticos nas ST são construídos levando em consideração os requisitos de simplicidade, economia (menor número possível de parâmetros) e facilidade de utilização para usuários interessados em manipulá-las (MORETTIN; TOLOI, 1985).

Recursos estatísticos como regressão, modelos de séries temporais e abordagens estocásticas são utilizados na tentativa de previsões que tenham relação com a agricultura. São exemplos: Carvalho *et al.* (2004) que utilizam modelos de regressão para prever a produtividade de cafeeiros no estado de Minas Gerais (MG), Silva *et al.* (2008), utilizam modelos de ST para fazer previsão da variável temperatu-

ra média em Uberlândia, MG, e Assis *et al.* (2006), que em seu trabalho simulam a produtividade potencial da cultura do milho, pelo método Monte Carlo, utilizando um modelo agrometeorológico estocástico. Cada recurso tem suas vantagens e limitações.

Os modelos de ST têm vantagens em certas situações. Eles podem ser usados com maior facilidade na previsão, porque a sequência histórica de observações sobre as variáveis estudadas estão facilmente disponíveis a partir de fontes secundárias publicadas. Essas observações sucessivas são estatisticamente dependentes e as ST estão relacionadas a técnicas de análise de tais dependências. Portanto, modelos de ST na previsão de valores de períodos futuros são baseadas no padrão de valores do passado da variável em estudo (RAMASUBRAMANIAN, 2005).

Segundo Ramasubramaniam (2005), há duas principais razões para não recorrer a modelos de ST. Primeiramente, o sistema pode não ser entendido e mesmo que seja entendido pode ser extremamente difícil medir a relação causa e efeito. Já na segunda, a principal preocupação é apenas prever o que vai acontecer sem saber por que ela acontece.

De acordo com Silva *et al.* (2007) quando fala-se em previsão de ST, além do horizonte de previsão, outro parâmetro usado pelo processo é o número de elementos históricos anteriores ao horizonte de previsão. Esse parâmetro é chamado de janela de previsão e é utilizado em boa parte dos métodos de previsão de ST.

A janela de previsão é utilizada para formar exemplos (padrões) nos quais alguns métodos de previsão realizam a extração do conhecimento (aprendizado) para aplicação na previsão de valores futuros. O próximo elemento, após a janela de previsão, torna-se o alvo (elemento a ser previsto). A ST é normalmente dividida em dois conjuntos de elementos: o primeiro é destinado ao método de previsão para obtenção do aprendizado (conjunto de treinamento) e o segundo é usado para verificação de seu desempenho na previsão de valores futuros (conjunto de teste). A Figura 15 mostra um exemplo da definição desses componentes para previsão de uma série temporal: a divisão da série em conjuntos para treinamento e teste, uma janela de previsão que possui cinco elementos e o horizonte de previsão de um elemento alvo (RIBEIRO *et al.*, 2009).

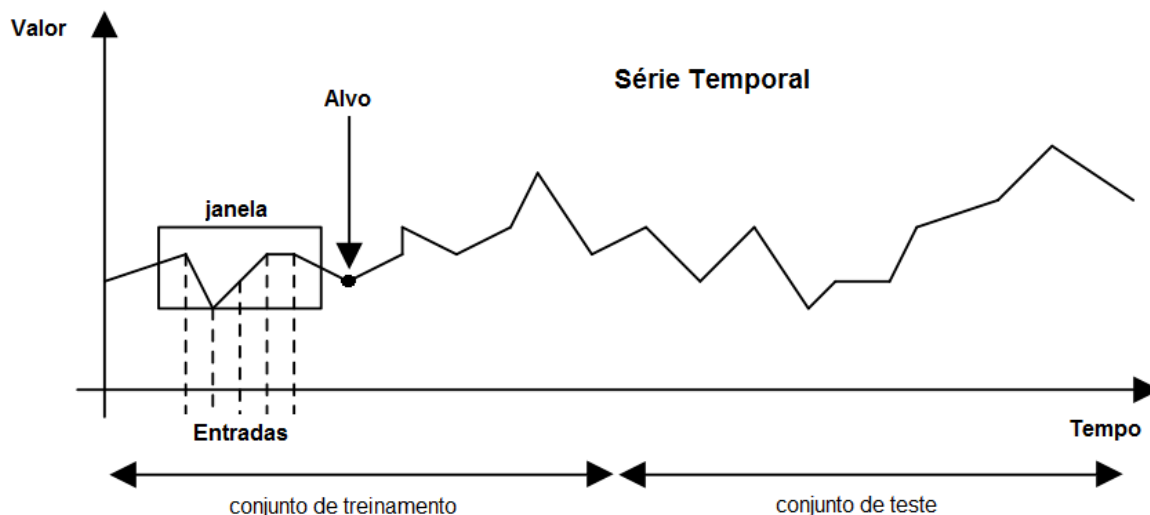


Figura 15 - Janela de previsão e horizonte igual a um
 Fonte: Ribeiro *et al.* (2009)

Quando as ST apresentam falhas, sejam elas, diárias, mensais ou anuais, essas séries ficam geralmente impossíveis de serem utilizadas (OLIVEIRA *et al.*, 2010). A existência de falhas nas ST ocorre geralmente pela ausência do observador, falhas nos mecanismos de registro, perda das anotações ou das transcrições dos registros pelos operadores e encerramento das transcrições dos registros pelos operadores. Entretanto, como existe a necessidade de se trabalhar com séries contínuas, essas falhas necessitam de ser preenchidas (STRECK *et al.*, 2009; OLIVEIRA *et al.*, 2010).

Para Oliveira *et al.* (2010), os métodos mais usuais utilizados para correção de ST são: ponderação regional, regressão linear, regressão potencial, regressão múltipla, ponderação regional com base em regressões lineares e vetor regional. Já Chibana *et al.* (2005) em seu trabalho, utilizaram para corrigir ST climática, médias de dados observados ou dados sintéticos obtidos por sistemas geradores de dados.

Trabalhos que utilizam métodos matemáticos para corrigir ST com falhas são encontrados em, Chibana *et al.* (2005), que implementam um aplicativo para importar, armazenar e avaliar métodos de preenchimento de falhas em dados meteorológicos e compara seu aplicativo com os aplicativos WGEN de (Richardson; Wright, 1984) e SIMMETEO (Geng, *et al.*, 1999). Oliveira *et al.* (2010), propuseram em seu trabalho comparar as metodologias de preenchimento de falhas de ST disponíveis na literatura. Outros trabalhos como, Streck *et al.* (2009) e Buriol *et al.* (2006), também necessitaram utilizar método matemático em seus trabalhos, para corrigir falhas em ST.

Tratando-se das ST que foram utilizadas neste trabalho, segundo Sivakumar *et al.* (2000), o uso de ST agrometeorológicas é de fundamental importância para que a agricultura se torne uma atividade sustentável. A preocupação crescente com o aumento da população mundial, com a degradação dos recursos naturais e com a sustentabilidade da agricultura tem exigido maiores esforços no desenvolvimento de melhores estratégias e práticas do uso do solo, a partir do melhor entendimento das relações entre a agricultura e o clima (SENTELHAS *et al.*, 2009).

ST agrometeorológicas são aquelas que consideram os dados meteorológicos associados aos requerimentos dos cultivos com o objetivo de estimar os respectivos impactos às culturas e às práticas agrícolas, tanto no âmbito do planejamento como no âmbito das tomadas de decisão (SENTELHAS *et al.*, 2009). As ST agrometeorológicas, de acordo com Mavi e Tupper (2004), podem ser empregadas de diferentes maneiras na agricultura. Primeiramente, essas ST podem ser utilizadas para o planejamento dos cultivos (componente estratégico), tanto na escala macroclimática como topoclimática. Além disso, essas informações podem ser empregadas no processo de tomada de decisão quanto ao melhor momento ou condição para a execução de diferentes práticas agrícolas (componente tático). Finalmente, as ST agrometeorológicas também podem permitir aos sistemas agrícolas adquirir maior capacidade para enfrentar condições meteorológicas adversas, tornando-as mais resilientes.

As ST nos contextos de agrometeorologia, planejamento e tomada de decisão na agricultura, associadas aos avanços nas áreas de agrometeorologia, climatologia, meteorologia, sensoriamento remoto, geoprocessamento e informática, têm melhorado substancialmente a possibilidade dos agricultores ajustarem suas atividades às variabilidades e mudanças do clima, levando à redução dos riscos na agricultura (SENTELHAS *et al.*, 2009).

O próximo capítulo descreverá o caminho metodológico percorrido e as etapas desenvolvidas neste estudo.

3 MATERIAIS E MÉTODOS

Este capítulo apresenta o caminho metodológico percorrido e detalha as etapas da pesquisa. Os dados utilizados para atingir os objetivos dessa dissertação foram obtidos de estações agrometeorológicas localizadas no estado do Paraná. Algumas variáveis foram escolhidas para verificar a eficiência do método proposto.

No que se refere à metodologia computacional foram utilizadas RNAs tipo Perceptron de Múltiplas Camadas (*Multilayer Perceptron*) com o algoritmo de treinamento *Backpropagation*, e a arquitetura do sistema computacional, baseou-se nos trabalhos de Medeiros (2006) e Dias (2007).

O sistema computacional foi desenvolvido com a linguagem de programação Object Pascal, utilizando o ambiente de desenvolvimento integrado (IDE), Embarca-deiro Delphi 2009, sendo executado na plataforma Windows.

3.1 BASES DE DADOS

Os dados utilizados foram obtidos de estações monitoradas pela Fundação ABC, desde junho de 2002, com o objetivo de descobrir tendências das variáveis climáticas de cada região, e orientar os produtores cooperados através da disponibilização de informações atualizadas (FUNDAÇÃO ABC, 2012).

Especificamente os dados utilizados foram de duas estações agrometeorológicas, uma com coordenadas geográficas, -25.30156819 de latitude, -49.95025733 de longitude, localizada na cidade de Ponta Grossa (PG), e a outra com -24.6752 de latitude e -49.8672 de longitude, na cidade de Castro.

Dentre as variáveis monitoradas nessas estações tem-se a precipitação, radiação solar, umidade relativa, velocidade do vento, direção do vento, temperatura do ar, temperatura do ponto de orvalho, temperatura do solo, pressão atmosférica, duração do período de molhamento, evapotranspiração potencial, umidade do solo, umidade específica do solo, temperatura do solo na raiz, índice de molhamento do solo, índice de molhamento da raiz, cobertura de nuvens, radiação OCI, radiação OLE, albedo, dentre outras, incluindo variáveis com diferentes intensidades e altitudes.

Sentelhas (2009), apoiado em (Hoogenboom, 2000); (Pereira *et al.*, 2002); (Mavi; Tupper, 2004) afirmam que as principais variáveis meteorológicas que afetam

o crescimento, desenvolvimento e produtividade das culturas são chuva, temperatura do ar e radiação solar, havendo ainda a influência do fotoperíodo, da umidade do ar e do solo e da velocidade do vento.

Os dados utilizados neste trabalho foram obtidos no período compreendido entre os meses de janeiro de 2010 a dezembro de 2010, totalizando 12 meses. As ST desses dados coletados apresentam intervalos de coleta de 15 em 15 minutos. Optou-se por tratar as variáveis agrometeorológicas, temperatura média e umidade relativa do ar, por terem apresentado os melhores resultados em experimentos efetuados. Além disso, Sentelhas (2009) baseado em (Camargo *et al.*, 1977) afirma que a temperatura é a principal variável agrometeorológica a ser considerada nos zoneamentos agroclimáticos. A umidade relativa do ar atua de forma indireta sobre a cultura afetando o poder evaporante do ar, condicionando a transpiração.

Na tabela 1 e 2, estão descritos fragmentos da composição da base de dados da variável temperatura média (TM) e umidade relativa do ar (UR), as quais, originalmente, contém 35.040 registros, organizados em 2 variáveis, onde constam a data e hora e a informação correspondente à variável agrometeorológica.

Tabela 1 - Composição parcial da base de dados de TMéd

Data_Hora (dd/mm/aaaa hh:mm)	TM
01/01/2010 00:00	17.76
01/01/2010 00:15	17.71
01/01/2010 00:30	17.72
01/01/2010 00:45	17.72
01/01/2010 01:00	17.77
01/01/2010 01:15	17.78
01/01/2010 01:30	17.76
01/01/2010 01:45	17.64
01/01/2010 02:00	17.47
01/01/2010 02:15	17.37

Tabela 2 - Composição parcial da base de dados de UR

Data_Hora (dd/mm/aaaa hh:mm)	UR
01/01/2010 09:30	100
01/01/2010 09:45	100
01/01/2010 10:00	100
01/01/2010 10:15	97,79
01/01/2010 10:30	96,04
01/01/2010 10:45	91,50
01/01/2010 11:00	91,81
01/01/2010 11:15	94,93
01/01/2010 11:30	93,90
01/01/2010 11:45	94,64

Para o tratamento dos registros com falhas, não foi utilizada a base de dados com todos os 35.040 registros. Foram selecionados fragmentos da base de dados total, para compor os dados a serem utilizados no tratamento e correção dos registros com falhas.

Dois métodos podem ser utilizados no processo de tratamento da falha. A escolha do método a ser utilizado depende da homogeneidade dos dados de trei-

namento em relação aos dados tratados e também dos resultados obtidos no tratamento dos registros.

No primeiro método, a composição da base de dados utilizada no treinamento é representada pelos registros anteriores ao período da falha. Os dados foram fragmentados em períodos de 7 dias (672 registros) e os dados a serem tratados foram originados do último dia da ST, ou seja, nos 96 últimos registros desse fragmento (Figura 16). O fragmento a ser utilizado, foi então separado da base de dados total e salvo no formato de arquivo CSV (*Comma Separated Value*).




Figura 16 - Fragmento com dados de treinamento

O segundo método é baseado em Chibana *et al.* (2005), onde a composição da base de dados utilizada no treinamento é formada por dados coletados em um mesmo período de tempo, de uma estação agrometeorológica próxima à estação onde ocorreu a falha. Esta metodologia é utilizada quando o primeiro método não consegue gerar resultados satisfatórios na correção dos registros com falha. Em ST como a da Figura 17 é que este método é utilizado.




Figura 17 - ST com vales e picos irregulares

O uso do segundo método permite inserir os registros correspondentes aos registros com falhas a serem corrigidas de outra estação agrometeorológica, no treinamento da RNA. Segundo Chibana *et al.*(2005), quando há similaridade nas bases

de dados, os resultados obtidos são melhores. A Figura 18 apresenta os dados de duas estações agrometeorológicas, obtidos em um mesmo período de tempo.




Figura 18 - ST de duas estações agrometeorológicas

Para validar o método proposto, foi necessário originar falhas na composição da base de dados, a fim de tratá-los. Para isso, utilizou-se um valor nulo representado por (-999), para simbolizar a simulação de falha na base de dados. A tabela 3 representa a variável agrometeorológica sem a falha e com a falha a ser tratada.

Tabela 3 - Fragmento base de dados com falhas

Data_Hora (dd/mm/aaaa hh:mm)	BD sem Falha	BD com Falha
06/01/2010 22:30	20,32	20,32
06/01/2010 22:45	20	20
06/01/2010 23:00	19,73	19,73
06/01/2010 23:15	19,87	19,87
06/01/2010 23:30	19,98	19,98
06/01/2010 23:45	20,22	20,22
07/01/2010 00:00	20,09	-999
07/01/2010 00:15	19,71	-999
07/01/2010 00:30	19,66	-999
07/01/2010 00:45	19,92	-999

3.2 METODOLOGIA COMPUTACIONAL

Para que se obtenham os resultados desejados de um sistema com RNAs e o aprendizado supervisionado, é necessário fazer uma análise preliminar do conjunto de dados, pré-processamento, para então dar início ao processo. É de fundamental importância um estudo na disponibilidade e no volume dos dados, também é necessário observar se as características desses dados permitem uma modelagem para a obtenção de conhecimento.

Em um segundo momento, os dados pré-processados são carregados no modelo computacional para serem tratados. Posteriormente escolhem-se os parâmetros que serão utilizados pela RNA para tratar os dados, carrega-se a base de dados sem a falha para poder validar o resultado e a partir do processamento, inicia-se o tratamento dos erros pela rede, retornando valores conforme o conhecimento implícito da RNA.

Após o processamento, é criada uma tabela com os resultados do tratamento das falhas dos dados, que é salva em formato de arquivo CSV para análise dos resultados. Também pode-se salvar o gráfico contendo os valores dos dados corrigidos e os dados sem a falha.

Para permitir uma melhor visualização dos processos executados pelo sistema computacional, a Figura 19 apresenta o diagrama UML comportamental de caso de uso e na Figura 20 é feita a reprodução temporal do processo realizado pelo sistema para correção de falhas em ST, utilizando para isso o diagrama UML de sequência.

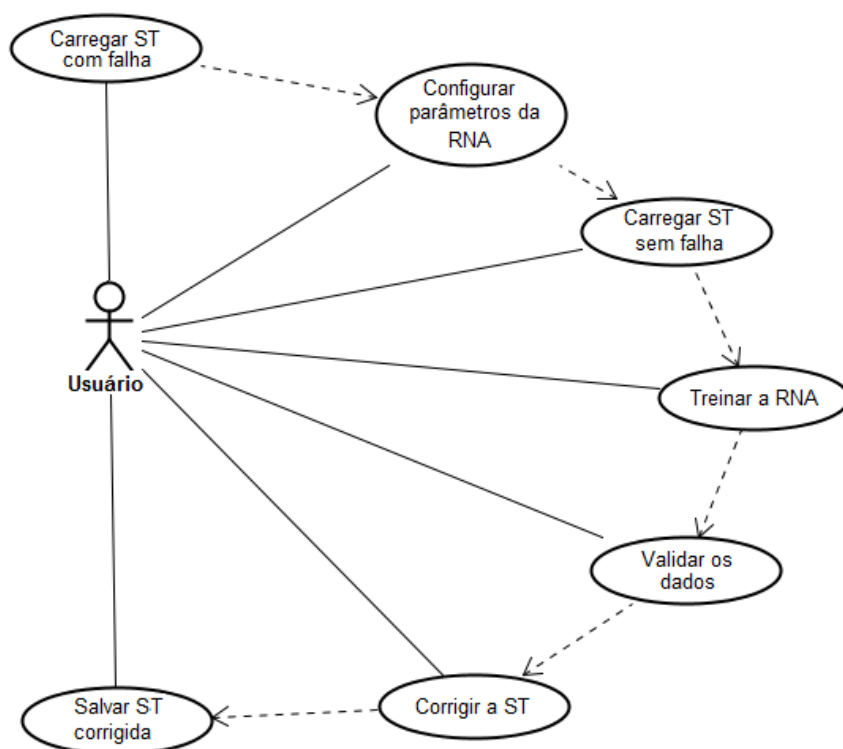


Figura 19 - Diagrama de Caso de Uso - STST Agrometeorológicas

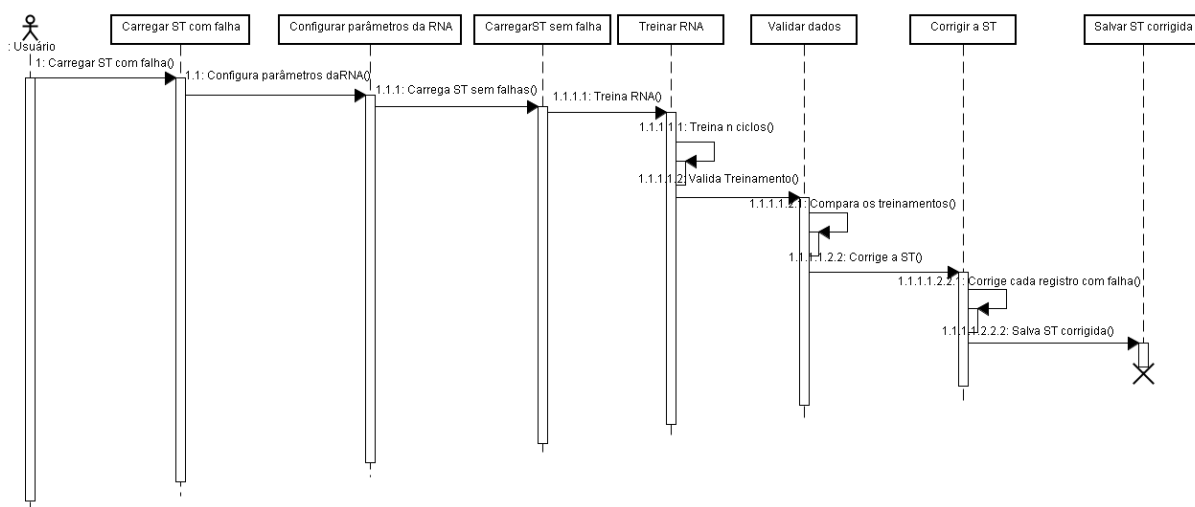


Figura 20 - Diagrama de Sequência do - STST Agrometeorológicas

O desenvolvimento do modelo seguiu a proposta de Caudill (apud Medeiros, 1999), representado na Figura 21.



Figura 21 - Etapas do desenvolvimento da RNA
Fonte: Medeiros (1999)

3.3 DESENVOLVIMENTO DO MODELO COM RNA

As etapas para o desenvolvimento do modelo computacional em Redes Neurais Artificiais serão descritos a seguir:

3.3.1 Definição do problema

Analisar a eficiência da tecnologia de RNA no processo de correção de registros com falhas em ST de dados agrometeorológicos.

3.3.2 Coleta de dados

Os dados utilizados foram fornecidos pela Fundação ABC, são dados obtidos de estações agrometeorológicas localizadas em Ponta Grossa e Castro, originadas para descobrir tendências em ST de variáveis climáticas, e por meio de informações agrometeorológicas atualizadas, orientar os produtores agrícolas cooperados.

3.3.3 Pré-processamento dos dados

Nesta etapa os dados são preparados conforme o formato requerido pela metodologia computacional adotada.

Dentre as atividades desenvolvidas nesta etapa de preparação dos dados, foi feita a exportação dos arquivos, originalmente arquivos de banco de dados do sistema de gerenciamento de banco de dados (SGBD) *postgres*, convertidos para o formato de arquivo CSV.

Em um segundo momento, ocorreu a fragmentação da base de dados. Originalmente a base de dados de cada variável é composta por registros de um ano de observações (35.096 registros). Nesse modelo computacional utilizou-se a fragmentação da base de dados em ST com períodos de 7 dias. Períodos menores de 7 dias não apresentaram resultados satisfatórios no tratamento dos dados, já quando se excede os 7 dias, os resultados foram parecidos mas o tempo de processamento aumentou.

Como o AM utiliza o paradigma do aprendizado neural supervisionado, para poder validar o sistema, as falhas foram produzidas. Essas falhas simulam situações ocorridas na obtenção dos dados das variáveis nas estações agrometeorológicas. A validação dos resultados ocorre com a comparação da falha simulada com os dados sem falhas.

3.3.4 Projeto da RNA

Nesta etapa é definida a escolha da arquitetura da RNA que é formada pela determinação do número de neurônios da camada de entrada, quantidade de camadas, número de neurônios da camada(s) oculta(s) e o número de neurônios da camada de saída.

Segundo Santos, *et al.* (2005), Medeiros (1999), uma das tarefas mais difíceis na elaboração do projeto de uma RNA é determinar o número de elementos de processamento da camada oculta, bem como o número de neurônios de camadas ocultas ideais para solucionar um determinado problema.

É necessário obter um modelo que não seja muito rígido a ponto de não modelar fielmente os dados. A ideia é que a rede responda de acordo com as características presentes nos dados de entrada e não exatamente igual aos dados de entrada (MATHIAS, 2006).

- Determinação da camada de entrada

Para determinar o número de neurônios de entrada, foram realizados diversos experimentos para descobrir qual a melhor combinação que proporcionava a menor porcentagem de erro ao comparar os dados tratados com os dados sem as falhas.

As entradas da RNA são formadas pelos registros da ST da variável a ser tratada. A quantidade de neurônios de entrada é definida levando em consideração fatores como, a quantidade de registros que formam a ST utilizada no experimento e o tamanho da falha contida nessa ST (períodos iguais ou menores que 1 dia - 96 registros), por exemplo, se o tamanho da ST é de 7 dias (672 registros) o último dia (últimos 96 registros) encontram-se as falhas, sendo assim tem-se no máximo 6 dias (576 registros) que podem ser utilizados como neurônios de entrada.

A quantidade de neurônios de entrada selecionados afeta no resultado do tratamento da falha dos registros de forma diferenciada dependendo da ST. No de-

envolvimento destes experimentos, a quantidade de neurônios da camada de entrada variou entre 96 a 480 parâmetros.

- Determinação das camadas ocultas

Definir a quantidade de camadas ocultas e a quantidade de neurônios a serem utilizados envolve subjetividade (MATHIAS, 2006). Caudill (1990) afirma que o número de unidades de camada oculta é uma incógnita.

Nesse contexto, se o número de camadas ocultas ou a quantidade de neurônios nelas for muito grande, a rede estará memorizando os padrões e com isso perdendo a capacidade de generalização (*over training / over fitting*). Por outro lado, se o número de camadas ocultas ou a quantidade de neurônios nelas for muito pequena, a rede levará mais iterações para atingir a precisão desejada.

Na resolução dos problemas deste trabalho, foram utilizadas redes neurais com uma e três camadas ocultas. Para a definição deste parâmetro, foram realizados testes variando-se os valores de quantidades de camadas ocultas e de neurônios em suas camadas, a fim de, aperfeiçoar os resultados. Esses testes encontram-se relatados no item discussões.

- Determinação da camada de saída

Como o tratamento dos registros com falhas da ST é feito um de cada vez, a quantidade de neurônios da camada de saída sempre será 1, independente da quantidade de registros a serem tratados.

A partir da determinação da arquitetura da RNA, o passo seguinte em um projeto de RNA é o treinamento.

3.3.5 Treinamento da RNA

Nesta etapa a RNA é submetida ao aprendizado e os fatores levados em consideração são os seguintes: metodologia de treinamento, o algoritmo de treinamento, parâmetros de aprendizagem e número de repetições (ciclos ou épocas).

O treinamento da RNA consiste em fazer com que os neurônios de entrada desloquem-se sobre os registros da ST da variável agrometeorológica selecionada, sincronizando com o deslocamento do neurônio de saída. Por exemplo, se a ST selecionada para o treinamento tiver 36 registros e desses 36 registros, os 6 últimos registros necessitem ser tratados, são definidos 18 neurônios de entrada. Na Figura

22, esta ilustrada uma descrição do processo de treinamento para tratamento dos respectivos registros.




Figura 22 - Metodologia de treinamento da RNA aplicada a ST
Adaptado de Ribeiro *et al.* (2009)

Algoritmo descritivo da Figura 22:

1. Com a entrada definida em D1;
2. Enquanto DN maior do que zero;
3. Repetir até que o número de ciclos seja igual a zero;
 - 3.1 Obtêm-se os nós de entrada;
 - 3.2 Treina a rede deslocando-se de D1 até DN;
4. Determina o próximo registro da ST;
5. Retorna ao passo 3.

Nota-se, na figura 22, o deslocamento dos neurônios de entrada na ST em D1, D2, D3 até DN. Quando o deslocamento chega até o primeiro registro da ST a ser tratado, repete-se o treinamento até que o número de ciclos determinado termine. Após o término dos ciclos, a RNA gera o valor tratado para o registro e o procedimento de treinamento inicia novamente até que todos os registros sejam tratados.

Como já mencionado, o algoritmo de treinamento utilizado foi o *Backpropagation* que segue o paradigma de aprendizado supervisionado.

Com relação ao parâmetro de treinamento que influencia nos resultados, é o *momentum*, o qual é utilizado para diminuir o tempo de treinamento e o risco de mínimos locais, sem que o risco de oscilações das RNAs aumente (ABELÉM, 1994). O valor desse parâmetro varia entre 0 a 100, obtendo o melhor resultado em 30, para todas as situações.

Outro parâmetro de fundamental importância no controle do gradiente descendente e no tempo de treinamento é a taxa de aprendizado. Encontrar a taxa de aprendizado apropriada para cada aplicação é uma tarefa difícil que depende basicamente de experimentações. Uma taxa de aprendizado pequena implica em pequenas variações, mesmo quando grandes mudanças são necessárias, tornando o treinamento lento e aumentando as chances de paradas em mínimos locais. Por outro lado, altas taxas de aprendizado provocam grandes mudanças nos pesos, diminuindo o tempo de treinamento e evitando mínimos locais, mas podendo levar a RNA à saturação ou mesmo à oscilação, comprometendo todo o processo de aprendizado (ABELÉM, 1994). Este parâmetro tem sua variação entre 0 a 100 e neste trabalho foram utilizadas taxas de aprendizado entre 80 e 90.

3.3.6 Teste e Validação da RNA

Para verificar a eficiência das RNAs na correção de ST de informações agrometeorológicas, foi calculada a porcentagem do erro entre os registros corrigidos e os registros sem falha, também foi feito o cálculo do coeficiente de correlação de Pearson (Figura 23).

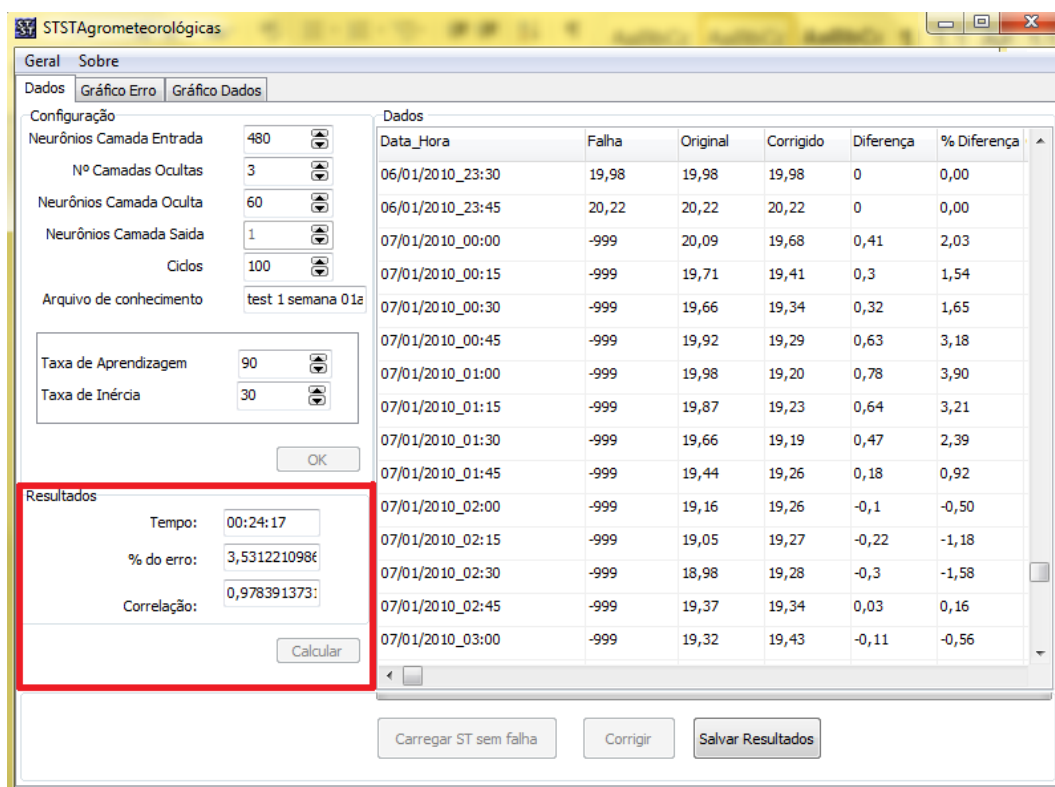


Figura 23 - Resultados obtidos no tratamento dos registros

O cálculo da porcentagem do erro entre a ST tratada e a ST sem falhas foi realizado seguindo os seguintes passos:

1- Média da soma dos registros correspondentes a ST com falha e da ST sem falha.

2- Média da soma dos valores dos registros tratados pela RNA.

3- Subtração do resultado do passo 1 com o passo 2. Descobre-se a média da diferença obtida no tratamento dos registros que continham falhas. O operador da frente não é considerado no resultado obtido.

4- Para calcular a porcentagem do erro obtido, fez-se uma regra de três em que o valor obtido no passo 1 é a parte do todo e representa cem por cento e o valor do passo 3 determinou a porcentagem do erro no tratamento dos registros da ST.

Para calcular o coeficiente de correlação de Pearson entre os registros da ST tratada e os registros sem falhas, fez-se uso da seguinte equação:

$$r_{X,Y} = \frac{n \cdot \sum X_i \cdot Y_i - (\sum X_i) \cdot (\sum Y_i)}{\sqrt{[n \cdot \sum X_i^2 - (\sum X_i)^2] \cdot [n \cdot \sum Y_i^2 - (\sum Y_i)^2]}} \quad (8)$$

Onde, X corresponde aos registros da ST sem falha, Y aos registros cujas falhas foram tratadas e n é o operador do valor esperado. A correlação entre as variáveis X e Y pode também ser definida como a Covariância de X e Y dividida pelo produto do Desvio Padrão (S) de ambas, como na equação abaixo.

$$r_{X,Y} = \frac{Cov(X,Y)}{S_X \cdot S_Y} \quad (9)$$

No simulador desenvolvido, o treinamento da rede é executado para cada registro com falha a ser tratada, originando conseqüentemente um erro da rede neural, para cada treinamento executado. Como geralmente as falhas nas ST de dados agrometeorológicos apresentam períodos com mais de um registro com falha, foi calculada uma média simples entre os erros da rede de cada registro tratado (Figura 24). Exemplificando, se a quantidade de registros a serem tratados é de 96, para cada um dos 96 registros será gerado um erro médio quadrático do treinamento da rede, o erro obtido para cada registro é somado e posteriormente dividido pela quantidade de registros tratados, neste caso 96.




Figura 24 - Média de Erro da Rede

A equação abaixo exemplifica o cálculo executado para obtenção da média do erro gerado no treinamento da RNA:

$$EM = \frac{\sum E_i}{N} \quad (10)$$

Onde, E é o valor do erro da rede neural treinada para cada registro tratado e N é a quantidade de registros a serem tratados.

3.3.7 Pós- Processamento

Esta é a última etapa do processo de correção das ST, nela a tabela “Dados” demonstrada na Figura 25, apresenta os resultados obtidos no procedimento realizado pela RNA. A tabela contendo estes dados foi salva em formato CSV, permitindo uma análise sobre o resultado, bem como, a importação dos valores tratados para o banco de dados utilizado pela estação agrometeorológica. Também salvou-se o gráfico de dados para ser comparado visualmente a ST tratada, com os registros sem falhas (Figura 26).

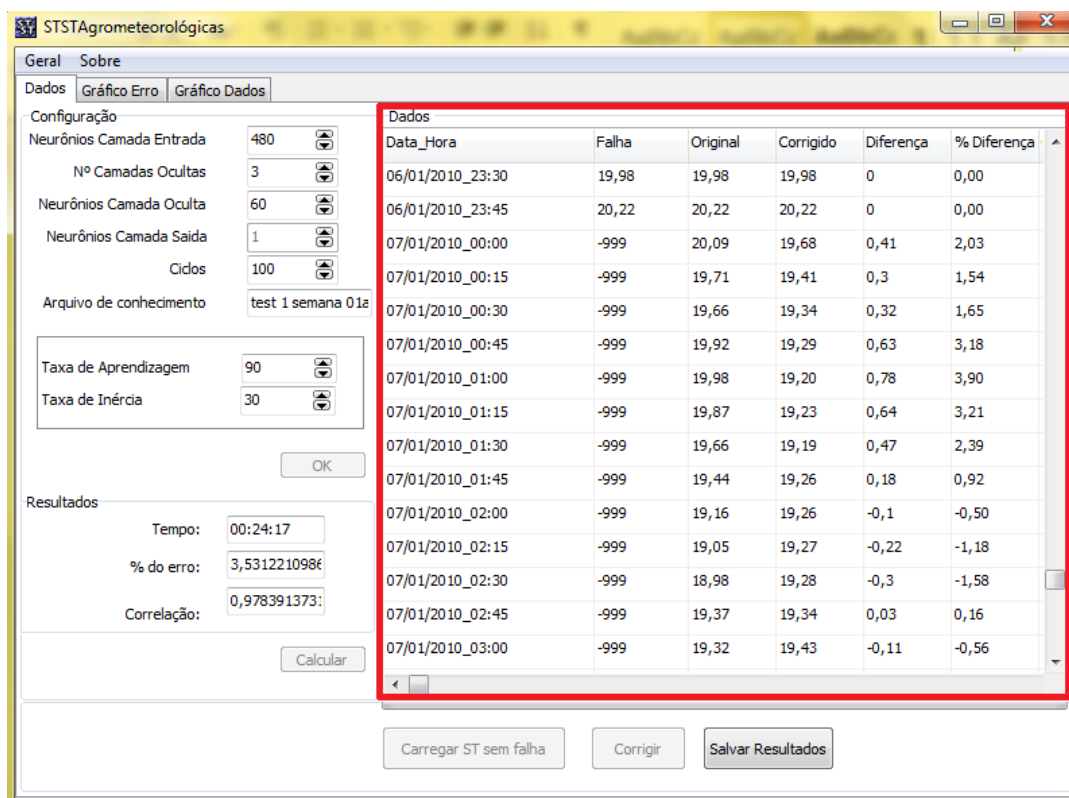


Figura 25 - Resultados obtidos pela RNA no tratamento de ST




Figura 26 - ST tratada e ST sem falhas

No próximo capítulo são apresentados os resultados.

4 RESULTADOS E DISCUSSÕES

4.1 RESULTADOS

Os resultados obtidos no tratamento das falhas dos registros de ST utilizando o STST Agrometeorológicas estão descritos em 6 estudos de caso. Os estudos de caso estão relacionados às variáveis agrometeorológicas temperatura média e umidade relativa do ar das estações agrometeorológicas das cidades de Ponta Grossa e Castro.

4.1.1 Estudo de caso 1

Neste estudo utilizou-se a ST da variável agrometeorológica temperatura média e foi selecionada a ST com período de 7 dias, referente ao período do mês de janeiro.

Para o mês de janeiro a ST escolhida foi com registros do dia 01 a 07. Nessa ST as falhas originadas totalizaram 96 registros, todos no dia 07. No treinamento, os dados utilizados foram os dados anteriores ao período da falha.

A Figura 27 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Castro, no mês de janeiro.



Figura 27 - Estudo de Caso 1 - Temperatura, Castro

A Figura 28 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Ponta Grossa no mês de janeiro.



Figura 28 - Estudo de Caso 1 - Temperatura, Ponta Grossa

Na Tabela 4, estão ilustrados, o percentual de acerto no tratamento dos registros deste estudo de caso, a média dos erros da rede neural, bem como o coeficiente de correlação de Pearson existente entre os dados tratados e os dados sem falhas. Também está descrita a arquitetura de RNA utilizada no tratamento das informações, a quantidade de ciclos e o tempo que levou cada procedimento.

Tabela 4 - Resultado: Estudo de Caso 1

ESTAÇÃO	RNA	TX-AP	INÉRCIA	CICLOS	MÉDIA DE ERRO DA REDE	% DE ACERTOS	CORRELAÇÃO	TEMPO
Castro	480-3-60	90	30	100	0,026406	96,5	0,98	24 min
PG	480-3-60	90	30	50	0,017985	94,7	0,93	13 min

Pode-se observar, na Tabela 4, que o melhor resultado obtido no tratamento dos registros com falha da variável temperatura média da ST da estação agrometeorológica de Castro utilizando RNA, apresentou percentual de acerto de 96,5%, um coeficiente de correlação entre a ST tratada e a ST sem falha de 0,98 e a média dos erros da rede neural foi 0,026406. Na correção da ST contendo informações da estação agrometeorológica de Ponta Grossa obteve-se percentual de acerto de 94,7%, um coeficiente de correlação de 0,93 e a média dos erros da rede neural foi 0,017985.

4.1.2 Estudo de caso 2

Para o estudo de caso 2, utilizou-se a ST da variável agrometeorológica temperatura média e foi selecionada a ST com período de 7 dias, ocorrido no mês de novembro.

Para o mês de novembro, a ST escolhida foi com registros do dia 01 a 07. Nesta ST, as falhas originadas totalizaram 96 registros sendo estes no dia 07. No treinamento, os dados utilizados foram os dados anteriores ao período da falha.

A Figura 29 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Castro no mês de novembro.

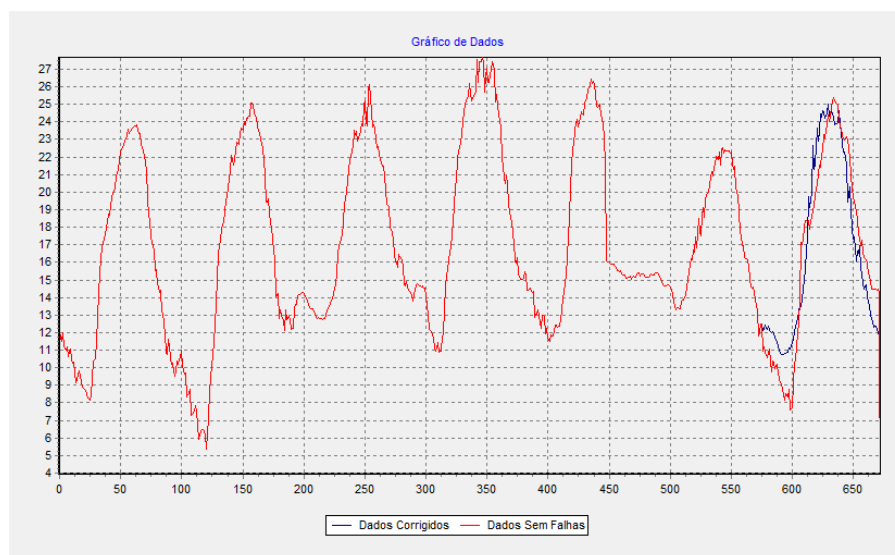


Figura 29 - Estudo de Caso 2 - Temperatura, Castro

A Figura 30 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Ponta Grossa no mês de novembro.




Figura 30 - Estudo de Caso 2 - Temperatura, Ponta Grossa

Estão ilustradas, na Tabela 5, o percentual de acerto encontrado no tratamento dos registros deste estudo de caso, a média dos erros da rede neural, bem como o coeficiente de correlação de Pearson existente entre os dados tratados e os

dados sem falhas. Também está descrita a arquitetura de RNA utilizada no tratamento das informações, a quantidade de ciclos utilizados no treinamento e o tempo que levou cada procedimento.

Tabela 5 - Resultado: Estudo de Caso 2

ESTAÇÃO	RNA	TX – AP	INÉRCIA	CICLOS	MÉDIA DE ERRO DA REDE	% DE ACERTOS	CORRELAÇÃO	TEMPO
Castro	288-3-200	90	30	100	0,030647	87,5	0,95	3h24 min
PG	480-3-90	90	30	100	0,012400	90,8	0,96	51 min

Percebe-se, na Tabela 5, que o melhor resultado obtido no tratamento dos registros com falha da variável temperatura média da ST da estação agrometeorológica de Castro utilizando RNA, apresentou percentual de acerto de 87,5%, um coeficiente de correlação de 0,94 entre a ST tratada e a ST sem falha e a média dos erros da rede neural foi 0,030647. Na correção da ST contendo informações da estação agrometeorológica de Ponta Grossa, obteve-se percentual de acerto de 90,8%, um coeficiente de correlação de 0,96 e a média dos erros da rede neural foi de 0,012400.

4.1.3 Estudo de caso 3

Neste estudo utilizou-se a ST da variável agrometeorológica temperatura média e foi selecionada a ST com período de 7 dias, referente ao mês de maio.

Para o mês de maio a ST escolhida foi com registros do dia 05 a 11. Nesta ST as falhas originadas totalizaram 96 registros ocorridos no dia 11. No treinamento, os dados utilizados foram os anteriores ao período da falha.

A Figura 31 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Castro no mês de maio.

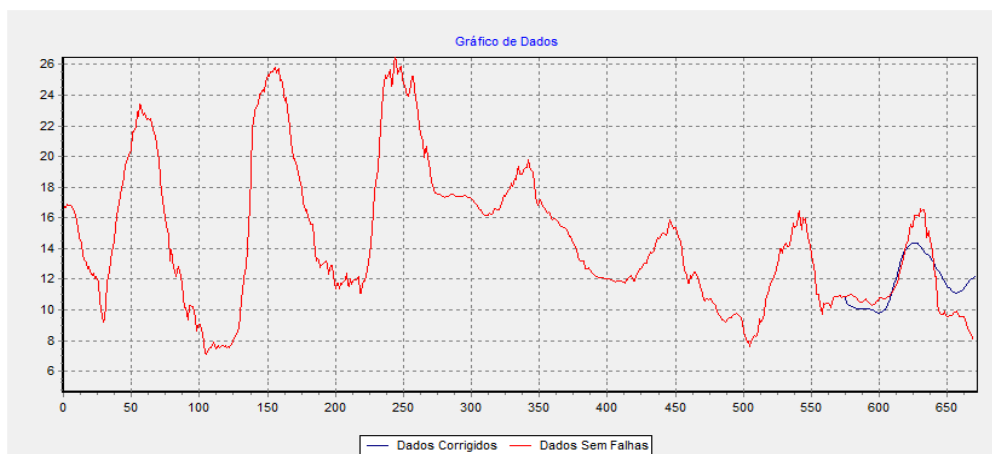


Figura 31 - Estudo de Caso 3 - Temperatura, Castro

A Figura 32 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Ponta Grossa no mês de maio.




Figura 32 - Estudo de Caso 3 - Temperatura, Ponta Grossa

O percentual de acerto no tratamento dos registros deste estudo de caso, a média dos erros da rede neural, bem como o coeficiente de correlação de Pearson existente entre os dados tratados e os dados sem falhas estão ilustrados na Tabela 6. Ainda estão descritas a arquitetura de RNA utilizada no tratamento das informações, a quantidade de ciclos e o tempo que levou cada procedimento.

Tabela 6 - Resultado: Estudo de Caso 3

ESTAÇÃO	RNA	TX – AP	INÉRCIA	CICLOS	MÉDIA DE ERRO DA REDE	% DE ACERTOS	CORRELAÇÃO	TEMPO
Castro	384-1-384	90	30	200	0,010605	89	0,72	3h 02min
PG	384-1-384	90	30	30	0,010184	81,2	0,49	51 min

Na Tabela 6, o melhor resultado obtido no tratamento dos registros com falha da variável temperatura média da ST da estação agrometeorológica de Castro utilizando RNA, apresentou percentual de acerto de 89%, coeficiente de correlação

entre a ST tratada e a ST sem falha de 0,72 e a média dos erros da rede neural de 0,010605. Na correção da ST contendo informações da estação agrometeorológica de Ponta Grossa, o percentual de acerto foi 81,2%, o coeficiente de correlação foi 0,49 e a média dos erros da rede foi de 0,010184.

4.1.4 Estudo de caso 4

O estudo de caso 4 utilizou a ST da variável agrometeorológica temperatura média e foi selecionada a ST com período de 7 dias, relativo ao mês de maio.

Os dados escolhidos se referem aos registros do dia 05 a 11. Nesta ST, as falhas originadas totalizaram 96 registros que ocorreram no dia 11. Foram utilizados dados para o treinamento da estação agrometeorológica da cidade de Ponta Grossa.

A Figura 33 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Castro no mês de maio.




Figura 33 - Estudo de Caso 4 - Temperatura, Castro

A Figura 34 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável temperatura média da estação agrometeorológica de Ponta Grossa no mês de maio.




Figura 34 - Estudo de Caso 4 - Temperatura, Ponta Grossa

Na Tabela 7, estão ilustrados o percentual de acerto no tratamento dos registros deste estudo de caso, a média dos erros da rede neural, bem como o coeficiente de correlação de Pearson existente entre os dados tratados e os dados sem falhas. Também está descrita a arquitetura de RNA utilizada no tratamento das informações, a quantidade de ciclos e o tempo que levou cada procedimento.

Tabela 7 - Resultado: Estudo de Caso 4

ESTAÇÃO	RNA	TX - AP	INÉRCIA	CICLOS	MÉDIA DE ERRO DA REDE	% DE ACERTOS	CORRELAÇÃO	TEMPO
Castro	384-1-60	90	30	100	0,016101	91,6	0,85	22 min
PG	384-1-384	90	30	30	0,015609	91,3	0,76	8 min

Na Tabela 7, observa-se que o resultado obtido no tratamento dos registros com falha da variável temperatura média da ST da estação agrometeorológica de Castro utilizando RNA, apresentou percentual de acerto de 91,6%, um coeficiente de correlação entre a ST tratada e a ST sem falha de 0,85 e a média dos erros da rede neural foi 0,016101. Na correção da ST contendo informações da estação agrometeorológica de Ponta Grossa, obteve-se percentual de acerto de 91,3%, um coeficiente de correlação de 0,76 e a média dos erros da rede foi 0,015609.

4.1.5 Estudo de caso 5

Neste estudo utilizou-se a ST da variável agrometeorológica umidade relativa do ar e foi selecionada a ST com período de 7 dias, referente ao mês de janeiro.

A ST escolhida continha registros do dia 01 a 07. Nesta ST, as falhas originadas totalizaram 96 registros ocorridos no dia 07. No treinamento, os dados utilizados foram os dados anteriores ao período da falha.

A Figura 35 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável umidade relativa do ar da estação agrometeorológica de Castro.




Figura 35 - Estudo de Caso 5 - Umidade relativa, Castro

A Figura 36 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável umidade relativa do ar da estação agrometeorológica de Ponta Grossa.




Figura 36 - Estudo de Caso 5 - Umidade relativa, Ponta Grossa

Na Tabela 8, estão ilustrados o percentual de acerto no tratamento dos registros deste estudo de caso, a média dos erros da rede neural, bem como o coeficiente de correlação de Pearson existente entre os dados tratados e os dados sem falhas. Também é informada, a arquitetura de RNA utilizada no tratamento das informações, a quantidade de ciclos e o tempo que levou cada procedimento.

Tabela 8 - Resultado: Estudo de Caso 5

ESTAÇÃO	RNA	TX- AP	INÉRCIA	CICLOS	MÉDIA DE ERRO DA REDE	% DE ACERTOS	CORRELAÇÃO	TEMPO
Castro	96-1-96	90	30	30	0,094298	95,7	0,97	5 min
PG	192-1-192	90	30	30	0,024899	94,1	0,86	18 min

Observa-se que o resultado obtido no tratamento dos registros com falha da variável temperatura média da ST da estação agrometeorológica de Castro utilizando RNA, apresentou percentual de acerto de 95,7%, um coeficiente de correlação entre a ST tratada e a ST sem falha de 0,97 e a média dos erros da rede neural foi de 0,094298. Na correção da ST contendo informações da estação agrometeorológica de Ponta Grossa, obteve-se um percentual de acerto de 94,1%, um coeficiente de correlação de 0,86 e a média dos erros da rede neural foi 0,024899.

4.1.6 Estudo de caso 6

Neste estudo de caso utilizou-se a ST da variável agrometeorológica umidade relativa do ar e foi selecionada a ST com período de 7 dias, referente ao mês de julho.

A ST escolhida continha registros do dia 01 a 07. Nesta ST, as falhas originadas totalizam 96 registros ocorridos no dia 07. No treinamento, os dados utilizados foram os dados anteriores ao período da falha.

A Figura 37 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável umidade relativa do ar da estação agrometeorológica de Castro.

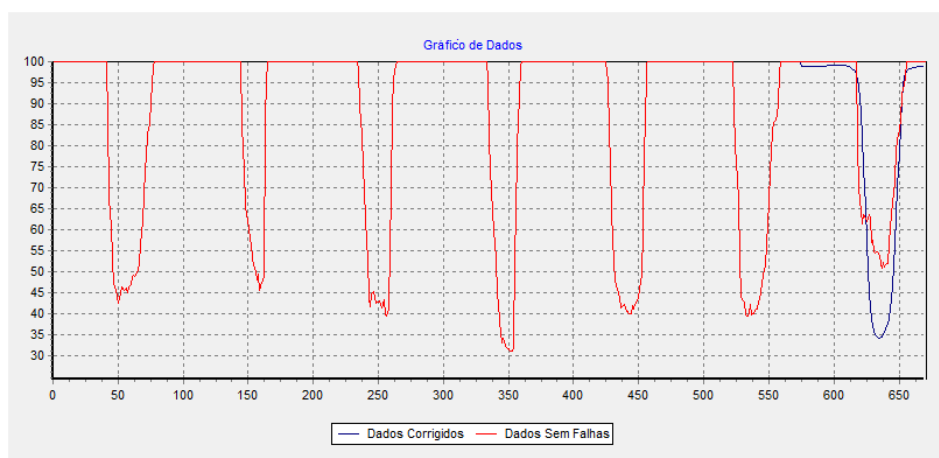


Figura 37 - Estudo de Caso 6 - Umidade relativa, Castro

A Figura 38 apresenta o gráfico do tratamento dos 96 registros em comparação com os dados sem a falha para variável umidade relativa do ar da estação agrometeorológica de Ponta Grossa.




Figura 38 - Estudo de Caso 6 - Umidade relativa, Ponta Grossa

Na Tabela 9, estão ilustrados o percentual de acerto encontrado no tratamento dos registros deste estudo de caso, a média dos erros da rede neural, bem como o coeficiente de correlação de Pearson existente entre os dados tratados e os dados sem falhas. Também está descrita a arquitetura de RNA utilizada no tratamento das informações, a quantidade de ciclos e o tempo que levou cada procedimento.

Tabela 9 - Resultado: Estudo de Caso 6

ESTAÇÃO	RNA	TX - AP	INÉRCIA	CICLOS	MÉDIA DE ERRO DA REDE	% DE ACERTOS	CORRELAÇÃO	TEMPO
Castro	96-1-96	90	30	30	0,011182	89,7	0,94	5 min
PG	96-1-96	90	30	30	0,004781	88,8	0,95	4 min

Observa-se, na Tabela 9, que o resultado obtido no tratamento dos registros com falha da variável temperatura média da ST da estação agrometeorológica de Castro utilizando RNA, apresentou percentual de acerto de 89,7%, um coeficiente de correlação entre a ST tratada e a ST sem falha de 0,94 e a média dos erros da rede neural foi de 0,011182. No tratamento da ST contendo informações da estação agrometeorológica de Ponta Grossa, obteve-se percentual de acerto de 88,8%, um coeficiente de correlação de 0,95 e a média dos erros da rede neural foi de 0,004781.

Para variável agrometeorológica temperatura média, a RNA, no melhor estudo de caso, apresentou no tratamento da ST, um percentual de acerto entre os registros tratados e os registros sem as falhas de 96,5%, um coeficiente de correlação de Pearson de 0,98 e a média dos erros da rede neural de 0,026406. Já para

variável agrometeorológica umidade relativa do ar, o melhor resultado foi de 95,7%, com um coeficiente de correlação de 0,97 e a média dos erros da rede neural de 0,094298.

4.2 DISCUSSÕES

Para variável agrometeorológica temperatura média, o melhor resultado foi encontrado no estudo de caso 1 para a estação agrometeorológica de Castro, onde a comparação dos registros tratados pela RNA e os registros correspondentes sem as falhas, apresentaram percentual de acerto de 96,5 %, um coeficiente de correlação de Pearson de 0,98 e a média dos erros da rede neural foi de 0,026406.

Já o pior resultado foi obtido no estudo de caso 3 para os dados da estação agrometeorológica de Ponta Grossa, com um percentual de acerto de 81,2%, um coeficiente de correlação de 0,49 e a média dos erros da RNA de 0,010184. Um fator que contribuiu para determinar esse resultado foi o fato de que a ST utilizada no treinamento da RNA, era descontínua. Entretanto, ao utilizar o método baseado em Chibana *et al.* (2005) no treinamento da RNA (estudo de caso 4) para os dados da mesma estação agrometeorológica, obteve-se percentual de acerto de 91,3%, um coeficiente de correlação de 0,76, e a média dos erros da RNA de 0,016101, ratificando o estudo realizado pelo autor supracitado, ou seja, utilizar na correção de ST uma base de dados formada por dados coletados em um mesmo período de tempo, de uma estação agrometeorológica próxima, pode gerar melhores resultados.

Nos estudos de caso da variável agrometeorológica umidade relativa do ar, o melhor resultado foi obtido no estudo de caso 5, no tratamento dos dados da estação agrometeorológica de Castro apresentando um percentual de acerto de 95,7%, um coeficiente de correlação de 0,97 e a média dos erros da RNA de 0,094298.

O pior resultado para variável agrometeorológica umidade relativa do ar foi encontrado no estudo de caso 6, no tratamento dos dados da estação agrometeorológica de Ponta Grossa, onde o percentual de acerto foi 88,8%, o coeficiente de correlação foi 0,95 e a média dos erros da rede neural foi de 0,004781.

Ainda tratando do estudo de caso 6, percebeu-se que o valor da porcentagem do acerto para o tratamento dos dados da estação agrometeorológica de Castro foi maior do que o de Ponta Grossa, porém a correlação dos resultados obtidos

no tratamento dos dados agrometeorológicos da estação de Ponta Grossa foi melhor. Isso ocorreu devido aos valores tratados na estação de Ponta Grossa apresentarem uma relação entre eles melhor do que o tratamento dos dados da estação de Castro, embora registrasse percentagem de acertos mais elevada.

Para todos os estudos de caso apresentados foram utilizadas ST contendo registros correspondentes a 7 dias de observações, sendo que no sétimo dia foram simuladas falhas. Durante o estudo, outros testes foram realizados utilizando uma quantidade menor de registro, entretanto, os resultados obtidos não foram satisfatórios. Observou-se também que utilizando períodos maiores que 7 dias, os resultados não apresentaram melhoras consideráveis e o tempo levado no processo de treinamento foi maior.

A definição dos parâmetros utilizados na correção das ST para a obtenção dos melhores resultados, foi realizado de forma gradual, tomando por base os parâmetros utilizados em trabalhos como os de Dias *et al.* (2007) e Tampelini (2008) que utilizaram RNA para fazer previsões em ST. A partir desses parâmetros foram elaboradas outras arquiteturas de RNA, a fim de obter os melhores resultados.

Para o tratamento de ST da variável agrometeorológica temperatura média, os testes iniciaram-se utilizando na composição da arquitetura da RNA uma camada oculta e foram feitas variações na quantidade de neurônios da camada de entrada, na quantidade de neurônios da camada oculta e na quantidade de ciclos de treinamento. Resultados satisfatórios foram encontrados utilizando na arquitetura da RNA apenas uma camada oculta, todavia, o tempo em que a RNA levou para fazer a correção da ST (maior que 24 horas), inviabilizou seu uso em algumas situações. Esse tempo elevado deu-se em função da quantidade de ciclo necessárias (mais de 50.000) para se obter uma correção com precisão equivalente aos estudos de caso demonstrados para variável agrometeorológica temperatura média.

Em situações onde a ST da variável temperatura média utilizada no treinamento da RNA, não apresentavam regularidade em sua sazonalidade, a arquitetura de RNA que apresentou melhores resultados foi formada por 1 camada oculta, e ocorreram variações na quantidade de neurônios da camada de entrada, na quantidade de neurônios da camada oculta e na quantidade de ciclos de treinamento, para se obter melhores resultados na correção da ST.

Por outro lado, em situações em que essa variável apresentou regularidade na sazonalidade no período utilizado para o treinamento da RNA, os melhores resul-

tados foram encontrados utilizando-se uma arquitetura de RNA com 3 camadas ocultas, variando-se a quantidade de neurônios da camada de entrada, a quantidade de neurônios das camadas ocultas, bem como a quantidade de ciclos de treinamento.

Já para variável agrometeorológica umidade relativa do ar, os resultados apresentados não foram satisfatórios ao utilizar na correção da ST a mesma arquitetura de RNA com 3 camadas ocultas, que apresentaram melhores resultados para a variável temperatura média, pois o comportamento apresentado entre a ST de diferentes variáveis agrometeorológicas, não são semelhantes.

Para variável agrometeorológica umidade relativa do ar, a arquitetura de rede neural que apresentou melhores resultados foi formada por apenas uma camada oculta e uma quantidade de 30 ciclos de treinamento, variando apenas a quantidade de neurônios da camada de entrada e a quantidade de neurônios da camada oculta. Outro diferencial ao comparar a correção da ST da variável temperatura média e umidade relativa do ar, é o tempo de processamento levado para obtenção da correção da ST. Enquanto a variável agrometeorológica temperatura média variou entre 8 minutos e 3 horas e 24 minutos, para a umidade relativa do ar a variação foi de 4 minutos e 18 minutos.

O principal fator que influenciou na qualidade do resultado do tratamento dos dados pela RNA, para todos os estudos de caso, foi a ST utilizada no treinamento em comparação ao período a ser tratado. Quanto maior a similaridade dos dados de treinamento com os dados a serem tratados, melhor foi o resultado. Isso ocorreu porque a metodologia desenvolvida no sistema, para o treinamento dos dados, utilizou registros de uma única variável nos neurônios de entrada da RNA.

Outra situação verificada foi o fato de que, para obtenção de melhores resultados, não foi possível utilizar uma configuração padrão dos parâmetros da RNA, ou seja, a maioria dos resultados obtidos nos estudos de caso, utilizaram arquitetura de RNA e parâmetros de treinamento distintos, como pode-se observar na Tabela 10.

Tabela 10 - Parâmetros da RNA para cada ST tratada

ESTUDO DE CASO	ESTAÇÃO	VARIÁVEL	ARQUITETURA DA RNA	CICLOS	MÉDIA DE ERRO DA REDE	% DE ACERTOS	CORRELAÇÃO
1	Castro	TM	480-3-60	100	0,026406	96,5	0,98
1	PG	TM	480-3-60	50	0,017985	94,7	0,93
2	Castro	TM	288-3-200	100	0,030647	87,5	0,95
2	PG	TM	480-3-90	100	0,012400	90,8	0,96
3	Castro	TM	384-1-384	200	0,010605	89	0,72
3	PG	TM	384-1-384	30	0,010184	81,2	0,49
4	Castro	TM	384-1-60	100	0,016101	91,6	0,85
4	PG	TM	384-1-384	30	0,015609	91,3	0,76
5	Castro	UR	96-1-96	30	0,094298	95,7	0,97
5	PG	UR	192-1-192	30	0,024899	94,1	0,86
6	Castro	UR	96-1-96	30	0,011182	89,7	0,94
6	PG	UR	96-1-96	30	0,004781	88,8	0,95

Nota-se, na tabela 10, que no tratamento dos registros de cada ST, a arquitetura da RNA apresentou uma variação de 96 a 480 para as entradas da RNA, o número de camadas ocultas variou de 1 a 3 e a quantidade de neurônios nas camadas ocultas foi de 60 a 384. No treinamento da RNA, a quantidade de ciclos teve variação de 30 a 200 e as únicas variáveis que permaneceram com os mesmos valores foram a taxa de aprendizado (90) e a inércia (30).

O sistema computacional foi desenvolvido para ser utilizado em computadores pessoais como os *desktops* e *laptops*. Sabe-se que esses equipamentos possuem diferentes velocidades, tecnologias de processamento, capacidade de memória RAM, o que pode interferir no desempenho do processo executado pelo sistema computacional. Neste trabalho, para todos os estudos de caso, os resultados foram obtidos utilizando um notebook Sony Vaio PCG-71312L, Core i5 M430 2,27 GHz, com 4 GB de RAM, em ambiente Windows Seven Home Premium.

Cabe considerar que a utilização de equipamentos e tecnologias que propiciem maior poder de processamento como a utilização de servidores, processamento em paralelo, computação em nuvem podem favorecer a obtenção de melhores resultados na correção de ST de dados agrometeorológicos.

Como o desenvolvimento das RNAs é um processo de aprendizado de máquina, o número de ciclos, a combinação de parâmetros, o tamanho e valores das ST utilizadas, e o tamanho das RNAs geram distintas velocidades e tempo de processamento. Neste estudo, o tempo necessário para obtenção do tratamento dos dados agrometeorológicos variou entre 4 minutos e 3 horas e 24 minutos.

5 CONCLUSÕES E TRABALHOS FUTUROS

De acordo com os estudos de caso descritos, para a variável agrometeorológica temperatura média, o estudo de caso 1 da estação agrometeorológica de Castro, foi o que apresentou o melhor resultado com um percentual de acerto entre os registros tratados e os registros sem falha de 96,5%, um coeficiente de correlação de Pearson de 0,98 e uma média simples entre os erros obtidos nos treinamentos da rede neural de 0,026406. Para variável agrometeorológica umidade relativa do ar, o melhor resultado encontrado foi o estudo de caso 5 da estação agrometeorológica de Castro, com um percentual de acerto de 95,7%, um coeficiente de correlação de Pearson de 0,97 e a média simples dos erros da rede neural de 0,094298.

Diante do exposto, foi possível perceber que o tratamento das variáveis agrometeorológicas temperatura média e umidade relativa do ar, utilizando o sistema desenvolvido STST Agrometeorológica, com a tecnologia de RNAs e o algoritmo de treinamento *backpropagation*, é uma alternativa viável no tratamento de falhas em ST de informações agrometeorológicas, uma vez que obteve-se resultados com percentual de acerto superior a 95% no tratamento de falhas das séries temporais estudadas.

Frente aos resultados obtidos e a operacionalidade do sistema STST Agrometeorológicas, propõe-se como trabalhos futuros:

- Desenvolver a arquitetura da RNA, utilizando como entrada da rede mais de uma variável agrometeorológica, permitindo que variáveis correlatas no tratamento de determinada ST possam auxiliar na obtenção de melhores resultados.
- Criar um sistema que auxilie na configuração dos parâmetros da RNA, através do armazenamento de informações de experimentos anteriores, cujo resultado do tratamento de variáveis agrometeorológicas foi satisfatório.
- Desenvolver o STST Agrometeorológicas, na linguagem de programação Java, visando a portabilidade e licença de uso por ser gratuita.

REFERÊNCIAS

ABELÉM, A. J. G. **Redes neurais artificiais na previsão de séries temporais**. 1994. Dissertação. 100p. (Mestrado em Engenharia Elétrica), Departamento de Engenharia Elétrica, Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 1994.

ASSIS, J. P. *et al.* Simulação estocástica de atributos do clima e da produtividade potencial de milho utilizando-se distribuição triangular. **Pesq. Agropec. Bras.** v.41, n.3, p. 539-543, mar. 2006.

BÍSCARO, G. A. **Meteorologia Agrícola Básica**. Mato Grosso do Sul: UNIGRAF, 2007.

BRAGA, A. P.; LUDIMIR, B. T.; CARVALHO, A. C. **Redes Neurais Artificiais - Teoria e Aplicações**. Rio de Janeiro: LTC, 2000.

BURIOL, G. A. *et al.* Homogeneidade e Estatísticas Descritivas dos Totais Mensais e Anuais de Chuva de Santa Maria, Estado do Rio Grande do Sul. **Rev. Bras. Rec. Hídricos.**, v.11, n.4, p.89-97, dez. 2006.

CARVALHO, L. G. de; *et al.* Modelo de regressão para a previsão de produtividade de cafeeiros no Estado de Minas Gerais. **Rev. Bras. Eng. Agríc. Ambient.**, v.8, n.2-3, p. 204-211, 2004.

CAUDILL, M. **Neural Network Primer**. San Francisco: Miller Freeman Publications, 1990.

CAWSEY, A. **The essence of artificial intelligence**. Old Tappan. NJ: Pearson Printers, 1998.

CHIBANA, E. Y. *et al.* Estimativa de falhas em dados meteorológicos. **V Congresso Brasileiro de Agroinformática, SBI-AGRO**. Londrina 28 a 30 set. 2005.

COPPIN, B. **Inteligência artificial**. Tradução de Jorge Duarte Pires Valério. Rio de Janeiro: LTC, 2010.

CPTEC - Centro de Previsão do Tempo e Estudos Climáticos. Disponível em: <<http://www.cptec.inpe.br/>>. Acesso em 13 jan. 2012.

DIAS, A. H. *et al.* Aplicação de Redes Neurais Artificiais Topologia MLP em Simulação de Dados Radiométricos. **Revista Brasileira de Agrocomputação**. Ponta Grossa, v. 2, n. 2, dez. 2007.

EHLERS, R. S. **Análise de Séries Temporais**. 4^o ed, Laboratório de Estatística e Geoinformação, Departamento de Estatística, UFPR, Curitiba, PR, 2007. Disponível em: <<http://leg.ufpr.br/~chlers/notas/stemp.pdf>>. Acesso em 20 de fevereiro de 2012.

FILHO, J. S. V.; LEITE, M. L.; CATANEO, A. Avaliação de Dois Simuladores de Dados Climáticos na Geração de Dados Diários de Radiação Solar Global. **V Congresso Brasileiro de Agroinformática, SBI-AGRO**. Londrina 28 a 30 set. 2005.

FUNDAÇÃO ABC. Objetivos. Disponível em: <<http://sma.fundacaoabc.org.br/conheca/objetivos>>. Acesso em: 12 jan. 2012.

GUIMARÃES, A. M. **Aplicação de computação evolucionária na mineração de dados físico-químicos da água e do solo**, 2005. 127 f. Tese. (Doutorado em Agronomia – Energia na Agricultura), Universidade Estadual Paulista – UNESP, Botucatu, 2005.

HAYKIN, S. **Redes neurais princípios e prática**. Porto Alegre, Bookman, 2001, 900p.

IAPAR - Instituto Agronômico do Paraná. Estações Meteorológicas do Paraná Histórico. Disponível em: <<http://www.iapar.br/modules/conteudo/conteudo.php?conteudo=889>>. Acesso em 21 jan. 2012.

LEVY, P. **As Tecnologias da Inteligência**. Tradução de Carlos Irineu da Costa. Rio de Janeiro: 34, 1993.

MATHIAS, I. M. **Aplicação de Redes Neurais Artificiais na Análise de Dados de Molhamento Foliar por Orvalho**. 2006, 120 f. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agronômicas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, Botucatu, 2006.

MAVI, H. S.; TUPPER, G. J. **Agrometeorology: principles and applications of climate studies in agriculture**. New York: Food Products Press, 2004, 364p.

MEDEIROS, J. S. de. **Bancos de geográficos e redes neurais artificiais: tecnologias de apoio à decisão do território**. 1999. 217p. Tese (Doutorado em Ciências: Geografia Física), Universidade de São Paulo, Faculdade de Filosofia, Letras e Ciências Humanas, Departamento de Geografia, São Paulo, 1999.

MEDEIROS, L. F. de. **Redes neurais em delphi**. 2. Ed. Florianópolis: Visual Books Editora, 2006, 205p.

MENDENHALL, W.; REINMUTH, J. E. **Statistic for management and economics**. 7. ed. E.U.A: Wadsworth inc, 1993.

MORETO, M. **Localização de Falhas de Alta Impedância em Sistemas de Distribuição de Energia: Uma Metodologia Baseada em Redes Neurais Artificiais**. 2005. 121 f. Dissertação (Mestrado em Engenharia Elétrica) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.

MORETTIN, P. A.; TOLOI, C. M. C. **Previsão de séries temporais**. 2. Ed. São Paulo: editora Atual, 1985. 531p.

NASCIMENTO JR, C. L.; YONEYAMA, T. **Inteligência artificial em controle e automação**. São Paulo: Edgard Blucher: FAPESP, 2004.

OLIVEIRA, L. F. C. *et al.* Comparação de metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual. **Rev. Bras. Eng. Agríc. Ambient.**, v.14, n.11, p.1186-1192, ago. 2010.

OSÓRIO, F. S.; BITTENCOURT, J. R. Sistemas Inteligentes baseados em Redes Neurais Artificiais aplicados ao Processamento de Imagens, In: I WORKSHOP DE INTELIGÊNCIA ARTIFICIAL, 1., 2000, Santa Cruz do Sul. **Anais...** Santa Cruz do Sul: UNISC, 2000. p. 30.

PAULA, M. B. **Reconhecimento de palavras faladas utilizando redes neurais artificiais**. 2000. 97p. Monografia. (Bacharelado em Informática), Instituto de Física e Matemática, Universidade Federal de Pelotas, Pelotas, 2000.

PESSIS-PASTERNAK, G. **Do caos à inteligência artificial**: quando os cientistas se interrogam. Tradução de Luiz Paulo Rouanet. São Paulo: UNESP, 1993.

PESSOA, J. D. C.; FREIRE L. Redes Neurais para predição de variáveis climáticas relevantes para agricultura. **EMBRAPA - Comunicado Técnico**, São Paulo, n.23, p.1-7, 1998.

RABUSKE, R. A. **Inteligência artificial**. Florianópolis: UFSC, 1995. 240p.

RAMASUBRAMANIAN V. **Time series analysis**. New Delhi: Library Avenue, 2005.

RAYMOND, P. M. **Meteorological Data to Support Farming Needs**. Applied Agrometeorology. (2010).

REZENDE, S. O. **Sistemas Inteligentes**. Fundamentos e aplicações. Barueri, SP: Manole, 2005.

RIBEIRO, C. V.; GOLDSCHMIDT, R. R.; CHOREN, R. **Métodos para previsão de séries temporais e suas tendências de desenvolvimento**. 2009. 26p. Monografia. (Sistemas e Computação), Instituto Militar de Engenharia, Instituto Superior de Tecnologia do Rio de Janeiro, Rio de Janeiro, 2009.

RIBEIRO, L. N. **Rede Neural com retropropagação: uma aplicação na classificação de imagens de satélite**. 2003. 131 f. Dissertação. (Mestrado em Estatística), Departamento de Computação e Estatística, Universidade Federal do Mato Grosso do Sul - UFMS, Campo Grande, 2003.

RICHARDSON, C.W.; WRIGHT, D.A. **WGEN: A model for generating daily weather variables**. U.S. Department of Agriculture, Agriculture Research Service, Washington, D.C., ARS-8, p.88, 1984.

ROSA, G. M. **Comunicação Seletiva de Mesclas Binárias e sua Simulação Por Redes Neurais Artificiais**. 2009. 140 f. Dissertação (Mestrado em Engenharia Mineral) – Programa de Pós-Graduação em Engenharia Mineral, Universidade Federal de Ouro Preto – UFOP, Ouro Preto, 2009.

RUSSELL, S; NORVIG, P. **Inteligência Artificial**. Tradução de PubliCare Consultoria. 2. ed. Rio de Janeiro: Elsevier, 2004.

SANTOS, A. M. *et al.* Usando Redes Neurais Artificiais e Regressão Logística na Predição da Hepatite A. **Rev. Bras. Epidemiol.**, v. 8, n. 2, p. 117-126, jun. 2005.

SENTELHAS, P. C.; MONTEIRO, J. E. B. A. **Agrometeorologia dos Cultivos: Informações para um Agricultura Sustentável**. INMET, 2009. Disponível em: <<http://www.economia.esalq.usp.br/~les700alunos/edmar/agromet.pdf>>. Acesso em 8 de fevereiro de 2012.

SILVA, I. N. *et al.* Projeto e análise de uma rede neural para resolver problemas de programação dinâmica. **Sba Controle & Automação**, v.12, n.1, p.1-10, 2001.

SILVA, M. I. S.; GUIMARÃES, E. C.; TAVARES, M. Previsão da temperatura média de Uberlândia, MG, com modelos de séries temporais. **Rev. Bras. Eng. Agríc. Ambient.**, v.12, n.5, p. 480-485, jan. 2008.

SILVA, P. L. **Modelagem de Superfícies Seletivas de Frequência e Antenas de Microfita utilizando Redes Neurais Artificiais**. 2006. 63 f. Dissertação (Mestrado de Ciências) – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Norte, Natal, 2006.

SILVA, P. O. M. P. *et al.* Previsão de Séries Temporais Utilizando Lógica Nebulosa. In: CONGRESSO INTERNACIONAL DE GESTÃO DE TECNOLOGIA E SISTEMAS DE INFORMAÇÃO, 4., 2007, São Paulo. **Anais...** São Paulo: 4ºCONTECSI, 2007. p. 661-678.

SIVAKUMAR, M.V.K.; GOMMES, R.; BAIER, W. Agrometeorology and sustainable agriculture. *Agricultural and Forest Meteorology*. **Agricultural and Forest Meteorology**. v. 103, p. 11-26, 2000.

SOUZA, R. C. **Modelos Estruturais para Previsão de Séries Temporais: Abordagem Clássica e Bayesiana**. 17º Colóquio Brasileiro de Matemática. RJ: IMPA, 1989.

SOUZA, R. C. T. **Previsão de séries temporais utilizando rede neural treinada por filtro de Kalman e evolução diferencial**. 2008. 74 f. Dissertação. (Mestrado em Engenharia de Produção e Sistemas), Pontifícia Universidade Católica do Paraná, Curitiba, 2008.

STRECK, N. A. *et al.* Associação da variabilidade da precipitação pluvial em Santa Maria com a Oscilação Decadal do Pacífico. **Pesq. Agropec. Bras.**, v.44, n. 12, p. 1553-1561, dez. 2009.

TAMPELINI, L. G. **Uma Aplicação das Redes Neurais Artificiais de Elman e Time Delay Neural Network na Predição de Séries Temporais**. 2008, 57 f. Trabalho de Conclusão de Curso (Graduação Bacharelado em Informática) – Centro de Ciências Exatas e Tecnológica, Universidade Estadual do Oeste do Paraná, Cascavel, 2008.

TURBAN, E.; MCLEAN, E.; WETHERBE, J. **Tecnologia da informação para gestão**: transformando os negócios na economia digital. Tradução de John Wiley & Sons. 3. ed. São Paulo: Bookman, 2002.

VAREJÃO-SILVA, M. A. **Metodologia e Climatologia**. 2. ed. Pernambuco: [s.n], 2006. Disponível em: <http://www.icat.ufal.br/laboratorio/clima/data/uploads/pdf/METEOROLOGIA_E_CLIMATOLOGIA_VD2_Mar_2006.pdf>. Acesso em: 30 de jan. 2012.

APÊNDICE – O sistema computacional

O sistema computacional

O sistema computacional baseado em RNA com *perceptron* multicamadas aplicado no tratamento de ST agrometeorológicas, denominado de “Sistema para tratamento de Séries Temporais Agrometeorológicas” (STST Agrometeorológicas), ilustrado na Figura 39.



Figura 39 - Tela de apresentação do Sistema Computacional

A Figura 40 representa a tela principal do sistema em que são realizados todos os procedimentos para o tratamento dos registros com falhas da ST e a apresentação dos resultados do procedimento.

Figura 40 - Tela principal do sistema

A próxima etapa para o tratamento dos registros é acessar o menu principal do sistema. Nele tem-se as opções “Geral” e “Sobre”. No menu “Geral” tem as opções de “Carregar”, “Limpar” e “Sair”. Nota-se na Figura 41 que em um primeiro momento as opções “Carregar” e “Sair” estão habilitadas para uso e a opção “Limpar” não pode ser utilizada nessa etapa do procedimento.

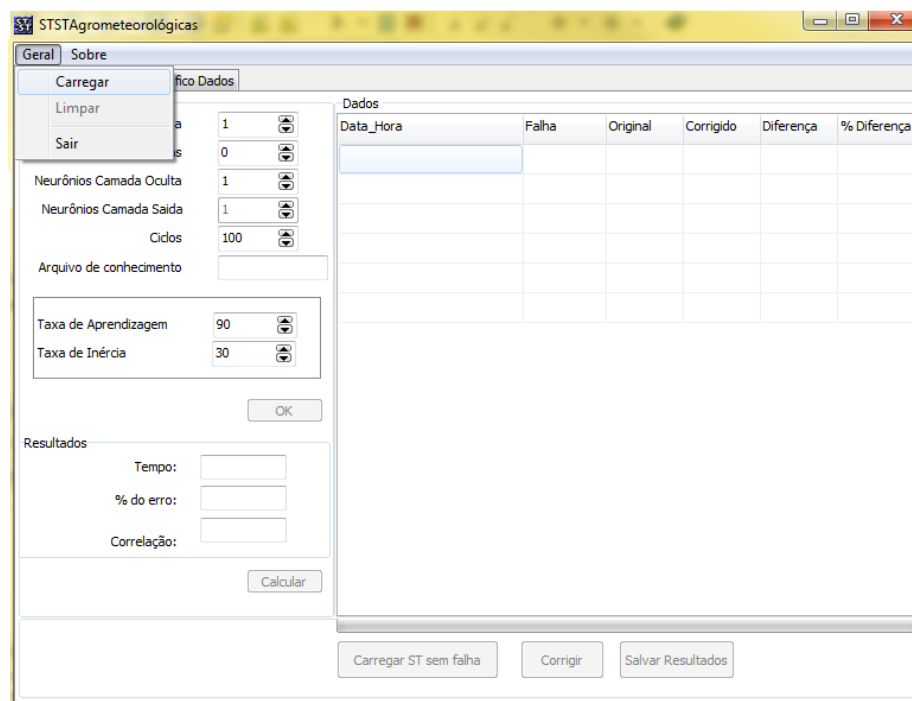


Figura 41 - Menu principal do sistema

Ao clicar no menu “Geral” e, em seguida, no item “Carregar” insere-se no sistema a ST com registros contendo as falhas a serem tratadas. Para o arquivo ser carregado corretamente, necessita ter a extensão CSV. A escolha desse tipo de arquivo foi feita pela facilidade de exportar dados de SGBD para esse formato, tornando possível a utilização de dados de estações agrometeorológicas sem se preocupar com a tecnologia de gerenciamento de arquivos ou método de armazenamento desses dados.

A opção “Sair” permite o fechamento do sistema em qualquer momento de sua execução.

A opção “Sobre”, (Figura 42) apresenta informações sobre o desenvolvimento do sistema.



Figura 42 - Informações encontradas na opção Sobre do menu principal

Na etapa ilustrada, Figura 43, o botão “OK” do item “Configuração” é habilitado, onde são definidos os parâmetros que serão utilizados no treinamento e a arquitetura da RNA. Também são inseridos os valores para os neurônios da camada de entrada, o número de camadas ocultas, a quantidade de neurônios destas camadas e a camada de saída é definida com valor “1”, respeitando a arquitetura de RNA a ser utilizada. Também são colocados valores para as variáveis de treinamento, como, a quantidade de ciclos, taxa de aprendizagem da RNA e taxa de inércia ou *momentum*. No parâmetro “Arquivo de conhecimento” é apresentado o nome do arquivo que foi carregado contendo a ST com a falha.

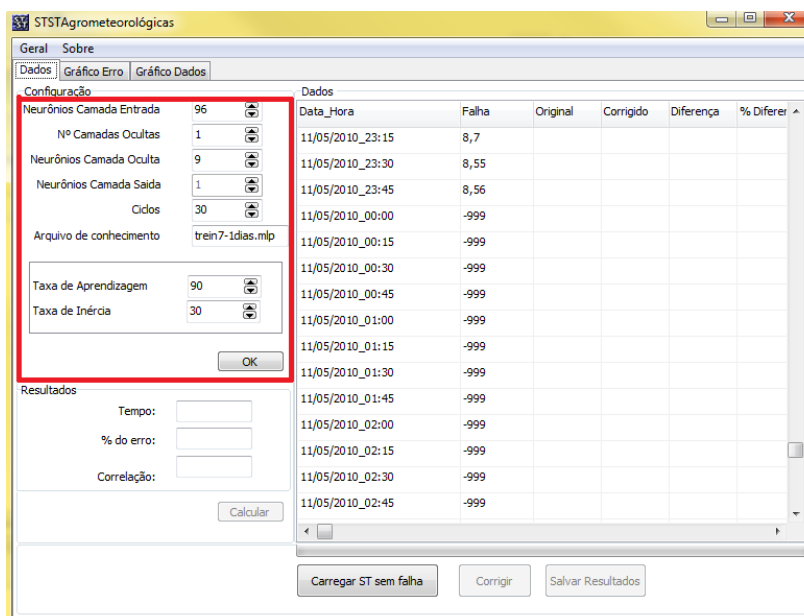


Figura 43 - Configuração dos parâmetros da RNA

O próximo procedimento é carregar a ST com os registros sem falhas, permitindo fazer a comparação dos valores dos registros tratados com os registros com falhas no final do procedimento de tratamento dos dados. A ST será mostrada na tabela do item “dados” na coluna “Original” (Figura 44).

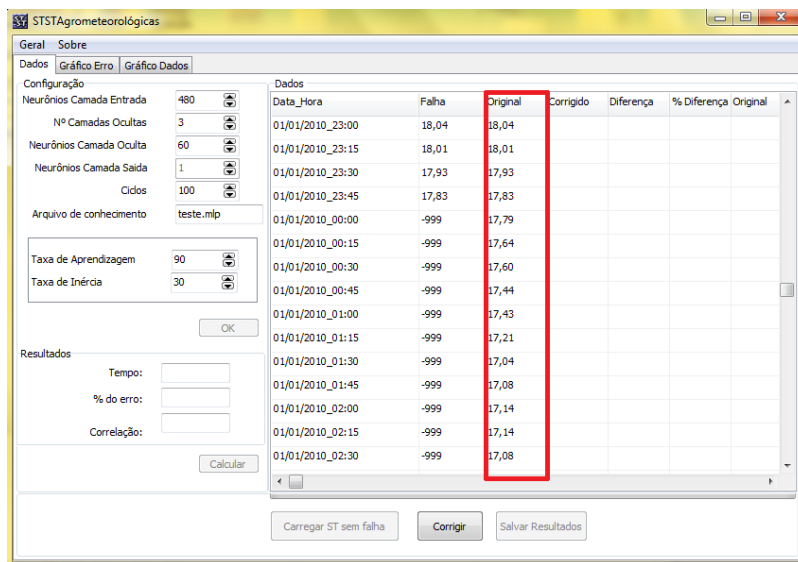


Figura 44 - Tela Carregar ST sem falha

Ao apertar o botão “Corrigir”, detalhe na Figura 45, será executado o treinamento e o tratamento dos registros com falhas. Nessa etapa são gerados os gráficos do erro para o treinamento de cada um dos registros a serem tratados. Esse gráfico pode ser observado alterando a aba “Dados” para “Gráfico do Erro”. Este procedimento está exemplificado na Figura 46.




Figura 45 - Gráfico do erro do treinamento da RNA

Após o treinamento, é gerado o gráfico contendo a ST tratada e a ST sem a falha (Figura 46), que permite fazer a comparação do resultado obtido pelo STST Agrometeorológicas.




Figura 46 - Gráfico comparando ST tratada com ST sem falha