

MARCOS ALBERTO BUSSAB

**MODELAGEM AMBIENTAL DE UMA CASA DE VEGETAÇÃO
UTILIZANDO REDE DE OSCILADORES DE VAN DER POL**

Tese apresentada à Escola Politécnica
da Universidade de São Paulo para
obtenção do Título de Doutor em
Engenharia Elétrica.

**São Paulo
2007**

MARCOS ALBERTO BUSSAB

**MODELAGEM AMBIENTAL DE UMA CASA DE VEGETAÇÃO
UTILIZANDO REDE DE OSCILADORES DE VAN DER POL**

Tese apresentada à Escola Politécnica
da Universidade de São Paulo para
obtenção do Título de Doutor em
Engenharia Elétrica.

Área de concentração:
Sistemas digitais

Orientador:
Prof. Dr. André Riyuiti Hirakawa

**São Paulo
2007**

FICHA CATALOGRÁFICA

Bussab, Marcos Alberto

Modelagem ambiental de uma casa de vegetação utilizando rede de osciladores de Van Der Pol / M.A. Bussab. -- São Paulo, 2007.

p.

Tese (Doutorado) - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Computação e Sistemas Digitais.

1.Estufas 2.Variáveis ambientais internas (Modelagem) 3.Osciladores I.Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Computação e Sistemas Digitais II.t.

DEDICATÓRIA

Dedico a minha família, em especial, a memória de meus pais Alberto e Amélia e a meu irmão Luiz Alberto.

AGRADECIMENTOS

Ao Prof. Dr. André Riyuiti Hirakawa, meu orientador, pelos conhecimentos, paciência, compreensão e sapiência no transcórre deste trabalho.

Ao Prof. Dr. Luiz Henrique Alves Monteiro, que orientou meu mestrado e onde começou esta jornada.

Aos Prof. Dr. André Felipe Henriques Librantz, Prof. Dr. Cleber Gustavo Dias, Prof. Dr. Júlio César Dutra, Profa. Cristina Koyama e Prof. Sidnei Alves de Araújo pelo apoio pessoal e científico.

Ao João Israel Bernardo pela amizade constante, em especial, nos momentos mais difíceis desta etapa.

A todos os membros do Laboratório de Automação Agrícola do Departamento de Engenharia de Computação e Sistemas Digitais da Escola Politécnica da Universidade de São Paulo.

Ao Jim Hesson, pelo apoio nos textos em inglês.

A Rafaela Ono pelo apoio na formatação e revisão.

A todos que oram por mim, nesta empreitada.

RESUMO

A automação agrícola tem se mostrado fator importante no desenvolvimento da produção nacional nas últimas décadas. A medição e controle das condições internas de casas de vegetação não são, muitas vezes, de fácil implementação e custo viável. Estudos e experiências nesta área procuram criar modelos que, utilizando-se de sistemas computacionais, estimem o comportamento de grandezas internas a uma casa de vegetação a partir da medida de grandezas externas. O objetivo deste trabalho é propor e avaliar a modelagem ambiental de uma casa de vegetação utilizando rede de osciladores de Van der Pol. A utilização de modelos confiáveis na previsão das condições internas de uma casa de vegetação é importante para melhorar a produtividade agrícola. A partir da literatura, foram levantados e estudados o modelo analítico e o modelo baseado em lógica nebulosa para a previsão da umidade relativa do ar e da temperatura interna da casa de vegetação. Um modelo baseado em rede neural multicamadas foi implementado como uma primeira alternativa. A substituição das funções de ativação comumente usadas neste tipo de modelo, pelas funções do oscilador de Van Der Pol, permite melhores resultados para processos não lineares e levou a uma satisfatória redução dos erros das estimativas, sem comprometer seu desempenho computacional. Os dados observados experimentalmente e estimados pelos modelos foram comparados a partir de critérios estatísticos. O erro relativo aos valores medidos para a grandeza temperatura variou entre 0,0% e 1,5%, enquanto o erro relativo aos valores medidos para a grandeza umidade relativa do ar variou entre 0,5% e 6,9%. O erro relativo aos valores medidos para ambas as grandezas apresentou um comportamento melhor do modelo proposto em relação aos modelos analíticos, baseado em lógica nebulosa e baseado em redes neurais. O desempenho computacional médio do modelo com osciladores de Van Der Pol, se comparado com o modelo baseado em redes neurais, considerando o número de iterações, degradou em 7,8%. Os resultados demonstram que

a modelagem utilizando rede de osciladores de Van der Pol é viável para a previsão de grandezas internas de uma casa de vegetação.

ABSTRACT

Agricultural automation is an important area in the development of Brazilian production in recent years. Often, measurement and control of the internal conditions of greenhouses are not easy to implement at a reasonable cost. Researches in this area look for models using computational theory, foreseeing the behavior of internal variables of a greenhouse from the measurement of external variables. The objective of this work is to consider and evaluate the environmental modeling of a greenhouse using a Van der Pol oscillator network. The use of trustworthy models for forecasting internal conditions of a greenhouse is important for improving agricultural productivity. Some researches present an analytical and fuzzy model used to forecast the relative humidity and internal temperature of a greenhouse. As first approach, a model based on a multilayer neural network was implemented. The neural network activation functions change for a Van Der Pol oscillator can produce better results when modeling non-linear process, and in this case, reduced estimate errors without compromising its computational performance. The measured experimental data and the estimated data were compared with statistical criteria. The relative error for the measured values of temperature varied from 0.0% through 1.5%, while the relative error of the measured values for the relative humidity varied from 0.5% through 6.9%. The relative error for both measured variables presented better behavior for the model considered in relation to the analytic, fuzzy, and neural network models. The average computational performance of the model with Van Der Pol oscillators, when compared with the neural network model, considering the number of iterations decreased approximately 7.8%. The results demonstrate that modeling based on Van der Pol oscillators is viable for forecasting the internal variables of a greenhouse.

LISTA DE FIGURAS

FIGURA 1: Foto ilustrativa de uma casa de vegetação	19
FIGURA 2: Exemplo de Neurônio Natural	21
FIGURA 3: Exemplo de Neurônio Artificial	22
FIGURA 4: Arquiteturas de redes neurais	31
FIGURA 5: Rede Hopfield com n elementos processadores	37
FIGURA 6: Rede de Hopfield com 8 estados possíveis	38
FIGURA 7: Estrutura de matriz para geração dos vetores de treinamento para a rede de Hopfield	39
FIGURA 8: Matriz para a geração do vetor de treinamento da rede de Hopfield – ‘L’	39
FIGURA 9: Matriz para a geração do vetor de treinamento da rede de Hopfield – ‘T’	39
FIGURA 10: Matriz para a geração do vetor de treinamento da rede de Hopfield – ‘+’	39
FIGURA 11: Padrão apresentado a rede de Hopfield	40
FIGURA 12: Padrões e a função de energia típica de uma rede de Hopfield	42
FIGURA 13: Esquema do modelo nebuloso para a casa de vegetação	60
FIGURA 14: Comparação da umidade relativa do ar interna medida e estimada pelos métodos analítico e nebuloso	62
FIGURA 15: Comparação da temperatura interna medida e estimada pelos métodos analítico e nebuloso	63
FIGURA 16: Esquema simplificado da rede neural proposta	68
FIGURA 17: Interface gráfica do Neural Networks Toolbox do MATLAB	70
FIGURA 18: Frequência de pares de valores estimados iguais aos valores medianos para o modelo com rede neural	71
FIGURA 19: Frequência de pares de valores estimados iguais aos valores medianos para o modelo com oscilador de Van Der Pol	73
FIGURA 20: Comportamento do valor medido e do valor estimado pela rede neural para a umidade relativa do ar	77

FIGURA 21: Comportamento do valor medido e do valor estimado pela rede neural para a temperatura	77
FIGURA 22: Erro relativo dos valores estimados pela rede neural para umidade relativa do ar e temperatura	78
FIGURA 23: Comparação do erro relativo da umidade relativa do ar obtido pela rede neural e pelo modelo analítico	79
FIGURA 24: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede neural e modelo analítico	79
FIGURA 25: Comparação do erro relativo da temperatura para a rede neural e para o modelo analítico	80
FIGURA 26: Quantidade de melhores resultados por modelo para a temperatura – rede neural e modelo analítico	81
FIGURA 27: Comparação do erro relativo da umidade relativa do ar para a rede neural e o modelo nebuloso	82
FIGURA 28: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede neural e modelo nebuloso	82
FIGURA 29: Comparação do erro relativo temperatura para a rede neural e o modelo nebuloso	83
FIGURA 30: Quantidade de melhores resultados por modelo para a temperatura – rede neural e modelo nebuloso	84
FIGURA 31: Comportamento do valor medido e do valor estimado pela rede de osciladores de Van Der Pol para a umidade relativa do ar	87
FIGURA 32: Comportamento do valor medido e do valor estimado pela rede de osciladores de Van Der Pol para a temperatura	87
FIGURA 33: Erro relativo dos valores estimados pela rede de osciladores de Van Der Pol para umidade relativa do ar e temperatura	88
FIGURA 34: Comparação do erro relativo da umidade relativa do ar para a rede de osciladores e o modelo analítico	89
FIGURA 35: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede de osciladores e modelo analítico	89

FIGURA 36: Comparação do erro relativo temperatura para a rede de osciladores e o modelo analítico	90
FIGURA 37: Quantidade de melhores resultados por modelo para a temperatura – rede de osciladores e modelo analítico	91
FIGURA 38: Comparação do erro relativo da umidade relativa do ar para a rede de osciladores e o modelo nebuloso	92
FIGURA 39: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede de osciladores e modelo nebuloso	93
FIGURA 40: Comparação do erro relativo temperatura para a rede de osciladores e o modelo nebuloso	93
FIGURA 41: Quantidade de melhores resultados por modelo para a temperatura – rede de osciladores e modelo nebuloso	94
FIGURA 42: Comparação do erro relativo da umidade relativa do ar para a rede de osciladores e a rede neural	95
FIGURA 43: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede de osciladores e rede de neural	95
FIGURA 44: Comparação do erro relativo temperatura para a rede de osciladores e a rede neural	96
FIGURA 45: Quantidade de melhores resultados por modelo para a temperatura – rede de osciladores e rede de neural	97
FIGURA 46: Quantidade de melhores resultados por modelo para a umidade relativa do ar	100
FIGURA 47: Quantidade de melhores resultados por modelo para a temperatura	100
FIGURA 48: Percentagem de melhores resultados para ao menos uma das grandezas por modelo	101
FIGURA 49: Percentagem de melhores resultados para as duas grandezas, simultaneamente, por modelo	102

LISTA DE TABELAS

TABELA 1: Vetores de treinamento para a rede de Hopfield	40
TABELA 2: Evolução da rede de Hopfield	41
TABELA 3: Medidas de erro	45
TABELA 4: Parâmetros do modelo analítico	55
TABELA 5: Dados estimados pelo modelo analítico	56
TABELA 6: Dados estimados pelo modelo analítico que correspondem aos conjuntos de teste	57
TABELA 7: Dados médios diários obtidos no período estudado	59
TABELA 8: Dados medidos, estimados pelo modelo analítico estimados pelo modelo nebulosa	61
TABELA 9: Dados estimados pelo modelo nebuloso que correspondem aos conjuntos de testes	64
TABELA 10: Número de dados utilizados para treinamento e teste da rede neural	64
TABELA 11: Tabela de dados para treinamento da rede neural	66
TABELA 12: Tabela de dados para teste da rede neural	67
TABELA 13: Resultados da simulação, utilizando-se a rede neural, das grandezas internas de uma casa de vegetação	75
TABELA 14: Resultados da simulação utilizando-se a rede neural das grandezas internas de uma casa de vegetação	76
TABELA 15: Resultados da simulação utilizando-se a rede de osciladores de Van Der Pol, das grandezas internas de uma casa de vegetação	85
TABELA 16: Erro relativo entre valores estimados pela rede de osciladores de Van Der Pol e valores medidos	86
TABELA 17: Tempo total de CPU para cada modelo	98

SUMÁRIO

1. INTRODUÇÃO	16
2. REVISÃO BIBLIOGRÁFICA	18
2.1 Casa de vegetação	18
2.2 Redes neurais artificiais	20
2.2.1 Conceitos básicos e evolução	20
2.2.2 Definição	23
2.2.3 Classificação e propriedades	24
2.2.4 Unidade de rede	29
2.2.5 Tipos de arquitetura de conexão das redes	30
2.2.6 Tipos de arquitetura de conexão das redes	35
2.2.7 Rede de Hopfield	36
2.2.8 Redes multilayer perceptron	43
2.3 Osciladores de Van Der Pol	46
3. MATERIAIS E MÉTODOS	49
3.1 Modelagem de casa de vegetação	49
3.2 Alternativas para modelagem da casa de vegetação	57
3.3 Base de dados medidos	58
3.4 Modelo nebuloso	60
3.5 Seleção de dados para as redes	64
3.5.1 Dados para treinamento	65
3.5.2 Dados para teste	66
3.6 Modelo com rede neural artificial	67
3.6.1 Definição do tipo e dos parâmetros da rede	67
3.6.2 Caixa de ferramentas computacionais	69
3.6.3 Código Fonte	70
3.6.4 Critério de seleção de dados para análise	71
3.7 Modelo com rede de osciladores de Van Der Pol	72
3.7.1 Critério de seleção de dados para análise	72
4. RESULTADOS E DISCUSSÕES	74
4.1 Rede neural multicamadas	74
4.1.1 Apresentação dos resultados estimados	74
4.1.2 Comparação entre os resultados da rede neural multicamadas e valores medidos	75
4.1.3 Comparação entre os resultados da rede neural multicamadas e da modelagem analítica	78
4.1.4 Comparação entre os resultados da rede neural multicamadas e da modelagem nebulosa	81
4.2 Rede de osciladores de Van Der Pol	84
4.2.1 Apresentação dos resultados estimados	84
4.2.2 Comparação entre os resultados da rede de osciladores de Van Der Pol e valores medidos	85
4.2.3 Comparação entre os resultados da rede de osciladores de Van Der Pol e da modelagem analítica	88
4.2.4 Comparação entre os resultados da rede de osciladores de Van Der Pol e da modelagem nebulosa	91

4.3	Comparação entre os resultados da rede de osciladores de Van Der Pol e da rede neural multicamadas.....	94
4.3.1	Valores estimados	94
4.3.2	Desempenho computacional	97
4.4	Comparação geral entre os resultados estimados.....	99
5.	CONSIDERAÇÕES FINAIS	103
5.1	Conclusões gerais.....	103
5.2	Contribuições e perspectivas.....	104
REFERÊNCIAS	106

1. INTRODUÇÃO

A tecnologia vem sendo requerida cada vez com maior intensidade nas atividades agropecuárias, em especial, naquelas de finalidade comercial. O profissional desta área necessita de sistemas de informação que possam apoiá-lo na tomada de decisões.

A decisão sobre ações a serem tomadas com relação à alteração das condições dentro de uma casa de vegetação deve ser rápida e eficiente, sob o risco de redução de produtividade e, portanto de lucros. A medição de grandezas, como, por exemplo, temperatura e umidade do ar, dentro de casas de vegetação não são fáceis e, por vezes, apresentam uma elevada relação custo-benefício.

Soluções analíticas vêm sendo propostas por especialistas, mas tem se mostrado pouco eficiente na solução da questão, pois, além de complexas não indicadas para esta classe de problemas.

Soluções na área de sistemas computacionais inteligentes são uma alternativa para essa classe de problemas. A aplicação inovadora de técnicas de inteligência artificial na melhoria de atividades ligadas a automação agrícola estão sendo pesquisadas, em especial, nas últimas duas décadas.

Conceitualmente, as técnicas de lógica nebulosa e redes neurais artificiais são mais adequadas à solução de problemas de comportamento não linear, como o da estimativa de grandezas dentro de uma casa de vegetação, do que a modelagem analítica.

A modelagem com redes neurais artificiais, no entanto, apresenta algumas restrições clássicas, como o do mínimo local, que vem sendo objeto de estudos e propostas. Modelos híbridos de redes neurais vêm sendo propostos para a superação desta restrição. (ENDO; CHUA; TAKEYAMA, 1991) apresentaram uma interessante alternativa. Eles criaram uma rede de Hopfield com osciladores de Van Der Pol. Esta rede foi usada, eficientemente, na solução de problemas como o do caixeiro viajante.

A modelagem de uma casa de vegetação é um problema de características diversas do problema do caixeiro viajante. Ambas podem ser

feitas com redes neurais artificiais, mas de tipos diferentes. O problema do caixeiro viajante utiliza-se da rede de Hopfield, enquanto a modelagem de uma casa de vegetação tem nas redes neurais multicamadas, o tipo de rede mais adequado.

Este trabalho tem como objetivo principal a proposta de uma modelagem ambiental de casas de vegetação com rede multicamadas de osciladores de Van Der Pol. A modelagem proposta visa ser menos complexa que a modelagem analítica. A solução apresentada busca, ainda, ser mais eficiente nas estimativas que as redes neurais artificiais, pela solução do problema dos mínimos locais.

Este texto está organizado em cinco capítulos. No segundo capítulo é feita uma revisão bibliográfica que contempla uma breve descrição de uma casa de vegetação, os principais conceitos sobre redes neurais pertinentes a implementação do trabalho, e a base matemática e teórica dos osciladores de Van Der Pol.

No terceiro capítulo são apresentados os métodos, procedimentos e recursos usados no desenvolvimento do trabalho. Neste capítulo, estão justificadas as opções feitas durante os procedimentos e sua sustentação científica.

No quarto capítulo são mostrados os resultados das diversas metodologias, em especial a proposta neste trabalho. Os resultados são analisados e comparados.

Finalmente, no quinto capítulo são apresentadas as conclusões oriundas dos resultados e de sua discussão, além de restrições e perspectivas futuras de continuidade do trabalho.

2. REVISÃO BIBLIOGRÁFICA

2.1 Casa de vegetação

A casa de vegetação é uma estrutura coberta e abrigada artificialmente com materiais transparentes para proteger as plantas contra os agentes meteorológicos exteriores, sendo que no seu interior pode-se cultivar os mais diversos tipos de plantas.

(OLIVEIRA, 1995) afirmou que há quatro tipos de estrutura de casa de vegetação: de vidro climatizadas; de vidro semi-climatizadas, produzindo o efeito estufa; casas de plástico semi-climatizadas, efeito estufa presente e casas de plástico tipo “guarda-chuva”, as quais não são climatizadas. Além das casas de vegetação, existem os chamados telados, que podem ser totalmente cobertos ou semi-cobertos, com as laterais livres, cobertos de plástico transparente, ou telas de cor branca, e às vezes verde, que deixam o vento passar parcialmente, e assim deve amenizar a temperatura interna. Para fins de pesquisa, a casa de vegetação deve ter, pelo menos, um ou dois pontos de água (irrigação), sistema de drenagem (ralos) e uma tomada de energia e iluminação artificial, para trabalhos noturnos. Toda casa de vegetação ou telado para a pesquisa, deve ter “bancadas” fixas (cimento e tijolos) ou móveis (hastes de ferro com estrado de madeira), com largura de cerca de 60,0 cm e comprimento variável de acordo com o tamanho (comprimento) da casa de vegetação. De uma bancada para outra, deve-se deixar uma distância de pelo menos 80,0 cm para a circulação. O piso poderá ser de cimento, em geral sem pintura ou de chão batido no caso de telados. É importante que a casa de vegetação tenha duas portas, uma em cada extremo (lados menores), e cobertura de duas águas como pode ser visto na FIGURA 1.

No caso de telados, deve-se dar preferência aos de plástico transparente (passagem da luz) e evitar as telas de cor, em especial a verde, pois reduz demais a luminosidade e a densidade do fluxo radiante no interior do ambiente, causando estiolamento, especialmente em espécies de metabolismo fotossintético C4 (eficientes) ou mesmo C3, que não se

saturam com o máximo da irradiância solar, em condições ecofisiológicas, como o algodoeiro herbáceo (*Gossypium hirsutum* L. raças latifolium Hutch.). No caso do algodoeiro ou plantas C4 como milho (*Zea mays* L.), sorgo (*Sorghum bicolor* (L.) Went) e outras, não devem ser usados telados verde, em um raio de 50 m, não deve haver árvores com altura superior a 5,0 m e nem construção próxima à casa de vegetação, para evitar interferências na luminosidade, radiação solar, ventos etc. (MAGALHÃES, 1979; BELTRÃO, 1997).

Em condições ecofisiológicas, em nível de campo, quanto a ambientes restritos, como o caso de casas de vegetação e telados, os princípios mesológicos funcionam plenamente (MOTA, 1976), em especial os dois primeiros, ou seja, os fatores limitantes, ampliação da lei do mínimo e o holocenotismo ambiental, que conduz a interações entre os fatores do ambiente e as reações complexas que ocorrem nas plantas, algumas desconhecidas, outras conhecidas, porém incontrolláveis (BELTRÃO, 1997). Vários fatores que podem ser evitados possibilitando a redução de erros devem ser levados em consideração, tanto na construção da casa de vegetação e/ou telado, quanto no planejamento para a condução experimental.



FIGURA 1: Foto ilustrativa de uma casa de vegetação

2.2 Redes neurais artificiais

2.2.1 Conceitos básicos e evolução

Segundo (FIESLER; BEALE, 1997), as redes neurais artificiais, também conhecidas como métodos conexionistas, são inspiradas nos estudos da maneira como se organiza e como funciona o cérebro humano. Este tipo de método possui características peculiares de representação e de aquisição de conhecimentos, sendo considerado um método de nível sub-simbólico, em oposição aos métodos simbólicos, tais como, árvores de decisão, sistemas baseados em casos e sistemas baseados em conhecimento.

Existem diferentes tipos de redes neurais artificiais e cada um destes modelos diferentes possui suas características próprias quanto à forma de representar e de adquirir conhecimentos.

A representação de conhecimentos nas redes conexionistas, como diz o próprio nome, é, fortemente, ligada à noção de conexão entre neurônios, que são elementos processadores de informação, que interagem uns com os outros através destas ligações. O modelo conexionista possui sua origem nos estudos feitos sobre as estruturas do cérebro humano, sofrendo uma grande simplificação do modelo original.

O conhecimento de uma rede neural artificial está codificado na estrutura da rede, onde se destacam as conexões, denominadas sinapses, entre as unidades, denominadas neurônios, que a compõe. Nestas redes artificiais obtidas por simulação em computadores, associa-se, a cada conexão um peso sináptico, que caracteriza a força da conexão entre dois neurônios. O aprendizado em uma rede neural artificial é realizado por um processo de adaptação dos seus pesos sinápticos. A FIGURA 2 e a FIGURA 3 mostram a relação entre os neurônios naturais e o modelo de neurônio artificial. Uma vez que os conhecimentos da rede estão codificados na estrutura de interconexões entre os neurônios e nos pesos associados a estas conexões, fica muito difícil para um ser humano realizar uma análise e

interpretação dos conhecimentos adquiridos por uma rede neural artificial, segundo (FIESLER; BEALE, 1997).




FIGURA 2: Exemplo de Neurônio Natural
Extraída de (OSÓRIO; VIEIRA, 1999)

Os conhecimentos das redes se resumem a um conjunto de valores numéricos descrevendo as conexões, e por conseqüência, estes valores descrevem, também, o comportamento da rede. Entretanto, para um ser humano, estes dados não fazem muito sentido. Os primeiros estudos sobre as Redes Neurais Artificiais e propostas de modelos destas redes surgiram nos anos 40. Os primeiros modelos evoluíram bastante, onde alguns deles se destacaram e tornaram-se famosos, mas mesmo assim até hoje continuam sendo propostos novos modelos de redes neurais. O estudo dos primeiros modelos e de sua evolução ajuda a entender melhor as redes neurais, e seu estágio atual de evolução. O começo do estudo das redes neurais artificiais pode ser atribuído à criação do Psychon, por (MCCULLOCH; PITTS, 1943), sendo que, alguns anos depois, (HEBB, 1949) publicou uma importante obra, o livro “The Organization of Behaviour”,

que influenciou vários modelos de redes neurais artificiais de destaque na atualidade.




FIGURA 3: Exemplo de Neurônio Artificial
Extraída de (OSÓRIO; VIEIRA, 1999)

O Perceptron, que foi criado por (ROSENBLATT, 1959), tem até hoje uma grande influência sobre os estudos das redes neurais, e mostrou que, apesar desta área de estudos ter crescido muito na atualidade, suas bases foram estruturadas juntamente com a criação dos fundamentos da ciência da computação. Alguns outros modelos similares ao Perceptron foram também desenvolvidos nesta época, como é o caso do Adaline – “Adaptive Linear Element”.

Somente na década de 80, surgiram novos modelos que impulsionaram as redes neurais. Em 1982 surgia um modelo importante de rede criado por Hopfield. O modelo que Hopfield criou era baseado em um

tipo de rede diferente dos modelos baseados no Perceptron, sendo uma rede com conexões recorrentes e com um comportamento baseado na competição entre os neurônios, onde o aprendizado era não supervisionado. A década de 80 ficou também marcada profundamente pelo reaparecimento das redes baseadas em Perceptrons. Isto se deveu ao desenvolvimento dos computadores, que eram mais velozes e permitiam realizar melhores simulações das redes neurais.

2.2.2 Definição

As redes conexionistas são formadas por um conjunto de unidades elementares de processamento de informações fortemente conectadas, que denominamos de neurônios artificiais. Segundo (FAUSETT, 1994), uma rede neural artificial é constituída por um grafo orientado e ponderado. Os nós deste grafo são autômatos simples, os chamados neurônios artificiais, que formam através de suas conexões um autômato mais complexo, a rede neural, também conhecida como rede conexionista.

Cada unidade da rede é dotada de um estado interno, denominado estado de ativação. As unidades podem propagar seu estado de ativação para as outras unidades do grafo, passando pelos arcos ponderados, denominados de conexões, ligações sinápticas ou simplesmente de pesos sinápticos. A regra que determina a ativação de um neurônio em função da influência vinda de suas entradas, ponderadas pelos seus respectivos pesos, se chama regra de ativação ou função de ativação. As mudanças realizadas nos valores dos pesos sinápticos ou na estrutura de interconexão das unidades de uma rede, são responsáveis pelas alterações no comportamento de ativação desta rede. Estas alterações nas conexões e na estrutura da rede é o que nos permite realizar o aprendizado de um novo comportamento. Desta maneira, pode se modificar o estado de ativação na saída da rede em resposta a determinada configuração de entradas. Portanto, a rede é capaz de estabelecer associações de entrada e saída ou estímulo e resposta a fim de se adaptar a uma situação proposta. No caso

de uma rede com aprendizado supervisionado, a rede deve adaptar os seus pesos de maneira a passar a responder de acordo com o exemplo dado, ou seja, gerando na sua saída um estado de ativação compatível para com o esperado. O método utilizado para modificar o comportamento de uma rede é denominado de regra de aprendizado.

2.2.3 Classificação e propriedades

A grande quantidade de modelos existentes conduz a uma análise de suas principais propriedades e diferenças em detrimento de uma análise caso a caso mais detalhada. O estudo das principais propriedades das redes neurais permite compreender melhor as vantagens e os inconvenientes da escolha de um modelo em detrimento de um outro. Não existe apenas uma maneira de classificar todos os modelos, mas de um modo geral devem ser considerados grupos de atributos, tais como: tipo de aprendizado, arquitetura de interconexões, forma interna de representação das informações e tipo de aplicação da rede.

O aprendizado conexionista é, conforme (FAUSETT, 1994), um processo gradual e iterativo, onde os pesos são modificados várias vezes, pouco a pouco, seguindo-se uma regra de aprendizado que estabelece a forma como estes pesos são alterados. O aprendizado é realizado utilizando-se um conjunto de dados de aprendizado disponíveis, chamada de base de exemplos. Cada iteração deste processo gradativo de adaptação dos pesos de uma rede neural, sendo feita uma apresentação completa do conjunto de dados, é chamada de época de aprendizado. Os métodos de aprendizado neural podem ser divididos em três grandes classes, segundo o grau de controle dado ao usuário:

- **Aprendizado supervisionado:** o usuário dispõe de um comportamento de referência preciso que ele deseja ensinar à rede. Sendo assim, a rede deve ser capaz de medir a diferença entre seu comportamento atual e o comportamento de referência e, então, corrigir os pesos de maneira a reduzir este

desvio de comportamento em relação aos exemplos de referência. O aprendizado supervisionado utiliza conhecimentos empíricos, habitualmente, representados por um conjunto de exemplos etiquetados, ou seja, exemplos com pares de dados de entrada com a respectiva saída associada. A tabela verdade de uma operação booleana do tipo AND pode ser considerada como um conjunto de exemplo de aprendizado, pois indica os valores de entrada e, também, a saída desejada. Nos casos de problemas de classificação, a saída é a classe à qual cada exemplo está associado. Como exemplo de aplicação, apresenta-se, conforme (OSÓRIO, 1999), o reconhecimento de caracteres de uma aplicação do tipo OCR – “Optical Character Recognition”.

- **Aprendizado semi-supervisionado:** o usuário possui apenas indicações imprecisas, como, por exemplo, sucesso ou insucesso da rede, sobre o comportamento final desejado. As técnicas de aprendizado semi-supervisionado são chamadas, também, de aprendizado por reforço – “reinforcement learning”, conforme (SUTTON 1998). Neste tipo de aprendizado, dispõe-se apenas de uma avaliação qualitativa do comportamento do sistema, sem, no entanto, poder medir, quantitativamente, o desvio de comportamento em relação ao comportamento de referência desejado. Como exemplo, apresenta-se aplicações em robótica autônoma, onde supondo uma situação hipotética, sabe-se que seguir em frente não é possível, pois existe um obstáculo, mas em compensação, não se tem uma medida numérica que indique para que lado seguir e exatamente como proceder-se para desviar desse obstáculo.
- **Aprendizado não-supervisionado:** os pesos da rede são modificados em função de critérios internos, tais como, por exemplo, a repetição de padrões de ativação em paralelo de vários neurônios. O comportamento resultante deste tipo de

aprendizado é, usualmente, comparado com técnicas de análise de dados empregadas na estatística, conhecidas como “clustering”. Como exemplo, apresenta-se a diferenciação de tomates de laranjas, segundo (KOHONEN, 1987), sem, no entanto, ter os exemplos com a sua respectiva classe etiquetada – “self-organizing feature maps”.

O aprendizado conexionista, conforme (HASSOUN, 1995), precisa de uma grande quantidade de dados, que são agrupados em uma base de aprendizado. De acordo com a técnica de aprendizado utilizada, outros conjuntos de dados podem ser necessários, principalmente, para que se possa medir a validade do aprendizado realizado pela rede, chamado de “cross-validation”. Este conjunto complementar de dados é, usualmente, chamado de conjunto de teste de generalização. Generalização é a capacidade de um modelo de aprendizado responder, corretamente, aos exemplos que lhe são apresentados, sendo que estes exemplos não devem estar presentes na base de aprendizado. Um modelo que tem uma boa generalização é aquele que responde, corretamente, aos exemplos contidos na base de aprendizado, mas, também, a outros exemplos diferentes daqueles da base de aprendizado, e que estão contidos em uma base de teste. A capacidade de generalizar é a principal capacidade buscada nas tarefas que envolvem aprendizado.

O aprendizado de um conjunto de dados, conforme (MENDEL; MCLAREN, 1970) podem ser realizados de diferentes formas, considerando-se a maneira pela qual a rede é alimentada por estes dados:

- Aprendizado instantâneo: o conjunto de dados de aprendizado é analisado uma única vez e com isto o conjunto de pesos da rede é determinado de maneira imediata em uma única passagem da base de exemplos. Este modo de aprendizado. Também é conhecido como “one single epoch learning / one shot learning”.

- **Aprendizado por pacotes:** o conjunto de dados de aprendizado é apresentado à rede várias vezes, de modo que se torne ótima a resposta da rede e reduzido seus erros na saída. Este modo de aprendizado é caracterizado por trabalhar com uma alteração dos pesos para cada época, ou seja, para cada passagem completa de todos os exemplos da base de aprendizado. O algoritmo de aprendizado deve reduzir pouco a pouco o erro de saída, o que é feito ao final de cada passagem da base de exemplos de aprendizado. Neste tipo de processo, pode-se apresentar os exemplos na ordem em que se encontram, ou de modo mais usual, apresentar os dados em uma ordem aleatória. Outros tipos de seleção de exemplos para análise pelo algoritmo de aprendizado levam a métodos como a aprendizagem ativa. Este método é conhecido pelo nome de “batch-learning” e constitui-se em um dos métodos mais utilizados.
- **Aprendizado contínuo:** o algoritmo de aprendizado leva em consideração, continuamente, os exemplos que lhe são repassados. Se o conjunto de dados é bem delimitado, denomina-se este método de aprendizado on-line, e caso o conjunto de dados possa ir aumentando pelo acréscimo de novos exemplos no decorrer do tempo, então, denomina-se este método de aprendizado incremental. O aprendizado on-line se opõe ao aprendizado por pacotes, pois, ao contrário deste, para cada novo exemplo analisado já se realiza uma adaptação dos pesos da rede, com o objetivo de convergir na direção do problema. O aprendizado contínuo incremental deve ser analisado sob o ponto de vista da aquisição dos dados (adição de novos exemplos na base de aprendizado), onde se deve prestar atenção para não confundir este tipo de aprendizado com o aprendizado incremental em relação à estrutura da rede (adição de novos neurônios no decorrer da

simulação). O principal problema do aprendizado contínuo é a dificuldade de achar um bom compromisso entre a plasticidade e a estabilidade da rede. Uma rede com uma grande facilidade de adaptação pode “esquecer”, rapidamente, os conhecimentos, anteriormente adquiridos e uma rede com uma grande estabilidade pode ser incapaz de incorporar novos conhecimentos.

- **Aprendizado ativo:** este modo de aprendizado assume que o algoritmo de adaptação da rede pode passar por uma posição passiva, apenas recebendo dados do jeito como lhe são passados, para uma posição ativa. Sendo assim, assume-se que este algoritmo poderá intervir sobre a forma como os dados lhe são repassados. Neste caso, a rede pode intervir e determinar quais dados serão considerados ou desconsiderados, além, também, de determinar a ordem em que estes dados deverão ser considerados. A rede pode, também, vir a solicitar novos dados que julgue necessários para o bom aprendizado do problema proposto.

A adaptação e otimização dos pesos, também, podem ser implementadas por diferentes métodos, segundo o tipo de regra de aprendizado que for empregado. As regras de aprendizado mais usadas são, segundo (OSÓRIO, 1999), as seguintes:

- Métodos de correção do erro, tais como a descida de uma superfície de erro baseada no gradiente. Exemplos de modelos deste tipo: Adaline, Perceptron, Back-Propagation, Cascade-Correlation;
- Métodos de aprendizado por reforço. Exemplos: Driver-Reinforcement Learning, AHC;
- Métodos de aprendizado por competição ou por auto-organização. Exemplos: Kohonen Self-Organizing Feature Maps, ART1;

- Métodos de aprendizado através da criação de protótipos ou clusters. Exemplos: RBF, ART1, ARN2;
- Métodos de aprendizado baseados em memórias associativas (auto-associativas ou hetero-associativas). Exemplos: Modelo de Hopfield, BAM;
- Métodos de aprendizado de seqüências temporais (redes recorrentes). Exemplos: SRN, BPTT, RTRL.

2.2.4 Unidade de rede

As unidades de uma rede, os neurônios artificiais, podem ser de diferentes tipos, de acordo com a função interna utilizada para calcular o seu estado de ativação. As principais diferenças são relativas ao tipo de função de ativação utilizada, como, por exemplo, linear, sigmóide assimétrica (exp), sigmóide simétrica (tanh) e gaussiana. Outro elemento importante diz respeito à forma como os neurônios armazenam as informações: unidades baseadas em protótipos, unidades do tipo Perceptron.

A rede à base de protótipos utiliza neurônios que servem para representar protótipos de exemplos aprendidos, onde as unidades têm uma representação interna que agrupa as características comuns e típicas de um grupo de exemplos. As redes baseadas em protótipos têm, normalmente, um aprendizado não supervisionado, com um ou mais protótipos associados a cada classe. Uma das vantagens deste tipo de rede é a possibilidade de fazer um aprendizado contínuo e incremental, uma vez que não é muito difícil conceber um algoritmo capaz de aumentar a rede neural através da adição de novos protótipos. Os protótipos são, também, denominados de clusters. Este tipo de redes gera uma representação dita localista de conhecimentos.

As Redes à base de Perceptrons foram criadas por Frank Rosenblatt na década de 50. Este é um dos modelos de neurônios mais utilizados na atualidade. Ele é a base de diversos tipos de Redes Neurais Artificiais com aprendizado supervisionado utilizando uma adaptação por correção de

erros, usualmente, baseada na descida da superfície de erro usando o gradiente. O modelo do Perceptron de múltiplas camadas, MLP – Multi-Layer Perceptron, tornou-se muito conhecido e aplicado, sendo a maior parte das vezes associado à regra de aprendizado do Back-Propagation.

2.2.5 Tipos de arquitetura de conexão das redes

As unidades de uma rede neural podem se conectar de diferentes modos, resultando em diferentes arquiteturas de interconexão de neurônios. As arquiteturas de redes mais importantes, segundo (HAUSSON, 1995), são:

- Redes com uma única camada: as unidades estão todas em um mesmo nível. Neste tipo de arquitetura, as unidades são conectadas diretamente às entradas externas e estas unidades servem, também, de saídas finais da rede. As redes de uma única camada possuem, normalmente, conexões laterais entre os neurônios de uma mesma camada. Um exemplo deste tipo de arquitetura são as redes do tipo “Self-Organizing Feature Maps”.
- Redes com camadas uni-direcionais: as unidades são organizadas em vários níveis bem definidos, que são chamados de camadas ou layers. A cada unidade de uma camada recebe suas entradas vindas a partir de uma camada precedente, e envia seus sinais de saídas em direção a camada seguinte. Estas redes são conhecidas como redes *feed-forward*.

A FIGURA 4 mostra os diferentes tipos de arquitetura de redes neurais.




FIGURA 4: Arquiteturas de redes neurais
Extraída de (OSÓRIO; VIEIRA, 1999)

O modelo MLP é composto, conforme (WIDROW, 1990), de uma arquitetura deste tipo, ou seja, com apenas uma camada oculta, mas nada impede que seja acrescentada mais uma camada oculta entre a camada de entrada e a camada de saída de uma rede. Um outro tipo de interconexão utilizado em redes unidirecionais são os atalhos que permitem a conexão de uma unidade à outra em uma camada posterior, passando por cima de outras camadas intermediárias. O uso desta técnica permite saltar por cima de uma camada até uma outra camada, com a condição de não introduzir uma recorrência na rede, o que descaracterizaria esta rede como sendo do tipo “feed-forward”.

- Redes recorrentes: as redes recorrentes podem ter uma ou mais camadas, mas a particularidade reside no fato de que há conexões que partem da saída de uma unidade em direção de

uma outra unidade da mesma camada ou de uma camada anterior a esta. Este tipo de conexão permite a criação de modelos que levam em consideração aspectos temporais e comportamentos dinâmicos, onde a saída de uma unidade depende de seu estado em um tempo anterior. Os laços internos, ao mesmo tempo em que dão características interessantes de memória e temporalidade às redes, tornam este tipo de redes muito instáveis, o que obriga o uso de algoritmos específicos e, usualmente, mais complexos, para o aprendizado destas redes. Um tipo particular de redes recorrentes são as redes totalmente conectadas, e um exemplo de modelo recorrente de uma única camada e totalmente conectado são as redes de Hopfield, que serão descritas, com mais detalhes adiante;

- Redes de ordem superior: as unidades deste tipo de rede permitem a conexão direta entre duas ou mais de suas entradas, antes mesmo de aplicar a função de cálculo da ativação da unidade. Este tipo de rede serve para modelar “sinapses de modulação”, ou seja, quando uma entrada pode agir sobre o sinal que vem de uma outra entrada.

A arquitetura de uma rede, também, pode ser classificada de acordo com a evolução desta no decorrer de sua utilização e desenvolvimento do aprendizado. Em função deste critério, apresentam-se os seguintes grupos, segundo (HAYKIN, 1994):

- Redes com estrutura estática: a rede tem a sua estrutura definida antes do início do aprendizado. A quantidade de neurônios e a sua estrutura de interconexões, não sofrem alterações durante a adaptação da rede. As únicas mudanças se realizam em nível dos pesos sinápticos, que são modificados durante o processo de aprendizado. Este tipo de modelo impõe uma dificuldade maior ao usuário: a

determinação do número ideal de neurônios e de conexões a serem utilizadas em uma determinada aplicação. Uma rede com poucas unidades e conexões tem forte chance de não ter sucesso em uma tarefa de aprendizado, não tendo condições de alcançar o melhor desempenho possível por falta de capacidade de representação de todos os conhecimentos envolvidos no problema tratado. Uma rede com muitas unidades pode ter, também, problemas de convergência e, principalmente, de generalização, pois quando se tem muita capacidade de armazenamento de informações em uma rede, esta tem uma tendência a decorar os exemplos no lugar de “aprendê-los”, ou seja, de generalizar os conhecimentos sobre o problema. No caso deste tipo específico de redes, não existe um método formal que permita determinar o número exato e ótimo de unidades e conexões a serem empregadas no aprendizado de um determinado problema.

- Redes com estruturas dinâmicas: as redes que possuem uma estrutura dinâmica são redes onde o número de unidades e conexões podem variar no decorrer do tempo. Estas redes são, também, chamadas de ontogênicas. As modificações na estrutura da rede podem ser do tipo generativo (incremental) ou do tipo destrutivo (reduzidor) por eliminação ou simplificação. A escolha entre estes dois tipos de métodos é bastante polêmica: deve-se começar com uma rede pequena e ir aumentando-a ou começar com uma rede bastante grande e ir reduzindo o seu tamanho, posteriormente. Do ponto de vista da carga de processamento de dados necessária para as simulações neurais, a opção por uma rede pequena, que adiciona, pouco a pouco, novas unidades e conexões, é a de melhor desempenho, pois, nas redes do tipo destrutivo, uma grande parte do esforço de aprendizado acaba, depois, sendo destruída, ao ser realizada a simplificação da rede. Apesar

desta discussão, sobre qual dos dois tipos de redes com estrutura dinâmica seria melhor usar, não possui um consenso, pode-se dizer que uma grande parte dos pesquisadores concorda que este, em geral, é um dos melhores métodos que existem para se escolher uma boa arquitetura para uma rede neural e assim resolver um determinado problema proposto.

O último ponto relevante em relação à arquitetura das redes neurais está relacionado à modularidade. As redes neurais podem trabalhar com arquiteturas modulares: elas podem ser construídas por blocos com uma maior ou menor dependência entre eles. Existem diferentes maneiras de integrar e fazer cooperar os diferentes módulos de uma rede neural. Um primeiro método consiste em decompor o problema e obter, assim, módulos especializados para cada subproblema. Um exemplo de aplicação deste tipo de método é o caso das aplicações de classificação em múltiplas classes, onde o problema de identificação de cada classe pode ser tratado por módulos separados e, então, no lugar de ter um único classificador para os N exemplos em M classes, têm-se um classificador para cada uma das M classes. Outro tipo de método usado pelas redes modulares, porém mais complexo de ser implementado, é aquele onde os diferentes módulos vão tentar cooperar entre si, a fim de em conjunto resolverem um problema. Neste tipo de método não são impostas tarefas particulares a módulos pré-especificados, deixando para a rede a tarefa de distribuir os conhecimentos e gerenciar a interação entre os módulos.

A modularidade é um problema relativo à escolha de uma arquitetura de rede, mas também, pode ser ligada ao problema de particionamento dos dados de aprendizado, em um esquema semelhante ao usado na aprendizagem ativa, onde cada módulo poderia escolher que informação fosse tratada. A modularidade pode se tornar um aspecto importante a ser considerado, segundo o tipo e a complexidade do problema a ser tratado.

2.2.6 Tipos de arquitetura de conexão das redes

As redes neurais artificiais podem ser aplicadas a diferentes tipos de tarefas, tais como: reconhecimento de padrões (reconhecimento de faces humanas), a classificação (reconhecimento de caracteres OCR), a transformação de dados (compressão de dados), a predição (previsão de séries temporais em cotação de bolsas de valores ou diagnóstico médico), o controle de processos e a aproximação de funções (aplicações na área de robótica). Todas essas tarefas podem ser reagrupadas em dois tipos principais, segundo o tipo de saída fornecido pela rede neural e o comportamento que se busca. Estes dois grupos são:

- Redes para a aproximação de funções: Segundo (HAYKIN, 1994), este tipo de rede deve ter uma saída com valores contínuos e, usualmente, são empregadas para realizar aproximações de funções (interpolação). Neste tipo de aplicações, as funções são representadas por um conjunto de pontos-exemplos. Este tipo de rede é capaz de aprender uma função de transformação de valores de entrada em valores de saída, usualmente, estimando por interpolação as respostas para os casos que não aparecem na base de exemplos. Este tipo de problema de aprendizado neural de funções é conhecido por ser uma aplicação de um problema de regressão, apresentado (FIESLER; BEALE, 1997) Em geral, as funções a serem aprendidas pelas redes possuem tanto entradas como saídas indicadas através de valores contínuos (variáveis não discretas);
- Redes para a classificação de padrões: Segundo (HAYKIN, 1994), este tipo de rede deve atribuir para cada exemplo que lhe é fornecido uma classe ao qual este exemplo pertence. Portanto, a saída da rede é a classe associada ao exemplo e por consequência, as classes são valores discretos e não contínuos. Segundo (BISHOP, 1995), a classificação é um

caso particular da aproximação de funções onde o valor de saída da rede é tornado discreto e pertence a um conjunto finito de classes. No caso do aprendizado supervisionado, o conjunto de classes é bem definido e conhecido antes de ser iniciado o processo de aprendizado. Uma rede utilizada para fins de classificação deve possuir saídas discretas, ou então, deve implementar métodos para tornar discretas de suas saídas, como, por exemplo, aplicação de um limiar de discriminação – “activation threshold”. As entradas da rede podem ser tanto contínuas como discretas. Isto não deve interferir no fato desta rede ser usada para uma aplicação de classificação.

2.2.7 Rede de Hopfield

A rede neural, proposta em (HOPFIELD, 1982) e (HOPFIELD; TANK, 1985) possui uma única camada de neurônios realimentados e implementa assim uma memória auto-associativa, isto é, ao ser apresentado um padrão de n bits a rede retorna um padrão armazenado de n bits que lhe é mais próximo, ou seja, que lhe é associado. Pela facilidade de treinamento e velocidade de operação a rede de Hopfield tem sido escolhida para implementações em VLSI.

Sistemas realimentados precisam ser projetados com cuidado, pois uma escolha inadequada dos pesos pode levar o sistema a apresentar comportamento instável. A escolha dos pesos da rede de Hopfield garante a sua estabilidade. A estrutura desta rede é mostrada na FIGURA 5.




FIGURA 5: Rede Hopfield com n elementos processadores
 Extraída de (BAUCHSPIESS , 2004)

A dinâmica da rede de Hopfield pode ser descrita pelo sistema de equações eq. (1).

$$\begin{cases} s_j^{(k)} = \sum_{i=1}^n w_{ij} y_i^{(k)} \\ y_j^{k+1} = f(s_j^{(k)}) \end{cases} \quad (1)$$

A rede de Hopfield pode ser inicializada como $y^{(0)} = x$ e o vetor de saída definido como $y^{(k)} = [y_i^{(k)}]$.

Para sistemas binários utiliza-se que:

$f(s_j)=1$, se $s_j > L_j$

$f(s_j)=0$, se $s_j < L_j$

$f(s_j)$ mantém o valor anterior, se $s_j = L_j$

Desta forma, segundo (MC ELIECE et al., 1987), a rede de Hopfield pode ser vista como um sistema IIR (Infinite Impulse Response) com entrada nula, uma vez que pode ser descrita por um conjunto de equações diferenciais. As formas de operação da Rede de Hopfield são assíncrona, síncrona, seqüencial.

Define-se o estado da rede como o conjunto de todas as saídas correntes, como, por exemplo, é mostrado na FIGURA 6.




FIGURA 6: Rede de Hopfield com 8 estados possíveis
Extraída de (BAUCHSPIESS, 2004)

Os padrões a serem armazenados na memória associativa são escolhidos à priori.

Assim, cada padrão pode ser definido como $A_p = [a_1^p, a_2^p \dots a_n^p]$ com $a_i^p = 0$ ou 1 , m padrões distintos e $L_i=0$, conforme eq.(2).

$$w_{ij} = \sum_{p=1}^m (2a_i^p - 1)(2a_j^p - 1) \quad (2)$$

A expressão $(2a_i^p - 1)$ converte 0 e 1 para -1 e $+1$. w_{ij} é incrementado de 1, se $a_i^p = a_j^p$, e diminuído de 1, caso contrário. Este procedimento é repetido para qualquer i e qualquer j e para todos os padrões A_p . Adicionar padrões à memória é um processo análogo ao reforço no ensino.

As FIGURA 7, 8, 9, 10 e a TABELA 1, a seguir, mostram um exemplo de treinamento para a rede de Hopfield.

a_1	a_2	A_3
a_4	a_5	A_6
a_7	a_8	A_9

FIGURA 7: Estrutura de matriz para geração dos vetores de treinamento para a rede de Hopfield

1		
1		
1	1	1

FIGURA 8: Matriz para a geração do vetor de treinamento da rede de Hopfield – ‘L’

1	1	1
	1	
	1	

FIGURA 9: Matriz para a geração do vetor de treinamento da rede de Hopfield – ‘T’

	1	
1	1	1
	1	

FIGURA 10: Matriz para a geração do vetor de treinamento da rede de Hopfield – ‘+’

Símbolo	Vetor de Treinamento
L	$A_1=[1\ 0\ 0\ 1\ 0\ 0\ 1\ 1\ 1]$
T	$A_2=[1\ 1\ 1\ 0\ 1\ 0\ 0\ 1\ 0]$
+	$A_3=[0\ 1\ 0\ 1\ 1\ 1\ 0\ 1\ 0]$

TABELA 1: Vetores de treinamento para a rede de Hopfield

A matriz de pesos, após o treinamento, possui a seguinte aparência:

$$W = \begin{bmatrix} 0 & -1 & 1 & -1 & -1 & -3 & 1 & 1 & 1 \\ -1 & 0 & 1 & -1 & 3 & 1 & -3 & 1 & -3 \\ 1 & 1 & 0 & -3 & 1 & -1 & -1 & -1 & -1 \\ -1 & -1 & -3 & 0 & -1 & 1 & 1 & 1 & 1 \\ -1 & 3 & 1 & -1 & 0 & 1 & -3 & 1 & -3 \\ -3 & 1 & -1 & 1 & 1 & 0 & -1 & -1 & -1 \\ 1 & -3 & -1 & 1 & -3 & -1 & 0 & -1 & 3 \\ 1 & 1 & -1 & 1 & 1 & -1 & -1 & 0 & -1 \\ 1 & -3 & -1 & 1 & -3 & -1 & 3 & -1 & 0 \end{bmatrix}$$

Considere-se, agora, o padrão mostrado na FIGURA 11, apresentado à rede.

1		1
1		
	1	1

FIGURA 11: Padrão apresentado a rede de Hopfield

Considerando a operação seqüencial, tem-se a evolução da rede, apresentada na TABELA 2.

EP disparado	Soma do EP	Saída do EP	Novo vetor de saída
1	2	1	101 100 011
2	-3	0	101 100 011
3	-4	0	100 100 011
4	1	1	100 100 011
5	-4	0	100 100 011
6	-4	0	100 100 011
7	4	1	100 100 111
8	0	1	100 100 111
9	4	1	100 100 111
1	2	1	100 100 111
2	-8	0	100 100 111

TABELA 2: Evolução da rede de Hopfield

Assim, após a convergência, a rede retorna o símbolo “L”, como aquele que está mais próximo ao padrão de entrada.

A FIGURA 12 ilustra o funcionamento da rede de Hopfield em termos de energia da rede.

Os padrões armazenados na Rede de Hopfield, de acordo com (MC ELIECE et al., 1987), são mínimos locais da função de energia (estados de equilíbrio). A partir de um padrão apresentado (valor inicial) a rede estabiliza no mínimo de energia de sua respectiva “bacia de atração”. Isto é, não se retorna necessariamente ao padrão mais próximo. Além disso, segundo (BALDI; HORNIK, 1989), pode acontecer de que haja mínimos locais não desejados, levando a rede a retornar padrões espúrios.




FIGURA 12: Padrões e a função de energia típica de uma rede de Hopfield
Extraída de Bauchspiess (2004)

A estabilidade da rede de Hopfield é determinada pela matriz $W = [w_{ij}]$. Cohen e Grossberg mostraram em 1983 que “se W é simétrica e sua diagonal principal é nula, então a rede recorrente é estável”. Esta é uma condição suficiente, mas não necessária para a estabilidade.

Conforme mostrado por (HOPFIELD, 1982), é possível associar um valor de energia para cada estado da rede. Esta energia varia de forma monotonicamente decrescente à medida que a rede evolui segundo a regra de atualização de suas saídas. A função de energia associada aos estados da rede é apresentada na eq.(3)

$$E = -\frac{1}{2} \sum_i \sum_j w_{ij} y_i y_j - \sum_j x_j y_j + \sum_j y_j L_j \quad (3)$$

Onde: E é a energia (artificial) associada ao estado da rede.

A variação da energia devido à variação do estado de um neurônio k é dada pela eq.(4)

$$\Delta E_k = -\frac{1}{2} \sum_{i \neq k} w_{ik} y_i \Delta y_k - \frac{1}{2} \sum_{j \neq k} w_{kj} \Delta y_k y_j - x_k \Delta y_k + \Delta y_k L_k \quad (4)$$

Tem-se, pela condição de simetria, a eq.(5)

$$\Delta E_k = - \sum_{i \neq k} w_{ij} y_i \Delta y_k - x_k \Delta y_k + \Delta y_k L_k \quad (5)$$

Modificando-se a eq.(5), obtém-se a eq.(6).

$$\Delta E_k = - \left[\sum_{i \neq k} w_{ij} y_i + x_k - L_k \right] \Delta y_k \quad (6)$$

Finalmente, de acordo com a dinâmica de Hopfield, têm-se a eq.(7)

$$\Delta E_k = - [s_k - L_k] \Delta y_k \quad (7)$$

A partir da eq.(7), as seguintes situações são possíveis:

1. Se $s_k > L_k$, então $y_k = 1$ e, portanto, $\Delta y_k = 1 \rightarrow \Delta E_k < 0$;
2. Se $s_k < L_k$, então $y_k = 0$ e, portanto, $\Delta y_k = -1 \rightarrow \Delta E_k < 0$;
3. Se $s_k = L_k$, então y_k fica inalterado e, portanto, $\Delta y_k = 0 \rightarrow \Delta E_k = 0$.

Deduz-se, então, que a energia só decresce até que o sistema se estabilize em um ponto de equilíbrio. Esta conclusão leva a algumas restrições. A rede de Hopfield não retorna, necessariamente, o padrão mais próximo. Há, também, diferenças entre padrões, pois nem todos os padrões têm igual ênfase. Além disso, surgem padrões espúrios, isto é, padrões equivocados que não constam do rol de padrões originais, de acordo com (BALDI ; HORNIK, 1989).

2.2.8 Redes multilayer perceptron

Extrapolando o conceito do perceptron proposto por (ROSENBLATT, 1959), foi proposta uma verdadeira rede, formada por vários perceptrons

interligados. Essas redes são muito mais poderosas do que as formadas por apenas um perceptron. A utilização dessas redes só foi possível com a elaboração de um algoritmo de treinamento que conseguisse minimizar o erro global de forma eficiente. Esse algoritmo foi denominado de retropropagação ou backpropagation.

Desenvolvido através da generalização da regra de aprendizagem, (RUMELHART; HINTON; WILLIAMS, 1986) propôs esse novo algoritmo. Apresentando valores de entrada, gera-se saídas que são comparadas com os valores esperados. Tal comparação gera um erro, que é utilizado para corrigir os pesos dos perceptrons das camadas interiores à rede. Tal procedimento para minimizar o erro quadrático médio é geralmente conhecido como *gradient descent algorithm*. Os pesos da rede são alterados negativamente em relação ao gradiente do erro.

Em geral, redes retropropagadas treinadas adequadamente tendem a fornecerem boas respostas a entradas nunca antes vistas.

O primeiro passo na construção de uma rede neural multicamadas é definir quais são as entradas e as saídas. O passo seguinte é escolher o número de camadas intermediárias, o número de neurônios em cada uma delas e a função de ativação de cada um deles. Em seguida, deve-se estabelecer o critério de parada do treinamento. Dentre os critérios utilizados em uma rede neural multicamadas, podem-se usar o número máximo de épocas, o erro global e para alguns casos, a variação da taxa de aprendizagem.

Como critério de parada, o parâmetro mais utilizado é o erro global ou erro quadrático médio, que pode ser definido conforme eq.(8).

$$E = \frac{1}{Am} \sum_{j=1}^{Am} \left[\sum_{i \in C} (d_i(j) - o(j))^2 \right] \quad (8)$$

Onde Am é o número de amostras, d_i o valor desejado, o_i o valor encontrado e C o conjunto de dados (diferentes saídas, se houver).

Segundo (THOMSEY; SMITH, 1995), existem três medidas comumente utilizadas para o erro, sendo elas: média do erro absoluto (MAE), raiz quadrada da média do erro ao quadrado (RMSE) e porcentagem de classificações corretas, conforme TABELA 3.

MAE	RMSE ou MSE	Porcentagem
$Erro = \frac{\sum_{p=1}^n d_i - o_i }{n}$	$Erro = \sqrt{\frac{\sum_{p=1}^n (d_i - o_i)^2}{n}}$	$Erro = \frac{\sum_{p=1}^n (Y_p)}{n} \cdot 100$

TABELA 3: Medidas de erro

Onde Y_p é 1 quando a diferença entre o real e o simulado for menor do que um valor pré-estabelecido, d_i é o valor real, o_i o valor obtido e n o número de dados.

O treinamento de retropropagação faz com que os pesos sejam atualizados levando a rede neural a um mínimo local do erro quadrático médio. Porém, mínimos locais não necessariamente correspondem ao mínimo global, onde a escolha dos pesos forneceria uma resposta muito mais satisfatória. Para evitar que o treinamento se torne preso a um mínimo local, adiciona-se um parâmetro à regra de mudança de pesos do algoritmo de retropropagação. Esse novo termo, chamado de *momentum*, corresponde a uma média do erro quadrático médio tomado em uma pequena região ao redor do ponto em si.

O erro global é calculado sobre o conjunto de treinamento, mas para melhorar a generalização, pode-se medir também o erro sobre um conjunto de testes e utilizar esse valor como critério de parada. Em redes neurais podemos sempre entender o treinamento pensando no universo de pesos. Conforme o treinamento acontece, os pesos dos neurônios que compõem a rede são alterados. Então, em um determinado momento, um conjunto específico de pesos representa a rede neural.

2.3 Osciladores de Van Der Pol

Segundo (MONTEIRO, 2002), B. van der Pol (1889-1959) sugeriu, em 1922, uma equação para modelar o funcionamento de um circuito elétrico que existia nos primeiros aparelhos de rádio. A equação de van der Pol escreve-se como a eq.(9).

$$\boxed{\frac{d^2x}{dt^2} + \mu(x^2 - 1)\frac{dx}{dt} + x = 0} \quad (9)$$

Sendo μ um parâmetro positivo. Essa equação representa um oscilador harmônico simples, com um “atrito” que depende da posição x de maneira não linear. A função $F(x) = \mu(x^2 - 1)$ age como amortecimento para $x^2 > 1$. Entretanto, para $x^2 < 1$, esse termo funciona como amplificador. Assim, o termo que contém $F(x)$ faz com que oscilações com grande amplitude decaiam e que oscilações com pequena amplitude cresçam. Isso leva o sistema a uma oscilação auto-sustentada, um ciclo-limite, em que a energia dissipada e a energia ganham, num período, se equivale.

Na descrição de variáveis de estado, a equação de van der Pol, torna-se a eq.(10)

$$\boxed{\begin{aligned} \frac{dx}{dt} &= f(x, y) = y \\ \frac{dy}{dt} &= g(x, y) = -\mu(x^2 - 1) \end{aligned}} \quad (10)$$

O divergente desse campo vetorial tem seu valor calculado pela eq.(11).

$$\boxed{\frac{\partial f}{\partial x} + \frac{\partial g}{\partial y} = -\mu(x^2 - 1)} \quad (11)$$

Observe-se que, de fato, esse sistema é dissipativo para $|x| > 1$, pois nesse caso o divergente é negativo; e amplificador para $|x| < 1$, pois nessa região do espaço de fases, o divergente é positivo.

Pelo retrato de fases dessa equação para $\mu=1$, observa-se que o ciclo-limite envolve a origem, o que está de acordo com os teoremas de índices de Poincaré. E tal ciclo cruza as linhas $x = \pm 1$, o que está de acordo com o critério de Bendixson.

Os autovalores associados ao ponto de equilíbrio (0,0) são obtidos por eq.(12)

$$\lambda_{1,2} = \frac{\mu \pm \sqrt{\mu^2 - 4}}{2} \quad (12)$$

Isto mostra que o ponto é um foco instável para $0 < \mu < 2$; um nó instável para $\mu > 2$; um foco assintoticamente estável para $\mu < -2$.

Ainda, segundo (MONTEIRO, 2002), A. Liénard analisou a eq.(13) que ficou conhecida como equação de Liénard.

$$\frac{d^2 x}{dt^2} + F(x) \frac{dx}{dt} + G(x) = 0 \quad (13)$$

Na verdade, Liénard estudou o caso $G(x)=x$. Tomando-se $F(x)=\mu(x^2-1)$ e $G(x)=x$, obtém-se a equação de van der Pol. Portanto, a equação de van der Pol é um caso particular da equação de Liénard.

De acordo com os teoremas provados por Liénard, em 1928, e por N. Levinson (1912-1975) e O.K. Smith, em 1942, há um ciclo-limite assintoticamente estável no retrato de fases da eq.(13) se as funções $F(x)$ e $G(x)$ satisfazem às seguintes condições:

1. Ambas as funções são continuamente diferenciáveis para todo x ;
2. $G(-x)=-G(x)$ para todo x , isto é, $G(x)$ é uma função ímpar;
3. $G(x)>0$ para todo $x>0$;
4. $F(-x)=F(x)$ para todo x , isto é, $F(x)$ é uma função par;

5. A função $H(x) = \int_0^x F(s)ds$ deve ter uma raiz positiva em $x=a$ e é negativa para $0 < x < a$ e é positiva e não decrescente para $x > a$ e $\lim_{x \rightarrow \infty} H(x) \rightarrow \infty$.

A equação de van der Pol, claramente, obedece às condições de 1 a 4. Para averiguar se a condição 5 é satisfeita, deve-se calcular a função

$H(x)$, que neste caso vale $H(x) = \int_0^x \mu(s^2 - 1)ds = \frac{\mu(x^2 - 3)}{3}$. Como $H(s)$ tem uma raiz positiva localizada em $a = \sqrt{3}$; é negativa no intervalo $0 < x < \sqrt{3}$; é positiva e não decrescente para $x > \sqrt{3}$; tende ao infinito, quando $x \rightarrow \infty$. Daí, conclui-se que a equação de van der Pol possui um único ciclo-limite assintoticamente estável no seu espaço de fases para $\mu > 0$.

3. MATERIAIS E MÉTODOS

3.1 Modelagem de casa de vegetação

A simulação dos parâmetros climáticos de temperatura e umidade relativa do ar no interior de uma casa de vegetação plástica, por meio do balanço de energia, pode propiciar ao produtor uma ferramenta de auxílio na tomada de decisão. Nesse propósito, (COSTA; LEAL; CARMO JÚNIOR, 2004) propuseram uma simulação das condições no interior de uma casa de vegetação plástica, em função de parâmetros externos e internos a ela. Com os valores simulados pode-se determinar a necessidade ou não da utilização de tecnologia mais avançada para obter as condições necessárias ao desenvolvimento da cultura instalada, evitando custos elevados com energia, material e mão-de-obra, proporcionando ao agricultor melhor renda.

A simulação foi feita em função do balanço de energia e consiste em determinar as condições climáticas do interior da casa de vegetação plástica quanto à temperatura e umidade relativa do ar. O balanço pode ser efetuado em qualquer instante do dia, mas, para o verão, é comumente realizado entre 12 e 15 h e, para o inverno, entre 4 h e 30 min e 6 h e 30 min, por serem horários críticos de temperaturas, ou seja, ocorrência de máxima e mínima, respectivamente (ALBRIGHT, 1990). O mesmo cálculo também pode ser feito em função das médias dos parâmetros climáticos externos de um determinado período.

O trabalho de (COSTA; LEAL; CARMO JÚNIOR, 2004) testou um modelo de simulação da temperatura média do ar (T_i) e da umidade relativa média do ar (UR_i) num determinado período do ano, no interior de casa de vegetação plástica com laterais móveis, utilizando o balanço de energia, confrontando com os dados obtidos dos sensores.

A simulação da temperatura média interna da casa de vegetação plástica (T_i), por meio do balanço de energia, utilizando apenas ventilação natural como renovação de ar, foi baseada nas equações de (ASHRAE, 1978) e (HELLICKSON, 1983), e envolveu as médias para o período de cálculo da temperatura do ar externo, da umidade relativa do ar

externo, da radiação solar externa e da velocidade do vento externa à casa de vegetação plástica, entre outras constantes físicas que podem ser extraídas de (ALBRIGHT, 1990), assim como dados do produto que podem ser extraídos de (HONÓRIO; BLISKA JÚNIOR, 1996), (ASHRAE, 1978) e (HELLICKSON, 1983). Esse balanço de energia dentro de casa de vegetação plástica foi estimado pela eq.(14) (ASHRAE, 1978) e (HELLICKSON, 1983).

$$Q_r + Q_m + Q_{so} + Q_{sa} + Q_{ve} = Q_{ce} + Q_{sp} + Q_{sl} + Q_{vs} + Q_{ft} + Q_{tt} \quad (14)$$

Onde,

Q_r - calor sensível de respiração do produto, W;

Q_m - calor de motores, equipamentos, luminárias, etc., W;

Q_{so} - calor sensível proveniente do Sol, W;

Q_{sa} - calor sensível do sistema de aquecimento, W;

Q_{ve} - calor sensível do ar de ventilação de entrada (natural ou forçado), W;

Q_{ce} - calor sensível de condução da estrutura, W;

Q_{sp} - calor sensível transferido ao solo ou piso pelo perímetro, W;

Q_{sl} - calor sensível convertido em calor latente dentro do espaço interno (evaporação da água dos vasos, sistemas de irrigação ou hidroponia e evapotranspiração), W;

Q_{vs} - calor sensível do ar de ventilação de saída (natural ou forçado), W;

Q_{ft} - calor sensível usado para a fotossíntese, W, e

Q_{tt} - calor de transmitância térmica, W.

Os valores dos termos Q_r , Q_{ft} e Q_{sp} são pequenos se comparados aos valores dos demais termos e, muitas vezes, podem ser desconsiderados. Além disso, o valor de Q_{sl} é muito difícil de ser medido, segundo (ASHRAE, 1978), podendo, também, ser desconsiderado.

Portanto, partindo da eq.(15), eliminando os termos desprezíveis, obtém-se a eq.(3), que é mais reduzida.

$$Q_{so} + Q_{ve} = Q_{ce} + Q_{sp} + Q_{vs} + Q_{tt} \quad (15)$$

As equações apresentadas a seguir, neste tópico são definidas por (ASHRAE, 1978) e (HELLICKSON, 1983).

O calor sensível proveniente do Sol (Q_{so}) é definido pela eq.(16).

$$Q_{so} = \tau * I_e * Ap \quad (16)$$

Onde,

τ - transmitância da superfície da cobertura em relação à radiação solar global (ALBRIGHT, 1990), adimensional;

I_e - radiação solar global externa, $W m^{-2}$, e

Ap - área do piso da casa de vegetação plástica, m^2 .

O calor sensível de respiração do produto (Q_r) é definido como mostrado na eq.(17).

$$Q_r = 0,10 * Q_{ft} \quad (17)$$

Outra forma é descrita pela eq.(18).

$$Q_r = mp * TR \quad (18)$$

Onde,

Q_{ft} - calor de fotossíntese, W;

mp - massa do produto, kg, e

TR - taxa de respiração do produto, $W kg^{-1}$.

O calor de fontes de energia mecânica, luminosa (luminárias) e humana (Q_m), é definido conforme a eq.(19).

$$Q_m = F * PE + ilu min ação + humana \quad (19)$$

Onde,

F - fator de potência do equipamento, adimensional;

PE - potência elétrica do equipamento, W;

iluminação - calor perdido pela potência de lâmpadas, W, e

humana - calor cedido por pessoas, W.

O calor sensível do sistema de aquecimento (Q_{sa}) é definido, conforme a eq.(20).

$$Q_{sa} = PC \quad (20)$$

Onde,

PC - potência calorífica da fonte aquecedora, W.

O calor sensível usado para a fotossíntese (Q_{ft}) é definido, conforme a eq.(21).

$$Q_{ft} = 0,03 * Q_{so} \quad (21)$$

O calor sensível de condução da estrutura (Q_{ce}) é definido, conforme a eq.(22).

$$Q_{ce} = U * Ac * \Delta T \quad (22)$$

em que,

U - coeficiente global de transferência de calor do plástico, $W m^{-2} K^{-1}$ (ALBRIGHT, 1990);

Ac - área do contorno da casa de vegetação plástica com a lateral aberta ou fechada, m^2 ;

ΔT - temperatura interna - temperatura externa ($T_i - T_e$), K, e

T_i - incógnita do balanço de energia, K.

O calor sensível transferido ao solo ou piso pelo perímetro (Q_{sp}) é definido conforme a eq.(23).

$$Q_{sp} = F * Per * \Delta T \quad (23)$$

Onde,

F - fator perimetral, $W m^{-1} K^{-1}$;

Per - perímetro da casa de vegetação plástica, m, e

ΔT - temperatura interna - temperatura externa ($T_i - T_e$), K.

O calor de ventilação (Q_v) é definido conforme a eq.(24).

$$Q_v = Q_{ve} - Q_{vs} = \bar{m} * cp * \Delta T \quad (24)$$

em que,

\bar{m} - fluxo mássico de ar seco, kg s^{-1} , e

cp - calor específico do ar externo, $\text{J kg}^{-1} \text{K}^{-1}$.

A relação entre o fluxo volumétrico (\bar{V}) e o fluxo mássico (\bar{m}) é descrita conforme a eq.(25).

$$\bar{V} = \frac{\bar{m}}{\rho * \rho} \quad (25)$$

em que,

\bar{V} - fluxo volumétrico, $\text{m}^3 \text{s}^{-1}$, e

ρ - densidade do ar externo, kg m^{-3} .

O fluxo volumétrico para a ventilação natural é descrita conforme a eq.(26).

$$\bar{V} = E * V_v * A_a \quad (26)$$

Onde,

E - eficiência das aberturas, adimensional, que segundo (HELLICKSON, 1983), para estruturas agrícolas, adota-se $E = 0,35$;

V_v - velocidade média do vento externo a 2 m de altura, m s^{-1} , e

A_a - área de abertura da casa de vegetação plástica, m^2 .

O calor sensível convertido em calor latente (Q_{sl}) é definido conforme a eq.(27).

$$Q_{sl} = ET * Fp * Q_{so} \quad (27)$$

em que,

ET - razão entre a radiação solar e a energia associada com a evapotranspiração da cultura, adimensional, que segundo (HELLICKSON, 1983) recomenda, adota-se 0,5;

F_p - fator de cultivo (área de cultivo/área do piso), adimensional.

O calor de transmitância térmica (Q_{tt}), é definido conforme a eq.(28).

$$Q_{tt} = \varepsilon_{sup} * \gamma_t * \sigma * A_p * (T_i^4 - \varepsilon_{ar} * T_e^4) \quad (28)$$

Onde,

ε_{sup} - emissividade do piso ou vegetação, adimensional;

γ_t - transmitância térmica do plástico na reirradiação, adimensional;

A_p - área do piso, m²;

σ - constante de Stefan Boltzmann, 5,678 10⁻⁸ W m⁻² K⁻⁴;

T_e - temperatura externa, K;

T_i - temperatura interna, K, e

ε_{ar} - emissividade do ar local, adimensional.

Para a determinação da umidade relativa interna média (URi), expressa em porcentagem, após a simulação da temperatura interna média (Ti), em K, utiliza-se o balanço de massa, definido pela eq.(29), o qual fornece a umidade absoluta interna média (Wi) (HELLICKSON, 1983).

$$\bar{m} * W_i = \bar{m} * W_e + Map \quad (29)$$

Onde,

\bar{m} - fluxo mássico de ar seco, kg s⁻¹;

W_i - umidade absoluta interna, kg kg⁻¹ (quilograma de vapor de H₂O por quilograma de ar seco);

W_e - umidade absoluta externa, kg kg⁻¹(quilograma de vapor de H₂O por quilograma de ar seco);

Map - fluxo mássico de água produzida pelas plantas, kg s⁻¹.

A seguir, são apresentados, na TABELA 4, os parâmetros de entrada adotados no modelo analítico da casa de vegetação para a eq.(2).

Parametros do modelo analítico			
$Q_r = Q_{ft} 0,1$	$m = V \rho$	$T_i = \text{incógnita, em K}$	$Q_{ft} = Q_{so} 0,03$
$Q_m = 0$	$V = E V_v A_a$	$Q_{ce} = U A_c \Delta T$	$Q_{tt} = \epsilon_{sup} \gamma_t \sigma A_p (T_i^4 - \epsilon_{ar} T_e^4)$
$Q_{so} = \tau I A_p$	$E = 0,35$	$U = 7,14$	$\epsilon_{sup} = 0,85$
$\tau = 0,95$	$V_v = 1,53$	$A_c = 139,77$	$\gamma_t = 0,8$
$I = 569,84$	$A_a = 19,06$	$Q_{sp} = F Per \Delta T$	$\sigma = 5,67 \cdot 10^{-8}$
$A_p = 74,75$	$\rho = 1,09$	$F = 1,15$	$A_p = 74,75$
$Q_{sa} = 0$	$cp = 1006$	$Per = 36$	$\epsilon_{ar} = 0,8$
$Q_v = m C_p \Delta T$	$\Delta T = (T_i - T_e)$	$Q_{st} = 0$	

TABELA 4: Parâmetros do modelo analítico

Nos modelos de sistemas de mais de uma grandeza que varia no tempo e no espaço, o uso de um processo de modelagem numérica, como o modelo analítico descrito, torna difícil a compreensão detalhada sobre a dinâmica do sistema, bem como a contribuição de cada uma das grandezas. Assim, o modelo analítico, que procura compreender os fenômenos físicos envolvidos no processo, da melhor maneira possível, sem, contudo, envolver nenhuma experimentação precedente dos mesmos, tem sua validade contestada para comportamentos mais complexos. Este tipo de modelagem, conhecido como fenomenológico, tem como escopo mais indicado para sua aplicação, por exemplo, quando os parâmetros envolvidos representam as propriedades dos materiais e as reações envolvidas do sistema.

Um exemplo desta situação são as casas de vegetação, onde o modelo analítico forneceu uma visão incompleta e imprecisa do sistema, uma vez que, em determinados casos, os parâmetros alcançados não têm significado físico.

A casa de vegetação é um sistema dinâmico com parâmetros distribuídos, não lineares e que variam com o tempo. Conseqüentemente, a modelagem de uma casa de vegetação envolve um conhecimento mais amplo dos fatores bióticos e não bióticos, cuja representação matemática é dada por equações diferenciais complexas.

Na TABELA 5, extraída, diretamente, de (COSTA; LEAL; CARMO JÚNIOR, 2004), são mostrados todos os dados estimados pelo modelo analítico.

Data	Saída	
	Grandezas internas simuladas pelo modelo analítico	
	Umidade Relativa do Ar (%)	Temperatura (°C)
17-nov.	52,4	20,5
18-nov.	54,2	21,9
19-nov.	59,2	22,3
20-nov.	62,7	21,2
21-nov.	62,4	23,8
22-nov.	59,1	24,5
23-nov.	54,6	24,9
24-nov.	47,5	26,3
25-nov.	44,6	27,5
26-nov.	81,9	21,9
27-nov.	54,8	27,2
28-nov.	51,7	24,2
29-nov.	58,7	23,9
30-nov.	62,1	22,7
1o-dez.	59,9	24,9
2-dez.	58,3	26,3
3-dez.	65,4	25,3
4-dez.	87,0	20,7
5-dez.	67,9	25,4
6-dez.	72,4	24,1
7-dez.	72,8	24,5
8-dez.	77,7	25,6
9-dez.	73,5	24,7
10-dez.	77,2	22,5
11-dez.	86,9	20,5
12-dez.	84,6	20,5
13-dez.	93,3	19,4

TABELA 5: Dados estimados pelo modelo analítico

Na TABELA 6, são mostrados, apenas, os dados estimados pelo modelo analítico, correspondentes aos conjuntos de teste da rede neural e da rede de osciladores de Van Der Pol, segundo critérios de seleção expostos mais adiante, neste trabalho.

Ordem	Saída	
	Grandezas internas estimadas - modelo analítico	
	Umidade Relativa do Ar (%)	Temperatura (°C)
1	54,6	24,9
2	47,5	26,3
3	44,6	27,5
4	81,9	21,9
5	51,7	24,2
6	62,1	22,7
7	58,3	26,3
8	87,0	20,7
9	72,4	24,1
10	72,8	24,5
11	77,7	25,6
12	77,2	22,5
13	84,6	20,5

TABELA 6: Dados estimados pelo modelo analítico que correspondem aos conjuntos de teste.

3.2 Alternativas para modelagem da casa de vegetação

Diante da complexidade da modelagem analítica da casa de vegetação, abordagens alternativas passaram a ser pesquisadas, em especial, no âmbito das técnicas de Inteligência Artificial.

Os modelos nebulosos têm uma boa base teórica. Podem ser construídos a partir de regras formuladas por especialistas da aplicação e utilizam uma lógica multi-valorada que permite “graus de pertinência” e não verdades ou falsidades absolutas.

Os modelos baseados em redes neurais artificiais exploram, razoavelmente bem, as amostras do processo. De fato, uma das vantagens desta abordagem é a possibilidade de treinamento das redes a partir dos dados. Não são necessárias regras ou uma teoria que descreva o processo e as regras, simplesmente “aprendem” com os exemplos. Estes exemplos

são apresentados sucessivamente à rede, que se adapta um pouco a cada exemplo. O comportamento desejado é reforçado e o comportamento indesejado é reprimido até que o sistema realize a tarefa almejada.

Ambas as abordagens alternativas apresentadas têm como característica o fato de que requisitam o conhecimento das entradas e das saídas do processo e não seu funcionamento, ou seja, funcionam como uma “caixa preta”. Este tipo de abordagem surge com boas possibilidades de fornecer uma solução mais adequada para problemas complexos como a estimativa das grandezas internas de uma casa de vegetação.

3.3 Base de dados medidos

Conforme (COSTA; LEAL; CARMO JÚNIOR, 2004), o experimento considerado como base da proposta de modelagem foi conduzido em um campo experimental da Faculdade de Engenharia Agrícola da Universidade Estadual de Campinas, que utiliza estufa plástica de polietileno de baixa densidade (PEBD), modelo tipo capela com laterais móveis e plástico transparente de espessura com 150 micras. Cultivou-se a alface (*Lactuca sativa* L.) variedade Vera, utilizando um sistema hidropônico com quatro bancadas triangulares de cultivo, no período de 17-11-1999 a 13-12-1999.

Para a medida da temperatura (T_i) e umidade relativa do ar (UR_i) internas, foi utilizado um psicrômetro constituído de termopares tipo T (Cu-Co) e J (Fe-Co) com precisão de $\pm 0,5$ °C, calibrado pelo fabricante. A temperatura do ar externa (T_e), a umidade relativa externa (UR_e) e a velocidade do vento externa (V_{ve}) a 2 m de altura foram obtidas no posto meteorológico que dista 100 m do local do experimento. A radiação solar global externa (I_e) foi medida por piranômetro LICOR modelo 200SZ.

Ainda, conforme (COSTA; LEAL; CARMO JÚNIOR, 2004), os dados internos, temperatura e umidade relativa do ar, foram coletados por meio de um sistema automatizado. Os dados foram medidos a cada 10 segundos e armazenados, sendo a média desses medidos a cada 30 minutos para a caracterização da temperatura horária e diária e obtenção da média no

período, objetivo da comparação. A temperatura obtida do posto meteorológico foi armazenada a cada 10 minutos. A radiação solar global externa foi coletada num sistema de aquisição de dados LICOR modelo Li-1400, que armazenava os dados diariamente de hora em hora, entre 7 e 17 h.

Os dados médios obtidos no período estudado são apresentados na TABELA 7.

Dados Medidos						
Data	Entrada				Saída	
	Grandezas Externa Medidas				Grandezas Internas Medidas	
	Radiação global $W m^{-2}$	Velocidade do vento $m s^{-1}$	Umidade Relativa do Ar (%)	Temperatura (°C)	Umidade Relativa do Ar (%)	Temperatura (°C)
17-nov.	727,01	2,47	62,8	52,4	18,16	21,3
18-nov.	782,34	2,09	65,5	54,2	18,94	22,6
19-nov.	623,88	1,88	69,0	59,2	19,73	23,3
20-nov.	354,07	1,24	76,8	62,7	19,28	22,5
21-nov.	496,51	0,88	74,6	62,4	19,95	23,2
22-nov.	679,05	1,24	71,4	59,1	20,43	24,7
23-nov.	763,33	1,36	64,8	54,6	20,60	24,6
24-nov.	840,95	1,56	58,0	47,5	22,09	26,5
25-nov.	762,02	1,39	53,1	44,6	23,28	27,9
26-nov.	292,94	0,95	80,1	81,9	19,93	22,3
27-nov.	759,16	1,24	65,5	54,8	22,49	26,6
28-nov.	739,54	2,39	53,9	51,7	21,73	25,6
29-nov.	816,29	2,22	65,3	58,7	20,91	24,4
30-nov.	616,28	2,58	69,4	62,1	20,84	24,2
1o-dez.	843,25	2,17	65,6	59,9	21,71	25,0
2-dez.	722,44	1,45	64,5	58,3	22,46	25,6
3-dez.	575,57	1,25	72,2	65,4	21,84	25,6
4-dez.	236,38	1,14	89,4	87,0	19,48	22,0
5-dez.	440,72	1,05	69,5	67,9	22,50	25,8
6-dez.	513,95	1,17	76,2	72,4	20,98	24,2
7-dez.	571,84	1,33	79,1	72,8	21,33	24,8
8-dez.	637,73	1,22	80,8	77,7	21,66	25,5
9-dez.	621,79	1,81	78,6	73,5	22,02	25,3
10-dez.	398,01	1,52	83,1	77,2	20,65	22,8
11-dez.	226,05	1,19	86,7	86,9	19,35	21,0
12-dez.	183,00	1,38	81,3	84,6	19,72	21,9
13-dez.	161,54	1,21	91,6	93,3	18,67	20,8

TABELA 7: Dados médios diários obtidos no período estudado.

3.4 Modelo nebuloso

(SILVÉRIO et al., 2006) apresentaram um modelo alternativo para casas de vegetação, como esquematizado na FIGURA 13, baseado em lógica nebulosa. A modelagem proposta considera as variáveis ambientais e as características da casa de vegetação, que são “fuzzyficadas” e inseridas no conjunto de regras nebulosas. O modelo foi aplicado em uma casa de vegetação real e os resultados foram comparados aos valores experimentais obtidos por (COSTA; LEAL; CARMO JÚNIOR, 2004).

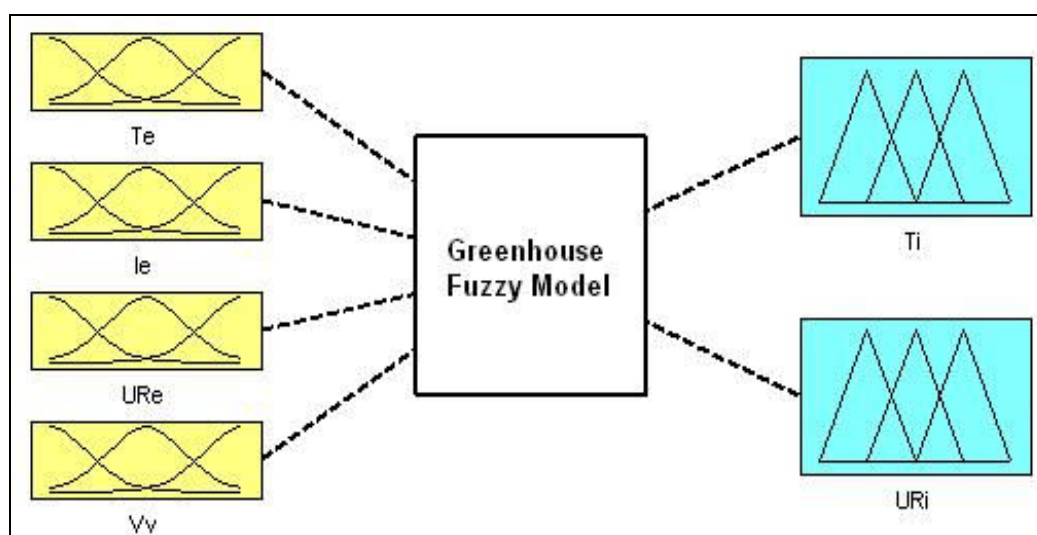


FIGURA 13: Esquema do modelo nebuloso para a casa de vegetação.

Extraída de (SILVÉRIO et al., 2006)

Na TABELA 8, extraída diretamente de (SILVÉRIO et al., 2006), são mostrados os dados medidos, os dados estimados pelo modelo analítico e os dados estimados pelo modelo nebuloso.

	le	Vve	Ure	Te	URi	URis	URiF	Ti	Tis	TiF
727.0										
1	2.47	62.8	18.16	52.4	54.2	55	21.3	20.5	21.4	
782.3										
4	2.09	65.5	18.94	54.2	54.5	55	22.6	21.9	22.2	
623.8										
8	1.88	69	19.73	59.2	58.9	62.5	23.3	22.3	23.7	
354.0										
7	1.24	76.8	19.28	62.7	68.1	71.9	22.5	21.2	22.5	

496.5										
1	0.88	74.6	19.95	62.4	58.8	62.5	23.2	23.8	23.7	
679.0										
5	1.24	71.4	20.43	59.1	55.7	62.5	24.7	24.5	25	
763.3										
3	1.36	64.8	20.6	54.6	49.9	57.8	24.6	24.9	25	
840.9										
5	1.56	58	22.09	47.5	45	51.5	26.5	26.3	25.8	
762.0										
2	1.39	53.1	23.28	44.6	41.3	47.5	27.9	27.5	27	
292.9										
4	0.95	80.1	19.93	81.9	71.1	84.8	22.3	21.9	22.5	
759.1										
6	1.24	65.5	22.49	54.8	49.6	55	26.6	27.2	25.7	
739.5										
4	2.39	53.9	21.73	51.7	46.3	55	25.6	24.2	25	
816.2										
9	2.22	65.3	20.91	58.7	54.5	62.5	24.4	23.9	25	
616.2										
8	2.58	69.4	20.84	62.1	61.8	62.5	24.2	22.7	23.8	
843.2										
5	2.17	65.6	21.71	59.9	54.2	62.5	25	24.9	25	
722.4										
4	1.45	64.5	22.46	58.3	51.3	55	25.6	26.3	25.2	
575.5										
7	1.25	72.2	21.84	65.4	58.8	65	25.6	25.3	24.6	
236.3										
8	1.14	89.4	19.48	87	82.7	87.6	22	20.7	22	
440.7										
2	1.05	69.5	22.5	67.9	58.3	70	25.8	25.4	26.3	
513.9										
5	1.17	76.2	20.98	72.4	62.9	69.4	24.2	24.1	24	
571.8										
4	1.33	79.1	21.33	72.8	65.1	70	24.8	24.5	24.6	
637.7										
3	1.22	80.8	21.66	77.7	63.9	73.3	25.5	25.6	25	
621.7										
9	1.81	78.6	22.02	73.5	66.9	70	25.3	24.7	25	
398.0										
1	1.52	83.1	20.65	77.2	74.1	77.5	22.8	22.5	22.5	
226.0										
5	1.19	86.7	19.35	86.9	80.8	84.8	21	20.5	21.9	
183	1.38	81.3	19.72	84.6	77.7	84.8	21.9	20.5	22.5	
161.5										
4	1.21	91.6	18.67	93.3	96	89.4	20.8	19.4	21.3	

TABELA 8: Dados medidos, estimados pelo modelo analítico estimados pelo modelo nebulosa.

Extraída de (SILVÉRIO et al., 2006)

Na TABELA 8, assim como na FIGURA 14 e na FIGURA 15, le é a radiação solar externa medida, V_{ve} é a velocidade do vento externa medida, UR_e é a umidade relativa do ar externa medida, Te é a temperatura externa medida, UR_i é a umidade relativa do ar interna medida, UR_{is} é a umidade relativa do ar interna simulada pelo modelo analítico, UR_{iF} é a umidade relativa do ar interna simulada pelo modelo nebuloso, T_i é a temperatura interna medida, T_{is} é a temperatura interna simulada pelo modelo analítico, T_{iF} é a temperatura interna simulada pelo modelo nebuloso

Na FIGURA 14 e na FIGURA 15, extraídas diretamente de (SILVÉRIO et al., 2006), são mostrados os gráficos comparativos entre os dados medidos, os dados estimados pelo modelo analítico e os dados estimados pelo modelo nebuloso, considerando todos os dados, para as duas grandezas internas à casa de vegetação analisadas.




FIGURA 14: Comparação da umidade relativa do ar interna medida e estimada pelos métodos analítico e nebuloso.

Extraída de (SILVÉRIO et al., 2006)




FIGURA 15: Comparação da temperatura interna medida e estimada pelos métodos analítico e nebuloso.

Extraída de (SILVÉRIO et al., 2006)

Ainda em (SILVÉRIO et al., 2006), conclui-se que o uso da modelagem com lógica nebulosa apresenta vantagens, pois possibilita uma estimativa de grandezas, sem um conhecimento prévio do processo real, o que é imperativo na modelagem analítica. Os resultados da simulação mostraram boa acurácia, se comparados aos valores medidos e aos valores obtidos pelo modelo analítico.

Na TABELA 9, são mostrados apenas os dados de temperatura e umidade internas estimados pelo modelo nebuloso, correspondentes aos conjuntos a serem utilizados para comparação nos testes com os métodos da rede neural e da rede de osciladores de Van Der Pol, segundo critérios de seleção expostos mais adiante, neste trabalho.

Ordem	Saída	
	Grandezas Internas Estimadas - Modelagem nebulosa	
	Umidade Relativa do Ar (%)	Temperatura (°C)
1	57,8	25,0
2	51,5	25,8
3	47,5	27,0
4	84,8	22,5
5	55,0	25,0
6	62,5	23,8
7	55,0	25,2
8	87,6	22,0
9	69,4	24,0
10	70,0	24,6
11	73,3	25,0
12	77,5	22,5
13	84,8	22,5

TABELA 9: Dados estimados pelo modelo nebuloso que correspondem aos conjuntos de testes.

3.5 Seleção de dados para as redes

Para avaliar a generalização dos treinamentos, dividiu-se o conjunto de dados em um conjunto de treinamento e um de teste, como mostrado na TABELA 10. A tabela mostra ainda o número de dados utilizado em cada uma das análises.

Distribuição dos dados em conjuntos				
Conjuntos	Real		Recomendado	
	Quantidade	Participação	Quantidade	Participação
Treinamento	14	51,9%	6	22,2%
Teste	13	48,1%	21	77,8%
Total	27	100,0%	27	100,0%

TABELA 10: Número de dados utilizados para treinamento e teste da rede neural.

Embora seja recomendada em diversas referências, tais como (HAYKIN, 1998) e (MEHROTRA; MOHAN; RANKA, 1997), uma relação próxima de 20% dos dados disponíveis para treinamento e 80% para teste, no caso deste trabalho, em função do pequeno conjunto disponível e de suas características, optou-se por outra distribuição. Essa é uma restrição que deve ser observada na análise dos resultados.

3.5.1 Dados para treinamento

A série de vinte e sete conjuntos de dados medidos foi classificada seis vezes. Em cada classificação, a série foi ordenada por uma das grandezas medidas. A partir de cada série classificada, foram selecionados para o treinamento, dois conjuntos de dados medidos: o conjunto de dados correspondente ao maior valor e o conjunto de dados correspondente ao menor valor da grandeza pela qual a série foi ordenada.

Finalmente, a série foi classificada pela data da medida e foram selecionados os conjuntos faltantes até completarem-se catorze conjuntos para treinamento, conforme mostrado na TABELA 11.

Dados para Treinamento						
Ordem	Entrada				Saída	
	Grandezas Externa Medidas				Grandezas Internas Medidas	
	Radiação global $W m^{-2}$	Velocidade do vento $m s^{-1}$	Umidade Relativa do Ar (%)	Temperatura (°C)	Umidade Relativa do Ar (%)	Temperatura (°C)
1	226,05	1,19	86,7	19,35	86,9	21,0
2	236,38	1,14	89,4	19,48	87,0	22,0
3	843,25	2,17	65,6	21,71	59,9	25,0
4	161,54	1,21	91,6	18,67	93,3	20,8
5	727,01	2,47	62,8	18,16	52,4	21,3
6	183,00	1,38	81,3	19,72	84,6	21,9
7	496,51	0,88	74,6	19,95	62,4	23,2
8	616,28	2,58	69,4	20,84	62,1	24,2
9	816,29	2,22	65,3	20,91	58,7	24,4
10	679,05	1,24	71,4	20,43	59,1	24,7
11	621,79	1,81	78,6	22,02	73,5	25,3
12	575,57	1,25	72,2	21,84	65,4	25,6
13	840,95	1,56	58,0	22,09	47,5	26,5
14	762,02	1,39	53,1	23,28	44,6	27,9

TABELA 11: Tabela de dados para treinamento da rede neural

3.5.2 Dados para teste

Os conjuntos de dados medidos que não foram selecionados para o treinamento, conforme os critérios expostos anteriormente, compuseram o conjunto de dados para teste, que são mostrados na TABELA 12.

Dados para Teste				
Entrada				
Ordem	Grandezas Externa Medidas			
	Radiação global W m^{-2}	Velocidade do vento m s^{-1}	Umidade Relativa do Ar (%)	Temperatura ($^{\circ}\text{C}$)
1	292,94	0,95	80,1	19,93
2	354,07	1,24	76,8	19,28
3	782,34	2,09	65,5	18,94
4	398,01	1,52	83,1	20,65
5	623,88	1,88	69,0	19,73
6	513,95	1,17	76,2	20,98
7	763,33	1,36	64,8	20,60
8	571,84	1,33	79,1	21,33
9	637,73	1,22	80,8	21,66
10	739,54	2,39	53,9	21,73
11	722,44	1,45	64,5	22,46
12	440,72	1,05	69,5	22,50
13	759,16	1,24	65,5	22,49

TABELA 12: Tabela de dados para teste da rede neural

3.6 Modelo com rede neural artificial

3.6.1 Definição do tipo e dos parâmetros da rede

A utilização de uma rede neural artificial exige que uma série de escolhas, não triviais, seja feita na busca de um modelo que apresente um resultado considerado satisfatório. Dentre as principais escolhas estão: a topologia da rede, o algoritmo de aprendizagem, a função de ativação, a taxa de aprendizagem, a taxa de momentum e o número ideal de épocas.

Inicialmente, consideraram-se dois tipos de rede neural: a rede neural multicamadas e a rede de Hopfield. A fundamentação teórica e as características de cada uma delas foram explicitadas anteriormente.

Para a proposta de modelagem da casa de vegetação utilizando rede neural, optou-se pelo modelo de rede neural *feedforward*, freqüentemente

utilizado em aplicações de estimativa, com algoritmo de treinamento *backpropagation*, no qual os pesos são ajustados baseados na regra de aprendizagem por correção de erro. A rede foi estruturada em três camadas, ou seja, apenas uma camada oculta foi utilizada, pois, de acordo com (FAUSETT, 1994), duas ou mais camadas ocultas podem beneficiar determinadas aplicações, mas uma única camada oculta é considerada suficiente. A rede proposta está esquematizada, de forma simplificada, na FIGURA 16.




FIGURA 16: Esquema simplificado da rede neural proposta

A camada de entrada é formada por quatro neurônios, um para cada variável de entrada da rede. O número de neurônios na segunda camada foi sendo modificado ao longo dos testes. Na terceira camada há dois neurônios que representam as variáveis de saída da rede.

Além do número de neurônios da camada oculta, a taxa de aprendizagem, a taxa de momentum e o número de épocas também foram sendo modificados durante a realização de inúmeros testes na busca da combinação que produzisse o melhor resultado.

A função tangente hiperbólica (\tanh) foi definida como a função de ativação para os neurônios da camada oculta. A função tangente hiperbólica possui forma de "s", assumindo valores entre 1 e -1, sendo representada por eq.(30).

$$f(v) = a \frac{e^{(bv)} - e^{(-bv)}}{e^{(bv)} + e^{(-bv)}} \quad (30)$$

Na eq.(30), a representa o parâmetro de inclinação da curva, b são os limites inferiores e superiores e v é o valor de ativação da unidade.

3.6.2 Caixa de ferramentas computacionais

Para criar, treinar e simular redes neurais artificiais do tipo multilayer perceptron, foi utilizado o software MATLAB 6.1 da Mathworks e a ferramenta Neural Networks Toolbox. Essa ferramenta permite que uma série de tipos diferentes de redes neurais artificiais seja criada e fornece um grau de liberdade relativamente grande para a alteração dos parâmetros dessas redes. Essa ferramenta permite sua utilização via uma interface gráfica, que pode ser vista na FIGURA 17. A programação em MATLAB pode ser encontrada em (HANSELMAN; LITTLEFIELD, 2003).



FIGURA 17: Interface gráfica do Neural Networks Toolbox do MATLAB

A reprodutibilidade e o número de neurônios contidos na camada intermediária foram avaliados. Os resultados mostram que as redes neurais artificiais treinadas fornecem boas respostas simuladas.

Os procedimentos para configuração da rede neural usando MATLAB foram extraídos de (LIMA, 2005).

3.6.3 Código Fonte

A rede neural multicamadas com retropropagação, que foi simulada através da caixa de ferramentas, conforme descrito acima, foi reproduzida em semelhantes condições em Linguagem C. No desenvolvimento do programa foi utilizado o algoritmo descrito por (RICH; KNIGHT, 1993).

A rede neural codificada foi treinada e verificada com os mesmos conjuntos de dados utilizados, para estas etapas, pela rede criada com a caixa de ferramentas.

Para o desenvolvimento do código foi usado o compilador TC++ 1.01 de uso livre e disponível em <http://dn.codegear.com/museum> e as informações contidas em (SEEDGEWICK, 2001).

3.6.4 Critério de seleção de dados para análise

Para o modelo com rede neural, foram realizadas trinta simulações com os dados de verificação. Em vinte e sete simulações a rede convergiu para um estado estável.

A partir dos dados das simulações convergentes, levantou-se a distribuição dos valores das grandezas estimadas obtidos para cada um dos treze pontos. Obtiveram-se, assim, treze pares de grandezas, considerando-se, em cada ponto, os valores das medianas.

Com estes dados, verificou-se a quantidade de pares coincidentes em cada uma das simulações convergentes e montou-se um gráfico de freqüências, conforme mostrado na FIGURA 18.




FIGURA 18: Freqüência de pares de valores estimados iguais aos valores medianos para o modelo com rede neural.

A maior freqüência, com dez simulações, ocorreu para doze pares com valores estimados iguais aos valores medianos. Dentre estas dez

simulações, somente uma combinação repetiu-se, exatamente, igual por quatro vezes. Os dados desta combinação foram considerados nas análises.

3.7 Modelo com rede de osciladores de Van Der Pol

A partir do modelo de rede neural proposto, anteriormente, substituiu-se as funções de ativação dos neurônios artificiais pela do oscilador de Van Der Pol, mantendo-se as demais características já discutidas. A substituição das funções de ativação por osciladores foi proposta por (ENDO; CHUA; TAKEYAMA, 1991).

Os osciladores de Van Der Pol apresentam um comportamento melhor que as funções de ativação tradicionais das redes neurais, em caso de sistemas mais complexos e não previsíveis, como a modelagem de casas de vegetação.

A diferença entre o proposto (ENDO; CHUA; TAKEYAMA, 1991) e o proposto neste trabalho está no tipo de aplicação e, portanto, no tipo de rede neural onde ocorre a mudança.

A substituição ocorreu na implementação do código fonte desenvolvido em linguagem C para a rede neural.

A rede de osciladores de Van Der Pol foi treinada e verificada com os mesmos conjuntos de dados usados, para estas etapas, pela rede neural.

3.7.1 Critério de seleção de dados para análise

Para o modelo com rede de osciladores de Van Der Pol, repetiu-se o procedimento descrito para o modelo com rede neural. Em vinte e seis simulações a rede convergiu para um estado estável.

O gráfico de frequências é mostrado na FIGURA 19.




FIGURA 19: Frequência de pares de valores estimados iguais aos valores medianos para o modelo com oscilador de Van Der Pol.

A maior frequência, com oito simulações, ocorreu para onze pares com valores estimados iguais aos valores medianos. Dentre estas oito simulações, somente uma combinação repetiu-se, exatamente, igual por três vezes. Os dados desta combinação foram considerados nas análises.

4. RESULTADOS E DISCUSSÕES

Este capítulo está dividido em quatro partes. Na primeira parte são apresentados os resultados estimados pela simulação do modelo ambiental de uma casa de vegetação utilizando-se uma rede neural multicamadas. São realizadas análises comparativas com os resultados medidos, estimados pelo método analítico e estimados pelo método nebuloso.

Na segunda parte são apresentados os resultados estimados pela simulação do modelo ambiental de uma casa de vegetação utilizando-se uma rede de osciladores de Van Der Pol, com o qual são realizados os mesmos tipos de análises comparativas da primeira parte.

Na terceira parte, os resultados estimados utilizando-se a rede neural multicamada e a rede de osciladores de Van Der Pol são comparados, inclusive, considerando-se o desempenho computacional de ambas.

Finalmente, na quarta parte, analisam-se os diversos modelos apresentados de forma conjunta.

4.1 Rede neural multicamadas

4.1.1 Apresentação dos resultados estimados

Na TABELA 13, são apresentados os resultados da simulação, utilizando-se a rede neural, das grandezas internas de uma casa de vegetação que são usados nas análises que se seguem e foram selecionados segundo os critérios e a metodologia expostos, anteriormente.

Ordem	Saída	
	Grandezas Internas Estimadas - Rede Neural	
	Umidade Relativa do Ar (%)	Temperatura (°C)
1	50,1	22,5
2	60,1	23,0
3	59,1	22,0
4	54,9	24,9
5	73,5	22,1
6	61,0	26,2
7	48,5	24,8
8	59,8	25,2
9	62,3	25,5
10	65,7	24,3
11	68,3	24,6
12	79,0	25,8
13	74,0	22,4

TABELA 13: Resultados da simulação, utilizando-se a rede neural, das grandezas internas de uma casa de vegetação.

4.1.2 Comparação entre os resultados da rede neural multicamadas e valores medidos

Conforme pode ser constatado na TABELA 14, o valor estimado de umidade relativa do ar interna à casa de vegetação, através do modelo de rede neural, apresenta um erro relativo ao valor medido superior a 5,0% para oito dos pontos analisados. O erro relativo médio é 5,8% para umidade relativa do ar, com desvio padrão de 3,5%.

Ordem	Saída	
	Erro relativo entre valores estimados pela rede neural e valores medidos	
	Umidade Relativa do Ar	Temperatura
1	7,6%	0,4%
2	1,5%	1,3%
3	5,7%	2,2%
4	0,5%	1,2%
5	10,3%	0,9%
6	11,3%	1,5%
7	6,2%	3,1%
8	2,6%	1,6%
9	8,2%	1,2%
10	9,3%	0,4%
11	6,2%	0,8%
12	1,7%	1,2%
13	4,1%	1,8%

TABELA 14: Resultados da simulação utilizando-se a rede neural das grandezas internas de uma casa de vegetação.

O comportamento gráfico do valor medido e do valor estimado pela rede neural para a umidade relativa do ar pode ser observado na FIGURA 20.

Ainda reportando-se a TABELA 14, o valor estimado de temperatura interna à casa de vegetação, através do modelo de rede neural, apresenta um erro relativo ao valor medido máximo de 3,1%. O erro relativo médio é 1,4% para temperatura, com desvio padrão de 0,7%.




FIGURA 20: Comportamento do valor medido e do valor estimado pela rede neural para a umidade relativa do ar.

O comportamento gráfico do valor medido e do valor estimado pela rede neural para a temperatura pode ser observado na FIGURA 21.




FIGURA 21: Comportamento do valor medido e do valor estimado pela rede neural para a temperatura.

O comportamento mais adequado deste modelo para os valores estimados de temperatura do que para os valores estimados de umidade relativa do ar pode ser constatado na FIGURA 22.




FIGURA 22: Erro relativo dos valores estimados pela rede neural para umidade relativa do ar e temperatura.

4.1.3 Comparação entre os resultados da rede neural multicamadas e da modelagem analítica

Na FIGURA 23, observa-se pelas curvas de erro relativo para o cálculo da umidade relativa do ar interno à camada, que o erro percentual obtido através da rede neural é em sua maioria menor se comparado ao modelo analítico, exceto para os pontos 1, 2, 6 e 13. As curvas se interceptam três vezes, o que denota flutuação nos cálculos entre os dois métodos. Entretanto, pode-se considerar que a utilização da rede neural apresenta melhor desempenho global para a estimativa da umidade relativa do ar.




FIGURA 23: Comparação do erro relativo da umidade relativa do ar obtido pela rede neural e pelo modelo analítico.

Os erros relativos da rede neural são inferiores aos do modelo analítico, em nove dos pontos estimados para a umidade relativa do ar, sendo que em quatro deles o erro reduziu-se em mais de 100%. A distribuição dos melhores resultados estimados entre os dois modelos para a umidade relativa do ar é mostrada na FIGURA 24.

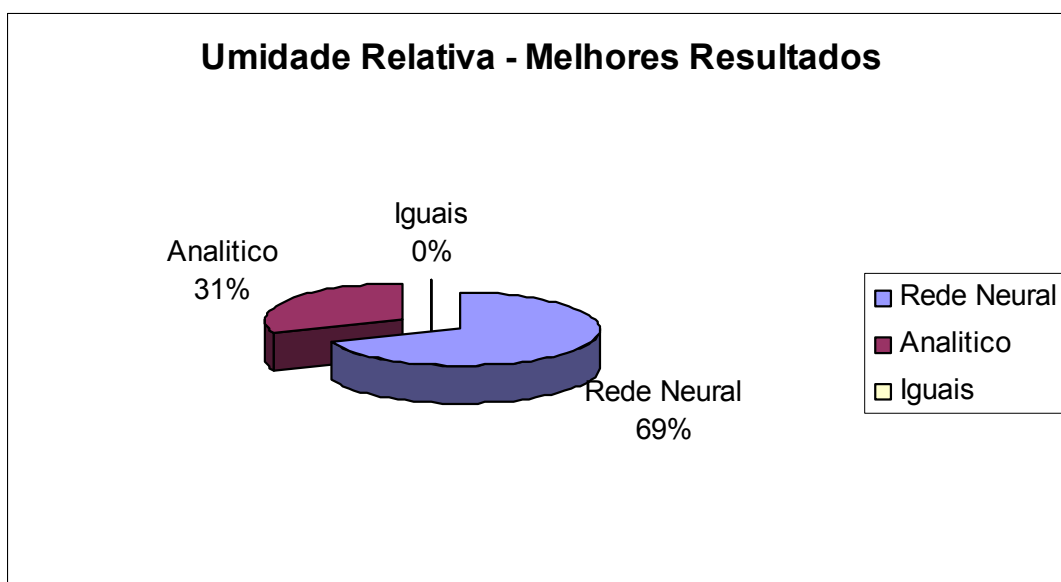


FIGURA 24: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede neural e modelo analítico.

Na FIGURA 25, observa-se que o comportamento da curva de erro relativo referente à rede neural difere da curva referente ao modelo analítico para a temperatura. Em dez pontos, os resultados apresentados pela rede neural são melhores ou iguais aos do modelo analítico. O modelo analítico mostrou resultado melhor que a rede neural para a temperatura nos pontos 10, 12 e 13, sendo que os modelos tiveram desempenho igual no ponto 4.




FIGURA 25: Comparação do erro relativo da temperatura para a rede neural e para o modelo analítico.

Assim, para a estimativa da temperatura, bem como para a estimativa da umidade relativa do ar, observa-se um melhor desempenho da rede neural em relação ao modelo analítico. A distribuição dos melhores resultados estimados entre os dois modelos para a temperatura é mostrada na FIGURA 26.




FIGURA 26: Quantidade de melhores resultados por modelo para a temperatura – rede neural e modelo analítico.

4.1.4 Comparação entre os resultados da rede neural multicamadas e da modelagem nebulosa

Na FIGURA 27, observa-se que a curva de erro relativo referente à rede neural cruza a curva referente o modelo nebuloso seis vezes, denotando uma freqüente inversão no desempenho dos métodos utilizados. A rede neural apresentou erro relativo menor em seis dos pontos analisados, enquanto o modelo nebuloso apresentou em sete dos pontos.




FIGURA 27: Comparação do erro relativo da umidade relativa do ar para a rede neural e o modelo nebuloso.

Assim, para a estimativa da umidade relativa do ar, não se detecta uma clara supremacia de um método sobre o outro. A distribuição dos melhores resultados estimados entre os dois modelos para a umidade relativa do ar é mostrada na FIGURA 28.




FIGURA 28: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede neural e modelo nebuloso.

Na FIGURA 29, observa-se que o comportamento da curva de erro relativo referente à rede neural não acompanha o da curva referente ao

modelo nebuloso para a temperatura. Ambas apresentam o mesmo resultado em três dos pontos analisados, 9, 7 e 13, sendo que em outros sete pontos, os resultados apresentados pela rede neural são melhores. Nota-se, ainda, que os resultados apresentados pelo modelo nebuloso são melhores em três pontos.




FIGURA 29: Comparação do erro relativo temperatura para a rede neural e o modelo nebuloso.

Assim, para a estimativa da temperatura, diferentemente do constatado para a estimativa da umidade relativa do ar, detecta-se um melhor desempenho da rede neural em relação ao modelo nebuloso. A distribuição dos melhores resultados estimados entre os dois modelos para a temperatura é mostrada na FIGURA 30.




FIGURA 30: Quantidade de melhores resultados por modelo para a temperatura – rede neural e modelo nebuloso.

Há três pontos, 2, 4 e 12, onde a rede neural apresenta um erro relativo menor para as duas grandezas. O modelo nebuloso apresenta um erro relativo menor para as duas grandezas em um único ponto, o ponto 13.

4.2 Rede de osciladores de Van Der Pol

4.2.1 Apresentação dos resultados estimados

Na TABELA 15, são apresentados os resultados da simulação, utilizando-se a rede de osciladores de Van Der Pol, das grandezas internas de uma casa de vegetação que são usados nas análises que se seguem e foram selecionados segundo os critérios e a metodologia expostos, anteriormente.

Ordem	Saída	
	Grandezas Internas Estimadas - Modelagem com Osciladores de Van Der Pol	
	Umidade Relativa do Ar (%)	Temperatura (°C)
1	52,7	22,5
2	58,6	23,0
3	59,5	22,5
4	54,3	24,4
5	76,9	22,1
6	51,1	26,2
7	48,8	25,5
8	56,6	25,3
9	63,9	25,5
10	67,4	24,1
11	68,8	24,6
12	77,1	25,2
13	74,4	22,6

TABELA 15: Resultados da simulação utilizando-se a rede de osciladores de Van Der Pol, das grandezas internas de uma casa de vegetação.

4.2.2 Comparação entre os resultados da rede de osciladores de Van Der Pol e valores medidos

Conforme pode ser constatado na TABELA 16, o valor estimado de umidade relativa do ar interna à casa de vegetação, através do modelo de rede de osciladores de Van Der Pol, apresenta um erro relativo ao valor medido entre 5,0% e 7,0% para os pontos 5, 6, 7, 9, 10 e 11. O erro relativo médio é de 4,1% para temperatura, com desvio padrão de 2,6%.

Ordem	Saída	
	Erro relativo entre valores estimados pela rede de osciladores de Van Der Pol e valores medidos	
	Umidade Relativa do Ar	Temperatura
1	2,8%	0,4%
2	1,0%	1,3%
3	5,1%	0,0%
4	0,5%	0,8%
5	6,1%	0,9%
6	6,8%	1,5%
7	5,6%	0,4%
8	2,9%	1,2%
9	5,9%	1,2%
10	6,9%	0,4%
11	5,5%	0,8%
12	0,8%	1,2%
13	3,6%	0,9%

TABELA 16: Erro relativo entre valores estimados pela rede de osciladores de Van Der Pol e valores medidos.

O comportamento do valor medido e do valor estimado pela rede de osciladores de Van Der Pol para a umidade relativa do ar pode ser observado na FIGURA 31.

Ainda reportando-se a TABELA 16, o valor estimado de temperatura interna à casa de vegetação, através do modelo de rede de osciladores de Van Der Pol, apresenta um erro relativo ao valor medido máximo de 1,5%. O erro relativo médio é de 0,8% para a temperatura, com desvio padrão de 0,4%.




FIGURA 31: Comportamento do valor medido e do valor estimado pela rede de osciladores de Van Der Pol para a umidade relativa do ar.

O comportamento do valor medido e do valor estimado pela rede de osciladores de Van Der Pol para a temperatura pode ser observado na FIGURA 32.




FIGURA 32: Comportamento do valor medido e do valor estimado pela rede de osciladores de Van Der Pol para a temperatura.

A dispersão para ambas as grandezas é elevada, mas considerando-se os baixos valores de erro relativo, na maioria dos pontos avaliados, os dados estimados por esse modelo serão considerados para análise.

Na FIGURA 33 pode-se observar um melhor comportamento do modelo baseado na rede de osciladores de Van Der Pol para os valores estimados de temperatura se comparado com os valores estimados de umidade relativa do ar.




FIGURA 33: Erro relativo dos valores estimados pela rede de osciladores de Van Der Pol para umidade relativa do ar e temperatura.

4.2.3 Comparação entre os resultados da rede de osciladores de Van Der Pol e da modelagem analítica

Na FIGURA 34, observa-se que a curva de erro relativo referente à rede de osciladores de Van Der Pol está abaixo da curva referente ao modelo analítico, exceto para os pontos 1 e 2. As curvas se cruzam uma única vez, o que denota que a rede com osciladores tem um desempenho melhor que o modelo analítico para a estimativa da umidade relativa do ar.




FIGURA 34: Comparação do erro relativo da umidade relativa do ar para a rede de osciladores e o modelo analítico.

Os erros relativos da rede de osciladores são inferiores ao modelo analítico em onze dos pontos estimados para a umidade relativa do ar, sendo que em cinco deles o erro reduziu-se em mais de 100%. A distribuição dos melhores resultados estimados entre os dois modelos para a umidade relativa do ar é mostrada na FIGURA 35.

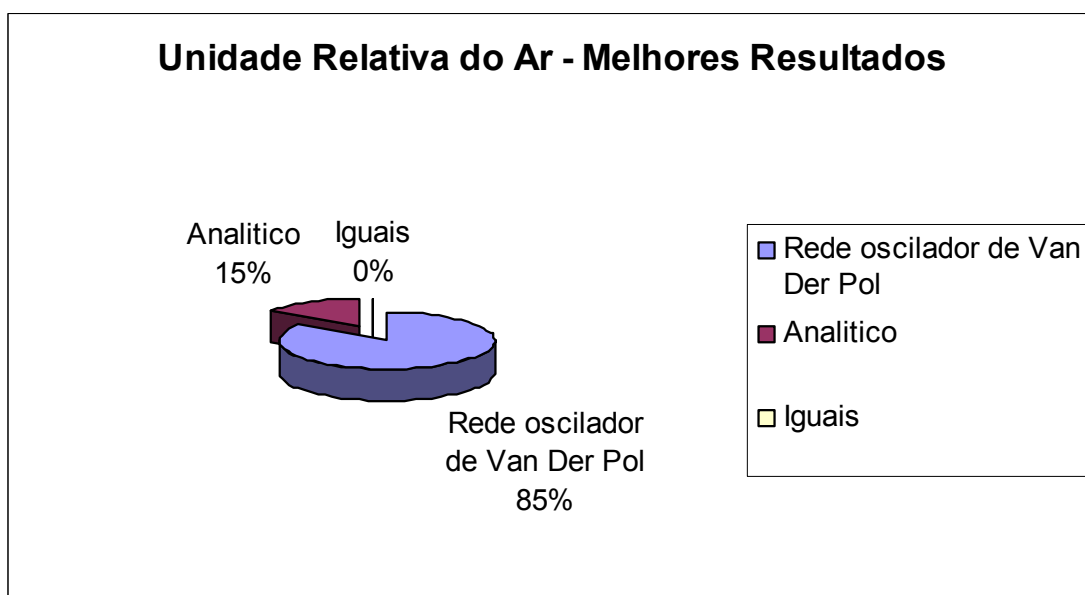


FIGURA 35: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede de osciladores e modelo analítico.

Na FIGURA 36, observa-se que a curva de erro relativo referente à rede de osciladores de Van Der Pol apresenta melhor desempenho se comparado ao modelo analítico para a temperatura. Em doze pontos, os resultados apresentados pela rede de osciladores são melhores ou iguais aos do modelo analítico. Ressalte-se que nos pontos 3 e 7, onde o modelo analítico apresenta os dois maiores erros relativos, a rede de osciladores mostra os menores erros relativos, sendo um deles praticamente nulo. O modelo analítico mostrou resultado melhor que a rede de osciladores para a temperatura no ponto 12, sendo que os modelos tiveram desempenho igual no ponto 10.

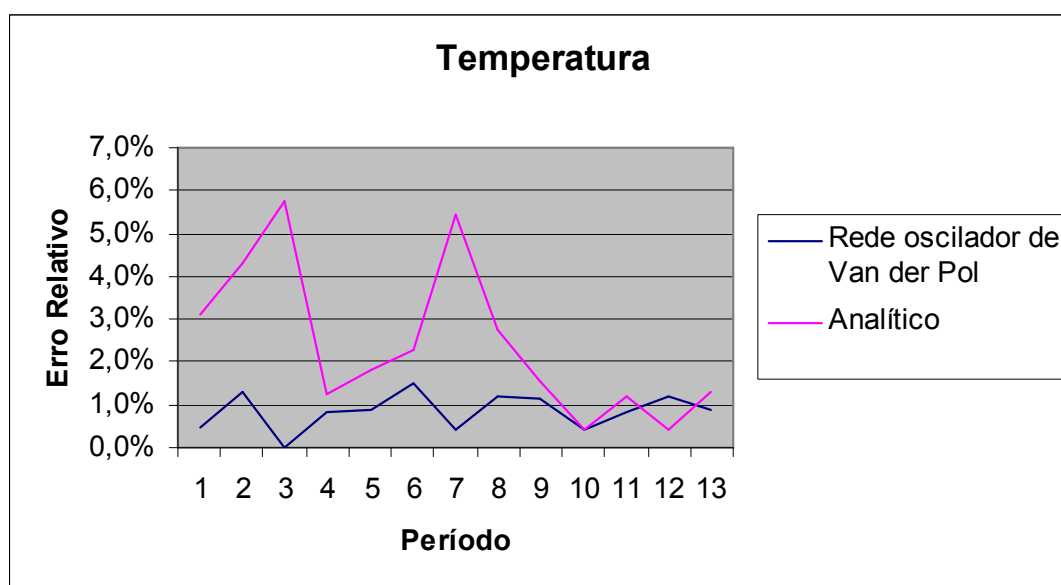


FIGURA 36: Comparação do erro relativo temperatura para a rede de osciladores e o modelo analítico

Assim, para a estimativa da temperatura, bem como para a estimativa da umidade relativa do ar, detecta-se um melhor desempenho da rede de osciladores em relação ao modelo analítico. A distribuição dos melhores resultados estimados entre os dois modelos para a temperatura é mostrada na FIGURA 37.




FIGURA 37: Quantidade de melhores resultados por modelo para a temperatura – rede de osciladores e modelo analítico.

Há dez pontos onde a rede de osciladores apresenta um erro relativo menor para as duas grandezas. O modelo analítico não apresenta um erro relativo menor para as duas grandezas em nenhum ponto.

4.2.4 Comparação entre os resultados da rede de osciladores de Van Der Pol e da modelagem nebulosa

Na FIGURA 38, observa-se que a curva de erro relativo referente à rede de osciladores de Van Der Pol cruza a curva referente ao modelo nebuloso seis vezes, denotando uma freqüente inversão de desempenho dos modelos. A rede de osciladores apresentou erro relativo menor em seis dos pontos analisados, enquanto o modelo nebuloso apresentou em sete dos pontos.




FIGURA 38: Comparação do erro relativo da umidade relativa do ar para a rede de osciladores e o modelo nebuloso.

Assim, para a estimativa da umidade relativa do ar, não se detecta uma clara supremacia de um método sobre o outro. Esta constatação, aliada a análise comparativa entre a rede neural e o modelo nebuloso, feita anteriormente neste trabalho, leva ao fato de que o desempenho da rede de osciladores é melhor do que o desempenho da rede neural para a umidade relativa do ar estimada. A distribuição dos melhores resultados estimados entre os dois modelos para a umidade relativa do ar é mostrada na FIGURA 39.




FIGURA 39: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede de osciladores e modelo nebuloso.

Na FIGURA 40, observa-se que o comportamento da curva de erro relativo referente à rede de osciladores de Van Der Pol apresenta melhor desempenho que o da curva referente ao modelo nebuloso para a temperatura. Ambas apresentam o mesmo resultado em três dos pontos analisados, sendo que nos outros dez pontos, os resultados apresentados pela rede de osciladores são melhores.




FIGURA 40: Comparação do erro relativo temperatura para a rede de osciladores e o modelo nebuloso.

Assim, para a estimativa da temperatura, diferentemente do constatado para a estimativa da umidade relativa do ar, detecta-se um melhor desempenho da rede de osciladores em relação ao modelo nebuloso. A distribuição dos melhores resultados estimados entre os dois modelos para a temperatura é mostrada na FIGURA 41.




FIGURA 41: Quantidade de melhores resultados por modelo para a temperatura – rede de osciladores e modelo nebuloso.

Há cinco pontos, 2, 4, 7, 8 e 12, onde a rede de osciladores apresenta um erro relativo menor para as duas grandezas. O modelo nebuloso não apresenta um erro relativo menor para as duas grandezas em nenhum ponto.

4.3 Comparação entre os resultados da rede de osciladores de Van Der Pol e da rede neural multicamadas

4.3.1 Valores estimados

Na FIGURA 42, observa-se que o comportamento da curva de erro relativo referente à rede de osciladores de Van Der Pol acompanha o da curva referente à rede neural quanto a sua direção e sentido para a umidade relativa do ar.




FIGURA 42: Comparação do erro relativo da umidade relativa do ar para a rede de osciladores e a rede neural.

Quanto à amplitude, excetuando-se dois pontos, que são mínimos locais, onde a rede neural apresentou erros menores, nos demais onze pontos, a rede de osciladores foi melhor, destacando-se a atenuação acentuada do erro nos pontos de máximo 6 e 10. A distribuição dos melhores resultados estimados entre os dois modelos para a umidade relativa do ar é mostrada na FIGURA 43.




FIGURA 43: Quantidade de melhores resultados por modelo para a umidade relativa do ar – rede de osciladores e rede de neural.

Na FIGURA 44, observa-se que o comportamento da curva de erro relativo referente à rede de osciladores de Van Der Pol difere significativamente da curva referente à rede neural para a temperatura. Ambas apresentam o mesmo resultado em sete dos pontos analisados, sendo que nos outros seis pontos, os resultados apresentados pela rede de osciladores são melhores. Nota-se que nos pontos 3 e 7, que são pontos de erro máximo para a rede neural, a rede de osciladores apresenta pontos de mínimo erro.




FIGURA 44: Comparação do erro relativo temperatura para a rede de osciladores e a rede neural.

A distribuição dos melhores resultados estimados entre os dois modelos para a temperatura é mostrada na FIGURA 45.

Há quatro pontos, 3, 7, 10 e 13, onde a rede de osciladores apresenta um erro relativo menor para as duas grandezas.




FIGURA 45: Quantidade de melhores resultados por modelo para a temperatura – rede de osciladores e rede de neural.

4.3.2 Desempenho computacional

Para a avaliação do desempenho computacional do modelo baseado em rede de osciladores de Van Der Pol foi feita uma comparação com o modelo utilizando a rede neural por se tratarem de métodos semelhantes e resultarem em valores de estimativas também semelhantes.

Para comparações em termos de desempenho computacional, utilizou-se como plataforma para as simulações, um microcomputador com processador AMD Athlon 1GHz, executando o sistema operacional Windows 2000.

Os parâmetros utilizados neste trabalho para medição do desempenho computacional são extraídos de (CROWL, 1994) e (BRYANT; O'HALLARON, 2002) e obtidos através de rotinas de extração de tempo disponíveis em bibliotecas da linguagem C.

Para o modelo usando a rede de osciladores de Van Der Pol, foram consideradas, para efeito de medida dos parâmetros de desempenho computacional, as oito simulações que apresentaram onze pares de grandezas (temperatura interna e umidade relativa do ar interna)

semelhantes aos pares de grandezas medianas do modelo em cada ponto estimado. Para o modelo usando a rede neural multicamadas, foram consideradas as dez simulações que apresentaram doze pares de grandezas semelhantes aos pares de grandezas medianas do modelo em cada ponto estimado.

O primeiro parâmetro utilizado são as medidas de tempo ou “tempo de CPU”, em segundos, que se referem ao tempo total consumido por uma CPU, no caso de processamento vetorial ou seqüencial somente, e ao tempo total consumido durante o processamento. Estão incluídas nestas medidas as operações alheias ao processamento, tais como operações do sistema, esperas, paginações, operações de entrada e saída a memórias secundárias entre outros. Os tempos apresentados, portanto, representam o resultado médio de diversas medidas efetuadas e constituem grandeza estatística.

A TABELA 17 apresenta o tempo de CPU total consumido em todo processamento de cada modelo. Observa-se que o modelo baseado em rede de osciladores de Van Der Pol apresenta um acréscimo de tempo de CPU da ordem de 5,3% em relação ao modelo baseado em rede neural. É importante citar que este acréscimo refere-se ao tempo total da análise: pré-processamento e processamento.

Modelo	CPU total (s)
Rede de osciladores de Van Der Pol	93,3
Rede neural	88,6

TABELA 17: Tempo total de CPU para cada modelo

Como segundo parâmetro, considerou-se a quantidade média de iterações necessárias para a obtenção dos resultados considerados nas análises anteriores.

Ressalte-se que a verificação da obtenção ou não do erro estipulado em cada simulação foi feita a cada 50 iterações.

Considerando-se o exposto, a quantidade de iterações necessárias foi de 4185, no caso da rede neural, e de 4513, no caso da rede de osciladores, o que representa uma degradação de 7,8% no desempenho da segunda em relação à primeira. Avaliando-se a imprecisão da medida, a degradação pode variar de 6,6% a 9,1%, sempre com um desempenho melhor da rede neural em relação à rede de osciladores.

4.4 Comparação geral entre os resultados estimados

O modelo baseado em rede de osciladores de Van Der Pol apresentou melhor resultado para as estimativas em doze pontos avaliados para a grandeza temperatura e o melhor resultado estimado em três pontos avaliados para a grandeza umidade relativa do ar. Um dos pontos, onde o modelo proposto mostrou desempenho melhor para a grandeza umidade relativa do ar, foi o único ponto no qual o modelo não teve o melhor desempenho para a grandeza temperatura. Assim, este modelo apresenta o melhor resultado em todos os treze pontos avaliados (100%), para pelo menos uma das duas grandezas, sendo que, em dois pontos, ele fornece o melhor resultado para ambas as grandezas (15,4%). Nenhum dos outros modelos avaliados obteve desempenho semelhante.

O modelo baseado em rede neural multicamadas apresentou melhor resultado estimado em seis pontos avaliados para a grandeza temperatura, sendo todos eles coincidentes com o modelo baseado em rede de Osciladores de Van Der Pol. O modelo baseado em rede neural apresentou, ainda, o melhor resultado estimado em dois pontos avaliados para a grandeza umidade relativa do ar. Assim, este modelo apresenta o melhor resultado em oito pontos avaliados (61,5%), para, pelo menos, uma das duas grandezas, sendo que, em nenhum ponto (0,0%), ele fornece o melhor resultado para ambas as grandezas.




FIGURA 46: Quantidade de melhores resultados por modelo para a umidade relativa do ar.

O modelo baseado em lógica nebulosa apresentou o melhor resultado estimado em três pontos avaliados para a grandeza temperatura, sendo todos eles coincidentes com o modelo baseado em rede de Osciladores de Van Der Pol. O modelo baseado em lógica nebulosa apresentou, ainda, o melhor resultado estimado em seis pontos avaliados para a grandeza umidade relativa do ar. Assim, este modelo apresenta o melhor resultado em sete pontos avaliados (53,8%), para, pelo menos, uma das duas grandezas, sendo que, em dois pontos (15,4%), ele fornece o melhor resultado para ambas as grandezas.




FIGURA 47: Quantidade de melhores resultados por modelo para a temperatura.

O modelo analítico apresentou melhor resultado estimado em dois pontos avaliados para a grandeza temperatura, sendo um deles coincidentes com o modelo baseado em rede de Osciladores de Van Der Pol. O modelo analítico apresentou, ainda, o melhor resultado estimado em dois pontos avaliados para a grandeza umidade relativa do ar. Assim, este modelo apresenta o melhor resultado em quatro pontos avaliados (30,8%), para, pelo menos, uma das duas grandezas, sendo que, em nenhum ponto (0,0%), ele fornece o melhor resultado para ambas as grandezas.




FIGURA 48: Percentagem de melhores resultados para ao menos uma das grandezas por modelo.

A somatória de melhores resultados para uma determinada grandeza pode superar a treze, pois, o melhor resultado para um ponto pode ser igualado para mais de um modelo.

As FIGURAS 46, 47, 48 e 49 apresentam os gráficos de desempenho comparativo para as variáveis analisadas.




FIGURA 49: Percentagem de melhores resultados para as duas grandezas, simultaneamente, por modelo.

5. CONSIDERAÇÕES FINAIS

5.1 Conclusões gerais

O uso do modelo de rede multicamada com osciladores de Van Der Pol para estimativa de variáveis abióticas de uma casa de vegetação é tão simples quanto o do modelo de rede neural artificial e o do modelo baseado em lógica nebulosa e permite modelos com boa capacidade de generalização e desempenhos adequados aos propósitos do trabalho. As diferenças entre os valores estimados pelo modelo proposto e os valores medidos foram consideravelmente pequenas. É importante ressaltar que o modelo proposto apresentou valores próximos das abordagens com redes neurais artificiais e com lógica nebulosa, quando considerados os conjuntos de dados cujas diversas simulações apresentaram baixo erro.

A metodologia proposta, neste trabalho, para a estimativa dos valores de temperatura e umidade relativa do ar dentro de uma casa de vegetação mostrou-se mais adequada do que as demais metodologias apresentadas na literatura, em especial, para as condições em que essas apresentaram significativo erro, em relação aos valores medidos.

A metodologia proposta apresentou ainda um comportamento mais adequado para a estimativa da grandeza temperatura do que para a grandeza umidade relativa do ar. Esta, no entanto, é uma característica que pode ser notada em todas as metodologias estudadas.

Uma restrição que o modelo possui é com relação à convergência das simulações. Conforme pode verificar-se, o modelo convergiu em 86,7% das simulações. Esta restrição, também, estende-se ao modelo com rede neural que convergiu em 90% das simulações. Neste aspecto, os modelos analítico e nebuloso não possuem restrições.

Em algumas combinações das variáveis de entrada dos modelos de estimativa das variáveis internas da casa de vegetação que são caracterizadas, principalmente, pela baixa frequência de ocorrência em condições de campo, mas, que são simuladas pelos modelos de estimativa,

o desempenho dos modelos foi prejudicado em virtude da falta de dados de treinamento, mas, ainda assim, o modelo proposto foi menos prejudicado por esta condição. O modelo apresentado permite erro menor em situações em que há poucos dados medidos e o analítico fica muito distante. Há necessidade de se obter maior quantidade de dados experimentais representativos de uma faixa mais ampla de combinações dessas variáveis de modo a ampliar a aplicabilidade dos modelos. Ressalte-se que se podem fazer comparações, entre valores simulados e valores medidos, em períodos maiores, utilizando dados horários ou diários, e com isso obter maior precisão do modelo.

O modelo de rede multicamada com osciladores apresentou um comportamento bastante semelhante ao modelo de rede neural artificial no que concerne ao desempenho computacional, o que permite supor, numa avaliação com o conjunto de dados disponíveis, que a melhora em termos de previsibilidade de resultados não implica em maior custo computacional.

5.2 Contribuições e perspectivas

Este trabalho apresentou contribuições de ordem metodológica e analítica, tais como, o desenvolvimento de modelo para utilização de redes multicamadas de osciladores de Van Der Pol na previsão da temperatura e da umidade relativa do ar dentro de uma casa de vegetação, o que constituiu um procedimento inédito nesse domínio do conhecimento. Os resultados obtidos mostraram a viabilidade da aplicação da metodologia proposta e sugerem um alto potencial para modelagem de outros processos ligados a área da automação agrícola adotando-se procedimentos similares. A disponibilidade de um modelo diferenciado de estimativa de variáveis internas de uma casa de vegetação constitui contribuição para tomada de decisão em sistemas de controle deste tipo de ambiente.

A ampliação da quantidade de variáveis de entrada e de saída com intuito de refinamento do modelo, a avaliação de outras categorias de redes, além de redes multicamadas e o estudo de outras funções de ativação que

permitam a obtenção de uma melhora no comportamento matemático das estimativas são algumas das perspectivas de desenvolvimento de outras pesquisas no âmbito da modelagem de casas de vegetação.

O bom comportamento do modelo usando lógica nebulosa indica que o uso da tecnologia neurofuzzy em conjunto com osciladores de Van Der Pol deve ser alvo de futuros estudos. A lógica neurofuzzy é uma tecnologia de inteligência artificial que gera regras diretamente de dados numéricos, e associa probabilidades a estas regras. A lógica neurofuzzy combina a lógica nebulosa com o aprendizado e capacidades adaptativas de redes neurais. Isto significa que o usuário pode inicializar a rede neural usando conhecimento apurado com regras nebulosas, e então treinar-la usando dados numéricos. Após treinar a rede, as regras podem ser avaliadas e editadas para sobrepor qualquer deficiência nos dados treinados (SILER; BUCKLEY, 2004).

A teoria do Caos é freqüentemente citada como uma explicação para a dificuldade de prever o tempo e outros sistemas complexos. De um modo geral o Caos mostra que pequenas mudanças em condições locais podem causar uma importante mudança global (HOLLAND, 1998). Assim, a modelagem considerando esta abordagem deve ser levada em conta em futuros trabalhos.

REFERÊNCIAS

- ASHRAE. Environment control for animals and plants. **ASHRAE Handbook of Applications**. USA: ASHRAE, 1978.
- ALBRIGHT, L.D. **Environment control for animals and plants**. St. Joseph: ASAE, 1990.
- AL-FARAJ, A.; MEYER, G.E.; HORST, G.L. A crop water stress index for tall fescue irrigation decision-making - a fuzzy logic method. **Computers and Eletronics in Agriculture**, v. 32, p. 69-84, 2001
- BALDI, P.; HORNIK, K. Neural networks and principal components analysis: learning from examples without local minima **Neural Networks**, 2: pp. 53-58, 1989.
- BAUCHSPIESS, A. **Introdução aos Sistemas Inteligentes Redes Neurais Artificiais, Lógica Fuzzy e Sistemas Neuro-Fuzzy**, Brasília: Universidade de Brasília, 2004. Disponível em: <<http://www.ene.unbr.br/adolfo/ISI>>. Acesso em 18/09/2005.
- BELTRÃO, N.E. de M. Caracterização de sistemas e tecnologias de cultivo para a cotonicultura herbácea, com ênfase para o Norte de Minas Gerais. Campina Grande: **EMBRAPA-CNPA**. 1997. 56p. Documentos, 55, 1997.
- BISHOP, C. **Neural Networks for Pattern Recognition** Oxford Press, 2005
- BRYANT, R. E.; O'HALLARON, D. R. **Computer Systems: Programmer's Perspective**. New Jersey: Prentice Hall, 2002.
- COSTA, E.; LEAL, P. A. M.; CARMO JÚNIOR, R. R. 2004. Modelo de Simulação da temperatura e umidade relativa no interior de estufa plástica, **Journal of the Brazilian Association of Agricultural Engineering**, v. 24, n. 1, p. 57-67, jan./abr. 2004.
- CROWL, L. A., How to Measure, Present, and Compare Parallel Performance, **IEEE Parallel and Distributed Technology**, p. 9-25, Spring, 1994.
- DE LA VEGA, M.L.B.P. **Fitomonitoração e modelagem de fotossíntese em jatobá (*Hymenaea courbaril* L.) com redes neurais artificiais**. 2003. 188p. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo. São Paulo, 2003.
- DRAZIN, P.G. **Nonlinear Systems**. Cambridge: Cambridge University Press, 1997.

ENDO, T.; CHUA, L.O.; TAKEYAMA, K. A. Neural Network Using Oscillators, **IEEE Trans. Circuits & Systems**, p. 782-785, April 1991.

EVSUKOFF, A.; BRANCO, A.C.S.; GALICHET, S. Structure identification and parameter optimization for non-linear fuzzy modeling. **Fuzzy Sets and Systems**, v. 132, p. 173-188, 2002.

FAUSETT, L. **Fundamentals of Neural Networks Architectures, Algorithms and Applications**. New Jersey: Prentice Hall, 1994.

FERREIRA, P. M., RUANO, A. E.. Soft-computing methods in greenhouse environmental and crop modelling, **EFITA/WCCA Joint Congress on IT in Agriculture**, 25-28 July 2005, Vila Real, Portugal., 2005

FIESLER, E.; BEALE, R. **Handbook of Neural Computation**. New York: Institute of Physics and Oxford University Press, 1997.

HAYKIN, S.; **Neural Networks: A comprehensive foundation**. New Jersey: Prentice Hall, 1999.

HANSELMAN, D.; LITTLEFIELD, B.; **Matlab 6 – Curso Completo**. São Paulo: Prentice Hall , 2003.

HASSOUN, M. H. **Fundamentals of artificial neural networks** MIT Press, Cambridge, M.A., 1995.

HEBB, D. O. **The Organization of Behaviour**. New York: John Wiley & Sons., 1949.

HELLICKSON, M.A. **Ventilation of agricultural structures**.. St. Joseph: ASAE, 1983.

HOLLAND, J. H. **Emergence- From Chaos to Order**. Reading: Addison-Wesley Publishing Company Inc., 1998.

HONÓRIO, S.L.; BLISKA JÚNIOR, A. **Cartilha tecnológica: plasticultura e estufa**. Campinas: FEAGRI/UNICAMP, 1996.

HOPFIELD, J.J. Neural networks and physical systems with emergent collective computational abilities. **Procedures National Academic Science**, 1982, 79, pp. 2554-2558.

HOPFIELD, J.J.; TANK, D. W. "Neural" Computation of Decisions in Optimization Problems. **Biological Cybernetics**, 1985, 52, pp. 141-152

KHALIL H.K. **Nonlinear System**. New Jersey: Prentice Hall, 1994

KOHONEN, T.. **Self-Organization and Associative Memory**. Springer-Verlag Series in Information Science. 1987.

HUANG, S.H.; XING, H. Extract intelligible and concise fuzzy rules from neural networks. **Fuzzy Sets and Systems**, v. 132, p. 233-243, 2002.

ROSENBLATT, R. **Principles of Neurodynamics**. New York.: Spartan Books, 1959.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J.; Learning representations of back-propagation errors, **Nature**, 323 (1986) 533-536.

KOVÁCS, Z. L. **Redes Neurais Artificiais: Fundamentos e Aplicações**. São Paulo: Editora Livraria da Física, 2002.

LIMA, J. P. H. **Redes neurais artificiais aplicadas à otimização de processos de deposição de filmes finos poliméricos**. 2006. 90 p. Dissertação (Mestrado) - Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.

MAGALHÃES, A.C.N. Fotossíntese. In: Ferri, M.G. (ed.). **Fisiologia vegetal 1**. São Paulo: Editora da Universidade de São Paulo, 1979.

MOTA, F.S. da. **Meteorologia agrícola**. São Paulo, SP: Nobel, 1976.

MENDEL, J. M.; McLAREN, R.W. **Adaptive, Learning, and Pattern Recognition System; Theory and Applications** Academic Press, 1970.

McCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Imminent in Nervous Activity. **Bulletin of Mathematical Biophysics**, 5, pp.115-133, 1943.

McELIECE, R. J.; POSNER, E. C.; RODEMICH, E.R.; VENKATESH, S.S. The capacity of the hopfield associative **memory IEEE Transactions on Information Theory**, 33:pp. 461-482, 1987.

MEHROTRA, K; MOHAN, C. K., RANKA, S. **Elements of Artificial Neural Networks**. MIT press , 1997.

MONTEIRO, L.H.A., **Sistemas Dinâmicos**. 1ª ed. São Paulo: Editora Livraria da Física, 2002.

OLIVEIRA, M.R.V. de. O emprego de casas-de-vegetação no Brasil: vantagens e desvantagens. **Pesquisa Agropecuária Brasileira**, Brasília, v.30, n.8, p.1049-1060, 1995.

OSORIO, F. S.; VIEIRA, R. Sistemas Híbridos Inteligentes. In: **ENIA'99 – Encontro Nacional de Inteligência Artificial (Tutorial)**. Congresso da SBC'99. Rio de Janeiro, 1999.

RICH, E.; KNIGHT K. **Inteligencia Artificial**. São Paulo: Makron Books do Brasil, 1993.

ROSENBLATT, R. **Principles of Neurodynamics**. New York.: Spartan Books, 1959.

SACHS, L. **Applied statistics – A handbook of techniques**. New York: Springer-Verlag Inc., 1984. 707p. (second edition).

SEdgeWICK, R. **Algorithms In C, Parts 1-5 (Bundle)**. Reading: Addison-Wesley Publishing Company Inc., 2001.

SHAW, I.S.; SIMÕES, M.G. **Controle e Modelagem Fuzzy**. São Paulo: Edgard Blucher, 1999.

SILER, W.; BUCKLEY, J.J. **Fuzzy Expert Systems and Fuzzy Reasoning**. New York: John Wiley Professional, 2004.

SILVÉRIO M.; BERNARDO J.I.; AMANCIO S.M.; HIRAKAWA A.R.; ATARASSI R.T. Greenhouse analytical modeling with spatial variability identification, **Proceedings of 8th International Conference on Precision Agriculture**, v. 1, p. 1-6., Minneapolis, 2006.

STEEB, W. H. **The Nonlinear Workbook**. Singapore: World Scientific, 2002.

STROGATZ, S. H. **Nonlinear Dynamics and Chaos with Applications to Physics, Biology, Chemistry, and Engineering**. Reading: Perseus Book, 1998.

SUTTON, R.S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. MIT Press (A Bradford Book), Cambridge, MA, 1998.

THOMSEY, J. M.; SMITH, A. E.; Performance Measures, Consistency, and power for artificial neural network models, **Mathematical Computation Modeling**, 21 (1995) p. 243-258, 1995.

WIDROW, B.; LEHR, M. 30 Years of Adaptive Neural Networks : **Perceptron, Madaline, and Back-Propagation. Proceedings of the IEEE**, September 1990, New York, Vol.78, N.9, pp.1415-1441.