



UNIVERSIDADE
ESTADUAL DE LONDRINA

ISABELLA PERES GUALDA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA
CIÊNCIA E TECNOLOGIA DE ALIMENTOS:
ESTUDO DE CASOS**

Londrina
2008

ISABELLA PERES GUALDA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA
CIÊNCIA E TECNOLOGIA DE ALIMENTOS:
ESTUDO DE CASOS**

Dissertação apresentada ao Programa de Pós-Graduação, em Ciência de Alimentos da Universidade Estadual de Londrina, como requisito parcial à obtenção do título de Mestre em Ciência de Alimentos.

Orientador: Prof. Dr. Rui Sergio dos Santos Ferreira da Silva

Londrina
2008

ISABELLA PERES GUALDA

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS NA
CIÊNCIA E TECNOLOGIA DE ALIMENTOS:
ESTUDO DE CASOS**

Dissertação apresentada ao Programa de Pós-Graduação, em Ciência de Alimentos da Universidade Estadual de Londrina, como requisito parcial à obtenção do título de Mestre em Ciência de Alimentos.

BANCA EXAMINADORA

Rui Sérgio dos Santos Ferreira da Silva
[Orientador]

Dionísio Borsato

Fábio Yamashita

Londrina, 9 de junho de 2008.

AGRADECIMENTOS

A realização deste trabalho não é mérito individual, mas resultado da contribuição de inúmeras pessoas que participaram direta ou indiretamente para o seu desenvolvimento. Agradeço a todas elas e, de forma particular:

Agradeço em primeiro lugar a Deus que iluminou o meu caminho durante esta caminhada.

Em especial aos meus queridos pais, Wadson e Solange pelas orações, pelo conselho, empenho, estímulo, força para realizar este trabalho e o grande amor dado a mim em todos os momentos bons e ruins de minha vida.

Aos meus avós Daniel e Maria Josefa que foram fundamentais na formação do meu caráter e na pessoa que sou hoje .

A minha irmã Danielle, a "Dan", por ser minha melhor amiga e estar sempre disposta a ouvir meus desabafos, reclamações e me ajudar nas tomadas de decisões.

Agradeço também ao meu namorado, Bruno, que de forma especial e carinhosa me deu força e coragem, me apoiando nos momentos de dificuldades.

Ao meu orientador, Prof. Dr. Rui Sérgio dos Santos Ferreira da Silva, pelas orientações, discussões enriquecedoras, paciência durante a realização deste trabalho.

Agradeço ao Evandro Bona por todo tempo e auxílio.

A Profa Dra. Sandra Cachoeira Stertz que gentilmente disponibilizou o banco de dados utilizado.

Ao CNPQ pelo apoio financeiro durante o curso de mestrado

Aos amigos, o mais sincero agradecimento, pois sem vocês a vida vale pouco.

"A maior recompensa pelo esforço de uma pessoa não é o que ela ganha com isso, mas o que ela se torna através dele."

John Ruskinz

GUALDA, Isabella Peres. **Aplicação de Redes Neurais Artificiais na Ciência e Tecnologia de Alimentos: Estudo de casos.** 2008. 136 f. Dissertação (Mestrado em Ciências de Alimentos) – Universidade Estadual de Londrina, Londrina, 2008..

RESUMO

Redes Neurais Artificiais (RNAs) são uma forma de computação não-algorítmica capaz de resolver problemas complexos obtendo resultados melhores que os métodos matemáticos. As RNAs têm sido aplicadas em muitas áreas da ciência e tecnologia de alimentos, principalmente em problemas de classificação, predição, reconhecimento de padrões e controle. Este trabalho trata dois casos. O primeiro caso simula a salga mista de queijo prato e utilizou uma rede Função Base Radial (RBF). Essas redes são consideradas aproximadoras universais de funções. O modelo que apresentou melhor resultado foi o desenvolvido com 7 variáveis de entrada: as três dimensões do queijo (X, Y e Z), tempo de salga, concentrações iniciais de NaCl e KCl na salmoura e condição de contorno (salga estática ou agitada), 29 neurônios na camada intermediária e 13 vizinhos mais próximos de K. O desvio na simulação foi de 5,5% para NaCl e 4,4% para KCl. O segundo caso foi uma tentativa de classificar hortícolas quanto à sua forma de cultivo (convencional, hidropônico e orgânico). Foram utilizadas redes Perceptron de Múltiplas Camadas (MLP). A rede MLP é muito empregada em classificações devido ao seu grande poder de generalização. As topologias que apresentaram classificação (acerto de 100% no treinamento e validação) foram as seguintes. Para o morango, rede com 12 variáveis de entrada (Mg, Al, Fe, Mn, Co, Cu, frutose, sacarose, nitrato, lipídios e carboidratos) e 6 neurônios na camada intermediária. Para alfaces crespas redes com 30 variáveis de entrada (composição centesimal, açúcares, todos os minerais, soma de açúcares, soma de minerais, nitrato, nitrito e soma nitrato+nitrito) e com 10 e 13 neurônios na camada oculta classificaram, respectivamente, quando foram comparados os cultivos convencional X orgânico e orgânico X hidropônico. Na comparação entre cultivos convencional e hidropônico foram necessárias 13 variáveis de entrada (Na, Mg, Al, Fe, Mn, Se, Hg, Pb, soma de açúcares, cinzas, lipídeos e energia) e 5 neurônios na camada escondida. No tomate cereja, os modelos que apresentaram classificação foram os que utilizaram 15 variáveis de entrada (Na, Mg, Al, Ca, Fe, Mn, Cd, Pb, nitrato, nitrito, soma nitrato+nitrito, cinzas, lipídios, proteínas e energia) e 10 neurônios quando se comparou os cultivos orgânico e hidropônico. Ainda, 11 variáveis (Na, Mg, P, Ca, Fe, Mn, Zn, Cd, nitrato, soma nitrato+nitrito e lipídios) e 4 neurônios na camada oculta quando os cultivos convencional e hidropônico foram comparados. Este trabalho adiciona evidências ao potencial de aplicação das RNAs para modelar tarefas complexas no controle e simulação de processos alimentares e na capacidade de classificação de dados na análise de alimentos.

Palavras-chave: Redes neurais artificiais. Simulação. Salga. Classificação. Orgânico. Hidropônico e convencional.

GUALDA, Isabella Peres. **Application of Artificial Neural Network in Technology and Food Science** : A study case. 2008. 136 p. Dissertation (Master`s degree in Food Science) –The State University of Londrina, Londrina, 2008.

ABSTRACT

Artificial Neural Networks (ANNs) are a non algorithm computing method capable of solving complex problems, getting better results than mathematical methods. The artificial neural networks has been used in many areas of technology and food science, most of them in classification problems, prediction, pattern recognition and control. This study approach two different situations. The first one simulates the brining of prato Brazilian cheese and uses a radial basis function (RBF). These networks are considerate universal function approximation. The model that have the best result was develop with 7 input variables: Three dimensions of cheese (X, Y, and Z), time of brining, NaCl and KCl inicial concentrations in the brining and boundary conditions (stationary or with agitation brine), 29 units in the hide layer and 13 K-Nearest neighbors. The simulation deviation was about 5,5% for NaCl and 4,4% for KCl. The second situation was an attempt to assort some horticultural based on the cultivation (conventional, hydroponic and organic). Multi Layer Perceptron (MLP) networks have been used to do that. The MLP has a great ability of generalization and is very used in classification problems. The topologies that acquired classification (100% in training and validation) was as follow: Strawberry, network with 12 input variables (Mg, Al, Fe, Mn, Co, Cu, fructose, sucrose, nitrate, lipid e carbohydrate) and 6 units in the hide layer. For crispleaf lettuce networks with 30 input variables (composition centesimal, sugars, all the minerals, sugars's sum, minerals's sum, nitrate, nitrite e sum of nitrate+nitrite) and with 10 and 13 units in the hide layer, was classificated when compared with conventional cultivation X organic cultivation and organic cultivation X hydroponic cultivation. For the comparison between conventional cultivation and hydroponic cultivation was used 13 input entries variables (Na, Mg, Al, Fe, Mn, Se, Hg, Pb, sugars' sum, ash, lipids e energy) and 5 units in the hide layer. Using the cherry tomato the model that could be classified was the one that has used 15 input variables (Na, Mg, Al, Ca, Fe, Mn, Cd, Pb, nitrate, nitrite, sum of nitrate+nitrite, ash, lipids, proteins and energy) and 10 units when compared agaist organic and hydroponic cultivation. Yet, 11 input variables (Na, Mg, P, Ca, Fe, Mn, Zn, Cd, nitrate, sum of nitrate+nitrite e lipids) and 4 units in the hide layer when the conventional and hydroponic cultivation where compared each other. This study adds some evidence to the potential of the ANN application to modeling complex tasks in the control and simulation of food process and the capacity of data classification in food analysis.

Keywords: Artificial neural networks. Simulation. Brine. Classification. Organic. Hydroponic and conventional.

LISTA DE FIGURAS

Figura 1	– Representação de um neurônio	19
Figura 2	– Sinapse entre neurônios	20
Figura 3	– Neurônio artificial projetado por McCulloch	20
Figura 4	– Modelo de um neurônio artificial	21
Figura 5	– Função sinal (a) e sua derivada em relação à entrada interna (b).....	22
Figura 6	– Função de ativação semi-linear (a) e sua derivada (b)	23
Figura 7	– Função de ativação Sigmóide (a) e sua derivada (b).....	23
Figura 8	– Tangente hiperbólica (a) e sua derivada (b).....	24
Figura 9	– Camadas de uma Rede Neural Artificial (RNA)	25
Figura 10	– Rede Direta (<i>Feedforward</i>).....	26
Figura 11	– Rede com Ciclos (<i>Feedback</i>).....	27
Figura 12	– Fase de Propagação.....	32
Figura 13	– Fase de Retropropagação.....	32
Figura 14	– Etapas para o desenvolvimento de um modelo de RNA.....	37
Figura 15	– Convensão adotada para os eixos imaginários, com origem no centro geométrico da amostra para identificação da simetria	52
Figura 16	– Caixa de diálogo inicial do Statistica - módulo De Redes Neurais Artificiais.....	56
Figura 17	– Caixa de diálogo do Statistica 7.1 para escolha do tipo de problema, variáveis e tipo de análise	57
Figura 18	– Caixa de diálogo do Statistica 7.1 para escolha do tipo de rede e quantidade de neurônios na camada escondida.....	58
Figura 19	– Caixa de diálogo do Statistica 7.1 - Treinamento da Rede de Função de Base Radial	59
Figura 20	– Caixa de diálogo do Statistica 7.1 - Resultados	59
Figura 21	– Caixa de diálogo do Statistica 7.1 - Continuação de Resultados.....	60
Figura 22	– Gráfico de comparação entre os valores previsto - NaCl2 (X) e os valores obtidos - NaCl2. 16 (Y) para concentração de NaCl.....	71
Figura 23	– Gráfico de comparação entre os valores previsto - KCl2 (X) e os valores obtidos - KCl2. 16 (Y) para concentração de KCl	72

Figura 24 – Desempenho de vendas de agrotóxicos no Brasil em 2006 Fonte: SINDAG, 2006	80
Figura 25 – Área plantada de alimentos orgânicos e hectares. Fonte: YUSSEFI, 2003.....	83
Figura 26 – Caixa de Diálogo inicial do Statistica - Módulo de Redes Neurais.....	93
Figura 27 – Caixa de diálogo para seleção das variáveis	94
Figura 28 – Especificação dos códigos das variáveis subset.....	94
Figura 29 – Caixa de diálogo para escolha da rede	95
Figura 30 – Caixa de diálogo para seleção da quantidade de camadas escondidas, neurônios nas camadas escondidas e função do erro de classificação.....	96
Figura 31 – Caixa de diálogo de parâmetros de treinamento.....	97
Figura 32 – Caixa de diálogo dos resultados	98
Figura 33 – Continuação da caixa de diálogo de resultados	99

LISTA DE TABELAS

Tabela 1 – Comparação nutricional entre queijo, carne e ovo (%) composição bruta.....	46
Tabela 2 – Proporção em massa entre os sais NaCl e KCL na salmoura	53
Tabela 3 – Análise de Sensibilidade das redes com eixos X, Y, Z, volume, Concentração inicial de NaCl e KCl, e tempo de salga como variáveis de entrada e neurônios entre 15 e 24	62
Tabela 4 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z.....	63
Tabela 5 – Desempenho de treinamento, validação e teste das redes com o volume	64
Tabela 6 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, neurônios variando de 25 a 30 e 35 e vizinhos mais próximos variando entre 9 e 15	65
Tabela 7 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29, 30 e 35 neurônios e vizinhos mais próximos variando entre 9 e 15	67
Tabela 8 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29, 30 e 35 neurônios e vizinhos mais próximos variando entre 9 e 15.....	68
Tabela 9 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29, 30 e 35 neurônios e vizinhos mais próximos variando entre 9 e 15.....	69
Tabela 10 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29 neurônios e 9 vizinhos mais próximos.....	70
Tabela 11 – Análise estatística de uma rede RBF com 29 neurônios e 13 vizinhos mais próximos K	70
Tabela 12 – Desempenho de treinamento, validação da classificação de morangos com 30 variáveis de entrada e variação entre 5 e 15 neurônios na camada intermediária	102
Tabela 13 – Análise de Sensibilidade das redes com 13 neurônios na camada intermediária.....	103

Tabela 14 – Desempenho de treinamento, validação da classificação de morangos com variação entre 4 e 8 neurônios na camada intermediária	104
Tabela 15 – Análise de sensibilidade da comparação entre alface convencional e orgânico e com 10 neurônios na camada intermediária	106
Tabela 16 – Análise de sensibilidade da comparação entre alface orgânico e hidropônico com 13 neurônios na camada intermediária	107
Tabela 17 – Análise de sensibilidade da comparação entre alface cressa convencional e hidropônico com 9 neurônios na camada intermediária	108
Tabela 18 – Análise de Sensibilidade da comparação entre tomate cereja Orgânico e Hidropônico com 8 neurônios na camada intermediária	111
Tabela 19 – Análise de sensibilidade da comparação entre tomate cereja convencional e hidropônico com 10 neurônios na camada intermediária	112

SUMÁRIO

INTRODUÇÃO GERAL	13
CAPÍTULO 1 – REDES NEURAIS ARTIFICIAIS	15
1 REVISÃO BIBLIOGRÁFICA	16
1.1 INTELIGÊNCIA ARTIFICIAL	16
1.2 REDES NEURAIS ARTIFICIAIS - RNAs	16
1.3 HISTÓRICO RNAs	17
1.4 CÉREBRO HUMANO E O NEURÔNIO BIOLÓGICO.....	19
1.5 NEURÔNIO ARTIFICIAL	20
1.6 ARQUITETURA DAS RNAs	24
1.7 APRENDIZADO RNAs	27
1.7.1 Algoritmo Backpropagation	29
1.8 REDES MULTILAYER PERCEPTRON - MLP	33
1.9 FUNÇÃO DE BASE RADIAL - RBF	34
1.10 MODELAGEM EM REDES NEURAIS ARTIFICIAIS.....	37
CAPÍTULO 2 – APLICAÇÕES DE REDES NEURAIS ARTIFICIAIS NA SALGA MISTA COM NaCl E KCl EM QUEIJO PRATO	41
1 INTRODUÇÃO	42
2 REVISÃO BIBLIOGRÁFICA	43
2.1 HIPERTENSÃO ARTERIAL E O CLORETO DE SÓDIO.....	43
2.2 QUEIJO PRATO E A REDUÇÃO DE CLORETO DE SÓDIO.....	46
2.3 DIFUSÃO	48
3 OBJETIVOS	51
3.1 OBJETIVO GERAL.....	51
3.2 OBJETIVOS ESPECÍFICOS.....	51
4 MATERIAL E MÉTODOS	52
4.1 QUEIJO PRATO	52
4.2 SIMULAÇÃO	52
4.3 APLICATIVO COMPUTACIONAL	54
4.4 DESENVOLVIMENTO DA REDE NEURAL: MANUAL DE OPERAÇÃO	55

5 RESULTADOS E DISCUSSÃO	62
6 CONCLUSÃO	73

CAPÍTULO 3 – UTILIZAÇÃO DE REDES NEURAIIS ARTIFICIAIS PARA CLASSIFICAR FRUTAS E HORTALIÇAS QUANTO A SUA FORMA DE CULTIVO: CONVENCIONAL, ORGÂNICO E HIDROPÔNICO	74
---	----

1 INTRODUÇÃO	75
---------------------------	----

2 REVISÃO BIBIOGRÁFICA	77
-------------------------------------	----

2.1 AGRICULTURA CONVENCIONAL	77
------------------------------------	----

2.2 AGRICULTURA ORGÂNICA	81
--------------------------------	----

2.3 AGRICULTURA HIDROPÔNICA	86
-----------------------------------	----

3 OBJETIVOS	89
--------------------------	----

3.1 OBJETIVO GERAL	89
--------------------------	----

3.2 OBJETIVOS ESPECÍFICOS	89
---------------------------------	----

4 MATERIAL E MÉTODOS	90
-----------------------------------	----

4.1 BANCO DE DADOS	90
--------------------------	----

4.2 APLICATIVO COMPUTACIONAL	91
------------------------------------	----

4.3 DESENVOLVIMENTO DAS REDES NEURAIIS: MANUAL DE OPERAÇÃO	92
--	----

5 RESULTADOS E DISCUSSÃO	101
---------------------------------------	-----

5.1 MORANGO	101
-------------------	-----

5.2 ALFACE CRESPA	105
-------------------------	-----

5.3 TOMATE CEREJA	110
-------------------------	-----

6 CONCLUSÃO	114
--------------------------	-----

REFERÊNCIAS	115
--------------------------	-----

ANEXOS	131
---------------------	-----

ANEXO 1 – Tabela com as medidas e volume dos três tamanhos de queijo	132
--	-----

ANEXO 2 – Tabela formulada no statistica 7.1 para estudo do queijo prato	133
--	-----

ANEXO 3 – Exemplo da tabela formulada no Statistica para o estudo da classificação de hortícolas quanto seu tipo de cultivo	134
---	-----

INTRODUÇÃO GERAL

O estudo das redes neurais artificiais é algo fascinante e esse fascínio aumenta à medida que se tem mais conhecimento sobre o assunto. Trata-se de um conceito de extrema importância da computação, responsável pela solução de muitos problemas complexos (ALECRIM, 2004).

As aplicações de RNAs são inúmeras. Podem ser utilizadas para analisar dados e processamento de sinais, controle de processos, robótica, análise de aroma (nariz eletrônico) e cor, classificação de dados, etc. Com base em bancos de dados de redes neurais específicas é possível prever novos valores, utilizando-se de um mínimo de dados experimentais, o que pode agilizar a determinação de parâmetros desconhecidos (VALE et al, 2000). Este procedimento computacional vem sendo utilizado em várias áreas da ciência e tecnologia de alimentos.

No capítulo 1 foi apresentada uma revisão bibliográfica sobre as Redes Neurais Artificiais, o que são, o histórico, principais arquiteturas formas de aprendizados, e algumas utilizações da área de ciências e tecnologia de alimentos.

O capítulo 2 aborda sobre um grave problema na sociedade mundial, a hipertensão arterial, que dentre as principais formas de amenizá-la esta a diminuição do consumo de Cloreto de sódio, mais conhecido como sal de cozinha e muito utilizado na fabricação de produtos alimentícios. Neste capítulo mostra estudos que vem sendo feito para substituição de parte de NaCl por KCl em queijos práticos e a utilização de uma rede do tipo RBF na determinação das concentrações finais de NaCl e KCl na salga do queijo prato.

O capítulo 3 através da revisão bibliográfica mostra a crescente preocupação dos consumidores com relação aos temas como: segurança alimentar, meio ambiente, bem-estar social e saúde. E que cada vez mais pessoas estão dispostas a pagar mais caro por "alimentos naturais" que não contenham produtos químicos ou outras fontes de contaminação. Visando atender as tendências do mercado e exigências dos consumidores a ciência agrícola tem trabalhado com novas formas de cultivo de hortícolas como a agricultura orgânica, hidropônica entre outras. Porém, há poucos estudos com controle efetivo que comparam alimentos obtidos pelos sistemas de cultivo convencional, orgânico e hidropônico, capazes de conclusões válidas cientificamente. Neste capítulo, foram testadas redes neurais

artificiais do tipo Multilayer Perceptron (MLP) para tentar classificar alimentos quanto sua forma de cultivo (Convencional, Orgânica e Hidropónica).

Capítulo 1 – REDES NEURAIS ARTIFICIAIS

1 REVISÃO BIBLIOGRÁFICA

1.1 INTELIGÊNCIA ARTIFICIAL

O objetivo da Inteligência Artificial (IA) é o desenvolvimento de paradigmas ou algoritmos que requeiram máquinas para realizar tarefas cognitivas, para as quais os humanos são atualmente melhores (SAGE, 1990).

Um sistema de IA deve ser capaz de fazer três coisas: (i) armazenar conhecimento, (ii) aplicar o conhecimento armazenado para resolver problemas e (iii) adquirir novo conhecimento através da experiência (HAYKIN, 2001).

1.2 REDES NEURAIS ARTIFICIAIS - RNAs

As redes neurais artificiais consistem em um método de solucionar problemas de inteligência artificial, construindo um sistema que tenha circuitos que simulem o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São mais que isso são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto que o cérebro de um mamífero pode ter muitos bilhões de neurônios (DIN, 2006). As redes neurais artificiais tentam reproduzir as funções das redes biológicas, buscando implementar seu comportamento básico e sua dinâmica (BRAGA; CARVALHO; LUDEMIR, 2000).

Para se definir RNAs são necessárias 3 palavras chaves: *neurônio*, que é a unidade computacional básica na rede em questão; *arquitetura*, estrutura topológica de como os neurônios são conectados; *aprendizagem*, processo que adapta a rede de modo a computar uma função desejada ou realizar uma tarefa.

As RNAs são uma forma de computação não-algorítmica. Por não ser baseadas em regras ou programas, a computação neural se constitui em uma

alternativa à computação algorítmica convencional (BRAGA; CARVALHO; LUDEMIR, 2000).

A rede neural artificial é um sistema de neurônios ligado por conexões sinápticas e dividido em neurônios de entrada, que recebe estímulos do meio externo, neurônios internos ou hidden (ocultos) e neurônios de saída, que se comunicam com o exterior (DIN, 2006). As RNAs apresentam como vantagens as características de adaptabilidade, generalização e tolerância a ruídos, dentre outras (HAYKIN, 2001).

O principal objetivo almejado com a estrutura de funcionamento de uma rede neural artificial e com algoritmos de aprendizagem é a capacidade de *generalização*. A generalização se refere ao fato de a rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (ou aprendizagem). Esta capacidade de processar informação torna possível para as redes neurais resolver problemas complexos, alguns intratáveis por meios convencionais (HAYKIN, 2001).

As redes neurais têm sido utilizadas com sucesso em variadas áreas, por exemplo, indústria, negócios, finanças, medicina, etc., principalmente em problemas de classificação, predição, reconhecimento de padrões e controle. A razão desse sucesso está relacionada ao fato de que uma rede, composta por uma ou mais camadas ocultas com um número adequado de neurônios, possa aproximar praticamente qualquer função (ou relação) não-linear contínua, num dado intervalo (SUYKENS; VANDEWALLE E DE MOOR, 1996; LIU, 1996), embora haja restrições práticas (HAYKIN, 2001).

1.3 HISTÓRICO RNAs

O primeiro modelo artificial de um neurônio biológico foi fruto do trabalho pioneiro do psiquiatra e neuroanatomista Warren McCulloch e do matemático Walter Pitts em 1943. Este trabalho se concentrou muito mais em descrever um modelo artificial de um neurônio e apresentar suas capacidades computacionais de que apresentar técnicas de aprendizado. Parte da discussão em RNAs gira em torno de métodos de aprendizagem para que os nós possamos ser

capazes de executar uma determinada função (BRAGA; CARVALHO; LUDEMIR, 2000).

McCulloch e Pitts, 1943, escreveram:

"A lei de tudo-ou-nada da actividade nervosa é suficiente para assegurar que a actividade de um neurônio pode ser denotada por uma proposição. As relações fisiológicas que existem entre actividades nervosas correspondem, então, às relações entre proposições, isto é, uma rede de conexões entre proposições simples pode originar proposições complexas".

O primeiro trabalho de que se tem notícia com ligação direta ao aprendizado foi apresentado por Donald Hebb (1949). Frank Rosenblatt (1958), demonstrou, com seu novo modelo, o *perceptron*, que, se fossem acrescentadas de sinapses ajustáveis, as RNAs como nós poderiam ser treinadas para classificar certos tipos de padrões.

Minsky e Papert (1969), chamaram a atenção para algumas tarefas que o *perceptron* não era capaz de executar, já que este só resolve problemas linearmente separáveis, ou seja, problemas cuja solução pode ser obtida dividindo-se o espaço de entrada em duas regiões através de uma reta.

Nos anos 70, a abordagem conexionista ficou adormecida, principalmente por causa da repercussão do trabalho de Minsky e Papert (BRAGA; CARVALHO; LUDEMIR, 2000).

Em meados dos anos 80, o avanço da tecnologia, principalmente a microeletrônica, alavancou uma explosão nestes estudos: John Hopfield (1982) publicou um artigo que chamou a atenção para as propriedades associativas das RNAs. Quatro anos depois Rumelhart, Hinton e Williams descreveram um algorítmico de treinamento, o *backpropagation* (retropropagação), mostrando que a visão de Minsky e Papert era pessimista. As Redes Neurais de múltiplas camadas são sem dúvida capazes de resolver "problemas difíceis de aprender" (BRAGA; CARVALHO; LUDEMIR, 2000).

A origem das Redes Neurais remonta aos modelos matemáticos e aos modelos de engenharia de neurônios biológicos (KOVÁCS, 1996). As RNAs foram criadas, não para imitar o funcionamento do cérebro, mas como um modelo de resolução de problemas não algorítmicos inspirado no funcionamento do cérebro humano.

1.4 CÉREBRO HUMANO E O NEURÔNIO BIOLÓGICO

O cérebro humano é responsável pelo que se chama de emoção, pensamento, percepção e cognição, assim como pela execução de funções sensoriomotoras e autônomas. Além disso, tem a capacidade de reconhecer padrões e relacioná-los, usar e armazenar conhecimento por experiência, além de interpretar observações (BRAGA; CARVALHO; LUDEMIR, 2000). O cérebro humano pesa cerca de 1,5 kg e tem cerca de 100 bilhões de neurônios e usa de 20% a 25% de toda a energia do corpo humano. O neurônio pode ser considerado a unidade básica da estrutura do cérebro e do sistema nervoso. O neurônio é constituído por uma célula principal, por dendritos, por um axônio e na sua extremidade existem estruturas designadas por sinapses (Fig.1) (VILELA, 2006).




Figura 1 – Representação de um neurônio

Sinapse é um tipo de junção especializada em que um terminal axonal faz contato com o dendrito de outro neurônio ou tipo celular (Fig. 2). As sinapses podem ser elétricas ou químicas (maioria). Os neurônios recebem continuamente impulsos nas sinapses de seus dendritos vindos de milhares de outras células. Os impulsos geram ondas de corrente elétrica (excitatória ou inibitória; cada uma num sentido diferente). O impulso nervoso constitui a informação que o neurônio processara, esse impulso passa pela sinapse através de neurotransmissores, que promovem a entrada de sódio no neurônio, provocando a

inversão de cargas elétricas e a condução de um impulso nervoso no neurônio estimulado (VILELA, 2006).

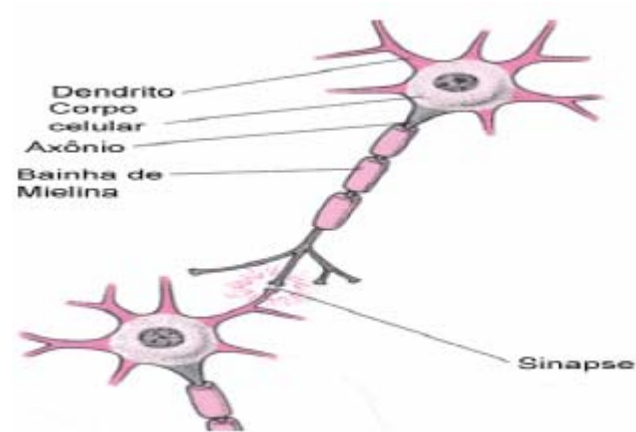


Figura 2 – Sinapse entre neurônios

1.5 NEURÔNIO ARTIFICIAL

O primeiro modelo de neurônio artificial proposto por McCulloch e Pitts em 1943 (Fig.3) é uma simplificação do que se sabia então, de um neurônio biológico. Eles interpretaram o funcionamento do neurônio biológico como sendo um circuito de entradas binárias combinadas por uma soma ponderada (com pesos) produzindo uma entrada efetiva (DIN, 2006):




Figura 3 – Neurônio artificial projetado por McCulloch

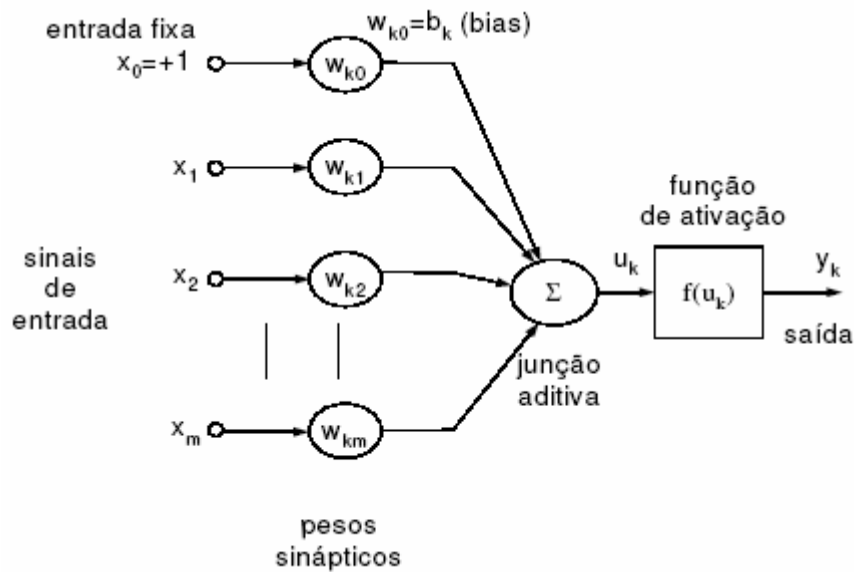


Figura 4 – Modelo de um neurônio artificial

A operação de um neurônio artificial se resume em (LACERDA, 2006):

- Sinais são apresentados à entrada (x_1 à x_m);
- Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade (w_k);
- É feita a soma ade (u_k);
- A função de ativação $f(u_k)$ tem a função de limitar a saída e introduzir não-linearidade ao modelo.
- O bias (viés) b_k tem o papel de aumentar ou diminuir a influência do valor das entradas.
- É possível considerar o bias como uma entrada de valor constante 1, multiplicado por um peso igual à b_k .

Matematicamente a saída pode ser expressa por:

$$y_k = f(u_k) = f\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (1)$$

ou considerando o bias como entrada de valor $x_0=1$ e peso $w_{k0}=b_k$,

$$y_k = f(u_k) = f\left(\sum_{j=0}^m w_{kj}x_j\right) \quad (2)$$

A função f é chamada de função de ativação e pode assumir várias formas, geralmente não-lineares. As quatro funções de ativação mais utilizadas são linear, rampa, degrau e sigmoideal (logística) (KARRER; CAMEIRA; VASQUES, 2005).

A seguir, as funções e derivadas das funções de ativação linear, semilinear, sigmoideal e tangente hiperbólica (VON ZUBEN, 2006):

Função de ativação linear:

$$a_i(u_i) = \begin{cases} 0 & \text{se } u_i < 0 \\ [0,1] & \text{se } u_i = 0 \\ 1 & \text{se } u_i > 0 \end{cases} \quad (3)$$




Figura 5 – Função sinal (a) e sua derivada em relação à entrada interna (b)

Função de ativação: semi-linear

$$a_i(u_i) = \begin{cases} 1 & \text{se } pu_i \geq 0 \\ pu_i & \text{se } 0 < pu_i < 1 \\ 0 & \text{se } pu_i \leq 0 \end{cases} \quad (4)$$

com p constante e positivo




Figura 6 – Função de ativação semi-linear (a) e sua derivada (b).

Função de ativação logística (sigmóide)

$$a_i(u_i) = \frac{e^{pu_i}}{e^{pu_i} + 1} = \frac{1}{1 + e^{-pu_i}}$$

$$\frac{\partial a_i}{\partial u_i} = pa_i(1 - a_i) > 0 \quad (5 \text{ e } 6)$$




Figura 7 – Função de ativação Sigmóide (a) e sua derivada (b).

Função de ativação tangente hiperbólica

$$a_i(u_i) = \tanh(pu_i) = \frac{e^{pu_i} - e^{-pu_i}}{e^{pu_i} + e^{-pu_i}}$$

$$\frac{\partial a_i}{\partial u_i} = p(1 - a_i^2) > 0 \quad (7 \text{ e } 8)$$




Figura 8 – Tangente hiperbólica (a) e sua derivada (b).

De forma geral, a operação de uma célula da rede se resume em (FERNANDES, 2003):

- Sinais são apresentados à entrada;
- Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade;
- É feita a soma ponderada dos sinais que produz um nível de atividade;
- Se este nível excede um limite (threshold), a unidade produz uma saída;

1.6 ARQUITETURA DAS RNAS

Arquiteturas de redes neurais são tipicamente organizadas em camadas, com unidades que podem estar conectadas às unidades da camada posterior como na figura 9 (FERNANDES, 2003).




Figura 9 – Camadas de uma Rede Neural Artificial (RNA)

Usualmente as camadas são classificadas em três grupos:

- Camada de entrada: onde os padrões são apresentados à rede;
- Camadas intermediárias ou ocultas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- Camada de saída: onde o resultado final é concluído e apresentado.

A definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Uma Rede Neural artificial é especificada, principalmente pela sua topologia, características de seus nós, regras de treinamento e tipos de modelos (BRAGA; CARVALHO; LUDEMIR, 2000).

As Redes Neurais podem ser distinguidas com base na direção na qual o sinal flui. Basicamente há dois tipos de Redes Neurais Artificiais (FERNANDES, 2003):

Redes diretas, acíclicas ou alimentadas para frente (*feedforward*): são RNA cuja representação gráfica não possui ciclos e cujos neurônios estão organizados em camadas (Fig.10). A RNA direta não, necessariamente, possui camadas intermediárias, as quais também são conhecidas como camadas escondidas ou ocultas (*hidden layers*). Entretanto, o uso de camadas ocultas permite

a extração de estatísticas de ordem elevada e a aproximação da RNA por uma função não-linear. Normalmente, para este tipo de redes, utiliza-se o algoritmo de treinamento de retropropagação (*backpropagation*) (RAMÍREZ, 2005). São exemplos deste tipo de rede aquelas "alimentadas adiante", como os Perceptrons de Múltiplas Camadas - *Multi-Layer Perceptron-MLP* (RUMELHART; MCCLEAND., 1986) e as redes de função de base radial - *Radial Basis Function-RBF* (BISHOP, 1995). Essas redes são usadas como identificadores e classificadores de padrões, controle, avaliação de dados de entrada etc. (KOHONEN, 2001).




Figura 10 – Rede Direta (*Feedforward*)

Redes com ciclos (retroação, retroalimentação ou *feedback*): correspondem a uma grande família de RNA cuja representação gráfica possui pelo menos um ciclo (Fig.11). Quando são compostas por neurônios dinâmicos com retardo são chamadas de *redes recorrentes* (RAMÍREZ, 2005). São exemplos deste tipo de rede, as redes de

Hopfield (FAUSETT, 1994) e a máquina de Boltzman (HAYKIN, 2001). As principais aplicações destas redes são: como função de memória associativa e em problemas de otimização, embora também sejam usadas no reconhecimento de padrões.




Figura 11 – Rede com Ciclos (*Feedback*)

1.7 APRENDIZADO RNAs

A maioria dos modelos neurais possui alguma regra de treinamento, onde os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Em outras palavras, elas aprendem através de exemplos (FERNANDES, 2003).

Aprendizagem é um processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre (HAYKIN, 2001).

Esta definição do processo de aprendizagem implica a seguinte seqüência de eventos (HAYKIN, 2001):

- A Rede Neural é *estimulada* por um ambiente.
- A Rede Neural *sofre modificações* nos seus parâmetros livres como resultado desta estimulação.
- A Rede Neural *responde de uma maneira nova* ao ambiente, devido às modificações ocorridas na sua estrutura interna. (HAYKIN, 2001).

Um conjunto preestabelecido de regras bem definidas para a solução de um problema de aprendizagem é denominado um algoritmo de

aprendizagem. Como se pode esperar, não há um algoritmo único de aprendizagem para o projeto de redes neurais. Em vez disso, temos um conjunto de ferramentas representado por uma variedade de algoritmos de aprendizagem cada qual oferecendo vantagens específicas. Basicamente, os algoritmos de aprendizagem diferem entre si pela forma como é formulado o ajuste de um peso sináptico de um neurônio (HAYKIN, 2001).

A aplicação do algoritmo de aprendizagem poderá ser seqüencial ou por lote. No treinamento seqüencial, a correção dos pesos sinápticos é aplicada toda vez que é apresentado um exemplo à RNA. Já no treinamento por lote esta correção somente será feita após a apresentação completa de uma época, que consiste em todos os exemplos da amostra de treinamento (RAMÍREZ, 2005).

Como foi dito anteriormente, é importante à maneira pela qual uma rede neural se relaciona com o ambiente. Neste contexto, existem os seguintes paradigmas de aprendizado (BRAGA; CARVALHO; LUDEMIR, 2000):

- **Aprendizado Supervisionado:** Este método é o mais comum no treinamento das RNAs, tanto de neurônios com pesos como com neurônios sem peso. É chamado supervisionado porque a entrada e a saída desejada para a rede são fornecidas por um supervisor (professor) externo. O objetivo da aprendizagem será minimizar o erro entre a resposta desejada e a resposta real da RNA. Normalmente, esta abordagem é utilizada para classificação de padrões e aproximação de funções. A desvantagem do aprendizado supervisionado é que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não cobertas pelos exemplos do treinamento da rede. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta e o algoritmo *backpropagation* (retropropagação). A regra delta usa apenas informação local da sinapse para o aprendizado. Além disso, ela é útil quando se deseja minimizar o erro médio quadrático durante o treinamento de uma RNA. Entretanto, o uso da regra delta é limitado a RNA com duas camadas de neurônios (uma camada de entrada e uma camada de saída). Quando a regra delta é aplicada a neurônios lineares pode ser chamada de algoritmo do *mínimo quadrado médio*, ou *LMS* (*Least Mean Squares*). O algoritmo de *backpropagation* ou retropropagação é considerado uma generalização da regra delta para redes diretas com mais de duas camadas, ou seja, que possuem pelo menos uma camada oculta. Para isso, na correção dos

pesos sinápticos são levados em conta os gradientes locais da rede (BRAGA; CARVALHO; LUDEMIR, 2000).

- Aprendizado não-supervisionado: não há um supervisor (professor) para acompanhar o processo de aprendizagem para este algoritmo. Somente os padrões de entrada estão disponíveis para rede e não há exemplos rotulados da função a ser aprendida pela rede. No aprendizado não-supervisionado a rede "analisa" os conjuntos de dados apresentados a ela, determina algumas propriedades dos conjunto de dados e "aprende" a refletir estas propriedades na sua saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. As propriedades que a rede vai "aprender" sobre os dados pode variar em função do tipo de arquitetura utilizada e da lei de aprendizagem. Por exemplo, Mapa Auto-Organizável de Kohonen, Redes de Hopfield e Memória Associativa Bidirecional, são algumas métodos de aprendizado não supervisionado (MEDEIROS,1999).

- Reforço: este conceito é usado em algumas redes neurais para indicar quando as conexões seriam adaptadas. Aprendizado por reforço é um mecanismo de aprendizado no qual apenas uma medida da adequação dos resultados obtidos é fornecida como um parâmetro externo. Este tipo de reforço ocorre quando dois eventos acontecem juntos e devem ser associados um ao outro. A associação é formada porque as conexões que são ativas são adaptadas ou ficam mais fortes ao mesmo tempo, isto estabelece que a rede responde quando um dos dois eventos originais é ativo (FERNANDES, 2003).

1.7.1 Algoritmo Backpropagation

O algoritmo *backpropagation* foi criado por Rumelhard, Hinton e Williams em 1986 (ZURADA, 1992; HAYKIN, 1994), a partir da generalização da regra de aprendizado "Widrow-Hoff", que fora introduzido em 1960 - 1962 para redes do tipo "feedforward perceptron". A regra de aprendizado "Widrow-Hoff", também

conhecida como "Regra Delta" - LMS (minimização do erro médio quadrático) - que ajusta os pesos das conexões entre os neurônios da rede de acordo com o erro.

O algoritmo *backpropagation* é o principal algoritmo de treinamento de rede utilizado e é, freqüentemente, usado como o algoritmo de aprendizado em redes neurais estruturadas em camadas, isto devido à sua eficiência (HIROSE; YAMASHITA; HIJIYA, 1991).

O algoritmo *backpropagation* ajusta os pesos das unidades das camadas intermediárias a partir dos erros das unidades da camada de saída. A aplicação do algoritmo *backpropagation* requer a escolha de um conjunto de parâmetros (número de iterações do algoritmo, critério de parada, pesos iniciais, taxa de aprendizado), cuja influência pode ser decisiva para a capacidade de generalização da rede (CALÔBA, 1995).

O critério de parada do treinamento exige considerar a capacidade de generalização da rede. Um treinamento prolongado demais pode levar a um sobreajuste da rede, especialmente no caso de dispormos de poucos pares de entrada e saída para o conjunto de treinamento, o que pode piorar o desempenho da rede quando o conjunto de teste lhe for apresentado (CALÔBA, 1995).

A escolha da taxa de aprendizado a depende da função a aproximar. Valores muito pequenos de a tornam o treinamento lento, enquanto valores muito grandes podem provocar divergência do processo de treinamento (KLEIBAUM, 1994).

A aplicação do algoritmo *backpropagation* envolve um deslocamento para frente, através da rede, para calcular as saídas de cada elemento neural da camada de saída e o seu respectivo erro. A segunda fase envolve um deslocamento no sentido contrário, durante o qual o sinal de erro é passado para cada elemento e as mudanças nos pesos são efetuadas. A rede é treinada através da apresentação de todos os dados de treinamento repetidas vezes. Em cada iteração, a diferença entre o valor da saída e o valor esperado, determina a correção que deverá ser feita nos valores dos pesos e dos limiares. Os valores dos pesos são ajustados após cada etapa de treinamento, até que a função erro seja reduzida a um valor tido como aceitável (FARACO et al, 1998).

O algoritmo de retropropagação envolve a execução de dois passos distintos de computação: o processamento direto (*forward*) e o processamento reverso (*backward*). O procedimento direto é executado no sentido, entrada → saída

da rede. Neste caso, um exemplo de treinamento é apresentado à rede e as saídas de todos os neurônios são computadas, usando as equações (9) e (10).

$$v_j(n) = \sum_{i=0}^p w_{ji}(n) y_i(n) \quad (9)$$

onde,

$$y_j(n) = f_j(v_j(n)) \quad (10)$$

Comparamos então as saídas da rede com as saídas desejadas e calculamos o erro, usando as equações (11) e (12).

$$e_j(n) = s_j(n) - y_j(n), \quad (11)$$

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n), \quad (12)$$

O processamento reverso é executado no sentido, saída \rightarrow entrada. Neste caso, os sinais de erro são propagados da saída para a entrada, camada a camada, através dos cálculos dos δ 's (gradientes locais) para cada neurônio da rede. Para os neurônios de saída, δ é calculado usando a Equação (13) e os respectivos pesos são ajustados usando a Equação (14).

$$\delta \varphi(v) = \frac{\partial \varepsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_i(n)} \frac{\partial y_i(n)}{\partial v_j(n)} = e_j(n) f_j'(v_j(n)) \quad (13)$$

$$w_{ji}(n+1) = w_{ji}(n) - \eta(n) \frac{\partial \varepsilon(n)}{\partial w_{ji}(n)}, \quad (14)$$

Com os δ 's da camada de saída calculados, usamos a Equação (15) para calcular os δ 's dos neurônios localizados na camada imediatamente anterior à camada de saída; os pesos destes neurônios são então atualizados segundo a Equação (14). Continuamos este procedimento camada a camada, até que a camada de entrada seja alcançada (IYODA, 2000).

$$\delta_j(n) = f_j'(v_j(n)) \sum \delta_k(n) w_{kj}(n) \quad (15)$$

As seguir ilustração da fase de propagação (Fig.12) e retropropagação (Fig. 13).




Figura 12 – Fase de Propagação

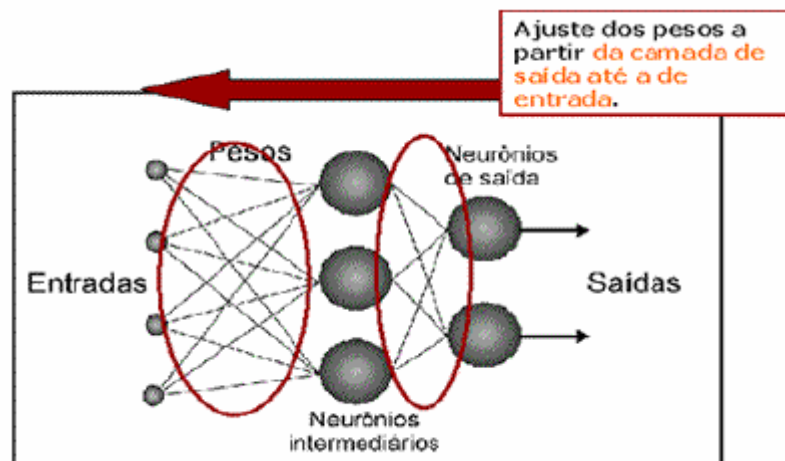


Figura 13 – Fase de Retropropagação

A rede neural baseia-se nos dados a ela exibidos para extrair o modelo desejado. Portanto, a fase de treinamento deve ser rigorosa e verdadeira, a fim de serem evitados modelos espúrios (SANTOS, et al, 2005).

Segundo Hair Jr. *et al.* (1998), existem três modelos básicos de redes neurais: perceptron multicamadas, função de base radial e redes de Kohonen.

As redes de base radial são mais recentes e são utilizadas, segundo os autores, para os mesmos tipos de aplicação que as multicamadas. Já as redes de Kohonen são mais apropriadas para agrupamentos (*clustering*). A seguir, expõem-se mais detalhadamente a rede Multicamadas (MLP) e a Função de Base Radial (RBF), por serem as utilizadas neste trabalho.

1.8 REDES MULTILAYER PERCEPTRON - MLP

De acordo com Rummelhart (1986) as redes com duas camadas (entrada e saída) apresentam desempenho muito limitado, a adição de uma camada intermediária faz-se necessária. Neste tipo de configuração, cada neurônio está ligado com todos os outros das camadas vizinhas, mas neurônios da mesma camada não se comunicam, além da comunicação ser unidirecional, apresentando assim um comportamento estático.

As redes MLP apresentam um poder computacional muito maior que aquele apresentado pelas redes sem camadas intermediárias (BRAGA; CARVALHO; LUDEMIR, 2000). A MLP é uma das RNAs mais importantes existentes atualmente. Ela permite a solução de problemas onde as classes são não-linearmente separáveis, pois, pode-se adicionar camadas ocultas para o processamento e usar uma função de ativação não linear, geralmente a *sigmoid function*, apresentada na eq. (16) (FERRARI et al., 2006).

$$S(T) = \frac{1}{1 + e^{-T}} \quad (16)$$

Seu treinamento é do tipo supervisionado e utiliza um algoritmo muito popular chamado retropropagação do erro (*error backpropagation*). Este algoritmo é baseado numa regra de aprendizagem que "corrige" o erro durante o treinamento (HAYKIN, 1994).

Hornik *et al.* (1989) provaram que uma rede com apenas uma camada intermediária, portanto, uma rede com três camadas, é suficiente para representar qualquer função ou problema de classificação.

Hair, Jr. *et al.* (1998) apresenta três elementos básicos das redes multicamadas:

- **Neurônios (Nós):** É o elemento básico das redes neurais, um elemento de processamento que atua em paralelo com os outros nós da rede.
- **Rede:** Uma rede neural é um arranjo seqüencial de três tipos básicos de nós ou camadas: nós (ou neurônios) de entrada, nós intermediários e nós de saída. Os nós de entrada recebem os dados iniciais e transmitem para a rede.
- **Aprendizado:** Segundo Hair Jr. *et al.* (1998), o que realmente diferencia uma rede neural de outras técnicas multivariadas é sua capacidade de aprendizado. Os valores são propagados pela rede através de pesos de conexão entre os nós. Os pesos de conexão são ajustados através de um método de aprendizado. O modelo mais freqüentemente utilizado é o método de retropropagação que se baseia nos modelos de processamento distribuído paralelo propostos por Rumelhart e McClelland. (1986).

1.9 FUNÇÃO DE BASE RADIAL - RBF

Recentemente as redes de funções radiais de base vêm ganhando bastante atenção no domínio das RNA (BORS, 2001).

Consideradas como aproximadores universais de funções, as redes neurais ativadas por função de base radial (RBF) produzem um mapeamento global dos dados de treinamento a partir de contribuições locais, ou seja, da soma das ativações de cada um de seus neurônios (HAYKIN, 1994; CHEN; CHEN, 1994). Esta característica torna sua aplicação rápida, didaticamente interessante, principalmente em problemas que envolvem mais de duas variáveis, dado que sua eficiência pode ser constatada em numerosos trabalhos internacionais (NIYOG; GIROSI, 1994).

As RBFs podem ser usadas em problemas de aproximação de funções, predição e classificação (FERNANDES; NETO; BEZERRA, 1999) .

São redes alimentadas adiantes (*feedforward*), basicamente envolve 3 camadas diferentes: a camada de entrada, a camada oculta e a camada de saída

(LEKUTAI, 1997). A primeira camada implementa uma conexão direta do espaço vetorial de entrada para a segunda camada ou camada escondida

As redes neurais com funções de ativação de base radial (RBF) apresentam três diferenças principais em relação às redes tipo perceptron multicamadas (MLP) (VON ZUBEN; CASTRO, 2005):

- Elas sempre apresentam uma única camada intermediária;
- Neurônios de saída são sempre lineares;
- Os neurônios da camada intermediária têm apenas funções de base radial como função de ativação, ao invés de funções sigmóides ou outras.

As funções de base radial (RBF's) são uma classe especial de funções cuja característica principal é o fato de seus valores crescerem (ou decrescerem) monotonicamente à medida que aumenta a distância a um ponto central, chamado de *centro* da função. Alguns exemplos desse tipo de função são dados abaixo (BRAGA; CARVALHO; LUDEMIR, 2000):

$$\text{função gaussiana: } f(u) = \exp(-v^2 / 2\sigma^2) \quad (17)$$

$$\text{função multiquadrática: } f(u) = \sqrt{v^2 + \sigma^2} \quad (18)$$

$$\text{função multiquadrática inversa: } f(u) = v^2 \log(v) \quad (19)$$

onde $v = \|x - \mu\|$, que é dado geralmente pela distância euclidiana, x é o vetor de entrada, e μ e σ representam o centro e a largura da função radial, respectivamente.

A função radial de base mais utilizada é a função de Gauss. Sua saída é determinada pela distância Euclidiana entre o centro e o vetor de entrada. Cada função requer um parâmetro vetorial - o centro, e um parâmetro escalar que define a *largura* da função radial. A última camada (camada de saída) transforma o espaço vetorial interno, implementando uma soma ponderada (processo linear) dos neurônios escondidos (BORS, 2001).

Vários métodos têm sido propostos para o treinamento de redes RBF. Na maioria destes métodos, o treinamento é classificado como híbrido, uma vez que é dividido em dois estágios (BRAGA; CARVALHO; LUDEMIR, 2000). Na primeira fase, os parâmetros da função radial utilizada (os centros e a largura) são determinados por métodos não supervisionados. Durante a segunda fase é realizado

o ajuste dos pesos dos neurônios de saída, correspondendo a um problema linear, de processamento mais simples (HAYKIN, 1994).

Os dois métodos usualmente utilizados para seleção dos centros são a sub amostragem (sub *sampling*) e o algoritmo K-médias (*K-means*). Após a seleção dos centros, deve-se determinar o fator de largura da função. Os algoritmos mais utilizados para essa operação são o isotrópico e o algoritmo dos vizinhos mais próximos de K (*K-nearest neighbors*). Após essa primeira fase, o passo seguinte corresponde à otimização da camada de saída, que pode ser feita empregando-se uma técnica padrão para otimização linear: pseudo-inversa. (HAYKIN, 1994; BISHOP, 1995).

Este modelo de rede é apropriado para desempenhar diversas tarefas, dentre as quais se inclui a aproximação de funções. Uma camada intermediária, segundo Bishop (1995), é o suficiente para a aproximação de qualquer função.

O algoritmo K-médias particiona o espaço de padrões em K regiões ou grupos. Esta partição é realizada da seguinte maneira: inicialmente são escolhidos aleatoriamente K vetores de entrada para serem os centros de K grupos de padrões. Os outros vetores de entrada são atribuídos ao grupo que tiver o centro mais próximo. Para isso geralmente é utilizada a distância euclidiana. Após esta fase, os centros são recalculados para que sejam os vetores médios do seu grupo, ou seja, a média dos vetores pertencentes ao grupo. Novamente os vetores de entrada são apresentados e associados ao centro mais próximo. Estes processos de redefinição de centros e dos vetores associados a cada centro é repetido até que o algoritmo convergir, isto é, até os centros não precisarem ser modificados (BRAGA; CARVALHO; LUDEMIR, 2000). Pseudo-inversa é usada para aperfeiçoar a saída linear na atribuição do desvio. Depois de calculado o erro, este é minimizado pela matriz pseudo-inversa (STATISTICA, 2006).

1.10 MODELAGEM EM REDES NEURAIAS ARTIFICIAIS

Para o desenvolvimento de um modelo ou projeto baseado em redes neurais artificiais são necessárias diversas etapas (Fig. 14), descritas conforme Caudill (1991):

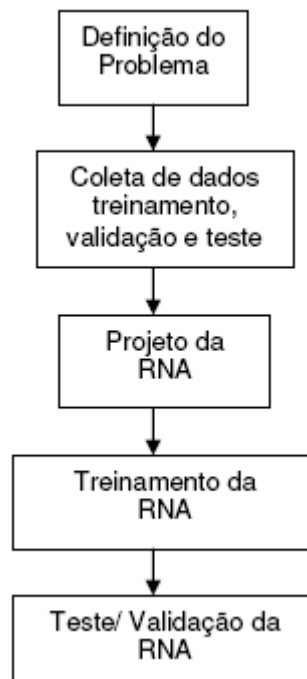


Figura 14 – Etapas para o desenvolvimento de um modelo de RNA

Os dois primeiros passos do processo de desenvolvimento de redes neurais artificiais são a definição do problema e a coleta de dados relativos ao problema e a sua separação em um conjunto de treinamento e um conjunto de testes (CLAUDILL, 1991).

O conjunto de treinamento é utilizado para o treinamento da rede e ajuste dos parâmetros da rede, devendo conter um número estatisticamente significativo de casos em estudo, de modo a constituir uma amostra representativa do problema que se pretende estudar (KLIMASUKAS,1991 ; HERTZ; KROGH; PALMER,1991).

O conjunto de teste é utilizado para verificar a capacidade de generalização da rede sob condições reais de utilização. Os dados do conjunto de teste não devem ser usados para ajuste dos parâmetros da rede. A habilidade de generalização da rede se refere a seu desempenho ao classificar padrões do conjunto de teste. Deficiências na capacidade de generalização da rede podem ser atribuídas ao problema de sobreajuste (*overfitting*). Esse problema ocorre quando, após um certo período de treinamento, a rede se especializa no conjunto de treinamento e perde a capacidade de generalização. Diz-se então que a rede memorizou os padrões de treinamento, gravando suas peculiaridades e ruídos, proporcionando perdas na capacidade de generalização quando essa é utilizada para classificar os padrões pertencentes ao conjunto de teste (KLIMASUKAS,1991; HERTZ; KROGH; PALMER,1991).

Para evitarmos o problema de sobreajuste, pode-se usar também uma subdivisão do conjunto de treinamento, criando um *conjunto de validação*, cuja finalidade é verificar a eficiência da rede quanto a sua capacidade de generalização durante o processo de treinamento, também podendo ser empregado como critério de parada do treinamento da rede (KLIMASUKAS,1991; HERTZ; KROGH; PALMER,1991).

O terceiro passo é a definição da configuração da rede, que pode ser dividido em três etapas: (i) seleção do paradigma neural apropriado à aplicação; (ii) determinação da topologia da rede a ser utilizados - o número de camadas, o número de unidades em cada camada, etc. (iii) determinação de parâmetros do algoritmo de treinamento e funções de ativação. Este passo tem um grande impacto no desempenho do sistema resultante (DIN, 2006).

O quarto passo é o treinamento da rede. Nesta fase, seguindo o algoritmo de treinamento escolhido, são ajustados os pesos das conexões. É importante considerar, nesta fase, alguns aspectos tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento. O quinto passo é o teste da rede. Durante esta fase o conjunto de teste é utilizado para determinar o desempenho da rede com dados que não foram previamente utilizados. O desempenho da rede, medida nesta fase, é uma boa indicação de seu desempenho real (DIN, 2006).

Não existem regras claras para se definir quantas unidades devem existir nas camadas intermediárias, quantas camadas, ou como devem ser as conexões entre essas unidades.

Em geral, redes neurais com poucos neurônios escondidos são preferidas, visto que elas tendem a possuir um melhor poder de generalização, reduzindo o problema de sobreajuste (*overfitting*). Entretanto, redes com poucos neurônios escondidos podem não possuir a habilidade suficiente para modelar e aprender os dados em problemas complexos podendo ocorrer *underfitting*, ou seja, a rede não converge durante o treinamento (PEREIRA, 1999).

O aumento do número de camadas implica num aumento da complexibilidade e conseqüentemente do tempo de processamento. Já um pequeno número de camadas pode fazer com que a RNA não tenha flexibilidade necessária para generalização; por outro lado, um número excessivo pode fazer com que a RNA "decore" os dados ao invés de generalizá-los (DINIZ, 1997).

A implementação de um modelo ou projeto que utilize as RNA poderá ser realizada de diversas formas. Caso o interessado possua bom conhecimento em desenvolvimento de software poderá desenvolver seu próprio código, específico para o problema. Caso contrário, poderá utilizar os pacotes de sistemas simuladores de redes neurais comerciais ou de domínio público. Também poderá projetar e construir um *hardware* utilizando *chips* de redes neurais disponíveis no mercado (MEDEIROS, 1999).

Embora as redes neurais artificiais demonstrem uma grande capacidade de previsão, apresentam também algumas limitações, dentre as quais se destaca que todos os processos de interconexões entre neurônios e camadas, correção do erro e previsão do valor desejado são efetuados de maneira que não há uma inferência direta. Além disso, deve-se ter cuidado para evitar a saturação da rede ou *overtraining*, o que faz com que, se o treinamento se estender por períodos muito longos, a rede tome decisões arbitrárias, especializando-se no grupo de variáveis utilizado no treinamento e perdendo sua capacidade de generalização (JANSSON, 1991).

As aplicações de RNAs são inúmeras. Podem ser utilizadas pra analisar dados e processamento de sinais, controle de processos, robótica, análise de aroma (nariz eletrônico) e cor, classificação de dados, etc. Com base em bancos de dados de redes neurais específicas é possível prever novos valores, utilizando-se de um mínimo de dados experimentais, o que pode agilizar a determinação de parâmetros desconhecidos (VALE et al, 2000). Este procedimento computacional vem sendo utilizado em várias áreas da Ciência e Tecnologia de Alimentos.

As redes neurais artificiais (RNAs) já foram aplicadas em praticamente todas as áreas da ciência de alimentos. As RNAs são ferramentas úteis para as análises de qualidade e segurança alimentar, que incluem a modelagem do crescimento microbiano, a interpretação de dados espectroscópicos, e a previsão de propriedades funcionais e sensoriais de vários alimentos durante o processamento e a distribuição. Uma promessa das RNAs é modelar tarefas complexas no controle e na simulação do processo e nas aplicações das previsões (HUANG; KANGAS; RASCO, 2007).

Na área de alimentos algumas redes já foram utilizadas com sucesso. Vale e Zambiasi (2000), confirmaram a viabilidade de previsão da estabilidade de óleos vegetais pela rede neural, a partir de dados de sua composição química, utilizando como parâmetro de estabilidade o índice de peróxido. Horinomoto *et al* (1995), usaram diferentes variáveis de processo e de composição do trigo para prever o volume da massa de pães elaborados de diferentes cultivares de trigo através de uma rede neural (*Brainmaker software*). Arteaga e Nakai (1993), desenvolveram uma rede neural usando propriedades físico-químicas de proteínas para prever sua estabilidade e capacidade de formação de espuma, destacando que a habilidade de previsão por parte da rede foi superior ao encontrado pela utilização da análise dos componentes principais.

Ramos (2003), através das redes neurais, formulou um modelo artificial de classificação de frutos que considerou simultaneamente vários atributos de propriedade físicas, procurando simular o mais próximo possível o grau de maturidade desejado pelos compradores de tomates. O'farrell *et al.* (2005), procuraram projetar uma única rede neural que verificasse a tendência, projetando uma escala de cor geral que classificasse diferentes cortes de frangos (filé, asa), com e sem pele, submetidos a diferentes tratamentos (cozido, grelhado e assado).

O campo de redes neurais artificiais é acima de tudo extremamente vasto e promissor. Por ser um assunto que surgiu há muito tempo atrás ganhou muita credibilidade, e devido á novas descobertas relacionadas a ela a cada instante, tornou-se bastante atrativo para profissionais de domínios distintos, tornando-se um assunto interdisciplinar. Os conhecimentos obtidos até hoje atraem o interesse de profissionais tais como psicólogos, neurofisiologistas, engenheiros, cientistas cognitivos, e cientistas da computação, que buscam cada um em sua área, novos caminhos através da computação neural (DIN, 2006).

**Capítulo 2 – APLICAÇÕES DE REDES NEURAIS ARTIFICIAIS NA SALGA MISTA
COM NaCl E KCl EM QUEIJO PRATO**

1 INTRODUÇÃO

A hipertensão arterial é uma doença muito comum em todo o mundo e atinge jovens, adultos e idosos, pessoas de ambos os sexos, de todas as raças e de qualquer padrão social. Na maioria dos casos a hipertensão parece estar ligada à herança familiar e a hábitos alimentares. A hipertensão é uma doença que não tem cura, mas pode-se, através de tratamento, manter controlados os níveis da pressão arterial (COREN, 2007).

O alimento mais relacionado com a hipertensão arterial é o cloreto de sódio, mas conhecido como sal de cozinha (ICRG, 1988). O cloreto de sódio está presente também em vários produtos industrializados que consumimos diariamente, como pães, queijos, cereais, bolachas, enlatados. Em muitos casos, a redução do sódio na dieta é suficiente para baixar a pressão sanguínea (PEDRINOLA, 2007).

Com isso, hoje se faz necessário à produção de alimentos com teor reduzido de sódio. Por isso, estudos vêm sendo realizados para substituir uma parte de cloreto de sódio por cloreto de potássio (BORSATO et al, 2007). Uma substituição completa não é recomendada, pois apesar de ter características semelhantes ao do cloreto de sódio, o cloreto de potássio apresenta sabor amargo quando utilizado em grandes quantidades (FITZGERALD et al, 1985; LINDSAY et al, 1982; RAPACCI, 1989).

O queijo é um exemplo de alimento muito apreciado, mas com grande quantidade de sal. Um dos queijos mais consumidos no Brasil é o queijo prato (SILVEIRA; ABREU, 2003), por isso estudos envolvendo a difusão do cloreto de sódio, na presença de um substituto (KCl), são fundamentais na estimativas de parâmetros como as concentrações finais desses sais no queijo e o tempo de salga necessário para alcançar essas concentrações.

2 REVISÃO BIBLIOGRÁFICA

2.1 HIPERTENSÃO ARTERIAL E O CLORETO DE SÓDIO

Segundo estimativa de 2004 do Instituto Brasileiro de Geografia Estatística (IBGE, 2004) atualmente 35% da população brasileira acima de 40 anos são hipertensos, isso representa em números absolutos um total de 17 milhões de portadores da doença (MINISTÉRIO DA SAÚDE, 2005). O termo hipertensão arterial, denominado comumente de hipertensão ou pressão alta, significa a perda de elasticidade das artérias, acompanhado da elevação da pressão arterial para além de 140 x 90 mmHg (CECIL, 2005). Esta elevação anormal pode causar lesões em diferentes órgãos do corpo humano, tais como cérebro, coração, rins e olhos (VARELLA, 2006).

Hipertensão é a causa de 60% dos ataques cardíacos e 80% dos derrames cerebrais. Mas o que pouca gente sabe é que a pressão alta também provoca sofrimento dos rins, levando à insuficiência renal. Grande parte dos doentes que precisam ser submetidos à diálise enquanto aguardam o transplante de rim chegaram a esse estágio por causa da pressão alta (VARELLA, 2006).

No cérebro, podem acontecer dois tipos de acidentes vasculares, conhecidos como derrames cerebrais. O isquêmico ocorre quando a artéria é obstruída, e o hemorrágico, quando a artéria rompe, provocando sangramento. (VARELLA, 2006).

No coração, a hipertensão pode contribuir para a obstrução das coronárias, artérias que nutrem o músculo cardíaco, levando ao infarto do miocárdio. (VARELLA, 2006).

Nos rins, o aumento da pressão conduz à dificuldade de filtrar o sangue, à retenção de líquido e à insuficiência renal, que pode exigir diálise e transplante de rim. (VARELLA, 2006).

O sal ajuda a reter no organismo os líquidos que ingerimos. Para cada nove gramas de sal que a pessoa ingere, o organismo retém um litro de água. Um litro de água a mais no volume circulante obriga o coração a fazer mais força para trabalhar. (VARELLA, 2006).

Dentre os fatores nutricionais estudados e que se associam à alta prevalência de hipertensão arterial estão o elevado consumo de álcool e sódio e excesso de peso (ICRG, 1988).

Populações ocidentais e com alto consumo de sal apareceram como tendo os maiores percentuais de hipertensão, enquanto as populações rurais ou primitivas que não faziam uso de sal de adição apresentaram menores prevalências ou nenhum caso de hipertensão arterial (ICRG, 1988).

As medidas de maior eficácia do tratamento da hipertensão arterial são:

- Redução do peso corporal e manutenção do peso ideal - índice de massa corpórea (peso em quilogramas dividido pelo quadrado da altura em metros) entre 20 e 25 kg/m² porque existe relação direta entre peso corpóreo e pressão arterial (SACKS et al, 2001).
- Redução da ingestão de sódio - é saudável ingerir até 6 g/dia de sal correspondente a 4 colheres de café rasas de sal, 4g, e 2g de sal presente nos alimentos naturais, reduzindo o sal adicionado aos alimentos, evitando o saleiro à mesa e alimentos industrializados. A dieta habitual contém 10 a 12 g/dia de sal (SACKS et al, 2001).
- Maior ingestão de potássio - dieta rica em vegetais e frutas contém 2 a 4g de potássio/dia e pode ser útil na redução da pressão e prevenção da hipertensão arterial (WHELTON et al, 1997). Os substitutos do sal contendo cloreto de potássio e menos cloreto de sódio (30% a 50%) são úteis para reduzir a ingestão de sódio e aumentar a de potássio.
- Redução do consumo de bebidas alcoólicas (MACMAHON, 1987; KRAUSS et al, 2000, PUDDEY ET AL, 1985 e PUDDEY; BEILIN; VANDONGEN, 1987) para os consumidores de álcool, a ingestão de bebida alcoólica deve ser limitada a 30g álcool/dia contidas em 600 ml de cerveja (5% de álcool) ou 250 ml de vinho (12% de álcool) ou 60ml de destilados (whisky, vodka, aguardente

- 50% de álcool). Este limite deve ser reduzido à metade para homens de baixo peso, mulheres, indivíduos com sobrepeso e/ou triglicérides elevados.

- Exercícios físicos regulares (BERLIN; COLDITZ, 1990; PAFFENBARGER, 1988) - há relação inversa entre grau de atividade física e incidência de hipertensão; exercício físico regular reduz a pressão.

Neil (2006) anunciou os resultados de um estudo duplo-cego com 608 indivíduos que foram randomizados para receber um substituto de sal (65% de cloreto de sódio, 25% de cloreto de potássio e 10% de sulfato de magnésio) ou sal comum (cloreto de sódio a 100%). O estudo teve duração de um ano. A escolha da composição do substituto foi realizada para que não houvesse o gosto residual amargo normalmente reportado pelos substitutos padrões que contém com maior quantidade de cloreto de potássio.

No início do estudo, a pressão arterial média aferida foi de 159/93 mmHg. Após 12 meses, a pressão sistólica era 5,4 mmHg menor entre aqueles que utilizaram o substituto do sal quando comparados ao grupo controle, com alta significância estatística (NEIL, 2006).

A indicação redução da ingestão de sal e aumento da ingestão de potássio se justifica pela possibilidade de o potássio exercer efeito anti-hipertensivo, ter ação protetora contra danos cardiovasculares, e servir como medida auxiliar em pacientes submetidos à terapia com diuréticos (SOCIEDADE BRASILEIRA DE CARDIOLOGIA, 2001).

Em muitos casos, a redução do sódio na dieta é suficiente para baixar a pressão sanguínea, mas o sal de mesa não é a nossa única fonte de sódio. Sabe-se que o sal de mesa tem 40% de sódio, mas ele está presente também em vários produtos industrializados que consumimos diariamente, como pães, queijos, cereais, bolachas, enlatados, etc. (PEDRINOLA, 2007).

2.2 QUEIJO PRATO E A REDUÇÃO DE CLORETO DE SÓDIO

A importância do queijo como alimento está no fato de ser um produto rico em proteínas, gordura, sais minerais (cálcio e fósforo) e vitaminas. Portanto, indivíduos que não apreciam o leite, encontram no queijo um alimento substitutivo, uma vez que uma pequena porção de queijo (40g.) contém proteína e cálcio em quantidades suficientes para substituir um copo de leite (200 ml) (CCA, 2001).

Incontestavelmente o queijo ocupa um lugar de grande destaque, pelo seu valor nutritivo, entre os alimentos chamados completos, mas que contém uma grande quantidade de sal, que pode ser constatado pela sua composição bruta, comparada com a carne de vaca e o ovo (Tab. 1) (CCA, 2001).

Tabela 1 – Comparação nutricional entre queijo, carne e ovo (%) composição bruta

COMPONENTES	QUEIJO	CARNE	OVO
Água	34,2	61,9	33,7
Gordura	33,7	18,5	10,5
Proteínas	25,9	18,6	14,8
Carboidratos	2,4	0,0	0,0
Sais	3,8	1,0	1,0
Calorias por libra	1885	1090	6,0

No Brasil, um dos queijos de maior destaque é o queijo prato. Este tipo de queijo foi introduzido no Brasil por imigrantes dinamarqueses, e originou-se dos queijos tybo e danbo, dinamarqueses, e do gouda, holandês. Possui grande importância no meio comercial, ocupando o segundo lugar em produção no Brasil. Esse tipo de queijo caracteriza-se por ter sabor suave, consistência macia, fácil fatiabilidade e melhor padronização tecnológica, sendo, portanto, mais bem caracterizado comercialmente (SILVEIRA; ABREU, 2003).

O teor de cloreto de sódio tem levado os consumidores conscientes a optarem por queijos ou derivados menos salgados, devido à associação entre o

consumo de sal e a hipertensão arterial. Uma alternativa para reduzir o teor salino em queijos é a substituição parcial do NaCl pelo KCl, desde que não se altere sua qualidade final (BORSATO et al, 2007)

Rappaci (1989), fez um estudo que substituiu uma parte de cloreto de sódio por cloreto de potássio. O cloreto de potássio pode ser utilizado como substituto, pois, possui características semelhantes ao cloreto de sódio. A substituição completa do NaCl pelo KCl não é recomendada, devido ao sabor amargo conferido ao produto, o que o torna pouco aceitável (FITZGERALD et al, 1985; LINDSAY et al, 1982; RAPACCI, 1989). Contudo, a substituição de até 30% do cloreto de sódio pelo cloreto de potássio não apresentou diferenças sensoriais, físico-químicas ou microbiológicas significativas ($p < 0,05$) em relação ao queijo prato salgado apenas com cloreto de sódio (RAPACCI, 1989).

A salga é uma etapa muito importante na fabricação de queijo. A salga melhora o sabor do queijo, ajuda a mascarar algum tipo de sabor indesejável que esteja com baixa intensidade e inicia a formação da casca do queijo. Quando o queijo absorve o sal, ocorre liberação de soro, levando a uma perda de peso de aproximadamente 2% no queijo Prato. Esse sal absorvido auxilia na inibição do desenvolvimento de alguns microrganismos, pois contribui de forma considerável na atividade de água (aw) do queijo, além de controlar a velocidade e intensidade da maturação. O queijo só é salgado quando atinge uma fermentação adequada, pois caso contrário, há inibição do fermento, levando ao aparecimento de problemas, principalmente na superfície do queijo, como manchas e fermentação indesejada (LATICÍNIO. NET, 2004). O conteúdo do sal determina também muitas características nos queijos, tais como, fragmentação, fatiabilidade, esticabilidade e derretibilidade. Quanto às formas de salga, existem quatro. São elas: no leite, na massa, a seco e em salmoura (LATICÍNIO. NET, 2004). Dentre os diferentes tipos de salga dos queijos, destaca-se a salga por submersão, onde o produto é mantido em salmoura por tempo variável (BORSATO et al, 2007).

A salga em salmoura ou salga úmida, é realizada normalmente em tanques de salmoura, onde os queijos são mergulhados após a prensagem. A quantidade de sal retida pelo queijo depende da concentração e temperatura da salmoura, e do tempo de salga. Geralmente utilizam-se salmouras com concentração de sal de 20 a 24% e uma temperatura entre 10 e 15°C, para evitar o crescimento de microrganismos indesejáveis. O tempo de salga é determinado em

função do teor de umidade, tamanho, formato do queijo em questão e do teor de sal desejado. Um queijo prato, variedade lanche de 1 kg, necessita permanecer aproximadamente 24 horas em uma salmoura com 20% sal em uma temperatura de 15°C. A salmoura deve obedecer a um rigoroso controle quanto à concentração do sal e condições adequadas de higiene (SHEGDONI; RETTI; SOUZA, 1979).

O sal exerce um papel preponderantemente nos fenômenos físico-químicos, bioquímicos e microbiológicos que ocorrem durante a maturação (HOHENDORFF; SANTOS, 2006).

Quando o queijo é colocado na salmoura ocorrem simultaneamente, a entrada de sal (difusão) e saída de água (osmose). O sistema NaCl/água, portanto pode ser classificado como binário (GERLA; RUBIOLO, 2003).

No caso da utilização de uma parte de cloreto de potássio na salga do queijo, passa a ser um sistema ternário (NAUMAN; SAVOCA, 2001). Para estudar a difusão nesse sistema é necessário levar em conta o fluxo do cloreto de potássio, bem como sua influência no fluxo de cloreto de potássio. Para isso Bona (2004), utilizou uma modelagem matemática mais ampla para a simulação do sistema de difusão que ocorre neste sistema multicomponente.

2.3 DIFUSÃO

A difusão representa um fenômeno de transferência de massa que surge devido a uma diferença de potencial, provocada graças a uma diferença de concentração puntual. Este fenômeno é o responsável por muitas das operações unitárias existentes no campo da Engenharia Química e da Engenharia de Alimentos. A grandeza que mede a condutividade da transferência de massa, no fenômeno da difusão, é a difusividade mássica ou coeficiente de difusão. Dos três estados da matéria, os gases são os mais fáceis de serem tratados matematicamente em relação difusão, pelo fato de suas moléculas estarem distantes uma das outras e as forças moleculares poderem ser descartadas ou consideradas apenas nas colisões. Já os líquidos, que têm sido tratados como "gases densos", estão num grupo intermediário e existem atualmente modelos razoáveis para a

predição do coeficiente de difusão de determinados pares (WELTY; WICKS; WILSON, 1986).

A difusão pode ser vista como um processo no qual a concentração tende a se igualar em todos os pontos do sistema com o passar do tempo, ou seja, a difusão é um processo no qual a diferença de concentração é reduzida através de um fluxo espontâneo da matéria (NETZ; GONZALEZ, 2002).

A expressão que descreve o processo de difusão mássica é a conhecida lei de Fick.

$$j_A = -\rho D_{AB} \nabla m_A \quad (20)$$

onde, ρ é a densidade mássica: $\rho = \rho_A + \rho_B$;

m_A é a fracção de massa: $m_A = \rho_A/\rho$

ou

$$j_A^* = -C D_{AB} \nabla x_A \quad (21)$$

onde, C é a concentração molar: $C = C_A + C_B$;

x_A fracção molar: $x_A = C_A/C$

A lei de Fick estabelece que o fluxo de matéria é proporcional à diminuição da concentração e inversamente proporcional à distância (dx) (NETZ; GONZALEZ, 2002).

A segunda lei de Fick representa a velocidade de alteração da concentração de soluto em função do tempo e o deslocamento, ou seja, dois fatores importantes na determinação do coeficiente de difusão de qualquer soluto em diferentes sistemas (NETZ; GONZALEZ, 2002).

A difusão mássica em um sólido é um fenômeno geralmente lento e pode ser satisfatoriamente modelado pela 2ª lei Fick (CRANK, 1975). Quando dois solutos estão presentes (difusão multicomponente), um sistema de equações formado a partir da segunda lei de Fick pode ser empregado no estudo quantitativo do fenômeno (CUSSLER, 1976). Ao sistema estão associados coeficientes de difusão referentes ao fluxo dos solutos em relação ao próprio gradiente de

concentração (coeficiente de difusão principal) e coeficientes de difusão cruzados que correlacionam a interação existente entre os solutos à variação da concentração (ZORRILA; RUBIOLLO, 1998).

A utilização de modelos que simulam a difusão multicomponente, como a 2^ª lei de Fick generalizada, durante a salga e maturação de queijos é importante para o controle do processo e da qualidade do produto (BORSATO et al, 2007).

Bona (2004), modelou e simulou a difusão multicomponente que ocorre durante a salga mista (NaCl e KCl) de queijo prato em salmoura estática. Para este estudo utilizou o Método de Elementos Finitos (MEF) e um método analítico (MA). O desvio em relação aos dados experimentais do NaCl foi de 2,7% para o MA e 2,8% para o MEF, já para o KCl o MA apresentou um desvio de 6,6% e o MEF 5,5%. Bona (2007), fez o mesmo estudo com o MEF, mas usando salga com agitação. O desvio de NaCl dos dados experimentais da concentração foi 7.3% e 5.4% para o KCl.

Atualmente um novo programa computacional vem sendo utilizado para simulações, as Redes Neurais Artificiais. As Redes Neurais consistem em algoritmos de aprendizagem podendo ser uma ferramenta poderosa para resolver determinados tipos de problemas complexos e resultados do rendimento melhores do que outros modelos matemáticos (HUANG; KANGAS; RASCO, 2007).

As Redes Neurais Artificiais podem ser utilizadas em todas as áreas da ciência de alimentos, são ferramentas úteis para análises da segurança alimentar e da qualidade, tais como a modelagem do crescimento microbiano e predição da segurança alimentar. Podem interpretar dados espectroscópicos, e a predição do produto químico, e propriedades funcionais de alimento durante o processamento e a distribuição. RNAs são uma promessa para modelar tarefas complexas no controle e na simulação do processo (HUANG; KANGAS; RASCO, 2007).

3 OBJETIVOS

3.1 OBJETIVO GERAL

Desenvolver a melhor Rede Neural Artificial para a obtenção das concentrações finais de NaCl e KCl.

3.2 OBJETIVOS ESPECÍFICOS

- i. Utilizar o programa Soft Statística 7.1, com o módulo RNA para simulação da salga mista.
- ii. Validar e verificar a confiabilidades dos resultados com a rede obtida.

4 MATERIAL E MÉTODOS

4.1 QUEIJO PRATO

Os queijos pratos foram medidos em supermercado da cidade de Londrina. Foram medidos queijos pratos de três pesos 0,5 kg marca Italic, 2,0 Kg Tirolez e 3,0 kg Leitebom. Dez queijos foram medidos utilizando como convenção os eixos imaginários (x,y,z) com origem no centro geométrico (Fig.15) .




Figura 15 – Convenção adotada para os eixos imaginários, com origem no centro geométrico da amostra para identificação da simetria.

Com as medidas do queijo foram calculados a média, desvio padrão e volume (ANEXO 1).

4.2 SIMULAÇÃO

Com os novos valores de medidas de queijos foi feita uma simulação utilizando um programa em linguagem FORTRAN para a criação de um banco de dados maior.

Para simulação utilizou-se o programa SIMUL 3.0 software (BONA, 2004), em linguagem Fortran. A partir da concentração inicial de NaCl e KCl da salmoura (tabela), o tempo salga, as medidas dos eixos X,Y,Z, condição de contorno (com e sem agitação), foi feita uma simulação para obtenção da concentração final de NaCl e KCl no queijo prato.

Tabela 2 – Proporção em massa entre os sais NaCl e KCL na salmoura

NaCl (%)	KCl (%)
90	10
80	20
75	25
70	30
65	35
60	40
50	50

Outros dados utilizados para a simulação:

Malha com 504 elementos: (8 no eixo X, 7 no Y e 9 no Z)

Discretização temporal: 2 x 0,05h; 3 x 0,30h; 11 x 1,00h

Pontos de integração: 3

Biot 16,577

Concentração inicial de NaCl e KCl no queijo (g/100g de água no queijo)

NaCl 0,18 e KCl 0,26

Umidade de queijo 45% (g/100g de queijo base úmida)

Matriz de coeficiente de difusão

0,242 0,019

0,039 0,254

Onde 0,242 e 0,254 são os coeficientes de difusão principais (cm^2/dia) para NaCl e KCl respectivamente e 0,039 e 0,019 são os coeficientes de difusão cruzados (cm^2/dia) para NaCl e KCl respectivamente.

O número de Biot (Bi) expressa a magnitude relativa das resistências externa e interna, relaciona a velocidade de transporte de massa na camada líquida estagnada ao redor da biopartícula com a velocidade de difusão intraparticular (FAZOLO et al, 2001) De acordo com Bailey e Ollis (1986), se Bi for da ordem de 100 ou maior, os efeitos de resistência externos não serão significativos. O número de Biot só foi utilizado para salga estática, onde $Bi = 16,577$.

No final da simulação teve um banco de dados com 504 dados, onde 240 para treinamento, 120 para validação e 144 para teste.

4.3 APLICATIVO COMPUTACIONAL

Foi utilizado o programa STATISTICA 7.1 (2006). O módulo de redes neurais consta de:

- aquisição de dados;
- pré e pós- processamento;
- perceptrons de multicamadas (MLP);
- funções de base radial (RBF);
- ferramentas estatísticas para avaliação e validação;
- mapas auto-ajustáveis (SOM) ou algoritmo de Kohonen para aprendizagem não supervisionada;
- solução de problemas de classificação;
- técnicas de ensemble (maquina de comitê) para melhorar o desempenho das redes;
- análise de componentes principais.

4.4 DESENVOLVIMENTO DA REDE NEURAL: MANUAL DE OPERAÇÃO

No programa Statistica 7.1 foi criada uma tabela, com as seguintes variáveis X,Y,Z, volume, NaCl, KCl, condição de contorno, tempo de salga, NaClf, KClf e amostragem. Um exemplo da tabulação dos dados encontra-se no ANEXO 2.

Onde X,Y e Z são as médias desses eixos para cada queijo e estão em cm. O volume foi encontrado pela multiplicação dos três eixos e esta em cm^3 . NaCl e KCl são as concentrações iniciais desses sais e estão expressos em grama por 100 de água do queijo. A condição de contorno foi estabelecida como salga com agitação e salga sem agitação (estática). O tempo de salga foi de 1 a 12 horas e NaClf e KClf são as concentrações finais desses sais em g/100g de água no queijo. A amostragem é utilizada para determinar quais são utilizadas para treinamento e quais utilizadas para validação e teste. Onde 1 representa treinamento e 2 validação e 3 teste (ANEXO 2). Os índices 1 e 2 foram selecionados aleatoriamente entre as simulações com 90 e 10, 80 e 20, 70 e 30, 60 e 40 e 50 e 50 de proporção em massa entre os sais NaCl e KCl na salmoura. O índice três 3 foi uma simulação que considerou as proporções de 75, 25 e 65, 35 para o NaCl e KCl respectivamente (Tab. 2).

O primeiro passo é definir o tipo de problema (Fig. 16). Neste caso, será utilizada a regressão. Em problemas de regressão, o objetivo é estimar o valor de uma variável de saída contínua e as variáveis de entrada são conhecidas. Os problemas de regressão podem ser resolvidos utilizando vários tipos de redes como MLP (*Multi Layer Perceptron*, Perceptron de Multi Camadas); RBF (*Radial Basics Function* ou Função de Base Radial); GRNN (*Generalized Regression Neural Network* ou Rede Neural de Regressão Generalizada) e Linear.

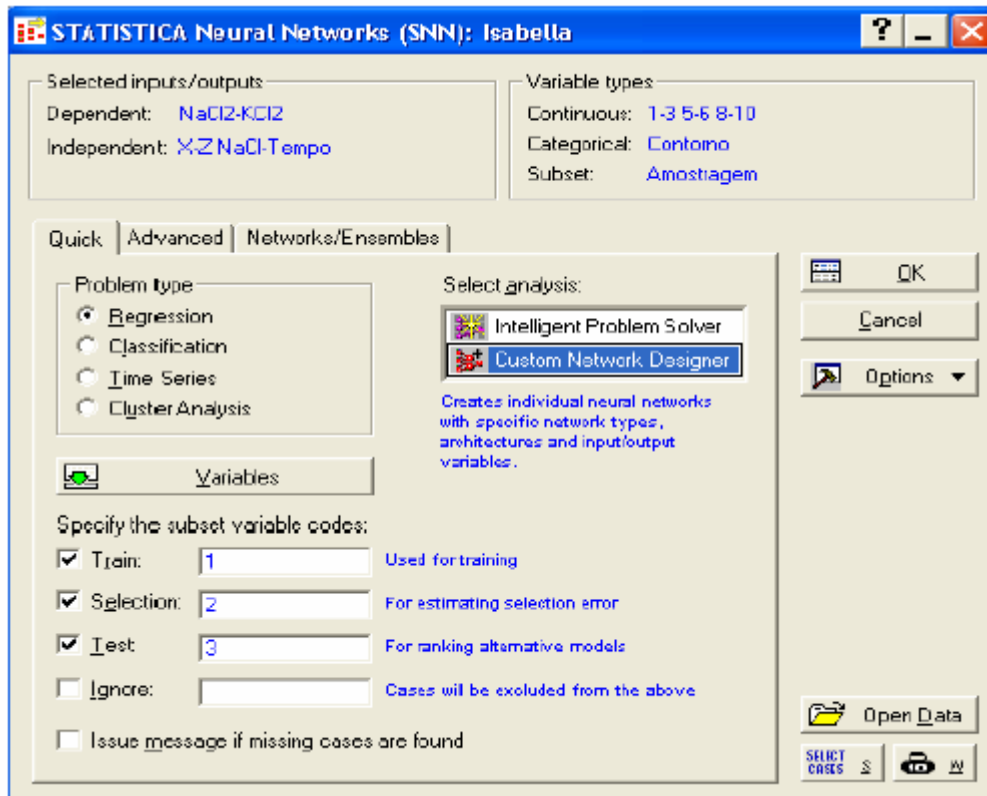


Figura 16 – Caixa de diálogo inicial do Statistica – módulo De Redes Neurais Artificiais

A seguir, em seleccione a análise (*Select analysis*) (Fig. 16) define-se o tipo de análise. Pode ser utilizado tanto o *Intelligent Problem Solver* (Resolução Inteligente de Problemas), onde se pode escolher mais de um tipo de rede ou o *Custom Network Designer* (CND - Projetista de Rede Customizada), onde se especifica o tipo de rede criando uma rede neural individual. Foi selecionado o CND, pois será utilizada uma rede individual. Após a seleção do CND, selecciona-se quais serão as variáveis de entrada (*input*), de saída (*output*), as variáveis qualitativas (*Categorical Inputs*), que são empregadas quando é necessário agrupar (grupos ou classes), por exemplo, a condição de contorno e por último a variável de subgrupos (*subset*), utilizada para definir quais subgrupos serão usados no treinamento, validação e teste da rede (Fig.

Quando se utiliza *subset variável*, é necessário especificar o código do variável, qual subgrupo será utilizado para o treinamento e qual será utilizado para validação e teste (Fig.16).

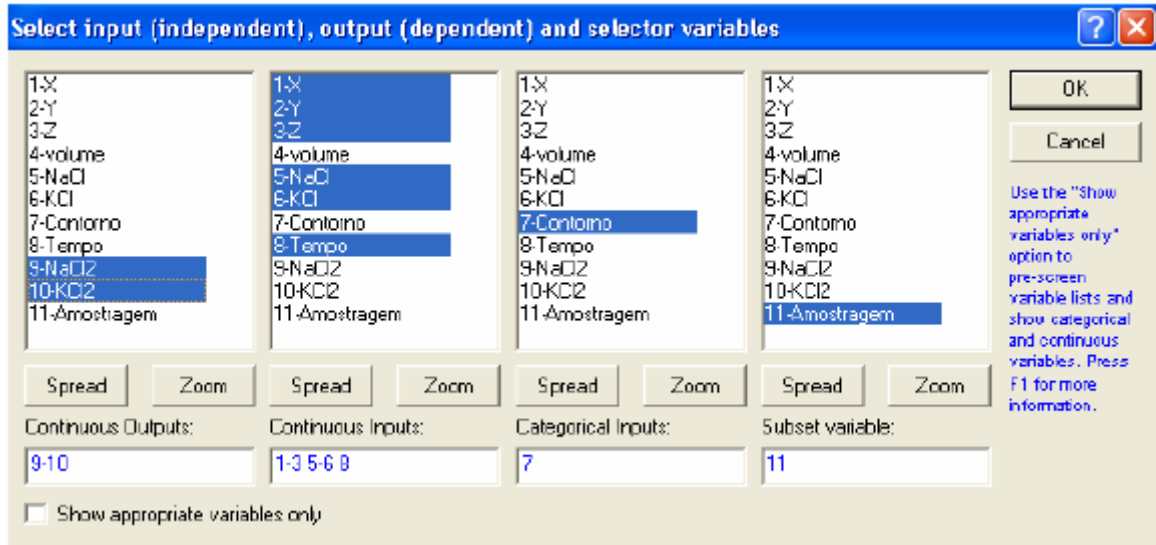


Figura 17 – Caixa de diálogo do Statistica 7.1 para escolha do tipo de problema, variáveis e tipo de análise

Depois de definido o tipo do problema, as variáveis e os tipos de análise, clica-se OK. Na próxima caixa de diálogo (Fig. 18) foi selecionado o tipo de rede. Para este estudo foi empregada uma rede do tipo RBF. Essa rede tem como característica combinar uma única camada intermediária ou escondida com uma camada de saída. A grande vantagem da utilização da RBF está na velocidade do processo de treinamento. As redes RBF, como descrito por Haykin (1994), são, usualmente mais rápidas no processo de treinamento que o MLP. Nesta mesma caixa de diálogo, em *Units* (unidades) escolhe-se a quantidade de neurônios da camada intermediária (escondida).

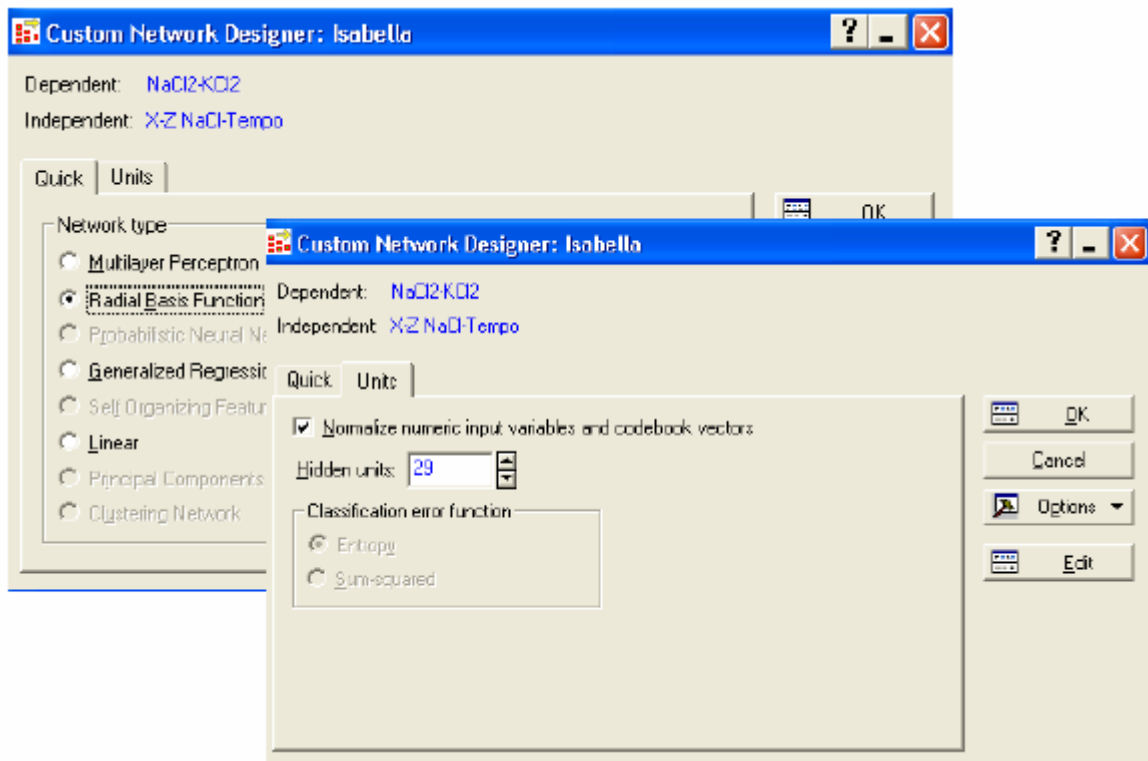


Figura 18 – Caixa de diálogo do Statistica 7.1 para escolha do tipo de rede e quantidade de neurônios na camada escondida

O próximo passo foi optar pelo algoritmo de treinamento da rede. Como visto no capítulo 1, as redes do tipo RBF podem ser treinadas por vários métodos. As redes RBF usam um processo de treinamento de 2 estágios:

1. Atribuição dos centros do radial e os seus desvios;
2. Otimização da camada de saída.

Na caixa de diálogo de treinamento (Fig. 19) escolhe-se entre *Sample training cases* (treinamento de amostras) e *K-means* (K-médias). Foi utilizado o *K-means*, que é um dos mais simples algoritmos de aprendizagem não supervisionado (MOORE, 2001). Depois deve-se escolher a propagação do radial (*radial spread*). Seleciona-se o *K-Nearest neighbors* ou vizinho mais próximo de K ou centro mais próximo de K e defini-se a quantidade de *K-Nearest neighbors* a ser utilizada.

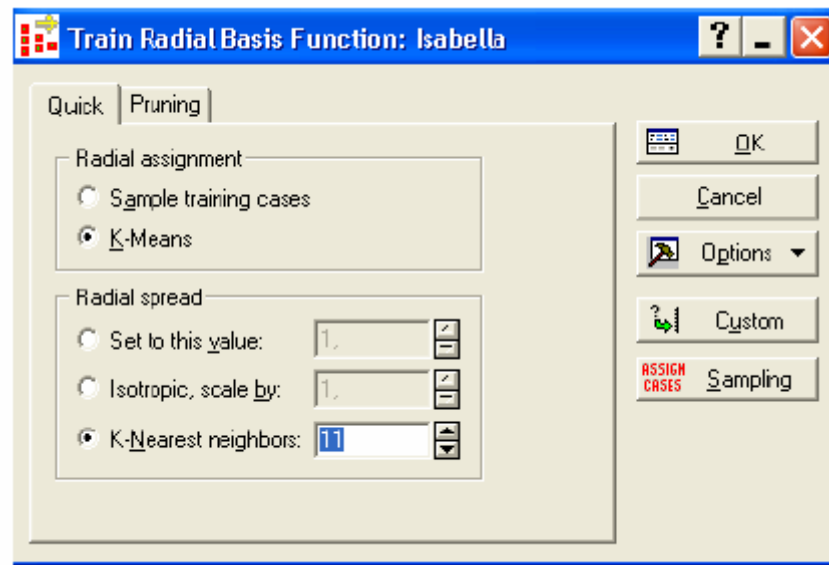


Figura 19 – Caixa de diálogo do Statistica 7.1 - Treinamento da Rede de Função de Base Radial

Após escolher os números de vizinhos mais próximos de K clica-se em OK e o programa calcula os desempenhos e os erros (Fig. 20 e 21).

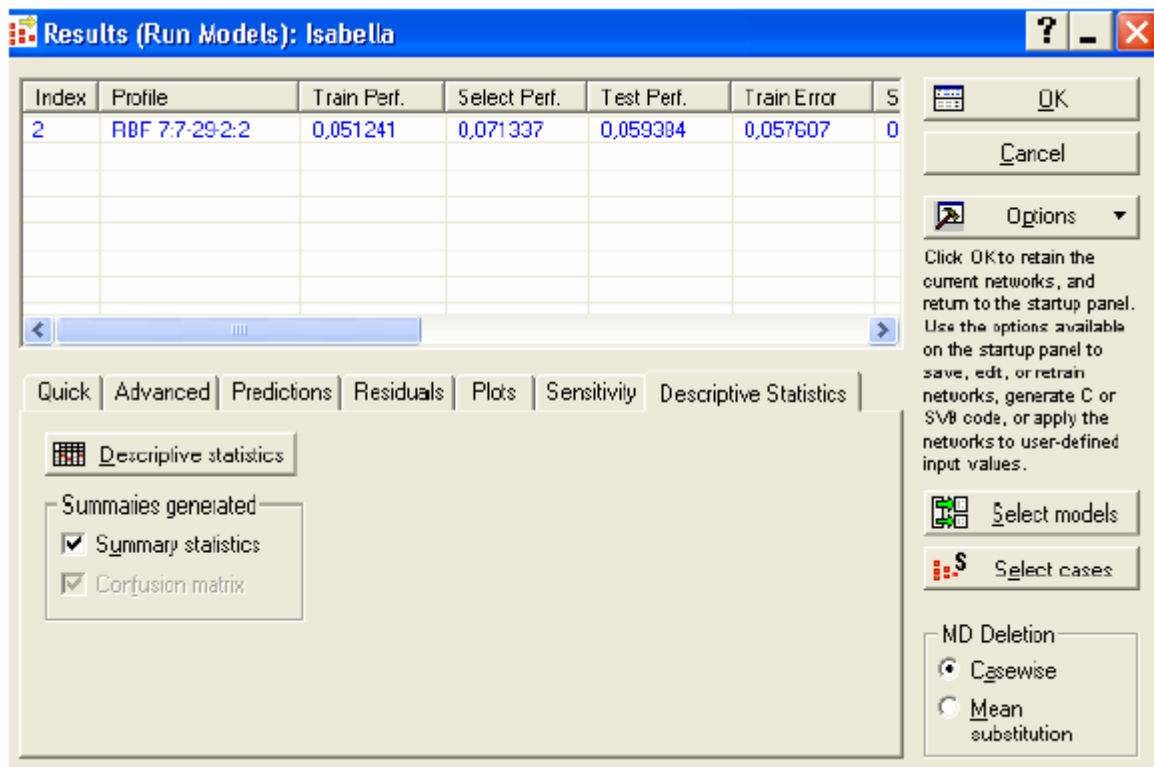


Figura 20 – Caixa de diálogo do Statistica 7.1 – Resultados

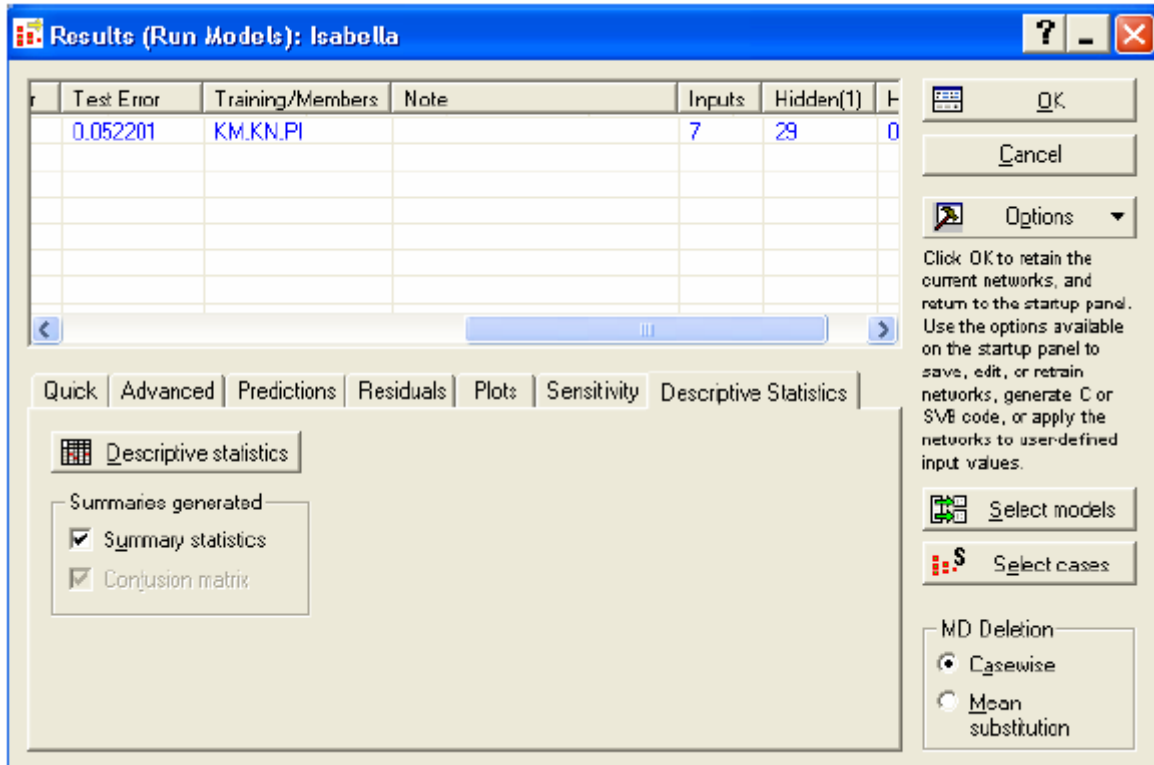


Figura 21 – Caixa de diálogo do Statistica 7.1 – Continuação de Resultados

Na coluna *Profile* - perfil (Fig. 20) está a topologia da rede. Por exemplo, RBF 7:7-29-2:2, significa: RBF é o tipo de rede, 7 é o número de variáveis de entrada, 7 número de neurônios de entrada, 29 número de neurônios na camada intermediária, 2 o número de neurônios de saída e 2 o número de variáveis de saída (as variáveis de entrada e saída são especificadas a frente (item 5.)) O *Train perf/ Select perf/ Test perf* referem-se à performance da rede no treinamento, validação e teste, respectivamente e são o valor do desvio entre os valores obtidos para as concentrações finais de NaCl e KCl pela rede neural e o valores previstos, durante o treinamento, validação e teste. *Train. Error; Select Error e Test Error* indicam o erro da rede nos subconjuntos usados durante o treinamento, validação e teste respectivamente.

A coluna *Training/Members* (Fig. 21), apresenta um breve resumo dos algoritmos usados no treinamento para aperfeiçoar a rede neural KM- K-means; KN- K-Nearest Neighbors e PI- Pseudo Inversa.

Na aba *Advanced* (Fig.21), se tem à geração especializada dos resultados, onde se pode fazer gráficos e ilustração das redes neurais. A aba

Predictions (Fig. 21), não esta disponível para todos modelos de rede, gera a previsão padrão da rede; isto é, um valor previsto para as variáveis de saída do modelo. A aba *Residual* (Fig. 21) funciona apenas em problemas de regressão e calcula os erros gerados por essas redes. Pode-se escolher entre os tipos de resíduos como, por exemplo, o *Raw* (valor observado - previsto); *Squared (Raw)²*; *Standart* (erro padrão) e *Absolute* (|Observado-Previsto|).

Na aba *Sensitivty* (Fig.21), avalia-se a sensibilidade das variáveis de entrada e sua importância. As relações abaixo de 1.0 são irrelevantes e essas variáveis podem ser desconsideradas (STATISTICA 7.1, 2006).

A aba *Plot* (Fig. 21) está somente disponível para redes de regressão. As opções nesta aba são usadas para produzir uma variedade de gráficos X versus Y, por exemplo valor previsto versus observado e histogramas. A aba *Descriptive Statistics* (Fig.21), gera estatísticas do desempenho da regressão. As estatísticas da regressão incluem:

Data Mean: valor médio da variável de saída (observada). **Data S.D.:** desvio padrão da variável de saída (observada).

Error Mean. erro médio (resíduo entre os valores de saída observados e previstos) das variáveis de saída.

Abs. E. Mean: erro médio absoluto (diferença entre os valores de saída observados e previstos) das variáveis de saída.

Error S.D. : desvio padrão dos erros das variáveis de saída. **S.D. Ratio:** relação do desvio padrão.

Correlation: coeficiente de correlação entre os valores previstos e observados dos valores de saída.

Essas etapas são repetidas várias vezes alterando a quantidade de neurônios da camada intermediária e do número de vizinhos mais próximos. Também se pode modificar as variáveis de entrada.

5 RESULTADOS E DISCUSSÃO

Antes de iniciar o estudo para desenvolver a melhor rede capaz de prever as concentrações finais de NaCl e KCl, verificou-se o que seria mais relevante, o uso do volume ou dos eixos X, Y e Z como variáveis de entrada ao problema em estudo. Para isso foi realizada uma análise de sensibilidade (aba *Sensitivity* Fig. 21) das redes quando essas foram simuladas utilizando os eixos X; Y; Z; volume; concentração inicial NaCl e KCl (g/100 g de água no queijo) e tempo de salga como variáveis de entrada. Como variáveis de saída foram definidas; concentração final de KCl (KClf) e NaCl (NaClf) (g/100 g de água no queijo). A variável qualitativa é a condição de contorno (contorno) e subset, a amostragem. A quantidade de neurônios variou entre 15 e 24.

Tabela 3 – Análise de Sensibilidade das redes com eixos X, Y, Z, volume, Concentração inicial de NaCl e KCl, e tempo de salga como variáveis de entrada e neurônios entre 15 e 24

	X	Y	Z	volume	NaCl	KCl	Contorno	Tempo
Rank.1	5,000000	8,000000	7,000000	6,000000	4,000000	3,000000	2,000000	1,000000
Rank.2	5,000000	8,000000	7,000000	6,000000	4,000000	3,000000	2,000000	1,000000
Rank.3	3,000000	8,000000	7,000000	6,000000	5,000000	4,000000	2,000000	1,000000
Rank.4	5,000000	8,000000	7,000000	6,000000	3,000000	4,000000	2,000000	1,000000
Rank.5	5,000000	8,000000	7,000000	6,000000	4,000000	3,000000	2,000000	1,000000
Rank.6	5,000000	8,000000	7,000000	6,000000	4,000000	3,000000	2,000000	1,000000
Rank.7	3,000000	8,000000	7,000000	6,000000	5,000000	4,000000	2,000000	1,000000
Rank.8	5,000000	8,000000	7,000000	6,000000	4,000000	3,000000	2,000000	1,000000
Rank.9	5,000000	8,000000	7,000000	6,000000	3,000000	4,000000	2,000000	1,000000
Rank.10	5,000000	8,000000	7,000000	6,000000	3,000000	4,000000	2,000000	1,000000

Observa-se na tabela 3 que o tempo e o contorno são as duas variáveis mais relevantes (1° e 2° lugares na classificação), seguidas pela concentração de cloreto de sódio e cloreto de potássio e o eixo x que variaram sua posição. as que apresentaram menor relevância foram o volume, o eixo Z e por ultimo o Y. Como, ao mesmo tempo em que o eixo X teve maior importância que o volume, e esse teve mais relevância que os eixos Y e Z, não se pode definir, a

princípio, se seria mais conveniente usar o volume ou os três eixos como variáveis de entrada.

Por isso, foram simuladas redes separadas. Primeiramente foram simuladas redes utilizando os eixos X, Y e Z e depois usando o volume. Em ambas simulações foram empregadas ainda como variáveis de entrada o tempo de salga e as concentrações iniciais de cloreto de sódio e cloreto de potássio. O contorno foi utilizado como variável qualitativa e a amostragem como variável subset. A quantidade de neurônios variou entre 20 e 30 e ainda 35, 40, 45 e 50 e o número de vizinhos na camada mais próxima (neighbors) foi mantido em 9 para começar. A seguir, as tabelas com as duas simulações (Tab. 4 e 5).

Tabela 4 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z.

Profile	Train Perf. - Desempenho do treinamento	Select perf – Desempenho da Validação	Test Perf – Desempenho do teste	Treinamento	Hidden(1)	neighbors
RBF 7:7-20-2:2	0,107770	0,117855	0,106309	KM,KN,PI	20	9
RBF 7:7-21-2:2	0,086933	0,099244	0,092957	KM,KN,PI	21	9
RBF 7:7-22-2:2	0,083301	0,101780	0,092370	KM,KN,PI	22	9
RBF 7:7-23-2:2	0,092711	0,102323	0,098442	KM,KN,PI	23	9
RBF 7:7-24-2:2	0,099812	0,106457	0,103683	KM,KN,PI	24	9
RBF 7:7-25-2:2	0,082863	0,096504	0,083615	KM,KN,PI	25	9
RBF 7:7-26-2:2	0,088723	0,107881	0,104375	KM,KN,PI	26	9
RBF 7:7-27-2:2	0,065904	0,085896	0,076949	KM,KN,PI	27	9
RBF 7:7-28-2:2	0,102320	0,113431	0,110844	KM,KN,PI	28	9
RBF 7:7-29-2:2	0,076123	0,095798	0,082393	KM,KN,PI	29	9
RBF 7:7-30-2:2	0,074084	0,097427	0,085472	KM,KN,PI	30	9
RBF 7:7-31-2:2	0,064314	0,078239	0,073401	KM,KN,PI	31	9
RBF 7:7-32-2:2	0,073986	0,098833	0,076202	KM,KN,PI	32	9
RBF 7:7-33-2:2	0,068150	0,086885	0,073677	KM,KN,PI	33	9
RBF 7:7-34-2:2	0,070508	0,088503	0,075168	KM,KN,PI	34	9
RBF 7:7-35-2:2	0,063346	0,091665	0,071887	KM,KN,PI	35	9
RBF 7:7-40-2:2	0,060539	0,076687	0,065464	KM,KN,PI	40	9
RBF 7:7-45-2:2	0,050449	0,076382	0,060514	KM,KN,PI	45	9
RBF 7:7-50-2:2	0,056831	0,081001	0,069868	KM,KN,PI	50	9

Tabela 5 – Desempenho de treinamento, validação e teste das redes com o volume

Profile	Train Perf. - Desempenho do treinamento	Select perf – Desempenho da Validação	Test Perf – Desempenho do teste	Treinamento	Hidden(1)	neighbors
RBF 5:5-20-2:2	0,122783	0,132714	0,114887	KM,KN,PI	20	9
RBF 5:5-21-2:2	0,115517	0,121144	0,124894	KM,KN,PI	21	9
RBF 5:5-22-2:2	0,104706	0,108739	0,111933	KM,KN,PI	22	9
RBF 5:5-23-2:2	0,106030	0,136535	0,095386	KM,KN,PI	23	9
RBF 5:5-24-2:2	0,113978	0,127395	0,121648	KM,KN,PI	24	9
RBF 5:5-25-2:2	0,121473	0,130031	0,125063	KM,KN,PI	25	9
RBF 5:5-26-2:2	0,100737	0,109901	0,110468	KM,KN,PI	26	9
RBF 5:5-27-2:2	0,118605	0,139940	0,122099	KM,KN,PI	27	9
RBF 5:5-28-2:2	0,112963	0,120206	0,116850	KM,KN,PI	28	9
RBF 5:5-29-2:2	0,086126	0,099001	0,088569	KM,KN,PI	29	9
RBF 5:5-30-2:2	0,099088	0,109980	0,096301	KM,KN,PI	30	9
RBF 5:5-31-2:2	0,096591	0,109053	0,113657	KM,KN,PI	31	9
RBF 5:5-32-2:2	0,077053	0,091115	0,073940	KM,KN,PI	32	9
RBF 5:5-33-2:2	0,080536	0,101962	0,078642	KM,KN,PI	33	9
RBF 5:5-34-2:2	0,086315	0,099472	0,089832	KM,KN,PI	34	9
RBF 5:5-35-2:2	0,071096	0,096239	0,070983	KM,KN,PI	35	9
RBF 5:5-40-2:2	0,080685	0,101483	0,084152	KM,KN,PI	40	9
RBF 5:5-45-2:2	0,077862	0,091494	0,073139	KM,KN,PI	45	9
RBF 5:5-50-2:2	0,071124	0,099028	0,083920	KM,KN,PI	50	9

Como pode ser observado, as redes que utilizaram os eixos X, Y e Z como variáveis de entrada tiveram valores menores de *train perf.*, *select perf.*, *test perf.* Por isso para o estudo foi decidido utilizar os eixos X, Y e Z.

Nos próximos testes, foram definidas como variáveis de entrada os eixos X, Y e Z; concentração inicial NaCl e KCl no queijo e tempo de salga. Como variáveis de saída KCl_f e $NaCl_f$. A variável qualitativa é o contorno e subset à amostragem.

Variou-se os números de neurônios (25 a 30 e 35) e dos vizinhos mais próximos de K (9 a 15) (Tab. 6).

Tabela 6 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, neurônios variando de 25 a 30 e 35 e vizinhos mais próximos variando entre 9 e 15

Profile	Train Perf. - Desempenho do treinamento	Select perf – Desempenho da Validação	Test Perf – Desempenho do teste	Treinamento	Hidden(1)	neighbors
RBF 7:7-25-2:2	0,083980	0,095612	0,092027	KM,KN,PI	25	9
RBF 7:7-25-2:2	0,066095	0,075775	0,075305	KM,KN,PI	25	10
RBF 7:7-25-2:2	0,099372	0,106873	0,091414	KM,KN,PI	25	11
RBF 7:7-25-2:2	0,072556	0,082566	0,077342	KM,KN,PI	25	12
RBF 7:7-25-2:2	0,058700	0,078415	0,065876	KM,KN,PI	25	13
RBF 7:7-25-2:2	0,061223	0,069016	0,065517	KM,KN,PI	25	14
RBF 7:7-25-2:2	0,064748	0,073525	0,067803	KM,KN,PI	25	15
RBF 7:7-26-2:2	0,076689	0,093108	0,084446	KM,KN,PI	26	9
RBF 7:7-26-2:2	0,084083	0,102669	0,092879	KM,KN,PI	26	10
RBF 7:7-26-2:2	0,063758	0,080863	0,074279	KM,KN,PI	26	11
RBF 7:7-26-2:2	0,077002	0,096408	0,083217	KM,KN,PI	26	12
RBF 7:7-26-2:2	0,065398	0,078628	0,073526	KM,KN,PI	26	13
RBF 7:7-26-2:2	0,084522	0,099175	0,089385	KM,KN,PI	26	14
RBF 7:7-26-2:2	0,056426	0,073218	0,067158	KM,KN,PI	26	15
RBF 7:7-27-2:2	0,108335	0,137320	0,108254	KM,KN,PI	27	9
RBF 7:7-27-2:2	0,082931	0,099868	0,089946	KM,KN,PI	27	10
RBF 7:7-27-2:2	0,065591	0,076236	0,067678	KM,KN,PI	27	11
RBF 7:7-27-2:2	0,067728	0,084246	0,074867	KM,KN,PI	27	12
RBF 7:7-27-2:2	0,078528	0,092291	0,084271	KM,KN,PI	27	13
RBF 7:7-27-2:2	0,076579	0,082090	0,078521	KM,KN,PI	27	14
RBF 7:7-27-2:2	0,063101	0,079355	0,069753	KM,KN,PI	27	15
RBF 7:7-28-2:2	0,065899	0,081613	0,072790	KM,KN,PI	28	9
RBF 7:7-28-2:2	0,086146	0,097400	0,092155	KM,KN,PI	28	10
RBF 7:7-28-2:2	0,064317	0,086879	0,066781	KM,KN,PI	28	11
RBF 7:7-28-2:2	0,086221	0,097681	0,092122	KM,KN,PI	28	12
RBF 7:7-28-2:2	0,077224	0,096844	0,088002	KM,KN,PI	28	13
RBF 7:7-28-2:2	0,065132	0,077784	0,069012	KM,KN,PI	28	14
RBF 7:7-28-2:2	0,063046	0,089876	0,069456	KM,KN,PI	28	15
RBF 7:7-29-2:2	0,064377	0,080859	0,069189	KM,KN,PI	29	9
RBF 7:7-29-2:2	0,086451	0,096079	0,090754	KM,KN,PI	29	10
RBF 7:7-29-2:2	0,064730	0,084119	0,073101	KM,KN,PI	29	11
RBF 7:7-29-2:2	0,073305	0,088569	0,076756	KM,KN,PI	29	12

Continuação (Tab .6)

RBF 7:7-29-2:2	0,053029	0,070589	0,059862	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,053162	0,071421	0,059039	KM,KN,PI	29	14
RBF 7:7-29-2:2	0,063878	0,080559	0,070290	KM,KN,PI	29	15
RBF 7:7-30-2:2	0,073264	0,090816	0,080162	KM,KN,PI	30	9
RBF 7:7-30-2:2	0,069357	0,084688	0,076286	KM,KN,PI	30	10
RBF 7:7-30-2:2	0,063208	0,081224	0,061674	KM,KN,PI	30	11
RBF 7:7-30-2:2	0,061136	0,070191	0,063257	KM,KN,PI	30	12
RBF 7:7-30-2:2	0,072770	0,087628	0,076988	KM,KN,PI	30	13
RBF 7:7-30-2:2	0,063428	0,085312	0,069597	KM,KN,PI	30	14
RBF 7:7-30-2:2	0,053312	0,069952	0,065713	KM,KN,PI	30	15
RBF 7:7-35-2:2	0,057539	0,079771	0,063190	KM,KN,PI	35	9
RBF 7:7-35-2:2	0,051736	0,077086	0,059307	KM,KN,PI	35	10
RBF 7:7-35-2:2	0,063195	0,082196	0,064907	KM,KN,PI	35	11
RBF 7:7-35-2:2	0,059989	0,079797	0,069748	KM,KN,PI	35	12
RBF 7:7-35-2:2	0,065402	0,081131	0,066372	KM,KN,PI	35	13
RBF 7:7-35-2:2	0,053398	0,067033	0,059816	KM,KN,PI	35	14
RBF 7:7-35-2:2	0,046364	0,065822	0,054147	KM,KN,PI	35	15

O próximo passo foi selecionar e repetir os testes que tiveram valor de train perf. $\leq 6 \times 10^{-2}$, ou seja, um desvio menor ou igual a 6% do valor obtido em relação ao valor previsto. As redes que tiveram menor desvio foram as que utilizaram 29, 30 e 35 neurônios. Nesta etapa, todas as variáveis e variação dos vizinhos mais próximos foram mantidas. Essa etapa foi repetida três vezes para verificar repetibilidade dos resultados (Tab. 7, 8 e 9).

Tabela 7 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29, 30 e 35 neurônios e vizinhos mais próximos variando entre 9 e 15

Profile	Train Perf. - Desempenho do treinamento	Select perf – Desempenho da Validação	Test Perf – Desempenho do teste	Treinamento	Hidden(1)	neighbors
RBF 7:7-29-2:2	0,080319	0,102855	0,089044	KM,KN,PI	29	9
RBF 7:7-29-2:2	0,081180	0,092752	0,082036	KM,KN,PI	29	10
RBF 7:7-29-2:2	0,057666	0,080267	0,063527	KM,KN,PI	29	11
RBF 7:7-29-2:2	0,069823	0,086167	0,075817	KM,KN,PI	29	12
RBF 7:7-29-2:2	0,056781	0,068766	0,067647	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,063179	0,081494	0,073252	KM,KN,PI	29	14
RBF 7:7-29-2:2	0,096217	0,097666	0,100857	KM,KN,PI	29	15
RBF 7:7-30-2:2	0,061036	0,081536	0,074665	KM,KN,PI	30	9
RBF 7:7-30-2:2	0,084781	0,098902	0,097052	KM,KN,PI	30	10
RBF 7:7-30-2:2	0,081283	0,095101	0,081248	KM,KN,PI	30	11
RBF 7:7-30-2:2	0,062467	0,082563	0,064781	KM,KN,PI	30	12
RBF 7:7-30-2:2	0,065981	0,084082	0,075298	KM,KN,PI	30	13
RBF 7:7-30-2:2	0,054538	0,071585	0,059840	KM,KN,PI	30	14
RBF 7:7-30-2:2	0,053652	0,070973	0,062172	KM,KN,PI	30	15
RBF 7:7-35-2:2	0,071905	0,096912	0,078030	KM,KN,PI	35	9
RBF 7:7-35-2:2	0,060476	0,085579	0,061847	KM,KN,PI	35	10
RBF 7:7-35-2:2	0,059863	0,075128	0,067684	KM,KN,PI	35	11
RBF 7:7-35-2:2	0,070168	0,093155	0,075632	KM,KN,PI	35	12
RBF 7:7-35-2:2	0,054956	0,073161	0,063854	KM,KN,PI	35	13
RBF 7:7-35-2:2	0,049573	0,075225	0,057763	KM,KN,PI	35	14
RBF 7:7-35-2:2	0,050434	0,064151	0,060169	KM,KN,PI	35	15

Tabela 8 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29, 30 e 35 neurônios e vizinhos mais próximos variando entre 9 e 15

Profile	Train Perf. - Desempenho do treinamento	Select perf – Desempenho da Validação	Test Perf – Desempenho do teste	Treinamento	Hidden(1)	neighbors
RBF 7:7-29-2:2	0,064799	0,082739	0,089044	KM,KN,PI	29	9
RBF 7:7-29-2:2	0,078160	0,102941	0,082036	KM,KN,PI	29	10
RBF 7:7-29-2:2	0,067158	0,089563	0,063527	KM,KN,PI	29	11
RBF 7:7-29-2:2	0,071172	0,090327	0,075817	KM,KN,PI	29	12
RBF 7:7-29-2:2	0,059437	0,074555	0,067647	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,048186	0,064731	0,073252	KM,KN,PI	29	14
RBF 7:7-29-2:2	0,062207	0,074962	0,100857	KM,KN,PI	29	15
RBF 7:7-30-2:2	0,079264	0,091808	0,074665	KM,KN,PI	30	9
RBF 7:7-30-2:2	0,084049	0,102861	0,097052	KM,KN,PI	30	10
RBF 7:7-30-2:2	0,058121	0,071083	0,081248	KM,KN,PI	30	11
RBF 7:7-30-2:2	0,060853	0,077444	0,064781	KM,KN,PI	30	12
RBF 7:7-30-2:2	0,071348	0,087308	0,075298	KM,KN,PI	30	13
RBF 7:7-30-2:2	0,057445	0,077402	0,059840	KM,KN,PI	30	14
RBF 7:7-30-2:2	0,061636	0,069814	0,062172	KM,KN,PI	30	15
RBF 7:7-35-2:2	0,068438	0,091469	0,078030	KM,KN,PI	35	9
RBF 7:7-35-2:2	0,054565	0,080184	0,061847	KM,KN,PI	35	10
RBF 7:7-35-2:2	0,054569	0,075462	0,067684	KM,KN,PI	35	11
RBF 7:7-35-2:2	0,054620	0,071671	0,075632	KM,KN,PI	35	12
RBF 7:7-35-2:2	0,052717	0,073037	0,063854	KM,KN,PI	35	13
RBF 7:7-35-2:2	0,066339	0,090071	0,057763	KM,KN,PI	35	14
RBF 7:7-35-2:2	0,051039	0,076381	0,060169	KM,KN,PI	35	15

Tabela 9 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29, 30 e 35 neurônios e vizinhos mais próximos variando entre 9 e 15

Profile	Train Perf. - Desempenho do treinamento	Select perf – Desempenho da Validação	Test Perf – Desempenho do teste	Treinamento	Hidden(1)	neighbors
RBF 7:7-29-2:2	0,086524	0,107116	0,096808	KM,KN,PI	29	9
RBF 7:7-29-2:2	0,070256	0,084517	0,071901	KM,KN,PI	29	10
RBF 7:7-29-2:2	0,069407	0,089326	0,078530	KM,KN,PI	29	11
RBF 7:7-29-2:2	0,065177	0,078801	0,074221	KM,KN,PI	29	12
RBF 7:7-29-2:2	0,054043	0,076782	0,062782	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,057839	0,076925	0,066990	KM,KN,PI	29	14
RBF 7:7-29-2:2	0,071448	0,084141	0,071239	KM,KN,PI	29	15
RBF 7:7-30-2:2	0,065927	0,083805	0,075764	KM,KN,PI	30	9
RBF 7:7-30-2:2	0,071391	0,088042	0,080670	KM,KN,PI	30	10
RBF 7:7-30-2:2	0,071833	0,089558	0,079876	KM,KN,PI	30	11
RBF 7:7-30-2:2	0,055551	0,073980	0,061274	KM,KN,PI	30	12
RBF 7:7-30-2:2	0,055918	0,070517	0,063007	KM,KN,PI	30	13
RBF 7:7-30-2:2	0,068944	0,095658	0,077683	KM,KN,PI	30	14
RBF 7:7-30-2:2	0,063980	0,082409	0,072786	KM,KN,PI	30	15
RBF 7:7-35-2:2	0,057943	0,071644	0,067628	KM,KN,PI	35	9
RBF 7:7-35-2:2	0,063497	0,089077	0,065656	KM,KN,PI	35	10
RBF 7:7-35-2:2	0,056340	0,074005	0,063937	KM,KN,PI	35	11
RBF 7:7-35-2:2	0,055796	0,070763	0,062476	KM,KN,PI	35	12
RBF 7:7-35-2:2	0,059777	0,080340	0,070000	KM,KN,PI	35	13
RBF 7:7-35-2:2	0,056321	0,077234	0,062972	KM,KN,PI	35	14
RBF 7:7-35-2:2	0,055945	0,079448	0,060213	KM,KN,PI	35	15

O exame das tabelas 7, 8 e 9 mostrou que a melhor rede (assinaladas em azul) foi a que utilizou 29 neurônios na camada intermediária e 13 vizinhos mais próximos de K. Essa rede foi escolhida pois, de acordo com Pereira (1999), é melhor utilizar o menor número de neurônios possíveis. O resultado também deve ser constante, não deve apresentar desvios de treinamento superiores ao arbitrado ($\leq 6 \times 10^{-2}$).

Para confirmar a repetibilidade dos resultados da rede com 29 neurônios e 13 vizinhos mais próximos de K, testou-se essa rede mais algumas vezes.

Tabela 10 – Desempenho de treinamento, validação e teste das redes com eixos X, Y e Z, com 29 neurônios e 9 vizinhos mais próximos

Profile	Train Perf. - Desempenho do treinamento	Select perf – Desempenho da Validação	Test Perf – Desempenho do teste	Treinamento	Hidden(1)	neighbors
RBF 7:7-29-2:2	0,059653	0,069897	0,068310	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,057811	0,063827	0,055980	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,056748	0,077837	0,062240	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,059148	0,077134	0,069180	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,057128	0,073359	0,061726	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,056782	0,074221	0,067572	KM,KN,PI	29	13
RBF 7:7-29-2:2	0,049962	0,067026	0,060387	KM,KN,PI	29	13

Depois dos realizados, foi escolhida a rede que utiliza como variáveis de entrada os eixos X, Y e Z; concentração inicial NaCl e KCl e tempo de salga. Como variáveis de saída concentração final de KCl e NaCl. A variável qualitativa é o contorno e subset à amostragem. Com 29 neurônios na camada intermediária e 13 vizinhos mais próximos de K. Pode-se observar que os valores de treinamento, validação e teste são próximos.

Para avaliar melhor o resultado, não se deve levar em consideração apenas os desvios do treinamento. Pode usar outros resultados como resíduos, previsões e análises estatística e gráficos. Na tabela 11 tem-se as análises estatísticas pra uma rede que foi definida como a melhor rede (RBF 7:7-29-2:2, com 13 neurônios na camada intermediária).

Tabela 11 – Análise estatística de uma rede RBF com 29 neurônios e 13 vizinhos mais próximos K

	NaCl _f	KCl _f
Data S.D.	0,951791	0,587280
Error S.D.	0,054958	0,043711
S.D. Ratio	0,057742	0,074429
Correlation	0,998334	0,997235

Um valor de S. D. Ratio de 0,1 ou menor indica um desempenho muito bom da regressão (STATISTICA, 2006). Pode-se observar que os valores de

S. D. Ratio foram menores que 0,1 (Tab. 11) tanto pro NaCl (0,058) como KCl (0,074) observados, comprovando que a rede selecionada foi capaz de uma boa aproximação com os valores finais da concentração de NaCl e KCl previstos e que pode ser utilizada para definir essa concentração final.

Com os valores de previsão foram construídos dois gráficos (Fig. 22 e 23) comparando os valores esperados (x) com os valores obtidos (y), tanto para concentração de NaCl e KCl. Pode-se observar que o grau de correlação é um valor bem próximo a 1 (0,9988) para NaCl e (0,9903) para KCl, o que demonstra que os valores foram bem próximos e que a rede conseguiu uma boa aproximação com a função desejada.

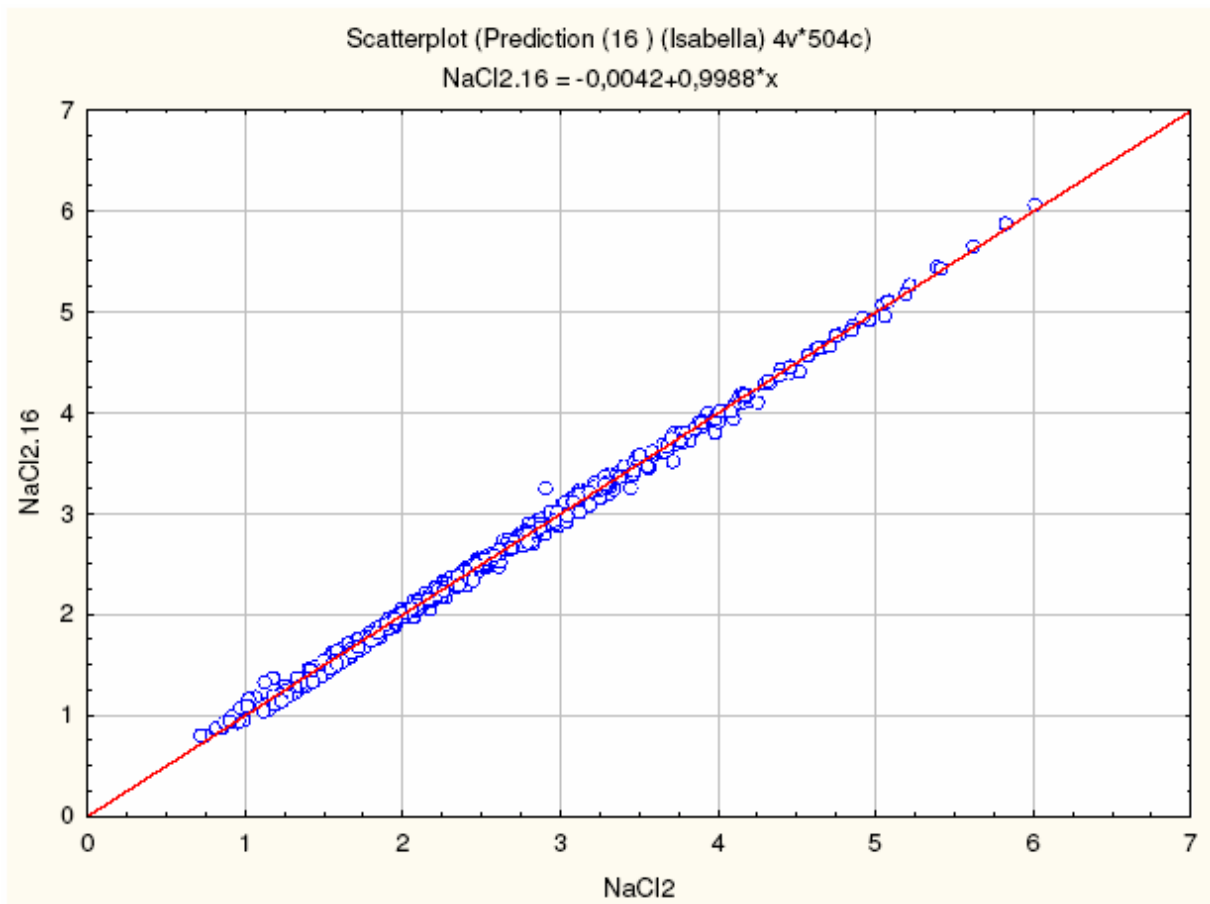


Figura 22 – Gráfico de comparação entre os valores previsto – n (X) e os valores obtidos – n. 16 (Y) para concentração de NaCl

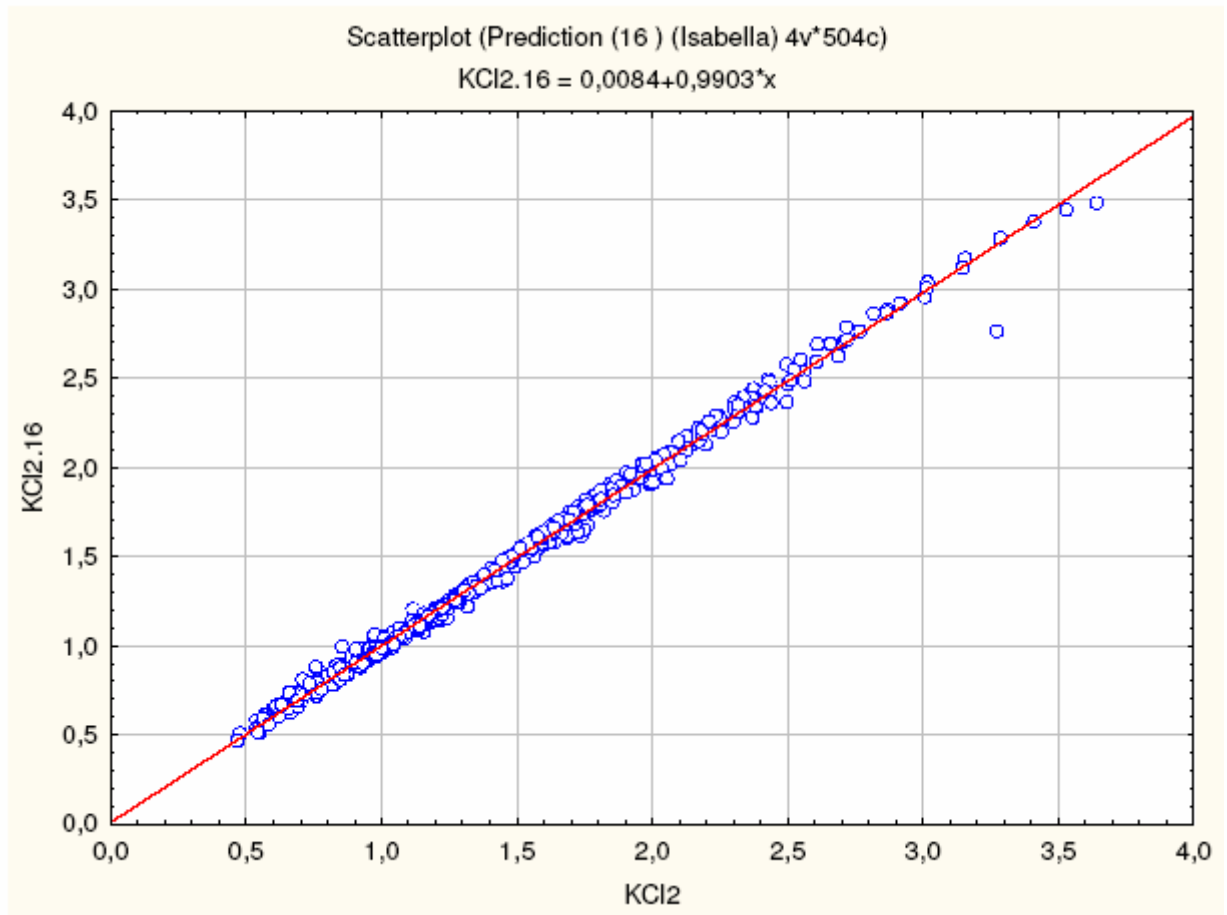


Figura 23 – Gráfico de comparação entre os valores previsto – k (X) e os valores obtidos – k. 16 (Y) para concentração de KCl

6 CONCLUSÃO

As concentrações finais de NaCl e KCl podem ser previstas com sucesso aplicando o programa de Redes Neurais Artificiais, quando utiliza-se as medidas do queijo, as concentrações iniciais, o tempo de salga e a condição de contorno como parâmetros.

A rede conseguiu uma boa aproximação com os valores utilizados, apresentando um desvio padrão médio percentual de 5,5% para NaCl e 4,4% KCl.

As Redes neurais mostraram-se tão eficiente quanto os métodos analíticos (desvio de 2,7% para NaCl e 6,6% para KCl) e métodos de elementos finitos (desvio de 2,8% para NaCl e 5,5% para KCl) (BONA, 2004) na modelagem das concentrações finais de NaCl e KCl, podendo ser utilizadas para simular a salga mista do queijo prato.

Os valores um pouco maiores do desvio podem ser explicados pela utilização da salga agitada. Quando Bona (2007), estudou a salga agitada pelos métodos de elementos finitos os erros foram: 7.3% para NaCl e 5.4% para o KCl.

Os valores do desvio durante a validação e o teste da rede, são comparáveis entre si e próximos do treinamento comprovando que a rede foi bem treinada.

**Capítulo 3 – UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS PARA
CLASSIFICAR FRUTAS E HORTALIÇAS QUANTO A SUA FORMA DE CULTIVO:
CONVENCIONAL, ORGÂNICO E HIDROPÔNICO**

1 INTRODUÇÃO

Durante as últimas décadas a agricultura mudou sua característica através do desenvolvimento de novas tecnologias, máquinas agrícolas e indústria química. Embora isto tenha impulsionado a produção de alimentos, também produziu efeitos colaterais.

A degradação ambiental na atualidade é muito grande especialmente no tocante ao solo, devido à erosão que reduz a oferta do ambiente agricultável em cerca de seis milhões de atar, além da salinização, desvios de águas impróprias para a irrigação, destruição dos lençóis de água, entre outros (MELO FILHO, 1999, CORSON, 1997), sendo que de 1945 para cá, dois bilhões de hectares de terra dos quais 1,5 bilhão em países em desenvolvimento (75% do total), quase o dobro da área do Brasil, foram degradadas por intervenções do homem (CONWAY, 1998). Somente de agrotóxicos ou pesticidas mais de três milhões de toneladas são utilizadas no mundo por ano com problemas sérios de contaminação, intoxicações, doenças agudas e crônicas e incremento da resistência das pragas (insetos, ácaros) e das plantas daninhas, com nove casos de resistência relatados por ano desde 1978 (GARCIA, 1997 a, b e c, VARGAS et al. 1999; GUEDES, 2001).

O uso indiscriminado de agrotóxicos na produção de alimentos vem causando preocupação em diversas partes do mundo. A crítica ao modelo de agricultura vigente cresce à medida que estudos comprovam que os agrotóxicos contaminam os alimentos e o meio ambiente, causando danos à saúde (ARCHANJO; BRITO; SAURBECK et al, 2001).

Um número crescente de consumidores tem se preocupado cada vez mais com temas como: segurança alimentar, meio ambiente, bem-estar social e saúde, mostrando-se dispostos a pagar mais caro por "alimentos naturais" que não contenham produtos químicos ou outras fontes de contaminação (REGMI, 2001; UNCTAD, 1999).

Visando atender as tendências do mercado e exigências dos consumidores a ciência agrícola tem trabalhado com novas formas de cultivo de hortícolas como a agricultura orgânica, hidropônica entre outras (SEVERINO, 2000).

A crescente preocupação quanto aos aspectos toxicológicos dos agrotóxicos e a possibilidade de contaminação dos produtos agrícolas têm levado muitos países a estabelecer programas de vigilância ou de monitoramento, com a execução de análises freqüentes e programadas. Preocupação esta que se estende também à qualidade nutricional, microbiológica e sensorial dos alimentos, alterada em função do sistema de cultivo (convencional, hidropônico, orgânico, etc.) de determinadas culturas (CALDAS, 1999).

Um grande número de fatores tem sido investigado em estudos que comparam alimentos produzidos pelos sistemas de cultivo orgânico e convencional, incluindo os de ordem econômica e social, agrônômica (propriedades químicas, físicas e microbiológicas do solo, pragas e doenças), produtividade, sistema de administração da propriedade, qualidade do produto (valor nutricional, sensorial, vida de prateleira), impactos ambientais, biodiversidade, entrada de nutrientes, comércio e políticas associadas com a produção de alimentos (FINESILVER, JOHNS, HILL, 1989; LAMPKIN, 1990). Entretanto pouco se tem estudado, em termos de comparação, sobre o sistema de cultivo hidropônico (MIYAZAWA; KHAUTOUNIAN; ODENATH-PENHA., 2001; CARMO JR., 2002).

2 REVISÃO BIBLIOGRÁFICA

2.1 AGRICULTURA CONVENCIONAL

A agricultura convencional vem demonstrando sérios problemas sociais, ambientais e econômicos. Nas questões ambientais pode-se citar a utilização inadequada de recursos naturais não renováveis bem como os renováveis. O meio ambiente está dando vários "gritos de socorro", o empobrecimento dos solos, erosão, rios contaminados, desequilíbrios da fauna e flora, entre tantas outras demonstrações que a natureza vem tornando visível para o homem. (QUADROS; KOSKUSCA, 2007).

A agricultura moderna teve sua origem ligada às descobertas do século XIX, a partir de estudos dos cientistas Saussure (1797-1845), Boussingault (1802-1887) e Liebig (1803-1873), que derrubaram a teoria do húmus, segundo a qual as plantas obtinham seu carbono a partir da matéria-orgânica do solo (PLANETA ORGÂNICO, 2004).

Liebig difundiu a idéia de que o aumento da produção agrícola seria diretamente proporcional à quantidade de substâncias químicas incorporadas ao solo. Toda a credibilidade atribuída às descobertas de Liebig deu-se ao fato de estarem apoiadas em comprovações científicas. Junto com Jean-Baptiste Boussingault, que estudou a fixação de nitrogênio atmosférico pelas plantas leguminosas, Liebig é considerado o maior precursor da "agroquímica" (EHLERS, 1996). As descobertas de todos esses cientistas, segundo Ehlers (1996), marcam o fim de uma longa data, da Antiguidade até o século XIX, na qual o conhecimento agrônomo era essencialmente empírico. A nova fase foi caracterizada por um período de rápidos progressos científicos e tecnológicos.

No início do século XX, Louis Pasteur (1822-1895), Serge Winogradsky (1856-1953) e Martinus Beijerinck (1851-1931), precursores da microbiologia dos solos, dentre outros, contribuíram com mais fundamentos científicos que fizeram uma contraposição às teorias de Liebig, ao provarem a importância da matéria orgânica nos processos produtivos agrícolas (EHLERS, 1996).

Contudo, mesmo com o surgimento de comprovações científicas a respeito dos equívocos de Liebig, os impactos de suas descobertas haviam extrapolado o meio científico e ganhado força nos setores produtivo, industrial e agrícola, abrindo um amplo e promissor mercado: o de fertilizantes "artificiais" (FRADE, 2000).

Na medida em que certos componentes da produção agrícola passaram a serem produzidos pelo setor industrial, ampliaram-se as condições para o abandono dos sistemas de rotação de culturas e da integração da produção animal à vegetal; que passaram a ser realizadas separadamente. Tais fatos deram início a uma nova fase da história da agricultura, que ficou conhecida como "Segunda Revolução Agrícola". São também parte desse processo o desenvolvimento de motores de combustão interna e a seleção e produção de sementes como os outros itens apropriados pelo setor industrial. Estas inovações foram responsáveis por sensíveis aumentos nos rendimentos das culturas (FRADE, 2000).

Entretanto, esse modelo de agricultura a partir da década de 60 começava a dar sinais de sua exaustão: desflorestamento, diminuição da biodiversidade, erosão e perda da fertilidade dos solos, contaminação da água, dos animais silvestres e dos agricultores por agrotóxicos passaram a ser decorrências quase inerentes à produção agrícola (EHLERS, 1993).

Rachel Carson (1962) lançou o livro "Primavera Silenciosa", onde detalhava os efeitos da utilização dos pesticidas e inseticidas químicos sintéticos no meio ambiente e na saúde humana. A obra ganhou relevância internacional, pois iniciou o debate sobre o custo ambiental dessa contaminação para o homem. A autora alertou para os prejuízos do uso de produtos químicos no controle de pragas e doenças, advertindo que estavam interferindo nas defesas naturais do próprio ambiente (CARSON, 1964).

Na prática, porém, o que se viu nos anos seguintes foi à continuação do avanço da agricultura convencional, particularmente nos países em desenvolvimento, com o agravamento dos danos ambientais. (PLANETA ORGÂNICO, 2004)

O crescimento da produção agrícola no Brasil se dava, basicamente, até a década de 50, por conta da expansão da área cultivada. A partir da década de 60, o uso de máquinas, adubos e defensivos químicos, passaram a ter, também, importância no aumento da produção agrícola. De acordo com os parâmetros da

"Revolução Verde", incorporou-se um pacote tecnológico à agricultura, tendo a mudança da base técnica resultante passada a ser conhecida como modernização da agricultura brasileira (SANTOS, 1986).

O processo de modernização intensificou-se a partir dos anos 70. Os modelos de desenvolvimento agrícola difundidos na década de 70 e predominantes na década de 80 caracterizaram-se por utilizar sistemas de produção intensivos em tecnologias mecânicas e químicas, que utilizavam grandes quantidades de capital e energia. Esses sistemas produtivistas aumentaram a eficiência econômica das empresas agrícolas isoladamente, devido ao crédito barato e aos ganhos de produtividade imediatos. Por outro lado, reduziam a necessidade de utilização de mão-de-obra e aumentavam os danos ao meio-ambiente, causando graves prejuízos para o conjunto da sociedade. "O modelo imperante, agroquímico, é fortemente negativo em relação à estabilidade sócio econômica do homem do campo, pois conduz ao desemprego rural devido à necessidade de se concentrar áreas e rendas. Com efeito, o uso dos modernos insumos agroquímicos e das sofisticadas maquinarias agrícolas paradigmas desse modelo - exige pesados investimentos de capital, concentrando, portanto, as áreas produtivas" (BONNILA, 1992).

O uso de fertilizantes artificiais e agrotóxicos também se acentuou a partir da década de 1960, com índices bastante elevados. Segundo Graziano Neto (1985), entre 1965 e 1975 o consumo de fertilizantes cresceu a taxa média de 60% ao ano, enquanto que os agrotóxicos cresceram numa média anual de 25%.

As expectativas atuais são mais otimistas que o *desempenho* observado em 2006, quando as vendas de defensivos agrícolas no Brasil totalizaram US\$ 3,920 bilhões. São Paulo se destacou como o maior Estado consumidor em 2006, representando 21,7% das vendas nacionais em termos de produto comercial e 20,6% em valor, ou seja, US\$ 808,2 milhões; seguido de Mato Grosso (17,9%), Paraná (13,4%), Rio Grande do Sul (10,4%), Minas Gerais (9,0%), Goiás (8,8%), Bahia (6,0%) e Mato Grosso do Sul (4,7%). As demais Unidades da Federação, juntas, responderam por 9,2%. (SINDAG, 2006).

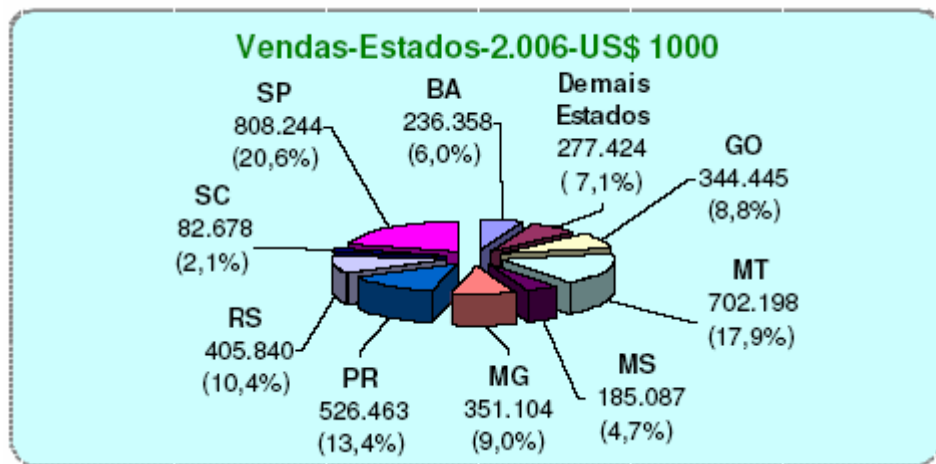


Figura 24 – Desempenho de vendas de agrotóxicos no Brasil em 2006

Fonte: SINDAG (2006)

Entre os prejuízos ambientais, pode-se citar o aumento do número de pragas resistentes, o transporte de produtos químicos pela atmosfera e a contaminação das águas subterrâneas, do solo; degradação do solo, devido compactações e erosões, redução da biodiversidade e dos processos microbianos do solo, presença de resíduos químicos em alimentos causando riscos à saúde dos consumidores e intoxicações dos trabalhadores que manuseiam os pesticidas. Os prejuízos sociais podem ser representados pelo êxodo rural e o inchaço urbano que ocorre a partir da década de 70 (MEURER; BISSANI; SELBACH, 2000; REGANOLD; GLOVER; ANDREWS., 2000).

Devido a esses e outros problemas, o paradigma agrícola produtivista vem sendo contestado pela sociedade, que cobra dos empreendimentos agrícolas intensivos os custos ambientais e sociais de suas atividades, seja através de um maior controle por parte do governo, seja através de uma mudança nos hábitos do consumidor, que privilegia as empresas responsáveis socialmente e ecologicamente. Um dos reflexos desta mudança de mentalidade por parte dos consumidores é crescimento do consumo dos produtos orgânicos (TEIXEIRA, 2005).

Nesta nova fase, são contemplados aspectos ligados às características organolépticas, à segurança alimentar e à proteção ao ambiente. Isso contrasta com o sistema de produção praticado nos últimos tempos, com excesso no uso de insumos e pouca preocupação com o impacto ambiental (MARTINS et al, 2001).

2.2 AGRICULTURA ORGÂNICA

Agricultura orgânica é um conjunto de processos de produção agrícola que parte do pressuposto básico de que a fertilidade é função direta da matéria orgânica contida no solo. A ação de microorganismos presentes nos compostos biodegradáveis existentes ou colocados no solo possibilita o suprimento de elementos minerais e químicos necessários ao desenvolvimento dos vegetais cultivados. Complementarmente, a existência de uma abundante fauna microbiana diminui os desequilíbrios resultantes da intervenção humana na natureza. Alimentação adequada e ambiente saudável resultam em plantas mais vigorosas e mais resistentes a pragas e doenças (ORMOND et al, 2002).

A agricultura orgânica tem por princípio estabelecer sistemas de produção com base em tecnologias de processos, ou seja, um conjunto de procedimentos que envolvam a planta, o solo e as condições climáticas, produzindo um alimento sadio e com suas características e sabor originais, que atenda às expectativas do consumidor (PENTEADO, 2000).

Em outras palavras, sistemas de produção que se limitam a evitar, ou excluir amplamente, o uso de fertilizantes sintéticos, pesticidas, reguladores de crescimento e aditivos para a alimentação animal, na medida em que esta é a demanda do mercado a ser atendido (ASSIS; ROMEIRO, 2002).

A agricultura orgânica tem diversas vantagens com relação ao plantio convencional, tais como: preservação de solos produtivos, com potencial para melhorá-los, preservação e recuperação dos recursos hídricos, proteção da biodiversidade, redução no uso de combustíveis fósseis e outros. Para desenvolver a agricultura sustentável há necessidade de se reduzir ao máximo a erosão do solo, reduzir a dependência ou eliminá-la, em termos de fertilizantes químicos, pesticidas e outros insumos modernos, reduzir o uso de combustível fóssil e reduzir as perdas dos produtos agrícolas. (SATURNINO, 1997; SEGUY; BOUZINAC; MARONEZZI. 1999)

De acordo com a Lei Federal no 10.831, de 23 de dezembro de 2003, considerase sistema orgânico de produção agropecuária todo aquele em que são adotadas técnicas específicas, mediante a otimização do uso dos recursos naturais e socioeconômicos disponíveis e o respeito à integridade cultural das

comunidades rurais, tendo por objetivo a sustentabilidade ecológica e econômica, a maximização dos benefícios sociais, a minimização da dependência de energia não renovável, empregando, sempre que possível, métodos culturais, biológicos e mecânicos, em contraposição ao uso de materiais sintéticos, a eliminação do uso de organismos geneticamente modificados e radiações ionizantes, em qualquer fase do processo de produção, processamento, armazenamento, distribuição e comercialização, e a proteção do meio ambiente (BRASIL, 2003).

De acordo com Torjusen et al (2001) a agricultura orgânica tem sido praticada desde a década de 20, inicialmente como uma resposta ao processo de industrialização da agricultura, marcado pela tecnificação. De acordo com Coelho (2001), o sistema de cultivo orgânico no Brasil, em bases tecnológicas, teve início no final da década de setenta, em pequena escala e começou a se expandir após a criação do Instituto Biodinâmico de Desenvolvimento Rural (IBD) em 1990, sendo que de 1994 até 2000, as vendas totais de produtos orgânicos cresceram mais de 16 vezes.

A busca da qualidade alimentar está se tornando uma das principais preocupações dos consumidores conscientes. Atualmente, as motivações para o consumo de alimentos orgânicos variam em função do país, da cultura e dos produtos que se analisa (DAROLT, 2001).

De acordo com Yussefi (2003), atualmente no mundo cerca de 23 milhões de hectares são manejados organicamente em aproximadamente 400.000 propriedades orgânicas, o que representa pouco menos de 1% do total das terras agrícolas do mundo. A maior parte destas áreas está localizada na Austrália (10,5 milhões de hectares), Argentina (3,2 milhões de hectares) e Itália (cerca de 1,2 milhão de hectares). Conforme mostra a fig. 25 a Oceania tem aproximadamente 46% da terra orgânica do mundo, seguida pela Europa (23%) e América Latina (21%). É importante destacar que os países que têm o maior percentual de área sob manejo orgânico em relação à área total destinada à agricultura, computam a área de pastagem. Assim, por exemplo, em países como a Austrália e Argentina mais de 90% da área de produção orgânica correspondem a áreas de pastagem. O mesmo acontece nos países da Europa: na Áustria 80% da área orgânica refere-se à pastagem; na Holanda, 56%; na Itália, 47%, e no Reino Unido 79%.




Figura 25 – Área plantada de alimentos orgânicos e hectares. Fonte: YUSSEFI, 2003

Segundo Archanjo et al (2001), o crescimento do consumo não está diretamente relacionado com o valor nutricional dos alimentos, mas aos diversos significados que lhes são atribuídos pelos consumidores. Tais significados variam desde a busca por uma alimentação mais saudável, de melhor qualidade e sabor, até a preocupação ecológica de preservar o meio ambiente.

Para Hall, Baker e Franco (1989), o crescimento do consumo é atribuído a maior preocupação com a saúde familiar e também com o meio ambiente. De acordo com Assis (1993); Junqueira e Luengo (2000), o consumo de produtos da agricultura orgânica tem se caracterizado como um segmento diferenciado de mercado, no qual a segurança alimentar, aliado ao não uso de agrotóxicos é decisiva na opção de consumo.

Observando países como Alemanha e Inglaterra (WOODWARD; MEIER-PLOEGER, 1999), Austrália (PEARSON,1999), Estados Unidos (HENDERSON, 1999), França (SYLVANDER, 1998), Dinamarca e Noruega (DUBGAARD; HOLST, 1994; SOGN; PERSILLET; SYLVANDER, 2002), Polônia (ZAKOWSKA-BIEMANS, 2002) e Costa Rica (AGUIRRE; TUMULTY, 2002) percebe-se que existe uma tendência de o consumidor orgânico privilegiar, em primeiro lugar,

aspectos relacionados à *saúde* e sua ligação com os alimentos, em seguida ao *meio ambiente* e, por último, à questão do *sabor e frescor* dos alimentos orgânicos.

No Brasil, a principal motivação para compra de alimentos orgânicos também está ligada à preocupação com a saúde. Uma pesquisa encomendada pelo SEBRAE-PR e realizada pelo DATACENSO (2002) nos estados do Sul e Sudeste do Brasil mostrou que os principais motivos que levaram a consumir os alimentos orgânicos foram: em 1º lugar e 2º lugar, *faz bem a saúde/saudável*; em 3º lugar, *sem agrotóxicos*, em 4º lugar, *mais sabor*; e em 5º lugar, *natural e qualidade do produto*.

A expansão do comércio e consumo de produtos da agricultura orgânica tem limitações, tanto em nível de cultivo como de canais de comercialização. Os aspectos de baixa qualidade visual, preços sobre valorizados em relação aos convencionais, aliado ao fato da irregularidade de sua oferta, são grandes empecilhos a este segmento de mercado (ASSIS, 1993; VÍGLIO, 1996; JUNQUEIRA; LUENGO, 2000).

Em média, os produtos orgânicos *in natura* têm um sobre-preço de 40%, quando comparados aos produtos convencionais, porém, alguns produtos, como o trigo e o açúcar, chegam a custar (venda ao atacado), respectivamente, 200% e 170% acima do convencional (SOUZA; ALCÂNTARA, 2003).

Os produtos comercializados *in natura*, sobretudo as hortaliças, são os mais expressivos na produção orgânica nacional (ORMOND et al, 2002). Entre os produtos orgânicos destinados à exportação, merecem destaque à soja, café, cacau, açúcar mascavo, erva-mate, suco de laranja, mel, frutas secas, castanhas de caju, óleos essenciais, óleo de palma, frutas tropicais, palmito, guaraná e arroz.

De acordo com a AAO (Associação de Agricultura Orgânica) a produção brasileira de alimentos orgânicos concentra-se nos estados de São Paulo, Minas Gerais, Espírito Santo, Paraná e Rio Grande do Sul. No Brasil, apesar dos consumidores (62,7%) considerarem os produtos orgânicos mais caros do que os convencionais, o mercado é crescente e firme (BELTRÃO, 2003).

Os pequenos produtores por necessitarem de diversificação da produção, têm maior facilidade de adaptação aos princípios da agricultura orgânica, que segundo Harkaly (1999), são: diversificação, integração da propriedade, indução do equilíbrio ecológico, reciclagem de nutrientes, insumos caseiros, conservação do solo e o controle de pragas e doenças na maneira ecológica.

Para Campanhola e Valarini (2001), a agricultura orgânica para o pequeno produtor, oferece diversas vantagens, destacando-se: viabilidade em pequenas áreas favorece a diversificação produtiva no estabelecimento, gera mais empregos do que a convencional tem menor dependência dos insumos externos, elimina o uso de agrotóxicos, os produtos são mais valorizados e a adoção é mais fácil. Como problemas deste tipo de exploração agrícola tem-se: produção em pequena escala, escassez de pesquisas, deficiência ou falta de assistência técnica, dificuldades ao acesso ao crédito, elevados custos da certificação e a possibilidade de alguns impactos negativos ao ambiente, devido ao uso inadequado de alguns insumos, em especial o esterco.

De acordo com Souza (2003), quanto menos direta for à relação entre produtores e consumidores, maior será a necessidade de instrumentos formais de certificação da produção. Isso ocorre devido à maior distância entre os agentes e à dificuldade para a comprovação das características inerentes a esses produtos. Para Campanhola e Valarini (2001) a certificação fornece maior credibilidade aos produtos e tranquiliza os consumidores.

O processo de certificação de alimentos orgânicos visa assegurar aos consumidores a oferta de um alimento que foi produzido segundo os princípios da agricultura orgânica (BRASIL, 2004), capaz de assegurar qualidade do ambiente natural, qualidade nutricional e biológica dos alimentos e qualidade de vida para quem os produz e para quem os consome.

Souza (2003), afirmou que "A regulamentação é necessária não só para manter os padrões éticos do movimento orgânico como também para fortalecer a confiança do consumidor nesses produtos".

Desde 29 de dezembro de 2007, a agricultura orgânica no Brasil passou a ter critérios para o funcionamento de todo o seu sistema de produção, desde a propriedade rural ao ponto de venda. Estas regras estão expressas no Decreto nº 6323 publicado nesta data, no Diário Oficial da União. A legislação, que regulamenta a Lei nº 10.831/2003, inclui a produção, armazenamento, rotulagem, transporte, certificação, comercialização e fiscalização dos produtos (BRASIL, 2007).

2.3 AGRICULTURA HIDROPÔNICA

A hidroponia, ou seja, o cultivo de plantas em meio líquido, é uma técnica bastante antiga. Resh (1997) cita o caso dos jardins suspensos da Babilônia e os jardins flutuantes dos Astecas e da China, como exemplos.

A hidroponia é caracterizada como o cultivo de plantas em meio líquido, associado ou não a substratos não orgânicos naturais, ao qual é adicionada uma solução nutritiva necessária ao desenvolvimento da cultura (CASTELLANE; ARAÚJO, 1994).

Na hidroponia as soluções nutritivas provenientes de fertilizantes químicos industriais, de custo elevado, determinam a exclusão da utilização da técnica por parte dos produtores, principalmente dos que utilizam sistemas que visam o desenvolvimento agrícola sustentável (NICOLA, 2002).

Este tipo de cultivo vem se tornando uma alternativa bastante interessante em relação ao cultivo tradicional feito no solo, podendo ser utilizada em regiões onde há pouca disponibilidade de terras agricultáveis e em locais onde ocorreu uso excessivo do solo, problema freqüente em solos sob estufa plástica, porém vem se destacando pela alta produtividade e qualidade dos produtos obtidos (SANTOS et al, 2000).

Um dos sistemas hidropônicos mais utilizados é o NFT (Nutrient Film Technique), onde a absorção de nutrientes pela planta é através de um filme de água que passa por suas raízes (CASTELLANE; ARAÚJO, 1995; MARTINEZ, 2002). Porém, este tipo de sistema apresenta como desvantagem um alto consumo de energia, aumentando assim os custos de produção.

O cultivo em solução nutritiva é utilizado tanto em estudos sobre nutrição de plantas quanto na área comercial. A solução nutritiva é um dos pontos mais importantes em todo o sistema de cultivo hidropônico, no qual, seu mau uso poderá acarretar em sérios prejuízos para as plantas (MARTINEZ, 2002).

Esse sistema de cultivo tem sido utilizado com sucesso em plantios de hortaliças como, por exemplo, à alface, pois possibilita elevar a produtividade, aumentar o número de colheitas por ano, prescindido da rotação da cultura, reduzir os gastos com defensivos agrícolas, obter um produto comercial de melhor aspecto, além de ocupar um menor espaço físico para o cultivo (MOREIRA; FONTES;

CAMARGO, 2001). A hortalíça fica protegida de geadas, chuvas intensas, granizo e ventos fortes, com ganho na produtividade e qualidade, fatores que contribuem para o fornecimento constante aos pontos de venda. Contudo, é necessário acompanhamento técnico especializado, para que se tenha uma solução nutritiva balanceada que forneça nutrição adequada às plantas e evite, dentre outros problemas, o acúmulo excessivo de nitrato (FERNANDES; MARTINEZ; PEREIRA, 2002). Além disso, esse sistema exige um investimento inicial maior e gasto com energia elétrica.

O nitrato é indispensável ao crescimento de vegetais e por isso os fertilizantes nitrogenados têm sido usados em doses cada vez maiores para aumentar a produção (RUSCHEL, 1998). Além de ser originado do fertilizante, o nitrato presente nos vegetais pode ser formado no substrato, pela mineralização ou nitrificação (MAYNARD et al., 1976).

Quando o nitrato (NO_3^-) é absorvido em grande quantidade, a planta não consegue metabolizá-lo totalmente, o que provoca o acúmulo nos tecidos. Quando ingerido, no trato digestivo pode ser reduzido a nitrito (NO_2^-), que entrando na corrente sanguínea oxida o ferro ($\text{Fe}^{++} \Rightarrow \text{Fe}^{+++}$) da hemoglobina, produzindo a metahemoglobina. Esta forma de hemoglobina é incapaz de transportar o O_2 para a respiração normal das células dos tecidos causando a chamada metahemoglobinemia. Outro problema é que parte do nitrito pode acabar combinando com as aminas formando nitrosaminas, as quais são cancerígenas e mutagênicas (OHSE, 1999). Trabalhos mais recentes mostram que o nitrato pode ser benéfico à saúde em doses comumente ingeridas nos alimentos (GOLDEN; LEIFERT, 1999; BOINK; SPEIJERS, 2001; ARCHER, 2002). Portanto, há controvérsias a respeito do efeito do nitrato na saúde humana.

Apesar de alguns cientistas defenderem que os teores de nitrato em plantas cultivadas no sistema convencional e hidropônico, ainda permanecem dentro do limite permitido pela Organização Mundial de Saúde (OMS), é preciso orientação mais adequada aos produtores sobre o manejo do nitrogênio, sobretudo, em sistemas hidropônicos, além de informação aos consumidores de como os alimentos são produzidos em cada sistema, permitindo uma escolha de produtos mais saudáveis (DAROLT, 2003).

Os custos iniciais elevados na implementação, a necessidade de prevenção contra falta de energia elétrica, conhecimentos técnicos e de fisiologia

vegetal indispensáveis, requerimento de acompanhamento freqüente do funcionamento do sistema e da solução nutritiva, além de uma planta doente poder contaminar toda a produção, são algumas desvantagens apontadas por Penningsfeld e Kurzmann (1983), Hamerschmidt (1997) e Carmo Jr. (2002).

Atualmente, o desenvolvimento de processos de produção agrícola alternativos aos tradicionais têm merecido a atenção de pesquisadores, no sentido de minimizar a intensa utilização de fertilizantes e defensivos sintéticos (agrotóxicos), e reduzir as influências ambientais. A agricultura orgânica e a hidroponia são técnicas de produção agrícola alternativas, mas, enquanto as motivações para a agricultura orgânica se remetem às tradições culturais mais integradas com a natureza, as motivações para a hidroponia são de outra ordem: ausência de solo e/ou clima adequados à agricultura (GRAF; FIGUEIREDO, 1999).

Estudos que comparam alimentos obtidos pelos sistemas de cultivo convencional, orgânico e hidropônico em relação ao seu valor nutricional, qualidade sensorial e segurança alimentar têm sido realizados, porém, há poucos estudos com controle efetivo capazes de conclusões válidas cientificamente. Em relação à *qualidade nutricional*, de forma geral, para a maioria dos nutrientes ainda não existe um consenso sobre a superioridade dos orgânicos. Com exceção do conteúdo de nitrato, matéria seca e vitamina C, não há evidências fortes de que alimentos orgânicos, convencionais e hidropônicos diferem em suas concentrações de nutrientes (LECLERC *et al.*, 1991; MIYAZAWA; KHAUTOUNIAN; ODENATH-PENHA., 2001; BOURN; PRESCOT, 2002; AFSSA, 2003).

Há um mercado potencial para os produtos orgânicos, uma vez que existe resistência de uma parcela da população em manter a aquisição e consumo de alguns alimentos convencionais, como tomate, morango e batata, cujo cultivo reconhecidamente envolve o emprego de substanciais quantidades de adubos sintéticos e pesticidas (PENTEADO, 2000).

No entanto, existem controvérsias sobre os alimentos orgânicos, principalmente, quando são classificados como mais nutritivos e seguros (PASCHOAL, 1994) devido à escassez de dados científicos que assegurem tais vantagens em relação ao alimento convencional.

3 OBJETIVOS

3.1 OBJETIVO GERAL

Verificar através das redes neurais artificiais a existência de diferenças entre hortícolas obtidas pelos sistemas de cultivo convencional, orgânico e hidropônico em relação à composição centesimal, açúcares e minerais.

3.2 OBJETIVOS ESPECÍFICOS

- i. Desenvolver a melhor Rede Neural Artificial para a classificação de hortícolas quanto ao seu cultivo.
- ii. Validar a confiabilidades dos resultados com a rede obtida.

4 MATERIAL E MÉTODOS

4.1 BANCO DE DADOS

Para este estudo foi utilizado um banco de dados cedido pela professora Doutora Sônia Cachoeira Stertz. Deste banco que contém informações de análises físico-químicos de hortícolas/culturas cultivadas em três sistemas: convencional, orgânico e hidropônico, foram retirados dados para o presente estudo. São eles: para a alface crespa, cv. Verônica (*Lactuca sativa* L., Compositaceae, morango, cv. Tundlas e Camarosa (*Fragaria ananassa* Duch, Rosaceae), tomate cereja, cv. Cindy (*Lycopersicum esculentum* var. *cerasiforme* (Duval) A. Gray., Solanaceae. Para cada cultura foram coletadas as mesmas variedades nos diferentes sistemas.

Foram coletadas com rastreabilidade 46 amostras sendo 18 amostras de culturas orgânicas (de sistemas certificados ou em conversão), 19 amostras de culturas convencionais e 9 amostras de culturas hidropônicas. A razão da menor quantidade de variedades e amostras hidropônicas é porque existe um menor número de produtores que dão preferência para culturas mais facilmente comercializáveis e com retorno econômico mais significativo, como é o caso do agrião, da alface, da rúcula, do tomate cereja e salada (STERTZ, 2004).

A rastreabilidade permite identificar os fornecedores que abastecem o comércio varejista ou atacadista, sendo considerados certificação, variedade, data e condições de colheita, condições da cadeia de distribuição, armazenamento no varejo, etc. Deste modo, algumas variáveis podem ser controladas, diminuindo as diferenças na composição nutricional do produto adquirido no varejo (BOURN; PRESCOTT, 2002).

As amostras empregadas foram analisadas quanto à composição centesimal: proteínas, lipídeos, cinzas, fibra alimentar, energia total metabolizável, carboidratos. Os açúcares, glicose, sacarose, maltose e frutose. Em relação aos minerais, foram determinados os teores de alumínio (Al), cálcio (Ca), cádmio (Cd), chumbo (Pb), cobalto (Co), cobre (Cu), ferro (Fe), fósforo (P), magnésio (Mg),

manganês (Mn), mercúrio (Hg), potássio (K), sódio (Na), selênio (Se) e zinco (Zn). Foram determinados também os teores de nitrato e nitrito (STERTZ, 2004).

Com exceção de energia total cuja unidade é kcal as outras análises da composição centesimal encontram-se em gramas. Os açúcares também foram apresentados em gramas. Cobalto, selênio, cádmio, mercúrio e chumbo estão demonstrados em µg os demais minerais estão em mg. Todos os resultados encontram-se em base úmida.

4.2 APLICATIVO COMPUTACIONAL

O hardware utilizado consistiu de um microcomputador PC, com processador Pentium III de 900 Mhz e 256 RAM. Foi utilizado o programa STATISTICA 7.1 (2006) adquirido com recursos da Fundação Araucária (PR). O módulo de redes neurais apresenta os seguintes recursos:

- aquisição de dados;
- pré e pós- processamento;
- perceptrons de multicamadas (MLP);
- funções de base radial (RBF);
- ferramentas estatísticas para avaliação e validação;
- mapas auto-ajustáveis (SOM) ou algoritmo de Kohonen para aprendizagem não supervisionada;
- solução de problemas de classificação;
- técnicas de ensemble (maquina de comitê) para melhorar o desempenho das redes;
- análise de componentes principais.

4.3 DESENVOLVIMENTO DAS REDES NEURAIIS: MANUAL DE OPERAÇÃO

No programa Statistica 7.1, no módulo de redes neurais "Neural Networks" foram criadas tabelas para cada tipo de hortaliça, esta tabela continha todas as análises físico-químicas, a soma de todos os minerais, soma de açúcares, soma nitrato e nitrito. Nesta tabela foi acrescentada uma coluna identificando as amostras quanto ao seu tipo de cultivo: convencional, orgânico e hidropônico e uma outra coluna que identificava se os dados da amostras seriam usados no treinamento ou validação da rede. A tabela encontra-se no ANEXO 3.

Na caixa de diálogo inicial do módulo (Fig. 26), o primeiro passo é definir o tipo de problema; neste caso será utilizada a classificação. Em problemas de classificação, a finalidade da rede é atribuir a cada caso um número de classes, ou mais genericamente, estimar a probabilidade do caso pertencer a uma cada classe. Os problemas de classificação podem ser resolvidos utilizando vários tipos de redes como MLP (*Multi Layer Perceptron*, Perceptron de Multi Camadas); RBF (*Radial Basics Function* ou Função de Base Radial); PNN (Probabilistic Neural Network, Probabilidade de Redes Neurais); SOFM (*Self Organizing Feature Map* ou Mapa auto-organizável); Linear e *Clustering Network* (Redes de conjuntos).

O próximo passo é definir qual o tipo de análise. Para isto pode ser utilizado tanto o *Intelligent Problem Solver* (Resolução Inteligente de Problemas), onde se pode escolher mais de um tipo de rede ou o *Custom Network Designer* (CND - Projetista de Rede Customizada), onde se pode especificar o tipo de rede, criando uma rede neural individual. Foi selecionado o CND, pois será utilizada uma rede individual (Fig. 26).

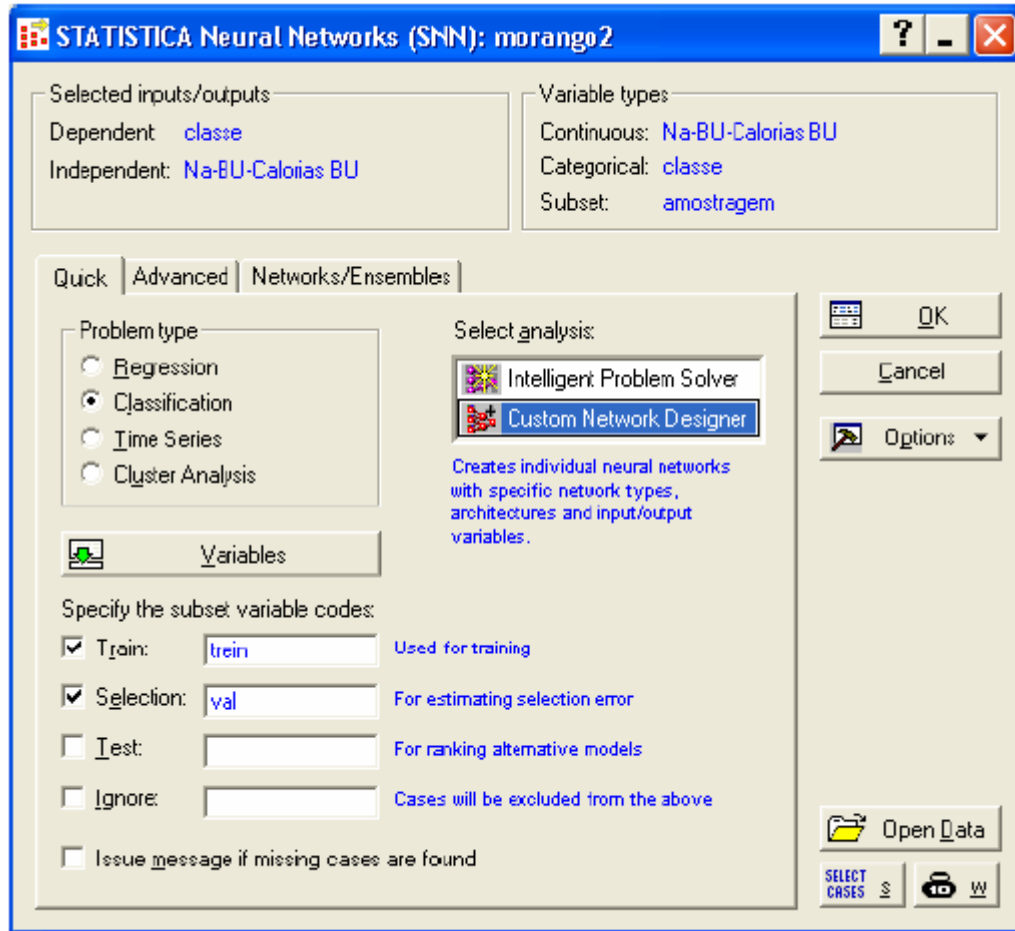


Figura 26 – Caixa de Diálogo inicial do Statística - Módulo de Redes Neurais

Após a seleção do CND, seleciona-se quais serão as variáveis contínuas de entrada (*Continuous inputs*), as variáveis qualitativas de saída (*Categorical Outputs*), que são os grupos ou classes que se espera classificar, por exemplo, os tipos de cultivo (convencional, orgânico e hidropônico) e, por último, a variável de subgrupos (*subset*), utilizada para definir os subgrupos que serão empregados no treinamento, validação e teste etc. da rede (Fig. 27).

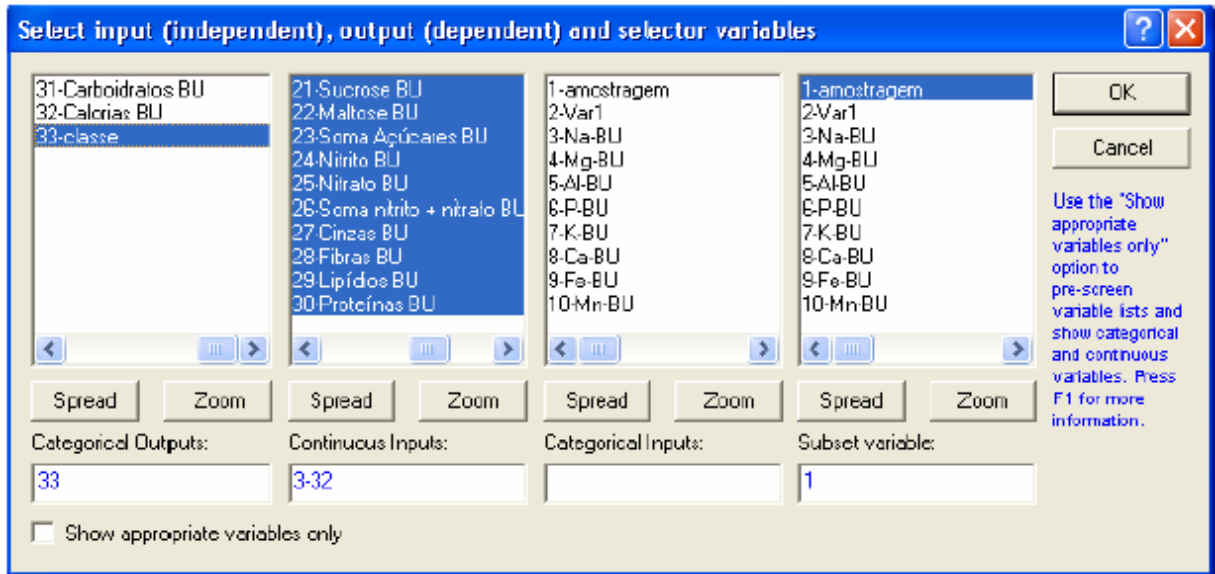


Figura 27 – Caixa de diálogo para seleção das variáveis

Quando se utiliza subset variável, é necessário especificar o código da variável, isto é, qual subgrupo será utilizado para o treinamento e qual será utilizado para validação e teste (Fig. 28).

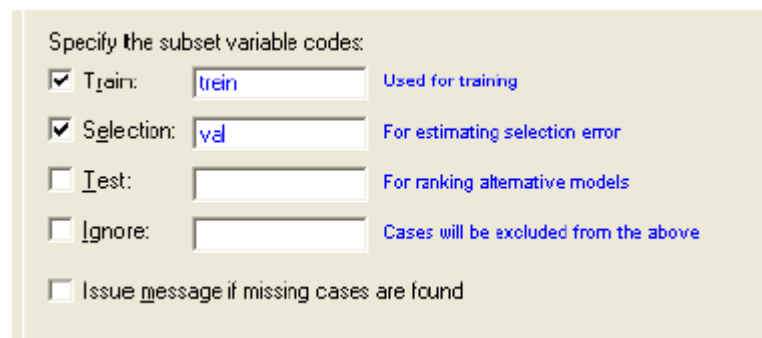


Figura 28 – Especificação dos códigos das variáveis subset

Depois de definido o tipo de problema, as variáveis e os tipos de análise, clica-se OK para continuar, então define-se o tipo de rede (Fig. 29). Para este estudo foi utilizada uma rede do tipo MLP, que permite a solução de problemas onde as classes são não-linearmente separáveis, que vem sendo muito utilizada para tarefas como classificação de padrões, controle e processamento de sinais.

Nas redes MLP pode-se especificar o número de camadas escondidas e o número de neurônios nestas camadas, modelando assim a complexidade da rede.

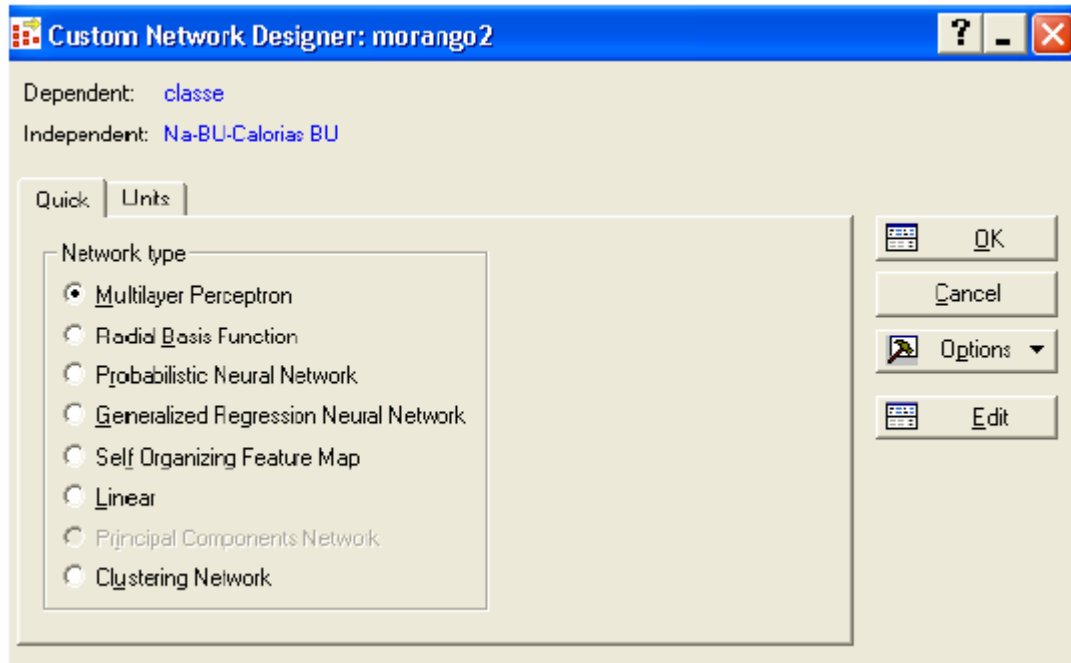


Figura 29 – Caixa de diálogo para escolha da rede

Nesta mesma caixa de diálogo (Fig. 30), na aba *Units* (unidades) deve-se escolher o número de camadas ocultas e a quantidade de neurônios em cada uma dessas camadas. Também se seleciona a função de erro da classificação. A função de erro da classificação é utilizada para a interpretação da saída; aplicável aos problemas com variáveis de saída qualitativas.

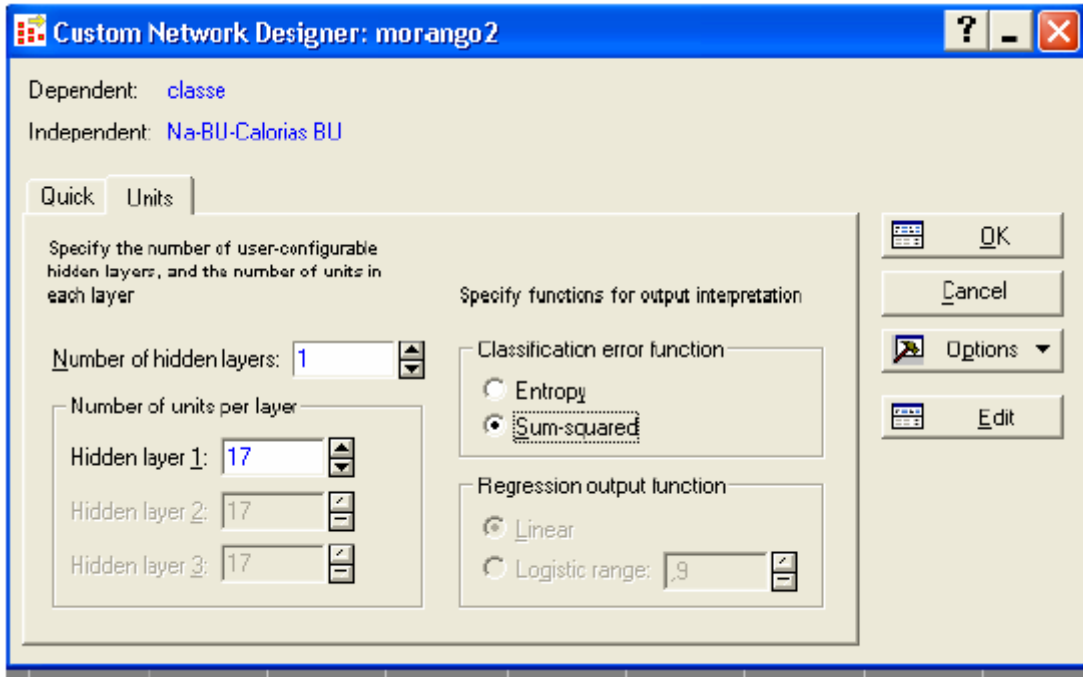


Figura 30 – Caixa de diálogo para seleção da quantidade de camadas escondidas, neurônios nas camadas escondidas e função do erro de classificação

Na caixa de diálogo seguinte (Fig. 31), na aba *quick*, define-se o algoritmo de treinamento que será usado na rede, a quantidade de épocas, que é a quantidade de iterações, e a taxa de aprendizagem de cada fase. O treinamento pode ser feito em uma ou duas fases. Neste estudo foram utilizadas duas fases.

1ª fase: definiu-se o algoritmo *backpropagation* (retropropagação), um dos métodos de aprendizagem mais aplicado atualmente. Ele funciona da seguinte maneira: primeiramente apresenta-se um padrão à camada de entrada da rede. Esse padrão é processado camada por camada até que a camada de saída forneça a resposta processada. Essa resposta é comparada com a resposta desejada e se estiver errada, o erro é calculado. Ele é retropropagado e o processamento é realizado novamente, até que se obtenha um erro mínimo.

Foram utilizadas 100 épocas (número de iterações) e uma taxa de aprendizagem de 0,01.

2ª fase: aplica-se a fase dois do procedimento bifásico do treinamento o *Conjugate gradient descent* (CG).

O gradiente descendente conjugado é um método avançado de treinamento para o multilayer perceptrons (MLP). Esse treinamento geralmente

produz resultados significativamente melhores que os de *backpropagation*, e pode ser usado em situações análogas.

O gradiente descendente conjugado é um algoritmo melhorado: o *backpropagation* ajusta os pesos da rede após cada caso, enquanto o gradiente descendente conjugado utiliza a média gradiente do erro da superfície de todos os casos antes de atualizar no final da época. Não é necessário selecionar taxas de aprendizagem para o método do gradiente descendente conjugado. Portanto ele pode ser muito mais simples de ser utilizado do que o *backpropagation* (STATISTICA 7.1, 2006).

Definiu-se 500 épocas (número de iterações) para fase dois e não há taxa de aprendizado.

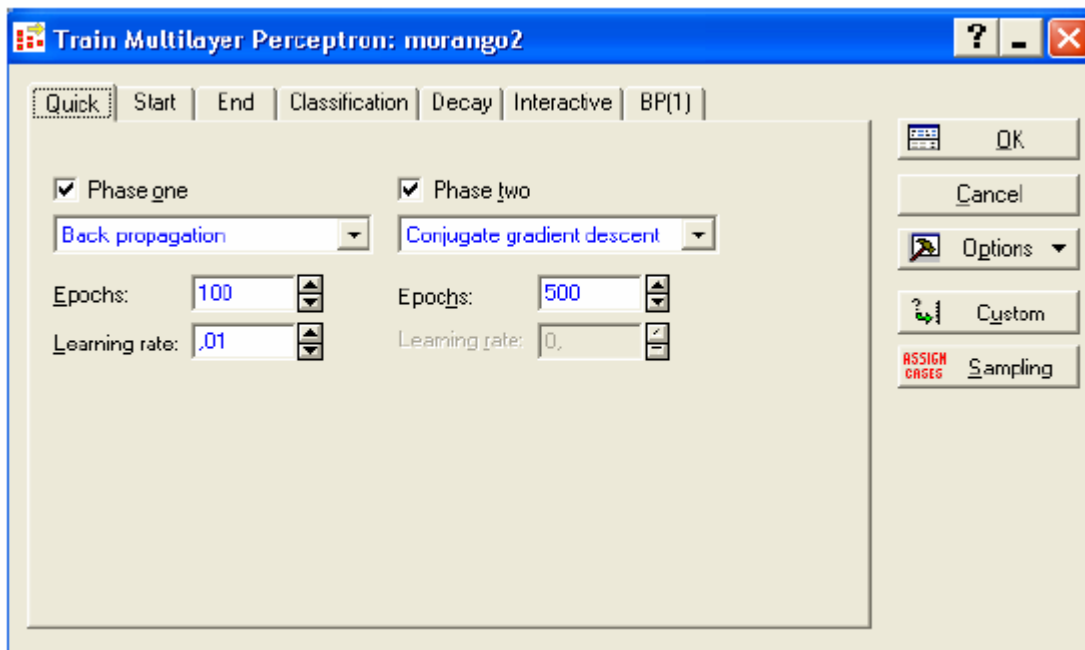


Figura 31 – Caixa de diálogo de parâmetros de treinamento

Clica-se em OK para se ter os resultados da classificação (Fig. 32 e 33).

A caixa de diálogo dos resultados (Fig. 32) é usada para gerar as saídas, incluindo estatísticas descritivas, previsões, resíduos, gráficos, superfícies de resposta e outros formulários da saída, executando modelos.

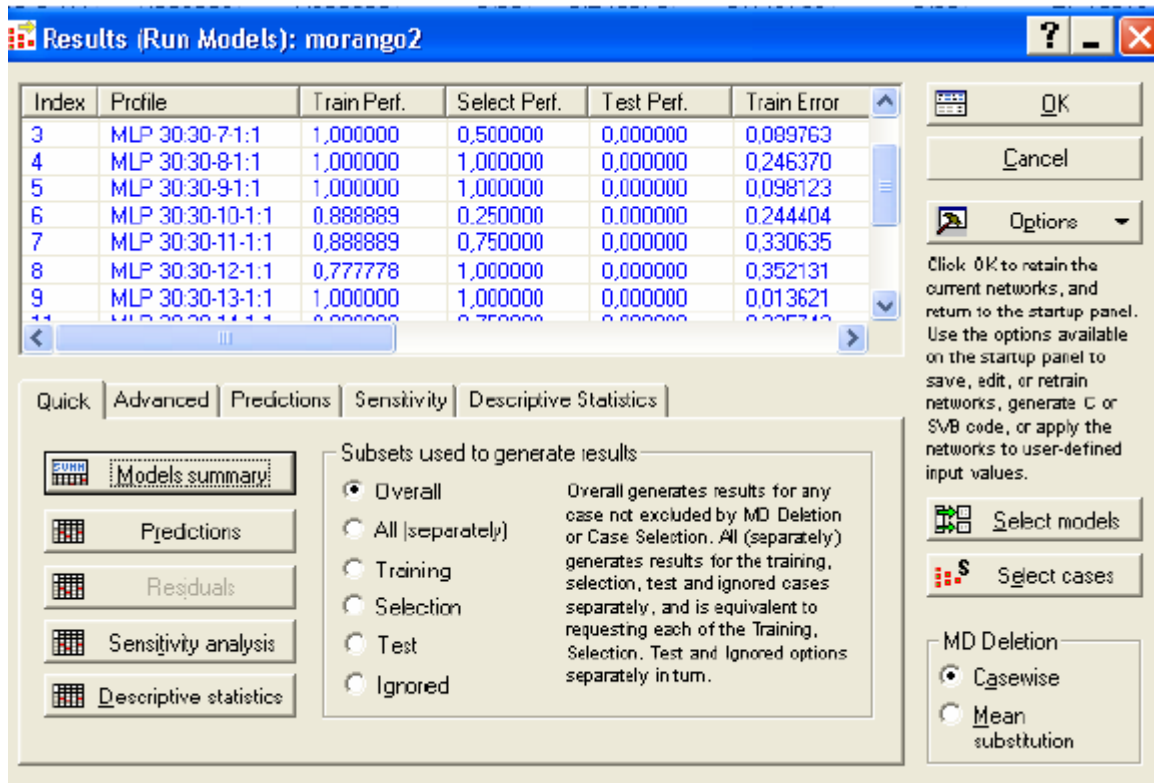


Figura 32 – Caixa de diálogo dos resultados

Na coluna *Profile* (Fig. 32), tem-se a topologia da rede. Assim, MLP 30:30-7-1:1, onde MLP é a abreviatura de *Multi Layer Perceptron*, que foi o tipo de rede utilizado, os números significam, respectivamente, o número de variáveis de entrada, o número de neurônios de entrada, a quantidade de neurônios na camada intermediária, o número de neurônios de saída e o número de variáveis de saída.

O *Train. Perf.*; *Select Perf.* e *Test Perf.* (Fig. 32) referem-se à medida de desempenho. É a proporção de casos classificados corretamente no treinamento, validação e teste respectivamente.

Train. Error; *Select Error* e *Test Error* (Fig. 32 e 33) referem-se ao erro da rede nos subconjuntos usados durante o treinamento, validação e teste, respectivamente.

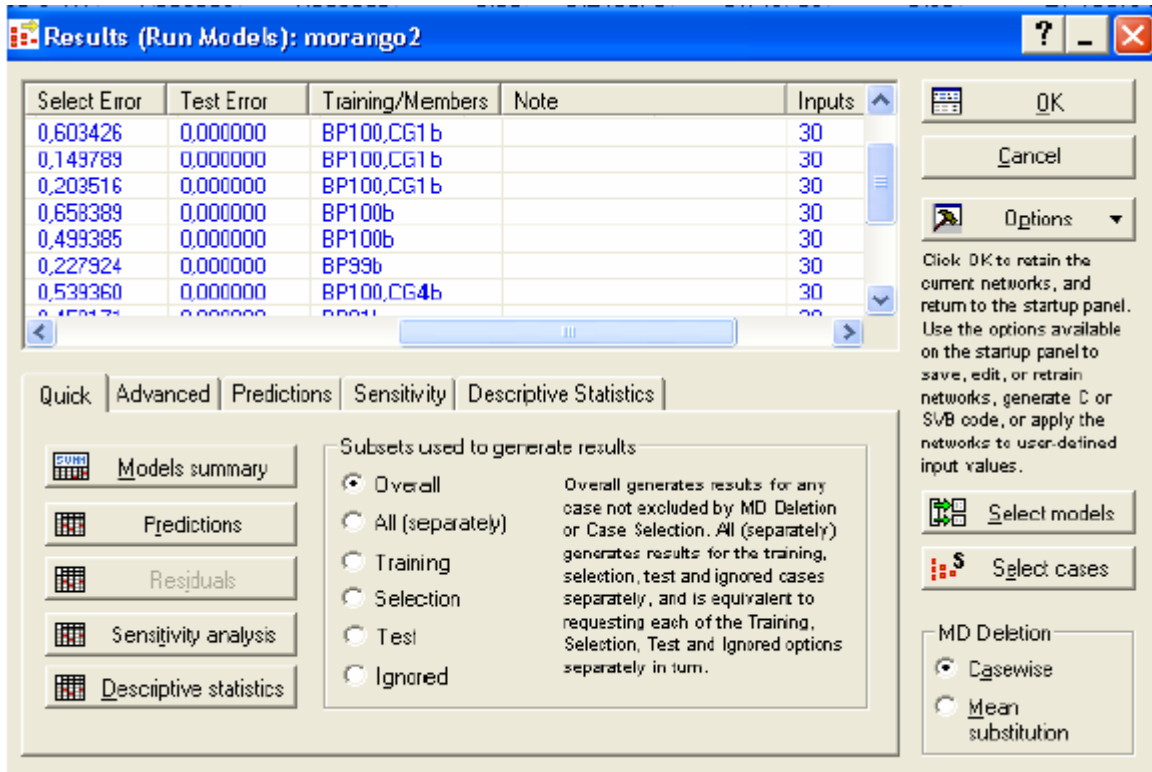


Figura 33 – Continuação da caixa de diálogo de resultados

A coluna *Training/Members* (Fig. 33) apresenta um breve resumo dos algoritmos usados no treinamento para aperfeiçoar a rede neural. Contém um número de códigos, que são seguidos pelo número de épocas que funcionou o algoritmo, e um código terminal que indica como a rede final foi selecionada. Por exemplo, o código: BP200 CG102b, que significa "duzentas épocas da retropropagação, seguidas por cento e duas épocas do gradiente conjugado, e que a melhor rede durante esse funcionamento foi selecionada (para o " b" leia o " o menor erro" da seleção)".

Os códigos são:

BP - *Backpropagation*;

CG - Gradiente conjugado;

"b" - A melhor rede (a rede com o menor erro da seleção no procedimento foi restaurada).

"s" - Condição de parada (o processo de treinamento foi interrompido antes que o número total de épocas decorresse; uma condição da parada foi satisfeita).

"c" - Convergência (o algoritmo interrompido cedo porque convergiu; isto é, foi alcançado e detectado um mínimo local ou global).

Na aba *Advanced* (Fig. 33), tem-se a geração especializada dos resultados, onde se pode produzir gráficos e ilustrações das redes neurais. A aba *Predictions* (Fig. 33) é somente para problemas de classificação e regressão. Seleciona-se o *Confidence levels*, que indica os níveis de confiança da rede nas várias classes possíveis, que são representadas pelos níveis da ativação dos neurônios de saída, que correspondem à variável de saída.

Na aba *Sensitivity* (Fig.33), avalia-se a sensibilidade das variáveis de entrada e sua importância. As relações abaixo de 1.0 são irrelevantes e essas variáveis podem ser desconsideradas (STATISTICA, 2006).

Na aba *Descriptive Statistics* (Fig. 33), pode-se gerar estatísticas totais do desempenho da classificação e uma matriz de confundimento. As estatísticas de classificação incluem, para cada classe:

Total: Número de casos dessa classe.

Correct: O número de casos classificados corretamente.

Wrong: Número de casos atribuídos erroneamente a uma outra classe.

Unknown: Número de casos que não poderiam ser classificados de forma correta.

Correct (%): A porcentagem dos casos classificados corretamente.

Wrong (%): A porcentagem dos casos classificados errado.

Unknown (%): A Porcentagem dos casos classificados como o desconhecido

Uma matriz de confundimento dá uma avaliação detalhada dos erros de classificação.

Estas etapas foram repetidas várias vezes para todas hortícolas alterando o número de neurônios da camada intermediária e as variáveis de entrada. A variável qualitativa de saída e a variável subset não foram alteradas. O erro da função de classificação, os algoritmos de aprendizagem nas duas fases, assim como a taxa de aprendizagem e a quantidade de épocas permaneceram as mesmas.

5 RESULTADOS E DISCUSSÃO

5.1 MORANGO

Para estudar a existência de diferenças entre morangos cultivados de forma convencional e orgânica foram utilizadas 7 amostras convencionais e 6 amostras orgânicas, onde 4 e 5 respectivamente foram selecionadas para o treinamento da rede e duas para a validação da mesma.

Foram testadas redes onde a quantidade de neurônios na camada escondida variou entre 5 e 15 quando se utilizou a composição centesimal, açúcares e minerais como variáveis de entrada e 5 e 10 neurônios quando foram utilizados Mg, Al, Fe, Mn, Co, Cu, Zn, Cd, frutose, sacarose, maltose, nitrato, lipídios, proteínas e carboidratos como variáveis de entrada.

Só considerou-se que a rede foi capaz de classificar o sistema de cultivo quando o resultado foi 100% de acerto, ou seja, os valores de *Train Perf.* (desempenho de treinamento) e *Select Perf.* (desempenho de validação) foram igual a 1; isso porque mesmo que se apenas uma amostra fosse classificada de forma errônea, como existem poucas amostras, isso resulta num erro superior a 5%.

Das redes testadas com 30 variáveis na camada de entrada, a arquitetura que classificou os morangos quanto ao cultivo foi a que utilizou 13 neurônios na camada oculta. Os modelos com 8 e 9 neurônios na camada oculta também classificaram os morangos, mas não foi possível repetibilidade. Como pode-se analisar na tabela 12 (redes assinaladas em amarelo).

Tabela 12 – Desempenho de treinamento, validação da classificação de morangos com 30 variáveis de entrada e variação entre 5 e 15 neurônios na camada intermediária

	Profile	Desempenho de treinamento	Desempenho da validação	Training
1	MLP 30:30-5-1:1	0,777778	0,500000	BP100b
2	MLP 30:30-6-1:1	1,000000	0,500000	BP100,CG1b
3	MLP 30:30-7-1:1	1,000000	0,500000	BP100,CG1b
4	MLP 30:30-8-1:1	1,000000	1,000000	BP100,CG1b
5	MLP 30:30-9-1:1	1,000000	1,000000	BP100,CG1b
6	MLP 30:30-10-1:1	0,888889	0,250000	BP100b
7	MLP 30:30-11-1:1	0,888889	0,750000	BP100b
8	MLP 30:30-12-1:1	0,777778	1,000000	BP99b
9	MLP 30:30-13-1:1	1,000000	1,000000	BP100,CG4b
10	MLP 30:30-14-1:1	0,888889	0,750000	BP81b
11	MLP 30:30-15-1:1	1,000000	0,500000	BP99b
12	MLP 30:30-9-1:1	0,888889	0,750000	BP100,CG2b
13	MLP 30:30-13-1:1	1,000000	1,000000	BP100,CG3b
14	MLP 30:30-8-1:1	0,888889	0,750000	BP100b
15	MLP 30:30-13-1:1	1,000000	1,000000	BP100,CG9b
16	MLP 30:30-13-1:1	1,000000	1,000000	BP100,CG1b

Como foi possível classificar o morango utilizando as trinta variáveis citadas anteriormente, tentou-se diminuir a quantidade de variáveis de entrada. Para isso, fez-se uma análise de sensibilidade. Essa análise é feita pelo programa na aba *sensitivity* na caixa de diálogo (Fig. 33) e é utilizada para saber quais as variáveis de entrada foram mais importantes na classificação. A análise de sensibilidade foi feita na rede que obteve melhor resultado de classificação ou seja a rede com 13 neurônios na camada intermediária (Tab. 13). Foram selecionadas as variáveis que ficaram "melhor posicionadas" no *rank* (assinaladas em azul) 3 e 4 vezes.

Tabela 13 – Análise de Sensibilidade das redes com 13 neurônios na camada intermediária

	Na-BU	Mg-BU	Al-BU	P-BU	K-BU	Ca-BU	Fe-BU	Mn-BU	Co-BU	Cu-BU
Rank.9	23,00000	12,00000	30,00000	24,00000	10,00000	6,00000	2,00000	14,00000	4,00000	8,00000
Rank.13	29,00000	22,00000	5,00000	19,00000	30,00000	20,00000	7,00000	14,00000	9,00000	15,00000
Rank.15	28,00000	9,00000	11,00000	6,00000	16,00000	24,00000	7,00000	13,00000	29,00000	10,00000
Rank.16	23,00000	4,000000	3,000000	12,00000	28,000000	26,00000	17,00000	19,00000	9,00000	30,00000
N	0	3	3	2	2	1	3	3	3	3

	Zn-BU	Se-BU	Cd-BU	Hg-BU	Pb-BU	Soma Minerais BU	Frutose BU	Glicose BU	Sacarose BU	Maltose BU
Rank.9	20,00000	3,00000	28,00000	27,00000	5,00000	29,00000	17,00000	25,00000	7,00000	19,00000
Rank.13	10,00000	17,00000	12,00000	27,00000	25,00000	28,00000	6,00000	23,00000	3,00000	13,00000
Rank.15	15,00000	25,00000	26,00000	17,00000	8,000000	4,00000	14,00000	18,00000	5,00000	20,00000
Rank.16	16,00000	10,00000	29,00000	7,000000	11,00000	1,000000	6,000000	15,00000	18,00000	25,00000
N	2	2	1	1	3	2	3	1	3	1

	Soma Açúcares BU	Nitrito BU	Nitrato BU	Soma nitrito+ nitrato BU	Cinzas BU	Fibras BU	Lipídios BU	Proteínas BU	Carboi dratos BU	Energia BU
Rank.9	22,00000	16,00000	1,00000	26,00000	21,00000	18,00000	15,00000	9,000000	11,00000	13,00000
Rank.13	16,00000	18,00000	1,00000	21,00000	26,00000	11,00000	8,00000	4,000000	2,00000	24,00000
Rank.15	27,00000	22,00000	1,000000	30,00000	2,00000	21,00000	3,000000	19,00000	12,00000	23,00000
Rank.16	8,000000	24,00000	5,000000	2,000000	14,00000	22,00000	13,00000	21,00000	27,00000	20,00000
N	1	0	4	1	2	1	4	2	3	1

N= número de vezes ranqueada entre 1 e 15

As variáveis de entrada que tiveram maior importância e que foram utilizadas nos novos testes (assinaladas em amarelo) foram: Mg, Al, Fe, Zn, Mn, Co, Cu, frutose, sacarose, nitrato, lipídios e carboidratos.

Nas redes que utilizaram 12 variáveis na camada de entrada foi possível classificação com 6 neurônios na camada intermediária. Quando utilizou-se 9 neurônios na camada intermediária não houve repetibilidade (redes assinaladas em amarelo, Tab. 14).

Tabela 14 – Desempenho de treinamento, validação da classificação de morangos com variação entre 4 e 8 neurônios na camada intermediária

	Profile	Desempenho de treinamento	Desempenho da validação	Training
1	MLP 12:12-4-1:1	0,888889	0,750000	BP100,CG7b
2	MLP 12:12-5-1:1	0,888889	0,750000	BP100,CG1b
3	MLP 12:12-6-1:1	1,000000	1,000000	BP100,CG2b
4	MLP 12:12-7-1:1	0,888889	0,250000	BP54b
5	MLP 12:12-8-1:1	0,555556	0,000000	BP0b
6	MLP 12:12-9-1:1	1,000000	1,000000	BP100,CG4b
7	MLP 12:12-6-1:1	1,000000	1,000000	BP100,CG6b
8	MLP 12:12-6-1:1	1,000000	1,000000	BP100,CG2b
9	MLP 12:12-9-1:1	0,777778	1,000000	BP13b
10	MLP 12:12-6-1:1	1,000000	1,000000	BP100b

Neste trabalho, Mg, Al, Fe, Cu, Zn, Mn e Co foram os elementos que demonstraram maior importância na classificação, ou seja, foram elementos que demonstraram níveis diferentes entre os cultivos.

Stertz (2004) obteve níveis mais altos de: K (79,67%), Mg (183,16%), Na (858,49%), P (63,06%), Co (399,53%), Cu (198,74%), Fe, (342,39%), Zn (134,13), Al (363,15%) e Pb (75,31%) nas amostras cultivada pelo sistema orgânico, quando comparado com o sistema convencional, compatíveis parcialmente (Mg, Al, Fe, Cu e Zn) com os dados obtidos no presente estudo. O sódio só foi detectado em apenas uma amostra de morango convencional podendo ser o provável motivo para o programa não ter destacado o Na na classificação.

Frutose e sacarose também estão entre as análises que foram importantes para diferenciar os morangos produzidos de forma orgânica e convencional, convergindo em parte com o trabalho de Cayuela et al (1997). Esses autores fizeram um estudo onde compararam morangos cultivados de forma convencional e orgânica quanto ao teor de acidez, açúcares, matéria seca, cinzas, vitamina C, Ca, Mg, Fe, Mn Zn e Cu. Obtiveram diferenças somente no teor de açúcares e matéria seca, sendo esses maiores nos morangos cultivados organicamente.

Quanto à composição centesimal, nitrato, lipídios e proteínas foram os que demonstraram maior importância na classificação. Estudos comprovam que alimentos produzidos de forma convencional apresentam maiores níveis de nitrato em comparação aos alimentos orgânicos. A aplicação de fertilizantes nitrogenados

no solo, prática comum na agricultura convencional, associada à irrigação, faz elevar os teores de nitrato nos alimentos (DAROLT, 2003).

5.2 ALFACE CRESPA

No item anterior, referente ao morango, foi apresentado o desenvolvimento passo-a-passo para melhor topologia de rede para classificação. A partir de agora, devido à similaridade de procedimentos, os resultados estão limitados às melhores redes escolhidas para classificação.

Foram coletadas amostras de alface dos três sistemas de cultivo. Na tentativa de classificar a alface crespa conforme seu cultivo e assim comprovar se existem diferenças entre esses sistemas, foram desenvolvidas várias redes. Primeiramente, foram testadas redes utilizando os dados dos três tipos de cultivos (convencional, orgânico e hidropônico), em seguida foram testadas redes comparando os cultivos convencional e orgânico, orgânico e hidropônico e por último foram comparados os sistemas convencional e hidropônico para ver se as redes desenvolvidas conseguiam fazer a classificação e identificar diferenças entre alfaves crespas cultivados nestes sistemas. Havia seis amostras de cada cultivo, dessas, 4 foram utilizadas para treinamento e 2 para validação. A quantidade de neurônio variou entre 5 e 15.

A seguir, foram refeitos os teste com a mesma comparação entre os cultivos, mas desta vez as variáveis de entrada utilizadas foram: todos os minerais, soma de açúcares, nitrato, nitrito, soma nitrato+nitrito e cinzas. E a quantidade de neurônios variou entre 5 e 10.

As primeiras redes testadas compararam os três tipos de cultivos simultaneamente e com 30 variáveis de entrada (todos os minerais, composição centesimal, nitrato, nitrito, frutose, glicose, sacarose, maltose, soma de minerais, soma de açúcares e soma nitrato+nitrito), Como não se observou classificação, foram feitas análises separadamente dos cultivos dois a dois: convencional X orgânico, onde com 10 neurônios na camada oculta, houve classificação; orgânico X hidropônico, neste caso foram necessários 13 neurônios e convencional X hidropônico, quando ocorreu classificação com 9 e 13 neurônios na camada

escondida. Mas, considerou-se que a melhor classificação aconteceu quando foram utilizados 9 neurônios na camada oculta por ser uma rede mais simples e que apresenta os mesmos resultados (PEREIRA, 1999).

Fez-se, então, uma análise de sensibilidade de cada rede que obteve classificação na comparação entre os cultivos (de 10, 13 e 9 neurônios) para selecionar quais variáveis havia sido mais importante para classificação (Tab. 15, 16 e 17, assinaladas em amarelo). Foram consideradas as variáveis mais importantes aquelas que tiveram $N \geq 3$ (N= Número de vezes que a variável foi ranqueada entre 1 e 15). Com as variáveis selecionadas foram feitos novos testes para saber se alguma rede seria capaz de classificar com uma menor quantidade de variáveis.

Tabela 15 – Análise de sensibilidade da comparação entre alface convencional e orgânica e com 10 neurônios na camada intermediária

	Na-BU	Mg-BU	Al-BU	P-BU	K-BU	Ca-BU	Fe-BU	Mn-BU	Co-BU	Cu-BU
Rank.6	25,00000	10,00000	29,00000	18,00000	8,00000	15,00000	11,00000	13,00000	2,00000	27,00000
Rank.13	7,00000	5,00000	15,00000	14,00000	3,00000	17,00000	26,00000	13,00000	29,00000	12,00000
Rank.14	12,00000	10,00000	13,00000	7,00000	26,00000	14,00000	3,00000	4,00000	2,00000	23,00000
Rank.15	4,00000	13,00000	12,00000	21,00000	23,00000	22,00000	26,00000	18,00000	29,00000	30,00000
N	3	4	3	2	2	2	2	3	2	1

	Zn-BU	Se-BU	Cd-BU	Hg-BU	Pb-BU	Soma Minerais BU	Frutose BU	Glicose BU	Sacarose BU	Maltose BU
Rank.6	28,00000	24,00000	23,00000	1,00000	9,00000	3,00000	21,00000	6,00000	26,00000	20,00000
Rank.13	11,00000	2,00000	19,00000	9,00000	1,00000	21,00000	27,00000	28,00000	30,00000	20,00000
Rank.14	9,00000	8,00000	28,00000	30,00000	1,00000	20,00000	18,00000	29,00000	11,00000	21,00000
Rank.15	27,00000	6,00000	19,00000	1,00000	25,00000	8,00000	10,00000	3,00000	28,00000	16,00000
N	2	3	0	3	3	2	1	2	1	0

	Soma Açúcares BU	Nitrito BU	Nitrato BU	Soma nitrito+ nitrato BU	Cinzas BU	Fibras BU	Lipídios BU	Proteínas BU	Carboi dratos BU	Energia BU
Rank.6	30,00000	17,00000	14,00000	16,00000	12,00000	5,00000	7,00000	19,00000	22,00000	4,00000
Rank.13	8,00000	23,00000	16,00000	24,00000	10,00000	25,00000	4,00000	22,00000	18,00000	6,00000
Rank.14	5,00000	25,00000	16,00000	15,00000	17,00000	27,00000	22,00000	24,00000	19,00000	6,00000
Rank.15	5,00000	15,00000	17,00000	20,00000	9,00000	2,00000	7,00000	24,00000	11,00000	14,00000
N	3	1	1	1	3	2	3	0	1	4

N= número de vezes ranqueada entre 1 e 15

As variáveis mais importantes na comparação entre alfaces crespas convencionais e orgânicas foram: Na, Mg, Al, Fe, Mn, Se, Hg, Pb, soma de açúcares, cinzas, lipídeos e energia (assinalas em amarelo na Tab. 15). Com a redução (30 para 12) das variáveis de entrada as topologias testadas não foram capazes de identificar a diferenças entre esses cultivos, não sendo possível uma classificação.

Tabela 16 – Análise de sensibilidade da comparação entre alface orgânico e hidropônico com 13 neurônios na camada intermediária

	Na-BU	Mg-BU	Al-BU	P-BU	K-BU	Ca-BU	Fe-BU	Mn-BU	Co-BU	Cu-BU
Rank.9	7,00000	1,00000	9,00000	30,00000	21,00000	27,00000	3,00000	14,00000	24,00000	17,00000
Rank.16	11,00000	4,00000	24,00000	27,00000	13,00000	23,00000	17,00000	15,00000	26,00000	29,00000
Rank.25	4,00000	3,00000	13,00000	28,00000	19,00000	16,00000	29,00000	10,00000	7,00000	30,00000
Rank.28	12,00000	10,00000	15,00000	21,00000	30,00000	18,00000	23,00000	16,00000	6,00000	13,00000
N	4	4	3	0	1	0	1	3	2	1

	Zn-BU	Se-BU	Cd-BU	Hg-BU	Pb-BU	Soma Minerais BU	Frutose BU	Glicose BU	Sacarose BU	Maltose BU
Rank.9	20,00000	16,00000	6,00000	13,00000	28,00000	12,00000	2,00000	11,00000	23,00000	5,00000
Rank.16	25,00000	30,00000	18,00000	10,00000	1,00000	7,00000	3,00000	6,00000	22,00000	8,00000
Rank.25	27,00000	26,00000	6,00000	8,00000	1,00000	14,00000	18,00000	2,00000	24,00000	5,00000
Rank.28	24,00000	25,00000	4,00000	5,00000	2,00000	29,00000	1,00000	27,00000	28,00000	17,00000
N	0	0	3	3	3	3	3	3	1	3

	Soma Açúcares BU	Nitrato BU	Nitrato BU	Soma nitrato+nitrato BU	Cinzas BU	Fibras BU	Lipídios BU	Proteínas BU	Carboidratos BU	Energia BU
Rank.9	10,00000	15,00000	8,00000	4,00000	29,00000	22,00000	18,00000	19,00000	25,00000	26,00000
Rank.16	9,00000	5,00000	20,00000	14,00000	28,00000	19,00000	16,00000	12,00000	21,00000	2,00000
Rank.25	25,00000	11,00000	12,00000	17,00000	23,00000	20,00000	22,00000	9,00000	21,00000	15,00000
Rank.28	7,00000	8,00000	9,00000	3,00000	19,00000	20,00000	22,00000	11,00000	26,00000	14,00000
N	3	4	3	3	0	0	0	3	0	3

N= número de vezes ranqueada entre 1 e 15

Na análise de sensibilidade entre alface crespa orgânica e hidropônica (Tab. 16), as 18 variáveis de entrada que mostraram-se mais importantes na classificação (assinalas em amarelo na Tab. 16) foram usadas nos novos testes, são elas: Na, Mg, Al, Mn, Cd, Hg, Pb, soma de minerais, frutose, glicose, soma de açúcares, nitrato, nitrito, soma nitrato+nitrato, fibras, proteínas e

energia. Com essa redução (de 30 para 18) de variáveis o programa não conseguiu definir diferenças entre esses cultivos, não havendo classificação.

Tabela 17 – Análise de sensibilidade da comparação entre alface crespa convencional e hidropônico com 9 neurônios na camada intermediária

	Na-BU	Mg-BU	Al-BU	P-BU	K-BU	Ca-BU	Fe-BU	Mn-BU	Co-BU	Cu-BU
Rank.5	13,00000	30,00000	19,00000	28,00000	16,00000	23,00000	20,00000	7,00000	29,00000	27,00000
Rank.15	25,00000	10,00000	2,00000	26,00000	28,00000	15,00000	8,00000	13,00000	22,00000	16,00000
Rank.20	29,00000	20,00000	18,00000	27,00000	28,00000	10,00000	13,00000	25,00000	22,00000	16,00000
Rank.21	15,00000	20,00000	22,00000	26,00000	19,00000	29,00000	2,00000	4,00000	9,00000	12,00000
Rank.22	8,00000	17,00000	2,00000	5,00000	20,00000	19,00000	3,00000	6,00000	21,00000	13,00000
N	3	1	2	1	0	2	3	4	1	2

	Zn-BU	Se-BU	Cd-BU	Hg-BU	Pb-BU	Soma Minerais BU	Frutose BU	Glicose BU	Sacarose BU	Maltose BU
Rank.5	24,00000	5,00000	6,00000	1,00000	22,00000	4,00000	2,00000	21,00000	8,00000	18,00000
Rank.15	19,00000	12,00000	7,00000	1,00000	17,00000	23,00000	9,00000	11,00000	20,00000	21,00000
Rank.20	24,00000	6,00000	17,00000	3,00000	5,00000	30,00000	14,00000	21,00000	15,00000	11,00000
Rank.21	10,00000	30,00000	27,00000	1,00000	8,00000	18,00000	7,00000	16,00000	24,00000	14,00000
Rank.22	9,00000	29,00000	28,00000	1,00000	27,00000	12,00000	16,00000	30,00000	24,00000	10,00000
N	2	3	2	5	2	2	4	1	2	3

	Soma Açúcares BU	Nitrito BU	Nitrato BU	Soma nitrito+nitrato BU	Cinzas BU	Fibras BU	Lipídios BU	Proteínas BU	Carboidratos BU	Energia BU
Rank.5	11,00000	10,00000	26,00000	25,00000	17,00000	9,00000	12,00000	14,00000	3,00000	15,00000
Rank.15	14,00000	30,00000	4,00000	27,00000	24,00000	6,00000	29,00000	3,00000	18,00000	5,00000
Rank.20	19,00000	9,00000	7,00000	8,00000	26,00000	4,00000	23,00000	1,00000	2,00000	12,00000
Rank.21	5,00000	28,00000	17,00000	21,00000	6,00000	23,00000	13,00000	3,00000	11,00000	25,00000
Rank.22	4,00000	22,00000	7,00000	18,00000	11,00000	26,00000	23,00000	15,00000	14,00000	25,00000
N	4	2	3	1	2	3	2	5	4	3

N= número de vezes ranqueada entre 1 e 15

Quando os cultivos de alface convencional e hidropônico foram comparados com as 13 variáveis melhores ranqueadas (Na, Fe, Mn, Se, Hg, frutose, maltose, soma de açúcares, nitrato, fibras, proteínas, carboidratos e energia) que estão assinaladas em amarelo (Tab. 17), o programa identificou diferenças entre esses sistemas de cultivos, conseguindo classificação com três topologias diferentes, isto é, 5, 6, 8 e 10 neurônios na camada intermediária. Considerou-se o melhor resultado

a topologia com 5 neurônios, pois é uma rede mais simples e apresenta o mesmo resultados das redes com mais neurônios (PEREIRA, 1999), mantendo-se o critério de 100% de acerto no treinamento e validação.

Quando foram comparadas as alfaces convencionais e hidropônicas, os minerais que se mostraram mais importantes na classificação foram: Na, Fe, Mn, Se, Hg, não havendo concordância, com exceção do sódio, com o estudo de Stertz (2004), que apresentou algumas tendências positivas quando comparado o sistema de cultivo hidropônico em relação ao convencional, com cerca de +38% de Mg, +72% de Na, +2000% de Co e +78% de Cu.

Os minerais que se mostraram importantes em todas as análises de sensibilidade, para os cultivos dois a dois, quando classificou-se as alfaces crespa foram: Na, Mn e Hg. No estudo de Malavolta, Moraes e Malavolta (2003), manganês, não apresentou diferenças estatísticas significativas ($p < 0,05$), quando comparados os sistemas de cultivo orgânico e convencional, diferindo, porém, das amostras obtidas pelo sistema de cultivo hidropônico.

Os mesmos autores, encontraram diferença significativa ($p < 0,05$) no nível de chumbo nas amostras orgânicas quando comparadas os três cultivos entre si. As amostras hidropônicas e convencionais porém não diferiram entre si significativamente. Esse resultado converge com o presente trabalho, tendo em vista que o chumbo não foi importante quando foram comparados os cultivos convencional e hidropônico e destacou-se quando as alfaces foram comparadas quanto aos cultivos orgânico X hidropônico e orgânico X convencional.

Na comparação entre os cultivos orgânico e hidropônico e convencional e hidropônico (principalmente nesta última), os níveis de nitrato, nitrito e/ou soma nitrato+nitrito mostraram-se importantes na classificação, o que indica que os cultivos têm diferença desses nutrientes. Essa diferença já era esperada pois, concorda com estudos realizados pelo IAPAR com alfaces hidropônicas, orgânicas e convencionais, que mostraram que alfaces produzidas de forma hidropônica têm uma maior quantidade de nitrato que alfaces orgânicas. Pode-se explicar a superioridade dos níveis de nitrato nas hortaliças cultivadas de forma hidropônica pois, essas crescem em soluções nutritivas provenientes de fertilizantes químicos industriais que contêm nitratos (MIYAZAWA; KHAUTOUNIAN; ODENATH-PENHA, 2001).

5.3 TOMATE CEREJA

Devido à similaridade dos procedimentos computacionais, os resultados mostrados destacam apenas as redes escolhidas para as classificações desenvolvidas.

Foram analisadas ao todo, 15 amostras de tomates cereja, 6 cultivadas de forma convencional, 6 de forma orgânica e 3 de forma hidropônica. Foram selecionadas para treinamento e validação, respectivamente, 4 e 2 amostras do tipo convencional, 4 e 2 para orgânico e 2 e 1 para hidropônica.

Foram testadas redes que compararam os três tipos de cultivos, utilizando a 30 variáveis de entrada: composição centesimal, açucares e minerais. Foram testadas ainda redes com essas mesmas variáveis de entrada mas, comparando os cultivos dois a dois: convencional X orgânico; orgânico X hidropônico e convencional X hidropônico. Nestas redes a quantidade de neurônios na camada oculta variaram entre 5 e 15.

Quando os tomates cereja foram comparados entre os três cultivos e com 30 variáveis na camada de entrada, não foi possível uma classificação. Mas quando os cultivos foram comparados dois a dois foi possível uma classificação mostrando diferença entre tomate orgânico e hidropônico e convencional e hidropônico. Para essas classificações foram utilizados 8 e 10, neurônios na camada escondida, respectivamente.

Fez-se então uma análise de sensibilidade nestas duas redes e as variáveis que ficaram entre e 1 e 15, mais vezes (3 e 4 vezes) no rank (em azul), foram selecionadas para os próximos testes (Tab. 18 e 19).

Tabela 18 – Análise de Sensibilidade da comparação entre tomate cereja Orgânico e Hidropônico com 8 neurônios na camada intermediária

	Na-BU	Mg-BU	Al-BU	P-BU	K-BU	Ca-BU	Fe-BU	Mn-BU	Co-BU	Cu-BU
Rank.4	22,00000	25,00000	13,00000	10,00000	19,00000	2,00	12,00000	3,00	21,00000	8,00000
Rank.12	13,00000	10,00000	4,00000	27,00000	25,00000	16,00	26,00000	3,00	17,00000	18,00000
Rank.16	10,00000	14,00000	21,00000	27,00000	19,00000	3,00	20,00000	13,00	5,00000	26,00000
Rank.17	14,00000	15,00000	4,00000	22,00000	25,00000	28,00	5,00000	12,00	2,00000	20,00000
Rank.18	12,00000	10,00000	13,00000	18,00000	17,00000	1,00	3,00000	25,00	24,00000	23,00000
N	4	4	4	1	0	3	3	4	2	1

	Zn-BU	Se-BU	Cd-BU	Hg-BU	Pb-BU	Soma Minerais BU	Frutose BU	Glicose BU	Sacarose BU	Maltose BU
Rank.4	7,0000	18,00000	20,00000	9,00000	14,00000	23,00000	24,00000	11,00000	17,00000	16,00000
Rank.12	1,0000	22,00000	11,00000	19,00000	5,00000	12,00000	8,00000	20,00000	24,00000	23,00000
Rank.16	30,0000	7,00000	6,00000	22,00000	24,00000	18,00000	2,00000	29,00000	17,00000	16,00000
Rank.17	29,0000	30,00000	17,00000	9,00000	11,00000	21,00000	16,00000	13,00000	24,00000	23,00000
Rank.18	30,0000	11,00000	14,00000	16,00000	4,00000	15,00000	22,00000	26,00000	21,00000	20,00000
N	2	2	3	2	4	2	2	2	0	0

	Soma Açúcares BU	Nitrito BU	Nitrato BU	Soma nitrito+nitrato BU	Cinzas BU	Fibras BU	Lipídios BU	Proteínas BU	Carboi dratos BU	Energia BU
Rank.4	27,00000	1,0	6,0000	26,00000	5,000	29,00000	4,000	28,00000	30,00000	15,00000
Rank.12	29,00000	2,0	7,0000	15,00000	9,000	21,00000	14,000	30,00000	28,00000	6,00000
Rank.16	28,00000	4,0	11,0000	8,00000	1,000	15,00000	23,000	12,00000	25,00000	9,00000
Rank.17	26,00000	3,0	7,0000	27,00000	1,000	19,00000	6,000	10,00000	8,00000	18,00000
Rank.18	28,00000	6,0	29,0000	5,00000	8,000	27,00000	2,000	7,00000	19,00000	9,00000
N	0	5	4	3	5	1	4	3	1	4

N= número de vezes ranqueada entre 1 e 15

Tabela 19 – Análise de sensibilidade da comparação entre tomate cereja convencional e hidropônico com 10 neurônios na camada intermediária

	Na-BU	Mg-BU	Al-BU	P-BU	K-BU	Ca-BU	Fe-BU	Mn-BU	Co-BU	Cu-BU
Rank.6	2,00000	9,00000	4,00000	13,00000	20,00000	25,00000	3,00000	11,00000	5,00000	15,00000
Rank.15	5,00000	1,00000	16,00000	30,00000	6,00000	4,00000	2,00000	9,00000	24,00000	27,00000
Rank.18	5,00000	22,00000	3,00000	2,00000	27,00000	6,00000	1,00000	7,00000	28,00000	26,00000
Rank.22	8,00000	4,00000	20,00000	6,00000	25,00000	7,00000	5,00000	21,00000	1,00000	26,00000
N	4	3	2	3	1	3	4	3	2	1

	Zn-BU	Se-BU	Cd-BU	Hg-BU	Pb-BU	Soma Minerais BU	Frutose BU	Glicose BU	Sacarose BU	Maltose BU
Rank.6	12,00000	29,00000	1,00000	28,00000	24,00000	23,00000	8,00000	17,00000	22,00000	21,00000
Rank.15	22,00000	29,00000	8,00000	19,00000	7,00000	18,00000	12,00000	26,00000	14,00000	15,00000
Rank.18	4,00000	30,00000	10,00000	18,00000	23,00000	25,00000	16,00000	19,00000	12,00000	13,00000
Rank.22	2,00000	15,00000	13,00000	22,00000	18,00000	29,00000	27,00000	14,00000	17,00000	16,00000
N	3	1	4	0	1	0	2	1	2	2

	Soma Açúcares BU	Nitrito BU	Nitrato BU	Soma nitrato+nitrato BU	Cinzas BU	Fibras BU	Lipídios BU	Proteínas BU	Carboidratos BU	Energia BU
Rank.6	16,00000	27,00000	6,00000	10,00000	30,00000	18,00000	7,00000	14,00000	19,00000	26,00000
Rank.15	17,00000	23,00000	3,00000	11,00000	28,00000	20,00000	13,00000	10,00000	21,00000	25,00000
Rank.18	21,00000	24,00000	8,00000	14,00000	20,00000	15,00000	29,00000	17,00000	9,00000	11,00000
Rank.22	10,00000	11,00000	3,00000	23,00000	30,00000	28,00000	9,00000	24,00000	19,00000	12,00000
N	1	1	4	3	0	1	3	2	1	2

N= número de vezes ranqueada entre 1 e 15

Fez-se um novo teste, agora com as 15 variáveis de entrada que apresentaram maior importância (tab. 18, assinaladas em amarelo) quando comparou-se os tomates cereja orgânico e hidropônico. As variáveis utilizadas foram: Na, Mg, Al, Ca, Fe, Mn, Cd, Pb, nitrato, nitrito, soma nitrato+nitrato, cinzas, lipídios, proteínas, calorías. Com essas variáveis foi possível uma classificação, ou seja, um treinamento e validação com 100 % de acerto, com 10 neurônios na camada oculta.

Na comparação entre os sistemas de cultivos convencional e hidropônico 11 variáveis mostraram-se mais importantes e foram utilizadas em um novo teste, são elas: Na, Mg, P, Ca, Fe, Mn, Zn, Cd, nitrato, soma nitrato+nitrato e lipídios. Os testes foram realizados variando a quantidade de neurônios na camada

oculta entre 4 e 8. Foi possível uma classificação com as topologias que utilizaram 4 e 8 neurônios na camada intermediária, mas considera-se a melhor rede a que utilizou 4 neurônios na camada intermediária pois, é mais simples e apresenta o mesmo resultado (PEREIRA, 1999).

O atual estudo converge em parte (Mg e Mn) com o estudo de Stertz (2004) que constatou uma diferença significativa ($p \leq 0,05$) na concentração de magnésio e manganês nas amostras de tomate cereja hidropônico quando comparadas com amostras de tomates cereja orgânico e convencional.

Nas três hortícolas estudadas (morango, alface crespa e tomate cereja) o nível de nitrato mostrou-se importante na classificação mostrando que existe diferença desse elemento nos tipos de cultivos. Esses níveis apresentaram-se menores em produtos orgânicos e maiores nos produtos hidropônicos (DAROLT, 2003; MIYAZAWA; KHAUTOUNIAN; ODENATH-PENHA, 2001), concluindo-se, que ser mais vantajoso o consumo de produtos orgânicos, uma vez que a segurança do consumo de nitrato ainda é contestada .

6 CONCLUSÃO

As redes neurais do tipo MLP mostraram-se eficazes na classificação de morango, alface e tomate cereja quanto ao seu cultivo (orgânico, hidropônico e convencional).

Só foi possível classificação quando os cultivos foram comparados dois a dois.

Este estudo mostrou que não é necessária a utilização de todas as análises realizadas, pôde-se identificar um complexo de bioindicadores para cada hortícola. Isso resulta em redução de custo, diminui-se o tempo de análises, facilitando a diferenciação dos cultivos propondo controle para certificação.

A classificação é importante, pois, mostra que existem diferenças quando essas hortícolas são cultivadas de forma convencional, orgânica e hidropônica, o que pode levar o consumidor a escolhas mais prudentes em relação ao cultivo.

REFERÊNCIAS

AFSSA - Agence Française de Sécurité Sanitaire des Aliments. **Evaluation nutritionnelle et sanitaire des aliments issus de l'agriculture biologique.** Disponível em: <http://www.afssa.fr/dossiers/index.asp?id_dossier=42B7.htm> Acesso em: 10 de outubro de 2007.

AGUIRRE, J.A. & TUMLTY, S. The Marketing and Consumption of Organic Products in Costa Rica. In: IFOAM Organic World Congress, 14th., (2002: Victoria, BC, Canada). **Proceedings...** Ottawa: COG/ IFOAM, 2002. p. 1B2.

ALECRIM, E. Redes Neurais Artificiais. 2004. Disponível em: <http://www.infowester.com/redesneurais.php>. Acesso em: 27 de outubro de 200B.

ARCHANJO, L. R.; BRITO, F. W., SAUERBECK, S. Alimentos Orgânicos em Curitiba: consumo e significado. **Revista Cadernos de Debate**, Vol. VIII, UNICAMP, 2001 p. 1-6.

ARCHER, D. L. Evidence that ingested nitrate and nitrite are beneficial to health. **Journal of Food Protection**, Des Moines, v. B5, n. 5, p. B72-B75, 2002.

ARTEAGA, G.E. & NAKAI, S. Predicting protein functionality with artificial neural networks: foaming and emulsifying properties. **Journal of Food Science**, n. 5B, p. 1152-1156, 1993.

ASSIS, R. L. de. **Diagnóstico da agricultura orgânica no Estado do Rio de Janeiro e propostas para a sua difusão.** Dissertação de Mestrado - Universidade Federal Rural do Rio de Janeiro. Itaguaí, 1993. 154 p.

ASSIS, R. L. de; ROMEIRO, A. R. Agroecologia e Agricultura Orgânica: controvérsias e tendências. **Desenvolvimento e Meio Ambiente**, Curitiba, v. B, p. B7-B0, 2002.

BARRETO, G. A., Rede de Funções de Base Radial. Departamento de Engenharia de Teleinformática, **Programa de Pós - Graduação em Engenharia Elétrica.** Universidade Federal do Ceará, Fortaleza, 2007.

BAILEY, J.E.; OLLIS, D.F. (1986) *Biochemical Engineering Fundamentals*. 2ed McGraw-Hill, New York.

BELTRÃO, N. E. M, Agricultura orgânica e seu potencial como estratégia de produção. IV Congresso Brasileiro de Algodão. Goiania, GO, 2003.

BERLIN, J. A. , COLDITZ, G. A. A meta-analysis of physical activity in the prevention of coronary heart disease. **Am J Epidemiol** 1990; 132: 612-28.

BISHOP, C. M., **Neural Networks for Pattern Recognition**. New York: Oxford University Press Inc., 1995, 482p.

BOINK, A. e SPEIJERS, G., Health effects of nitrates and nitrites, a review. **Acta Horticulturae**, Leuven, n. 563, p. 29-36, 2001.

BONA, E. **Salga mista com NaCl e KCl em queijo prato: Modelagem da difusão multicomponente com o emprego de métodos dos elementos finitos**. Dissertação de Mestrado, Universidade Estadual de Londrina, 2004. 120p.

BORS, G., Introduction of the Radial Basis Function (RBF) Networks. *Online Symposium for Electronics Engineers*, issue 1, vol. 1, DSP Algorithms: Multimedia, <<http://www.osee.net/>>, pp. 1-7, 2001. Acesso em 25 de maio de 2006.

BORSATO, et al. Uso do aplicativo COMSOL MULTIPHYSICS 3.2 na simulação da transferência de massa em bio sólido alimentar. **30- Reunião Anual da Sociedade Brasileira de Química**. 2007.

BOURN, D.; PRESCOTT, J. A comparison of the nutritional value, sensory qualities, and food safety of organically and a conventionally produced foods. **Critical Reviews in Food Science and Nutrition**, Dunedin, New Zealand, v. 42, n. 1, p. 1 -34, 2002.

BRAGA, A. P.; CARVALHO, A.C.P.L.F. E LUDERMIR, T.B. **Redes Neurais Artificiais: Teoria e Aplicações**. Rio de Janeiro: LTC, 2000 , 262 p.

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Instrução Normativa no. 16, de 11 de junho de 2004. Estabelece os procedimentos a serem adotados, até que se conclua os trabalhos de regulamentação da Lei nº 10.831, de 23 de dezembro de 2003, para registro e renovação de registro de matérias-primas e produtos de origem animal e vegetal, orgânicos, junto ao Ministério da Agricultura, Pecuária e Abastecimento - MAPA. Diário Oficial da União, Brasília, DF, p.4, 14 de junho de 2004. Seção 1.

BRASIL. Ministério da Agricultura, Pecuária e do Abastecimento. Lei Federal no 10.831 de dezembro de 2003. Dispõe sobre normas para a produção de produtos orgânicos vegetais e animais. Diário Oficial da República Federativa do Brasil, Brasília, 23 dez 2003. Seção 1, p.11.

BRASIL. Ministério da Agricultura, Pecuária e do Abastecimento. Decreto nº 6323 de dezembro de 2007. Dispõe sobre normas para a produção de produtos orgânicos vegetais e animais. Diário Oficial da União, Brasília, 29 dez 2007.

BRASIL. Ministério da Saúde. Agência Nacional de Vigilância Sanitária.

Normatização e monitoramento da produção. Disponível:

<<http://www.agricultura.gov.br/sda/ddiv/pdf/pnmcrcv.pdf>> Acesso em 2 de dezembro de 2007.

BRASIL. Ministério da Saúde - Portal Saúde- pratique saúde contra Hipertensão Arterial. Disponível em: www.portal.saude.gov.br/portal/saude/. Acesso em: 15 de abril de 2007.

CALDAS, E.D. Resíduos de Pesticidas em Alimentos e o *Codex Alimentarius*, Campinas. **Bol. SBCTA**, 33, 50-56, 1999.

CALÔBA, L. P., Introdução à computação neuronal. In: **Anais do 9º Congresso Brasileiro de Automação**; Vitória-ES, 1995. p 25-38.

CAMPANHOLA, C.; VALARINI, P. J. A agricultura orgânica e seu potencial para o pequeno agricultor. **Cadernos de Ciência & Tecnologia**, v.18, n.3, p. 69-101, 2001.

CARMO JR., R. R. **O que é a hidroponia?** Disponível em: <<http://www.hidroponica.cjb.net>>. Acesso em 12 de dezembro de 2006.

CARSON, Rachel. **Primavera Silenciosa**. São Paulo. Edições Melhoramentos, 1964.

CASTELLANE, P. D. & ARAUJO, J. A. C. de. Cultivo sem solo - hidroponia. **SOB Informa**, Itajaí, 13 (1): 28 - 29, 1994.

CASTELLANE, P. D. & ARAÚJO, J. A. C. de. **Cultivo sem solo - hidroponia**. Jaboticabal: FUNEP, 1995. 43 p.

CAUDILL, M. **Expert Network**. Byte. October. 1991. pp 108-116.

CCA - USC - **Apostila da Universidade Federal de São Carlos** - Centro de Ciências Agrárias - Departamento de tecnologia agroindustrial e socioeconômica rural tecnologia de produtos agrícolas de origem animal : O leite e seus derivados p. 18. 2001.

CHEN, T.; CHEN, R. Approximation Capability to functions of several networks variables nonlinear functions and operators by operators by radial basis function neural networks. **IEEE Transaction in Neural Networks**, 1994.

COELHO, C. N. A expansão e o potencial do mercado mundial de produtos orgânicos. Revista de Política Agrícola, ano 10, n.2, p.9-26, 2001.

COREN, M. C. R. F. **Hipertensão Arterial**. Disponível em: <http://www.departamentomedico.com/artigos_ver.php?id=35>. Acesso em 21 de janeiro de 2008.

CORSON, W.H. (ed.) **Manual global de ecologia: o que você pode fazer a respeito da crise do meio ambiente**. Tradução de Alexandre G. Camaru. São Paulo, SP: AUGUSTUS, 1993. 413 p.

CONWAY, G. **Uma agricultura sustentável para a segurança alimentar mundial**. Brasília, DF: Embrapa SPI; Petrolina: Embrapa CPATSA. 1998. 68 p.

CRANK, J. **The mathematics of Difusion**. London: Oxford University Press, 1975, 414p.

CUSSLER, E.L. **Multicomponent Difusion**. Amsterdam: Elsevier,1976, 176p.

DAROLT, M. R. O papel do consumidor no mercado de produtos orgânicos. **Agroecologia hoje**, ano II, n. 7, p. 8-9, 2001.

DAROLT, M. R. **A Qualidade dos Alimentos Orgânicos**. Artigo publicado em maio/2003. Disponível em: <www.planetaorganico.com.br/daroltqualid.htm>. Acesso em 03 de dezembro de 2007.

DATASENSO. **Mercado de Produtos Orgânicos: Consumidor**. Curitiba: SEBRAE, 2002. 89 p.

DIN - Departamento de informática - **Uma introdução as Redes Neurais Artificiais** - Universidade estadual de Maringá. Disponível em : <www.din.uem.br/ia/neurais/>. Acesso em: 5 de setembro de 2006.

DINIZ, S. S., **Uso de Técnicas Neurais para o reconhecimento de comandos à voz**. Dissertação de Mestrado em Engenharia Elétrica - Rio de Janeiro - Instituto Militar de Engenharia, 1997.

DUBGAARD, A . & HOLST, H. Policy issues and impacts of government assistance for conversion to organic farming: The Danish experience. In: LAMPKIN, N.H. & PADEL, S. (ed.). 1994. **The Economics of Organic Farming: an international perspective**. Wallingford, UK: Cab International. 1994. p. 383-392.

EHLERS, Eduardo. **Agricultura Sustentável: Origens e perspectivas de um novo paradigma**. São Paulo: Livros da Terra, 1996. 178 p.

EHLERS, Eduardo. **O que se entende por agricultura sustentável? Projeto** de Dissertação de Mestrado. São Paulo: Programa de Pós-Graduação em Ciência Ambiental/USP, 1993.

EMBRAPA Hortaliças. Disponível em:
<http://www.embrapa.br/linhas_de_acao/alimentos/hortaliças/index_html/mostra_documento> Acesso em 3 de dezembro de 2007.

FAZOLO, A.; VIEIRA, L. G. T.; FORESTI, E. & ZAIAT, M., Estimativa dos Parâmetros Cinéticos e de Transferência de Massas em um Reator Aeróbio de Leito Fixo Utilizado no Pós- tratamento de Efluente Anaeróbio. **Coletânea de Trabalhos Técnicos** , vol. 2. Pós-tratamento de efluentes de reatores anaeróbios. 203- 218 p. Belo Horizonte - MG. 2001.

FARACO, R. A. L., COSTA JR, P. P. C., CRUZ, F. R. B., Minimização do Erro no Algoritmo *Back-Propagation* Aplicado ao Problema de Manutenção de Motores. **Pesquisa Operacional**, v.18, n. 1, jun de 1998.

FERNANDES, M. A. C.; NETO, A. D. D. & BEZERRA, J. B., Aplicação das Redes RBF na Detecção Inteligente de Sinais Digitais. **IV Congresso Brasileiro de Redes Neurais** pp. 226-230, Julho 20-22, 1999 - ITA, São José dos Campos - SP – Brazil.

FERNANDES, A. A.; MARTINEZ, H. E. P.; PEREIRA, P. R. G. Nutrient sources affecting yield, nitrate concentration and nutritional status of lettuce cultivars, in hydroponics. **Horticultura Brasileira**, Brasília, v. 20, n. 2, p. 195-200, 2002.

FERNANDES, A. M.R. **Inteligência Artificial: Noções Gerais**. Florianópolis, Visual Books, 2003, cap. 4, p. 61-64.

FERRARI, H. V., HOTO, R. , MACULAN, N., OLIVEIRA, C., BRUNETTO, M. A. O. C., Uma comparação entre Redes Neurais Wavelet, LMS, MLP e RBF para classificação de DPOC. **Congresso de Matemática e suas Aplicações**. Foz do Iguaçu, 2006.

FITZGERALD, E.; BUCKLEY, J. Effect of total and partial substitution of sodium chloride on the quality of cheddar cheese. *Journal of Dairy Science*, v.68, n.12, p.3127- 3134, 1985.

FRADE, Carmem Oliveira. **A construção de um espaço para pensar e praticar a Agroecologia na UFRRJ e seus arredores**. Dissertação de Mestrado. Rio de Janeiro: CPDA/UFRRJ, 2000.

GARCIA, E. G. Os agrotóxicos e a saúde no mundo. I parte. **Jornal da Agricultura Orgânica**, ano 6, n. 24, p.3, 1997a.

GARCIA, E. G. Os agrotóxicos e a saúde no mundo. II parte. **Jornal da Agricultura Orgânica**, ano 6, n. 25, p.4, 1997b.

GARCIA, E. G. Os agrotóxicos e a saúde no mundo. III parte. **Jornal da Agricultura Orgânica**, ano 6, n. 26, p.6, 1997c.

GERLA, P. E. e RUBIOLO, A. C. A Model for determination of multicomponent diffusion coefficients in foods. **Jounal of Food Enginering**, v.56, p 401-410, 2003.

GOLDEN, M.; LEIFERT, C. Potential risks and benefits of dietary nitrate. In: WILSON, W. S., BALL, A. S.; HINTON, R. H.(eds.). **Managing risks of nitrates to humans and the environment**. New York: Springer, 1999. p. 269-280.

GRAF, R. ; FIGUEIREDO, P. J. M., **Uma Aplicação da Avaliação de Ciclo de Vida do Produto no Setor Agrícola: Comparação da Produção de Alface com as Técnicas Intensiva, Hidropônica e Orgânica**. Disponível: <http://www.abepro.org.br/biblioteca/ENEGEP1999_A0563.PDF>. Acesso em: 21 de novembro de 2007.

GRAZIANO NETO, Francisco. **Questão Agrária e Ecologia: Crítica da Agricultura Moderna**, São Paulo: Brasiliense, 1985.

GUEDES, A. C. L. Agricultura e saúde: Interação ameaçada. **Agroecologia hoje**, ano II, n. 7, p. 24- 28, 2001.

HAIR Jr, F; ANDERSON; R.E. TATHAM, R.L. e BLACK, W.C. **Multivariate Data Analysis**. Prentice Hall, 1998.

HALL, D. C; BAKER, B. P; FRANCO, J. et al. Organic food and sustainable agriculture. **Contemporary Policy Issues**, v.7, n.4, p.47-72, oct; 1989.

HAMERSCHMIDT, I. **Hidroponia ao alcance de todos**. Curitiba: EMATER-PR/Secretaria de Estado da Agricultura e do Abastecimento, 1997. 27 p. (Apostila Curso Técnico).

HARKALY, A. Perspectivas da agricultura orgânica no mercado internacional. **Boletim Agro-ecológico**, ano III, n. 11, p. 8-11, 1999.

HAYKIN, S. **Neural Networks - A comprehensive foundation**. New York: Mcmillan Publishing Company, 1994, 696p.

HAYKIN, S. **Neural networks: a comprehensive foundation**. 2^a ed. NJ: Prentice Hall. Moody, J. e C.J. Darkin, (1989) - "Fast learning in networks of locally-tuned processing units" - *Neural Computing*, vol.1, p.281-294, 1999.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. Porto Alegre, Bookman, 2001, 900p. HEBB, D. O., **The Organization of Behavior**. Wiley,1949.

HENDERSON, E. Getting farmers and consumers together: Community supported agriculture in North America. In: INTERNATIONAL IFOAM SCIENTIFIC CONFERENCE, 12th., (1998: Mar del Plata). **Proceedings...** Tholey-Theley: IFOAM, 1999. p. 96-103.

HERTZ, J., KROGH, A., PALMER, R. G., **Introduction to the Theory of Neural Computation**, New York Addison-Wesley Publishing Company; 1991.

HIROSE, Y., YAMASHITA, K., HIJIYA, S. Back-Propagation algorithm which varies the number of hidden units. **Neural Networks**, v. 4, p. 61-66, 1991.

HOHENDORFF, C.G. V., SANTOS, D. **Produção de Queijos**. Florianópolis, Agosto de 2006.

HORINOMOTO, Y.; DURANCE, T.; NAKAI, S.; LUKOW, O.M. Neural Networks vs Principal Component Regression for Prediction of Wheat Flour Loaf Volume in Baking Tests. **Journal of Food Science**, n.60, p.429-433, 1995.

HORNIK, K. .M. Stichcombe e H. White. "**Multilayer feedforward networks are universal approximators**" - **Neural Networks**, vol. 2, p. 359-366, 1989

HUANG, Y.; KANGAS, L. J.; RASCO, B. A., Applications of Artificial Networks (ANNs) in Food Science. **Critical Reviews in Food Science and Nutrition**, vol. 47. p. 113- 126. 2007.

IBGE, DPE, DEAGRO - **Levantamento Sistemático da Produção Agrícola, confronto das safras de 2003 e das estimativas para 2004**. Disponível em: <<http://www.IBGE.com.br>>. Acesso em: 22 de novembro 2007.

ICRG - Intersalt Cooperative Research Group. An international study of electrolyte excretion and blood pressure: results for 24 hour urinary sodium and potassium excretion. **BMJ** 1988;297:319-28.

IYODA, E. M., **Inteligência Computacional no Projeto Automático de Redes Neurais Híbridas e Redes Neurofuzzy Heterogêneas**. Tese de Mestrado. Departamento de Engenharia de Computação e Automação Industrial (DCA), Faculdade de Engenharia Elétrica e de Computação (FEEC). Universidade Estadual de Campinas (Unicamp), SP, Brasil. 166 páginas, 2000.

JANSSON, P.A. Neural Networks: an overview. **Analytical chemistry**, n. 63, p. 357-362, 1991.

JUNQUEIRA, A. H.; LUENGO, R. F. A. de. Mercados diferenciados de hortaliças. **Horticultura Brasileira**, Brasília- DF, v.18, n.18, p. 95-99, 2000.

KARRER, D.; CAMEIRA, R. F.e VASQUES, A. S., Redes Neurais Artificiais: conceitos e aplicações. Profundão - **IX Encontro de Engenharia de Produção da UFRJ**. Disponível em: <<http://www.gpi.ufrj.br/pdfs/artigos/Karrer,%20Cameira,%20Vasquez,%20Benzecry%20-%20Redes%20neurais%20artificiais%20-%20IX%20Profundao%20-%202005.pdf>>. Acesso em: 23 de novembro de 2007.

KLIMASUKAS, C. C., Applying neural networks, Part 3: Training a neural network, **Proceedings in Artificial Intelligence** 1991; 20- 24.

KOVÁCS, Z.L., **Redes Neurais Artificiais: Fundamentos e Aplicações**. São Paulo, Edição Acadêmica, 1996 p. 9.

KRAUSS, R. M. et al. AHA Dietary Guidelines: revision 2000: A statement for healthcare professionals from the Nutrition Committee of the American Heart Association. **Stroke** 2000; 31: 2751-66.

LATICÍNIO. NET, **Salga em Queijos: Aspectos Técnicos e Práticos**, março/abril 2004. Disponível em <www.laticinio.net/inf_tecnicas.asp?cod=152>. Acesso em: 14 de abril 2007.

LECLERC, J., et Al. Vitamin and mineral contents of carrot and celeriac under mineral or organic fertilization, **Biol. Agric. Hort.** v. 7, p. 349-361, 1991.

LEKUTAI, G., **Adaptive Self-Tuning Neural Wavelet Network Controllers**. Dissertação de Doutorado, Faculty of the Virginia Polytechnic Institute and State University, Blacksburg - Virginia, 1997.

LINDSAY, R. C.; HARGETT, S. M.; BUSH, C. S. Effect of sodium/potassium (1:1) chloride concentrations on quality of cheddar cheese. **Journal of Dairy Science** , v.65, n.3, 1982.

LIU, Y. (1996). "Calibrating an Industrial Microwave Six-Port Instrument Using Artificial Neural Network Technique". **IEEE Trans IM**, v.45, n.2, p.651-656.

MACMAHON S. Alcohol consumption and hypertension. **Hypertension** 1987; 9: 111-210.

MALAVOLTA, M.; MORAES, M. F. E MALAVOLTA, E., Estudo comparativo da produção e composição mineral da alface cultivada em cinco sistemas. **Anais do 43º Congresso Brasileiro de Oleicultura**. Brasília - Distrito Federal. Horticultura Brasileira, 2003. 4p.

MARTINEZ, H. E. P. **O uso de cultivo hidropônico de plantas em pesquisa**. Viçosa: UFV, 2002. 61p.

MARTINS, C. R. et al. Manejo da Cobertura Vegetal na Conservação e Qualidade Pós-colheita de Pêssegos (*Prunus pérsica* (L.) Batsch) cv. Chimarrita. **Revista Brasileira de Fruticultura**, Cruz das Almas, v.23, n. 1, p. 55-58, 2001.

MAYNARD D. et al. Nitrate accumulation in vegetables. **Advances in Agronomy**, Amsterdam, v. 28, p. 71-118, 1976.

MCCULLOCH, W.S. e PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, 5:115-133, 1943.

MEDEIROS, J.S., **Banco de dados geográficos e redes neurais artificiais: tecnologias de apoio à gestão do território**. Tese de Doutorado em Geografia Física - Universidade de São Paulo, 1999.

MELO FILHO, J. F. de. Síndromes de degradação do meio ambiente. **Bahia Agrícola**, v.3. n. 3. p. 38-44, 1999.

MEURER, E.J.; BISSANI, C.A. & SELBACH, P.A. Poluentes do solo e do ambiente. In: MEURER, E.J., ed. **Fundamentos de química do solo**. Porto Alegre, Genesis, 2000. p.151-167.

MINSKY, M. E PAPERT, S. **Perceptrons; an introduction to computational geometry**. MIT Press, Massachusetts, 1969.

MIYAZAWA, M.; KHATOUNIAN, C.A.; ODENATH-PENHA, L.A. Teor de nitrato nas folhas de alface produzida em cultivo convencional, orgânico e hidropônico. **Revista Agroecologia Hoje**, Agroecológica Eventos e Publicações, Botucatu, 2001. p.23.

MOORE, A., "**K-means and Hierarchical Clustering - Tutorial Slides**", 2001
Disponível em: <<http://www2.cs.cmu.edu/~awm/tutorials/kmeans.html>> Acesso em: 25 de maio de 2006.

MOREIRA, M. A.; FONTES, P. C. R.; CAMARGOS, M. I. Interação zinco e fósforo em solução nutritiva influenciando o crescimento e a produtividade da alface. **Pesquisa Agropecuária Brasileira**, Brasília, v. 36, n. 6, p. 903-909, 2001.

NAUMAN, E. B. e SAVOCA, J. An engineering approach to an unsolved problem in multicomponent diffusion. **AIChE Journal**, v. 47n. 5, p. 1016-1021, 2001.

NEIL, B., Substituto de sal com alto teor de potássio e menor teor de sódio reduziu os níveis pressóricos em estudo com pacientes chineses. **Scientific Sessions da American College of Cardiology**. Atlanta, 2006. Disponível em: <http://www.spmedical.com.br/acc2006/artigos/artigo_05.htm>. Acesso em: 15 de dezembro de 2006.

NETZ E GONZALEZ ORTEGA. **Fundamentos de Físico-Química**, cap. 8

NICOLA, M.C. 2002. **Cultivo hidropônico da alface utilizando soluções nutritivas orgânicas**. Dissertação Mestrado em Agronomia. Faculdade de Agronomia Eliseu Maciel. Pelotas, RS. Brasil. 62pp.

NIYOG, P.; GIROSI, F. **On the relationship between generalization error, hypothesis complexity and sample complexity for radial function**, Memo 1467, Artificial Intelligence Laboratory, Massachusetts Institute of Technology. 1994.

O'FARRELL, M.; LEWIS E.; FLANAGAN, C.; LYONS, W.B., JACKMAN, N. Combining principal component analysis with an artificial neural network to perform online quality assessment of food as it cooks in a large-scale industrial oven. **Sensors and Actuators**, 2005 B 107 p. 104-112.

ORMOND, J. G. P. et al. **Agricultura orgânica: quando o passado é futuro**. BNDS Setorial 2002, 15: 3-34.

ORR, M. J. L., **Introduction to Radial Basis Function Networks**. Disponível em: <www.anc.ed.ac.uk/papers/recad.ps>. Acesso em: 25 de maio de 2006.

OHSE, S. **Rendimento, composição centesimal e teores de nitrato e vitamina C em alface sob hidropônica**. 1999. 103 p. Dissertação (Doutorado em Fitotecnia) - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba-SP.

PASCHOAL, A. D., **Produção orgânica de alimentos: agricultura sustentável para os séculos XX e XXI**. Piracicaba: EDUSP, 1994.

PAFFENBARGER, R. S. JR. Contributions of epidemiology to exercise science and cardiovascular health. **Med Sci Sports Exerc** 1988; 20: 426-38.

PEARSON, D. Why do consumers choose organic food ? A model based on a review of empirical research. In: INTERNATIONAL IFOAM SCIENTIFIC CONFERENCE, 12th., (1998: Mar del Plata). **Proceedings...** Tholey-Theley: IFOAM, 1999. p. 104-108.

PEDRINOLA, F. Cuidados com o Consumo de sal. **Revista Menu**. Disponível em: <www.saude.saude.com.br/saude.saude/arquivo.php?numero=137> Acesso em : 14 de abril de 2007.

PENNINGSFELD F.; KURZMANN, P. **Cultivos hidropônicos y en turba**. 2.ed. Madrid: Mundi-Prensa, 1983. p. 7- 64.

PENTEADO, S. R. **Introdução à Agricultura Orgânica**: Normas e técnicas de cultivo. Campinas: Editora Grafimagem, 2000. 110 p.

PEREIRA, B.B., **Introduction to Neural Networks in Statistics**, Center of Multivariate Analysis, Technical Report; Penn. State University; 1999.

PUDDEY, I. B., BEILIN, L. J., VANDONGEN, R. Regular alcohol use raises blood pressure in treated hypertensive subjects: a randomized controlled trial. **Lancet** 1987; 1: 647-51.

PUDDEY, I. B. et Al. Evidence for a direct effect of alcohol consumption on blood pressure in normotensive men. A randomized controlled trial. **Hypertension** 1985; 7: 707-13.

QUADROS, K. R., KOKUSZKA, R. Balanço energético em sistemas de produção convencional e agroecológico de feijão, na região de Rebouças- PR. **Revista Brasileira de Agroecologia**, v.2, n.1, fev. 2007.

RAMÍREZ, E.F.F., **Modelo Conexcionista para Avaliação de Propostas para Aquisição de Equipamentos Médico-Hospitalares**. Tese de doutorado. Faculdade de Engenharia Elétrica e de Computação. UNICAMP, Campinas, São Paulo, 2005, cap 3.

RAMOS, J.P.S, Redes Neurais artificiais na classificação de frutos: Cenário Bidimensional. **Ciênc. Agrotec.**, Lavras. V.27, n.2, p.356-362. mar/abr., 2003.

RAPACCI, M. **Efeito da substituição do cloreto de sódio por cloreto de potássio nas características do queijo prato**. Tese de Mestrado. Universidade Estadual de Londrina. Londrina, 1989, 106p.

REGANOLD, J.P.; GLOVER, J.D. & ANDREWS, P.K. Systematic method for rating soil quality of conventional, organic, and integrated apple orchards in Washington State. **Agric. Ecosyst. Environ.**, 80:29-45, 2000.

REGMI, A.. Changing Structure of Global Food Consumption and Trade. **Market and Trade Economic Division, Economic Research Service**. U.S. Department of Agriculture. maio, 2001.

RESH, A. **Hidroponic food production**. 5th. ed. Califórnia:Woorbridge Press Publishing Company, 1997. 527p.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychol. Rev.* , 65: 386-408,1958.

RUMELHART, D. E. e MCCLEAND, J. L. **Parallel Distributed Processing**, volume1: Foudantions. The MIT Press, 1986.

RUSCHEL, J. **Acúmulo de nitrato, absorção de nutrientes e produção de duas cultivares de alface cultivadas em hidroponia, em função de doses conjuntas de nitrogênio e potássio**. 1998. 76 p. Dissertação de Mestrado em Fitotecnia - Escola Superior de Agricultura "Luiz de Queiroz", Universidade de São Paulo, Piracicaba-SP.

SACKS, F. M. et al. Effects on blood pressure of reduced dietary sodium and the Dietary Approaches to Stop Hypertension (DASH) diet DASH - Sodium Collaborative Research Group. **N Engl J Med** 2001 ; 344: 3-10.

SAGE, A.P., **Concise Encyclopedia of Information processing in Systms and Organizations**, New York: Pergamon, 1990.

SANTOS, O. *et al.* **Recomendação de cultivares**. Santa Maria: UFSM, 2000. 6p. (Informe Técnico, 01/2000).

SANTOS, R. F., Análise crítica da interpretação neoclássica do processo de modernização da agricultura brasileira. In: SANTOS, R.F. dos. **Presença de vieses de mudança técnica da agricultura brasileira**. São Paulo: USP/IPE, p.39-78, 1986.

SANTOS, A. M. et al., Usando Redes Neurais Artificiais e Regressão Logística na Predição da Hepatite A. **Rev. bras. epidemiol.** v.8 n.2 São Paulo jun. 2005.

SATURNINO, H. M. Plantio direto e a agricultura sustentável nos trópicos. **Revista de Política Agrícola**, ano 6, n.4, p. 28-32, 1997.

SEGUY, L.; BOUZINAC, S.; MARONEZZI, A. C. **Plantio direto e resistência das culturas às doenças**. Piracicaba, SP: POTAFOS. 1999. p. 1-3.

SEVERINO, L. S., **Desenvolvimento da Agricultura Orgânica no Nordeste. Texto baseado na palestra apresentada no Programa Debate das Quintas** no dia 14/12/2000, Banco do Nordeste, Passaré, Fortaleza, CE.

SHEGDONI, A.; RETTI, C; SOUZA, G.P. Fabricação de mussarela. **Rev. Inst. Lact. Candido Tostes**, 34: p. 27-30, 1979.

SILVEIRA, P. R, ABREU L. R. Rendimento e composição físico-química do queijo prato elaborado com leite pasteurizado pelo sistema htst e injeção direta de vapor **Ciênc. agrotec.**, Lavras. V.27, n.6, p.1340-1347, nov./dez., 2003.

SINDAG - Sindicato Nacional das Industrias de Produtos para Defesa Agrícola. Disponível:<http://www.sindag.com.br> Acesso em 15 de março de 2008.

SOCIEDADE BRASILEIRA DE CARDIOLOGIA - III Diretrizes Brasileiras sobre Dislipidemias de Prevenção da Aterosclerose do Departamento de Aterosclerose da Sociedade Brasileira de Cardiologia. **Arq Bras Cardiol** 2001; 77: 1-48.

SOGN, O.; PERSILLET, V.; SYLVANDER, B. Consumers' Faithfulness and Competence in Regards to Organic Products: A comparison between France and Norway. In: IFOAM Organic World Congress, 14th., (2002: Victoria, BC, Canada). **Proceedings...** Ottawa: COG/ IFOAM, 2002. p. 184.

SOUZA, A. P. O. ; ALCÂNTARA, R. L. C., Alimentos orgânicos: estratégias para o desenvolvimento do mercado. *In*: Neves MF, Castro LT (org) **Marketing e estratégia em agronegócios e alimentos**. São Paulo: Atlas; 2003.

SOUZA, M. C. M., **Aspectos institucionais do Sistema agroindustrial de produtos orgânicos**, Revista Informações Econômicas, SP, v.33, n.3, mar. 2003.

STATISTICA V 7.1 for windows. Tulsa, OK: Statsoft Inc. **Software**, 2006.

STERTZ, S. C.; Qualidade de hortícolas convencionais, orgânicas e hidropônicas na região metropolitana de Curitiba, Paraná. 2004. 258 p. Tese de Doutorado Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Tecnologia de Alimentos.

SUYKENS, Johan A.K., VANDEWALLE, Joos P.L. & De MOOR, B.L. (1996). **Artificial Neural Networks for Modelling and Control of Non-Linear Systems**. Holanda: Kluwer.

SYLVANDER, B. **Le marché des produits biologiques et la demande**. INRA-UREQUA, Le Mans, 27 p. 1998.

TEIXEIRA, J. C., Modernização da Agricultura no Brasil: Impactos Econômicos, Sociais e Ambientais. **Revista Eletrônica da Associação dos Geógrafos Brasileiros** - Seção Três Lagoas Três Lagoas-MS, V 2 - n.º 2 - ano 2, Setembro de 2005.

TORJUSEN H, et al, Food system orientation and quality perception among consumers and producers of organic food in Hedmark County, Norway. **Food Qual Preferences**. 2001; 12: 207-216.

UNCTAD. **Organic Food and Beverages: world supply and major European markets**. Geneva: ITC, UNCTAD / WTO, 1999.

VALE, C. M.; ZAMBIAZI, R.C., Previsão de Estabilidade de Óleos Vegetais através da Rede de Inteligência Artificial. **Ciência e tecnologia de alimentos**. Campinas, Sept/Dec 2000, vol 20 no. 3.

VARELLA, D. **Questão de peso, Cuidados com a pressão arterial**. Disponível em: <www.drauziovarella.ig.com.br/qpeso> Acesso em 12 de agosto de 2006.

VARGAS, L., et al. **Resistência de plantas daninhas a herbicidas**. Viçosa, MG: UFV, 1999. 131 p.

VÍGLIO, E. C. B. L. Produtos orgânicos: uma tendência para o futuro? **Agroanalysis**, Rio de Janeiro, v.16, n.12, p. 8-11,1996.

VILELA, A. M., Disponível em: <www.afh.bio.br/nervoso/nervoso2.asp#tiposneuro>. Acesso em; 5 de setembro de 2006.

VON ZUBEN, F. J., Modelos e Aplicações de Redes Neurais Artificiais - Parte I - **Baseado em Notas de Aula da disciplina Inteligência Artificial de pós-graduação**. 2006. FEEC/ UNICAMP. Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ea072_2s06/notas_de_aula/topicoP L2_06_Partel.pdf>. Acesso em: 23 de novembro de 2007.

VON ZUBEN, F. J.; CASTRO, L. N., Redes Neurais com Função de Ativação de Base Radial. 2005. **Baseado em Notas de Aula da disciplina Inteligência Artificial de pós-graduação**. FEEC/ UNICAMP. Disponível em:

<ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia353_05/topico8_05.pdf>. Acesso em: 23 de novembro de 2007.

WELTY, J. R., WICKS C. E. & WILSON, R. E. - Fundamentals of Momentum, Heat and Mass Transfer, **John Wiley & Sons**, 3th Edition, 1986.

WHELTON, P. K. et al. Effects of oral potassium on blood pressure. Meta-analysis of randomized controlled clinical trials. **JAMA** 1997; 277: 1624-32.

WOODWARD, L. & MEIER-PLOEGER, A. "Raindrops on Roses and Whiskers no Kittens": Consumer's Perceptions of Organic Food Quality ? In: INTERNATIONAL IFOAM SCIENTIFIC CONFERENCE, 12th, (1998: Mar del Plata). **Proceedings...** Tholey-Theley: IFOAM, 1999. p. 81- 88.

YUSSEFI, M. Development and State of Organic Agriculture World-wide. In: YUSSEFI, M. & WILLER, H. (Org.) The World of Organic Agriculture 2003 -**Statistics and Future Prospects**. IFOAM Publication, 5th revised edition, February 2003, 130 pages, ISBN 3-934055-22-2.

ZAKOWSKA-BIEMANS, S. Organic Foods and Farming in the Perception of Polish Consumers. In: IFOAM Organic World Congress, 14th, (2002: Victoria, BC, Canada). **Proceedings...** Ottawa: COG/ IFOAM, 2002. p. 185.

ZORRILA, S. E. e RUBIOLLO, A. C. Modelling average concentrations of salt and salt substitute in partial or total volumes of semihard cylindrical cheeses. **International Journal of Food Science and Technology**, v.33, p 501-508, 1998.

ZURADA, J. M., **Intruducion to Artificial Neural Systems**. Boston, Mass: West Publishing Company, 1992.

ANEXOS

ANEXO 1 – Tabela com as medidas e volume dos três tamanhos de queijo

Italac 0,5 kg					Tirolez 2,0 kg				Tirolez 3,0 kg			
	X	Y	Z	Volume(cm3)	X	Y	Z	Volume (cm3)	X	Y	Z	Volume (cm3)
1,0	4,1	6,8	15,7	437,7	9,5	9,0	20,0	1710,00	8,0	11,7	24,4	2283,8
2,0	4,5	6,8	14,0	428,4	9,3	9,1	20,2	1709,53	8,0	11,6	24,3	2255,0
3,0	4,7	6,5	13,3	406,3	9,4	8,9	20,4	1706,66	7,4	12,2	23,8	2148,7
4,0	4,8	6,3	13,0	393,1	9,7	9,3	19,6	1768,12	9,1	11,2	24,0	2446,1
5,0	4,5	6,7	14,1	425,1	9,3	8,9	20,3	1680,23	7,4	11,2	23,5	1947,7
6,0	4,8	6,3	13,9	420,3	9,6	9,0	20,5	1771,20	8,1	11,8	23,7	2265,2
7,0	4,2	6,3	13,8	365,1	9,5	9,4	19,8	1768,14	9,0	11,7	23,5	2474,6
8,0	4,4	6,6	13,1	380,4	9,2	8,8	20,1	1627,30	7,4	12,8	23,2	2197,5
9,0	5,0	6,2	13,4	415,4	9,8	8,7	20,2	1722,25	9,1	11,9	24,2	2620,6
10,0	4,5	6,6	13,2	392,0	9,1	9,5	20,6	1780,87	7,3	12,9	23,3	2194,2
média	4,6	6,5	13,8	406,4	9,4	9,1	20,2	1724,4	8,1	11,9	23,8	2283,3
dp	0,3	0,2	0,8	23,2	0,2	0,3	0,3	48,7	0,7	0,6	0,4	189,8

ANEXO 2 – Tabela formulada no statistica 7.1 para estudo do queijo prato

Amostra	X	Y	Z	volume	NaCl	KCl	Contorno	Tempo	NaClf	KClf	Amostragem
1	4,6	6,5	13,8	412,12	10	10	com agitação	1	1,8264	1,9048	1
2	4,6	6,5	13,8	412,12	10	10	com agitação	2	2,056	2,1422	2
3	4,6	6,5	13,8	412,12	10	10	com agitação	3	2,2587	2,3507	1
4	4,6	6,5	13,8	412,12	10	10	com agitação	4	2,4419	2,5385	1
5	4,6	6,5	13,8	412,12	10	10	com agitação	5	2,6098	2,7103	2
6	4,6	6,5	13,8	412,12	10	10	com agitação	6	2,7652	2,8692	1
7	4,6	6,5	13,8	412,12	10	10	com agitação	7	2,9103	3,0172	2
8	4,6	6,5	13,8	412,12	10	10	com agitação	8	3,0466	3,156	1
9	4,6	6,5	13,8	412,12	10	10	com agitação	9	3,1752	3,2869	1
10	4,6	6,5	13,8	412,12	10	10	com agitação	10	3,2971	3,4108	1
11	4,6	6,5	13,8	412,12	10	10	com agitação	11	3,413	3,5287	1
12	4,6	6,5	13,8	412,12	10	10	com agitação	12	3,5237	3,641	2
.											
.											
500	9,4	9,1	20,2	1727,908	13	7	sem agitação	8	2,062	1,4486	3
501	9,4	9,1	20,2	1727,908	13	7	sem agitação	9	2,1642	1,5144	3
502	9,4	9,1	20,2	1727,908	13	7	sem agitação	10	2,2617	1,5772	3
503	9,4	9,1	20,2	1727,908	13	7	sem agitação	11	2,355	1,6373	3
504	9,4	9,1	20,2	1727,908	13	7	sem agitação	12	2,4448	1,695	3

ANEXO 3 – Exemplo da tabela formulada no Statistica para o estudo da classificação de hortícolas quanto seu tipo de cultivo

amostragem	Var1	Na-BU	Mg-BU	Al-BU	P-BU	K-BU	Ca-BU	Fe-BU	Mn-BU	Co-BU	Cu-BU	classe
trein	65	48,8405	367,0524	9,9484177	408,6916	3334,0593	1096,8792	20,0855665	3,6030029	0,0268088	0,9036562	conv
trein	69	75,7617	381,3369	20,7922071	530,061	3709,2531	1030,5939	24,222072	2,5466406	0,0260064	0,7899444	conv
trein	72	214,245	637,353	5,272911	595,953	3523,14	824,9985	9,793998	15,247206	0,0468855	1,9251	conv
trein	73	23,4544	370,4768	7,3402	459,5864	2658,2224	916,6904	12,915328	3,533568	0,017548	0,8437592	conv
val	94	17,7755841	55,0981635	2,2834371	156,077798	1105,67859	280,477306	4,0388121	1,2293061	0,0046206	0,2426721	conv
val	95	24,8040765	59,841873	1,9593798	250,730111	1232,36168	420,80959	5,1247371	1,3486116	0,0041013	0,3328563	conv
trein	151	6,771714	13,456714	7,908928	61,939772	996,280448	19,9798224	0,5043164	0,5453814	0,001719	0,552181	org
trein	62	31,85	386,6625	2,3328375	406,0875	2710,4875	669,9875	8,2705	1,518475	0,01155	0,4354	org
trein	63	36,1018	290,0128	17,9039462	281,1746	3129,6965	746,4534	37,2264235	3,3231632	0,0378994	0,5556082	org
trein	64	13,3584	655,9784	25,3076912	457,7276	3154,91	1254,0704	43,986074	2,7416092	0,0160908	0,6316904	org
val	66	230,7265	621,6005	15,048975	515,569	3536,122	1252,7365	19,4484265	3,2119965	0,015485	0,9247805	org
val	132	12,3496068	50,6390312	5,5669692	169,244634	1398,39323	472,631678	12,3304612	2,19248	0,0064076	0,4503076	org
trein	3	113,4224	104,6812	1,10331	113,1559	2659,6167	432,0498	8,1016	1,96144	0,008528	0,23985	hidr
trein	17	29,9907	249,8238	0,9306	237,3453	2738,8404	328,7133	5,38479	1,808325	0,0947097	0,892107	hidr
trein	32	171,696	307,377	4,012365	208,005	1519,245	1021,1355	16,1994	7,824516	0,0187425	6,587511	hidr
trein	41	136,4316	458,7132	6,0398772	335,0256	2115,7872	856,4676	9,7089456	3,0444	0,0092748	0,4434912	hidr
val	67	197,6148	467,0172	6,88806	385,9272	2002,4028	995,418	11,0420712	1,3120668	0,007038	0,4101012	hidr
val	146	7,3407334	24,7664495	0,9972092	224,601218	1290,16778	320,461344	4,4671913	2,772003	0,0040404	0,457912	hidr

Zn-BU	Se-BU	Cd-BU	Hg-BU	Pb-BU	Soma Minerais BU	Frutose BU	Glicose BU	Sacarose BU	Maltose BU
4,6722177	0,0402132	0,0304451	0	0,0280922	5294,86142	0,260958	0	0	0,072013
5,816223	0,0391902	0,0146286	0,0014448	0,0474978	5781,30245	0,210399	0,121002	0	0
19,8505755	0,043677	0,0493695	0,000621	0,0301185	5847,94996	0,23598	0,145935	0,09522	0,08073
5,5671672	0,021828	0,013696	0	0,0331272	4458,71662	0,234544	0,087312	0	0
2,5522473	0,0350169	0,0110079	0,0050736	0,0236466	1625,53329	0,17667	0,079275	0	0
2,9970087	0,0642537	0,0199206	0,005208	0,0094395	2000,41285	0,335265	0,25389	0	0
0,3997248	0,0803346	0,0027886	0,000573	0,0203224	1108,44474	0,018718	0	0	0
7,9830625	0,17675	0,1414875	0,0032375	0,028175	4225,97647	0,14	0	0,06475	0
2,5540151	0,1041859	0,0078645	0,0041944	0,0337799	4545,19018	0,135569	0	0,141561	0
3,9664328	0,0686136	0,0090068	0,0021252	0,0512072	5612,82534	0,274252	0	0	0
6,3632755	0,059006	0,015974	0,0008965	0,0688675	6201,91218	0,168705	0	0	0
3,407994	0,1114768	0,017756	0,0032424	0,0253988	2127,37068	0,187596	0,13124	0,071796	0,0579
3,42719	0,011726	0,004797	0,027716	0,022386	3437,83454	0,011193	0	0	0
3,3791355	0,0335862	0,0972054	0,0233919	0,0136629	3597,37101	0	0	0	0
6,4538145	0,039984	0,00574035	0,0055125	0,0841575	3268,69024	0,03087	0,252105	0,125685	0
2,9192256	0,0758268	0,0039648	0,001416	0,0408516	3924,71247	0,19824	0,045312	0,090624	0
2,5980012	0,0201348	0,0042228	0,0088128	0,0273564	4070,69787	0,289476	0,204408	0,106488	0
0,9127456	0,0504569	0,0036075	0,0012025	0,0218374	1877,02573	0,263588	0	0	0

S. Açú BU	Nitrito BU	Nitrato BU	Soma N/N BU	Cinzas BU	Fibras BU	Lipídios BU	Proteínas BU	Carboidratos BU	Energia BU
0,332971	97,477795	1,015312	98,493107	1,094455	1,84667	0,589651	2,307981	3,137913	19,704468
0,331401	2,93475	2,119341	5,054091	1,286775	2,432682	0,612234	2,803815	4,327176	24,304245
0,557865	13,656825	2,56059	16,217415	1,1385	2,418795	0,682065	3,161925	5,36751	30,58218
0,321856	0	1,358472	1,358472	1,147896	2,386528	0,365512	2,827368	4,219224	21,929008
0,255945	61,36791	0,859341	62,227251	0,978027	1,274742	0,281766	1,147902	2,121852	10,519566
0,589155	0	0,430962	0,430962	0,883407	1,58193	0,374976	1,351476	3,900141	18,053532
0,018718	42,491006	1,629612	44,120618	0,959966	1,3179	0,161204	0,929024	1,769806	6,974556
0,20475	143,780875	779,030875	922,81175	0,644875	2,258375	0,5775	2,482375	5,62275	23,387875
0,27713	0,223951	0,784203	1,008154	1,1984	2,245502	0,39697	3,416938	2,874662	16,183643
0,274252	10,657372	714,55296	725,210332	1,535204	3,404368	0,585948	3,246496	4,752352	23,653476
0,168705	53,080135	0,9291	54,009235	1,322745	2,22006	0,67971	0,54768	5,599865	21,82733
0,448532	0	1,070764	1,070764	1,260676	2,360776	0,321152	1,78332	4,354852	18,001496
0,011193	56,111575	306,063524	362,175099	1,21524	1,133158	0,404014	0,401349	3,310463	13,946478
0	18,054486	156,47193	174,526416	1,019853	1,076112	0,11421	0,375624	2,720313	9,10719
0,40866	125,23665	9,608655	134,845305	0,913605	1,96539	0,663705	2,095485	3,677205	21,201075
0,334176	39,0108	35,009184	74,019984	1,0974	2,174976	0,346212	2,00718	3,629208	16,960848
0,600372	14,216148	0,299268	14,515416	0,806004	2,0196	0,317016	1,519596	3,477384	14,762664
0,263588	80,827721	1,108705	81,936426	0,994227	1,32756	0,203463	0,073593	3,538717	11,144289

Obs: Foi feita uma tabela dessa para cada tipo de hortícola