

NAIARA BARBOSA CARVALHO

**REDES NEURAIS ARTIFICIAIS APLICADAS À ANÁLISE SENSORIAL  
DE REQUEIJÃO *LIGHT***

Dissertação apresentada à  
Universidade Federal de Viçosa, como  
parte das exigências do Programa de  
Pós-Graduação em Ciência e Tecnologia  
de Alimentos, para obtenção do título de  
*Magister Scientiae*.

VIÇOSA  
MINAS GERAIS – BRASIL  
2011

NAIARA BARBOSA CARVALHO

**REDES NEURAIS ARTIFICIAIS APLICADAS À ANÁLISE SENSORIAL  
DE REQUEIJÃO *LIGHT***

Dissertação apresentada à  
Universidade Federal de Viçosa, como  
parte das exigências do Programa de  
Pós-Graduação em Ciência e Tecnologia  
de Alimentos, para obtenção do título de  
*Magister Scientiae*.

APROVADA: 18 de julho de 2011.

---

Prof. Luis Antonio Minim  
(Co-orientador)

---

Prof<sup>a</sup>. Suzana Maria Della Lucia  
(Co-orientadora)

---

Prof. Sérgio Henriques Saraiva

---

Prof. Renato Souza Cruz

---

Prof<sup>a</sup>. Valéria Paula Rodrigues Minim  
(Orientadora)

*“O Bom Deus não seria capaz de  
inspirar-me desejos irrealizáveis.”  
(Santa Teresinha do Menino Jesus)*

## AGRADECIMENTOS

A Deus em primeiro lugar, pela vida, pela saúde, pela forte amizade e por iluminar o meu caminho em todos os momentos.

À minha mãe Tânia pelas palavras de amor e conforto, pela presença amiga mesmo que de longe e pelo grande exemplo de superação. Ao meu pai Ricardo, pelo exemplo de luta e fibra, por ter abdicado muitas vezes de seus sonhos para me oferecer uma boa educação e para que eu realizasse os meus. Não tenho nem palavras para expressar toda minha gratidão... Amo vocês!!!

À minha querida amiga e irmã Lauana, por sempre me apoiar em todas as etapas e por ser uma fiel torcedora pelo meu sucesso e minha felicidade.

Ao Lucas, meu querido namorado, por toda compreensão, carinho, pelas palavras de ânimo nos momentos mais difíceis e pela amizade sempre. Obrigada por fazer parte da realização deste sonho! Te amo muito!!!

À Prof<sup>a</sup>. Valéria Paula Rodrigues Minim, pela orientação e disponibilidade em todos os momentos em que precisei de sua atenção. Pela amizade e pelos valiosos conselhos nestes três anos de trabalho e convivência. Por ser uma pessoa tão humana e com bondade de coração, te admiro muito como profissional e pessoa!

Ao Prof<sup>o</sup>. Luis Antonio Minim, pelos ensinamentos, atenção e conselhos. Obrigada pela oportunidade de aprender tanto com você!

À Prof<sup>a</sup>. Suzana Maria Della Lucia, pela amizade que se iniciou no meu primeiro período de graduação, por ser sempre tão disponível, prestativa, e pelas valiosas contribuições no desenvolvimento da minha dissertação.

Ao Prof<sup>o</sup>. Leandro Soares e ao Roney, por terem passado seus conhecimentos e experiência neste assunto de forma tão agradável, clara e objetiva, pelas sugestões, idéias e pela enorme contribuição para que este trabalho fosse concluído.

Aos Profs. Sérgio Henriques Saraiva e Renato Souza Cruz pela participação na banca de defesa de dissertação.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa, à Universidade Federal de Viçosa, e em

especial, ao Departamento de Tecnologia de Alimentos, pela oportunidade de realização deste trabalho e pela minha formação acadêmica.

Aos meus avós, tios (as), primos (as), afilhado, cunhados (as), obrigada pelas orações, pela corrente de torcida formada com muito amor para que eu concluísse com vitória mais esta etapa.

Com muita saudade quero agradecer à minha prima Juliana, pela convivência inesquecível desde criança, pelas suas gargalhadas marcantes que tanto nos alegrava, pelo seu jeitinho único. Sei que está aí junto de Deus olhando por nós e sei o quanto torcia por mim também!!! SAUDADE JU!

Aos meus sogros Ieda e Zé Carlos por me acolherem como filha, pelo carinho e cuidado.

Agradeço de forma muito especial às minhas amigas Cláudia e Ritinha, pela participação e dedicação em todas as etapas do meu trabalho, pelas sugestões e correções as quais foram muito úteis e essenciais para a execução do passo-a-passo desta pesquisa.

Aos meus amigos e colegas de curso, em especial à Claudinha, Taline, Elaine, Regiane, Tati, Rafael e Henrique, por todos os momentos vividos durante esta trajetória.

Aos meus amados amigos de Sete Lagoas, Tia Nai, Tereza, Vinícius, Vanessa, Tomás, Luíza, Jansen, João Marcos, Alessandra, Flávio e Hudson, por toda experiência compartilhada nos tempos de ensino médio e fundamental, pelo apoio incondicional, pela torcida e pela amizade que não se findou a essa época.

À “turma” de amigos do bairro São Geraldo e agregados, por terem feito parte de uma das épocas mais felizes em minha vida, pela lembrança feliz e saudosa que tenho desses nossos velhos tempos. Agradeço em especial ao Juliano (Ju) pela amizade sólida, por ser sempre tão presente, pela sua sinceridade e verdade em nossos momentos de convívio.

À minhas amigas de república, que durante estes sete anos vividos em Viçosa foram a minha segunda família. Obrigada Lau, Tereza, Alaila, Tia Nai, Isabela e Nínive pelos momentos alegres e divertidos, pela convivência saudável, pelos laços criados!

À equipe do laboratório de Análise Sensorial: Aline, Inês, Rita, Márcia, Maria Patrícia, Simone, Érika, Ana Cristina, Gabrielle, Renata, Liliane, Jociele,

Andrea, Paula, Vanelle e Luiz Paulo, pela convivência adorável e por terem tornado essa fase mais leve, divertida.

À equipe do laboratório do Minim: Lizzy, Vanessa, Janaína, Priscila, Guilherme, Ana Paula, Isabela, Milene, Cecília, Leandro, Roney, por terem me recebido com carinho no laboratório durante o meu experimento, pelas conversas e risadas.

À Pequena Via de Santa Teresinha que me proporcionou fortes ensinamentos, que contribuiu para minha formação humana e espiritual, que me fez acreditar que “O amor tudo vence”, e por ter sido um local em que encontrei pessoas tão boas e abençoadas por Deus!

Aos funcionários do Departamento de Tecnologia de Alimentos, pela ajuda, apoio e amizade.

E a todos que contribuíram para a realização deste trabalho e para que este tão sonhado momento se tornasse realidade.

## **BIOGRAFIA**

NAIARA BARBOSA CARVALHO, filha de Ricardo José de Carvalho e Tânia D'arc Barbosa Carvalho, nasceu em 09 de agosto de 1985, na cidade de Sete Lagoas - MG.

Em 2000, concluiu o ensino fundamental no Colégio João Herculino e em 2003 concluiu o ensino médio no Colégio Impulso, ambos em Sete Lagoas – MG.

Ingressou na Universidade Federal de Viçosa – MG, em março de 2004, onde se graduou em Engenharia de Alimentos em julho de 2009.

Em agosto do mesmo ano, iniciou o curso de Mestrado no programa de Pós-graduação em Ciência e Tecnologia de Alimentos na Universidade Federal de Viçosa, submetendo-se à defesa da dissertação no dia 18 de julho de 2011.

# ÍNDICE

|                                                                |      |
|----------------------------------------------------------------|------|
| LISTA DE TABELAS .....                                         | x    |
| LISTA DE FIGURAS .....                                         | xi   |
| RESUMO.....                                                    | xiii |
| ABSTRACT .....                                                 | xv   |
| REFERÊNCIAS.....                                               | 3    |
| CAPÍTULO 1 .....                                               | 4    |
| REVISÃO DE LITERATURA .....                                    | 5    |
| 1 – ANÁLISE SENSORIAL DE ALIMENTOS .....                       | 5    |
| 2 – CORRELAÇÕES ENTRE MEDIDAS SENSORIAIS E INSTRUMENTAIS ..... | 7    |
| 3 – REDES NEURAIS ARTIFICIAIS .....                            | 8    |
| 3.1 – ANALOGIA DAS REDES NEURAIS COM O CÉREBRO HUMANO.....     | 9    |
| 3.2 – COMPONENTES DE UM NEURÔNIO ARTIFICIAL .....              | 11   |
| 3.3 – ARQUITETURA E TOPOLOGIA DAS RNA'S.....                   | 13   |
| 3.4 – FASES USUAIS NA SOLUÇÃO DE PROBLEMAS POR RNA'S .....     | 16   |
| 3.5 – TIPOS DE APRENDIZADO .....                               | 17   |
| 3.5.1 - Algoritmo <i>back-propagation</i> .....                | 19   |
| 3.6 – BENEFÍCIOS DE UMA RNA.....                               | 21   |
| 3.7 – APLICAÇÕES DAS RNA'S .....                               | 23   |
| 5 - REFERÊNCIAS.....                                           | 26   |
| CAPÍTULO 2 .....                                               | 31   |
| 1- INTRODUÇÃO .....                                            | 32   |
| 2 - MATERIAIS E MÉTODOS .....                                  | 35   |
| 2.1 - DADOS EXPERIMENTAIS .....                                | 35   |



|                                                                                                        |    |
|--------------------------------------------------------------------------------------------------------|----|
| 2.1.1 - AMOSTRAS .....                                                                                 | 35 |
| 2.1.2 - ANÁLISE DESCRITIVA QUANTITATIVA (ADQ) .....                                                    | 36 |
| 2.1.3 - AVALIAÇÃO INSTRUMENTAL .....                                                                   | 37 |
| 2.2 - MODELAGEM UTILIZANDO REDES NEURAS ARTIFICIAIS .....                                              | 38 |
| 3- RESULTADOS E DISCUSSÃO .....                                                                        | 40 |
| 3.1 - TREINAMENTO DA REDE NEURAL .....                                                                 | 40 |
| 3.2 - SELEÇÃO DA MELHOR ARQUITETURA DA REDE DE PREDIÇÃO .....                                          | 42 |
| 3.3 - ESCOLHA DO MELHOR NÚMERO DE ITERAÇÕES .....                                                      | 42 |
| 3.4 - DESEMPENHO DA RNA ÓTIMA .....                                                                    | 44 |
| 4 - CONCLUSÃO .....                                                                                    | 48 |
| 5 – REFERÊNCIAS .....                                                                                  | 49 |
| CAPÍTULO 3 .....                                                                                       | 52 |
| 1- INTRODUÇÃO .....                                                                                    | 53 |
| 2 - MATERIAIS E MÉTODOS .....                                                                          | 56 |
| 2.1 - DADOS EXPERIMENTAIS .....                                                                        | 56 |
| 2.2 - ACEITABILIDADE SENSORIAL .....                                                                   | 56 |
| 2.3 - MODELAGEM UTILIZANDO REDES NEURAS ARTIFICIAIS .....                                              | 56 |
| 3 - RESULTADOS E DISCUSSÃO .....                                                                       | 59 |
| 3.1 - TREINAMENTO DA REDE NEURAL COM AS NOTAS DE ACEITAÇÃO SENSORIAL<br>ORIGINAIS E TRANSFORMADAS..... | 59 |
| 3.2 – ESCOLHA DA MELHOR ARQUITETURA DA REDE 1 E REDE 2.....                                            | 61 |
| 3.3 - ESCOLHA DO MELHOR NÚMERO DE ITERAÇÕES PARA AS REDE 1 E REDE 2.....                               | 62 |
| 3.4 - DESEMPENHO DAS RNA'S ÓTIMAS.....                                                                 | 64 |
| 4 – CONCLUSÃO.....                                                                                     | 68 |
| 5 - REFERÊNCIAS.....                                                                                   | 69 |
| CAPÍTULO 4 .....                                                                                       | 72 |

|                                                                                                     |    |
|-----------------------------------------------------------------------------------------------------|----|
| 1 - INTRODUÇÃO .....                                                                                | 73 |
| 2 - MATERIAIS E MÉTODOS .....                                                                       | 76 |
| 2.1- DADOS EXPERIMENTAIS .....                                                                      | 76 |
| 2.1.1- AMOSTRAS .....                                                                               | 76 |
| 2.1.2 – ANÁLISE DESCRITIVA QUANTITATIVA (ADQ) .....                                                 | 76 |
| 2.2 - MODELAGEM UTILIZANDO RNA PARA PREDIÇÃO DE ATRIBUTOS SENSORIAIS.....                           | 77 |
| 2.3 - MODELAGEM UTILIZANDO RLM PARA PREDIÇÃO DE ATRIBUTOS SENSORIAIS.....                           | 79 |
| 2.4 – COMPARAÇÃO ENTRE OS MODELOS DA RNA DE MELHOR DESEMPENHO E DA RLM.....                         | 80 |
| 3- RESULTADOS E DISCUSSÃO .....                                                                     | 82 |
| 3.1- TREINAMENTO DA REDE NEURAL COM MEDIDAS DOS ATRIBUTOS SENSORIAIS ORIGINAIS E TRANSFORMADAS..... | 82 |
| 3.3 – ESCOLHA DA MELHOR ARQUITETURA DA REDE 1 E REDE 2.....                                         | 83 |
| 3.2- ESCOLHA DO MELHOR NÚMERO DE ITERAÇÕES DAS RNA'S.....                                           | 85 |
| 3.4- DESEMPENHO DAS RNA'S ÓTIMAS .....                                                              | 87 |
| 3.5 – MODELAGEM POR RLM .....                                                                       | 90 |
| 3.6 – COMPARAÇÃO ENTRE OS MODELOS DA RNA DE MELHOR DESEMPENHO (REDE 2) E DA RLM .....               | 90 |
| 4 – CONCLUSÃO.....                                                                                  | 94 |
| 5 - REFERÊNCIAS.....                                                                                | 95 |
| CONCLUSÃO GERAL .....                                                                               | 98 |

## LISTA DE TABELAS

|                                                                                                                                                                        |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| TABELA 1. 1 - FUNÇÕES DE ATIVAÇÃO: TIPOS, EQUAÇÃO E VALORES-LIMITES. ....                                                                                              | 12 |
| TABELA 2. 1 - ATRIBUTOS SENSORIAIS LEVANTADOS PELA EQUIPE DE JULGADORES, SUAS RESPECTIVAS DEFINIÇÕES E PADRÕES QUE ANCORAM OS EXTREMOS DA ESCALA NÃO ESTRUTURADA. .... | 37 |
| TABELA 2. 2 - PARÂMETROS QUE CARACTERIZAM O <i>DESIGN</i> DA RNA ÓTIMA. ....                                                                                           | 44 |
| TABELA 3. 1 – PARÂMETROS DAS RNA'S PARA REDE 1 E REDE 2. ....                                                                                                          | 64 |
| TABELA 3. 2 – DESEMPENHO DA REDE 1 E DA REDE 2. ....                                                                                                                   | 65 |
| TABELA 3. 3 – AVALIAÇÃO DA PRECISÃO DA CLASSIFICAÇÃO ....                                                                                                              | 66 |
| TABELA 4. 1 - ATRIBUTOS SENSORIAIS LEVANTADOS PELA EQUIPE DE JULGADORES, SUAS RESPECTIVAS DEFINIÇÕES E PADRÕES QUE ANCORAM OS EXTREMOS DA ESCALA NÃO ESTRUTURADA. .... | 77 |
| TABELA 4. 2 – PARÂMETROS DAS RNA'S PARA OS DADOS ORIGINAIS E DADOS TRANSFORMADOS. ....                                                                                 | 87 |
| TABELA 4. 3 – VALORES DA RAIZ QUADRADA DO ERRO QUADRADO MÉDIO ( <i>RMSE</i> ) OBTIDOS PARA A REDE 1 E REDE 2 ÓTIMAS. ....                                              | 87 |
| TABELA 4. 4 - MODELAGEM ESTATÍSTICA DO EFEITO DA GORDURA E DA ÁGUA NOS ATRIBUTOS SENSORIAIS DO REQUEIJÃO <i>LIGHT</i> ADICIONADO DE CPS. ....                          | 90 |
| TABELA 4. 5 – <i>RMSE</i> PARA OS DADOS DO CONJUNTO DE VALIDAÇÃO. ....                                                                                                 | 93 |

## LISTA DE FIGURAS

|                                                                                                                                                                              |    |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 1. 1 - ESQUEMA DE UM NEURÔNIO CEREBRAL.....                                                                                                                           | 10 |
| FIGURA 1. 2 - REPRESENTAÇÃO TÍPICA DE UM NEURÔNIO ARTIFICIAL.                                                                                                                | 10 |
| FIGURA 1. 3 - REPRESENTAÇÃO SIMBÓLICA DE UM NEURÔNIO CONSISTINDO DE UM NÓ DE PROCESSAMENTO E CONEXÕES SINÁPTICAS.....                                                        | 13 |
| FIGURA 1. 4 - REDE <i>FEEDFORWARD</i> COM DOIS NÓS DE ENTRADA, QUATRO NEURÔNIOS EM CADA CAMADA OCULTA E UM NEURÔNIO NA SAÍDA. ....                                           | 15 |
| FIGURA 2. 1 - DISPOSIÇÃO DOS PONTOS EXPERIMENTAIS NO DELINEAMENTO COMPOSTO CENTRAL ROTACIONAL (DCCR).....                                                                    | 35 |
| FIGURA 2. 2 - DISPERSÃO DAS NOTAS ORIGINAIS E DAS NOTAS TRANSFORMADAS DOS ATRIBUTOS CONSISTÊNCIA E ESPALHABILIDADE DO REQUEIJÃO LIGHT. ....                                  | 41 |
| FIGURA 2. 3 - ARQUITETURA SELECIONADA PARA RNA DE PREDIÇÃO DOS ATRIBUTOS SENSORIAIS CONSISTÊNCIA E ESPALHABILIDADE. ...                                                      | 42 |
| FIGURA 2. 4 - EFEITO DO NÚMERO DE ITERAÇÕES NO RMSE DO CONJUNTO DE TREINAMENTO E VALIDAÇÃO.....                                                                              | 43 |
| FIGURA 2. 5 – GRÁFICO DOS RESÍDUOS PARA AS MEDIDAS DE CONSISTÊNCIA E ESPALHABILIDADE PREDITAS PELA RNA ÓTIMA PARA OS DADOS DO CONJUNTO DE TREINAMENTO E TESTE/VALIDAÇÃO..... | 45 |
| FIGURA 2. 6 - COMPARAÇÃO ENTRE OS VALORES EXPERIMENTAIS E PREDITOS PELA RNA ÓTIMA PARA O ATRIBUTO DE CONSISTÊNCIA.....                                                       | 46 |
| FIGURA 2. 7 - COMPARAÇÃO ENTRE OS VALORES EXPERIMENTAIS E PREDITOS PELA RNA ÓTIMA PARA O ATRIBUTO DE ESPALHABILIDADE. ....                                                   | 46 |
| FIGURA 3. 1 - DISPERSÃO DAS NOTAS DE ACEITAÇÃO ORIGINAIS ATRIBUÍDAS PELOS 100 CONSUMIDORES ÀS FORMULAÇÕES 1 E 3 DO REQUEIJÃO <i>LIGHT</i> . ....                             | 60 |

|                                                                                                                                                          |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| FIGURA 3. 2 - DISPERSÃO DAS NOTAS DE ACEITAÇÃO TRANSFORMADAS ATRIBUÍDAS PELOS 100 CONSUMIDORES ÀS FORMULAÇÕES 1 E 3 DO REQUEIJÃO <i>LIGHT</i> .....      | 60 |
| FIGURA 3. 3 - ARQUITETURA DA REDE 1 E REDE 2 ÓTIMAS. ....                                                                                                | 61 |
| FIGURA 3. 4 – INFLUÊNCIA DO NÚMERO DE ITERAÇÕES NO RMSE DE TREINAMENTO E VALIDAÇÃO DAS REDES 1 E 2, RESPECTIVAMENTE. .                                   | 63 |
| FIGURA 4. 1 - DISPERSÃO DAS NOTAS DOS ATRIBUTOS SENSORIAIS ADESIVIDADE E ESPALHABILIDADE ATRIBUÍDAS ÀS NOVE FORMULAÇÕES DO REQUEIJÃO <i>LIGHT</i> . .... | 84 |
| FIGURA 4. 2 – REPRESENTAÇÃO DA CONFIGURAÇÃO ÓTIMA DA REDE 1 E DA REDE 2. ....                                                                            | 85 |
| FIGURA 4. 3 – INFLUÊNCIA DO NÚMERO DE ITERAÇÕES NO RMSE DE TREINAMENTO E VALIDAÇÃO DAS REDES 1 E 2, RESPECTIVAMENTE. .                                   | 86 |
| FIGURA 4. 4 - COMPARAÇÃO ENTRE OS VALORES EXPERIMENTAIS E PREDITOS PELA REDE 1 E PELA REDE 2 PARA OS SEIS ATRIBUTOS ESTUDADOS. ....                      | 89 |
| FIGURA 4. 5 - COMPARAÇÃO ENTRE OS VALORES EXPERIMENTAIS E PREDITOS PELA REDE 2 E PELA RLM PARA OS SEIS ATRIBUTOS ESTUDADOS. ....                         | 92 |

## RESUMO

CARVALHO, Naiara Barbosa, M. Sc., Universidade Federal de Viçosa, julho de 2011. **Redes neurais artificiais aplicadas à análise sensorial de requeijão *light***. Orientadora: Valéria Paula Rodrigues Minim. Co-orientadores: Luis Antonio Minim e Suzana Maria Della Lucia.

O presente trabalho objetivou desenvolver modelos matemáticos empregando a técnica de Redes Neurais Artificiais (RNA's) como alternativa potencial aos métodos estatísticos tradicionais para modelar as características sensoriais do requeijão *light* por meio de medidas instrumentais, da composição química, bem como a aceitabilidade sensorial do consumidor frente às diferentes texturas. Todas as RNA's desenvolvidas foram do tipo multicamadas *feedforward*, treinadas por meio do algoritmo *back-propagation*. Os dados utilizados para treinar e testar/validar as RNA's foram obtidos da caracterização reológica e sensorial de nove formulações de requeijão *light*. Inicialmente, foi desenvolvida uma rede de 8-3-9-2 neurônios em suas camadas para estabelecer a relação entre medidas instrumentais (firmeza, gomosidade, mastigabilidade, elasticidade, coesividade, tensão inicial, viscosidade aparente, tangente  $\delta$ ,) e os atributos sensoriais de consistência e espalhabilidade. Um apropriado método de transformação dos dados foi aplicado para reduzir as variações das notas sensoriais atribuídas pelos julgadores treinados. Essa RNA foi a que melhor se adequou à modelagem dos dados em questão, apresentando excelente capacidade de generalização, com um erro (RMSE) de validação de 0,0506. Em uma segunda etapa, foram construídas duas RNA's, Rede 1 (com dados originais) e Rede 2 (com dados transformados), as quais foram comparadas quanto ao seu desempenho para classificar os requeijões em diferentes classes de aceitação ("Aceito" e "Rejeitado") a partir das medidas instrumentais descritas acima. A rede ótima apresentou uma arquitetura caracterizada por 8-3-3-2 neurônios em suas camadas e foi desenvolvida com os dados transformados (Rede 2), a qual apresentou um ótimo desempenho na classificação das duas categorias de aceitação, bem superior se comparado à Rede 1. Além disso, demonstrou uma

excelente capacidade de generalização, com um baixo erro (RMSE) de validação de 0,1022. Posteriormente, foi estabelecida a relação entre os dados de composição química (teor de gordura e teor de água) do requeijão e seus atributos sensoriais (consistência, espalhabilidade, aroma característico, sabor característico, viscosidade e adesividade), RNA essa, que também foi analisada em relação às medidas originais dos atributos sensoriais (Rede 1) e medidas transformadas (Rede 2). Verificou-se que usando uma adequada transformação dos dados, a Rede 2, composta por 2-15-6-6 neurônios em suas camadas, apresentou uma excelente capacidade de predição dos atributos sensoriais com um erro (RMSE) dos dados do conjunto de validação igual a 0,0632. Em seguida, esta técnica de modelagem foi comparada com o modelo de Regressão Linear Múltipla (RLM) apresentando as mesmas condições para construção e validação dos modelos. Constatou-se, por meio de um teste t pareado, que o modelo de RNA apresentou melhor desempenho que a RLM ao nível de 10 % de significância. Assim, constata-se que uma excelente e promissora alternativa, para indústria de alimentos, na modelagem de dados que caracterizam diferentes texturas do requeijão *light*, a fim de atingir os anseios e necessidades dos consumidores, é o uso da ferramenta denominada RNA, visto que elas necessitam apenas de um conjunto representativo de dados de entrada-saída para aprender as relações implícitas nesses, predizendo e classificando acertadamente as variáveis dependentes de interesse. Além de apresentarem vantagens atrativas para aplicações industriais como precisão, simplicidade e baixo custo para sua implementação.

## ABSTRACT

CARVALHO, Naiara Barbosa, M. Sc., Universidade Federal de Viçosa, July, 2011. **Artificial neural networks applied to the sensory analysis of light cream cheese.** Adviser: Valéria Paula Rodrigues Minim. Co-advisers: Luis Antonio Minim and Suzana Maria Della Lucia.

This study aimed to develop mathematical models using the technique of Artificial Neural Networks (ANN) as a potential alternative to traditional statistical methods for modeling of the sensory characteristics of light cream cheese by means of instrumental measurements, chemical composition and the sensory acceptability of the consumer based on different textures. All ANN's developed were multilayer *feedforward* networks, trained using the *back-propagation* algorithm. The data used to train and test/validate the ANN's were obtained from rheological and sensory characterization of nine formulations of light cream cheese. Initially, a network of 8-3-9-2 neurons in its layers was developed to establish the relationship between instrumental measurements (firmness, gumminess, chewiness, elasticity, cohesiveness, yield stress, viscosity, tangent  $\delta$ ,) and the sensory attributes of consistency and spreadability. An appropriate data transformation method was applied to reduce the variations in the sensory scores reported by trained judges. This ANN was that which best adapted to modeling of such data, showing excellent ability of generalization with a validation error (RMSE) of 0.0506. In a second step two ANN's were constructed, Network 1 (with original data) and Network 2 (transformed data), which were then compared regarding their performance to rank the cream cheeses into different classes of acceptance ("Accepted", "Rejected") from the instrumental measures described above. The optimized network presented an architecture characterized by 8-3-3-2 neurons in layers and was developed with the transformed data (Network 2), which presented excellent performance in the classification of two acceptance categories, better than Network 1. Moreover, it showed an excellent generalization capacity, with a low validation error (RMSE) of 0.1022. Subsequently, a relationship was established between the data of chemical composition (fat and water content) of the cream cheeses and their sensory attributes (consistency, spreadability,



aroma, flavor, viscosity and adhesiveness), where this ANN was also analyzed in relation to the original measurements of the sensory attributes (Network 1) and transformed measurements (Network 2). It was found that when using appropriate data transformation, Network 2, composed 2-15-6-6 neurons in its layers, presented an excellent prediction capacity of sensory attributes with an error (RMSE) of data from the validation set equal to 0.0632. Then, this modeling technique was compared with the model of Multiple Linear Regression (MLR) exhibiting the same conditions for construction and validation of the models. Using a paired t-test, it was found that the ANN model performed better than the MLR at a 10 % significance level. Thus, the ANN appears that an excellent and promising alternative for the food industry in regards to modeling of data that characterize the different textures of light cream cheese, in order to meet the desires and needs of consumers, since it requires only a representative set of input-output data to learn the relationships, accurately predicting and classifying the dependent variables of interest. This alternative also presents attractive advantages for industrial applications such as accuracy, simplicity and low cost for its implementation.

## INTRODUÇÃO GERAL

Nos últimos anos tem-se verificado que os consumidores estão mais conscientes e exigentes quanto à qualidade dos alimentos. Consequentemente, é de grande importância, por parte da indústria, a avaliação do comportamento do consumidor para o desenvolvimento ou inovação de um produto e para a escolha de sua estratégia de *marketing*, uma vez que o objetivo principal é obter a aceitação do produto por parte desse consumidor (NGAPO et al., 2003).

Entretanto, pesquisas e testes com consumidores são procedimentos que demandam muito tempo e apresentam elevado custo. Visando contornar tal problema, observa-se a constante busca por parte de pesquisadores da área de *marketing* e análise sensorial por desenvolver modelos matemáticos que sejam capazes de prever a aceitação de novos produtos por meio de informações obtidas a partir de dados descritivos levantados por uma equipe treinada, de medidas instrumentais, de dados da composição química do alimento e/ou de dados de preferência dos consumidores (BARDOT, et al., 1994; KRISHNAMURTHY et al., 2007; PANAGOU et al., 2008).

Vários são os métodos estatísticos multivariados tradicionalmente utilizados como ferramentas para modelar problemas como este, todavia, a maioria das estatísticas multivariadas utilizadas baseia-se na natureza linear das variáveis e não se adequa bem a casos que apresentam não-linearidade, fato comum em dados sensoriais e dados de aceitação do consumidor (PIGGOTT, 1986; JOHNSON e DEAN WICHEM, 1998).

É neste sentido que as Redes Neurais Artificiais (RNA's), que são sistemas computacionais os quais procuram reproduzir o modo de raciocínio do cérebro humano, apresentam-se como uma alternativa promissora (BRAGA, CARVALHO e LUDEMIR, 2000; NEURALWARE, 2001). As características de aprender por meio de exemplos, incorporar muitas variáveis, adequar-se bem ao comportamento de variáveis não-lineares, generalizar relações e tolerância a falhas, proporcionam fortes incentivos para a escolha da técnica de RNA como uma ferramenta eficaz de modelagem (DELLA LUCIA e MINIM, 2010).

Tais propriedades das RNA's têm despertado o interesse de diversos pesquisadores que as têm aplicado a uma série de disciplinas científicas (HAYKIN, 2002).

Na ciência e tecnologia de alimentos, mais especificamente na análise sensorial, com enfoque para estudos envolvendo aceitação/preferência dos consumidores, descrição do perfil sensorial de alimentos e estabelecimento das relações entre medidas sensório-instrumentais, esta técnica é ainda pouco explorada. No entanto, ela pode representar uma alternativa viável para métodos estatísticos multivariados, uma vez que se aplicam de forma apropriada a esses dados os quais possuem, em muitos casos, características de não-linearidade, interações, variáveis correlacionadas, bem como perda de observações (KRISHNAMURTHY et al., 2007; DELLA LUCIA e MINIM, 2010).

No caso específico do requeijão *light*, a textura desempenha um papel tão importante quanto os atributos de aroma e sabor. Assim, o emprego da RNA a fim de modelar as características sensoriais do produto por meio de medidas instrumentais, da composição química, bem como a aceitabilidade sensorial do consumidor frente às diferentes texturas é essencial para indústria de alimentos, a fim de atingir os anseios e necessidades dos consumidores.

Neste contexto, o objetivo deste trabalho foi aplicar RNA para prever medidas sensoriais e a aceitabilidade de requeijão *light* com diferentes teores de gordura e água.

## REFERÊNCIAS

BARDOT, I.; BOUCHEREAU, L.; MARTIN, N.; ALAGOS, B. Sensory-instrumental correlation by combining data analysis and neural network techniques. **Food Quality and Preference**, v.5, p.159-166, 1994.

BRAGA, A. P., CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Editora LTC, 2000. 262p.

DELLA LUCIA, S. M.; MINIM, L. A. Redes Neurais Artificiais: Fundamentos e Aplicações. In: MINIM, V. P. R. (Ed.). **Análise sensorial: estudos com consumidores**. Viçosa: Editora. UFV, 2010. Cap. 7, p.168-213.

HAYKIN, S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman. 2002. 900p.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 4 ed. Upper Saddle River, New Jersey-USA: Prentice-Hall, 1998. 816p.

KRISHNAMURTHY, R.; SRIVASTAVA, A. K.; PATON, J. E.; BELL, G. A.; LEVY, D. C. Prediction of consumer liking from trained sensory panel information: Evaluation of neural networks. **Food Quality and Preference**, v.18, p.275-285, 2007.

NEURALWARE. **Neural computing: a technology handbook for NeuralWorks 1Professional II / Plus**. USA, Neuralware: 2001. 325p.

NGAPO, T. M.; DRANSFIELD, E.; MARTIN, J. F.; MAGNUSSON, M.; BREDAHL, L.; NUTE, G. R. Consumer perceptions: pork and pig production. Insights from France, England, Sweden and Denmark. **Meat Science**, v.66, n.1, p.125-134, 2003.

PIGGOTT, J. R. **Statistical procedures in food research**. England: Elsevier Applied Science Publishers, 1986.

## **CAPÍTULO 1**

# **REDES NEURAIS ARTIFICIAIS COM ENFOQUE PARA A ANÁLISE SENSORIAL DE ALIMENTOS: UMA REVISÃO**

# REVISÃO DE LITERATURA

## 1 – Análise sensorial de alimentos

O consumidor representa o destino final de todo e qualquer produto que se desenvolva, seja ele um bem de consumo ou especificamente um alimento. Assim, todo e qualquer empreendimento tem como objetivo final a aceitação e a satisfação do consumidor (NGAPO et al., 2003). Em relação à indústria de alimentos, de nada vale um produto excelente, no que se refere a suas características físicas, químicas e microbiológicas, se as suas propriedades sensoriais, bem como os fatores não sensoriais relacionados a este não satisfazem às necessidades e aos anseios de quem o consumirá (GUERRERO et al., 2000; JAEGER, 2006; DELLA LUCIA et al., 2010).

A relação entre o consumidor e a escolha, a compra e a aceitação de um alimento é um fenômeno bastante complexo e vem despertando o interesse de diversas áreas do conhecimento, sendo pesquisado por estudiosos das áreas de Sociologia, Psicologia, Filosofia, Economia, Marketing, Ciência e Tecnologia de Alimentos etc. (GRUNERT, 2002). A atitude do consumidor frente a um produto é influenciada por vários fatores e pela interação entre eles, os quais são relacionados à psicologia que envolve o consumidor, ao aspecto sensorial do produto e ao *marketing* relacionado a ele (GUERRERO et al., 2000).

Este fato leva a crer que a prioridade por maior investigação e esforços por parte dos empreendimentos devem ser voltados ao entendimento e à percepção dos fatores que determinam o comportamento do consumidor em relação a um produto (CHILDS e PORYZEES, 1997; NGAPO et al., 2003; RESANO et al., 2010 ). A partir da compreensão desta relação crucial entre consumidor e produto é que se pode garantir o sucesso da empresa em longo prazo, a inovação de seus produtos, a escolha das estratégias de *marketing* e a manutenção de sua vantagem competitiva sobre seus concorrentes (NGAPO et al., 2003; RESANO et al., 2010). Em virtude disso, vem crescendo o interesse das empresas em avaliar o desempenho de seus produtos por meio de testes e pesquisas realizados com consumidores.

Entretanto, pesquisas e testes com consumidores constituem-se em processos caros e demorados e, para contornar tal problema, observa-se a constante busca de pesquisadores, da área de *marketing* e análise sensorial, por desenvolver modelos preditivos que possibilitem estabelecer a relação de medidas instrumentais com medidas de atributos sensoriais e aceitabilidade sensorial de um novo produto desenvolvido (BOCCORH e PATERSON, 2002; KRISHNAMURTHY et al., 2007).

Quando o objetivo é obter informações que caracterizam sensorialmente um produto para, a partir dessas, prever a aceitação dos consumidores, técnicas de análise descritiva são empregadas. Dentre as técnicas descritivas, a Análise Descritiva Quantitativa é a mais utilizada. Neste caso, julgadores treinados avaliam a qualidade geral do produto de acordo com uma matriz de descritores sensoriais pré-determinados e, conseqüentemente, fornecem valiosas informações para a indústria de alimentos no que se refere à definição de perfis sensoriais para seus produtos, representando, assim, um dos métodos mais completos para a caracterização sensorial de atributos importantes e que influenciam a aceitação pelo consumidor (MURRAY, DELAHUNTY e BAXTER, 2001; RESANO et al., 2010).

Luckow e Delahunty (2004), Techakriengkrai et al. (2006) e Krishnamurthy et al. (2007) utilizaram as informações levantadas por uma equipe treinada para prever a aceitação global/preferência dos consumidores de suco de laranja contendo ingredientes funcionais, cerveja e caldo de carne, respectivamente. Em todos estes trabalhos a análise estatística multivariada foi aplicada a fim de se estabelecer a relação entre os dados das respostas hedônicas dos consumidores e os dados descritivos da equipe sensorial.

Segundo Krishnamurthy et al. (2007), existem vários métodos estatísticos multivariados empregados para a análise dos dados da pesquisa com consumidor, sendo que os mais utilizados são a regressão linear múltipla (RLM), regressão de componentes principais (RCP) e regressão de mínimos quadrados parciais (PLS). No entanto, os autores ressaltam um inconveniente dessas técnicas, uma vez que as mesmas se fundamentam na natureza linear das variáveis, comportamento este nem sempre observado em dados de consumidores.

## **2 – Correlações entre medidas sensoriais e instrumentais**

A avaliação descritiva é raramente usada na indústria, principalmente devido ao elevado custo e ao tempo necessário para treinar e conduzir uma equipe treinada (LASSOUED et al., 2008). É importante ressaltar que por meio de tal técnica é possível obter dados sensoriais que podem ser correlacionados com dados instrumentais, bem como, com dados da aceitação dos consumidores (MURRAY, DELAHUNTY e BAXTER, 2001).

Assim, medidas instrumentais podem ser preferidas pelas indústrias alimentícias, em particular para a rotina do controle de qualidade, uma vez que essas geralmente apresentam menor custo, podem ser realizadas mais rapidamente e são mais fáceis de ser controladas. Elas também possuem alta reprodutibilidade de dados, característica importante quando as medidas precisam ser realizadas em diferentes indústrias. Entretanto, para que as medidas instrumentais sejam utilizadas, é essencial que forneçam previsões acuradas dos atributos sensoriais. Isto é alcançado pela construção inicial de um modelo preditivo, baseado na calibração do conjunto de dados das medidas instrumentais com medidas sensoriais do mesmo produto (WILKINSON e YUKSEL, 1997).

Diversos são os trabalhos existentes na literatura que abordam o emprego de modelos preditivos para estabelecer a relação entre medidas sensoriais e instrumentais. Donahue et al. (2000) elaboraram um modelo de predição da preferência de consumidores de mirtilos a partir de dados instrumentais. Boccorh e Paterson (2002) realizaram a predição da intensidade de sabor em concentrados de groselhas a partir de dados de cromatografia gasosa. Verifica-se, nestes estudos, que técnicas multivariadas foram empregadas para estabelecer modelos matemáticos que predissessem a relação entre medidas sensoriais e instrumentais, bem como, modelos de predição da aceitação/preferência dos consumidores a partir de dados instrumentais.

No entanto, os procedimentos estatísticos multivariados são de natureza linear, e não irão modelar adequadamente a não-linearidade que é comum em dados sensoriais e de aceitação do consumidor (JOHNSON e DEAN WICHEM, 1998). Esse comportamento de não-linearidade pode surgir na relação entre



medidas sensoriais e instrumentais por várias razões. Atributos sensoriais originam-se de interações de complexos processos bioquímicos, químicos e/ou físicos não-lineares que podem somente ser quantificados individualmente por instrumentos. Mesmo em análises sensoriais, o uso de escalas categorizadas na avaliação de atributos pode também produzir relações não-lineares, especialmente se muitos resultados estão localizados próximo às âncoras da escala (WILKINSON e YUKSEL, 1997). Embora relações não-lineares possam ser linearizadas por modelos de regressão convencional, tais manipulações reduzem a veracidade de modelos por respostas humanas para o estímulo do alimento - o objetivo principal (BOCCORH e PATERSON, 2002).

Assim, uma promissora e uma das melhores alternativas para a superação desta limitação são redes neurais artificiais (CHEN, 1991; NUI et al., 1991), uma vez que estas constituem-se em técnicas computacionais que se adequam bem a dados não-lineares.

### **3 – Redes Neurais Artificiais**

As Redes Neurais Artificiais (RNA's) compreendem um ramo da Inteligência Artificial (AI) que procura reproduzir o modo de raciocínio do cérebro humano – portanto o nome “neural”. São constituídas por uma série de neurônios artificiais que simulam os neurônios biológicos, os quais operam de forma paralela e distribuída, adquirindo conhecimento por meio da experiência e sendo utilizadas para resolver muitos problemas complexos do mundo real (BASHEER e HAJMEER, 2000; BRAGA, CARVALHO e LUDEMIR, 2000; DELLA LUCIA e MINIM, 2010).

Os neurônios artificiais, unidades básicas que compõem uma rede neural, também são conhecidos como nós, nodos, unidades de processamento, elementos de processamento ou apenas neurônios. Esses elementos são interconectados por conexões sinápticas artificiais, associadas a pesos (simbolizados por uma matriz de números) que armazenam o conhecimento adquirido pela rede e podem ser ajustados por um processo de aprendizagem. Dessa forma, por meio dos seus nodos e conexões, a rede processa toda a informação recebida do meio para alcançar o desempenho

desejado (BAUGHMAN e LIU, 1995; ZURADA, 1995; BRAGA, CARVALHO e LUDEMIR, 2000).

Segundo Braga, Carvalho e Ludemir (2000), uma rede neural nada mais é do que uma função matemática complexa (normalmente não-linear) que computa uma ou mais saídas (variáveis dependentes), com base em um conjunto de variáveis de entrada (variáveis independentes). Para que esse processo ocorra, a rede deve passar por uma fase de aprendizagem, por meio de exemplos apresentados, dos quais a rede extrai as informações necessárias para posteriormente gerar respostas corretas para o problema em questão, o que leva a uma generalização da informação aprendida.

Baughman e Liu (1995) referem-se ainda às RNA's como um modelo “caixa preta”, em que são conhecidas apenas as relações de entrada e saída do seu processo.

### **3.1 – Analogia das Redes Neurais com o cérebro humano**

O comportamento básico e a dinâmica das RNA's são vistos de maneira análoga, como a estrutura das redes biológicas – o cérebro humano.

A célula nervosa, ou, simplesmente, neurônio, é o principal componente do sistema nervoso. O cérebro é composto de dezenas de bilhões de neurônios densamente interligados que, juntos, formam uma grande rede, chamada rede neural. Cada neurônio é uma simples unidade de microprocessamento que recebe e combina os sinais de muitos outros neurônios constituintes da rede neural (NEURALWARE, 2001).

Os neurônios biológicos são constituídos por três partes principais: os dendritos, o corpo da célula e o axônio (Figura 1.1). Nos neurônios a comunicação é realizada por meio de sinais ou impulsos nervosos que são recebidos por meio dos dendritos e, quando a soma dos impulsos ultrapassa o limiar (*threshold*) de excitação da célula, ocorre ativação do neurônio (BRAGA, CARVALHO e LUDEMIR, 2000), sendo este disparado, produzindo um sinal-resposta no corpo celular, o qual percorre o axônio da célula. Por meio das junções inter-neuronais, denominadas sinapses, a resposta produzida é enviada do axônio de um neurônio ao dendrito de outra célula. As sinapses funcionam como válvulas, e são capazes de controlar a transmissão de

impulsos entre os nodos da rede neural. O efeito das sinapses é variável, e é esta variação que dá ao neurônio a capacidade de adaptação. Dessa forma, a sinapse, em combinação com o processamento da informação dentro do neurônio, forma o mecanismo básico de memorização do cérebro (NEURALWARE, 2001).




Figura 1. 1 - Esquema de um neurônio cerebral.

Fonte: DELLA LUCIA e MINIM, 2006.

O neurônio artificial é uma estrutura lógico-matemática que procura simular a forma, o comportamento e as funções de um neurônio biológico. Assim sendo, os dendritos foram substituídos por *entradas* e os axônios por um ou mais *terminais de saída*, que podem ou não estar conectados a entradas de outras unidades de processamento, formando uma rede (Figura 1.2) (BRAGA, CARVALHO e LUDEMIR, 2000; NEURALWARE, 2001).




Figura 1. 2 - Representação típica de um neurônio artificial.

Fonte: KLASSEN, 2008.

As entradas dos neurônios são ligadas ao corpo celular artificial por meio de elementos chamados de *peso*, os quais correspondem à força sináptica das conexões neurais (NEURALWARE, 2001). Os estímulos captados pelas entradas são processados pela *função de soma*; uma função de transferência (ou de ativação) é encarregada de ativar ou não a saída do neurônio artificial, de acordo com o valor da soma ponderada de entradas (BAUGHMAN e LIU, 1995; BRAGA, CARVALHO e LUDEMIR, 2000). Essa função de transferência pode ser uma função limiar, que apenas passa a informação se determinado nível de atividade combinada for atingido, ou ela pode ser uma função contínua da entrada combinada (NEURALWARE, 2001).

### 3.2 – Componentes de um neurônio artificial

De acordo com Baughman e Liu (1995) os principais constituintes de um neurônio artificial (Figura 1.3) são:

#### 1- Entradas e saídas

A entrada para o  $j$ -ésimo neurônio artificial, situado na camada  $k$ , é representada pelo vetor de entrada,  $\mathbf{x}^{k-1}$ , com os componentes  $x_i^{k-1}$  ( $i = 1 \dots n$ ). O neurônio manipula essas entradas e calcula a saída  $x_j^k$ , que pode ser parte da entrada para outros nodos.

#### 2- Fatores pesos

São valores ajustáveis e que são associados com as conexões entre os neurônios em uma rede neural, atuando como um dos fatores que determinam a saída do neurônio. Esses valores podem ser positivos ou negativos, dependendo se as sinapses correspondentes são inibitórias ou excitatórias. Cada entrada  $x_i^{k-1}$  é multiplicada pelo seu correspondente fator peso,  $w_{ji}^k$  e o neurônio utiliza essa entrada ponderada para efetuar os cálculos. Se  $w_{ji}^k$  for ajustado de maneira que  $w_{ji}^k \cdot x_i^{k-1}$  seja positivo, a tendência é de que o

neurônio artificial se excite. Por sua vez, se esse valor for negativo, esse será inibido.

### 3- Funções de transferência ou ativação

É um fator importante que governa a saída do nodo. Esta função de ativação irá disparar ou não a saída de um neurônio, dependendo do valor da soma ponderada de suas entradas. A função de ativação  $f(I_j^k)$  define a saída do neurônio em termos do potencial de ativação  $I_j^k$  como representado na equação (1.1):

$$f(I_j^k) = f\left(\sum_{i=0}^n w_{ji}^k \cdot x_i^{k-1}\right) \quad (1.1)$$

Várias são as funções de ativação existentes. Segundo Baughman e Liu, (1995), as mais comumente usadas são as apresentadas na Tabela 1.1.

Tabela 1. 1 - Funções de ativação: tipos, equação e valores-limites.

| Tipo de função              | Equação                                  | Valores-limite                                           |
|-----------------------------|------------------------------------------|----------------------------------------------------------|
| Função Sigmoidal            | $f(x) = \frac{1}{1 + e^{-x}}$            | 0 (para $x_j = -\infty$ ) e 1<br>(para $x_j = +\infty$ ) |
| Função Tangente hiperbólica | $f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$   | -1 e +1                                                  |
| Função Gaussiana            | $f(x) = \exp\left(-\frac{x^2}{2}\right)$ | 0 e 1                                                    |

Fonte: BAUGHMAN e LIU (1995).




Figura 1. 3 - Representação simbólica de um neurônio consistindo de um nó de processamento e conexões sinápticas.

Fonte: GONÇALVES, MINIM e MINIM, 2006.

### 3.3 – Arquitetura e Topologia das RNA's

Do ponto de vista de uma rede neural, estudar um neurônio artificial isoladamente não é interessante, mas sim, a forma como se encontram interligados em diversos nós.

Para que se possa desenvolver uma rede neural com diversos nodos interconectados, é necessário que se defina inicialmente sua arquitetura e topologia. O planejamento da arquitetura de uma rede neural trata-se de uma etapa muito importante na sua concepção, uma vez que é ela quem vai restringir o tipo de problema que pode ser solucionado pela rede. O termo arquitetura de uma RNA refere-se ao número de camadas que esta apresenta, bem como à quantidade de nodos presentes em cada camada. Já a topologia define o tipo de conexão existente entre os nodos (BRAGA, CARVALHO e LUDEMIR, 2000).

Braga, Carvalho e Ludemir (2000) classificam a arquitetura das RNA's em duas categorias, quanto ao número de camadas:

- Redes de camada única – só existe um nó entre qualquer entrada e qualquer saída da rede, ou seja, elas possuem nós de fontes de dados que são apresentados à rede para serem processados e estes se projetam em uma camada de saída que recebe a

informação processada e envia os resultados para um receptor externo.

- Redes de múltiplas camadas – existe mais de um neurônio entre alguma entrada e alguma saída da rede. Assim, elas possuem uma ou mais camadas denominadas ocultas ou escondidas. Os nós presentes nestas camadas recebem a informação da camada de entrada e realizam o processamento dessa informação, emitindo um sinal para a camada subsequente ou de saída (se for a camada final).

Em relação às conexões, essas podem se apresentar de três formas (BAUGHMAN e LIU, 1995):

- Conexões intracamadas - em que as saídas de um nodo, situado na camada  $k$ , alimentam outro nodo da mesma camada;
- Conexões intercamadas - em que as saídas de um nodo, situado na camada  $k$ , alimentam nodos de outra camada;
- Conexões recorrentes - em que as saídas de um nodo são consideradas como novas informações de entrada.

Dentro da topologia intercamadas existem duas opções de conexões denominadas:

- “*Feedforward*”, ou acíclica, ou redes alimentadas adiante - as conexões são unidirecionais, e as respostas de saída estão baseadas em um sinal de entrada da informação. Não há retroalimentação dos neurônios de saída para os nós de entrada. Essas redes são interessantes devido à sua característica de não-linearidade durante o processamento dos sinais.
- “*Feedback*”, ou cíclicas - a rede neural desenvolvida treina a si própria, ou seja, fazem da saída de um neurônio a entrada de outro numa camada anterior qualquer, ou seja, ocorre realimentação de dados na rede.

Na Figura 1.4 está esquematizado um exemplo de uma rede *feedforward* de múltiplas camadas, tipicamente utilizada na resolução de vários problemas complexos do mundo real.




Figura 1. 4 - Rede *feedforward* com dois nós de entrada, quatro neurônios em cada camada oculta e um neurônio na saída.

Fonte: MORAIS, 2010.

Braga, Carvalho e Ludemir (2000) citam ainda a classificação de RNA's quanto à sua conectividade, existindo redes completamente conectadas (todos os nós de uma camada conectam-se a todos os outros nós da camada subsequente) e redes parcialmente conectadas (quando nem todos os neurônios se conectam entre si).

É importante ressaltar que a especificação da quantidade de neurônios, bem como o número de camadas presentes na rede, pode variar de acordo com a necessidade e com o problema envolvido. Cybenko (1989) investigou o número de camadas intermediárias necessárias para a implementação de classes de funções em uma RNA. Os resultados indicaram que redes com duas camadas intermediárias podem implementar qualquer função, seja ela linearmente separável ou não.

Moraes (2010) ressalta que se deve observar que, em alguns casos, a utilização de duas ou mais camadas intermediárias pode facilitar o treinamento da rede. Contudo, a utilização de um grande número de camadas intermediárias não é recomendada, pois, cada vez que o erro medido durante o



treinamento é propagado para a camada anterior, esse erro se torna menos útil e preciso.

### **3.4 – Fases usuais na solução de problemas por RNA's**

Para que uma rede neural possa desempenhar adequadamente sua função, são consideradas três fases principais durante seu desenvolvimento: a fase de treinamento ou aprendizagem, a fase de teste de desempenho e a fase de generalização ou validação.

Na primeira fase, denominada treinamento ou aprendizagem, vista com mais detalhes adiante, um conjunto de exemplos ou dados de entrada e saída é apresentado para a rede a fim de treiná-la por meio de algum algoritmo de aprendizado (BAUGHMAN e LIU, 1995; HAYKIN, 2002). Nesta fase ocorre o processo de adaptação ou modificação dos pesos das conexões entre os neurônios artificiais até que uma entrada específica produza a saída desejada (NEURALWARE, 2001). A RNA extrai, então, características dos dados para utilizá-las na geração de respostas para o problema (BRAGA, CARVALHO e LUDEMIR, 2000). Esta fase é normalmente a mais longa no desenvolvimento da rede e é crítica para o sucesso da mesma. Nesta etapa, pode-se utilizar algum esquema de correção dos pesos, a fim de minimizar os erros das saídas (BAUGHMAN e LIU, 1995).

A segunda fase envolve o teste de desempenho da rede. Alimenta-se a rede com um segundo conjunto de dados de entrada, diferente daqueles apresentados na fase de treinamento, para os quais se calculam as respostas, sendo estas comparadas com as respostas reais. Caso o grau de precisão na previsão seja igual ou próximo do obtido durante o treinamento, pode-se afirmar que o treinamento está válido (BRAGA, CARVALHO e LUDEMIR, 2000; HAYKIN, 2002). As duas primeiras fases são realizadas simultaneamente a fim de avaliar o desempenho da rede por meio da análise do erro do valor predito (BASHEER e HAJMEER, 2000).

Finalmente, na etapa de generalização, em que ocorre a validação do modelo encontrado para os dados do estudo, apresenta-se à rede um conjunto de dados de entrada diferente daqueles apresentados nas duas fases anteriores. Assim, avalia-se a capacidade de generalização da rede treinada,

ou seja, a sua capacidade em fornecer respostas coerentes, com um erro mínimo (BRAGA, CARVALHO e LUDEMIR, 2000; HAYKIN, 2002).

Segundo Baughman e Liu (1995), a fase de treinamento deve produzir uma rede que seja estável e convergente. Diz-se que uma rede neural é estável quando ela é capaz de mapear um conjunto de dados de entrada para uma saída fixa. A estabilidade garante um resultado, mas não garante, necessariamente, que esse resultado seja acurado. Por outro lado, uma rede neural convergente gera como resultado uma relação entrada-saída precisa. A magnitude do erro entre os resultados reais e aqueles produzidos pela rede é uma indicação direta da convergência desta.

Embora Braga, Carvalho e Ludemir (2000) e Haykin (2002) considerem três fases distintas para se desenvolver uma RNA, observa-se que vários autores como Angerosa et al. (1996), Donahue et al. (2000), Boccorh e Paterson (2002) e Mohebbi et al. (2009) têm realizado apenas as etapas de treinamento e validação, considerada também como fase de teste de desempenho da rede.

### **3.5 – Tipos de aprendizado**

A etapa de treinamento ou processo de aprendizagem é uma das mais importantes na formulação de um modelo baseado em RNA's, pois é por meio do treinamento que os parâmetros livres, ou seja, os valores dos pesos das conexões entre os neurônios de uma rede são calculados, e esses pesos é que caracterizam e definem as relações entre os dados de entrada e saída. O ajuste dos pesos pode ser feito por meio de um algoritmo de aprendizado, o qual consiste em um conjunto de procedimentos definidos para adaptá-los, a fim de que a RNA possa aprender uma determinada função. Os algoritmos de aprendizado existentes diferem entre si pela maneira pela qual o ajuste dos pesos é feita, possuindo cada um as suas vantagens e desvantagens (BRAGA, CARVALHO e LUDEMIR, 2000; DELLA LUCIA e MINIM, 2010).

De acordo com Braga, Carvalho e Ludemir (2000), a etapa de aprendizagem consiste em um processo iterativo de ajuste dos pesos das conexões entre os nós, que guardam, ao final do processo, o conhecimento que a rede adquiriu do ambiente em que está operando. Vários são os

algoritmos utilizados no processo de aprendizagem das RNA's, que podem ser agrupados em dois paradigmas principais: aprendizado supervisionado e aprendizado não-supervisionado.

- **APRENDIZADO SUPERVISIONADO:** Neste caso, para cada estímulo de entrada (vetor de entrada), existe um estímulo de saída (vetor alvo de saída), os quais são apresentados à rede. É também conhecido como *aprendizagem com um professor*, pois a resposta desejada para cada entrada é fornecida à RNA por um supervisor externo (professor) e a rede configura seu sistema procurando atingir a combinação entrada/saída correta. Um vetor de entrada é aplicado, a saída da rede é calculada e comparada ao vetor alvo. O erro determinado é retropropagado através da rede e os pesos são mudados conforme o algoritmo de treinamento escolhido que tende a minimizar o erro. A minimização da diferença é incremental, já que pequenos ajustes são feitos nos pesos a cada etapa de treinamento de tal forma que estes caminhem para uma solução (BRAGA, CARVALHO e LUDEMIR, 2000; NEURALWARE, 2001; HAYKIN, 2002). Uma desvantagem que pode ser mencionada sobre esse tipo de aprendizado é que a rede, na ausência do professor, não consegue aprender outras estratégias em situações não estudadas pelos exemplos do treinamento (BRAGA, CARVALHO e LUDEMIR, 2000). Como exemplos para o aprendizado supervisionado, podem-se citar a aprendizagem por *correção de erros*, a regra delta (WIDROW e HOFF, 1960) e a sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation* (RUMELHART, HINTON e WILLIAMS, 1986), o qual será utilizado neste trabalho.
- **APRENDIZADO NÃO-SUPERVISIONADO:** Também conhecido como autônomo ou auto organizado. Neste tipo de aprendizado não há a intervenção de um supervisor (professor) externo e nem há um vetor projetado de saída. O algoritmo de treinamento

necessita apenas de vetores de entrada, modificando os pesos para produzir vetores de saída consistentes. A rede organiza-se internamente de modo a desenvolver habilidades para reconhecer características dos estímulos recebidos e/ou criar grupos de dados. É importante salientar que este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada. Sem redundância seria impossível encontrar quaisquer padrões ou características dos dados de entrada (BRAGA, CARVALHO e LUDEMIR, 2000; KOVÁCS, 2002). O aprendizado não-supervisionado envolve métodos como o *aprendizado hebbiano* e o *aprendizado por competição ou competitivo*, Modelo de Linsker, Regra de Oja, Regra de Yuille. Pelo motivo deste trabalho fazer uso do aprendizado supervisionado, estes modelos não serão detalhados.

Há ainda, um terceiro tipo de aprendizado, compreendido entre o aprendizado supervisionado e não supervisionado, denominado aprendizado por reforço, no qual um professor externo indica apenas se a resposta a uma entrada é boa ou ruim (NEURALWARE, 2001).

Independentemente do tipo de aprendizado utilizado, uma característica fundamental de qualquer RNA é a sua regra de aprendizado, a qual especifica como os pesos se adaptam em resposta a um exemplo aprendido. O aprendizado pode necessitar que se apresentem à rede vários exemplos, repetidamente. Os parâmetros que controlam uma regra de aprendizado podem mudar ao longo do tempo, à medida que a rede obtém progressos em relação ao seu aprendizado (NEURALWARE, 2001).

### **3.5.1 - Algoritmo *back-propagation***

O algoritmo *back-propagation* trata-se de um algoritmo de aprendizagem comumente utilizado para o treinamento de redes multicamadas, tipicamente denominada rede *back-propagation*, rede esta caracterizada por sempre ter uma camada de entrada contendo um nó para cada variável independente, uma camada de saída, contendo um nó para cada variável dependente e pelo

menos uma camada escondida (oculta). Durante a aprendizagem, a informação neste caso é também retropropagada através da rede e usada para atualizar os pesos das conexões.

Um elemento *back-propagation* representado na Figura 1.3 transfere suas entradas da seguinte forma, como apresentado na equação (1.2):

$$x_j^k = f\left(\sum_i (w_{ji}^k \cdot x_i^{k-1})\right) = f(I_j^k) \quad (1.2)$$

em que  $x_j^k$  é a saída corrente do j-ésimo neurônio na camada  $k$ ,  $w_{ji}^k$  é o peso na junção da conexão entre o i-ésimo neurônio na camada  $k-1$  e o j-ésimo neurônio na camada  $k$ ,  $I_j^k$  é a soma ponderada das entradas do j-ésimo neurônio na camada  $k$  e  $f$  é uma função diferenciável, como por exemplo, uma sigmóide ou uma tangente hiperbólica. O objetivo do processo de aprendizagem é minimizar o erro global  $E$  do sistema pela modificação dos pesos. Dado o atual conjunto de pesos  $w_{ji}^k$  é necessário determinar como alterá-los, a fim de reduzir o erro global. Isto pode ser feito usando a regra do gradiente descendente como mostrado a seguir:

$$\Delta w_{ji}^k = -\eta \cdot \left( \frac{\partial E}{\partial w_{ji}^k} \right) \quad (1.3)$$

em que  $\eta$  é a taxa de aprendizagem, uma constante positiva, baseada no cálculo do termo de correção por gradiente descendente, que controla a taxa na qual os novos fatores pesos são ajustados.

O parâmetro crítico que é passado por meio das camadas é definido por:

$$\delta_j^k = -\left( \frac{\partial E}{\partial I_j^k} \right) \quad (1.4)$$

que pode ser considerado uma medida do erro local no elemento de processamento  $j$  na camada  $k$ .

A derivada parcial na equação (1.3) pode ser calculada utilizando a regra da cadeia e as equações (1.2) e (1.4):

$$\frac{\partial E}{\partial w_{ji}^k} = \left( \frac{\partial E}{\partial I_j^k} \right) \cdot \left( \frac{\partial I_j^k}{\partial w_{ji}^k} \right) = -\delta_j^k \cdot x_i^{k-1} \quad (1.5)$$

Combinando equações (1.3) e (1.5) tem-se:

$$\Delta w_{jk}^p = \eta \cdot \delta_j^p \cdot x_k^{(p-1)} \quad (1.6)$$

Assumindo o erro global  $E$  da forma

$$E = (1/2) \cdot \sum_p ((d_p - o_p)^2) \quad (1.7)$$

em que  $d$  é a saída desejada especificada por um professor,  $o$  é a saída atual produzida pela rede com o atual conjunto de pesos e os subscritos  $p$  são os índices dos componentes  $d$  e  $o$ . Pode ser mostrado que o erro é obtido para a camada de saída de acordo com a equação (1.8), e para qualquer camada intermediária de acordo com a equação (1.9).

$$\delta_j = (d_j - o_j) \cdot f'(I_j) \quad (1.8)$$

$$\delta_j = \left( \sum_i \delta_i \cdot w_{ji} \right) \cdot f'(I_j) \quad (1.9)$$

Conforme definido na equação (1.7),  $E$  define o erro global da rede para um particular par (padrão) de entrada-saída. Uma função do erro global pode ser definida como a soma de todos os pares de funções do erro específico.

### 3.6 – Benefícios de uma RNA

As RNA's possuem uma série de características relevantes que as torna atraentes e desperta a atenção de diversos pesquisadores de áreas multidisciplinares para sua aplicação na resolução de problemas complexos.

Haykin (2002) menciona várias propriedades úteis associadas às RNA's. Entre elas, uma das suas características mais importantes é a sua não-linearidade, ou seja, uma rede constituída por conexões não-lineares de neurônios artificiais é também não-linear. Tal fato é muito interessante principalmente se as informações de entrada apresentadas a ela tiverem comportamento característico de uma função não-linear, pois neste caso, a rede provavelmente irá representar uma saída mais verossímil para aqueles

dados do que, por exemplo, alguma modelagem estatística que envolva uma função apenas linear para a resolução de problemas. Assim, as RNA's têm a capacidade de resolver problemas lineares e não-lineares, além de serem uma técnica de processamento computacional útil em casos em que não se dispõe de informações matemáticas exatas.

Outra vantagem importante de uma RNA é a sua adaptabilidade: a rede construída para operar em determinado ambiente com base em alguns dados pode ser retreinada a partir de novos dados, sem sofrer alteração na sua estrutura (arquitetura e topologia) e, assim, ser novamente utilizada.

A capacidade de tolerância a falhas é, também, bastante interessante; se um neurônio ou suas conexões é destruído, a rede não se torna, necessariamente, inoperante. Mesmo que alguns nós sejam destruídos, desativados, ou suas conexões sejam levemente alteradas, o comportamento da rede como um todo é apenas levemente degradado. A natureza de sua arquitetura e da distribuição da informação existente faz com que o dano causado à rede deva ser muito grande para que ela seja inutilizada.

Uma vantagem adicional dos modelos de redes neurais é que não se faz necessário conhecer a relação entre as variáveis de entrada (variáveis independentes) e as variáveis de saída (variáveis dependentes) *a priori*; ao invés disso, estas relações são descobertas por meio de sucessivos treinamentos. Além disso, as redes neurais são capazes de aprender com exemplos, incorporar muitas variáveis, e fornecer respostas adequadas e rápidas para novas informações não apresentadas anteriormente dada a sua habilidade de generalizar relações numa série de dados complexos (SABLANI e SHAYYA, 2001).

Um benefício adicional de redes neurais é que elas são de uso mais simples quando comparadas a muitos procedimentos estatísticos padrões, não sendo necessário um conhecimento aprofundado dos métodos estatísticos para sua aplicação (TOMLINS e GAY, 1994). Além disso, um sistema baseado em RNA's é considerado mais inteligente do que a abordagem estatística convencional devido à sua robustez a ruídos e inconsistências nos dados (LIPPMANN, 1987; KAMAL, KARNA e BREEN, 1989; ANON, 1992).

Uma característica desta ferramenta diretamente relacionada à Análise Sensorial é que esta simula as funções cerebrais de aprendizagem e retenção

de conhecimento, enquanto se mantém livre das influências e interferências de preferência pessoal, que estão presentes quando um ser humano é convidado a realizar uma avaliação subjetiva de um produto (BOCCORH e PATERSON, 2002).

### **3.7 – Aplicações das RNA's**

Devido aos inúmeros atributos inerentes à modelagem por meio de RNA's, estas estão sendo utilizadas por diversos pesquisadores de diferentes disciplinas científicas: neurociência, matemática, estatística, física, ciência da computação, engenharia, entre outras. Mais precisamente, as RNA's têm sido aplicadas em campos como modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle (HAYKIN, 2002), para identificação de impressões digitais, faces, assinaturas (MARINAI, GORI e SODA, 2005), previsão para o diagnóstico médico (STEPHAN, CAMMANN e JUNG, 2005), economia (PINO et al., 2008), para prever o comportamento humano (MARCHIORI e WARGLIEN, 2008), entre outras tantas áreas, atuando de maneira multidisciplinar.

A abordagem de redes neurais tem sido bastante significativa em termos de ciência, tecnologia e engenharia de alimentos, e a sua utilização tem ocorrido com uma frequência cada vez maior. Observa-se que esta ferramenta computacional tem sido usada para resolver uma ampla gama de problemas específicos, em especial no controle de processos, sensores e interpretação de modelos dinâmicos (GARCIA et al., 1995; KUPONGSAK et al., 2004).

Na Análise Sensorial, as RNA's podem representar uma alternativa viável para métodos estatísticos multivariados uma vez que se aplicam de forma apropriada aos dados de consumidores que possuem características de não-linearidade, interações, variáveis correlacionadas, bem como perda de observações (KRISHNAMURTHY et al., 2007; DELLA LUCIA e MINIM, 2010).

Krishnamurthy et al. (2007) realizaram um estudo sobre a predição da aceitação do consumidor a partir de informações levantadas por um painel sensorial treinado. Foram mensurados no trabalho o perfil sensorial e a aceitação de 10 amostras comerciais de caldo de carne. Métodos de regressão (Regressão linear múltipla, Regressão de componentes principais e Regressão



de mínimos quadrados parciais) e RNA's foram empregados para a simulação experimental. Os autores verificaram que, embora os métodos de regressão utilizados tenham fornecido uma predição acurada dos escores de aceitação dos consumidores, esta aproximação não foi robusta o suficiente para lidar com variações normalmente encontradas em dados de um painel sensorial treinado. No caso da modelagem com RNA, os autores utilizaram rede do tipo “*feed-forward*”, composta por nove nodos na camada de entrada, representando os atributos sensoriais; cinco nodos na camada oculta e dois nodos na camada de saída, representando os dois grupos distintos de consumidores que foram formados com relação à aceitação do produto. A RNA treinada com os dados sensoriais transformados, por meio do algoritmo *back-propagation*, apresentou um ótimo desempenho com uma taxa de 80 % a 90 % de acertos na fase de aprendizagem e 80 % a 95 % de acertos na fase de teste. Dessa forma, os autores concluíram que a excelente propriedade de tolerância ao ruído e a habilidade de predizer mais de um grupo de aceitação dos consumidores com apenas um modelo fizeram com que a rede fornecesse melhor predição se comparada aos outros métodos. Assim, o uso de redes neurais na modelagem da aceitação do consumidor em função dos escores sensoriais apresentou-se como uma possível abordagem na pesquisa da aceitabilidade sensorial do consumidor.

Boccorh e Paterson (2002), a fim de racionalizar a utilização de concentrado de groselha na produção de bebidas desta fruta, elaboraram um modelo de rede neural artificial para predizer a intensidade do sabor nos concentrados de groselha a partir de dados de cromatografia gasosa dos mesmos, que variavam com relação à época, origem geográfica e tecnologia de processamento. Os dados sensoriais referentes à intensidade do sabor do concentrado de groselha nas bebidas foram coletados por meio da *ratio scaling* (escala de magnitude). As relações entre os dados cromatográficos e sensoriais dos concentrados foram modeladas por uma rede neural treinada com o algoritmo *back-propagation* usando escores de regressão de componentes principais como variáveis de entrada. Neste estudo, os autores concluíram que as RNA apresentaram um melhor resultado na predição da intensidade do sabor global dos concentrados se comparado ao resultado apresentado pelo método de mínimos quadrados parciais.

Panagou et al. (2008) investigaram o potencial de um nariz eletrônico para diferenciar a qualidade de azeitonas verdes de mesa fermentadas baseada no seu perfil volátil. As técnicas de análise estatística multivariada (Análise de componentes principais, Análise de agrupamento hierárquico e Análise da função discriminante) e RNA's foram aplicadas ao padrão dos compostos voláteis presentes nas azeitonas para atingir diferentes tarefas de classificação. Azeitonas verdes foram inicialmente classificadas em três categorias principais (Aceitáveis, Marginais e Inaceitáveis), com base em dados de uma equipe sensorial. A abordagem estatística multivariada mostrou boa discriminação entre as amostras pertencentes à classe denominada inaceitáveis e as classes de amostras aceitáveis e marginais (indiferente). No entanto, nas últimas duas classes havia uma área de sobreposição em que uma clara diferenciação não podia ser feita. O potencial para discriminar as azeitonas verdes nas três classes selecionadas também foi avaliado por meio de uma rede neural de multicamadas como classificador com uma estrutura 18-15-8-3. Os resultados mostraram bom desempenho da rede desenvolvida, uma vez que apenas duas amostras foram erroneamente classificadas em uma população de 66 amostras do conjunto de treinamento, considerando que apenas um caso foi erroneamente classificado numa população de 12 amostras do conjunto de teste. Os resultados desse estudo fornecem perspectivas promissoras para o uso de um sistema rápido e de baixo custo de diferenciação da qualidade de azeitonas verdes fermentadas baseado no seu perfil volátil.

## 5 - REFERÊNCIAS

- ANGEROSA, F.; GIACINTO, L. D.; VITO, R.; CUMITINI, S. Sensory evaluation of virgin olive oils by artificial neural network processing of dynamic headspace gas chromatographic data. **Journal of the Science of Food and Agriculture**, v.72, p.323-328, 1996.
- ANON. Designing an electronic wine-taster using neural networks. **Electronic Engineering**, p.37–41, 1992.
- BASHEER, I. A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**. v.43, p.3-31, 2000.
- BAUGHMAN, D. R.; LIU, Y. A., **Neural Networks in Bioprocessing and Chemical Engineering**. Academic Press, San Diego, CA, 1995, 488p.
- BOCCORH, R. K.; PATERSON, A. An artificial neural network model for predicting flavour intensity in blackcurrant concentrates. **Food Quality and Preference**, v.13, n.2, p.117-128, 2002.
- BRAGA, A. P., CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Editora LTC, 2000. 262p.
- CHEN, C. H. On the relationships between statistical pattern recognition and artificial neural Networks. International. **Journal of Pattern Recognition and Artificial Intelligence**, v.5, p.655–661, 1991.
- CHILDS, N. M., PORYZEES, G. H. Foods that help prevent disease: consumer attitudes and public policy implications. **Journal of Consumer Marketing**, v.14, n.6, p.433–447, 1997.
- CYBENCO, G. Approximation by superpositions of a sigmoid function. **Mathematics of Control, Signals and Systems**, v.2, n.1, p.303-314, 1989.
- DELLA LUCIA, S. M.; MINIM, L. A. Redes Neurais Artificiais: Fundamentos e Aplicações. In: MINIM, V. P. R. (Ed.). **Análise sensorial: estudos com consumidores**. Viçosa: Editora. UFV, 2006. Cap. 7, p. 173-194.

DELLA LUCIA, S. M.; MINIM, L. A. Redes Neurais Artificiais: Fundamentos e Aplicações. In: MINIM, V. P. R. (Ed.). **Análise sensorial: estudos com consumidores**. Viçosa: Editora. UFV, 2010. Cap. 9, p.258-279.

DELLA LUCIA, S. M.; MINIM, V. P. R.; CARNEIRO, J. D. S. Análise Sensorial de Alimentos. In: MINIM, V. P. R. (Ed.). **Análise sensorial: estudos com consumidores**. Viçosa: Editora. UFV, 2010. Cap. 1, p. 13-49.

DONAHUE, D. W.; BENOIT, P. W.; LAGASSE, B. J.; BUSS, W. R. Consumer and instrumental evaluation of Maine wild blueberries for the fresh pack market. **Postharvest Biology and Technology**, v.19, n.3, p.221-228, 2000.

GARCIA, L.; ARGUESO, F.; GARCIA, A.; DIAZ, M. Application of neural networks for controlling and predicting quality parameters in beer fermentation, **Journal of Industrial Microbiology**, v.15, p.401-406, 1995.

GONÇALVES, E. C.; MINIM, L. A.; MINIM, V. P. R. Thermal process calculation using artificial neural networks and other traditional methods. **Journal of Food Process Engineering**, v.29, n.2, p.162-173, 2006.

GRUNERT, K. G. Current issues in the understanding of consumer food choice. **Trends in Food Science & Technology**. v.13, p.275-285, 2002.

GUERRERO, L.; COLOMER, Y.; GUÀRDIA, M. D.; XICOLA, J.; CLOTET, R. Consumer attitude towards store brands. **Food Quality and Preference**, v.11, n.5, p.387-395, 2000.

HAYKIN, S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman. 2002. 900p.

JAEGER, S. R. Non-sensory factors in sensory science research. **Food Quality and Preference**, v.17, n.1-2, p.132-144, 2006.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 4 ed. Upper Saddle River, New Jersey-USA: Prentice-Hall, 1998. 816p.

KAMAL, N.; KARNA, N.; BREEN, D. M. An artificial neural networks tutorial: Part 1—basics. **Neural Networks**, v.1, p.4-22, 1989.

KLASSEN, T. **Uso de redes neurais artificiais para a modelagem da temperatura e da retenção de água no processo de resfriamento de**

**carcaças de frangos por imersão.** 2008. 59p. Tese (Mestrado em Engenharia Química) - Universidade Estadual do Oeste do Paraná, Toledo – PR.

KOVÁCS, Z. L. **Redes neurais artificiais: fundamentos e aplicações.** São Paulo: Editora Livraria de Física, 2002. 174p.

KRISHNAMURTHY, R.; SRIVASTAVA, A. K.; PATON, J. E.; BELL, G. A.; LEVY, D. C. Prediction of consumer liking from trained sensory panel information: Evaluation of neural networks. **Food Quality and Preference**, v.18, p.275-285, 2007.

KUPONGSAK, S.; TAN, J.; HATEM, I.; LU, W.; GUTHRIE, B.; TANOFF, M. Set point determination from sensory evaluations for food process control, **Journal of Food Process Engineering**, v.27, p.87-102, 2004.

LASSOUED, N.; DELARUE, J.; LAUNAY, B.; MICHON, C. Baked product texture: Correlations between instrumental and sensory characterization using Flash Profile. **Journal of Cereal Science**, v.48, p.133-143, 2008.

LIPPMANN, R.P. **An introduction to computing with neural networks.** IEEE ASSP Magazine, April, p.4–21, 1987.

LUCKOW, T.; DELAHUNTY, C. Consumer acceptance of orange juice containing functional ingredients. **Food Research International**, v.37, p.805-814, 2004.

MARCHIORI, D.; WARGLIEN, M. Predicting human interactive learning by regret driven neural networks, **Science**, v.319, p.1111-1113, 2008.

MARINAI, S.; GORI, M.; SODA, G. Artificial neural networks for document analysis and recognition. IEEE Transact. Pattern Anal. **Machine Intelligence**, v.27, p.23-35, 2005.

MOHEBBI, M., AKBARZADEH-T, M-R.; SHAHIDI, F., MOUSSAVI, M., GHODDUSI, H-B. Computer vision systems (CVS) for moisture content estimation in dehydrated shrimp. **Computers and Electronics in Agriculture**, v.69, p.128-134, 2009.

MORAIS, E. C. **Reconhecimento de padrões e redes neurais artificiais em predição de estruturas secundárias de proteínas.** 2010. 135p. Tese

(Doutorado em Engenharia de Sistemas e Computação) - Universidade Federal do Rio de Janeiro, Rio de Janeiro- RJ.

MURRAY, J. M.; DELAHUNTY, C. M.; BAXTER, I. A. Descriptive sensory analysis: past, present and future. **Food Research International**, v.34, n.6, p.461-471, 2001.

NEURALWARE. **Neural computing: a technology handbook for NeuralWorks 1Professional II / Plus**. USA, Neuralware: 2001. 325p.

NGAPO, T. M.; DRANSFIELD, E.; MARTIN, J. F.; MAGNUSSON, M.; BREDAHL, L.; NUTE, G. R. Consumer perceptions: pork and pig production. Insights from France, England, Sweden and Denmark. **Meat Science**, v.66, n.1, p.125-134, 2003.

NUI, A.; LI, D. L.; WAN, L.; WEE, W. G. A comparative study of model fitting by using neural networks and regression. **Proceedings of SPIE-International Society of Optical Engineering**, v.1469, p.495–505, 1991.

PANAGOU, E. Z., SAHGAL, N., MAGAN, N., NYCHAS, G.-J.E. Table olives volatile fingerprints: Potential of an electronic nose for quality discrimination. **Sensors and Actuators B**, v.134, p.902-907, 2008.

PINO, R.; PARRENO, J.; GOMEZ, A.; PRIORE, P. Forecasting next-day price of electricity in the Spanish energy market using artificial neural networks. Engin. Applic. **Artificial Intelligence**, v.21, p.53-62, 2008.

RESANO, H.; SANJUÁN, A. I.; CILLA, I.; RONCALÉS, P.; ALBISU, L. M. Sensory attributes that drive consumer acceptability of dry-cured ham and convergence with trained sensory data. **Meat Science**, v.84, p.344-351, 2010.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J., 1986, "Learning representations by back-propagation errors". **Nature**, v.323 n.1, p.533-536, 1986.

SABLANI, S. S.; SHAYYA, W. H. Computarization of Stumbo's method of thermal process calculations using neural networks, **Journal of Food Engineering**, v.47, p.233-240, 2001.

STEPHAN, C.; CAMMANN, H.; JUNG, K. Artificial neural networks: Has the time come for their use in prostate cancer patients? **Nature Clinical Practice Urology**, v. 2, p.262-263, 2005.

TECHAKRIENGKRAI, I.; PATERSON, A.; TAIDI, B.; PIGGOTT, J. R. Staling in two canned lager beers stored at different temperatures - Sensory analyses and consumer ranking. **Journal of the Institute of Brewing**. v.112, n.1, p.28-35, 2006.

TOMLINS, K. I.; GAY, C. Prediction of quality and origin of black tea and pine resin samples from chromatographic and sensory information: evaluation of neural networks. **Food Chemistry**, v.50, p.157-165, 1994.

WIDROW, B.; HOFF, M. E. **Adaptive switching circuits**. Institute of Radio Engineers, Western Electronic Show and Convention. 1960.

WILKINSON, C.; YUKSEL, D. Using artificial neural networks to develop prediction models for sensory-instrumental relationships; an overview. **Food Quality and Preference**, v.8, n.5-6, p.439-445, 1997.

ZURADA, J. M. **Multilayer feedforward networks**, in: Introduction to Artificial Neural System, West Publishing Company, St. Paul, 1995, p.163–235.

## **CAPÍTULO 2**

### **REDES NEURAIS ARTIFICIAIS (RNA's): PREDIÇÃO DE MEDIDAS SENSORIAIS A PARTIR DE MEDIDAS INSTRUMENTAIS**



# 1- INTRODUÇÃO

O requeijão cremoso é um tipo de queijo fundido originalmente brasileiro, fabricado em todo território nacional, com algumas variações de tecnologia, e apresenta como característica o elevado teor de gordura (GALLINA et al., 2008; GOMES e PENNA, 2010). No entanto, como a gordura desempenha um papel importante na textura dos alimentos, desenvolver produtos com teores reduzidos de gordura, mas com a mesma qualidade sensorial da versão convencional, torna-se um grande desafio às indústrias de alimentos (DRAKE e SWANSON, 1995; ROMEIH et al., 2002).

É importante ressaltar que a textura sensorial de um alimento deve ser determinada por meio de testes sensoriais e nenhum instrumento ou combinações de instrumentos pode substituir plenamente os sentidos humanos. Entretanto, como os testes sensoriais são caros e demorados, é desejável se encontrar medidas instrumentais que possam prever medidas sensoriais e, então, utilizar o instrumento na rotina da indústria (MINIM, 2001).

Para que as medidas instrumentais substituam os atributos sensoriais, é essencial que forneçam previsões acuradas desses. Isto é alcançado pela construção inicial de um modelo preditivo, baseado na calibração do conjunto de dados das medidas instrumentais com medidas sensoriais do mesmo produto (WILKINSON e YUKSEL, 1997).

A fim de modelar este tipo de relação, técnicas de regressão tradicionais que se baseiam em estatísticas multivariadas são normalmente empregadas (BOCCORH e PATERSON, 2002). Todavia, essas se baseiam na natureza linear das variáveis e não se adequam de forma apropriada às variáveis que apresentam comportamento não-linear, fato comumente observado em dados obtidos por meio de testes sensoriais (JOHNSON e DEAN WICHEM, 1998).

Neste sentido, destaca-se a ferramenta de modelagem denominada Redes Neurais Artificiais (RNA's), a qual se trata de um sistema computacional baseado em elementos de processamento (nodos), altamente conectados entre si, que processam informação por meio de respostas dinâmicas frente a estímulos externos (BAUGHMAN e LIU, 1995). Tais redes baseiam-se no funcionamento do cérebro humano, em particular de seus neurônios; as

unidades artificiais das redes são dispostas em uma ou mais camadas, ligadas entre si por conexões associadas a pesos, que ponderam a influência de cada neurônio na resposta da rede (BRAGA, CARVALHO e LUDEMIR, 2000).

As vantagens das redes neurais residem em sua capacidade de representar tanto as relações lineares e não-lineares entre as variáveis quanto em sua capacidade de aprender essas relações diretamente a partir dos dados que estão sendo modelados (RAI et al., 2005). Além disso, não necessitam do conhecimento prévio da relação entre variáveis de entrada e saída e, ao invés disso, descobrem essas relações por meio de sucessivos treinamentos, podem incorporar muitas variáveis e fornecem respostas adequadas e rápidas para novas informações não apresentadas previamente (SABLANI e SHAYYA, 2001).

Esta técnica tem se tornado de grande importância e se observa a sua aplicação em diversas áreas da ciência (HAYKIN, 2002). Na área de Análise Sensorial de Alimentos, especificamente no que tange ao estudo da relação entre medidas sensoriais e instrumentais, observa-se que poucos trabalhos são encontrados com a aplicação das RNA's. Thai e Shewfelt (1991) utilizaram RNA para modelagem da qualidade sensorial da cor de pêssegos e tomates, por meio de relações matemáticas que ligam avaliações sensoriais humanas com medidas físicas da cor desses alimentos. Bardot et al. (1994) estudaram a correlação entre dados sensoriais e instrumentais na predição de sabor de bebida a partir de sua composição química. Angerosa et al. (1996) aplicaram essa ferramenta de modelagem para estabelecer a correlação entre dados sensoriais e instrumentais de óleo de oliva. Boccorh e Paterson (2002), a fim de racionalizar a utilização de concentrado de groselha na produção de bebidas desta fruta, elaboraram um modelo de RNA para prever a intensidade do sabor nos concentrados de groselha a partir de dados de cromatografia gasosa dos mesmos. Entretanto, há necessidade de mais estudos para uma melhor compreensão sobre essa poderosa ferramenta de modelagem focada aos dados sensoriais e instrumentais de produtos alimentícios.

É neste contexto que este capítulo objetivou prever medidas sensoriais a partir de medidas instrumentais da textura do requeijão *light* por meio da

modelagem com RNA's, buscando obter de forma rápida e precisa informações sobre os atributos de textura percebidos por uma equipe treinada.

## 2 - MATERIAIS E MÉTODOS

### 2.1 - Dados experimentais

#### 2.1.1 - Amostras

Foram utilizados, para o desenvolvimento da estrutura da rede neural artificial, dados experimentais obtidos por Silva (2010), provenientes da avaliação sensorial e reológica de nove formulações de requeijão *light* adicionado de concentrado protéico de soro (CPS), contendo diferentes concentrações de gordura (G) e água (A).

A composição das diferentes formulações foi definida por meio do Delineamento Composto Central Rotacional (DCCR) com dois fatores (gordura e água) em dois níveis ( $2^2$ ), mais quatro pontos axiais ( $2 \times 2$ ) e o ponto central (PC). O PC foi repetido três vezes perfazendo um total de 11 ensaios ( $2^2 + 2 \times 2 + 3$ ) (Figura 2.1).




Figura 2. 1 - Disposição dos pontos experimentais no delineamento composto central rotacional (DCCR).

Os requeijões foram processados utilizando massa obtida por acidificação direta do leite com ácido láctico 85 % P.A à temperatura de 70 °C, conforme tecnologia descrita por Alves et al. (2007). Os produtos foram constituídos de massa, creme de leite, concentrado protéico de soro (2,0 % - CPS34 GEMACOM), NaCl (0,80 % - CISNE), sal fundente (0,70 % - JOHA S9) e conservantes sorbato de potássio (0,020 % - GEMACOM) e nisina (0,017 % - DANISCO). O processamento foi realizado em tacho aberto provido de agitador mecânico 50 rpm.

### **2.1.2 - Análise Descritiva Quantitativa (ADQ)**

A caracterização sensorial das formulações foi realizada por meio da Análise Descritiva Quantitativa (ADQ) (STONE e SIDEL, 2004; MEILGAARD, CIVILLE e CARR, 2006). A equipe sensorial foi composta por nove julgadores (seis mulheres e três homens com idade compreendida entre 20 e 32 anos). Os testes foram realizados em laboratório de análise sensorial equipado com cabines individuais. As intensidades dos atributos sensoriais de “consistência” e “espalhabilidade” foram avaliadas utilizando uma escala não-estruturada ancorada em “fraco” (0) e “forte” (9). As definições dos descritores, a forma como os julgadores avaliaram as amostras e os padrões que ancoram os extremos da escala não estruturada estão apresentados na Tabela 2.1. Os atributos “consistência” e “espalhabilidade” foram avaliados utilizando uma colher de plástico (avaliação visual). Para avaliar a espalhabilidade das amostras foi utilizado um biscoito água e sal (*cream cracker*). As amostras refrigeradas (10 °C) foram apresentadas aos julgadores em temperatura ambiente (25 °C). O delineamento em blocos completos foi utilizado para avaliação das amostras. As amostras foram servidas de forma aleatória e monádica, cada uma em uma bandeja de plástico, identificadas com um código de três dígitos aleatórios. Os avaliadores foram instruídos a lavar a boca com água mineral entre as avaliações de cada amostra.

Tabela 2. 1 - Atributos sensoriais levantados pela equipe de julgadores, suas respectivas definições e padrões que ancoram os extremos da escala não estruturada.

| Atributos              | Definições                                                          | Referências      |
|------------------------|---------------------------------------------------------------------|------------------|
| <b>Consistência</b>    | Força necessária para mexer o produto a com a colher.               | <b>Fraca:</b> F2 |
|                        |                                                                     | <b>Forte:</b> F8 |
| <b>Espalhabilidade</b> | Capacidade de espalhar o requeijão com uma colher sobre o biscoito. | <b>Fraca:</b> F8 |
|                        |                                                                     | <b>Forte:</b> F2 |

**F2:** 17,3 % G e 70 % A, **F8:** 8,7 % G e 67,5 % A.

Fonte: SILVA, 2010.

### 2.1.3 - Avaliação instrumental

O Perfil de Textura (TPA) foi realizado em máquina universal de teste mecânico (Instron - Série 3367, United States, 2005) à temperatura de 10 °C. Uma probe de 15 mm de diâmetro foi movida perpendicularmente sobre a amostra de requeijão contida em uma embalagem de formato cilíndrico de 50 mm de diâmetro e 40 mm de altura. As condições do teste foram: célula de carga de 1 kN, distância de compressão de 20 % da altura do produto, velocidade: 1,0 mm/s, tempo de contato de 5 segundos, com dois ciclos de penetração (GALLINA et al., 2008). A força exercida sobre o produto foi automaticamente registrada e os parâmetros de textura firmeza (N), gomosidade (N), coesividade (adimensional), mastigabilidade (J) e elasticidade (mm) foram automaticamente calculadas pelo software Blue Hill 2.0 (Instron, Estados Unidos, 2005) a partir das curvas de força (N) versus tempo (s) geradas durante o teste. Foram realizadas 5 análises para cada repetição (replicatas). As medidas reológicas foram realizadas em um reômetro oscilatório HAAKE MARS (Modular Advanced Reometer System, Thermo Electron Corp., Alemanha), equipado com um banho termostático (Phoenix 2C30P, Thermo Electron Corp., Alemanha), utilizando o sensor de placas paralelas serrilhadas de 20 mm de diâmetro (PP 20S) para todas as formulações. As medições foram realizadas à temperatura de  $10 \pm 0,15$  °C. A viscosidade aparente ( $\eta_{ap}$ ) e a tensão inicial ( $\tau_0$ ) de todas as formulações foram determinadas. No teste oscilatório, o componente elástico ( $G'$ ) e o

componente viscoso ( $G''$ ) foram obtidos. A  $\tan \delta$  ( $G'' / G'$ ) foi calculada para cada formulação.

Maiores informações sobre a coleta dos dados experimentais estão disponíveis em Silva (2010).

## 2.2 - Modelagem utilizando redes neurais artificiais

A fim de modelar a relação sensório-instrumental do requeijão *light* foi aplicada a técnica de RNA's, para estimar medidas de atributos sensoriais (consistência e espalhabilidade), em função de medidas instrumentais (tensão inicial, viscosidade aparente, tangente  $\delta$ , firmeza, gomosidade, coesividade, mastigabilidade e elasticidade) determinadas à temperatura de 10 °C, representando a temperatura de armazenamento/refrigeração do requeijão. O estudo da relação existente entre essas variáveis foi obtido de Silva (2010), que determinou a correlação entre tais medidas sensoriais e instrumentais a 10 °C por meio do coeficiente de correlação de *Pearson*. Assim, a rede foi desenvolvida para prever os atributos de textura provenientes de diferentes combinações do teor de gordura e água, dentro da faixa de valores estudados. Portanto, a rede construída foi composta de oito elementos de processamento na camada de entrada e dois elementos de processamento na camada de saída.

Para predição dos atributos sensoriais, utilizou-se o algoritmo *back-propagation*, empregado para o treinamento de redes supervisionadas. Fez-se uso da regra *Extended Delta-Bar-Delta* (MINAI e WILLIAMS, 1990) para o aprendizado da rede e a função de ativação adotada foi do tipo sigmoideal. É importante ressaltar que essa regra de aprendizagem utiliza uma heurística para variação da taxa de aprendizagem e do coeficiente de momento durante o treinamento, os quais se iniciam com valores de 0,3 e 0,4, respectivamente (NEURALWARE, 2001).

Inicialmente, um conjunto de 99 dados foi obtido por meio das medidas descritivas realizadas por 9 julgadores treinados nas 9 formulações de requeijão, sendo 3 repetições do ponto central, perfazendo um total de 11 ensaios (9 x 11 = 99 dados). Uma avaliação visual na dispersão dos dados mostrou que notas individuais de alguns julgadores estavam bastante

discrepantes em relação à equipe e, portanto, foram removidas (LUNDAHL e MCDANIEL, 1988, 1990). Dessa forma, um conjunto final de 72 dados foi dividido em dois subconjuntos usados nas etapas de treinamento e teste/validação da rede.

O conjunto de validação foi composto por dados referentes às formulações F2, F3 e F4 por representarem os três grupos de requeijões com diferentes características de textura obtidos no estudo de Silva, (2010) e o restante dos dados compuseram o conjunto de treinamento. Dessa forma, a divisão dos dados correspondeu a 70 % desses para a fase de treinamento e 30 % para a fase de teste/validação.

Visto que não existe uma técnica-padrão para determinar a arquitetura ótima de uma rede (o número de camadas ocultas com seu respectivo número de neurônios), no presente estudo, foi empregada a técnica de tentativa e erro, na qual várias arquiteturas distintas de rede são testadas adotando-se como critério para a escolha da melhor rede a que apresentar menor valor da raiz quadrada do erro quadrado médio (*RMSE* - root mean square error) (Equação 2.1), denominado posteriormente apenas por erro (RMSE), dos dados do conjunto de validação:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_d - x_p)^2} \quad (2.1)$$

em que  $n$  é o número de pares de dados,  $x_d$  e  $x_p$  são os valores experimentais

(também denominados valores desejados) e preditos dos atributos sensoriais, respectivamente.

A determinação do melhor número de iterações para o treinamento da rede também foi realizada por meio da técnica de tentativa e erro que resultasse no menor valor do RMSE de validação.

O RMSE das etapas de treinamento e validação, bem como os coeficientes de correlação ( $r$ ) e a análise do gráfico de dispersão dos resíduos entre os valores experimentais e os valores preditos pela rede ótima, foram utilizados como medida de seu desempenho.



O desenvolvimento da rede foi realizado no *software* comercial NeuralWorks Professional II/ Plus (Neuralware Inc., Pittsburg, PA, USA).

### 3- RESULTADOS E DISCUSSÃO

#### 3.1 - Treinamento da rede neural

A fim de obter um melhor desempenho da RNA, as notas originais dos atributos avaliados pela equipe sensorial foram transformadas visando à redução da variância dos dados. A transformação dos dados foi feita usando a média e a variância das notas dos atributos sensoriais atribuídas às nove formulações do requeijão pela equipe treinada (NAYAK, DWIVEDI e SRIVASTAVA, 1993; SRIVASTAVA, 2003; KRISNAMURTHY et al., 2007). De acordo com este método, se a variância ( $V_{ij}$ ) das notas do i-ésimo atributo para a j-ésima formulação é maior que um, os dados são transformados conforme a equação 2.2:

$$T_{ijk} = \frac{(X_{ijk} - \bar{X}_{ij})}{V_{ij}} + \bar{X}_{ij} \quad (2.2)$$

em que  $X_{ijk}$  é o valor da nota do i-ésimo atributo para a j-ésima formulação atribuído pelo k-ésimo julgador,  $\bar{X}_{ij}$  é a média das notas do i-ésimo atributo para a j-ésima formulação e  $T_{ijk}$  é o valor transformado da nota do i-ésimo atributo para a j-ésima formulação atribuído pelo k-ésimo julgador.

No caso em que  $V_{ij}$  é menor que um, o seguinte método de transformação pode ser usado (Equação 2.3):

$$T_{ijk} = (X_{ijk} - \bar{X}_{ij}) * V_{ij} + \bar{X}_{ij} \quad (2.3)$$

Na Figura 2.2 está representada a dispersão das notas originais e transformadas para os dois atributos sensoriais estudados. Observa-se que houve uma considerável redução da dispersão dos dados após a transformação dos mesmos. Este resultado também foi confirmado por Krishnamurthy et al. (2007) ao aplicarem essa transformação para reduzir a variância das notas dos nove atributos sensoriais de 10 diferentes tipos de caldo de carne avaliados por uma equipe treinada.




Figura 2. 2 - Dispersão das notas originais e das notas transformadas dos atributos consistência e espalhabilidade do requeijão *light*.

### 3.2 - Seleção da melhor arquitetura da rede de predição

Buscando determinar a configuração da RNA de predição, o número de neurônios na primeira e segunda camadas escondidas foi variado de três em três até 15, fixando-se o número de iterações e a divisão dos conjuntos de treinamento e validação. Optou-se por testar até duas camadas escondidas.

Entre as diversas arquiteturas testadas a que apresentou um valor mínimo para o RMSE dos dados de validação foi a arquitetura composta por duas camadas escondidas contendo três neurônios na primeira camada escondida e nove neurônios na segunda camada escondida, sendo dessa forma, a configuração da RNA selecionada para este estudo (Figura 2.3).




Figura 2. 3 - Arquitetura selecionada para RNA de predição dos atributos sensoriais consistência e espalhabilidade.

### 3.3 - Escolha do melhor número de iterações

Para se obter uma RNA com um bom desempenho, é fundamental acompanhar o progresso de aprendizagem como uma forma de detectar quando uma rede neural é treinada de forma inadequada resultando em

predições com elevado RMSE ou treinada em excesso, passando a memorizar ao invés de generalizar as respostas.

Neste estudo, a fim de selecionar o melhor número de iterações para um adequado treinamento da rede, utilizou-se a rede com 8-3-9-2 neurônios em suas camadas e a divisão do conjunto de dados especificada na sessão 2.2 do item Materiais e Métodos. Assim, a rede foi treinada para um grande número de iterações, até 1.000.000 de ciclos.

O RMSE do conjunto de treinamento e validação foi determinado simultaneamente e em intervalos frequentes. O que se observa na Figura 2.4 é que, inicialmente, tanto para os dados do conjunto de treinamento quanto para os de validação, o RMSE diminui e, após atingir um certo mínimo, o erro do conjunto de validação começa a aumentar enquanto o erro do conjunto de treinamento continua a diminuir até permanecer constante. É nesse ponto, quando o erro de validação começa a aumentar que o treinamento da rede deve ser interrompido. Dessa forma, verifica-se que o melhor número de iterações para treinar a rede de forma apropriada é de 4.000 ciclos de treinamento. Esta etapa é importante, uma vez que a memorização da rede pode ser evitada.




Figura 2. 4 - Efeito do número de iterações no RMSE do conjunto de treinamento e validação.

Um resumo detalhado da topologia da rede neural ótima resultante deste estudo, parâmetros de aprendizagem e condições de treinamento são apresentados na Tabela 2.2.

Tabela 2. 2 - Parâmetros que caracterizam o *design* da RNA ótima.

| Parâmetros da RNA                         | RNA ótima                |
|-------------------------------------------|--------------------------|
| Arquitetura da Rede                       |                          |
| Nº de nós na camada de entrada            | 8                        |
| Nº de camadas ocultas                     | 2                        |
| Nº de nós na camada oculta                | 3 - 9                    |
| Nº de nós na camada de saída              | 2                        |
| Tipo de aprendizado                       | Supervisionado           |
| Função de Ativação                        | Sigmoidal                |
| Algoritmo de aprendizagem                 | <i>Back- propagation</i> |
| Parâmetros de aprendizagem                |                          |
| Regra de aprendizagem                     | Extended delta-bar-delta |
| Taxa de aprendizagem ( $\alpha$ ) inicial | 0,3                      |
| Termo de momento ( $\eta$ ) inicial       | 0,4                      |
| Iterações X 1000                          | 4                        |

### 3.4 - Desempenho da RNA ótima

Os valores do RMSE que caracterizam o desempenho da rede ótima demonstram que a rede foi adequadamente treinada, uma vez que apresentou um baixo erro (0,0485) para a fase de treinamento e ainda apresentou uma boa capacidade de generalização, tendo em vista o baixo valor do RMSE (0,0506) dos dados do conjunto de validação.

Na Figura 2.5 está representado o gráfico dos resíduos para os valores dos atributos sensoriais de consistência e espalhabilidade preditos pela RNA

ótima, para o conjunto total de pontos disponíveis, ou seja, para o conjunto de dados usados no treinamento e para o conjunto de dados utilizados para teste/validação. Os dados enumerados de 1 a 50 correspondem aos exemplos apresentados à rede no treinamento, e os de 51 a 72 são os dados utilizados para validação. Pode-se notar que a distribuição dos resíduos ocorre aleatoriamente em torno do eixo x, não havendo nenhuma variação tendenciosa nas respostas do modelo.




Figura 2. 5 – Gráfico dos resíduos para as medidas de consistência e espalhabilidade preditas pela RNA ótima para os dados do conjunto de treinamento e teste/validação.

Nas Figuras 2.6 e 2.7 estão representadas as comparações entre os valores experimentais e os preditos pela RNA de configuração ótima para os dados do conjunto de validação. Observa-se que os valores experimentais e preditos para os atributos de consistência e espalhabilidade apresentaram elevada correlação ( $r > 0,9000$ ). Tais correlações também apresentaram significância ( $p < 0,0001$ ) pelo teste F, indicando uma boa concordância entre

esses valores, bem como um bom ajuste do modelo neural ao comportamento da relação entre as medidas sensório-instrumentais.




Figura 2. 6 - Comparação entre os valores experimentais e preditos pela RNA ótima para o atributo de consistência.




Figura 2. 7 - Comparação entre os valores experimentais e preditos pela RNA ótima para o atributo de espalhabilidade.

Vale ressaltar, aqui, que os resultados obtidos para os valores preditos para os dois atributos em questão foram excelentes, já que os mesmos predizem notas de atributos sensoriais determinadas por meio de uma Análise Descritiva Quantitativa (ADQ) e, neste caso, o que se avalia é se a equipe apresenta uma concordância entre suas notas e não se apresentam exatidão com relação às mesmas, pois não existe um valor pré-determinado na ADQ. O importante é que, para uma mesma formulação, a equipe sensorial atribua notas próximas para o atributo avaliado que descrevam a mesma intensidade para o mesmo.

Este fato coloca em evidência que o modelo desenvolvido apresentou um ótimo desempenho, já que os valores preditos, para os dados não apresentados durante o treinamento da RNA, foram acurados e, apesar de apresentarem erros em relação ao valor experimental dos atributos, esses erros são insignificantes do ponto de vista da Análise Sensorial, uma vez que as notas obtidas por meio da predição mantêm as mesmas faixas de intensidade dos dados experimentais que caracterizam o requeijão *light* quanto a seus atributos de textura avaliados.

Resultado semelhante foi encontrado por Angerosa et al. (1996), que obtiveram correlação significativa entre os valores preditos e experimentais ( $R^2=0,874$ ,  $p=0,05$ ) das notas da equipe sensorial treinada para avaliar a qualidade de óleo de oliva virgem a partir de dados de cromatografia gasosa, com emprego da técnica de RNA para modelar a relação entre as medidas sensório-instrumentais.

Boccorh e Paterson (2002) também encontraram boa correlação ( $0,68 \leq r \leq 0,89$ ) entre dados de cromatografia gasosa (medida instrumental) e a intensidade do sabor em bebidas concentradas de groselha por meio da modelagem empregando RNA.



## 4 - CONCLUSÃO

A rede selecionada e treinada possibilitou uma excelente predição das medidas dos atributos sensoriais estudados. A configuração da rede composta por 8-3-9-2 neurônios em suas camadas foi a que melhor se adequou ao problema em questão, apresentando excelente capacidade de generalização, com um RMSE de validação de 0,0506, e alta correlação ( $r > 0,9000$ ) entre os valores preditos e experimentais para os dados do conjunto de validação.

Constata-se que a técnica de RNA apresentou grande potencial para a modelagem da relação entre medidas sensório-instrumentais, com vantagens como precisão e simplicidade, além de fornecer respostas acuradas e rápidas para novas informações não apresentadas previamente durante o seu treinamento.

Dessa forma, verificou-se que o modelo final de predição, das medidas sensoriais a partir das instrumentais, obtido por meio dessa ferramenta de modelagem, pode ser uma alternativa promissora para aplicações industriais, podendo predizer a avaliação obtida por meio de uma equipe treinada de forma rápida e com baixo custo.

## 5 – REFERÊNCIAS

- ALVES, R. M. V.; VAN DENDER, A. G. F.; JAIME, S. B. M.; MORENO, I.; PEREIRA, B. C. Effect of light and packages on stability of spreadable processed cheese. **International Dairy Journal**, v.17, p.365-373, 2007.
- ANGEROSA, F.; GIACINTO, L. D.; VITO, R.; CUMITINI, S. Sensory evaluation of virgin olive oils by artificial neural network processing of dynamic headspace gas chromatographic data. **Journal of the Science of Food and Agriculture**, v.72, p.323-328, 1996.
- BARDOT, I.; BOCHEREAU, L.; MARTIN, N.; PALAGOS, B. Sensory-instrumental correlations by combining data analysis and neural network techniques. **Food Quality and Preference**, v.5, n.1-2, p.159-166, 1994.
- BAUGHMAN, D. R.; LIU, Y. A., Neural Networks in Bioprocessing and Chemical Engineering. **Academic Press**, San Diego, CA, 1995, 488p.
- BOCCORH, R. K.; PATERSON, A. An artificial neural network model for predicting flavour intensity in blackcurrant concentrates. **Food Quality and Preference**, v.13, n.2, p.117-128, 2002.
- BRAGA, A. P., CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. Editora LTC, 2000. 262p.
- DRAKE, M. A.; SWANSON, B. G. Reduced and low fat cheese technology: a review. **Trends Food Sci. Technol.**, v.6, p.336-369, 1995.
- GALLINA, D. A.; VAN DENDER, A. G. F.; YOTSUYANAGI, K.; RODRIGUES DE SÁ, P. B. Z. Influence of storage temperature on the texture profile and colour characteristics of UHT *Requeijão cremoso*. **Brazilian Journal of Food Technology**, v.11, n.3, p.169-174, 2008.
- GOMES, R. G.; PENNA, A. L. B. Caracterização de requeijão cremoso potencialmente prebiótico pela adição de inulina e proteína de soja. **Boletim CEPPA**, v.28, n.2, p.289-302, 2010.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman. 2002. 900p.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 4 ed. Upper Saddle River, New Jersey-USA: Prentice-Hall, 1998, 816p.

KRISHNAMURTHY, R.; SRIVASTAVA, A. K.; PATON, J. E.; BELL, G. A.; LEVY, D. C. Prediction of consumer liking from trained sensory panel information: Evaluation of neural networks. **Food Quality and Preference**, v.18, p.275-285, 2007.

LUNDAHL, D. S.; MCDANIEL, M. R. The panelist effect-fixed or random. **Journal of Sensory Studies**, v.3, p.113-121, 1988.

LUNDAHL, D. S.; MCDANIEL, M. R. Use of contrasts for the evaluation of panel inconsistency. **Journal of Sensory Studies**, v.5, p.265-277, 1990.

MEILGAARD, M. C., CIVILLE, G. V., CARR, B. T. **Sensory evaluation techniques**, 4 ed. Boca Raton, FL: CRC, 2006.

MINAI, A. A.; WILLIAMS, R. D. Acceleration of back-propagation through learning rate and momentum adaptation. **International Joint Conference on Neural Networks**, v.1, p.676-679, 1990.

MINIM, V. P. R. Correlação entre Dados de Consumidores, Termos Descritivos e Medidas Instrumentais. In: MERCADANTE, A. Z.; BOBBIO, F. O., BOBBIO, P. A., PERREIRA, J. L., PASTORE, G. M. **Ciência de Alimentos: avanços e perspectivas** Campinas SP, 2001, Cap. 69, p.250-251.

NAYAK, M. S.; DWIVEDI, R.; SRIVASTAVA, S. K. Transformed cluster analysis: An approach to the identification of gases/odours using an integrated gas-sensor array. **Sensors and Actuators B**, v.12, p.103–110, 1993.

NEURALWARE. **Neural computing: a technology handbook for NeuralWorks 1Professional II / Plus**. USA, Neuralware: 2001. 325p.

RAI, P.; MAJUMDAR, G. C.; DASGUPTA, S.; DE, S. Prediction of the viscosity of clarified fruit juice using artificial neural network: A combined effect of concentration and temperature. **Journal of Food Engineering**, v.68, p.527-533, 2005.

ROMEIH, E. A.; MICHAELIDOU, A.; BILIADERIS, C. G.; ZERFIRIDIS, G. K. Lowfat white-brined cheese made from bovine milk and two commercial fat

mimetics: chemical, physical and sensory attributes. **International Dairy Journal**, v.12, p.525-540, 2002.

SABLANI, S. S.; SHAYYA, W. H. Computerization of Stumbo's method of thermal process calculations using neural networks, **Journal of Food Engineering**, v.47, p.233-240, 2001.

SILVA, R. C. S. N. **Caracterização sensorial e reológica de requeijão *light* adicionado de concentrado protéico de soro**. 2010. 147p. Tese (Mestrado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Viçosa, Viçosa –MG.

SRIVASTAVA, A. K. Detection of volatile organic compounds (VOCs) using SnO<sub>2</sub> gas sensor array and artificial neural network. **Sensors and Actuators B**, v.96, p.24-37, 2003.

STONE, H., SIDEL, J. L. **Sensory evaluation practices**. (3rd ed.) New York: Academic. 2004.

THAI, C. N.; SHEWFELT, R. L. Modelling sensory colour quality of tomato and peach: Neural networks and statistical regression. **American Society of Agricultural Engineering**, v.34, p.950-955, 1991.

WILKINSON, C.; YUKSEL, D. Using artificial neural networks to develop prediction models for sensory-instrumental relationships; an overview. **Food Quality and Preference**, v.8, n.5-6, p.439-445, 1997.

## **CAPÍTULO 3**

### **REDES NEURAIS ARTIFICIAIS (RNA's): CLASSIFICAÇÃO DA ACEITABILIDADE SENSORIAL A PARTIR DE MEDIDAS INSTRUMENTAIS**

# 1- INTRODUÇÃO

O consumidor é, por sua própria definição, o destino final de todo e qualquer produto que se desenvolva, seja este um bem de consumo ou especificamente um alimento (DELLA LUCIA, 2008). No entanto, entender o comportamento do consumidor trata-se de uma tarefa difícil, visto que as decisões e hábitos de compra desses são influenciados por fatores fisiológicos, comportamentais e cognitivos, os quais interagem na percepção dos atributos sensoriais (NORONHA, DELIZA e SILVA, 2005). Pesquisas e testes com consumidores são procedimentos tradicionalmente utilizados para acessar e entender os fatores que determinam o comportamento do consumidor, possibilitando a obtenção de informações importantes que devem ser utilizadas pelas empresas para tomada de decisões relacionadas aos seus produtos. Tais procedimentos podem ser utilizados no desenvolvimento e *marketing* de novos produtos, na reformulação de produtos existentes, no estabelecimento de especificações do controle de qualidade, entre outros (RESURRECCION, 1998; MEILGAARD, CIVILLE e CARR, 2006), visando sempre à aceitação do produto pelo consumidor, à manutenção da vantagem competitiva perante o resto do mercado e ao sucesso da empresa em longo prazo (NGAPO et al., 2003; RESANO et al., 2010). É diante deste cenário que se percebe a força que o consumidor exerce sobre o sucesso ou fracasso de qualquer negócio e como é importante voltar a atenção e os investimentos para investigar melhor os fatores que influenciam o seu comportamento.

Entretanto, pesquisas e testes com consumidores são procedimentos com alto custo e que demandam muito tempo, tornando-se muitas vezes inviáveis de serem realizados como uma atividade rotineira pelas indústrias (KRISHNAMURTHY et al., 2007). Visando a contornar esse problema, pesquisadores de *marketing* e análise sensorial buscam desenvolver modelos preditivos da aceitação/preferência do consumidor a partir de informações sensoriais (KRISHNAMURTHY et al., 2007) e instrumentais (PANAGOU et al., 2008). Existem na literatura alguns métodos estatísticos para análise de dados da pesquisa com consumidor (KRISHNAMURTHY et al., 2007); no entanto, estes se baseiam na natureza linear das variáveis e não conseguem modelar

de forma adequada a não-linearidade normalmente inerente a esses dados (PIGGOTT, 1986; JOHNSON e WICHERN, 1992).

Rede Neural Artificial (RNA) tem sido utilizada nos últimos anos como uma alternativa aos modelos de regressão convencional, devido à sua capacidade de resolver problemas altamente complexos e não-lineares em muitos campos da ciência (HAUGEN e KVAAL, 1998). Uma RNA pode ser definida como uma ferramenta de modelagem computacional com elementos de processamento (nodos) paralelamente distribuídos e conectados (BASHEER e HAJMEER, 2000). O funcionamento dessa técnica baseia-se na extração direta do conhecimento contido nos padrões de entrada (variáveis independentes) e saída (variáveis dependentes), ajustando-se os parâmetros não-lineares da topologia da rede, na medida em que os dados de entrada e saída são repetidamente apresentados a ela (HAYKIN, 2002). Quando o sistema é supervisionado por um conjunto de dados de treinamento adequado, ele pode ser posteriormente utilizado para prever ou classificar diferentes padrões não apresentados inicialmente para a rede durante o seu treinamento, característica esta denominada generalização (PANAGOU et al., 2008).

Além disso, existem vários outros benefícios inerentes à utilização de RNA's que a destacam como uma técnica em potencial para modelagem de dados obtidos a partir de testes e pesquisas com consumidores, tais como apresentam tolerância a falhas, adequam-se bem a variáveis correlacionadas e à perda de observações, além de serem procedimentos rápidos e apresentarem respostas acuradas (SABLANI e SHAYYA, 2001; DELLA LUCIA e MINIM, 2010).

Algumas pesquisas envolvendo a aplicação de RNA's para modelar a aceitação/preferência de consumidores estão registradas na literatura (DONAHUE et al., 2000; KRISHNAMURTHY et al., 2007; PANAGOU et al., 2008). Entretanto, observa-se que trabalhos com emprego de RNA na Análise Sensorial de Alimentos, especificamente em relação aos dados obtidos em estudos com consumidores, são ainda bastante escassos. É, portanto, pertinente que se proceda a este tipo de estudo, tendo em vista a importância de se desenvolver e entender o funcionamento de outras alternativas de modelagem que se adequem à análise de resultados desse tipo de pesquisa.

No caso específico do requeijão *light*, faz-se muito importante entender o comportamento do consumidor e os fatores que determinam a sua aceitabilidade sensorial, uma vez que a redução do teor de gordura no requeijão pode ser responsável pela rejeição sensorial deste produto, particularmente devido à diminuição da cremosidade conferida pela gordura (FLOURY et al., 2009). Tal defeito na textura do produto está associado ao concomitante aumento do conteúdo de caseína como resultado da redução da gordura (SHEEHAN e GUINEE, 2004).

Dentre as estratégias de substituição da gordura em requeijão, o aumento do teor de água do produto final é uma maneira simples para reduzir o teor de caseína e recuperar as características de qualidade perdidas com a redução de gordura (ZALAZAR et al., 2002). Desta forma, os teores de gordura e de água são os principais fatores que influenciam a textura do requeijão *light*, merecendo relevância no estudo da aceitabilidade sensorial da textura do produto (VAN DENDER, 2006; SILVA, 2010).

Neste contexto, o objetivo deste trabalho foi classificar a aceitabilidade sensorial de requeijões formulados com diferentes combinações entre gordura e água, utilizando as medidas instrumentais da textura como dados de alimentação da RNA.



## 2 - MATERIAIS E MÉTODOS

### 2.1 - Dados experimentais

As formulações de requeijão *light* e as medidas instrumentais utilizadas neste estudo foram as mesmas previamente descritas na sessão 2.1.1 e 2.1.3 do item Material e Métodos do Capítulo 2. Assim, as medidas instrumentais que serão utilizadas para classificar a aceitabilidade sensorial das nove formulações dos requeijões *light* são: firmeza (N), gomosidade (N), mastigabilidade (J), elasticidade (mm), coesividade (adimensional), tensão inicial (Pa), viscosidade aparente ( $\text{Pa}\cdot\text{s}^{-1}$ ) e  $\tan \delta$  ( $G''/G'$ ), determinadas à temperatura de  $10^{\circ}\text{C}$ , representando a temperatura de consumo do produto.

### 2.2 - Aceitabilidade sensorial

Para a avaliação da aceitabilidade sensorial da textura dos requeijões *light*, foram recrutados, no Campus da Universidade Federal de Viçosa, 100 consumidores de requeijão. As formulações foram servidas aos consumidores de forma aleatória e monádica, em copos descartáveis contendo aproximadamente 10 g do produto. Utilizou-se a escala hedônica de nove pontos, variando de “gostei extremamente” (escore 9) a “desgostei extremamente” (escore 1), para os julgadores expressarem a aceitação em relação à textura dos produtos (MEILGAARD, CIVILLE e CARR, 2006).

### 2.3 - Modelagem utilizando redes neurais artificiais

A fim de modelar a relação entre as medidas instrumentais que caracterizam a textura do alimento e os dados de aceitação dos consumidores em relação à textura do produto, uma RNA tipo *back-propagation* de classificação foi construída. Esta rede foi desenvolvida com o objetivo de separar os requeijões em diferentes categorias de aceitação, de acordo com a escala hedônica de nove pontos. Os requeijões foram classificados como Aceito, representando as notas de 6 a 9 (categorias situadas entre “gostei

ligeiramente” e “gostei extremamente”) e Rejeitado, representando as notas de 1 a 5 (categorias situadas entre “desgostei extremamente” e “indiferente”). A categoria “indiferente” da escala hedônica foi considerada uma resposta ruim, uma vez que consumidores indiferentes a um produto não são propensos a consumirem o mesmo. Essa classificação ocorreu em função das medidas instrumentais desse produto (firmeza, gomosidade, mastigabilidade, elasticidade, coesividade, tensão inicial, viscosidade aparente, tangente  $\delta$ ). Neste caso, a rede desenvolvida foi composta por oito elementos de processamento na camada de entrada e dois elementos de processamento na camada de saída.

A saída da rede foi representada por um vetor multidimensional com o número de dimensões iguais ao número de classes de aceitabilidade do requeijão *light* a ser determinado, e a cada dimensão vetorial atribuiu-se uma classe. Nos arquivos de treinamento e teste/validação, os conjuntos de dados foram codificados em um formato numérico, atribuindo 1 se a formulação de requeijão pertencesse à classe e 0 caso contrário, ou seja, os requeijões foram codificados como:

- (1,0) = pertencente à classe “Aceito”;
- (0,1) = pertencente à classe “Rejeitado”.

Neste caso, um total de 900 dados, referentes ao teste de aceitação em relação à textura das 9 formulações (sendo que as três repetições do ponto central deram origem a uma única amostra) realizado por 100 consumidores ( $9 \times 100 = 900$  dados), foi fornecido à rede para treiná-la e testar/validar o modelo em estudo.

O conjunto de validação foi composto por dados referentes às formulações F4 e F9 por representarem formulações de requeijões pertencentes a cada uma das classes de aceitação estudadas e o restante dos dados compuseram o conjunto de treinamento. Dessa forma, a divisão dos dados correspondeu a 78 % desses para a fase de treinamento e 22 % para a fase de teste/validação.

Para classificação da aceitabilidade do requeijão, utilizou-se o algoritmo *back-propagation* com o emprego da regra *Extended Delta-Bar-Delta* (MINAI e WILLIAMS, 1990) para o aprendizado da rede e a função de ativação adotada

foi do tipo sigmoidal. É importante mencionar que essa regra de aprendizagem utilizada possui uma heurística que modifica os valores da taxa de aprendizagem (inicialmente 0,3) e do coeficiente de momento (inicialmente 0,4) ao longo do treinamento da rede (NEURALWARE, 2001).

A seleção da arquitetura ótima da rede foi realizada por meio da técnica de tentativa e erro; adotou-se como critérios para a escolha da melhor configuração da rede a que resultasse na menor raiz quadrada do erro quadrado médio (*RMSE* - root mean square error), denominado posteriormente apenas por erro (*RMSE*), dos dados do conjunto de validação.

A determinação do melhor número de iterações para o treinamento da rede também foi realizada por meio da técnica de tentativa e erro, que resultasse no menor valor do *RMSE* dos dados do conjunto de validação.

O desempenho da rede ótima foi avaliado por meio dos valores da taxa de classificação correta dos dados para cada classe avaliada e do *RMSE* de validação. A precisão da classificação da RNA ótima foi determinada pelo número de formulações corretamente classificadas ( $n_1$ ) em cada classe sensorial dividido pelo número total de formulações ( $n_2$ ) presentes na classe para os dados dos conjuntos de treinamento e validação (Equação 3.1):

$$Precisão = \left( \frac{n_1}{n_2} \right) * 100 \quad (3.1)$$

O desenvolvimento da rede foi realizado no software comercial NeuralWorks Professional II/ Plus (Neuralware Inc., Pittsburg, PA, USA).

### 3 - RESULTADOS E DISCUSSÃO

#### 3.1 - Treinamento da rede neural com as notas de aceitação sensorial originais e transformadas

Buscando alcançar um melhor desempenho da RNA, as notas originais de aceitação foram transformadas, a fim de reduzir a variância dos dados. Visando a comparar o desempenho da RNA modelada com as notas de aceitação originais e com as notas de aceitação transformadas foram apresentadas todas as etapas para o desenvolvimento das duas RNA's. As RNA's desenvolvidas foram denominadas de Rede 1 (RNA modelada com notas de aceitação originais) e Rede 2 (RNA modelada com notas de aceitação transformadas).

A transformação dos dados foi feita usando a média e a variância das notas de aceitação atribuídas às diferentes formulações do requeijão (F1,..., F9) pelos 100 consumidores (NAYAK, DWIVEDI e SRIVASTAVA, 1993; SRIVASTAVA, 2003; KRISNAMURTHY et al., 2007). De acordo com este método, se a variância ( $V_{ij}$ ) da i-ésima nota de aceitação para a j-ésima amostra é maior que um, os dados são transformados de acordo com a equação 3.2. Se menor que um são transformados pela equação 3.3.

$$T_{ijk} = \frac{(X_{ijk} - \bar{X}_{ij})}{V_{ij}} + \bar{X}_{ij} \quad (3.2)$$

$$T_{ijk} = (X_{ijk} - \bar{X}_{ij}) * V_{ij} + \bar{X}_{ij} \quad (3.3)$$

em que  $X_{ijk}$  é a i-ésima nota de aceitação para a j-ésima amostra atribuída pelo k-ésimo consumidor,  $\bar{X}_{ij}$  é a média da i-ésima nota de aceitação para a j-ésima amostra e  $T_{ijk}$  é o valor transformado da i-ésima nota de aceitação para a j-ésima amostra atribuída pelo k-ésimo consumidor.

A título de ilustração, para melhor esclarecimento sobre o efeito dessa transformação nos dados originais, a redução da variância entre as notas de

aceitação das formulações 1 e 3 do requeijão *light* pode ser observada quando se compara as Figura 3.1 e Figura 3.2.




Figura 3. 1 - Dispersão das notas de aceitação originais atribuídas pelos 100 consumidores às formulações 1 e 3 do requeijão *light*.




Figura 3. 2 - Dispersão das notas de aceitação transformadas atribuídas pelos 100 consumidores às formulações 1 e 3 do requeijão *light*.

### 3.2 – Escolha da melhor arquitetura da Rede 1 e Rede 2

Foram testadas diversas configurações de RNA's com uma e duas camadas escondidas, com seus neurônios variando de três em três até 15 neurônios em cada camada. Essas redes foram desenvolvidas fixando o número de iterações e a divisão dos dados no conjunto de treinamento e validação.

Tanto para Rede 1 quanto para Rede 2 o RMSE dos dados de validação apresentou um valor mínimo quando se desenvolveu as redes com configuração de três neurônios na primeira camada escondida e três neurônios na segunda camada escondida. Dessa forma, a configuração ótima encontrada para a Rede 1 e Rede 2 apresenta duas camadas intermediárias composta por três neurônios em cada uma delas, conforme apresentado na Figura 3.3.




Figura 3. 3 - Arquitetura da Rede 1 e Rede 2 ótimas.

### **3.3 - Escolha do melhor número de iterações para as Rede 1 e Rede 2**

A fim de definir o melhor número de iterações a ser empregado no treinamento das duas redes simulou-se o treinamento da Rede 1 e Rede 2 com a divisão dos dados nos conjuntos de treinamento e validação especificados na sessão 2.3 do item Materiais e Métodos, na rede com configuração ótima de 8-3-3-2 neurônios, para um número de iterações igual a 1.000.000 de ciclos de treinamento.

Observa-se na Figura 3.4 que, para ambos os casos, tanto o RMSE de treinamento quanto o de validação vão diminuindo à medida que se aumenta o número de iterações, até que se chega a um ponto em que o RMSE de validação da Rede 1 começa a aumentar e o RMSE de validação da Rede 2 permanece praticamente constante. No ponto em que a Rede 1 apresenta um RMSE de validação mínimo, que corresponde à 400.000 iterações e a Rede 2 apresenta um RMSE a partir do qual ele permanece constante, correspondente à 300.000 iterações, o ciclo de treinamento deve ser interrompido. Dessa maneira, evita-se uma possível memorização das redes e se garante que as mesmas apresentem uma boa generalização.





Figura 3. 4 – Influência do número de iterações no RMSE de treinamento e validação das Redes 1 e 2, respectivamente.

Na Tabela 3.1 é apresentado um resumo sobre as principais características das duas redes (Rede 1 e Rede 2) de configuração ótima, visando à verificação das diferenças e semelhanças entre elas.



Tabela 3. 1 – Parâmetros das RNA's para Rede 1 e Rede 2.

| Parâmetros da RNA                 | Rede 1 (dados originais) | Rede 2 (dados transformados) |
|-----------------------------------|--------------------------|------------------------------|
| Arquitetura da rede               |                          |                              |
| Nº de nós na camada de entrada    | 8                        | 8                            |
| Nº de camadas ocultas             | 2                        | 2                            |
| Nº de nós na camada oculta        | 3-3                      | 3-3                          |
| Nº de nós na camada de saída      | 2                        | 2                            |
|                                   |                          |                              |
| Tipo de aprendizado               | Supervisionado           | Supervisionado               |
| Função de Ativação                | Sigmoidal                | Sigmoidal                    |
| Algoritmo de aprendizagem         | <i>Back- propagation</i> | <i>Back- propagation</i>     |
|                                   |                          |                              |
| Parâmetros de aprendizagem        |                          |                              |
| Regra de aprendizagem             | Extended delta-bar-delta | Extended delta-bar-delta     |
| Taxa de aprendizagem ( $\alpha$ ) | 0,3                      | 0,3                          |
| Termo de momento ( $\eta$ )       | 0,4                      | 0,4                          |
| Iterações X 1000                  | 400                      | 300                          |

### 3.4 - Desempenho das RNA's ótimas

De acordo com os resultados apresentados na Tabela 3.2, pode-se afirmar que houve uma melhora considerável no desempenho da Rede 2, na qual se realizou a transformação nas notas dos consumidores, se comparada à Rede 1, com as notas de aceitação originais. A Rede 2 apresentou elevados percentuais de classificação correta para a classe “Aceito” (99 %), tanto para os dados de treinamento quanto para os dados de validação. Embora a classe “Rejeitado” tenha apresentado uma porcentagem de classificação correta inferior para os dados de treinamento (85 %) e validação (97 %), esses valores ainda são bem elevados levando em consideração os obtidos na Rede 1.

Vale ressaltar neste ponto que, analisando-se as notas referentes à classe “Rejeitado” presentes no conjunto de treinamento, sugere-se que a menor porcentagem de classificação correta para tais dados tenha ocorrido em virtude da presença das notas atribuídas à formulação 6, terem sido

selecionadas para comporem este conjunto. Essa formulação de requeijão apresentou experimentalmente 57 notas de aceitação e 43 notas de rejeição, mostrando que praticamente metade dos consumidores gostou deste tipo de requeijão e a outra metade não gostou.

A Rede 2 apresentou elevadas porcentagens de classificação correta para os dados de validação, demonstrando que essa, ao contrário da Rede 1, apresentou uma ótima capacidade de generalização.

Ainda pode-se observar na Tabela 3.2 que o RMSE dos dados de treinamento e validação da Rede 1 (0,2627 e 0,2330, respectivamente) praticamente duplicam o valor dos correspondentes RMSE apresentados pela Rede 2 (0,1415 e 0,1022, respectivamente). Isso indica que as respostas (a classificação das formulações do requeijão *light*) geradas pela Rede 1 apresentam-se com uma maior probabilidade de estarem incorretas. Frente às evidências apresentadas, selecionou-se a Rede 2 como a melhor técnica de modelagem para os dados estudados.

Tabela 3. 2 – Desempenho da Rede 1 e da Rede 2.

| Modelo | Classe de aceitação | % Correta de classificação dos dados |           |
|--------|---------------------|--------------------------------------|-----------|
|        |                     | Treinamento                          | Validação |
| Rede 1 | Aceito              | 75 %                                 | 72 %      |
|        | Rejeitado           | 67 %                                 | 91 %      |
|        | RMSE                | 0,2627                               | 0,2330    |
| Rede 2 | Aceito              | 99 %                                 | 99 %      |
|        | Rejeitado           | 85 %                                 | 97 %      |
|        | RMSE                | 0,1415                               | 0,1022    |

Este resultado também foi confirmado por Krishnamurthy et al. (2007), que empregaram a ferramenta de RNA para modelar a aceitação do consumidor a partir de dados obtidos por uma equipe sensorial treinada, utilizando o mesmo artifício de transformação das medidas dos atributos sensoriais e comparando os resultados da RNA com os dados originais e com os dados transformados. Os autores selecionaram a rede neural com dados transformados como o modelo que apresentou o melhor desempenho final para modelar os dados em questão.

Na Tabela 3.3 são apresentados o número de formulações corretamente classificadas em cada classe sensorial para os conjuntos de treinamento e validação e o número total de formulações pertencentes a cada classe para cada conjunto, por meio da qual se avalia a precisão da classificação da rede selecionada (Rede 2). A precisão da classificação da Rede 2 foi de 100 % para as formulações presentes no conjunto de treinamento e validação pertencentes às classes “Aceito” e “Rejeitado”, visto que essa rede classifica corretamente todas as sete formulações presentes no conjunto de treinamento e as duas formulações presentes no conjunto de validação em suas respectivas classes de aceitação.

Tabela 3. 3 – Avaliação da precisão da classificação

| Conjunto    | Classe    | Formulações classificadas como “Aceito” | Formulações classificadas como “Rejeitado” | TOTAL |
|-------------|-----------|-----------------------------------------|--------------------------------------------|-------|
| Treinamento | Aceito    | 4                                       | 0                                          | 4     |
|             | Rejeitado | 0                                       | 3                                          | 3     |
| Validação   | Aceito    | 1                                       | 0                                          | 1     |
|             | Rejeitado | 0                                       | 1                                          | 1     |

É pertinente que se faça aqui um comentário acerca da separação espacial dos requeijões obtida por meio da análise do Mapa de Preferência Interno (MDPREF) no trabalho de Silva (2010), a qual sugeriu a formação de quatro grupos distintos de formulações de requeijão de acordo com a aceitação das diferentes formulações do requeijão *light*. Um grupo foi formado pelos requeijões F1, F3 e F9 (primeiro quadrante), que apresentaram maior aceitação quanto à textura, um outro foi formado pelas formulações F4, F7 e F8 (segundo quadrante), os quais não foram aceitos pelos consumidores em relação ao atributo avaliado, um terceiro grupo foi formado pelo requeijão F2 (terceiro quadrante), que também não foi aceito pelos consumidores, e um último grupo constituído pelas formulações F5 e F6, as quais também foram aceitas, porém por um menor grupo de consumidores.

A baixa aceitação sensorial dos requeijões F4, F7 e F8 pode ser explicada devido ao elevado teor de proteína (aproximadamente 24,80 %)

destes produtos, os quais apresentaram uma matriz protéica muito firme (aproximadamente 1,97 N), desfavorecendo a textura dos requeijões. Já para o requeijão F2 o inverso foi verificado, em que a elevação do teor de água a 70,00 % combinado com 17,30 % de gordura resultou em alta dissolução do conteúdo protéico, conferindo uma textura pouco firme (0,02 N) ao requeijão, o que também prejudicou a aceitação do produto.

Verificou-se que os requeijões F1, F3 e F9, formulações com diferentes níveis de redução de gordura, obtiveram aceitação sensorial semelhante quando combinados com diferentes teores de água, ou seja, o requeijão com 17,30 % G e 65,00 % A (F1) apresentou aceitabilidade sensorial equivalente ao produto com 10,20 % G e 70,00 % A (F3) e, também, equivalente ao requeijão com 13,70 % G e 67,50 % A (F9). É importante ressaltar que estas formulações apresentaram teor de caseína muito próximos (aproximadamente 19,30 %), o que evidencia que a redução de gordura em requeijão deve ser aliada ao aumento no teor de água, para que ocorra equilíbrio na textura do produto.

No MDPREF, os consumidores situaram-se mais próximos da F5 que da F6, demonstrando que esses ficaram bem divididos com relação à aceitação desta formulação. Vale ressaltar, ainda, que a Rede 2 permanece classificando todas as formulações conforme o apresentado no estudo de Silva (2010), em que as formulações F1, F3, F5, F6, F9 foram classificadas em “Aceito” e as formulações F2, F4, F7, F8 em “Rejeitado”.

Resultado similar foi encontrado por Panagou et al. (2008) ao aplicar RNA's para classificar a aceitação de azeitonas verdes fermentadas (nas classes: aceitável, marginal e inaceitável) a partir de seu perfil volátil determinado por um nariz eletrônico.

## 4 – CONCLUSÃO

Os resultados referentes ao desempenho das redes testadas mostraram que, com o uso de uma transformação adequada de dados, a Rede 2, composta por 8-3-3-2 neurônios em suas camadas, apresentou ótimo desempenho na classificação das duas categorias de aceitação, bem superior se comparado à Rede 1. Sendo assim, a Rede 2 foi a RNA selecionada como a ideal para modelagem do problema, por apresentar elevada taxa de classificação do requeijão nas categorias “Aceito” e “Rejeitado”, e ainda por apresentar uma excelente capacidade de generalização.

A RNA demonstrou ser uma poderosa técnica para a classificação da aceitação sensorial de requeijão *light* a partir de medidas instrumentais, o que é de grande valia para a indústria de alimentos, uma vez que as medidas instrumentais são obtidas mais facilmente. Assim, fica claro que o uso de RNA's na modelagem da aceitação do consumidor em função das medidas instrumentais do produto pode ser uma possível abordagem na pesquisa da aceitação/preferência do consumidor, apresentando importantes vantagens como ser uma técnica de modelagem rápida e precisa, que lida de forma adequada com o comportamento linear e não-linear das variáveis, além de prever mais de um tipo de categoria de aceitação por meio de um único modelo matemático.

## 5 - REFERÊNCIAS

- BASHEER, I. A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**. v.43, p.3-31, 2000.
- DELLA LUCIA, S. M. **Métodos estatísticos para avaliação da influência de características não sensoriais na aceitação, intenção de compra e escolha do consumidor**. 2008. 116p. Tese (Doutorado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Viçosa, Viçosa-MG.
- DELLA LUCIA, S. M.; MINIM, L. A. Redes Neurais Artificiais: Fundamentos e Aplicações. In: MINIM, V. P. R. (Ed.). **Análise sensorial: estudos com consumidores**. Viçosa: Editora. UFV, 2010. Cap. 9, p.258-279.
- DONAHUE, D. W.; BENOIT, P. W.; LAGASSE, B. J.; BUSS, W. R. Consumer and instrumental evaluation of Maine wild blueberries for the fresh pack market. **Postharvest Biology and Technology**, v.19, n.3, p.221-228, 2000.
- FLOURY, J.; CAMIER, B.; ROUSSEAU, F.; LOPEZ, C.; TISSIER, J.; FAMELART, M. Reducing salt level in food: Part 1. Factors affecting the manufacture of model cheese systems and their structure–texture relationships. **LWT - Food Science and Technology**, v.42, p.1611-1620, 2009.
- HAUGEN, J-E.; KVAAL, K. Electronic nose and artificial neural network. **Journal of Meat Science**, v.49, n.1, p.273-S286, 1998.
- HAYKIN, S. **Redes neurais: princípios e prática**. 2 ed. Porto Alegre: Bookman. 2002. 900p.
- JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. 4 ed. Upper Saddle River, New Jersey-USA: Prentice-Hall, 1998, 816p.
- KRISHNAMURTHY, R.; SRIVASTAVA, A. K.; PATON, J. E.; BELL, G. A.; LEVY, D. C. Prediction of consumer liking from trained sensory panel information: Evaluation of neural networks. **Food Quality and Preference**, v.18, p.275–285, 2007.

MEILGAARD, M. C., CIVILLE, G. V., CARR, B. T. **Sensory evaluation techniques**, 4 ed. Boca Raton, FL: CRC, 2006.

MINAI, A. A.; WILLIAMS, R. D. Acceleration of back-propagation through learning rate and momentum adaptation. **International Joint Conference on Neural Networks**, v.1, p.676-679, 1990.

NGAPO, T. M.; DRANSFIELD, E.; MARTIN, J. F.; MAGNUSSON, M.; BREDAHL, L.; NUTE, G. R. Consumer perceptions: pork and pig production. Insights from France, England, Sweden and Denmark. **Meat Science**, v.66, n.1, p.125-134, 2003.

NAYAK, M. S.; DWIVEDI, R.; SRIVASTAVA, S. K. Transformed cluster analysis: An approach to the identification of gases/odours using an integrated gas-sensor array. **Sensors and Actuators B**, v.12, p.103–110, 1993.

NEURALWARE. **Neural computing: a technology handbook for NeuralWorks 1Professional II / Plus**. USA, Neuralware: 2001. 325p.

NORONHA, R. L. F.; DELIZA, R.; SILVA, M. A. A. P. A expectativa do consumidor e seus efeitos na Avaliação sensorial e aceitação de produtos Alimentícios. **Alimentos e Nutrição**, v.16, n.3, p.299-308, 2005.

PANAGOU, E. Z.; SAHGAL, N.; MAGAN, N.; NYCHAS, G. J. E. Table olives volatile fingerprints: Potential of an electronic nose for quality discrimination. **Sensors and Actuators B**, v.134, p.902-907, 2008.

PIGGOTT, J. R. **Statistical procedures in food research**. England: Elsevier Applied Science Publishers, 1986.

RESANO, H.; SANJUÁN, A. I.; CILLA, I.; RONCALÉS, P.; ALBISU, L. M. Sensory attributes that drive consumer acceptability of dry-cured ham and convergence with trained sensory data. **Meat Science**, v.84, p.344-351, 2010.

RESURRECCION, A. V. A. **Consumer sensory testing for product development**. Maryland: Aspen Publishers, 1998.

SABLANI, S. S.; SHAYYA, W. H. Computarization of Stumbo's method of thermal process calculations using neural networks, **Journal of Food Engineering**, v.47, p.233-240, 2001.

SHEEHAN, J. J.; GUINEE, T. P. Effect of pH and calcium level on the biochemical, textural and functional properties of reduced-fat Mozzarella cheese. **International Dairy Journal**, v.14, p.161-172, 2004.

SILVA, R. C. S. N. **Caracterização sensorial e reológica de requeijão *light* adicionado de concentrado protéico de soro**. 2010. 147p. Tese (Mestrado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Viçosa, Viçosa –MG.

SRIVASTAVA, A. K. Detection of volatile organic compounds (VOCs) using SnO<sub>2</sub> gas sensor array and artificial neural network. **Sensors and Actuators B**, v.96, p.24-37, 2003.

VAN DENDER, A. G. F. **Requeijão cremoso e outros queijos fundidos: tecnologia de fabricação, controle do processo e aspectos do mercado**. Campinas, S.P. Fonte Comunicações e Editora Ltda, 2006, 390p.

ZALAZAR, C. A.; ZALAZAR, C. S.; BERNAL, S.; BERTOL, N.; BEVILACQUA, A.; ZARITZKY, N. Effect of moisture level and fat replacer on physicochemical, reological and sensory properties of low fat soft cheeses. **International Dairy Journal**, v.12, p.45-50, 2002.



## **CAPÍTULO 4**

**PREDIÇÃO DE ATRIBUTOS SENSORIAIS DO  
REQUEIJÃO *LIGHT* : UMA COMPARAÇÃO ENTRE A  
MODELAGEM POR REDES NEURAIS ARTIFICIAIS  
(RNA's) E POR REGRESSÃO LINEAR MÚLTIPLA (RLM)**

# 1 - INTRODUÇÃO

Metodologias descritivas consistem na detecção, descrição e quantificação das propriedades sensoriais dos alimentos, proporcionando informações qualitativas e quantitativas sobre aparência, aroma, sabor e textura (MURRAY, DELAHUNTY e BAXTER, 2001).

Os dados obtidos por meio da análise descritiva podem ser correlacionados com dados instrumentais e com dados da aceitação do consumidor, o que nos permite definir grupos de consumidores de acordo com as suas preferências em relação às características sensoriais de um determinado produto (BLEIBAUM et al., 2002; MEILGAARD, CIVILLE e CARR, 2006).

No entanto, na situação particular da indústria de alimentos, onde há restrições em termos de tempo, acompanhar a evolução do desempenho de um painel de julgadores acarreta em grandes dificuldades na aplicação desta ferramenta de qualidade. Segundo Labe, Ritz e Hugi (2003), o treinamento dos julgadores é a etapa crítica para obtenção de perfis sensoriais no contexto prático da indústria.

Frente a isso, observa-se o interesse e empenho de pesquisadores em propor novas metodologias como a Análise Descritiva por Ordenação (RODRIGUE, 2000; RICHTER, 2006) e Análise Descritiva Modificada (SILVA, 2010) para a descrição sensorial, visando à redução de tempo e custo do teste.

Outra alternativa utilizada por pesquisadores da área de *marketing* e de análise sensorial é a criação de modelos matemáticos que sejam capazes de prever características de qualidade do alimento, sua descrição sensorial, assim como sua aceitação/preferência pelos consumidores. A regressão linear múltipla (RLM) é um dos métodos estatísticos multivariados amplamente empregados para predição e diagnóstico em muitos campos da ciência, apresentando resultados bastante efetivos na resolução de problemas de menor complexidade (MOHEBBI et al., 2009).

Entretanto, entre os métodos de regressão linear, a RLM possui algumas restrições no desenvolvimento dos modelos: (1) o número de observações disponíveis deve ser maior que o número de parâmetros do modelo, para

dessa forma possibilitar uma estimativa do erro puro (REGAZZI, 2010); (2) os sinais dos coeficientes de regressão podem não fazer sentido; (3) fortes correlações entre as variáveis independentes afetam adversamente a habilidade preditiva do modelo por meio da introdução de redundância inerente às variáveis não ortogonais (interdependentes), tal fato leva a ocorrência da multicolinearidade, ou seja, a presença de colunas linearmente dependentes impossibilitando calcular a estimativa dos parâmetros da regressão (HELLAND E TRYGVE, 1994; REGAZZI, 2010); e (4) os modelos consideram somente associações lineares entre as variáveis e ignoram as relações não-lineares (KRISHNAMURTHY et al., 2007).

Embora a RLM possa modelar relações de não linearidade entre as variáveis dependentes e independentes pela introdução de uma transformação nas variáveis independentes (variável X), a implementação em software desse algoritmo é mais complexa e o esforço computacional é maior (KRISHNAMURTHY et al., 2007).

Diante do exposto é necessária a busca de alternativas para que essas limitações possam ser superadas e, uma das melhores, trata-se da ferramenta de modelagem denominada Rede Neural Artificial (CHEN, 1991; NUI et al., 1991).

Uma rede neural é composta por vários elementos chamados neurônios. Esses neurônios podem ser conectados uns aos outros por meio de conexões intercamadas (*feedforward* ou *feedback*), conexões intracamadas e/ou conexões recorrentes, podendo, dessa forma, constituir diferentes tipos de RNA's. A RNA mais popular é do tipo multicamadas *feedforward*, onde os neurônios são organizados em camadas: camada de entrada, camada oculta e camada de saída (BARDOT et al., 1994). A RNA do tipo *feedforward* geralmente tem uma ou mais camadas ocultas, que permitem à rede lidar com a correlação não-linear e complexa (MASTERS, 1993). Quando esse sistema é supervisionado por um conjunto de dados de treinamento adequado, ele pode ser usado para prever ou classificar diferentes padrões não inicialmente introduzidos na rede, característica essa denominada generalização (PANAGOU et al., 2008).

Vale enfatizar que as RNA's são capazes de manipular dados com relações não-lineares, embora a forma precisa dessas relações não seja

conhecida. Além disso, também são adequadas para a previsão da qualidade dos alimentos que, em muitos casos, é complicada devido à inter-relação entre parâmetros de qualidade, composição e condições de processamento (NI e GUNASEKARAN, 1998). Uma outra vantagem da utilização dessa ferramenta de modelagem é que ela pode reconhecer e explorar as relações nos dados que não são predefinidas (como ocorre em técnicas de regressão) e não precisa ser expressa por meio de uma equação. Isso as torna particularmente adequadas às relações de mapeamento que são não-lineares e empíricas, desde que dados suficientes sejam disponíveis para treinar a rede (LEFRÈVE et al., 2005).

Muitos autores têm realizado comparações entre as técnicas estatísticas, especificamente entre a RLM e RNA, em diferentes áreas da ciência e aplicações (DONAHUE et al., 2000; LEFRÈVE et al., 2005; DVIR et al., 2006; MOHEBBI et al., 2009; PALIWAL e KUMAR, 2009). Entretanto, observa-se que não há um consenso definido nesses estudos sobre a superioridade de um ou outro método. Os resultados dessas comparações são fortemente dependentes do problema específico (MOHEBBI et al., 2009).

É importante ressaltar que os trabalhos que descrevem a aplicação de RNA para predição de atributos sensoriais a partir de dados da composição química do alimento e os comparam com métodos estatísticos, como observado no estudo de Bardot et al. (1994), no qual se aplica tais ferramentas de modelagem para predição de atributos sensoriais de uma nova bebida a partir de dados de sua composição química, são mais escassos. Este fato evidencia a necessidade de se realizar este tipo de estudo, tendo em vista que a concepção de modelos preditivos entre esses tipos de dados pode ser útil em várias aplicações na indústria de alimentos, tais como controle *on-line* de qualidade, diagnóstico de defeitos sensoriais e de otimização do produto (BARDOT et al., 1994).

Neste contexto, este capítulo objetivou desenvolver e comparar modelos (RNA e RLM) que possam prever a qualidade sensorial do requeijão *light* percebida por uma equipe treinada a partir de dados do teor de gordura e água.

## **2 - MATERIAIS E MÉTODOS**

### **2.1- Dados experimentais**

#### **2.1.1- Amostras**

As formulações de requeijão foram obtidas conforme descrito na sessão 2.1.1 do item Material e Métodos do Capítulo 2. Os dados utilizados nesta análise foram aqueles relativos à composição das diferentes formulações do requeijão *light*, definida por meio do Delineamento Composto Central Rotacional (DCCR) com dois fatores em estudo: gordura (G) e água (A). As combinações dos níveis de gordura e de água foram analisadas em uma faixa correspondente de 8,7 % a 18,7 % e 64 % a 71 %, respectivamente.

#### **2.1.2 – Análise Descritiva Quantitativa (ADQ)**

A caracterização sensorial das formulações foi realizada por meio da Análise Descritiva Quantitativa (ADQ) (STONE e SIDEL, 1974; MEILGAARD, CIVILLE e CARR, 2006). A equipe sensorial foi composta por nove julgadores (seis mulheres e três homens com idade compreendida entre 20 e 32 anos). Os testes foram realizados em laboratório de análise sensorial equipado com cabines individuais. As intensidades dos atributos sensoriais de consistência, espalhabilidade, aroma característico, sabor característico, viscosidade e adesividade foram avaliadas utilizando uma escala não-estruturada ancorada em “fraco” (0) e “forte” (9). As definições dos descritores, a forma como os julgadores avaliaram as amostras e os padrões que ancoram os extremos da escala não estruturada estão apresentados na Tabela 4.1. As amostras refrigeradas (10 °C) foram apresentadas aos julgadores em temperatura ambiente (25 °C). O delineamento em blocos completos foi utilizado para avaliação das amostras. As amostras foram servidas de forma aleatória e monádica, cada uma em uma bandeja de plástico, identificadas com um código de três dígitos aleatórios. Avaliadores foram instruídos a lavar a boca com água mineral entre as avaliações das amostras.

Tabela 4. 1 - Atributos sensoriais levantados pela equipe de julgadores, suas respectivas definições e padrões que ancoram os extremos da escala não estruturada.

| Atributos            | Definições                                                          | Referências |
|----------------------|---------------------------------------------------------------------|-------------|
| APARÊNCIA            |                                                                     |             |
| Consistência         | Força necessária para mexer o produto a com a colher.               | Fraca: F2   |
|                      |                                                                     | Forte: F8   |
| Espalhabilidade      | Capacidade de espalhar o requeijão com uma colher sobre o biscoito. | Fraca: F8   |
|                      |                                                                     | Forte: F2   |
| AROMA                |                                                                     |             |
| Aroma Característico | Aroma característico de requeijão cremoso.                          | Fraco: F8   |
|                      |                                                                     | Forte: F6   |
| SABOR                |                                                                     |             |
| Sabor Característico | Sabor característico de requeijão cremoso.                          | Fraco: F8   |
|                      |                                                                     | Forte: F6   |
| TEXTURA              |                                                                     |             |
| Viscosidade          | Força necessária para puxar o produto da colher para a boca.        | Fraca: F2   |
|                      |                                                                     | Forte: F8   |
| Adesividade          | Força necessária para remover o produto que adere ao palato.        | Fraca: F2   |
|                      |                                                                     | Forte: F8   |

**F1:** 17,3 % G e 65 % A; **F2:** 17,3 % G e 70 % A; **F3:** 10,2 % G e 70 % A; **F4:** 10,2 % G e 65 % A; **F5:** 13,7 % G e 71 % A; **F6:** 18,7 % G e 67,5 % A; **F7:** 13,7 % G e 64 % A; **F8:** 8,7 % G e 67,5 % A; **F9 (ponto central):** 13,7 % G e 67,5 % A.

Fonte: SILVA, 2010.

## 2.2 - Modelagem utilizando RNA para predição de atributos sensoriais

Para a modelagem da relação entre a composição química e a descrição do perfil sensorial do requeijão *light*, foi empregada a técnica de RNA's, a fim de determinar medidas de atributos sensoriais como a consistência, espalhabilidade, aroma característico, sabor característico, viscosidade e adesividade do produto, em função de dados de sua composição química (medidas do teor de gordura e água). Dessa forma, a rede construída foi

composta por dois elementos de processamento na camada de entrada e seis elementos de processamento na camada de saída.

Visando a modelar a relação entre as variáveis independentes e as variáveis dependentes especificadas acima, RNA's supervisionadas de múltiplas camadas foram construídas. O algoritmo *back-propagation* foi utilizado para o treinamento das redes neurais; fez-se uso da regra *Extended Delta-Bar-Delta* (MINAI e WILLIAMS, 1990) para o aprendizado das redes e a função de ativação selecionada foi do tipo sigmoideal. Vale a pena mencionar que essa regra de aprendizagem utiliza uma heurística para variação da taxa de aprendizagem e do coeficiente de momento durante o treinamento, os quais se iniciam com valores de 0,3 e 0,4, respectivamente (NEURALWARE, 2001).

Inicialmente, um conjunto de 99 dados foi obtido por meio das medidas descritivas realizadas por nove julgadores treinados nas nove formulações de requeijão, sendo três repetições do ponto central, perfazendo um total de 11 ensaios ( $9 \times 11 = 99$  dados), sendo dividido em dois conjuntos menores e fornecidos à rede para realização das etapas de treinamento e teste/validação. Posteriormente, uma avaliação visual da dispersão dos dados mostrou que notas individuais de alguns julgadores estavam bastante discrepantes em relação à equipe e, portanto, foram removidas (LUNDAHL e MCDANIEL, 1988, 1990). Nesse caso, um conjunto final de 63 dados foi dividido em dois conjuntos menores fornecidos à rede para realização das etapas de treinamento e teste/validação.

O conjunto de validação foi composto por dados referentes às formulações F2, F3 e F4 por representarem os três grupos de requeijões com diferentes características de textura obtidos no estudo de Silva (2010) e o restante dos dados compuseram o conjunto de treinamento. Dessa forma, a divisão dos dados correspondeu a 70 % desses para a fase de treinamento e 30 % para a fase de teste/validação.

A determinação da arquitetura ótima das redes foi realizada por meio da técnica de tentativa e erro, adotando-se como critérios para a escolha da melhor rede a configuração que resultasse no menor valor da raiz quadrada do erro quadrado médio (*RMSE* - root mean square error) (Equação 4.1), denominado posteriormente apenas por erro (RMSE), dos dados do conjunto de validação:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_d - x_p)^2} \quad (4.1)$$

em que  $n$  é o número de pares de dados,  $x_d$  e  $x_p$  são os valores experimentais (também denominados valores desejados) e preditos dos atributos sensoriais, respectivamente.

A fim de determinar o melhor número de iterações para o treinamento das redes, também foi aplicada a técnica de tentativa e erro que resultasse no menor valor do RMSE de validação.

O RMSE das etapas de treinamento e validação, assim como o coeficiente de correlação ( $r$ ) entre os valores experimentais e os valores preditos pela rede ótima, foram utilizados como uma medida de seu desempenho.

As redes foram desenvolvidas no software comercial NeuralWorks Professional II/ Plus (Neuralware Inc., Pittsburg, PA, USA).

### 2.3 - Modelagem utilizando RLM para predição de atributos sensoriais

A fim de avaliar quais das técnicas poderiam prever os atributos sensoriais de forma mais precisa, o mesmo subconjunto de dados (conjunto de treinamento) que foi utilizado para o desenvolvimento da RNA foi utilizado para determinar os modelos de RLM (LEFÈVRE, WATSON e WATSON, 2005; DVIR et al., 2006; MOHEBBI et al., 2009).

A obtenção dos modelos de RLM que explicam o efeito da gordura e da água nos atributos sensoriais do requeijão *light* deu-se a partir do modelo semelhante ao resultante da modelagem por RNA's, na qual as variáveis independentes foram constituídas por teor de gordura e água e as variáveis dependentes representavam os seis atributos sensoriais, dado por:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \epsilon_i \quad (4.2)$$



em que:

- $Y_i$  : é a variável resposta (atributos sensoriais);
- $\beta_0$  : constante do modelo de regressão;
- $\beta_1$  e  $\beta_2$  : efeito de primeira ordem do teor de gordura e do teor de água;
- $X_{1i}$  : teor de gordura da formulação;
- $X_{2i}$  : teor de água da formulação;
- $\epsilon_i$  : erro experimental NID  $(0, \sigma^2)$

As análises para ajuste do modelo proposto foram realizadas utilizando-se o *software* SAS<sup>®</sup> (Statistical Analysis System – SAS), versão 9.1, licenciado para uso da Universidade Federal de Viçosa.

## 2.4 – Comparação entre os modelos da RNA de melhor desempenho e da RLM

A comparação entre as duas técnicas de modelagem foi realizada com base nos valores dos atributos sensoriais preditos para os dados do conjunto de teste (validação), conjunto este que foi idêntico para os dois casos. Por meio do coeficiente de correlação ( $r$ ) entre os valores experimentais e os valores preditos pela RNA de melhor desempenho e pela RLM analisou-se e se comparou o desempenho das duas ferramentas abordadas.

O critério de obtenção do erro foi idêntico nas duas modelagens. Ambas ferramentas, RNA e RLM utilizaram a raiz quadrada do erro quadrado médio (*RMSE* - root mean square error) (Equação 4.1), denominado posteriormente apenas por erro (RMSE), dos dados do conjunto de validação, para avaliar qual técnica apresentou um menor valor para o mesmo (MOHEBBI et al., 2009).

Um teste t para amostras pareadas foi realizado para verificar se a diferença entre o RMSE médio dos seis atributos sensoriais, para os dados do conjunto de validação, relativos aos dois modelos em estudo, foi estatisticamente significativa, ao nível de 10 % de significância (DVIR et al.,

2006; MOHEBBI et al., 2009). Neste teste, a variável de interesse é a diferença entre os valores de RMSE obtidos por cada um dos modelos desenvolvidos, para cada atributo sensorial. A hipótese testada ( $H_0$ ) é a de que a média das diferenças é igual a zero, isto é,  $\bar{D} = 0$  (ver, como exemplo, RIBEIRO JÚNIOR, 2001 e DELLA LUCIA, 2008), ou seja, que os dois modelos testados possuem capacidade de prever os seis atributos sensoriais estatisticamente de forma igual. A hipótese alternativa ( $H_a$ ) é de que a média das diferenças é diferente de zero, isto é,  $\bar{D} \neq 0$ , ou seja, que um dos modelos testados possui maior ( ou melhor ) capacidade de prever os seis atributos sensoriais. Dessa maneira, tem-se que:

$$t = \frac{\bar{d}_i - \bar{D}}{\frac{s(d_i)}{\sqrt{n}}} \quad (4.3)$$

em que:

- $\bar{d}_i$  : média das diferenças do RMSE da RNA e da RLM (amostral);
- $\bar{D}$  : média das diferenças da população (assumindo o valor 0);
- $s(d_i)$ : desvio-padrão das diferenças amostrais;
- $n$  : tamanho total da amostra, sendo, neste caso,  $n = 6$  seis atributos sensoriais.

Essa análise foi realizada utilizando-se o software SAS<sup>®</sup> (Statistical Analysis System – SAS), versão 9.1, licenciado para uso da Universidade Federal de Viçosa.

### 3- RESULTADOS E DISCUSSÃO

#### 3.1- Treinamento da rede neural com medidas dos atributos sensoriais originais e transformadas

Na perspectiva de se obter uma RNA com um desempenho otimizado, as notas atribuídas por alguns jogadores treinados, aos atributos sensoriais em estudo que apresentaram inconsistências com a equipe, foram removidas; além disso, as notas restantes após a remoção de alguns dados discrepantes foram submetidas a uma transformação. Com o intuito de se examinar o desempenho da RNA desenvolvida com todas as notas dos atributos sensoriais originais e com as notas dos atributos sensoriais com dados removidos e transformados foram indicadas todas as etapas para a construção das duas RNA's. As RNA's desenvolvidas foram denominadas de Rede 1 (RNA modelada com todas as notas dos atributos sensoriais originais) e Rede 2 (RNA modelada com notas dos atributos sensoriais removidas e transformadas).

A transformação dos dados foi feita usando a média e a variância das notas dos atributos sensoriais das nove formulações do requeijão *light*, atribuídas pelos nove jogadores treinados (NAYAK, DWIVEDI e SRIVASTAVA, 1993; SRIVASTAVA, 2003; KRISNAMURTHY et al., 2007). De acordo com este método, se a variância ( $V_{ij}$ ) da i-ésima nota do atributo sensorial para a j-ésima amostra é maior que um, os dados são transformados conforme a equação 4.4; se menor que um, de acordo com a equação 4.5:

$$T_{ijk} = \frac{(X_{ijk} - \bar{X}_{ij})}{V_{ij}} + \bar{X}_{ij} \quad (4.4)$$

$$T_{ijk} = (X_{ijk} - \bar{X}_{ij}) * V_{ij} + \bar{X}_{ij} \quad (4.5)$$

em que  $X_{ijk}$  é a i-ésima nota do atributo sensorial para a j-ésima amostra atribuída pelo k-ésimo jogador,  $\bar{X}_{ij}$  é a média da i-ésima nota de um determinado atributo sensorial para a j-ésima amostra e  $T_{ijk}$  é o valor


transformado da  $i$ -ésima nota do atributo sensorial para a  $j$ -ésima amostra atribuída pelo  $k$ -ésimo julgador.

Para elucidar o resultado da transformação nos dados originais, a redução da variância dos atributos sensoriais adesividade e espalhabilidade avaliados nas nove formulações do requeijão *light* estão apresentadas na Figura 4.1. Pode-se observar o comportamento, já esperado, entre esses dois atributos sensoriais: à medida que a espalhabilidade aumenta, a adesividade do produto diminui. Isso ocorre pelo fato de que esses atributos representam características antagônicas em uma mesma formulação de requeijão, pois um requeijão que apresentar uma facilidade para ser espalhado sobre uma bolacha (espalhabilidade), geralmente necessitará de uma pequena força para remoção da amostra que adere ao palato e aos dentes durante o processo de deglutição (adesividade).

### **3.3 – Escolha da melhor arquitetura da Rede 1 e Rede 2**

A fim de determinar a melhor arquitetura para a Rede 1 e Rede 2, procedeu-se ao teste de diversas configurações de RNA's com uma e duas camadas escondidas, com seus neurônios variando de três em três até 15 neurônios em cada camada, mantendo-se fixos o número de iterações para o treinamento das redes, bem como a divisão dos dados nos conjuntos de treinamento e validação. Entre as diferentes arquiteturas testadas para os dois casos, a que apresentou configuração de quinze neurônios na primeira camada escondida e seis neurônios na segunda camada escondida tanto para a Rede 1 quanto para Rede 2, forneceu um valor mínimo para o RMSE dos dados de validação; sendo assim selecionada como configuração ótima para ambos casos (Figura 4.2).

Rede 1



Rede 2





Figura 4. 1 - Dispersão das notas dos atributos sensoriais adesividade e espalhabilidade atribuídas às nove formulações do requeijão *light*.




Figura 4. 2 – Representação da configuração ótima da Rede 1 e da Rede 2.

### 3.2- Escolha do melhor número de iterações das RNA's

Com o propósito de definir o melhor número de iterações a ser utilizado no treinamento das duas redes, utilizou-se as redes de arquitetura ótima selecionadas e a divisão do conjunto de dados especificada na sessão 2.2 do item Materiais e Métodos, para a Rede 1 e Rede 2. Dessa forma, procedeu-se ao treinamento das redes para um grande número de iterações, até 1.000.000 de ciclos de treinamento.

Na Figura 4.3 é apresentado o perfil comportamental do RMSE de treinamento e validação em função do número de iterações realizadas. Analisando-se o comportamento do RMSE para os dois casos, verifica-se que ambos vão diminuindo à medida que se aumenta o número de iterações até atingir um ponto de erro mínimo correspondente a 20.000 iterações na Rede 1 e 13.000 iterações na Rede 2, a partir do qual o RMSE de validação apresenta um aumento no seu valor. Nesses pontos em que as duas redes apresentam um RMSE de validação mínimo, o treinamento deve ser interrompido, tendo em

vista que, dessa maneira, pode-se evitar uma possível memorização das redes e oferecer condições para que as mesmas apresentem uma boa generalização.




Figura 4. 3 – Influência do número de iterações no RMSE de treinamento e validação das Redes 1 e 2, respectivamente.

Na Tabela 4.2 é apresentado um resumo sobre as principais características das duas redes (Rede 1 e Rede 2) de configuração ótima, tendo

em vista o fornecimento de detalhes sobre as diferenças e semelhanças entre elas.

Tabela 4. 2 – Parâmetros das RNA's para os dados originais e dados transformados.

| Parâmetros da RNA                 | Rede 1 (dados originais) | Rede 2 (dados transformados) |
|-----------------------------------|--------------------------|------------------------------|
| Arquitetura da rede               |                          |                              |
| Nº de nós na camada de entrada    | 2                        | 2                            |
| Nº de camadas ocultas             | 2                        | 2                            |
| Nº de nós na camada oculta        | 15-6                     | 15-6                         |
| Nº de nós na camada de saída      | 6                        | 6                            |
| Tipo de aprendizado               |                          |                              |
|                                   | Supervisionado           | Supervisionado               |
| Função de Ativação                |                          |                              |
|                                   | Sigmoidal                | Sigmoidal                    |
| Algoritmo de aprendizagem         |                          |                              |
|                                   | <i>Back- propagation</i> | <i>Back- propagation</i>     |
| Parâmetros de aprendizagem        |                          |                              |
| Regra de aprendizagem             | Extended delta-bar-delta | Extended delta-bar-delta     |
| Taxa de aprendizagem ( $\alpha$ ) | 0,3                      | 0,3                          |
| Termo de momento ( $\eta$ )       | 0,4                      | 0,4                          |
| Iterações X 1000                  | 20                       | 13                           |

### 3.4- Desempenho das RNA's ótimas

Os valores do RMSE que caracterizam o desempenho da Rede 1 e da Rede 2 ótimas são apresentados na Tabela 4.3 e demonstram a superioridade da modelagem dos dados em questão pela Rede 2, rede esta em que se trabalhou com os dados dos atributos sensoriais removidos e transformados.

Tabela 4. 3 – Valores da raiz quadrada do erro quadrado médio (*RMSE*) obtidos para a Rede 1 e Rede 2 ótimas.



| Modelo | Conjunto de Treinamento | Conjunto de Validação |
|--------|-------------------------|-----------------------|
|        | RMSE                    | RMSE                  |
| Rede 1 | 0,1042                  | 0,1183                |
| Rede 2 | 0,0592                  | 0,0632                |

Comprova-se que a Rede 2 foi adequadamente treinada, já que apresentou um baixo erro (0,0592) se comparado ao erro apresentado pela Rede 1 (0,1042) para a fase de treinamento. É importante ressaltar, também, que a Rede 2 possui uma ótima capacidade de generalização, tendo em vista o baixo valor do RMSE obtido para os dados do conjunto de validação. Já a Rede 1 demonstrou ter uma capacidade de generalização inferior, uma vez que o RMSE dos dados do conjunto de validação para esta rede praticamente duplica o valor apresentado pela Rede 2.

A comparação entre os valores experimentais e os preditos pela Rede 1 e Rede 2 de configuração ótima para os dados do conjunto de validação está ilustrada na Figura 4.4. Os valores experimentais e preditos para os seis atributos sensoriais foram significativamente correlacionados para os dados da Rede 1 ( $p < 0,0007$ ) e para os dados da Rede 2 ( $p < 0,0001$ ), indicando uma boa concordância entre esses valores. Mas é importante ressaltar que os coeficientes de correlação ( $r$ ) entre os valores experimentais e preditos, obtidos por meio da Rede 2, foram superiores aos da Rede 1 para os seis atributos sensoriais estudados, demonstrando que a Rede 2 apresentou um melhor ajuste do modelo neural ao comportamento da relação existente entre as medidas sensoriais e os dados do teor de gordura e água do requeijão.

Diante dessas evidências, selecionou-se a Rede 2 como a melhor técnica de modelagem para os dados estudados.









Figura 4. 4 - Comparação entre os valores experimentais e preditos pela Rede 1 e pela Rede 2 para os seis atributos estudados.

### 3.5 – Modelagem por RLM

A influência do teor de gordura e de água nos atributos sensoriais foi modelada estatisticamente por meio das equações apresentadas na Tabela 4.4. Os modelos foram testados quanto à falta de ajuste e significância dos parâmetros da regressão.

Tabela 4. 4 - Modelagem estatística do efeito da gordura e da água nos atributos sensoriais do requeijão *light* adicionado de CPS.

| Atributo sensorial   | Modelo                                            | R <sup>2</sup> |
|----------------------|---------------------------------------------------|----------------|
| Aroma característico | $Y = - 50,1524 + 0,4762 \cdot G + 0,7100 \cdot A$ | 0,6244         |
| Consistência         | $Y = 73,3558 - 0,5619 \cdot G - 0,8985 \cdot A$   | 0,9296         |
| Espalhabilidade      | $Y = - 62,2642 + 0,6175 \cdot G + 0,8591 \cdot A$ | 0,8969         |
| Sabor característico | $Y = - 51,9439 + 0,4739 \cdot G + 0,7388 \cdot A$ | 0,7340         |
| Viscosidade          | $Y = 68,9211 - 0,5658 \cdot G - 0,8326 \cdot A$   | 0,9161         |
| Adesividade          | $Y = 73,9434 - 0,6036 \cdot G - 0,90154 \cdot A$  | 0,9013         |

Y: variável resposta; G: teor de gordura; A: teor de água; R<sup>2</sup>: coeficiente de determinação.

Os teores de gordura e água contribuíram positivamente para a intensidade dos atributos aroma característico, sabor característico e espalhabilidade e, negativamente, para os atributos consistência, viscosidade e adesividade.

### 3.6 – Comparação entre os modelos da RNA de melhor desempenho (Rede 2) e da RLM

Os valores preditos dos dados do conjunto de validação, obtidos por meio da modelagem utilizando a Rede 2 e a RLM, em relação aos seis atributos sensoriais das formulações de requeijão *light*, foram comparados com os valores experimentais medidos pelos julgadores treinados que participaram da ADQ, conforme mostrado na Figura 4.5.

Verifica-se na Figura 4.5 que as duas técnicas apresentaram elevados coeficientes de correlação ( $r > 0,9600$ ) para todos os atributos sensoriais

avaliados e esses foram estatisticamente significativos ( $p < 0,0001$ ), indicando um bom ajuste tanto do modelo da Rede 2 quanto da RLM para explicar as variáveis dependentes em função das variáveis independentes (teor de gordura e água). É importante ressaltar ainda que, analisando-se de forma minuciosa os coeficientes de correlação entre os valores experimentais e preditos para os atributos sensoriais, pode-se constatar que esses são bem próximos para ambos os casos, apresentando uma superioridade desses valores para a modelagem realizada pela Rede 2 para os atributos de consistência, espalhabilidade, aroma, sabor e adesividade. Isto sugere que a técnica da RNA adequou-se de forma mais apropriada à modelagem do comportamento desses dados, realizando uma predição dos mesmos com maior acuracidade.

Em relação aos RMSE's dos dados do conjunto de validação apresentados na Tabela 4.5, para cada atributo sensorial, correspondentes às duas ferramentas de modelagem, pode-se afirmar que, em relação à capacidade preditiva dos dois métodos, a Rede 2 proporcionou melhores resultados que a RLM, visto que o valor do RMSE para a Rede 2 é inferior ao da RLM para a maioria dos atributos sensoriais. Além disso, por meio do teste t pareado, ao nível de 10 % de significância, a hipótese de nulidade ( $H_0$ ) foi rejeitada (valor de  $t_{calc} = 2,37$  ( $p = 0,0643$ )). Assim, existe diferença significativa ( $p < 0,10$ ) entre os valores dos RMSE's dos atributos sensoriais preditos pela RNA e RLM. Visto que o RMSE médio para RNA é menor se comprado ao da RLM, pode-se afirmar que a Rede 2 apresenta uma vantagem em relação à RLM para predizer, de uma forma geral, as notas para os seis atributos sensoriais.

Estes resultados deixam claro que o modelo desenvolvido pela RNA (Rede 2) foi mais preciso, quando comparado ao da RLM, em relação à sua capacidade de predizer os atributos sensoriais que descrevem o perfil sensorial das formulações dos requeijões.









Figura 4. 5 - Comparação entre os valores experimentais e preditos pela Rede 2 e pela RLM para os seis atributos estudados.

Tabela 4. 5 – RMSE para os dados do conjunto de validação.

| Atributo             | RMSE da Rede 2 | RMSE da RLM |
|----------------------|----------------|-------------|
| Consistência         | 0,5802         | 0,8222      |
| Espalhabilidade      | 0,8802         | 1,1167      |
| Aroma característico | 1,0877         | 1,0697      |
| Sabor característico | 1,0132         | 0,9589      |
| Viscosidade          | 0,8200         | 0,9591      |
| Adesividade          | 0,7223         | 0,9811      |
| Média                | 0,8506         | 0,9846      |

Resultados similares foram observados por Mohebbi et al. (2009) ao compararem as ferramentas de RNA e RLM para estimar o nível de desidratação de camarão por meio da análise de cor durante o processo de secagem. Os coeficientes de correlação entre os valores experimentais e preditos para os dados de teste/validação foram de 0,86 e 0,80 para o modelo de RNA e RLM, respectivamente. Assim, eles deduziram que o modelo da RNA pôde prever o conteúdo de umidade, mais precisamente, ao mesmo tempo que, realizando um teste t pareado, foi mostrado que houve diferença significativa entre RLM e RNA ( $p = 0,032$ ).

Este resultado também foi encontrado por Dvir et al. (2006), que realizaram um estudo a fim de comparar as técnicas de RNA e RLM para identificar fatores críticos que afetam o sucesso da gestão dos projetos de defesa de alta tecnologia. Eles mostraram que, em média, o erro quadrado médio da RNA (0,0476) foi menor se comparado ao da RLM (0,0579); concomitantemente, realizaram um teste t pareado nos resultados encontrados para os erros quadrados médios e verificaram que, ao nível de 5 % de significância, a hipótese de nulidade foi rejeitada levando-os à conclusão de que a vantagem da RNA foi estatisticamente significativa.

## 4 – CONCLUSÃO

Predizer o perfil sensorial de alimentos a partir de dados de sua composição química é uma alternativa atraente para indústrias alimentícias que buscam reduzir o tempo e o custo necessários para se realizar testes descritivos de seus produtos. Embora ambas as técnicas de modelagem (RNA e RLM) tenham apresentado resultados satisfatórios para prever os atributos sensoriais do requeijão, houve uma melhora significativa na predição dos dados realizada pela Rede 2 ao nível de 10 % de significância. Além disso, essa rede demonstrou possuir uma excelente capacidade de predição de dados que não estavam presentes durante o seu treinamento, uma vez que apresentou um baixo erro (0,0632) para os dados de validação .

É importante ressaltar que uma das principais vantagens da utilização da Rede 2 na predição dos atributos sensoriais que caracterizam o requeijão *light* é que, ao contrário da RLM, abordagem que precisa de um modelo distinto para prever cada atributo avaliado, a RNA fornece a oportunidade de prever todos os atributos sensoriais por meio de um único modelo. Outro ponto favorável, também muito importante, é que ela pode automaticamente aproximar qualquer função matemática não-linear. Este aspecto é particularmente útil quando a relação entre as variáveis não é conhecida ou é complexa e, portanto, torna-se difícil lidar com métodos estatísticos.

Dessa forma, constata-se que a RNA teve melhor poder de explicação e predição das medidas dos atributos sensoriais que descrevem o perfil sensorial das formulações dos requeijões em estudo, se comparada ao tradicional método estatístico.

## 5 - REFERÊNCIAS

- BARDOT, I.; BOUCHEREAU, L.; MARTIN, N.; ALAGOS, B. Sensory-instrumental correlation by combining data analysis and neural network techniques. **Food Quality and Preference**, v.5, p.159-166, 1994.
- BLEIBAUM, R. N.; STONEA, H.; TANB, T.; LABRECHEB, S.; SAINT-MARTIN, E.; ISZ, S. Comparison of sensory and consumer results with electronic nose and tongue sensors for apple juices. **Food Quality and Preference**, v.13, p.409-422, 2002.
- CHEN, C. H. On the relationships between statistical pattern recognition and artificial neural Networks. **International Journal of Pattern Recognition and Artificial Intelligence**, v.5, p.655-661, 1991.
- DELLA LUCIA, S. M. **Métodos estatísticos para avaliação da influência de características não sensoriais na aceitação, intenção de compra e escolha do consumidor**. 2008. 116p. Tese (Doutorado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Viçosa, Viçosa-MG.
- DONAHUE, D. W.; BENOIT, P. W.; LAGASSE, B. J.; BUSS, W. R. Consumer and instrumental evaluation of Maine wild blueberries for the fresh pack market. **Postharvest Biology and Technology**, v.19, n.3, p.221-228, 2000.
- DVIR, D.; BEN-DAVID, A.; SADEH, A.; SHENHAR, A. J. Critical managerial factors affecting defense projects success: a comparison between neural network and regression analysis. **Engineering Applications of Artificial Intelligence**, v.19, p.535-543, 2006.
- HELLAND, S. I.; TRYGVE, A. Comparison of prediction methods when only a few components are relevant. **Journal of the American Statistical Association**, v.89, n.426, p.583-591, 1994.
- KRISHNAMURTHY, R.; SRIVASTAVA, A. K.; PATON, J. E.; BELL, G. A.; LEVY, D. C. Prediction of consumer liking from trained sensory panel information: Evaluation of neural networks. **Food Quality and Preference**, v.18, p.275-285, 2007.



LEFÈVRE, N.; WATSON, A. J.; WATSON, A. R. A comparison of multiple regression and neural network techniques for mapping *in situ*  $p\text{CO}_2$  data. **Tellus**, v.57B, p.375-384, 2005.

LABE, D.; RITZ, A.; HUGI, A. Training is a critical step to obtain reliable product profiles in a real food industry context. **Food Quality and Preference**, v.15, p.341-348, 2004.

LUNDAHL, D. S.; MCDANIEL, M. R. The panelist effect-fixed or random. **Journal of Sensory Studies**, v.3, p.113-121, 1988.

LUNDAHL, D. S.; MCDANIEL, M. R. Use of contrasts for the evaluation of panel inconsistency. **Journal of Sensory Studies**, v.5, p.265-277, 1990.

MASTERS, T. **Practical neural network recipes in C<sup>++</sup>**. London: Academic Press, 1993.

MEILGAARD, M. C., CIVILLE, G. V., CARR, B. T. **Sensory evaluation techniques**, 4 ed. Boca Raton, FL: CRC, 2006.

MINAI, A. A.; WILLIAMS, R. D. Acceleration of back-propagation through learning rate and momentum adaptation. **International Joint Conference on Neural Networks**, v.1, p.676-679, 1990.

MOHEBBI, M., AKBARZADEH-T, M-R.; SHAHIDI, F., MOUSSAVI, M., GHODDUSI, H-B. Computer vision systems (CVS) for moisture content estimation in dehydrated shrimp. **Computers and Electronics in Agriculture**, v.69, p.128-134, 2009.

MURRAY, J. M.; DELAHUNTY, C. M.; BAXTER, I. A. Descriptive sensory analysis: past, present and future. **Food Research International**, v.34, p.461-471, 2001.

NAYAK, M. S.; DWIVEDI, R.; SRIVASTAVA, S. K. Transformed cluster analysis: An approach to the identification of gases/odours using an integrated gas-sensor array. **Sensors and Actuators B**, v.12, p.103-110, 1993.

NEURALWARE. **Neural computing: a technology handbook for NeuralWorks 1Professional II / Plus**. USA, Neuralware: 2001. 325p.

NI, H.; GUNASEKARAN, S. Food quality prediction with neural networks. **Food Technology**, v.52, n.10, p.60-65, 1998.

NUI, A.; LI, D. L.; WAN, L.; WEE, W. G. A comparative study of model fitting by using neural networks and regression. **Proceedings of SPIE-International Society of Optical Engineering**, v.1469, p.495-505, 1991.

PALIWAL, M.; KUMAR, U. A. Neural networks and statistical techniques: A review of applications. **Expert Systems with Applications**, v.36, p.2-17, 2009.

PANAGOU, E. Z.; SAHGAL, N.; MAGAN, N.; NYCHAS, G. J. E. Table olives volatile fingerprints: Potential of an electronic nose for quality discrimination. **Sensors and Actuators B**, v.134, p.902-907, 2008.

REGAZZI, A. J. **Modelos Lineares**. Departamento de Estatística, Universidade Federal de Viçosa, 2010.

RIBEIRO JÚNIOR, J. I. **Análises estatísticas no SAEG**. Departamento de Informática, Universidade Federal de Viçosa, 2001. 301p.

RICHTER, V. B. **Desenvolvimento de uma técnica descritiva por ordenação**. Londrina: UEL. 2006. 74p. Tese (Mestrado em Ciência de Alimentos) - Universidade Estadual de Londrina, Londrina – MG.

RODRIGUE, N.; GUILLET, M.; FORTIN, J.; MARTIN, J.F. Comparing information obtained from ranking and descriptive tests of four sweet corn products. **Food Quality and Preference**, v.11, n.1, p.47-54, 2000.

SILVA, R. C. S. N. **Caracterização sensorial e reológica de requeijão light adicionado de concentrado protéico de soro**. 2010. 147p. Tese (Mestrado em Ciência e Tecnologia de Alimentos) - Universidade Federal de Viçosa, Viçosa –MG.

SRIVASTAVA, A. K. Detection of volatile organic compounds (VOCs) using SnO<sub>2</sub> gas sensor array and artificial neural network. **Sensors and Actuators B**, v.96, p.24-37, 2003.

STONE, H.; SIDEL, J. L. **Sensory evaluation practices**. (3rd ed.) New York: Academic. 2004.

## CONCLUSÃO GERAL

Os passos necessários para se desenvolver e avaliar o desempenho de uma Rede Neural Artificial foram descritos e exemplificados de forma sucinta, com enfoque para as aplicações voltadas para área de Análise Sensorial de Alimentos, mais especificamente, para modelar a relação entre dados referentes ao perfil sensorial e aceitabilidade de requeijão *light*, a partir de informações sobre suas medidas instrumentais e seus diferentes teores de gordura e água.

Rede Neural Artificial demonstrou grande capacidade para a modelagem dos dados aplicados à análise sensorial, com vantagens como precisão e simplicidade, já que não requerem informações a priori a respeito da relação existente entre os dados a serem estudados e podem fornecer respostas adequadas e rápidas para novas informações não apresentadas previamente.

A rede com configuração de 8-3-9-2 neurônios em suas camadas foi a que melhor se adequou à modelagem da relação entre medidas sensorio-instrumentais do requeijão *light*, apresentando excelente capacidade de generalização, para quaisquer novos dados de entrada que se encontrem dentro da faixa de valores estudada, com um erro (RMSE) de validação de 0,0506.

O modelo de RNA que apresentou melhor desempenho na classificação dos requeijões na classe “aceito” e “rejeitado” foi composto por 8-3-3-2 neurônios em suas camadas (Rede 2 – rede construída com dados transformados). Essa rede apresentou elevada precisão na correta classificação das formulações dos requeijões nas duas categorias especificadas, com um baixo erro (RMSE) de validação de 0,1022.

Na etapa em que se avaliou a capacidade preditiva dos atributos sensoriais dos requeijões a partir de dados de sua composição química (teor de gordura e água), a rede com 2-15-6-6 neurônios em suas camadas (Rede 2 – rede modelada com dados removidos e transformados) foi a que apresentou menor erro (RMSE) de validação, de 0,0632, para os dados que não foram apresentados durante o treinamento da mesma.

O modelo de RNA (Rede 2 do caso acima) apresentou melhor desempenho na predição dos atributos sensoriais do requeijão quando comparado ao modelo desenvolvido por meio de Regressão Linear Múltipla. Nesse caso, o modelo de RNA demonstrou grande potencial como alternativa para os métodos estatísticos tradicionais, como a RLM, com vantagens como precisão, simplicidade, não requerer conhecimentos aprofundados de estatística, predição e classificação de dados por meio de um único modelo.

Em todos os casos pôde-se comprovar o potencial que essa ferramenta possui para aplicações na Análise Sensorial. Além disso, tal técnica possui vantagens que a torna atrativa para aplicações na indústria de alimentos, uma vez que sua utilização promoveria redução de tempo e custos envolvidos na execução de análises descritivas dos alimentos e pesquisas e testes com consumidores.