

# SISTEMA PARA CLASSIFICAÇÃO DE MÉIS BASEADO EM REDES NEURAIS

E. F. DIAS<sup>1</sup>, M. M. de ALMEIDA<sup>2</sup> e E. R. DUARTE<sup>3</sup>

<sup>1</sup>Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa, Departamento de Engenharia Química

<sup>2</sup>Universidade Estadual de Ponta Grossa, Departamento de Engenharia de Alimentos

<sup>3</sup>Universidade Tecnológica Federal do Paraná, Campus Ponta Grossa, Departamento de Engenharia Química

E-mail para contato: erduarte@utfpr.edu.br

**RESUMO** – A classificação do mel está relacionada com a origem da matéria prima utilizada pelas abelhas na sua elaboração. O objetivo deste trabalho foi programar um sistema que utiliza redes neurais artificiais (RNA) para classificação do tipo de mel, utilizando como entrada da rede o pH e % de açúcar redutor. RNA é um modelo matemático que pode ser facilmente traduzida para uma linguagem comum de programação e bastante aplicado em diversas áreas. O tipo de rede neural utilizada foi *Multilayer Perceptron* com algoritmo de aprendizagem do tipo *Backpropagation*. Para o modelo neural foram testadas diferentes arquiteturas de redes sendo escolhida a com quatro neurônios na camada intermediária. Para o treinamento e teste das redes avaliadas foram utilizadas 25 amostras de méis. O sistema desenvolvido mostrou-se eficiente na classificação dos méis, utilizando apenas dois parâmetros físico-químicos, diminuindo os custos e tempo para classificação, além de possuir uma interface amigável.

Palavras-chave: sistema, amigável, classificação, redes neurais, mel.

## 1. INTRODUÇÃO

O mel de melato difere do mel floral em várias propriedades: possui menor concentração de açúcares redutores, maior teor de oligossacarídeos, cinzas e maior valor de pH. Na legislação brasileira as especificações físico-químicas para os valores de açúcares redutores, sacarose aparente e minerais são distintas para os dois tipos de mel.

O aumento no interesse em questões associadas à identificação desses produtos tem sido no controle de qualidade e como forma de proteger o consumidor da especulação comercial (CONSONNI; CAGLIANI, 2008). De acordo com Marena et al. (2011) diversos trabalhos foram desenvolvidos na caracterização do mel brasileiro com o objetivo principal de contribuir para a valorização do produto regional. Devido à diversidade de fatores que influencia na qualidade final do mel, a análise estatística pode ser uma ferramenta poderosa na classificação.

Os modelos computacionais como as redes neurais artificiais (RNA) são algoritmos que têm a capacidade de aproximação dos valores de saída baseados nos dados de entrada sem qualquer conhecimento prévio do modelo e da complexidade do mecanismo, neste caso à relação entre os resultados das análises físico-químicas (dados de entrada) e classificação da

origem do mel (dados de saída) (CABRERO e PIETRO, 2010; MARENDA et al, 2011).

São sistemas paralelos que possuem unidades de processamento simples, denominados neurônios artificiais. Esses neurônios artificiais são responsáveis por calcular funções matemáticas associadas aos Pesos Sinápticos. Esses Pesos Sinápticos que representam o conhecimento adquirido pelo modelo quando dados de entrada e saída (padrões) são apresentados à rede neural, que possuem o objetivo de ponderar as entradas recebidas por cada neurônio artificial (BRAGA et al., 2007)

Em uma primeira etapa, a rede neural é treinada, ou seja, um conjunto de dados selecionados de entrada com sua respectiva saída é apresentado à rede, a qual é responsável por adquirir um padrão entre esses dados. É esse padrão adquirido que posteriormente é utilizado para gerar respostas em uma simulação.

Neste trabalho foi usada a RNA do tipo *Multilayer Perceptron* (MLP), devido a sua simplicidade matemática e a alta precisão de resposta em sistemas de classificação, com cerca de 90% a 100% de precisão (DEBSKA, GUZOWSKA-SWIDER, 2011). Para aprendizagem da rede foi utilizado o algoritmo *Backpropagation*.

A linguagem de programação Delphi é uma linguagem de alto nível e que mais se aproxima da linguagem utilizada pelo ser humano (SOMERA, 2007). Possui um compilador próprio e uma IDE (*Integrated Development Environment*), ou seja, não é apenas uma linguagem de programação, mas representa um ambiente repleto de recursos computacionais que proporcionam todas as ferramentas necessárias para desenvolver qualquer tipo de software desktop. Por essas razões, o sistema computacional utilizado para, o treinamento da RNA, bem como os testes de validação, simulação e teste de otimização de parâmetros, foi desenvolvido em linguagem Delphi

## 2. METODOLOGIA

### 2.1. Modelo Neural

A rede neural utilizada é do tipo *Multilayer Perceptron* (MLP), na qual o fluxo de informação é direcionado das camadas de entrada para as camadas de saída, é formada por três tipos de camadas: Entrada, as Intermediárias e a Saída. A camada de entrada recebe os dados de entrada que seguem para as camadas intermediárias, as quais processam essas informações e as enviam para a camada de saída, conforme a Figura 1.

Considerando a Figura 1, um neurônio “i” da camada “k”, recebe um conjunto de informações “ $X_{j(k-1)}$ ”, correspondentes as saídas “ $n_{k-1}$ ” dos neurônios da camada anterior, ponderadas, cada uma, pelo correspondente peso da conexão “ $w_{i,j}^{(k)}$ ”. O neurônio soma essas entradas ponderadas e o valor resultante é por sua vez somado a um limite interno de ativação, um bias que pode ser descrito por “ $w_{i,0}^{(k)}$ ”. A esse sinal resultante, o neurônio “i” produz uma resposta “ $X_i^{(k)}$ ”, de acordo com uma função limite ou função de ativação  $f(\cdot)$ , sendo normalmente aplicadas as funções sigmoidal lógica ou tangente hiperbólica. Pode-se então generalizar a RNA pelas Equações 1 e 2.

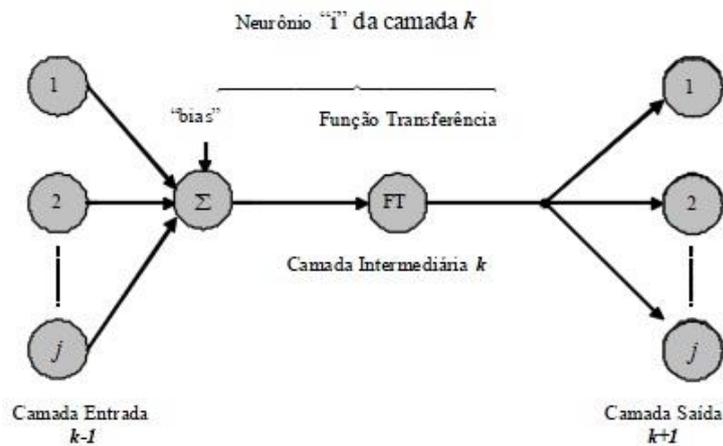


Figura 1 – Esquema do modelo neural generalizado.

$$S_i^{(k)} = w_{i,0}^k + \sum_{j=1}^{(n_{k-1})} w_{i,j}^{(k)} X_j^{(k-1)} \quad (1)$$

$$X_i^{(k)} = f(S_i^{(k)}) \quad (2)$$

Neste modelo neural, cada uma das camadas que compõem a camada intermediária pode possuir um número variável de neurônios. Estes são interligados em rede por meio de parâmetros ajustáveis, chamados pesos sinápticos. Os neurônios das camadas de entrada e saída estão associados às condições iniciais e as respostas do sistema, respectivamente. Assim, é o número de neurônio das camadas intermediárias que determinam o grau de complexidade de uma RNA (HAYKIN, 2001). Em suma, aumentando o número de neurônios nessas camadas, obtém-se um grau de complexidade maior, o que, dependendo dos dados utilizados e do sistema que eles representam pode ajudar a encontrar uma melhor solução, porém, um maior tempo computacional é necessário para o ajuste de todos os parâmetros. Desta forma, é de grande importância à avaliação do número de neurônios das camadas intermediárias para cada sistema, buscando o aperfeiçoamento da arquitetura da rede (STRAPASSON, 2003).

As redes utilizadas foram treinadas com o algoritmo de aprendizagem *Backpropagation* e função de ativação a *sigmoide*, a taxa de aprendizagem (que relaciona a velocidade de ajuste dos pesos das redes) foi testada entre 0,1 e 0,9.

Uma das formas de identificação de méis bastante utilizada foi descrita por Kirkwood (1960 e 1961) que se baseia na diferenciação dos parâmetros físico-químicos e na equação de Kirkwood, mas outros procedimentos de identificação da origem do mel podem ser empregados. Marena et al. (2011) cita análises físico-químicas combinada com redes neurais, análise do perfil de carboidratos por cromatografia líquida e gasosa (RUIZ-MATUTE et al., 2010) e análise do teor de cinzas (MADEJCZYC e BARALKIEWICZ, 2008).

Para escolha da arquitetura da rede neural, foram testados os parâmetros de entrada: pH, açúcares redutores e cinzas, bem como parâmetros de saída: tipo de mel (floral ou melato). Após estas análises preliminares observou-se que igualmente ao obtido por Marena

et al. (2011) as redes neurais conseguiram classificar os tipos de mel com apenas 2 parâmetros de entrada. Desta forma, as redes utilizadas possuem 2 neurônios na camada de entrada, que são obtidos experimentalmente, sendo estes pH e % de açúcar redutor. Um neurônio na camada de saída que define o tipo de mel (floral ou melato) e uma camada intermediária, na qual foram estudadas redes diferente número de neurônios.

Para o treinamento e testes das redes foram utilizados os dados obtidos por 25 amostras de mel adquiridas no comércio local de diferentes municípios do estado do Paraná-Brasil, pertencentes à região dos Campos Gerais. Sendo 30% utilizadas para teste e 70% para treinamento das redes.

## 2.1. Análise Sistêmica

Para determinar o melhor caminho racional para que a informação possa ser processada pelo sistema a ser desenvolvido é necessária uma análise antecipada para prever o sistema como um todo (estrutura, *designer*, algoritmos, banco de dados) e todas as variáveis envolvidas.

A análise do sistema desenvolvido foi dividida em análise estrutural, análise gráfica (*design*) e análise de processamento (programação).

A estrutura do sistema computacional é descrita na Figura 2, na qual a tela principal do sistema é dividida em Simulação, Treinamento e Teste/Validação.

Na aba simulação será feita a classificação do mel, a partir de um modelo neural já definido, para isto o usuário deve entrar com os dados de pH e % de açúcar redutor e obterá como resposta o tipo de mel.

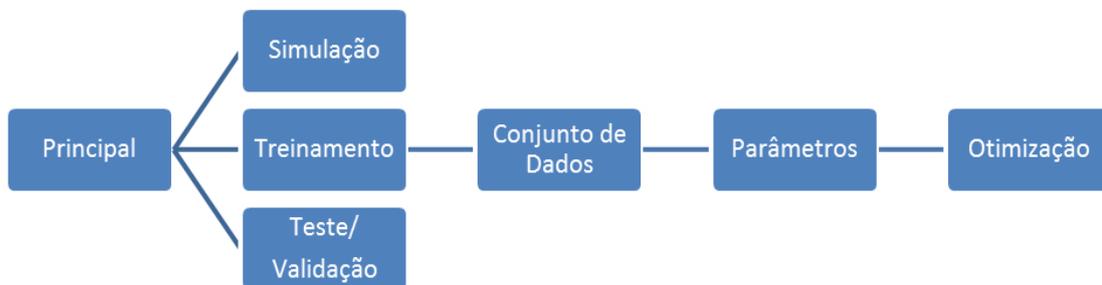


Figura 2 – Esquema do modelo neural generalizado.

A aba treinamento permite ao usuário definir um novo modelo neural, ou seja, treinar novamente a rede. Para isto, o usuário deve possuir um novo número de dados experimentais (no mínimo 25 amostras de mel já classificadas entre melato e floral). O conjunto de dados deve ser dividido para as etapas de treinamento e teste/validação. Do número total de amostras 70% deve ser utilizado para treinamento e 30% para teste. Esta aba só será utilizada caso o usuário tenha estes conjuntos de dados e queira gerar um novo modelo neural. Para gerar um novo modelo neural o usuário deve inserir o novo conjunto de dados e parâmetros da rede no sistema que o mesmo irá encontrar o melhor modelo neural na etapa de otimização.

O Conjunto de dados: são os valores de pH, açúcar redutor e tipo de mel este conjunto deve possuir amostras aleatórias dos tipos de mel melato e floral.

Parâmetros da Rede: vão definir os valores que serão testados na etapa de otimização para: taxa de aprendizagem, número de camadas intermediárias, número máximo de iterações e a quantidade de neurônios na camada intermediária.

Otimização: Nesta etapa o sistema desenvolvido faz vários testes com os parâmetros da rede inseridos (etapa anterior) e escolhe a rede que possui o menor erro na etapa de aprendizagem (através do erro quadrático entre a resposta real e a resposta gerada pela rede). No final desse processamento, automaticamente é selecionada a rede que representa o novo modelo neural.

Na etapa de teste e validação, o usuário irá testar o novo modelo neural gerado na etapa de otimização para isto deve inserir o conjunto de dados reservados para o teste/validação. Ou seja, os 30% do total dos dados experimentais. Nesta etapa o sistema compara qual o melhor modelo neural o antigo (*default*) do sistema ou novo (gerado na etapa de otimização). A escolha do melhor modelo neural ocorre a partir do menor erro quadrático para as redes testadas.

Como o sistema foi direcionado a aplicação de classificação de mel, foi desenvolvido o *designer* gráfico voltado a esse tipo de aplicação. O Delphi 7 possui excelentes recursos gráficos para esse tipo de aplicabilidade, com o objetivo principal de tornar os sistemas desenvolvidos através dele, acessíveis e simplórios, de fácil utilização pelo usuário através de uma *interface* amigável.

## 2.2 Teste em Aplicação

Após o desenvolvimento do sistema, foi realizado treinamento para a classificação do mel em floral ou melato através dos dados experimentais entrada (pH e % de ar) e saída (tipo de mel), dos 25 dados experimentais 30% foram utilizados para treinamento.

Para definição do modelo neural foi realizada uma varredura via programação, esta é realizada através de vários *loops* que quando o sistema é executado em fase de treinamento, automaticamente altera os parâmetros de aprendizagem e executa o treinamento conforme a variação definida anteriormente em *parâmetros*. No processo de teste, o sistema busca todos os testes realizados em *treinamento* e compara os valores simulados com os valores fornecidos como parâmetro de teste acima citados, retornando ao usuário os valores do erro calculado nessa comparação, fornecendo assim qual são os parâmetros que propiciaram um aprendizado mais eficiente e de menor erro.

Para o aprendizado, foi imposto o uso de três camadas sendo a variação dos neurônios da camada intermediária de 2 a 20. Definiu-se como valor de interações máximas como sendo 100.000.000. As taxas de aprendizagem testadas de 0,1 e 0,9.

## 3. RESULTADOS E DISCUSSÕES

O protótipo do sistema SoftMel foi desenvolvido em programação e *interface* gráfica amigável, de fácil uso e execução, com uma programação sucinta e eficiente.

A Figura 3 apresenta a tela principal do sistema SoftMel onde são executadas as simulações de classificação. Como resposta, o sistema retorna ao usuário o tipo de mel baseados nos dados inseridos de pH e açúcar redutor

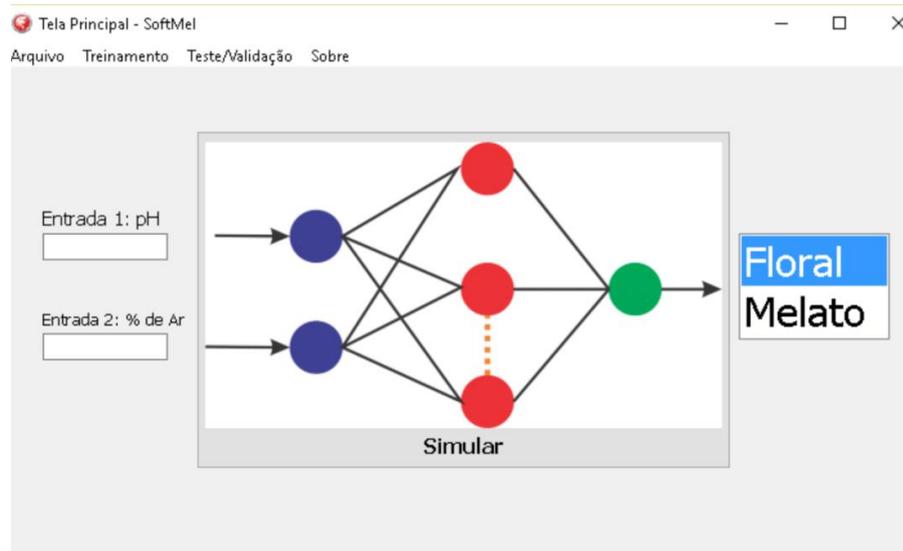


Figura 3 – Tela inicial do sistema Softmel.

Na Figura 4, é representada a tela para definição de um novo modelo neural, que se refere à aba treinamento, na qual o usuário fará a inserção de dados de entrada, treinamento e teste.

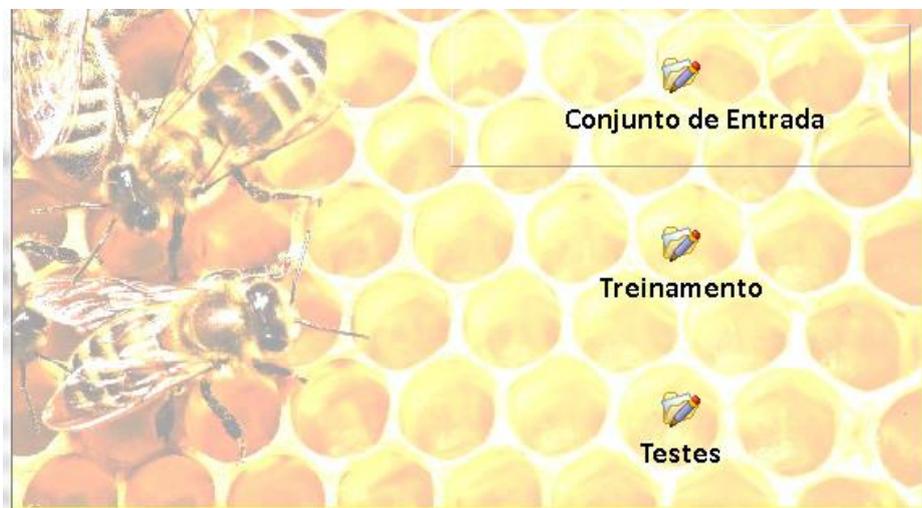


Figura 4 – Definição de novo modelo neural.

Ao clicar no Conjunto de dados de entrada o usuário deve inserir manualmente o conjunto de dados (pH, açúcar redutor e tipo de mel) reservados para o treinamento. Ao clicar em Treinamento, o usuário insere os parâmetros da RNA (relacionado às arquiteturas de redes que serão testadas). Ao clicar em testes o sistema processa a etapa de otimização e determina qual melhor modelo neural comparando o existente no sistema e o gerado a partir dos novos dados experimentais.

Para definição do modelo neural utilizado como padrão (*default*) do sistema SoftMel, foram testadas redes com 3 camadas variando o número de neurônios (de 2 até 20), taxa de aprendizagem 0,1 e 0,9 e executado e com máximo de 100000000 iterações. Como já descrito anteriormente foram utilizadas 25 amostras de méis sendo 70% na etapa de treinamento e 30% na etapa de teste.

Após a escolha da melhor arquitetura o sistema de forma automática salva os pesos para a arquitetura escolhida no no arquivo definido como “*classif\_mel.pesos*”.

Para o conjunto de dados das 25 amostras testadas o sistema desenvolvido apresentou melhores resultados com o modelo neural que possui arquitetura com 4 neurônios na camada intermediária e taxa de aprendizagem igual a 0,9. Desta forma, o modelo *default* do sistema SoftMel apresenta esta arquitetura de rede.

O modelo neural utilizado no sistema desenvolvido conseguiu classificar 100% das amostras testadas, resultado semelhante foi obtido por Marendá et al. (2011). A vantagem deste sistema comparado ao já desenvolvido é a interface amigável, que pode ser utilizada e testada por apicultores e também por órgãos regulatórios de forma rápida e com baixo custo.

#### 4. CONCLUSÃO

O sistema desenvolvido conseguiu identificar todas as amostras testadas o que demonstra um grande potencial para o uso de redes neurais, devido à forma rápida e com baixo custo que foram classificados os tipos de mel. Como o sistema é amigável e de fácil uso o mesmo pode ser aplicado e testado por apicultores, consumidores e até por órgãos regulatórios. O usuário pode utilizar o modelo neural inicial ou definir novo modelo de forma otimizada e simplificada.

#### 6. REFERÊNCIAS

BRAGA, A. P.; CARVALHO, A. C.; LUDERMIR, T. B. *Redes Neurais Artificiais: teoria e aplicações*. 2. ed. São Carlos: LTC, 2007.

CABRERO, A. C.; PRIETO, J. M.; Application of artificial neural networks to the prediction of the antioxidant activity of essential oils in two experimental in vitro models. *Food Chemistry*, v. 118, p. 141–146, 2010

CONSONNI, R.; CAGLIANI, L.R.; Geographical characterization of polyfloral and acacia honey by nuclear magnetic resonance and chemometrics. *Journal of Agricultural and Food Chemistry*. v. 56, p. 6873-6880, 2008.

DĘBSKA, B .GUZOWSKA-SWIDER B.; Application of artificial neural network in food classification. *Analytica Chimica Acta*, v. 705 (1-2), p. 283-291, 2011.

HAYKIN, S. S.; *Redes Neurais Princípios e Prática*. 2. Ed. Bookman, 99, p. 366.2001

KIRKWOOD, K. C.; MITCHELL, T. J.; SMITH, D.; Examination of the occurrence of honeydew in honey. *Analyst*, v. 85, p. 412-416, 1960.

KIRKWOOD, K. C. MITCHELL, T. J.; SMITH, D.; Examination of the occurrence of honeydew in honey. Part. 2, *Analyst*, v. 85, p. 164-165, 1961.

MADEJCZYC, M.; BARALKIEWICZ, D.; Characterization of Polish rape and honeydew honey according to their mineral contents using ICP-MS and F-AAS/AES. *Analytica Chimica Acta*, n. 617, p. 11-17, 2008

MARENDA, T. A. et al. Desenvolvimento de um sistema para classificação do mel em floral e melato por parâmetros físico químicos combinados com redes neurais artificiais. *Evidência*, Joaçaba v. 11 n. 1, p. 61-74, janeiro/junho 2011.

RUIZ-MATUTE, A. I. et al. Gas chromatographic-mass spectrometric charadterisation of tri- and tetrasaccharides in honey. *Food Chemistry*, v. 120, p. 637-642, 2010.

SOMERA, G. Treinamento Profissional em Delphi. *Digerati Books*, São Paulo, 2007.

STRAPASSON, R. A. Otimização das variáveis do bioprocesso de fermentação no estado sólido para produção de ácido fumárico a partir de resíduos agroindustriais, utilizando redes neurais. 2003. 112 f. Tese (Doutorado em Processos Biotecnológicos)–Universidade Federal do Paraná, Curitiba, 2003.