



A UTILIZAÇÃO DE REDES NEURAIS ARTIFICIAIS NA CIÊNCIA DOS ALIMENTOS

Ana Paula Ayub da Costa Barbon¹, Sylvio Barbon Júnior²

1. Doutoranda pela Universidade Estadual de Londrina, Londrina, Brasil (apbarbon@gmail.com)
2. Prof. Dr. Universidade Estadual de Londrina, Londrina, Brasil.

Recebido em: 12/04/2014 – Aprovado em: 27/05/2014 – Publicado em: 01/07/2014

RESUMO

A utilização de Redes Neurais Artificiais (RNAs) como solução para muitos problemas de classificação é uma realidade em diversas áreas do conhecimento e na Ciência dos Alimentos vem ganhando cada vez mais espaço. As RNAs tem a característica de simular a capacidade de aprendizado do cérebro humano, inferindo o conhecimento por meio de exemplos, o que possibilita a automatização e otimização de processos. Esta abordagem pode ser aplicada na classificação e predição de classes de problemas, por exemplo, a segurança e qualidade dos alimentos atuando na melhoria das técnicas de avaliação. O objetivo deste artigo foi abordar as diversas pesquisas que utilizaram as RNAs em detrimento da melhoria da cadeia produtiva dos alimentos, discutindo as várias arquiteturas e resultados obtidos.

PALAVRAS-CHAVE: Alimentos, Inteligência Artificial, Redes Neurais Artificiais, Tecnologia.

THE USE OF ARTIFICIAL NEURAL NETWORKS IN FOOD SCIENCE

ABSTRACT

The use of Artificial Neural Networks (ANN) as a solution to many problems of classification is a reality in several areas of knowledge and Food Science has been gaining more space. The RNA has the feature of simulate the learning capacity of the human brain, inferring knowledge through examples, which enables the automation and processes optimization. This approach can be applied to classify and predict classes of problems, for example, the safety and quality of food acting to improve assessment techniques. The aim of this paper was to address the several researches using the ANN at the expense of improving the food supply chain, discussing the various architectures and results.

KEYWORDS: Food, Classification, Prediction, Artificial Neural Networks, Technology.

INTRODUÇÃO

O Brasil se destaca no agronegócio mundial como um dos principais fornecedores de alimentos, contribuindo de forma significativa para a economia nacional. As projeções de 2012 a 2023 indicam um crescimento no setor agropecuário permitindo ao país abastecer, anualmente, 200 milhões de brasileiros e excedentes exportáveis para mais de 200 países (BRASIL, 2013). Para continuar

em posição de destaque neste cenário, investimentos em qualidade e tecnologia são primordiais para o diferencial competitivo e para o avanço do estado da arte.

Em uma indústria de alimentos a garantia da qualidade dos produtos em todas as fases produtivas, desde o recebimento da matéria-prima até o seu armazenamento, é a chave fundamental para o sucesso. Ela fideliza clientes e resulta em maior participação da indústria neste mercado em expansão. A garantia da segurança do alimento é um requisito substancial para a aceitabilidade do consumidor e está inserida na qualidade da saúde pública (BHUNIA, 2008).

De uma forma geral os métodos tradicionais de avaliação do alimento consistem e dependem da subjetividade humana, por isso são métodos tediosos, trabalhosos e demorados que não fornecem a resposta imediata necessária para a tomada de decisão. A necessidade do uso de técnicas que avaliam de forma menos subjetiva todas as etapas de processamento da cadeia de alimentos está cada vez mais sendo pesquisada (ARGYRI et al., 2010).

Neste contexto, a abordagem computacional como a utilização de técnicas de Inteligência Artificial para a cadeia produtiva de alimentos vem ganhando destaque, principalmente com a utilização de Redes Neurais Artificiais (RNAs). As RNAs possuem como princípio central simular a capacidade de aprendizado do cérebro humano. Segundo SILVA et al. (2010), as RNAs são modelos computacionais inspirados no sistema nervoso dos seres vivos com capacidade de aquisição e manutenção do conhecimento, podendo ser aplicada em diversas áreas.

Semelhante ao cérebro humano, as RNAs recebem uma série de informações de entrada ligadas a fatores de pesos e o aprendizado da rede neural sobre essas informações irá gerar o conhecimento, expressa pela saída da rede. Trata-se de um processo robusto e versátil, principalmente pela variedade de arquiteturas que podem ser implementadas para cada tipo de problema. Essa é uma ferramenta poderosa para problemas não-lineares de alta complexidade como a avaliação dos alimentos, sendo o único inconveniente a necessidade de qualidade da amostragem (MARINI, 2009).

O objetivo deste artigo foi abordar algumas das diversas pesquisas e a aplicação das RNAs no campo da Ciência dos Alimentos. Foram selecionados trabalhos que descreviam as arquiteturas, justificativas e procedimentos do uso das RNAs.

CIÊNCIA E TECNOLOGIA DOS ALIMENTOS

Desde os primórdios, a industrialização dos produtos agropecuários contribui para a melhoria da dieta de um país e do estado nutricional dos seus habitantes e a tecnologia alimentar se torna o vínculo entre a produção e o consumo dos alimentos (GAVA, 1984). Nas duas últimas décadas, os hábitos alimentares passaram por diversas modificações demandando o desenvolvimento de novas técnicas de produção, preparação, distribuição e avaliação dos alimentos (OPAS, 2006).

Isso ocorreu devido a crescente preocupação e interesse dos consumidores em saber como os alimentos são produzidos. Além deste cenário de preocupações dos consumidores com a forma de produção, a diferenciação dos produtos se torna uma vantagem competitiva para a indústria de alimentos (POUTA et al., 2010).

A transformação do alimento é um processo complexo que envolve uma série de fatores, principalmente microbiológicos e físico-químicos. Existem aqueles que estão relacionados com as características próprias do alimento, classificados como intrínsecos e os relacionados com o ambiente, classificados como extrínsecos. São considerados fatores intrínsecos: atividade de água, acidez, potencial de oxi-

redução, composição química e a interação entre os microrganismos presentes nos alimentos. Entre os fatores extrínsecos, tem-se como os principais fatores: a temperatura ambiental, a umidade e a composição química da atmosfera onde está inserido o alimento (FRANCO & LANDGRAF, 2005).

A interação entre esses fatores com a qualidade da matéria-prima, do processamento, do armazenamento e distribuição irão direcionar a qualidade do produto final. Essa etapa é de importante valor no momento da escolha do produto pelo consumidor. De fato, os consumidores estão dispostos a adquirirem produtos com qualidade certificada e garantida visando alimentação com saúde e preservação do sabor (WILKINSON, 2002).

Segundo DOGANIS et al. (2006) as empresas de alimentos estão preocupadas com a previsão de vendas aliada a condições especiais como a vida de prateleira curta dos alimentos, a necessidade de manter a alta qualidade dos produtos ofertados e as flutuações das exigências dos consumidores que são causadas por fatores como preço, promoções e as particularidades na preferência dos mesmos.

Contudo, os processos de padronização e avaliação da qualidade dos alimentos ainda são fortemente dependentes da inspeção manual influenciada por fatores subjetivos, o que acarreta em diversos erros e onera tempo e custo. A crescente necessidade de uma gestão da qualidade total nas indústrias demandou a construção de sistemas automatizados, robustos e flexíveis para a avaliação do produto (DEBSKA & GUZOWSKA-SWIDER, 2011).

Dessa forma, ao longo das últimas duas décadas, a inserção de ferramentas computacionais na Ciência dos Alimentos tem-se destacado, principalmente na predição da segurança e qualidade dos mesmos, assim como na melhoria das técnicas de avaliação do alimento. Dentre as várias tecnologias utilizadas, o uso de Inteligência Artificial (IA) por meio das Redes Neurais Artificiais (RNAs) se mostra uma tendência para aplicações que envolvam tecnologias aliadas à qualidade do alimento, buscando sobretudo, a otimização e padronização (HUANG et al., 2007).

REDES NEURAIS ARTIFICIAIS

Segundo COPPIN (2010), a Inteligência Artificial (IA) envolve métodos baseados no comportamento inteligente de humanos e outros animais para solucionar problemas complexos. Este mesmo autor descreve que o objetivo do estudo da IA não é criar um robô tão inteligente quanto o ser humano e sim usar algoritmos, heurísticas e metodologias baseadas nos modos pelos quais o cérebro humano soluciona problemas.

Dentre as várias abordagens da área da IA, as RNAs estão entre as técnicas mais populares para classificação como solução para problemas, assim como os Algoritmos Genéticos. A estrutura das RNAs foi desenvolvida a partir de modelos conhecidos de sistemas nervosos biológicos do cérebro humano, ou seja, as unidades processadoras computacionais são baseadas em uma simplificação dos neurônios biológicos inspirados na análise de geração e propagação de impulsos elétricos pela membrana celular (SILVA et al., 2010).

As RNAs podem resolver problemas não-lineares e fornecem saídas tipicamente contínuas. Dentre os trabalhos que utilizam as RNAs na solução de problemas, é possível identificar o uso no mapeamento de soluções, regressões, modelagem, agrupamento, classificação e análise de dados multivariada (DEBSKA & GUZOWSKA-SWIDER, 2011)

São capazes de realizar funções simples, baseadas na coleta dos sinais encaminhados para suas entradas, agregá-los de acordo com sua função operacional e produzir uma resposta de saída. A Figura 1 representa um modelo de um neurônio artificial e demonstra os diversos sinais de entrada $x_0, x_1, x_2 \dots x_n$ que por meio do processo de aprendizado, representado por $\Sigma \rightarrow f$, ajustam os pesos sinápticos ($w_0, w_1, w_2 \dots w_n$). Durante a fase de treinamento os pesos sinápticos ponderam cada uma das variáveis de entrada, quantificando as suas relevâncias em relação à funcionalidade do respectivo neurônio.

Após a fase de treinamento, com todos os pesos definidos, as entradas a serem avaliadas sofrem atuação dos pesos sinápticos e produzem um valor de potencial de ativação. O resultado é uma função de ativação (f) que produzirá o valor de saída (y) conforme o aprendizado da rede (HUANG et al., 2007; SILVA et al., 2010).




FIGURA 1 - Representação de um modelo de um neurônio artificial.

Fonte: adaptado de HUANG et al. (2007, p. 114).

Segundo RUSSEL & NORVIG (2004), o processo de classificação de padrões via RNA pode ser dividido em três etapas: Treinamento, Testes e Aplicação. A etapa de treinamento pode seguir o paradigma supervisionado, no qual as classes são identificadas e apresentadas para a RNA durante o treinamento, assim, para cada exemplo de treinamento, uma saída esperada é fornecida. O paradigma não supervisionado exige do algoritmo de aprendizado a generalização do conhecimento sem a interferência humana, ou seja, o paradigma irá identificar a quantidade de classes e o modelo para a solução do problema de forma autônoma. Nessa fase, os pesos (w_n) são ajustados para se adequar a saída da rede (y), que representa a classe do problema (RUSSEL & NORVIG, 2004).

Na sequência, a etapa de Testes corresponde à validação do aprendizado adquirido pela RNA, onde são fornecidas e processadas as entradas e verificadas as saídas que são previamente conhecidas. Caso a saída corresponda à classe adequada, o treinamento da RNA é considerado como concluído e deve-se seguir para a próxima etapa. No entanto, se os testes não corresponderem à classe das entradas, o processo de treinamento deve ser repetido, pois o mesmo não é satisfatório. Essa repetição deve ser realizada ajustando-se a quantidade de exemplos de treinamento, adequando as entradas informadas e até mesmo

modificando a arquitetura da RNA (HAYKIN, 2009). A última etapa, Aplicação, trata do uso efetivo da RNA em um ambiente de produção, onde a mesma será utilizada como mecanismo de classificação seguindo o problema real a ser processado (HAYKIN, 2009).

Como apresentado na Figura 1, as RNAs são formadas por neurônios artificiais que podem ser organizados de diferentes maneiras, com diversos tipos de funções de ativação (f). As organizações dos neurônios e suas respectivas interligações são chamadas de arquiteturas, das quais destacam-se: *Multi-Layer Perceptron* (MLP), *Backpropagation* e *Radial Basis Function* (RBF) (HUANG et al., 2007).

MULTI-LAYER PERCEPTRON

RUSSEL & NORVIG (2004) consideram a MLP como uma das representações mais comuns de RNAs. A MLP ou *Perceptron* de Múltiplas Camadas (PCM) é dividida em três partes: neurônios de entrada, neurônios ocultos ou intermediários e neurônios de saída. Um grupo de neurônios com mesma função é denominado uma camada. Na MLP o número de neurônios na camada de entrada é igual ao número de variáveis da entrada e o número de neurônios na camada de saída é igual ao número de variáveis de saída, sendo o número de neurônios em cada camada oculta é adequado ao problema. As variáveis podem ser interpretadas como as características do problema que serão avaliadas (RUSSEL & NORVIG, 2004).

Considerando o mecanismo de aprendizado, na MLP pode-se utilizar a implementação do algoritmo *Backpropagation* que será discutido na próxima subseção ou a regra Delta generalizada, que ajusta de forma gradativa os pesos dos neurônios em direção à classificação adequada aos exemplos do experimento.

Uma das principais vantagens da MLP é tratar problemas com classes não linearmente separáveis (SILVA et al. 2010), se adequando a problemas reais da Ciência e Tecnologia dos Alimentos.

Os pontos negativos da adoção da MLP como arquitetura de RNA tem origem no domínio do problema, pois a quantidade de neurônios da camada escondida deve ser previamente definida e está diretamente associado ao sucesso da generalização do conhecimento (ÖLMEZ & ZÜMRAY, 2003). A velocidade do aprendizado também é um ponto questionável desta arquitetura. Para muitos problemas a arquitetura é uma das mais lentas no processo de aprendizado.

BACKPROPAGATION

Considerada por muitos autores (MARENDA et al., 2011; BALASUBRAMANIAN, et al., 2009; CHEN et al., 2011) como uma arquitetura e para outros apenas um algoritmo de aprendizado (SILVA et al., 2010; ÖLMEZ & ZÜMRAY, 2003; BASHEER & HAJMEER, 2000). Neste trabalho será tratada como uma arquitetura.

O termo *backpropagation* refere-se à maneira como o erro encontrado na classificação é ajustado nos pesos sinápticos da arquitetura. O valor a ser ajustado é propagado para trás a partir da camada de saída, para a camada escondida e finalmente para a camada de entrada (BASHEER & HAJMEER, 2000).

A *Backpropagation* apresenta as mesmas vantagens e desvantagens da MLP, quando utilizada como a regra de aprendizado na MLP. Quando comparada a regra Delta, a *Backpropagation* apresenta precisão superior, justificável pela maneira otimizada de ajustes dos pesos.

RADIAL BASIS FUNCTION (RBF)

Pode ser considerado um caso especial de *Backpropagation* com três camadas (HAN et al., 2012). A camada oculta, ou intermediária, é usada para agrupar as entradas da rede e apresenta uma função de ativação diferente das anteriores. A RBF utiliza uma função de base radial como função de ativação, sendo a gaussiana a mais empregada. A cada treinamento a função gaussiana de cada neurônio se adequa aos padrões aprendidos, formando o conhecimento. Cada neurônio da camada de saída implementa uma combinação linear das funções de base linear (BASHEER & HAJMEER, 2000).

A RBF possui a capacidade de resolução de problemas não lineares e desempenho de treinamento superior às RNAs que solucionam o mesmo tipo de problema, como a MLP (CHEN et al., 2011). A Figura 2 contém um exemplo da delimitação de fronteiras para solução de problemas linearmente não separáveis com a MLP e RBF.




FIGURA 2. Delimitação de fronteiras para um mesmo problema com MLP (esquerda) e RBF (direita).

Fonte: SILVA et al. (2010, p.189)

Na Figura 2 é possível observar a delimitação por função de base radial proposta pela RBF (direita) e como seria a delimitação por uma MLP (esquerda), uma vez conhecida a quantidade de neurônios intermediários necessários. Pode-se interpretar a Figura 2 como duas classes delimitadas pelas linhas pontilhadas criadas pelas RNAs como proposta de separação entre as classes. Na separação adotada pela RBF, nota-se o formato radial, proposto pelo aprendizado de dois neurônios. Diferentemente, a MLP separa as classes por retas associadas ao aprendizado de cada neurônio formando um polígono. Nota-se a quantidade diferente de neurônios para a solução do problema, no entanto ambas arquiteturas realizam a separação.

REDES NEURAIS ARTIFICIAIS E A CIÊNCIA DOS ALIMENTOS

Diante do exposto, essa revisão tem o princípio de descrever trabalhos com aplicação das RNAs em diversos setores alimentícios, suas implicações, resultados, bem como as vantagens da sua utilização.

O foco dos trabalhos são RNAs do paradigma supervisionado, pois são modelos tradicionalmente oferecidos por softwares matemáticos como Matlab, R e Octave (FARRELL et al. 2005; EATON et al., 2007; VENABLES et al., 2014).

DEBSKA & GUZOWSKA-SWIDER (2011) publicaram um trabalho com o uso das RNAs na avaliação da qualidade da cerveja. A escolha das RNAs se deu pela flexibilidade para solução de problemas não lineares com base em diferentes tipos de informação. Nesse trabalho foram utilizadas amostras da mesma marca de cerveja, porém com diferentes lotes e datas de fabricação constituindo dois subgrupos: primeiro com amostras de boa qualidade e segundo com amostras de qualidade insatisfatória.

As arquiteturas selecionadas nesse trabalho foram *Backpropagation* e RBF com diferentes configurações para as camadas, isto é, quantidades variadas de neurônios por camada. Para a realização dos testes foram utilizados 70 exemplos de treinamento, caracterizados por 12 parâmetros, separados entre grupo de teste e validação.

Os resultados permitiram identificar a classe de cada amostra, com 100% de acerto, e também avaliar uma arquitetura ótima para tratar o problema, neste caso a *Backpropagation* com 12 neurônios na camada de entrada, 10 ou 13 na camada intermediária e duas na camada de saída. Sabe-se que para a certificação de bebidas alcoólicas a análise sensorial é realizada por provadores humanos e as avaliações baseiam-se na experiência e conhecimento dos especialistas, propensos a fatores subjetivos. Com este experimento foi possível demonstrar uma alternativa precisa e não dependente de subjetividade.

Outro trabalho que utilizou a arquitetura descrita como MLP, com o algoritmo de aprendizagem *Backpropagation* nos experimentos foi MARENDA et al. (2011), com a proposta de classificação adequada da origem em dois tipos de mel: melato ou floral. A motivação pela seleção da arquitetura foi baseada na alta precisão para classificação da proposta. A configuração da arquitetura foi de três camadas, com os neurônios da camada intermediária variando de dois a oito.

Como parâmetros de entrada para a RNA foram utilizadas características físico-químicas como pH e açúcar redutor em busca da saída “tipo de mel” para as 25 amostras de mel analisadas. Mais de 70% das arquiteturas desse trabalho identificaram todas as amostras de mel, constituindo um método alternativo para a classificação do mel em melato ou floral, utilizando análises físico-químicas de baixo custo.

Diferente do trabalho de MARENDA et al. (2011) que visava classificar o mel em dois tipos específicos, na literatura, foi possível identificar diversos trabalhos (BALASUBRAMANIAN et al. 2009; CHEN et al. 2011, DOULGERAKY et al. 2012; KHOT et al. 2012, ARGYRI et al. 2013) relacionados a inocuidade do alimento. Nesse contexto se encontra a carne que é um dos alimentos mais consumidos em todo o mundo, porém apresenta vida de prateleira curta, podendo causar graves perigos à saúde do consumidor quando consumida fora das condições adequadas. Por isso, a utilização de sistemas de avaliação da qualidade que sejam rápidos e confiáveis é essencial para diminuir perdas econômicas desnecessárias e também garantir a segurança do alimento (DOULGERAKY et al., 2012)

Por esse motivo, BALASUBRAMANIAN et al. (2009) buscaram em seu trabalho classificar e prever a qualidade da carne bovina usando parâmetros extraídos dos sensores de um nariz artificial. A escolha da utilização das RNAs pelos autores deu-se pelo fato da abordagem tratar problemas não lineares convergindo ao conhecimento de forma dinâmica e auto-adaptativa, em outras palavras, aprender com os exemplos apresentados à rede.

Esse trabalho teve em seus experimentos as arquiteturas RBF e *Backpropagation* para a classificação de carne em contaminada ($\geq 6.0 \log_{10}$ cfu/g) e

não contaminada ($<6.0 \log_{10}$ cfu/g). Os experimentos foram realizados com diversas combinações de parâmetros, variando desde parâmetros extraídos do nariz artificial até umidade, temperatura e leituras de dióxido de carbono. A combinação dos parâmetros ideais para cada bateria de experimentos foi realizada com auxílio da PCA (Análise de Componentes Principais), observando os parâmetros mais relevantes para encaminhar à camada de entrada das RNAs.

Para os experimentos foram observadas variações das configurações da arquitetura, como mudanças na quantidade de entradas oferecidas à rede, diretamente associadas às características obtidas da carne. Esta escolha foi utilizada com o intuito de verificar quais são as características mais relevantes para a generalização de uma solução para o problema.

Entre as arquiteturas estudadas por BALASUBRAMANIAN et al. (2009), a RBF com a configuração de oito neurônios na camada de entrada, nove na camada intermediária e dois na final obtiveram 94,7% de reconhecimento com as características extraídas a uma temperatura de 10°C. Para a tarefa de predição, a rede *Backpropagation* alcançou a predição da população da *Salmonella typhimurium* e *E. coli* com uma correlação de 0,96 com os valores reais observados.

Outra contribuição do trabalho foi a conclusão de que as amostras armazenadas a 10°C apresentaram um comportamento mais uniforme. Este fator foi observado uma vez que os resultados de predição pela *Backpropagation* a 10°C foram mais promissores do que a 4°C, onde os exemplos de treinamento, por serem mais homogêneos, facilitaram o processo de aprendizado para predição. O resultado geral do trabalho tratou a solução com RNAs, para predição da qualidade de carne, com acurácia superior a 90% em duas diferentes temperaturas.

Por sua vez, KHOT et al. (2012) utilizaram uma RNA do tipo RBF com diversas configurações em busca da previsão da contaminação de pacotes de carne bovina com a bactéria *Salmonella* sp, um dos agentes mais comuns responsáveis por grandes surtos de gastroenterite em diversos países (MOREIRA et al., 2013).

A escolha do uso de uma RNA foi justificada pela abordagem robusta como ferramenta de reconhecimento de padrões. A opção da RBF se deu, pois, quando comparada a *Backpropagation* apresenta maior velocidade durante a fase de treinamento e uma estrutura mais simples.

Os experimentos foram realizados com 24 pacotes de carne, sendo que 12 tiveram a bactéria inoculada e outros 12 foram mantidos preservados. De cada uma das classes, com 12 pacotes em cada, foram extraídos parâmetros via nariz artificial. Após a extração dos dados, as características passaram por um processamento via Transformada Wavelet Packet (WPT). Este processo possibilitou uma avaliação precisa do comportamento dos parâmetros, sendo possível sintetizar 100 amostras para cada classe. A RBF da proposta utilizou somente as amostras sintéticas para o treinamento, um total de 200 amostras, sendo 150 para treinamento, 20 para validação e outras 30 para testes.

Além de experimentos relacionados à WPT, o trabalho de KHOT et al. (2012) realiza seis experimentos diferentes, com arquiteturas diversas. Como métrica para descrever a arquitetura ideal, este trabalho utilizou o Erro Quadrático Médio (EQM). Com um EQM de 0,04, as arquiteturas com 18 neurônios na camada inicial, 11, 12 e 19 na intermediária com dois neurônios na saída foram as melhores configurações para a RBF. Ao final de todos os experimentos, o autor descreve que a RNA somada à abordagem de sinterização de amostras com a WPT (para aumentar e qualificar a base do experimento) apresentou uma taxa de reconhecimento de 98,89% para as saídas: carne contaminada ou não.

O tempo de armazenamento da carne também é um fator importante para determinar a deterioração do produto, uma vez que é constituída por diversos nutrientes essenciais para o crescimento microbiano. Dessa forma, métodos de análises mais rápidos, de fácil execução e que não requerem a utilização de reagentes vem sendo utilizados nos últimos anos, como exemplo o FT-NIR (espectroscopia infravermelha). Contudo, a deterioração da carne é um processo complexo e muitas vezes as técnicas lineares não são capazes de fornecer a solução completa, demandando a necessidade do uso de técnicas não-lineares como as RNAs.

CHEN et al. (2011) descreveram em seu trabalho o uso do FT-NIR associado a uma *Backpropagation* para classificar o tempo de armazenamento da carne suína. Junto a *Backpropagation* foram selecionadas outras duas abordagens de classificação: Análise de Discriminante Linear (LDA) e K-vizinhos mais próximos (KNN). O intuito da seleção de diversas técnicas foi compará-las a abordagem de extração de parâmetros com o FT-NIR. A *Backpropagation* utilizada foi com uma arquitetura de cinco neurônios na camada inicial, cinco na intermediária e um na final.

Foram realizados seis experimentos, em duas baterias (uma para classificação e outra para predição). As diversas técnicas deveriam classificar e prever quais seriam os tempos de prateleira de um a seis dias. O melhor resultado foi da *Backpropagation* com a taxa de 99,3% para classificação e 96,2 para predição. A KNN e LAD obtiveram respectivamente 95,2% e 94,8% para classificação e 91,6% e 89,4% para predição. Pode-se concluir que a técnica de FT-NIR associada a uma RNA tem o potencial de determinar o tempo de armazenamento da carne suína de acordo com o seu frescor.

AMIRYOUSSEFI et al. (2014) descreveram a possibilidade de utilizar uma RNA da arquitetura MLP para predição e controle do processo de fritura em gordura de carne de avestruz. A escolha da utilização de uma rede neural foi justificada pela técnica ser capaz de modelar a solução de um problema sem conhecimento sobre o processo *a priori*, em outras palavras, a rede neural irá generalizar o modelo do processo com exemplos sem a necessidade de especificação por um especialista.

Foram utilizados parâmetros extraídos de imagens para prever a transferência de massa cinética pela MLP, bem como alterações de cor e encolhimento do teor de gordura em cubos de carne frita de avestruz. A base para os experimentos foi de 216 amostras, cujas características extraídas foram energias de microondas, um total de 4, 3 temperaturas e nove intervalos de fritura.

A configuração ideal para a rede foi de três neurônios na camada de entrada, duas camadas escondidas com 13 neurônios na primeira e 12 na segunda. Como saída para rede neural a configuração realizada foi de dois neurônios. Essa configuração alcançou um coeficiente de correção superior a 0,89.

Com o intuito de classificar a qualidade das carcaças de cordeiros utilizando processamento de imagem e análise de textura, CHANDRARATNE et al., (2007) utilizaram em seu trabalho uma RNA do modelo MLP e compararam com um modelo estatístico DFA (Função de Análise Discriminante).

A adoção da MLP foi justificada como uma alternativa para problemas de classificação limitados ao escopo não linear e vantagens em lidar com entradas complexas ao sistema. Nos experimentos foram utilizadas 160 imagens, das quais foram extraídos parâmetros selecionados via PCA. Diversas configurações foram experimentadas e com o uso de 18 características processadas pela MLP foi

possível obter 96.9% de acurácia na classificação, enquanto que a DFA obteve 84.4%.

Em busca de definir melhor um modelo de crescimento bacteriano do *Staphylococcus aureus* em função da combinação de pH, temperatura e atividade de água; FERNÁNDEZ-NAVARRO et al., (2010) propuseram em seu trabalho uma terceira classe de definição: crescimento de transição.

Os autores avaliaram também as classes já definidas como crescimento e não crescimento. Utilizaram uma RNA do tipo RBF para criar um modelo de multi-classificação para prever a probabilidade de pertencer a uma dessas três classes. A RBF foi capaz de classificar com mais de 86% de acerto com diversas arquiteturas, mesmo com a grande variabilidade dos dados. A inclusão dessa nova classe foi importante para modelar melhor o perfil de crescimento microbiano, auxiliando no momento de tomada de decisão para garantir a segurança dos alimentos.

Um dos grandes problemas da indústria leiteira são as incrustações que se formam ao longo do tempo nos equipamentos, caracterizadas como um acúmulo de proteínas devido à desnaturação durante o processo de aquecimento. Este acúmulo aumenta a resistência da transferência de calor, diminui a eficiência térmica do equipamento de aquecimento e aumenta os custos de produção. Visando diminuir este problema, WALLHÄUBER et al., (2011) propuseram um novo método de reconhecimento de padrões para detecção de incrustações em aço inoxidável por meio da combinação dos parâmetros extraídos do ultrassom com as RNAs do tipo *Multilayer Perceptron* (MLP).

Segundo WALLHÄUBER et al. (2011) as RNAs foram escolhidas pois os modelos tradicionais falham quanto utilizados na modelagem de fenômenos complexos com relacionamentos não lineares.

Nesse trabalho, os autores utilizaram uma RNA com cinco neurônios na entrada, dois neurônios escondidos e um neurônio na camada de saída exibindo “0” para ausência de incrustações e “1” para presença de incrustações. Após o treinamento com 400 amostras e validação com 250 amostras, pode-se concluir que a RNA utilizada demonstrou uma precisão de 98,58% para a detecção das variáveis: presença ou ausência de incrustações.

O resfriamento dos alimentos é uma técnica importante de conservação, pois a temperatura influencia no crescimento de microrganismos e também nos indicadores de qualidade. Trata-se de um dos métodos mais antigos de conservação (SOUZA et al., 2013). Dessa forma, KLASSEN et al. (2009) propôs uma forma de modelagem do sistema de resfriamento por imersão de carcaças de frango utilizando as RNAs. Para isso foram testadas diversas arquiteturas para delinear a rede que apresentasse menor erro ao predizer a temperatura da carcaça de frango ao sair do último tanque de resfriamento.

Foram utilizados como parâmetros de entrada: massa da carcaça, temperatura antes do resfriamento, temperatura da camisa de propilenoglicol, vazão de água em cada módulo, tempo de residência e temperatura da água de renovação. Os resultados demonstraram que a arquitetura 8-24-1 foi a que apresentou o menor erro, de 4,16% no treinamento e de 3,52% na validação, demonstrando que a utilização de RNAs para modelar o resfriamento de carcaças de frangos em tanques de imersão é uma ferramenta eficiente.

A literatura apresenta outros trabalhos que envolvem as RNAs com arquiteturas e paradigmas diferentes dos descritos. Por exemplo, CHEROUTRE-VIALETTE & LEBERT (2000) utilizaram uma RNA Recorrente (RNAR) com dois neurônios de entrada e seis neurônios na camada oculta para produzir um modelo

dinâmico de predição do crescimento da bactéria *Listeria monocytogenes* em função da concentração de NaCl e do pH.

A seleção da abordagem de classificação baseada em RNA foi justificada pela capacidade de aprendizado baseado em exemplos, sem a necessidade de inserção de variáveis no processo de aprendizado.

De acordo com o trabalho, a RNA pode ser utilizada como uma ferramenta de predição do crescimento de microrganismos, podendo auxiliar nos programas de autocontrole da qualidade das indústrias, assim como auxiliar no sistema de segurança dos alimentos.

Um outro paradigma diferente do supervisionado utilizado pelas MLP, *Backpropagation*, RBF e RNAR é o não supervisionado. No modelo não supervisionado não é necessário delimitar a saída esperada na fase de treinamento. A própria rede se encarrega de generalizar o conhecimento e buscar as saídas mais adequadas para a RNA e solucionar o problema. Essa abordagem pode ser encontrada no trabalho apresentado por PREVOLNIK et al. (2014), usando uma RNA do tipo Mapa Reorganizável de Kohonen. Nesse trabalho buscou-se a predição da maturação de presunto cru em 4 tempos e a RNA não supervisionada apresentou uma taxa de reconhecimento de 79,7%, mostrando a necessidade de maiores estudos.

CONSIDERAÇÕES FINAIS

Nota-se uma preocupação cada vez mais crescente em melhorar as técnicas de avaliação dos alimentos em busca de menos subjetividade, menor custo e maior rapidez na análise, preservando a qualidade e segurança dos alimentos.

Essa busca por novas técnicas, incluindo as que envolvem processos computacionais, se expande para diversos tipos de alimentos como: laticínios, fermentados e carnes (bovina, suína, ovina e aves) com o intuito de melhorar os processos que avaliam a qualidade e inocuidade dos alimentos.

Pode-se observar que os trabalhos que utilizaram as RNAs apresentaram melhores resultados quando comparadas a outras técnicas para classificação e predição. Os critérios utilizados para avaliação do resultado da classificação e desempenho das RNAs foram vários, com destaque para o coeficiente de correlação, erro quadrático médio e acurácia.

Independente do critério de avaliação notou-se que os trabalhos realizam experimentos para reconhecer a arquitetura e configuração ideal para a rede, variando em quantidade de camadas e neurônios por camada. Os trabalhos estudados apresentaram uma variação na quantidade de amostras de treinamento, no entanto os resultados apresentados foram satisfatórios quando comparados a outras técnicas.

Os problemas tratados foram de diversas áreas da Ciência dos Alimentos, na gama de estudos abordados observou-se o uso das três arquiteturas, MLP, *Backpropagation* e RBF para diferentes soluções, com justificativas pautadas na não linearidade, desvinculação de conhecimento prévio e simplicidade dos modelos.

Nos últimos trabalhos apresentados foi possível verificar outros modelos e paradigmas das RNAs. Os tipos de redes e modelos de aprendizado são diversos e ainda são alvo de pesquisas em áreas como Ciência da Computação e Engenharia Elétrica. Dessa forma, espera-se encontrar novos trabalhos com mais precisão e adequação aos problemas reais estudados, inclusive pela Ciência dos Alimentos.

REFERÊNCIAS

- ARGYRI, A. A.; PANAGOUE, E. Z.; TARANTILIS, P. A.; POLYSIOU, M.; NYCHAS, G-J. E. Rapid qualitative and quantitative detection of beef fillets spoilage based on Fourier transform infrared spectroscopy data and artificial neural networks. **Sensors and Actuators B: Chemical**, v. 145, p. 146-154, 2010.
- ARGYRI, A. A.; JARVIS, R. M.; WEDGE, D.; XU, Y.; PANAGOUE, E. Z.; GOODACRE, R.; NYCHAS, G-J. E. A comparison of Raman and FT-IR spectroscopy for the prediction of meat Spoilage. **Food Control**, v. 29, 461-470, 2013.
- AMIRYOUSEFI, M. R.; MOHEBBI, M.; KHODAIYAN, F. Applying an intelligent model and sensitivity analysis to inspect mass transfer kinetics, shrinkage and crust color changes of deep-fat fried ostrich meat cubes. **Meat Science**, v. 96, p. 172–178, 2014.
- BALASUBRAMANIAN, S.; PANIGRAHI, S.; LOGUE, C.M.; GU, H.; MARCHELLO, M. Neural networks-integrated metal oxide-based artificial olfactory system for meat spoilage identification. **Journal of Food Engineering**, v. 91, p. 91–98, 2009.
- BASHEER, I. A. & HAJMEER, M. Artificial neural networks: fundamentals, computing, design and application. **Journal of microbiological methods**, v. 43.1, p. 3-31, 2000.
- BHUNIA, A. K. Biosensors and Bio-Based Methods for the Separation and Detection of Foodborne Pathogens. **Advances in food and Nutrition Research**, v.54, p.1-44, 2008.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. **Projeções do Agronegócio: Brasil 2012/2013 a 2022/2023**. Brasília: Mapa/ACS, 2013. 96p.
- CHANDRARATNE, M. R.; KULASIRI, D.; SAMARASINGHE, S. Classification of lamb carcass using machine vision: Comparison of statistical and neural network analyses. **Journal of Food Engineering**, v. 82, p. 26–34, 2007.
- CHEN, Q.; CAI, J.; WAN, X.; ZHAO, J. Application of linear/non-linear classification algorithms in discrimination of pork storage time using Fourier transform near infrared (FT-NIR) spectroscopy. **LWT - Food Science and Technology**. v. 44, p. 2053-2058, 2011.
- CHEROUTRE-VIALETTE, M. & LEBERT, A. Modelling the growth of *Listeria monocytogenes* in dynamic Conditions. International. **Journal of Food Microbiology**. v. 55, p. 201–207, 2000.
- COPPIN, B. Uma Breve História da Inteligência Artificial. In:_____. **Inteligência Artificial**. Rio de Janeiro: LTC, 2010. cap. 1, p. 3-15.
- DEBSKA, B. & GUZOWSKA-SWIDER, B. Application of artificial neural network in food classification. **Analytica Chimica Acta**, Amsterdam, v. 705, p. 283-291, 2011.

DOGANIS, P.; ALEXANDRIDIS, A.; PATRINOS, P.; SARIMVEIS, H. A time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. **Journal of Food Engineering**, v. 75, p. 196–204, 2006.

DOULGERAKY, A. I.; DANILO, E.; FRANCESCO, V.; NYCHAS, G. J. E. Spoilage microbiota associated to the storage of raw meat in different conditions. **International Journal of Food Microbiology**, v. 157, p. 130-141, 2012.

EATON, J. W.; BATEMAN, D.; HAUBERG, S. **GNU Octave**: A high-level interactive language for numerical computations. 3^a ed.; version 3.0.1, 2007.

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

FERNÁNDEZ-NAVARRO, F.; VALERO, A.; HERVÁS-MARTÍNEZ, A.; GUITIÉRREZ, P. A.; GARCÍA-GIMENO, R. M.; ZURERA-COSANO, G. Development of a multi-classification neural network model to determine the microbial growth/no growth interface. **International Journal of Food Microbiology**, v.141, p. 203–212, 2010.

FRANCO, B.D.G. M & LANDGRAF, M. **Microbiologia dos alimentos**. Atheneu, 2005. 177p.

GAVA, A. J. **Princípios da tecnologia dos alimentos**. São Paulo: Nobel, 1984. 289p.

HAN, J.; KAMBER, M.; PEI, J. **Data mining: Concepts and techniques**. USA: Morgan Kaufmann, 2012. 3rd ed, 673p.

HAYKIN, SIMON. S. **Neural Networks and Learning Machines**. Upper Saddle River: Pearson Education, 2009. 3rd ed, 936p.

HUANG, Y.; KANGAS, L. J.; RASCO, B. A. Applications of Artificial Neural Networks (AANs) in Food Science. **Critical Reviews in Food Science and Nutrition**. London, v. 47, n. 2, p. 113-126, jan. 2007.

KLASSEN, T.; MARTINS, T. D.; FILHO, L. C.; SILVA, E. A. Modelagem do sistema de resfriamento por imersão de carcaças de frangos utilizando redes neurais artificiais. **Acta Scientiarum Technology**, v. 31, n. 2, p. 201-205, 2009.

KHOT, L. R.; PANIGRAHI, S.; DOETKOTT, C.; CHANG, Y.; GLOWER, J.; AMAMCHARLA, J.; LOGUE, C.; SHERWOOD, J. Evaluation of technique to overcome small dataset problems during neural network based contamination classification of packaged beef using integrated olfactory sensor system. **LWT - Food Science and Technology**, v. 45, p. 233-240, 2012.

MARENDA, T. A.; LIMA, R. C. A.; SENNA, R. M.; ALMEIDA, M. M.; DUARTE, E. R. 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, 2011.

MARINI, F. Artificial Neural Networks in foodstuff analyses: Trends and perspectives. A review. **Analytica Chimica Acta**, v. 635, p. 121-131, jan. 2009.

MOREIRA, N. M.; OLIVEIRA, J. J.; FREITAS, F. A.; OLIVEIRA, A. P.; SOLA, M. C. Métodos de tipificação de *Salmonella* sp. **Enciclopédia Biosfera**, Goiânia, v. 9, n. 16, p. 1027-1046, 2013.

ÖLMEZ, T. & ZÜMRAY, D. Classification of heart sounds using an artificial neural network. **Pattern Recognition Letters**, v. 24.1, p. 617-629, 2003.

OPAS (Organização Pan-Americana da Saúde). **Higiene dos Alimentos** – Textos Básicos / Organização Pan-Americana da Saúde; Agência Nacional de Vigilância Sanitária; Food and Agriculture Organization of the United Nations. – Brasília: Organização Pan-Americana da Saúde, 2006. 64 p.: il.

POUTA, E.; HEIKKILA, J.; FORSMAN-HUGG, S.; ISONIEMI, M.; MAKELA, J. Consumer choice of broiler meat: the effects of country of origin and production methods. **Food Quality and Preference**, Oxford, v. 21, n. 5, p. 539-546, 2010.

PREVOLNIK, M.; ANDRONIKOV, D.; ZLENDER, B.; FONT-I-FURNOLS, M.; NOVIC, M.; SKORJANC, D.; CANDEK-POTOKAR, M. Classification of dry-cured hams according to the maturation time using near infrared spectra and artificial neural networks. **Meat Science**, v. 96, p. 14–20, 2014.

RUSSEL, S. & NORVIG, P. **Inteligência Artificial**: tradução da segunda edição. Rio de Janeiro: Campus, 2004. 1021p.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Introdução. In:_____. **Redes Neurais Artificiais**: para engenharia e ciências aplicadas. São Paulo: Artliber, 2010. Cap. 1, 393 p.

SOUZA, M. C.; TEIXEIRA, L. J. Q.; ROCHA, C. T. FERREIRA, G. A. M.; FILHO, T. L. Emprego do frio na conservação de alimentos. **Enciclopédia Biosfera**, Goiânia, v. 9, n. 16, p. 1027-1046, 2013.

VENABLES, W. N.; SMITH, D. M.; CORE TEAM, R. **An Introduction to R**. Notes on R: Programming Environment for Data Analysis and Graphics. Version 3.0.3, 2014. 105p.

WALLHÄUBER, E.; HUSSEIN, W. B.; HUSSEIN, M. A.; HINRICHS, J.; BECKER, T. M. On the usage of acoustic properties combined with an artificial neural network – A new approach of determining presence of dairy fouling. **Journal of Food Engineering**. v. 103, p. 449–456, 2011.

WILKINSON, J. Os gigantes da indústria alimentar entre a grande distribuição e os novos clusters a montante. **Para Estudos Sociedade e Agricultura**. v.18, p.147-174, 2002.