

SISTEMA INTELIGENTE DE RECONHECIMENTO DE FRUTAS

ANTONIO R. HIDALGO, CARLOS V. CARDOSO, LECIO N. DE OLIVEIRA, RODRIGO RIBEIRO SANTOS

*Núcleo de Engenharia Elétrica, Universidade Federal de Sergipe
Cidade Universitária "Prof. José Aloísio de Campos" - Av. Marechal Rondon, s/n Jardim Rosa Elze
CEP 49100-000 São Cristóvão - SE*

E-mails: ahidalgo@ufs.br, cvcardoso@ufs.br, rodrigorbst@gmail.com

Abstract— This paper describes the experience in the development of an recognition intelligent system of fruits. This system was developed based in the Electronic Nose, system composed by a group of sensor with different answer profiles with an algorithm of artificial intelligence accomplish the classification of products by the volatile compositions analysis.

Keywords— Electronic Nose, Fruit Identification, Neural Networks, Odor Detection.

Resumo— O presente trabalho relata a experiência no desenvolvimento de um sistema inteligente de reconhecimento de frutas. Este sistema foi desenvolvido a partir do denominado Nariz Eletrônico, sistema que através de um conjunto de sensores com diferentes perfis de resposta junto com um algoritmo de inteligência artificial consegue realizar o reconhecimento de produtos por meio da análise dos seus compostos voláteis.

Palavras-chave— Nariz eletrônico, Reconhecimento de Frutas, Redes Neurais, Detecção de Odores.

1 Introdução

Desde sua concepção, nos anos 80, os narizes eletrônicos têm sido utilizados numa ampla variedade de aplicações, por exemplo: análise aromática de vinhos, monitoramento da qualidade de alimentos, detecção de doenças, monitoramento ambiental, monitoramento de qualidade de combustíveis, estagio de maturação de alimentos, etc [1-12]. Neste contexto, o principal objetivo deste trabalho é explorar a aplicação do nariz eletrônico na análise aromática de frutas de forma a verificar, por meio de um sistema microcontrolado, a viabilidade da sua utilização na identificação de frutas.

É denominado nariz eletrônico, a um sistema formado por um arranjo de sensores que junto com técnicas de reconhecimento de padrões e/ou de inteligência artificial permitem extrair informações relevantes e confiáveis para realizar a identificação de gases [13]. O fundamento do nariz eletrônico é a idéia que cada sensor no arranjo tem diferentes sensibilidade, por exemplo o odorante 1 pode produzir uma alta resposta num sensor e uma baixa resposta em outros, considerando que um odorante 2 deve produzir uma alta leitura para outros sensores diferentes daqueles para o odorante 1 [13].

O sistema de reconhecimento de frutas desenvolvido neste trabalho se baseou no microcontrolador dsPIC30F4011, sendo nesta primeira versão implementado com base num kit de desenvolvimento, porém passível de se tornar embarcado com facilidade. A utilização do microcontrolador permite além da adequada coleta dos dados a programação e o processamento do algoritmo de reconhecimento de padrões, neste caso as Redes Neurais.

Os sensores utilizados são sensores baseados em oxido de estanho SnO₂, encontrados normalmente no mercado.

O sistema é capaz de identificar a presença de quatro tipos de frutas (maça nacional, manga, goiaba e caju) e a ausência das mesmas em um tempo relativamente curto.

2 Componentes do Sistema

O sistema projetado possui três componentes principais: sensores de gás, microcontrolador dsPIC30F4011 e ambiente gráfico de coleta e treinamento

2.1 Sensores de Gás

Devido a sua disponibilidade no mercado e a suas características de resposta, na implementação do sistema, foram utilizados sensores baseados em óxido de estanho. Este tipo de sensores são normalmente utilizados na identificação de gases voláteis. A sensibilidade à concentração de gases voláteis do sensor é possível graças à mudança de condutividade devido à interação química entre os gases e a superfície do sensor. Sensibilidade é a capacidade que o sensor possui em distinguir os odores em relação a sua concentração. A sensibilidade é medida em partes por milhão (ppm). Uma vez que os sensores possuem características de respostas diferentes, será possível otimizar sua seletividade por meio de técnicas de reconhecimento de padrões com redes neurais

Os sensores Tagushi da Tabela 1, fabricados pela Figaro, foram selecionados no projeto devido as suas funcionalidade:

Tabela 1. Sensores usados no projeto

Sensores Tagushi	Compostos Detectados
TGS 2602	Air Quality / VOC, Odor
TGS 2600	General Air Quality
TGS 2620	Alcohol, organic vapor

2.2 Microcontrolador dsPIC30F4011

O sistema baseado no microcontrolador dsPIC30F4011 realiza duas funções: aquisição dos dados de treinamento bem como o reconhecimento de frutas propriamente dito. Na aquisição de dados, com os quais se fará o treinamento da rede neural artificial, o microcontrolador realiza a conversão A/D (10 bits) dos sinais dos sensores. O reconhecimento das frutas será realizado também pelo microcontrolador, o qual será programado com o algoritmo da rede neural selecionada a partir do treinamento. A seguir é apresentado o fluxograma utilizado para a coleta de dados

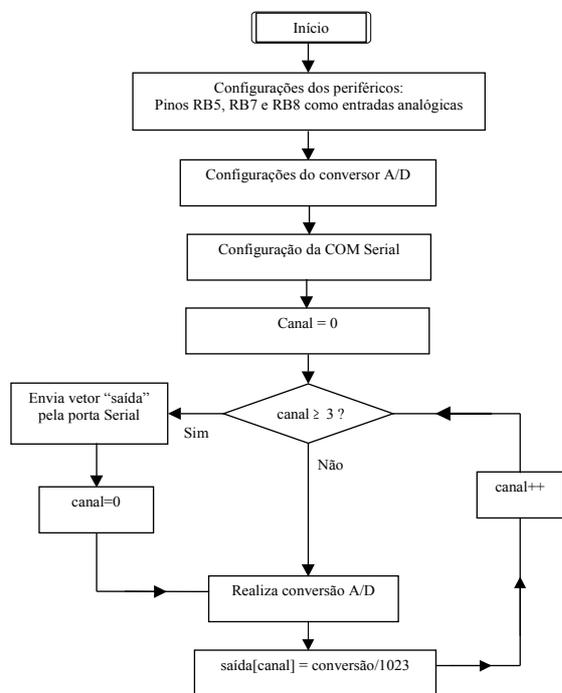


Figura 1. Fluxograma para coleta de dados

Neste fluxograma (fig 1) pode-se verificar que primeiro configura-se os periféricos, o conversor A/D e a comunicação serial. É também definida uma variável “canal”, a qual comandará o envio dos dados a um PC através da porta serial. No PC, microcomputador com processador AMD Turion 64x2 de 1.9 GHz de clock e 2 GB de memória RAM, é realizado o treinamento da redes neurais.

2.3 Ambiente Gráfico

Uma vez que a coleta e treinamento dos dados será realizado no PC foi necessário projetar um ambiente gráfico que permita comandar o envio dos dados desde o microcontrolador via porta serial, bem como realizar o treinamento das redes neurais a partir destes dados

3 Coletas e Análise dos Dados

Para que a rede neural reconheça um determinado padrão é necessário que seja treinada a partir de uma base de dados. Para isso foi necessário planejar a coleta dos dados e fazer a análise destes para identificar dados característicos para cada fruta, separando assim uma base de dados para o treinamento e outra para a verificação da rede neural. As frutas as quais foram amostradas foram: **Maça nacional, manga, goiaba e caju**. As frutas foram colocadas em recipientes de vidro transparentes com um volume de cinco litros (fig 2). A metodologia utilizada para a coleta de dados foi: aquecimento dos sensores sempre antes de iniciar a primeira coleta, o que também permitiu limpar os sensores. A primeira coleta tem uma duração de 15 minutos e é realizada no ar, sem amostra.



Figura 2. Protótipo do Sistema Identificador de Odores usando RNA

O estudo foi iniciado com a realização de quatro tipos de coletas com amostras, uma vez que não se tinha noção de qual destes tipos poderia resultar numa base de dados que pudesse ser utilizada com sucesso no treinamento da rede neural artificial. Os tipos de coletas foram: **Coleta com Recipiente Aberto Fruta Inteira (R.A.F.I)**, **Coleta com Recipiente Fechado Fruta Inteira (R.F.F.I)**, **Coleta com Recipiente Aberto Fruta Fatiada (R.A.F.F)** e **Coleta com Recipiente Fechado Fruta Fatiada (R.F.F.F)**. Cada coleta teve dez minutos de estabilização e quinze minutos para descansar os sensores. As coletas foram realizadas durante cinco dias seguidos para todas as frutas, considerando-se um peso aproximadamente igual para todas as frutas. O ambiente onde foram realizados as coletas de dados e os testes era fechado, a temperatura e a umidade não foram controladas. A análise dos dados mostrou que as medidas realizadas com os recipientes abertos não seriam adequadas devido às grandes oscilações na resposta dos três sensores seja com a fruta inteira ou com a fruta fatiada, ver figuras 3 e 4.

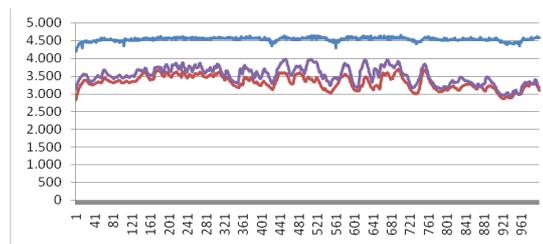


Figura 3. Coleta da goiaba R.A.F.F

Esta mesma análise permitiu observar que a coleta dos dados com recipiente fechado e com fruta fatiada também não seria útil, pois as leituras das concentrações nos sensores aumentavam rapidamente se tornando muito semelhantes entre si principalmente para a goiaba e manga, conforme mostrado nas figuras 5 e 6.

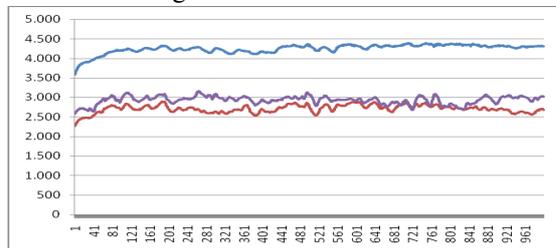


Figura 4. Coleta do Caju R.A.F.I

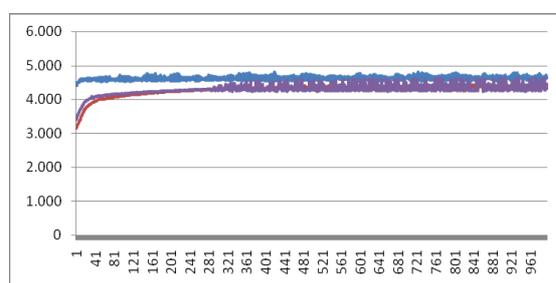


Figura 5. Coleta da goiaba R.F.F.F

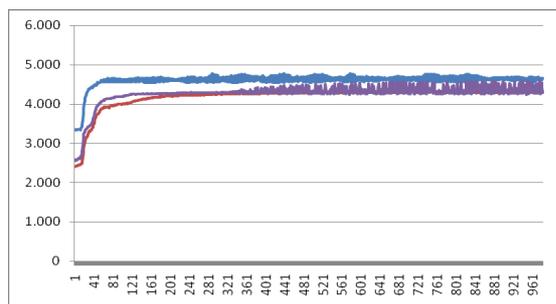


Figura 6. Coleta da manga R.F.F.F

Assim, dos quatro tipos de coletas realizadas somente a coleta do recipiente fechado com a fruta inteira foi utilizada para o treinamento da rede.

Para a convergência da rede neural artificial, se utilizou os dados que estão entre os limiares característicos para cada fruta (ver tabela 2). Foi criado uma faixa de valores no início que são característicos da ausência de fruta.

Tabela 2. Valores mínimos e máximos de tensões característica normalizadas das frutas.

FRUTA	SEM FRUTA		MAÇÃ		MANGA		GOIABA		CAJU	
	Mínimo	Máximo	Mínimo	Máximo	Mínimo	Máximo	Mínimo	Máximo	Mínimo	Máximo
Sensor 1	0,5376	0,6246	0,6656	0,6794	0,8808	0,9198	0,9062	0,9394	0,9218	0,9306
Sensor 2	0,4076	0,4360	0,4604	0,4810	0,6560	0,7184	0,7600	0,7938	0,8220	0,8476
Sensor 3	0,4478	0,4702	0,4946	0,5122	0,6754	0,7400	0,7860	0,8162	0,8456	0,8652

4 Redes Neurais Artificiais

Para o reconhecimento das frutas foi utilizada uma rede neural artificial baseada no modelo do

multilayer perceptron (MPL), treinada com o algoritmo de retropropagação (*backpropagation*) [14]. Esta rede possui 3 neurônios na camada de entrada (devido aos três sensores utilizados), n neurônios na camada escondida e 3 neurônios na camada de saída (que mostra uma codificação que identifica cada fruta). A inicialização dos pesos para o treinamento da rede é feita de maneira aleatória, de modo que o processo de treinamento posterior é do tipo não determinístico.

O algoritmo de retroalimentação foi implementado em linguagem C. Um importante parâmetro desta função é a taxa de aprendizado, que determina o tamanho do passo dado na atualização dos pesos. A taxa de aprendizado é um fator pelo qual é multiplicado o negativo do gradiente, sendo o resultado utilizado para atualizar os pesos. Para a taxa de aprendizado, foi empregado o valor 0,7. O desempenho do algoritmo *backpropagation* foi substancialmente melhorado com pequenas alterações. A mais simples foi a introdução do termo de momento e a atualização da taxa de aprendizagem. O termo de momento permite a rede responder não apenas ao gradiente local, mas também às tendências na superfície da função de erro, diminuindo a possibilidade de parar o treinamento em um ponto de mínimo local daquela superfície. Para o treinamento e teste das redes, foram coletados os dados referentes a quatro frutas diferentes. Os dados foram divididos para 70% serem utilizados durante a fase de treinamento e 30% serem utilizados durante a fase de testes. O fluxograma para o treinamento da rede é mostrado na figura 7.

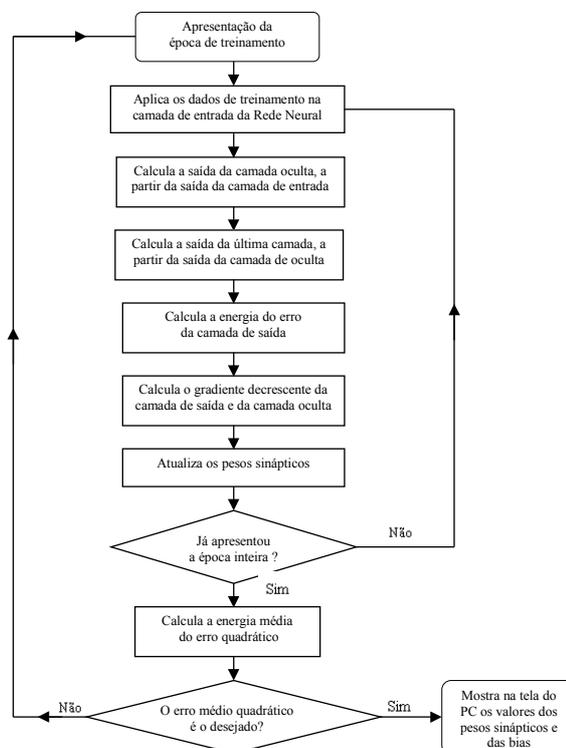


Figura 7. Fluxograma do software para o treinamento da rede

As redes neurais deste trabalho foram treinadas sempre com três neurônios na entrada e três na saída, variando-se sempre o número de neurônios na camada oculta entre três, cinco ou oito. O treinamento da rede neural permitirá encontrar os pesos adequados para cada configuração de rede, mudando neste caso a camada oculta. Também será possível comparar o desempenho das configurações da camada oculta.

Na comparação dos resultados do treinamento das três redes testadas: 3 3 3, 3 5 3 e 3 8 3, a rede 3 8 3 resultou num menor erro, além disso foi a que menos interações precisou até chegar no valor adequado de pesos.

Na tabela 3 pode ser visto um conjunto de treinamentos realizados variando os número de neurônios na camada oculta e o erro médio desejado, além do número de iterações realizadas em cada um desses casos.

Tabela 3. Erro médio e Iterações por configuração de rede

Rede	Erro médio	Iterações
3 3 3	0.00001	73441200
3 3 3	0.000008	82266800
3 5 3	0.000016	57527400
3 5 3	0.000014	58062200
3 8 3	0.00001	43953000
3 8 3	0.000001	133457800

Na fase de testes, a partir dos pesos obtidos na etapa de treinamento foram elaborados os algoritmos de reconhecimento de frutas para cada rede. Desta forma utilizando um grupo de dados diferentes dos dados do treinamento. Pode-se verificar que o desempenho das redes treinadas (3 3 3, 3 5 3 e 3 8 3). Estes resultados permitirão verificar que a medida que os dados utilizados se aproximavam da região entre duas frutas ou o limiar dos dados de uma determinada fruta a rede 3 8 3 tinha um desempenho superior as outras. Na figura 8 é apresentado o fluxograma do código implementado na fase de teste para verificar o desempenho das redes.

5 Verificação do Sistema

As verificações finais foram realizadas com as redes 3 3 3 e 3 8 3 com os menores erros. Como em ambos os casos as redes funcionaram, a verificação final tinha por objetivo ver o desempenho destas duas configurações. Assim, foram realizados dois testes com cada uma das configurações para cada fruta. Para realização dos testes finais nas duas configurações foi implementado no microcontrolador o algoritmo.

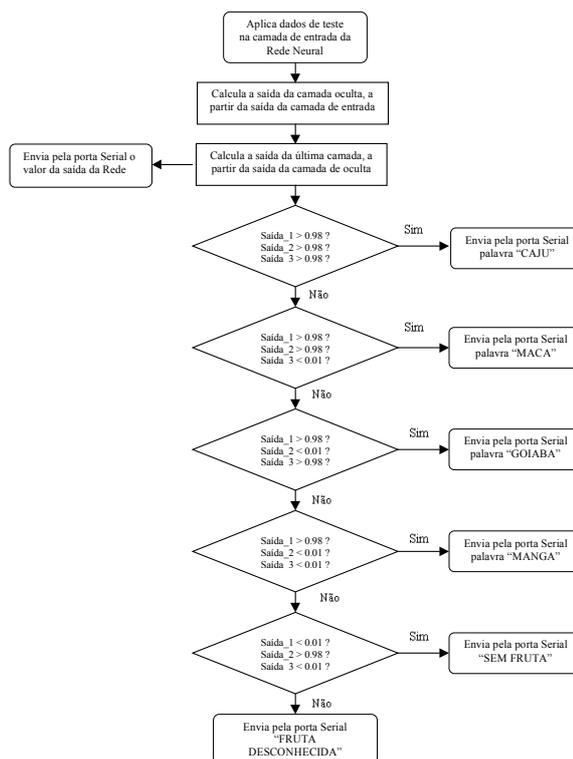


Figura 8. Fluxograma do software para a verificação da rede neural

Para as duas configurações foram realizados dois testes de identificação para cada fruta, sendo os resultados resumidos a continuação.

5.1 Teste da rede 3 3 3

O primeiro teste a maçã só foi identificada com 7 minutos e 10 segundos e assim permaneceu até os 10 minutos. No segundo teste feito com a maçã a mesma foi identificada com 5 minutos e 30 segundos e assim permaneceu até os 10 minutos. No primeiro teste feito com a manga obteve-se a seguinte resposta: A manga só foi identificada com 9 minutos e assim permaneceu até os 10 minutos. No segundo teste feito com a manga, a mesma foi identificada com 1 minuto e 15 segundos e com 6 minutos e 30 segundos foi reconhecida como fruta desconhecida e assim permaneceu até os 10 minutos. No primeiro teste feito com a goiaba esta só foi identificada com 7 minutos e 34 segundos e assim permaneceu até os 10 minutos. No segundo teste feito com a goiaba a mesma foi identificada com 5 minutos, com 8 minutos oscilava entre fruta desconhecida e goiaba e aos 10 minutos foi reconhecida como fruta desconhecida. Em ambos os testes feitos com o caju obteve-se a seguinte resposta: O caju só foi identificado com 3 minutos, mas a resposta oscilava bastante entre fruta desconhecida e caju.

5.2 Teste da rede 3 8 3

No primeiro teste feito com a maçã nacional esta foi identificada com 45 segundos, com 3 minutos e 20 segundos a saída identificada era fruta desconhecida. No segundo teste feito com a maçã a mesma foi identificada com 1 minuto, com 3 minutos e 25 segundos oscilava entre maçã e fruta desconhecida e aos 4 minutos já era reconhecida como fruta desconhecida. No primeiro teste feito com a manga obteve-se a seguinte resposta: A manga foi identificada com 1 minuto, com 6 minutos e 40 segundos a resposta de saída identificada era fruta desconhecida. No segundo teste feito com a manga a mesma foi identificada com 35 segundos, com 2 minutos e 50 segundos oscilava entre manga e fruta desconhecida e aos 3 minutos e 30 segundos já era reconhecida como fruta desconhecida. No primeiro teste feito com a goiaba obteve-se a seguinte resposta: A goiaba só foi identificada com 1 minuto e 45 segundos, com 4 minutos a resposta de saída identificada era fruta desconhecida. No segundo teste feito com a goiaba a mesma foi identificada com 1 minuto e 40 segundos, com 2 minutos e 50 segundos oscilava entre goiaba e fruta desconhecida e aos 4 minutos e 30 segundos já era reconhecida como fruta desconhecida. No primeiro teste feito com o caju obteve-se a seguinte resposta: O caju foi identificado com 1 minuto e 20 segundos e assim permaneceu até 10 minutos sem oscilar. No segundo teste feito com o caju o mesmo foi identificado com 2 minutos e 20 segundos, e assim permaneceu até 10 minutos sem oscilar.

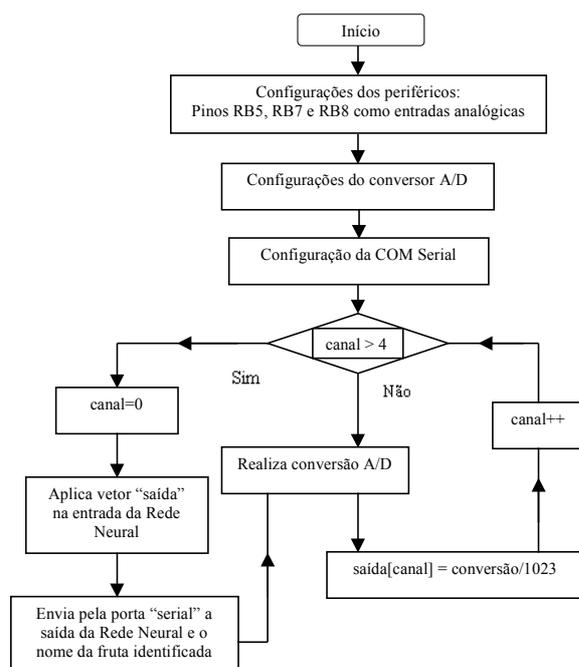


Figura 9. Fluxograma do software para o teste final do projeto

Para a rede 3 3 3 utilizava-se muito mais tempo para reconhecer o padrão da fruta que com a rede 3 8 3. O fato de que em alguns casos a fruta ser identificada como fruta desconhecida deve-se à semelhança entre os dados das frutas, pois foram extraídos apenas os dados característicos de cada fruta para o treinamento da rede neural, sendo alguns dados de cada fruta perdidos. Assim a fruta só era identificada quando os sensores identificavam os dados característicos da fruta em análise. Comparando os resultados dos testes pode-se observar que na rede 3 8 3 todas as frutas foram identificadas entre 2 e 3 minutos, essa margem de tempo onde todas as frutas são identificadas não ocorre com a rede 3 3 3.

6 Conclusões

A proposta de desenvolver um sistema identificador de frutas utilizando sensores de óxido estanho e redes neurais foi atingida com relativo sucesso, uma vez que foi desenvolvido um sistema que faz a aquisição de dados, processa esses dados num dsPIC30F4011, reconhece a fruta e envia a resposta da rede neural artificial para uma interface com o usuário desenvolvida para o projeto. Apesar de a proposta inicial ser cumprida ainda existe muito trabalho por ser feito, pois o sistema identifica apenas quatro frutas. Além disso foi tomado como referencia um único estagio de maturação, os próximos trabalhos estarão orientados a incrementar o número de frutas, bem como identificar diferentes estágios de maturação, para isso será necessário aumentar a base de dados e o número de sensores, bem como fazer a comparação com outros métodos não destrutivos que reconheçam o estado de maturação das frutas utilizadas.

Outro ponto que pode ser aperfeiçoado é a forma da coleta dos dados e limpeza dos sensores de óxido de estanho, tendo sido esta etapa realizada de forma manual, o uso de cilindros de nitrogênio e oxigênio solucionaria o problema da limpeza dos sensores, separar a concentração dos gases da etapa de medição tornaria o processo mais oneroso, mas seria mais preciso.

O conceito de reconhecimento de padrões utilizado neste trabalho poderia ser usado em outras aplicações, por exemplo no campo da saúde, para diagnosticar câncer de pele, ou para identificar odores no hálito advindos de problemas gastrointestinais. Na conservação do meio ambiente, este poderia servir para monitorar a qualidade da água potável, do ar e as emissões de poluentes das indústrias, identificar lixo tóxico ou detectar vazamento de óleo. Na indústria de alimentos, serviria para controle da fermentação e inspeção de alimentos por odor, dentre varias outras aplicações em diversas áreas, deixando evidente a grande utilidade do identificador de odores.

Referências Bibliográficas

1. Lozano, J; Santos, J. P; Aleixandre, M; Sayago, I; Gutierrez, J; Horrillo, M. C. Identification of Typical Wine Aromas by Means of an Electronic Nose. *IEEE Sensor Journal*, vol 6, no 1, Fevereiro, 2006, p173-178.
2. Di Natale, C; Davide, F. A. M; D'amico, A; Nelli, P; Gropelli, S; Sberveglieri, G. An electronic nose for the recognition of the vineyard of a red wine. *Sensor and Actuator B* 33 (1996) 83-88.
3. Barriga P. de la Veja, Madeleine Lita. Sistema Inteligente para Identificar Gases. Dissertação de Mestrado, Universidade de São Paulo. 1998.
4. Gardner, J. W; Bartlett, P. N. A brief history of electronic noses, *Sensors and Actuators B* 18 (1994) 211.
5. Olafsdottir, G et al. Multisensor for fish quality determination, *Trends Food Society Technology*. Vol 5, 2004, p86-93.
6. Garcia, M; Horrillo, M. C; Santos, J. P; Aleixandre, I; Sayago, Fernandez, M. J; Ares, L. e Gutierrez, J. Artificial olfactory system for the classification of Iberian ham. *Sensor and Actuator B*. Vol 96, 2003, p612-629.
7. Thaler, E. R; Hanson, W. C. Medical applications of electronic nose technology. *Expert Review of Medical Devices Expert Review of Medical Devices*. Vol. 2, 2005, No 5, p559-566.
8. Thaler, E.; Hanson, W. Use of an Electronic Nose to Diagnose Bacterial Sinusitis. *American Journal of Rhinology*. 2006, 20(2): 170-172.
9. Gendron, K. G; Hockstein, N. G; Thaler, E. R; Vachani, A e Hanson, W. In vitro discrimination of tumor cell lines with an electronic nose. *Otolaryngology – Head and Neck Surgery*. Vol. 137, 2007, p269-273.
10. Canhoto, O. Applications of Volatile Fingerprint Sensor Arrays for Rapid Detection of Environmental and Microbiological Contaminants, Cranfield, 2005. 134p. Tese (Doutorado) – Universidade de Cranfield.
11. Hirayama, V. Classificador de qualidade de álcool combustível e poder calorífico de gás GLP, São Paulo, 2004. 82p. Dissertação de mestrado – Escola Politécnica, Universidade de São Paulo.
12. Brezmes, J et al. Evaluation of an Electronic Nose to Assess Fruit Ripeness. *IEEE Sensor Journal*, Vol 5, n 1, 2005.
13. Nagle, H. T; Schiffman, S e Gutierrez-Osuna. The how and why of electronic noses. *IEEE Spectrum*, vol. 35, pp22-31, setembro, 1998.
14. Santos Filho, José Alípio. Utilização de Redes Neurais Artificiais em Classificação Autônoma de Peças Metálicas Empregando Imagens Radiográficas Aplicáveis a Sistemas IVA. Dissertação (Mestrado) CEFET-MG, Belo Horizonte, 2006. Cap. 3.