



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA QUÍMICA E
ENGENHARIA DE ALIMENTOS
PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA
COOPERAÇÃO VERSUCHS UND LEHRANSTALT FÜR
BRAUEREI IN BERLIN

AMANDA REITENBACH

**DESENVOLVIMENTO DE NARIZ ELETRÔNICO
PARA DETECÇÃO DE COMPOSTOS VOLÁTEIS NA CERVEJA**

FLORIANÓPOLIS
2016

**DESENVOLVIMENTO DE NARIZ ELETRÔNICO
PARA DETECÇÃO DE COMPOSTOS VOLÁTEIS NA CERVEJA**

Tese submetida ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Santa Catarina como requisito para obtenção do grau de Doutor em Engenharia Química.

Orientador: Prof. Dr. Leonel Teixeira Pinto.

Amanda Reitenbach

Florianópolis
2016

Reitenbach, Amanda

Desenvolvimento de nariz eletrônico para detecção de compostos voláteis na cerveja / Amanda Reitenbach ; orientador, Leonel Teixeira Pinto - Florianópolis, SC, 2016. 248 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação Multidisciplinar em Saúde.

Inclui referências

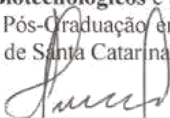
1. Saúde. 2. Nariz eletrônico. 3. Off-flavors. 4. Cerveja. 5. Redes neurais. I. Pinto, Leonel Teixeira. II. Universidade Federal de Santa Catarina. Programa de Pós Graduação Multidisciplinar em Saúde. III. Título.

**Desenvolvimento de Nariz Eletrônico para Compostos
Voláteis da Cerveja**

por

Amanda Felipe Reitenbach

Tese julgada para obtenção do título de **Doutor em Engenharia Química**, área de Concentração de **Desenvolvimento de Processos Químicos e Biotecnológicos** e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Santa Catarina.



Prof. Dr. Leonel Teixeira Pinto
orientador



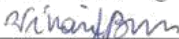
Prof.^a. Dr.^a. Cíntia Soares
coordenadora

Banca Examinadora:

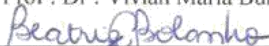


Prof. Dr. Artovaldo Bolzan

Prof.^a. Dr.^a. Edna Regina Amante



Prof.^a. Dr.^a. Vivian Maria Burin



Prof.^a. Dr.^a. Beatriz Cervejeira Bolanho
(vdeoconferência)



Prof.^a. Dr.^a. Grace Ferreira Ghetti

Florianópolis, 21 de junho de 2016.

AGRADECIMENTOS

A Deus, pela Sua presença constante na minha vida, sem que eu precise pedir; pelo auxílio Dele nas minhas escolhas e por Ele me confortar nas horas difíceis.

Ao meu orientador, Professor Leonel, pelos importantes ensinamentos, tanto científicos quanto pessoais, pela amizade e apoio.

Ao Capes pela bolsa de estudos fornecida.

À VLB pela parceria realizada neste estudo.

À minha família, por todo amor, carinho e apoio incondicionais: Amo muito vocês!

Aos amigos do NEUROLAB e FIBGD (VLB), que compartilharam comigo todos os percalços e êxitos deste trabalho; pelas “orientações em entre amigos”, conversas, festas e por tornarem o laboratório um ambiente agradável e prazeroso.

A todos os meus amigos, pelo apoio e pelos momentos de alegria!

Ao Mestre Cervejeiro Macedo, pelas nossas discussões científicas, pelo incentivo, atenção e conhecimentos transmitidos.

À Thais e Marcio o pelo apoio e pelas contribuições na discussão dos resultados.

Aos amigos que me acompanharam nessa jornada pelo mundo da cerveja, descobrindo pequenos detalhes que tornaram esse mundo cervejeiro ainda mais interessante e gostoso para todos nós.

Enfim, a todos que de alguma maneira contribuíram para a execução deste trabalho, seja pela ajuda constante ou por uma palavra de amizade.

Muito obrigada!

[...]

Eu não tenho filosofia: tenho sentidos...
Se falo na Natureza não é porque saiba o que ela é,
Mas porque a amo, e amo-a por isso,
Porque quem ama nunca sabe o que ama
Nem sabe por que ama, nem o que é amar ...
Amar é a eterna inocência,
E a única inocência não pensar...

Fernando Pessoa

RESUMO

A cerveja é uma das bebidas mais sensíveis e instáveis do ponto de vista sensorial. Possui sabor e aroma complexos e moderados, mas apresenta pouca estabilidade de aroma, se comparada a outras bebidas alcoólicas. O sabor e aroma da cerveja variam devido a uma ampla gama de influências que ocorrem em todos os estágios do processo de preparação e durante a estocagem. A cerveja é composta de mais de mil componentes que podem contribuir para o sabor do produto, conferindo à bebida aromas agradáveis ou, em muitos casos, desagradáveis, quando há presença de compostos denominados *off-flavors*. A presença dos *off-flavors* é um dos problemas mais sérios na indústria cervejeira, porque a maioria dos consumidores julga o produto principalmente pela qualidade do seu sabor. Sua avaliação é complexa e primordial no controle de qualidade da indústria cervejeira, e comumente é realizada por meio de técnicas de análise, por vezes de alto custo, morosas ou mesmo subjetivas. O presente trabalho trata do desenvolvimento de um nariz eletrônico que avalie e detecte compostos indesejáveis em amostras de cervejas, sendo uma nova proposta para o controle de qualidade de aromas. O nariz eletrônico, também conhecido como *e-nose*, é um instrumento constituído por um arranjo de sensores parcialmente seletivos, que tem sido muito utilizado na análise de voláteis alimentares. A tecnologia dos narizes eletrônicos procura detectar o perfil dos compostos voláteis e necessita de uma quantidade pequena de amostra (15 mL), permitindo resultados rápidos e de menor custo. Para o processamento das informações recebidas do *e-nose*, é necessário que o equipamento seja acoplado a uma interface multivariada capaz de reconhecer padrões aromáticos - as redes neurais artificiais - e que analise os perfis aromáticos. Para resposta elétrica dos sensores (medidas de capacitância), foi utilizada a rede neural artificial do tipo probabilística *PNN*, também análise de componentes principais PCA, reconhecendo e classificando os padrões aromáticos encontrados na cerveja. Os resultados do presente estudo mostram que a diferença em entre os grupos de painel treinado e não treinado foi significativa, mostrando a necessidade de treinamento para melhor identificação de compostos a serem analisados. Observando o as análises de PCA e PNN foi observado que somente alguns compostos não foram identificados pelos métodos de reconhecimento de padrão, o que sugere que mais sensores poderiam ser implementados no equipamento para ampliar o reconhecimento desses compostos. A combinação do nariz eletrônico

com as redes neurais artificiais se mostra uma alternativa promissora para

o desenvolvimento de novos produtos, para a comparação de similaridades entre produtos concorrentes e para o controle da qualidade aromática de cerveja.

Palavras-chave: Nariz eletrônico. Cerveja. *Off-flavors*. Redes neurais.

ABSTRACT

From a sensorial point of view, beer is one of the most delicate and unstable beverages. It has complex and moderate aromas and flavors, but little aroma stability, when compared to other alcoholic beverages. Beer's flavor and aroma vary due to a wide range of influences which can occur at every single stage of its production and storage. Beer is made of over one thousand components which can contribute to the product's flavor, providing it with pleasant or, in several cases, unpleasant aromas, due to the presence of what is called off-flavor compounds. The presence of off-flavors is one of the most serious problems in the beer industry because most consumers judge the product mainly by the quality of its flavor. Its evaluation is complex and fundamental in the beer industry's quality control and it is commonly done by analysis techniques - usually slow, expensive and subjective ones. This project aims at developing an electronic nose which is able to evaluate and detect undesirable compounds in beer samples, as a new proposal to the aroma's quality control. The electronic nose, also known as e-nose, is an instrument made of an array of partially selective sensors which has been long used in the analysis of food volatiles. The technology of electronic noses aims at detecting the profile of volatile compounds and needs a small sample amount (15mL), allowing quick and cheaper results. For the processing of the information acquired by the e-nose, it is necessary that the equipment is connected to a multi-varied interface which has to be able to recognize aromatic patterns - the artificial neural networks - and which analyzes the aromatic profiles. For the electrical responses of the sensors (capacitance measures), the PNN probabilistic artificial neural network was used. The PCA main compounds analysis was also used to recognize and classify the aromatic patterns found in beer. The results of this study show that the difference between the groups of trained and non-trained panels was significant, showing the necessity of training for the better assessment of the compounds to be analyzed. Observing the PCA and PNN analysis, it was noticed that only a few compounds were not identified by the standard recognition methods, which suggests that more sensors could be implemented into the equipment in order to amplify the recognition of such compounds. The combination of the electronic nose with the artificial neural networks presents itself as a promising alternative for the development of new products, for the comparison of similarities

among competing products and for the control of the aromatic quality in beer.

Keywords: Electronic nose. Beer. Off-flavors. Artificial Neural Networks.

LISTA DE ABREVIATURAS

ADQ	Análise descritiva quantitativa
ASBC	American Society of Brewing Chemists
ATP	Trifosfato de adenosina
CG-FID	Cromatografia a gás com detector por ionização de chama
CG-MS	Cromatografia a gás acoplada a espectrometria de massa
CP	Polímero condutor
CSA	Arranjo se sensores colorimétricos
DA	Diacetil
DHS	Técnica de Purga e Trap (P&T) e Headspace Dinâmico
DMS	Dimetil sulfeto
ETH	Etanol
FRU	Frutose
GLC	Glicose
HPLC	Cromatografia líquida de alta eficiência
ICA	Análise dos componentes independentes
IMS	Ion Mobility Spectrometry
INDEX	Extração Dinâmica com Agulha Interna
KLT	Transformada Discreta de Karhuen-Loève
MIMS	Espectrometria de Massa de Introdução de membrana
MOS	Óxidos metálicos semicondutores
MS	Espectrometria de massa
PC	Componente principal
PCA	Análise dos componentes principais
PEN2	Nariz eletrônico PEN2
PPB	Partes por bilhão
PPM	Partes por milhão
PPN	Probabilistic Neural Netorks (Redes neurais probabilísticas)
QMB	Sensor Quartz Microbalance
RBF	Rede Radial-Basis Functions
RNA	Rede neural artificial
SBSE	Extração por Barra de Adsorção
SHS	Técnica do Headspace Estático

SNK Student-Neman-Keuls
SPME Microextração em Fase Sólida
SUC Sacarose
VLB Versuchs - und Lehranstalt für Brauerei in Berlin
(Instituto de Investigação e Formação Cervejeira em
Berlim)
VOC Composto orgânico volátil

LISTA DE FIGURAS

- Figura 1 - Esquema e blocos do sistema nervoso mostrando a recepção do estímulo até a geração de uma resposta
- Figura 2 - Constituintes do neurônio biológico, evidenciando as estruturas corpo celular, axônio, sinapse e dendritos.....
- Figura 3 - Esquema de percepção de um aroma por um nariz eletrônico, evidenciando os sensores, rede neural artificial e a resposta (identificação e quantificação de odores)
- Figura 4 - Diagrama representando os diferentes métodos de detecção de gás, baseados na variação elétrica ou em outros tipos de variação.....
- Figura 5 - Representação de um neurônio artificial k , esquematizando os sinais de entrada, o combinador linear, a função de ativação e saída do neurônio
- Figura 6 - Esquema de uma rede de camada única
- Figura 7 - Esquema de uma rede de múltiplas camadas (*multilayer*)
- Figura 8 - Arquitetura típica de uma rede PNN, evidenciando as unidades de entrada, unidades de padrões, unidades de soma e as unidades de saída
- Figura 9 - Esquema da aplicação da análise de componentes principais, evidenciando as etapas envolvidas.....
- Figura 10 - Componentes principal (CP1) e componente secundária (CP2).....
- Figura 11 - Rota metabólica resumida das vias de degradação da sacarose extra e intracelular em *S. cerevisiae*. Legenda: SUC (sacarose), GLC (glicose), FRU (frutose), ETH (etanol), ATP (trifosfato de adenosina). 1. Transportadores Hxtp. 2. Transportadores Agt1p ou Malx1p. 3. H⁺- ATPase de membrana.
- Figura 12 - Destino catabólico da glicose durante a fermentação alcoólica por levedura, gerando etanol e CO₂.....
- Figura 13 - Representação Etapas da via metabólica da glicose proveniente de açúcares como sacarose, maltose, entre outros, até a obtenção do piruvato, evidenciando metabólitos e enzimas envolvidas. (a) Fase preparatória e (b) fase de pagamento.....

Figura 14 - Representação das mudanças sensoriais da cerveja durante o envelhecimento	
Figura 15 - Sensor DFRobot DHT11	
Figura 16 - Aplicação típica do sensor DHT11. 3Pin - null, MCU = unidade de microcomputador ou computador chip único.	
Figura 17 - Processo de comunicação geral do sensor DHT11	
Figura 18 - Estrutura e configuração do sensor de gás MQ-04 (configuração A ou B).....	
Figura 19 - características de sensibilidade típicas do MQ-4 para vários gases na temperatura de 20° C, umidade de 65%, concentração de O ₂ a 21% e RL=20kΩ. Ro: resistência do sensor a 1000ppm de CH ₄ no ar limpo e Rs: resistência do sensor a várias concentrações de gases.	
Figura 20 - Estrutura e configuração do sensor de gás MQ-04 (configuração A ou B).....	
Figura 21 - Características de sensibilidade típicas do MQ-4 para vários gases na temperatura de 20° C, umidade de 65%, concentração de O ₂ a 21% e RL=20kΩ. Ro: resistência do sensor a 1000ppm de H ₂ no ar limpo e Rs: resistência do sensor a várias concentrações de gases.	
Figura 22 - Descarbonatação das cervejas para leitura em protótipo	
Figura 23 - Roda de aromas e sabores, agrupando termos de classes e subclasses recomendados em análise sensorial de cerveja.....	
Figura 24 - Amostras codificadas em 3 dígitos, servidas sempre com a amostra de referência R.....	
Figura 25 - Modelo de ficha utilizada para os testes de análise descritiva quantitativa das amostras com compostos aromaticos	
Figura 26 - <i>Software</i> do <i>Arduino</i> (em evidência, o botão para ligar o <i>serial monitor</i>).....	
Figura 27 - Visão geral do prototipo, evidenciando os diferentes sensores de gás empregados.....	
Figura 28 - Visão geral do circuito para teste do sensor de temperatura.....	
Figura 29 - O circuito do sensor de temperatura	
Figura 30 - Conexão do circuito do sensor no <i>Arduino</i>	
Figura 31 - Conexão do circuito do led no <i>Arduino</i>	

- Figura 32 - Sensor a gas com circuito interligado.....
- Figura 33 - Representação dos múltiplos sensores de gás para microcontrolador *Arduino*.....
- Figura 34 - Tela com leitura instantânea dos sensores.....
- Figura 35 - Leitura de compostos volateis com multiplo sensores
- Figura 36 - Médias de leitura em volts para 37 atributos referente ao sensor MQ1135.....
- Figura 37 - Médias de leitura em volts para 37 atributos referente ao sensor MQ8.....
- Figura 38 - Médias de leitura em volts para 37 atributos referente ao sensor MQ7.....
- Figura 39 - Médias de leitura em volts para 37 atributos referente ao sensor MQ4.....
- Figura 40 - Médias de leitura em volts para 37 atributos referente ao sensor MQ2.....
- Figura 41 - Médias de leitura em volts para 37 atributos referente ao sensor MQ3.....
- Figura 42 - PNN para classificação dos compostos sensores MQ2 e suas interações
- Figura 43 - PNN para classificação dos compostos dos sensores MQ3 e suas interações
- Figura 44 - PNN para classificação dos compostos MQ4 e suas interações
- Figura 45 - PNN para classificação dos compostos sensores MQ7 e suas interações
- Figura 46 - PNN para classificação dos compostos sensores MQ8 e suas interações
- Figura 47 - PNN para classificação dos compostos sensores MQ1135 e suas interações

LISTA DE TABELAS

- Tabela 1 - Matriz de dados de n indivíduos e p variáveis.....
- Tabela 2 - Coeficientes de correlação e o erro médio quadrado entre os descritores e as variáveis do *e-nose* obtidas pela validação
- Tabela 3 - Matriz obtida na validação da rede (*backpropagation*) para amostras de vinhos brancos novos
- Tabela 4 - Principais compostos orgânicos formados durante a fermentação por leveduras, incluindo ácidos orgânicos, álcoois alifáticos superiores, ésteres e aldeídos e suas concentrações típicas na cerveja
- Tabela 5 - Tipos de sensores que detectam os principais componentes que comprometem a qualidade da cerveja com base nos dados do fabricante *Figaro*
- Tabela 6 - Limiares de odor e sabor dos compostos *de off flavor* na cerveja tipo pilsen
- Tabela 7 - Soluções utilizadas na aplicação do teste de gostos básicos.....
- Tabela 8 - Definições e referências propostas pela *American Society of Brewing Chemists* para treinamento de provadores em avaliação de cerveja e as correspondentes classes e subclasses conforme apresentado no Círculo de Aromas e Sabores
- Tabela 9 - Definições e referências propostas pela *American Society of Brewing Chemists* (ASBC) para treinamento de provadores em avaliação de cerveja e as correspondentes classes e subclasses conforme apresentado no Círculo de Aromas e Sabores referências utilizadas para intensificação de sabores
- Tabela 10 - Resultados analíticos da cerveja, com o respectivo método empregado e unidades
- Tabela 11 - Compostos analisados.....
- Tabela 12 - Análise descritiva dos compostos
- Tabela 13 - Análise descritiva dos atributos
- Tabela 14 - Análise descritiva dos compostos
- Tabela 15 - Avaliação da diferença na escala de análise sensorial para os 14 atributos estudados de acordo com o painel (treinado e não treinado)

- Tabela 16 - Avaliação da diferença na escala de análise sensorial para os 14 atributos estudados e comparando as respostas observadas com os padrões de resposta esperados
- Tabela 17 - Médias das leituras em volts para cada sensor e cada composto químico
- Tabela 18 - Valores médios das três repetições para cada tipo de sensor e atributo.....
- Tabela 19 - Correlações de cada um dos atributos com os componentes principais 1 e 2
- Tabela 20 - Médias observadas para o ácido actético em relação aos diferentes tipos de sensores
- Tabela 21 - Médias observadas para o ácido de isoamila em relação aos diferentes tipos de sensores
- Tabela 22 - Médias observadas para terra molhada ou ethil fenchol em relação aos diferentes tipos de sensores
- Tabela 23 - Médias observadas para 3-metil-2-butano-1-tiol (*light struck*) em relação aos diferentes tipos de sensores.....
- Tabela 24 - Médias das avaliações dos sensores e correlação com os componentes.....
- Tabela 25 - Resultados utilizando a rede PNN. Taxas de classificação correta para o conjunto treinamento e para o conjunto de teste.....
- Tabela 26 - Resultados utilizando a rede PNN, apresentando a porcentagem de acertos do painel não treinado, painel treinado e nariz eletrônico com rede PNN.....

LISTA DE GRÁFICOS

- Gráfico 1 - Perfil *Berliner Pilsner*, com os diferentes atributos apresentados.....
- Gráfico 2 - Análise sensorial dos compostos na amostra completa
- Gráfico 3 - Análise sensorial dos compostos para participantes não treinados.....
- Gráfico 4 - Análise sensorial dos compostos para participantes treinados
- Gráfico 5 - Análise sensorial dos compostos - painel de respostas para análise sensorial
- Gráfico 6 - Análise sensorial dos compostos para o padrão esperado de análise sensorial
- Gráfico 7 - Análise sensorial dos atributos na amostra completa
- Gráfico 8 - Análise sensorial dos atributos para o grupo não treinado
- Gráfico 9 - Análise sensorial dos atributos para o grupo treinado
- Gráfico 10 - Análise sensorial dos atributos para respostas de análise sensorial
- Gráfico 11 - Análise sensorial dos atributos para o padrão de respostas de análise sensorial esperado
- Gráfico 12 - Perfil descritivo dos sensores
- Gráfico 13 - Escores dos sensores avaliados associados ao CP1 e ao CP2.....

SUMÁRIO

1	INTRODUÇÃO	
1.1	DEFINIÇÃO, DESCRIÇÃO E ESTRUTURA DE UM NARIZ ELETRÔNICO	
1.2	SISTEMA BIOLÓGICO	
1.3	SISTEMA ELETRÔNICO	
1.4	JUSTIFICATIVA	
1.5	OBJETIVOS	33
1.5.1	Objetivo geral	
1.5.2	Objetivos específicos	
1.6	PARCEIROS NO DESENVOLVIMENTO DO PROJETO.....	
1.6.1	VLB - Berlin Alemanha Versuchs - und Lehranstalt für Brauerei in Berlin	
2	REVISÃO BIBLIOGRÁFICA	
2.1	SENSORES.....	
2.1.1	Características e funcionamento de um sensor	
2.1.1.1	Visão geral e classificação de sensores	37
2.1.2	Tipos de sensores	
2.1.2.1	Sensores de Óxidos Metálicos (MOS)	38
2.1.2.2	Sensores de Polímeros Condutores (CP)..	41
2.1.2.3	Sensores colorimétricos	42
2.1.2.4	Sensores com nanomateriais	43
2.1.2.5	Ion Mobility Spectrometry (IMS)	43
2.1.3	Métodos de preparação de amostras para introdução em narizes eletrônicos	
2.1.3.1	Técnica do Headspace Estático (SHS).....	43
2.1.3.2	Técnicas de Purga e <i>Trap</i> (P&T) e <i>Headspace</i> Dinâmico (DHS)	44
2.1.3.3	Microextração em Fase Sólida (SPME) ...	44
2.1.3.4	Extração por Barra de Adsorção (SBSE) .	44
2.1.3.5	Extração Dinâmica com Agulha Interna (INDEX).....	45
2.1.3.6	Espectrometria de Massa de Introdução de	

	Membrana (MIMS).....	45
2.2	REDES NEURAIS.....	
2.2.1	Características e vantagens de RNAS.....	
2.2.2	Fatores que influenciam no desempenho das RNAS.....	
2.2.3	Aprendizado (ou treinamento).....	
2.2.4	Arquitetura e topologia das RNAS.....	
2.2.5	Desenvolvimento e treinamento de uma rede neural.....	
2.2.6	Aplicações de redes neurais.....	
2.2.7	Redes PNN.....	
2.3	ANÁLISE DOS COMPONENTES PRINCIPAIS (PCA).....	
2.3.1	Componentes principais (PCS).....	
2.3.2	Matriz de covariância.....	
2.3.3	Autoespaços, autovetores e autovalores.....	
2.3.4	Transformada de Hotelling.....	
2.4	ANÁLISE DESCRITIVA QUANTITATIVA (ADQ).....	
2.4.1	Análise descritiva quantitativa (ADQ).....	
2.4.1.1	Requisitos.....	66
2.4.1.2	Procedimento do teste.....	67
2.4.2	Utilização de ADQ na literatura.....	
2.5	APLICAÇÕES DE NARIZES ELETRÔNICOS.....	
2.5.1	Aplicação de narizes eletrônicos em análise de alimentos e cervejas.....	
2.6	BIOQUÍMICA DO PROCESSO CERVEJEIRO.....	
2.6.1	Fermentação de açúcares por leveduras.....	
2.6.2	Produção de aromas.....	
2.7	OFF-FLAVORS EM CERVEJAS.....	
2.7.1	Qualidade sensorial da cerveja.....	
2.7.2	Tipos comuns de <i>off-flavor</i>	
3	MATERIAL E MÉTODOS.....	
3.1	MATERIAL.....	
3.1.1	Sensores utilizados.....	
3.1.2	Placa de aquisição de dados <i>Arduino</i>	

3.1.3	Protoboard	
3.2	MÉTODOS.....	
3.2.1	Características e funcionamento dos sensores empregados	
3.2.2	Análise dos compostos aromáticos via protótipo	
3.2.3	Reconhecimento de padrões e redes neurais artificiais.....	
3.2.4	Metodologia de treinamento das redes PNN	
3.2.5	Limiares de odor para <i>off flavor</i>	
3.2.6	Preparo da amostra para leitura no protótipo.....	
3.2.7	Análise sensorial - avaliação descritiva quantitativa	
3.2.8	Armazenamento das amostras	
3.2.9	Teste de gostos básicos (para seleção de avaliadores)	
3.2.10	Teste triangular	
3.2.11	Familiarização com estímulos e avaliação do desempenho.....	
3.2.12	Treinamento dos provadores.....	
3.2.13	Teste sensorial nas amostras.....	
3.2.14	Armazenamento e preparo das amostras para ADQ com compostos aromáticos	
3.2.15	ADQ para grupo não treinado	
3.2.16	Análise físico-química da cerveja <i>Berliner Pilsner</i>	
3.2.17	Funcionamento do <i>Arduino</i> com o protótipo.....	
4	RESULTADOS E DISCUSSÕES.....	
4.1	Perfil da cerveja base definida pelo painel treinado.....	
4.2	Avaliação entre o painel treinado e não treinado	
4.3	DESEMPENHO DO PROTÓTIPO AVALIANDO 6 SENSORES CONSIDERANDO 37 ATRIBUTOS.....	
4.4	ANÁLISE ESTATÍSTICA	
4.5	RESULTADOS PCA.....	
4.6	Rede neural PNN	
5	CONCLUSÕES.....	
5.1	PERSPECTIVAS FUTURAS	

REFERÊNCIAS

ANEXOS

ANEXO A - GRÁFICOS DE ANÁLISE EXPLORATÓRIA

ANEXO B - RESULTADO INDIVIDUAL PARA CADA COMPOSTO
QUÍMICO.....

ANEXO C - CÓDIGO DE PROGRAMAÇÃO *ARDUINO*.....

ANEXO D - FUNÇÕES DE ATIVAÇÃO

ANEXO E - *DATASHEET* DOS SENSORES UTILIZADOS.....

ANEXO F - TABELA DE *OFF-FLAVORS* ENCONTRADOS NA
CERVEJA.....

1 INTRODUÇÃO

Odores são importantes características percebidas pelo corpo. Novas tecnologias baseadas nessas características buscam copiar a percepção de cheiros e possuem aplicações bastante promissoras. É o caso dos narizes eletrônicos.

O olfato é um dos cinco sentidos usados para se relacionar com o ambiente, dele se pode obter informações, tomar decisões ou simplesmente apreciar odores. Baseados no funcionamento do nariz humano, os narizes eletrônicos foram desenvolvidos com esta mesma finalidade: detectar diferentes odores e tornar possível, então, a identificação e classificação. A habilidade de perceber odores é, para o ser humano, um fator muito importante que o permite reconhecer, identificar e qualificar elementos ao seu redor. Além disso, fragrâncias revelam a qualidade do ar: perfumes agradáveis, emanações enjoativas, alarmes de toxicidade. Os odores também são utilizados como uma forma de advertir ao perigo. Um odor é composto por moléculas de diferentes tamanhos e formas. Cada uma dessas moléculas tem um receptor correspondente no nariz humano. No homem, possui grande importância na evocação da memória e na emocional e desempenha papel significativo na alimentação, juntamente com o sentido gustatório.

1.1 DEFINIÇÃO, DESCRIÇÃO E ESTRUTURA DE UM NARIZ ELETRÔNICO

Um nariz eletrônico é um equipamento desenvolvido para detectar e discriminar odores, usando um arranjo de sensores. Esse arranjo consiste um conjunto de sensores não específicos que são tratados com uma variedade de materiais química ou biologicamente sensíveis (PERIS et al., 2009). Um estímulo de odor gera uma resposta específica do arranjo de sensores. Esses sensores possuem ampla seletividade, respondendo a um grande número de compostos. Essa característica torna-se um fator fundamental para o funcionamento dos narizes eletrônicos. Os sensores devem ser capazes de produzir repostas distintas quando expostos a diferentes tipos de substâncias odoríferas; e um bom conjunto de sensores gera um padrão de resposta característico da substância a qual foi exposto. Padrões de odores são usados para construir uma base de dados e treinar um sistema de reconhecimento de tal forma que odores desconhecidos possam ser identificados e classificados (BLAKE, 2005).

A tecnologia dos narizes eletrônicos procura detectar o perfil dos compostos voláteis presentes em uma amostra, necessitam de uma quantidade relativamente pequena e permitem, ainda, resultados rápidos (RÖCK; BARSAN; WEIMAR, 2008).

O nariz eletrônico utiliza uma plataforma de um sistema de detecção com uma rede neural artificial para distinguir produtos químicos específicos de determinados odores. No lugar das células do nariz humano do receptor, o nariz eletrônico usa uma série de filmes poliméricos de tipos diferentes. Os filmes poliméricos são isolantes dopados com partículas condutoras que lhes permitem melhorar a condução de eletricidade.

Tal como são encontrados comercialmente, os narizes eletrônicos são constituídos por um arranjo de sensores responsáveis pela geração de um conjunto de sinais como resposta à exposição a um determinado odor. Após passar por um conversor analógico-digital, os sinais chegam a um computador ou uma rede neural, onde são comparados com padrões previamente estabelecidos e resultam na identificação do odor, que pode ser constituído por uma única substância volátil ou por uma mistura de substâncias.


1.2 SISTEMA BIOLÓGICO

O olfato é um dos cinco sentidos usados pelo ser humano para se relacionar com o ambiente, dele obter informações, tomar decisões ou simplesmente apreciar odores. Baseados no funcionamento do nariz humano, os narizes eletrônicos foram desenvolvidos com esta mesma finalidade: detectar diferentes odores e tornar possível, então, a identificação e classificação desses odores.

A habilidade de perceber odores é, para o ser humano, um fator muito importante que o permite reconhecer, identificar e qualificar elementos ao seu redor. Além disso, fragrâncias revelam a qualidade do ar: perfumes agradáveis, emanações enjoativas, alarmes de toxicidade. Os odores também são utilizados como uma forma de advertir ao perigo, fator ilustrado pelo traçador adicionado ao gás natural (SILVA, 2009). Um odor é composto por moléculas de diferentes tamanhos e formas. Cada uma dessas moléculas tem um receptor correspondente no nariz humano. Nos seres humanos os odores têm uma grande importância na evocação da memória emocional e desempenha um papel significativo na alimentação, juntamente com o sentido gustatório.

De forma simples, a cadeia de reações humanas por meio da qual sensações, tais como odores, são percebidas é representado na Figura 1.

Figura 1 - Esquema e blocos do sistema nervoso mostrando a recepção do estímulo até a geração de uma resposta

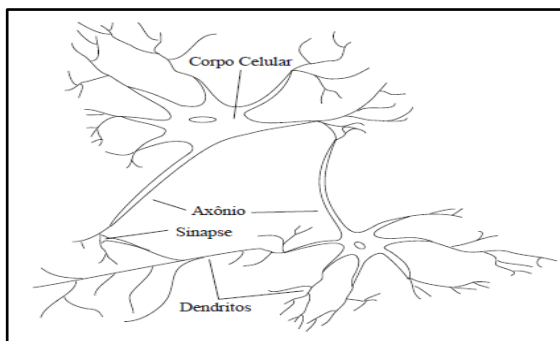


Fonte: elaborado pela autora.

As setas que apontam da esquerda para a direita indicam a transmissão do sinal para frente. As setas que apontam da direita para a esquerda representam a realimentação que existe no sistema. O bloco central do sistema representa o cérebro (ou rede neural), que tem o papel de receber informações, percebê-las e tomar as decisões adequadas para cada situação.

Os receptores fazem a conversão dos estímulos do corpo humano ou do meio externo para impulsos elétricos, que serão transmitidos para o cérebro. Os atuadores têm o papel de converter os impulsos elétricos que saem do cérebro em respostas ao corpo, como por exemplo, movimentar um músculo ou sentir um odor (SILVA, 2003). A informação é processada por neurônios, que são as unidades centrais na rede neural biológica (Figura 2).

Figura 2 - Constituintes do neurônio biológico, evidenciando as estruturas corpo celular, axônio, sinapse e dendritos



Fonte: Stitzel (2011).

Dessa forma, o cérebro humano é responsável por todas as funções sensoriais, motoras e autônomas de um ser humano. Além disso, ele também é responsável pelo que chamamos de emoção, pensamento, percepção e cognição (ORTEGA, 2009).

O nariz humano contém mais de 100 milhões de receptores especializados, ou sensores, que atuam conjuntamente em complexas operações para identificação dessas moléculas. O cérebro é capaz de interpretar esses padrões a fim de distinguir os diversos tipos de odores. Os sinais do sistema olfativo humano são transmitidos para o cérebro para processamento, o cérebro, então, interpreta esse conjunto de sinais em termos de sensação odorante (LISBOA et al., 2009).

A quimiorrecepção é a sensação mais antiga e universal do reino animal. As moléculas trazidas pelo ar sinalizam prazer ou perigo e informam sobre alimento e bebida, ou a presença de algo para procurar ou evitar. Assim como os outros sentidos, o olfato informa sobre o mundo externo. Além disso, contudo, também conecta essa percepção com informações sobre o ambiente interno, suas necessidades e suas satisfações. A interpretação fisiológica de um odor implica em julgar o quão forte, agradável ou desagradável ele é. Odores desagradáveis estão, em geral, associados a coisas desagradáveis. Os odores provenientes de uma estação de tratamento de esgotos estão geralmente associados à decomposição biológica da matéria orgânica. Embora um odor possa ser não-tóxico, sua associação à decomposição biológica pode indicar algo a se evitar, ou um eventual risco à saúde. A presença de um mau odor em geral é um sinal para que se evite sua fonte (GOSTELOW, 2001).

A estrutura natural de um nariz permite que os diferentes odores sejam identificados. A substância odorífera, chegando à cavidade nasal, entra em contato com as células receptoras, sendo gerado, então, um sinal elétrico, que é transmitido para as regiões olfatórias do cérebro.

A percepção de moléculas de odores no nariz humano é conseguida por meio de um conjunto de células sensoriais chamadas de epitélio olfativo. Essas células atuam como sensores biológicos que reagem à presença de moléculas odorantes, por meio da geração de sinais elétricos. Esses sinais são enviados ao cérebro através do córtex olfativo e viajam ao longo do nervo olfativo. Nossos sensores de odores biológicos não são específicos para produtos químicos simples, mas são especializados para grupos de compostos químicos. As células, portanto, reagem fortemente aos produtos químicos para os quais elas são especializadas, mas também para outros produtos químicos, especialmente se estiverem presentes em concentrações elevadas.

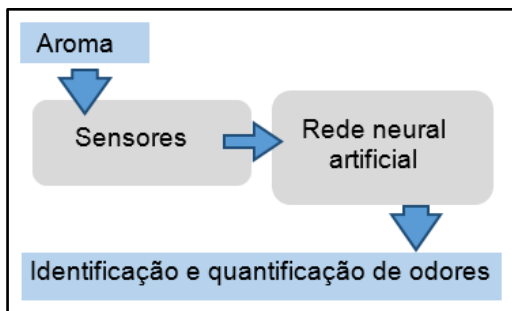
No nariz humano, os neurônios olfativos produzem estímulos elétricos que são transmitidos ao cérebro. Evidências mostram que um único neurônio olfativo responde a vários odores, e cada odorante é sentido por múltiplos neurônios olfativos. Da mesma forma, narizes eletrônicos baseiam-se na análise da reatividade cruzada de uma matriz de sensores semisseletivos. Assim, produtos com aroma similar resultam em padrões semelhantes de resposta do sensor (similar: "impressões digitais" semelhantes), enquanto que produtos com aroma diferentes mostram diferenças em seus padrões (diferentes: "impressões digitais" diferentes). O sistema olfativo dos mamíferos é capaz de detectar muito mais odorantes do que o número de receptores, utilizando receptores olfativos de reação cruzada, que geram os padrões de resposta únicos para cada odorante. (STITZEL, 2011).

1.3 SISTEMA ELETRÔNICO

O nariz eletrônico busca imitar a estrutura de um nariz humano. Ambos os sistemas interagem com moléculas de compostos voláteis (geralmente misturas complexas) com receptores apropriados: receptores olfatórios no nariz biológico e o arranjo de sensores no nariz eletrônico. Imitando o sistema de mamíferos, narizes artificiais combinam conjuntos de sensores de reação cruzada com algoritmos de reconhecimento de padrões para criar sistemas robustos de discriminação de odores (STITZEL, 2011).

O nariz eletrônico é composto por um conjunto de sensores químicos (sensíveis a gases e vapores) e um algoritmo de reconhecimento. Após ser 'cheirado', o sinal, a interpretação, realizada pelo software, compara o espectro medido com os padrões armazenados na memória do computador para substâncias conhecidas. Inicialmente, o nariz eletrônico é como um instrumento composto de um arranjo de sensores eletrônico-químicos que apresentam especificidade parcial e um sistema de reconhecimento de padrões apropriado, capaz de identificar odores simples e complexos. Esse instrumento é capaz de produzir uma impressão digital para um odor específico. Quando um aroma é percebido, suas moléculas interagem com numerosos receptores, causando então um sinal interpretado por uma rede neuronal ou um computador (OUELLETTE, 1999). A Figura 3 mostra um esquema de percepção de um aroma (composto volátil) pelos sensores de um nariz eletrônico.

Figura 3 - Esquema de percepção de um aroma por um nariz eletrônico, evidenciando os sensores, rede neural artificial e a resposta (identificação e quantificação de odores)



Fonte: elaborado pela autora.

Narizes eletrônicos têm sido usados em uma variedade de aplicações e podem ajudar na solução de problemas em muitos campos, incluindo a garantia da qualidade de cerveja em indústrias (VARNAMKHASTI et al., 2011). A demanda pela tecnologia de narizes eletrônicos cresce porque seu uso é versátil e de fácil operação, e eles propiciam uma rápida e precisa análise do produto final ou no monitoramento da qualidade do processo de produção.

A integração e combinação de alguns métodos e instrumentos analíticos com o nariz eletrônico podem ser uma saída muito interessante para o monitoramento completo da qualidade da cerveja (VARNAMKHASTI et al., 2011). Sistemas integrados como este podem contribuir no processo industrial, chegando a detectar níveis de até mesmo partes por trilhão (ppt) para alguns compostos e, combinados com línguas eletrônicas (APETREI et al., 2010), alcançam um nível de monitoramento bastante satisfatório.

1.4 JUSTIFICATIVA

O desenvolvimento da indústria cervejeira nos últimos anos exigiu que o controle de qualidade do produto fosse aprimorado. Tradicionalmente, a indústria cervejeira emprega métodos de análise considerados caros ou morosos. Medidas hoje existentes para avaliar os compostos de *off-flavor* são caras (cromatografia gasosa), precisam de pré-tratamentos e são, em geral, demoradas. Análises como as do painel sensorial para determinar a intensidade dos descritores aromáticos da

bebida requerem o treinamento de pessoas e, de uma forma geral, consomem muito tempo, podem ser dispendiosas e subjetivas e, assim, possuem pouca reprodutibilidade. Além disso, análises de cromatografia gasosa e painel sensorial não são usadas diretamente na linha de produção da cerveja.

Tendo em vista a importância de um controle de qualidade rigoroso e mais prático, a proposta é criar uma medida rápida, barata, sem preparo prévio da amostra e portátil, visando melhorar o controle de qualidade da cerveja. Um nariz eletrônico pode ser a saída para diminuir os custos de análise ao longo do tempo e fornecer resultados rápidos e precisos. Constitui um método mais objetivo que pode diminuir os problemas com reprodutibilidade e longos treinamentos de pessoas. A tecnologia permite, ainda, que o aparelho possa ser utilizado diretamente na linha de produção e forneça resultados ao longo do processo de produção da cerveja.

1.5 OBJETIVOS

1.5.1 Objetivo geral

O objetivo geral deste projeto é implementar um sistema capaz de identificar um conjunto de aromas indesejáveis presentes na cerveja denominados de *off-flavors*. Este sistema, denominado *e-nose* ou ‘nariz eletrônico’, será implementado com um conjunto de sensores a gás.

1.5.2 Objetivos específicos

- Realizar teste com painel sensorial com a finalidade de compará-lo com o protótipo;
- Realizar teste com painel treinado e não treinado com a finalidade de comparar a capacidade de reconhecimento dos grupos;
- Projetar um circuito elétrico para os sensores;
- Testar os sensores quanto a sua seletividade para compostos aromáticos da cerveja;
- Realizar medidas no protótipo: amostras de cerveja com adição dos atributos em concentração no limiar de percepção de cada um dos compostos, as respostas dos sensores serão amostradas e transmitidas a um computador;

- Testar o recebimento do sinal e tratamento, processamento de dados;
- Implementar em *software* o algoritmo de uma rede neural artificial;
- Encontrar medidas com os sensores de gases, atributos para o processo de reconhecimento de padrões através de PNN e PCA;
- Treinar e testar a rede neural artificial com os atributos das medidas com os sensores de gases.

1.6 PARCEIROS NO DESENVOLVIMENTO DO PROJETO

1.6.1 VLB - Berlin Alemanha Versuchs - und Lehranstalt für Brauerei in Berlin



O Instituto de Investigação e Formação Cervejeira (VLB) em Berlim foi fundado em 1883. Sua especialidade é fabricação de cerveja, malte e a indústria de bebidas. Hoje, cerca de 100 funcionários trabalham em Berlim nas áreas de pesquisa, educação, informação e serviços. É um instituto independente e um dos principais centros de competências internacionais para a investigação aplicada, ensino e serviço para o setor de cerveja e outras bebidas, bem como para os seus fornecedores e clientes.

O laboratório desenvolve soluções inovadoras para os problemas atuais e para as questões básicas dos clientes. Além disso, aplicam-se, serviços modernos de análise orientadas para o cliente e consultoria especializada. Nosso nível de qualidade é assegurado por modernos equipamentos e motivação, treinamento e habilidades de comunicação de nossa equipe de aproximadamente 120 funcionários.

A experiência adquirida tem um impacto direto sobre os programas de treinamento e reciclagem. Como um organizador de conferências internacionais, o Instituto fornece uma plataforma para a troca de experiências, seja com outras disciplinas, parcerias ou empresas. O VLB - Berlim tem trabalhado desde 1883 como um instituto independente no ponto de intersecção entre a investigação, a educação e a prática industrial.

Justificativa de parceria A VLB possui a estrutura necessária de laboratórios para projetos relacionados a cerveja, possui experiência e tradição em projetos que envolvem novas tecnologias para aprimoramento de cerveja e é respeitada mundialmente.

2 REVISÃO BIBLIOGRÁFICA

2.1 SENSORES

Narizes eletrônicos utilizam um conjunto de sensores que imitam receptores olfativos e são responsáveis por captar estímulos de compostos químicos voláteis que compõem o odor característico de uma amostra. Ao contrário da maioria dos sensores químicos existentes, projetados para detectar compostos químicos específicos, os sensores em um nariz eletrônico não são específicos a nenhum vapor ou gás. Portanto, usando um conjunto de diferentes sensores que respondem a diversos compostos, podem ser identificados vapores, gases e misturas de gases a partir da comparação a padrões de respostas disponíveis no computador. Uma linha de base de um ar limpo é estabelecida e seus desvios registrados como mudanças na resistência dos sensores. As respostas dos diferentes sensores podem ser comparadas e agrupadas de modo a permitir a identificação e quantificação dos diferentes compostos químicos presentes na amostra, usando um *software* para análise, a partir dos padrões registrados ou uma rede neural artificial (RYAN, 2007).

2.1.1 Características e funcionamento de um sensor

2.1.1.1 Visão geral e classificação de sensores

Sensores de gás são sensores químicos compostos por um transdutor e uma camada ativa para conversão da informação química em uma outra forma - um sinal eletrônico - como mudanças na frequência, na corrente elétrica ou voltagem. A detecção de gases pode utilizar diferentes tipos de tecnologia de detecção de gases, incluindo sensores de gás semicondutores, sensores de gás catalíticos, sensores de gás eletroquímicos, sensores de gás óticos e sensores de gás acústicos.

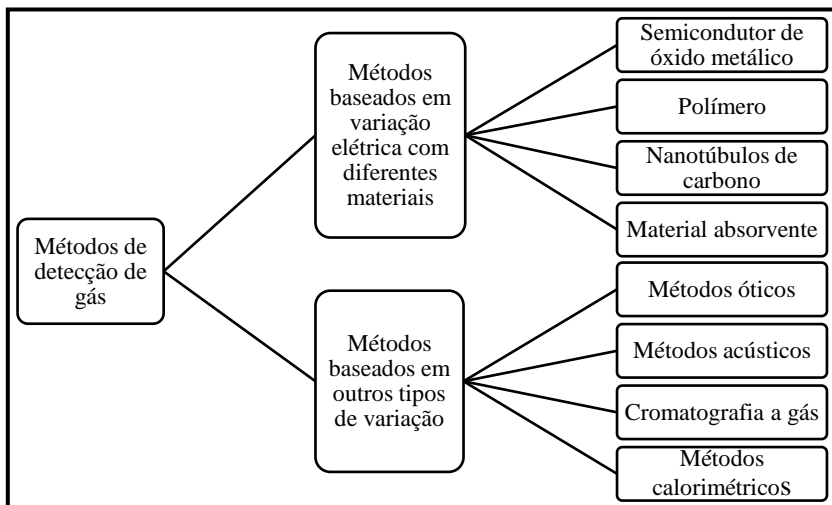
Recentemente, a aplicação de sensores de gás em sistemas inteligentes tem recebido atenção tanto na indústria quanto na academia. Possui aplicação em áreas como proteção industrial, indústria automotiva, aplicações médicas, supervisão da qualidade do ar em residências e estudos ambientais.

Para avaliar a performance de um sensor de gás, muitos indicadores podem ser avaliados. Entre eles, merecem destaque: (1) sensibilidade: o valor mínimo de concentração volumétrica do gás de

interesse detectável; (2) seletividade: habilidade do sensor de gás em identificar um gás específico em uma mistura de gases; (3) tempo de resposta: período entre o tempo em que a concentração de gás atinge um valor específico para gerar um sinal de alerta; (4) consumo de energia; (5) reversibilidade: o material do sensor deve retornar ao seu estado inicial após a detecção; (6) capacidade adsorptiva (também afeta a sensibilidade e seletividade); (7) custo de fabricação (LIU et al, 2012).

A Figura 4 representa a classificação dos métodos de detecção de gases, divididos em duas categorias principais: métodos baseados em variação elétrica com diferentes materiais e métodos baseados em outros tipos de variação.

Figura 4 - Diagrama representando os diferentes métodos de detecção de gás, baseados na variação elétrica ou em outros tipos de variação



Fonte: Liu et al. (2012).

2.1.2 Tipos de sensores

2.1.2.1 Sensores de Óxidos Metálicos (MOS)

Os sensores de óxidos metálicos demonstram boa sensibilidade aos vapores orgânicos (ppm ou mesmo ppb) para uma grande abrangência de compostos químicos (MARSILLI, 1995). Apresentam baixa seletividade - isto é, todos os sensores podem responder a um mesmo composto volátil, mas em magnitudes diferentes - arranjos desse

tipo de sensor devem ser empregados. São sensores compostos por um filme de óxido metálico semicondutor revestido sobre um substrato de cerâmica. São feitos depositando uma camada fina de filme de óxido em um material cerâmico (por exemplo, SnO_2 , TiO_2 , ZnO , ZrO_2).

Nos sensores de óxidos metálicos, reações de oxirredução ocorrem de acordo com a interação com o odor, assim, elétrons são gerados e uma variação na resistência pode ser medida. “O oxigênio do ar é dissolvido em uma rede de semicondutores”, levando a resistência elétrica a um nível de fundo (quando em equilíbrio estável). Durante a medição, as moléculas voláteis (principalmente não polar) são adsorvidas na superfície do semicondutor onde reagem (redução/oxidação) com as espécies de oxigênio dissolvidas, provocando uma nova modificação da resistência (ou condutividade) do dispositivo. Com a magnitude da resposta dependente da natureza da molécula detectada e do tipo de óxido metálico usado na preparação do sensor, o tempo de resposta dos sensores está entre 10 e 120 segundos (MARSILLI, 1995).

Sensores de óxidos metálicos demonstram boa sensibilidade aos vapores orgânicos (ppm ou mesmo ppb) para uma grande abrangência de compostos químicos. Devido à sua pobre seletividade - isto é, todos os sensores podem responder a um mesmo composto volátil, mas em magnitudes diferentes - arranjos desse tipo de sensor devem ser empregados. Os sensores de óxidos metálicos são feitos depositando uma camada fina (505 micrômetros) de filme de óxido em um material cerâmico. Para funcionar apropriadamente, os sensores de óxidos metálicos são aquecidos geralmente a 175°C e 425°C . A resistência elétrica do sensor diminui na presença de um odor, com a magnitude da resposta dependente na natureza da molécula detectada e do tipo de óxido metálico usado na preparação do sensor. O tempo de resposta de sensores de óxidos metálicos é entre 10 e 120 segundos (MARSILLI, 1995). Nos sensores de óxidos metálicos, reações de oxirredução ocorrem de acordo com a interação com o odor, assim, elétrons são gerados e uma variação na resistência pode ser medida. As taxas da reação são aumentadas em altas temperaturas, de modo que estes sensores operem geralmente entre 300°C e 400°C . Estes sensores têm a vantagem de não se saturarem em compostos químicos, como é o caso dos odores. Isto é devido à reação de oxidação em superfície.

Com relação à influência da umidade, os tipos de óxido metálicos podem alterar as respostas obtidas. As moléculas de água, quando adsorvidas quimicamente, podem influenciar a condutividade da camada

semicondutora de duas formas. Na primeira, as moléculas dissociam-se em hidroxilas, que agem como doadoras de elétrons. Estes elétrons causam um aumento na condutividade do sensor. Na segunda, os átomos de hidrogênio dissociados da molécula de água podem reagir com os átomos de oxigênio da rede e se difundirem pelo corpo, agindo como doadoras de elétrons.

O efeito da umidade sobre a sensibilidade e a seletividade dos sensores de óxido de estanho depende da quantidade de água no ar, do tipo de gás da atmosfera ambiente e do tipo de aditivo introduzido na camada semicondutora. Para reduzir a interferência da umidade no sensor, utilizam-se filmes metalorgânicos finos, condensação de material hidrófobo ou processamento do seu sinal do sensor. Quando em operação, os sensores requerem aproximadamente uma semana até atingirem um regime estável.

Alterar o tamanho da partícula e a espessura do filme de semicondutores também é algo que tem sido testado com a mesma finalidade, bem como o revestimento de um sensor de gás com uma membrana semipermeável, com espessura variando com aumento da seletividade. Sensores dopados apresentam maior sensibilidade para os compostos orgânicos voláteis oxigenados (por exemplo, álcoois, cetonas) do que alifáticos aromáticos ou compostos clorados. A dopagem com Pt e Pd aumenta a sensibilidade dos sensores de SnO_2 para gases, como benzeno e tolueno.

Devido à dependência logarítmica da resposta do sensor com a concentração dos voláteis, a perda da sensibilidade surge (para compostos de baixa volatilidade de aroma) na presença de alta concentração de espécies detectáveis, como o etanol.

Os modelos mais recentes no mercado são capazes de corrigir o desvio e possibilitam um monitoramento da temperatura e umidade com dispositivo de controle de temperatura, tornando possível lidar com a intoxicação, pois permitem uma melhor regeneração do sensor após cada análise. Estes sensores têm a vantagem de não se saturarem em compostos químicos, como é o caso dos odores, devido à reação de oxidação na superfície.

Com relação à influência da umidade, os tipos de óxido metálicos podem alterar as respostas obtidas. As moléculas de água, quando adsorvidas quimicamente, podem influenciar a condutividade da camada semicondutora de duas formas. Na primeira, as moléculas dissociam-se em hidroxilas, que agem como doadoras de elétrons. Estes elétrons causam um aumento na condutividade do sensor. Na segunda, os átomos

de hidrogênio dissociados da molécula de água podem reagir com os átomos de oxigênio da rede se difundirem pelo corpo, agindo como doadoras de elétrons.

2.1.2.2 Sensores de Polímeros Condutores (CP)

Sensores de polímeros condutores orgânicos (também chamados de polímeros intrinsecamente condutores, ICP) são feitos de materiais semicondutores, aromáticos ou heteroaromáticos (por exemplo, polipirrol, polianilina politiofeno), depositados em um substrato e entre dois eletrodos metálicos. Após a interação com as moléculas voláteis uma mudança reversível de condutividade elétrica dos dispositivos é observada. Embora mais sensíveis aos compostos voláteis polares, a sua seletividade e sensibilidade pode ser modificada pelo uso de diferentes grupos funcionais, estrutura do polímero e íons dopantes. Além disso, moléculas biológicas, tais como enzimas, anticorpos e células podem ser facilmente incorporados nas estruturas do polímero. Uma variante deste tipo de sensores é baseada em polímeros isolantes eletricamente carregados com negro de fumo como carga que conduz eletricidade.

Quando expostos aos compostos voláteis, o volume do polímero isolante cresce, ampliando a distância entre as partículas condutoras de eletricidade do negro de fumo. Isso resulta em um aumento na resistência elétrica.

Os filmes sensores são feitos por polímeros conjugados dopados para torná-los condutores de eletricidade. Cada sensor é feito de um filme muito fino depositado sobre um par de eletrodos. A resistência de cada filme é medida e as mudanças na resistência são registradas. Tais mudanças resultam em um padrão no sensor e sua magnitude é usada para identificar e quantificar o composto responsável pelas mudanças. No caso desses sensores, forças de Van der Waals atuam entre os polímeros e o odorante, causando uma mudança na carga e uma consequente variação da resistência (PIAGGIO, 2009).

Os instrumentos baseados em polímeros condutores podem detectar compostos orgânicos com uma escala de peso molecular bem ampla, essencialmente a mesma escala que o nariz humano pode detectar. Os sensores com polímeros condutores trabalham melhor com compostos ou moléculas polares, pois têm uma carga associada. Os sensores são especialmente sensíveis às moléculas orgânicas com grupos funcionais de enxofre e aminas. Concentrações elevadas de

ácidos, bases e aminas podem interferir no funcionamento apropriado dos sensores de polímeros condutores.

Geralmente, os polímeros absorvem vapor de água e, como resultado, a concentração de sítios de ligação disponíveis para outros voláteis diminui drasticamente. Esta é a razão para a sensibilidade reduzida dos sensores de gás CP em elevados níveis de umidade. Alguns autores têm sugerido a aplicação de ‘filtros’ para reter compostos indesejáveis, tais como etanol ou água antes da análise, ou durante a análise no caso de sensores QMB.

O outro desafio desta tecnologia é melhorar a reprodutibilidade na fabricação de sensores de polímeros condutores. No entanto, os sensores baseados em CP apresentam respostas lineares e seletividade maior em comparação com sensores MOS.

Em contraste com os sensores MOS, nenhum efeito de envenenamento com compostos contendo enxofre ou ácidos fracos tem sido observado. Eles mostram respostas mais rápidas e as recuperações da linha de base, e não necessitam de altas temperaturas de operação.

2.1.2.3 Sensores colorimétricos

Os componentes dos arranjos de sensores colorimétricos (CSA) são inerentes à nano escala. Tais arranjos agem como um nariz óptico-eletrônico, usando um conjunto de múltiplas tinturas, cujas mudanças de cores são baseadas numa ampla gama de interações intermoleculares (SUSLICK, 2004). Os arranjos de sensores colorimétricos foram desenvolvidos em anos recentes e apresentam imagens digitalizadas antes e após uma exposição, as diferenças resultantes fornecem uma impressão digital para qualquer composto orgânico volátil (VOC) ou mistura de odorantes.

O resultado é um enorme aumento no poder discriminatório dos compostos odorantes, quando comparados às demais tecnologias eletrônicas dos narizes eletrônicos. Esses sensores têm sido utilizados na detecção de importantes analitos biológicos, tais como aminas, ácidos carboxílicos e tióis, com sensibilidades elevadas (ppb). Esse tipo de sensor não responde às mudanças na umidade devido à hidrofobicidade das tinturas e membranas (SUSLICK, 2010).

2.1.2.4 Sensores com nanomateriais

Pesquisas têm sido desenvolvidas com aplicações da nanotecnologia para uso como sensores olfatométricos. Esses nano materiais podem melhorar a condutividade dos sensores e simplificar a sua fabricação, são muito utilizados para a detecção de gases perigosos em pequenas concentrações na indústria aeroespacial (GREB, 2002).

Nanotubos de carbono (CNTs) são atrativos por suas propriedades únicas e se tornaram materiais promissores para sensores de gás de alta sensibilidade. Esses materiais possuem propriedades elétricas e são extremamente sensíveis a pequenas quantidades de gases como álcool, amônia, dióxido de carbono e óxidos de nitrogênio a temperatura ambiente, enquanto outros materiais como óxidos metálicos necessitam ser aquecidos para operar normalmente. Essa alta sensibilidade elimina a necessidade de tecnologias como pré-concentração e contribuem com a vantagem de ser de baixo custo, peso e de configuração simplificada (LIU et al, 2012).

2.1.2.5 Ion Mobility Spectrometry (IMS)

São sensores que têm a capacidade de separar espécies iônicas na pressão atmosférica. Existem pesquisas em desenvolvimento para sistemas IMS em baixa pressão, técnica utilizada para determinar e caracterizar vapores orgânicos no ar (SHVARTSBURG, 2008).

2.1.3 Métodos de preparação de amostras para introdução em narizes eletrônicos

Para introduzir os compostos voláteis presentes no *headspace* da amostra no sistema de detecção do nariz eletrônico, são utilizados vários tipos de técnicas (PERIS et al., 2009).

2.1.3.1 Técnica do Headspace Estático (SHS)

Consiste em colocar a amostra em um domo hermeticamente fechado e, quando o equilíbrio entre a matriz e a fase gasosa é atingido, uma amostra é retirada do *headspace*. A temperatura da amostra, tempo de equilíbrio, tamanho do domo e quantidade de amostra são os principais parâmetros que devem ser otimizados, e para se obter uma melhor reprodutibilidade dos resultados, um amostrador automático

pode ser utilizado. Em algumas aplicações, um sistema que use corrente de vapor pode ser empregado e fornecer melhor controle da temperatura de operação e quantidade de analito que uma injeção manual.

2.1.3.2 Técnicas de Purga e *Trap* (P&T) e *Headspace* Dinâmico (DHS)

Têm sido usadas em algumas aplicações para aumentar a sensibilidade, uma vez que elas proporcionam uma pré-concentração dos voláteis. Nesse sistema, os compostos voláteis são purgados por uma corrente de gás inerte e retidos em um adsorvente. Na técnica de P&T, a corrente de gás é injetada através da amostra, enquanto na técnica de DHS, apenas o *headspace* é purgado com o gás. A depleção constante do *headspace* leva ao deslocamento do equilíbrio em favor de uma desorção das moléculas presentes na matriz. As moléculas retidas são subsequentemente dessorvidas por aquecimento e introduzidas em um sistema de detecção. Além da escolha do adsorvente, parâmetros como temperatura da amostra, tempo de equilíbrio, taxa de vazão do gás extrator e tempo de purga devem ser otimizados.

2.1.3.3 Microextração em Fase Sólida (SPME)

É um método de pré-concentração relativamente fácil e não requer equipamento especial. A sílica de vidro coberta com uma fina camada de adsorvente é exposta ao *headspace* da amostra para reter os compostos voláteis na sílica. Os compostos adsorvidos são, depois, dessorvidos por aquecimento e introduzidos no sistema de detecção. Além do adsorvente depositado na sílica, são parâmetros importantes a serem otimizados o tempo de equilíbrio, temperatura da amostra e a duração da extração.

2.1.3.4 Extração por Barra de Adsorção (SBSE)

Utiliza uma barra magnética coberta por polímeros que pode ser suspensa no *headspace* para amostragem. Sua capacidade de concentração é muito maior do que a da técnica SPME. Embora seja recente, é um tipo de extração promissora quando alta sensibilidade é requerida.

2.1.3.5 Extração Dinâmica com Agulha Interna (INDEX)

É também uma técnica de pré-concentração. As agulhas INDEX contêm uma fase de polímero absorvente muito semelhante a um leito fixo. Os compostos voláteis são forçados através da agulha por seguidos movimentos de aspiração/ejeção do êmbolo da seringa. A vantagem potencial deste sistema, se comparado ao SPME, é a sua robustez mecânica e possibilidade de aumento da quantidade de polímero adsorvente, bem como da área superficial disponível para adsorver os compostos voláteis.

2.1.3.6 Espectrometria de Massa de Introdução de Membrana (MIMS)

É um sistema usado em narizes eletrônicos baseados em espectrometria de massa (MS). A técnica permite a introdução direta de compostos específicos de uma amostra líquida ou gasosa no espectrômetro de massa. Uma fina membrana é instalada entre a amostra e a fonte de íons de um espectrômetro de massa de tal forma que alguns compostos se dissolvem na membrana, sofrem difusão através dela e, finalmente, evaporam diretamente para a fonte de íons.

2.2 REDES NEURAIS

As redes neurais artificiais consistem em um método de solucionar problemas de inteligência artificial, compostas de um sistema com circuitos que simulam o cérebro humano, inclusive seu comportamento, ou seja, aprendendo, errando e fazendo descobertas. São mais que isso, são técnicas computacionais que apresentam um modelo inspirado na estrutura neural de organismos inteligentes e que adquirem conhecimento por meio da experiência. Uma grande rede neural artificial pode ter centenas ou milhares de unidades de processamento, enquanto o cérebro de um mamífero pode ter vários bilhões de neurônios.

As RNAs procuram reproduzir o modo de raciocínio do cérebro humano e, por este motivo, são denominadas neurais. 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 são utilizadas para resolver muitos problemas complexos do mundo real (DELLA LUCIA; MINIM, 2010). A associação entre a estrutura de um cérebro humano e de uma

RNA é facilmente observável. Primeiramente, a rede adquire conhecimento a partir de seu ambiente por meio de um processo de aprendizagem, da mesma forma que o cérebro. Além disso, todo o conhecimento adquirido pela rede é armazenado nas conexões entre os neurônios, ou seja, nos pesos sinápticos.

As redes neurais são formadas por uma grande quantidade de processadores simples, chamados de neurônios, unidades ou elementos processadores conectados entre si por canais de comunicação conhecidos como sinapses. Pelas sinapses, trafegam os dados numéricos, formando canais de comunicação entre as unidades. O aprendizado da rede é armazenado pelas sinapses na forma de ‘intensidade’ de ligação entre as unidades. A Figura 5 apresenta o esquema de um neurônio artificial e seus constituintes.

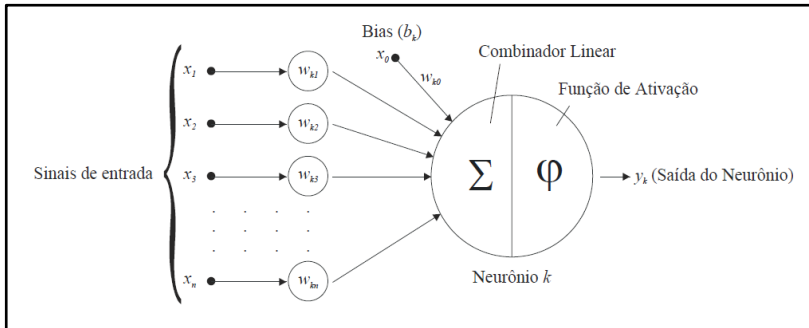
A base de uma rede neural são os neurônios artificiais que ‘copiam’ o funcionamento dos neurônios biológicos do cérebro humano. As entradas (*inputs*) para os neurônios chegam por meio dos dendritos. Esses, por sua vez, também podem agir como saídas (*outputs*), interconectando os neurônios. Matematicamente, os dendritos seriam o somatório. Os axônios, por outro lado, são encontrados somente nas células de saída, têm função sináptica e quando ativos transmitem um sinal elétrico. São responsáveis também por conectar os demais neurônios por meio de seus dendritos.

A rede neural artificial é um sistema de neurônios ligados por conexões sinápticas e divididos em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou *hidden* (ocultos) e neurônios de saída, que se comunicam com o exterior. A forma de arranjar perceptrons em camadas é denominada de *multilayerperceptron*. O *multilayerperceptron* foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Um único perceptron ou uma combinação das saídas de alguns perceptrons poderia realizar uma operação XOR (operação lógica de dois operandos que resulta em um valor lógico verdadeiro), porém, seria incapaz de aprendê-la. Para isso são necessárias mais conexões, os quais só existem em uma rede de perceptrons dispostos em camadas.

Os neurônios internos são de suma importância na rede neural. Uma rede é composta por várias unidades de processamento, geralmente conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões.

O comportamento inteligente de uma RNA (rede neural artificial) vem das interações entre as unidades de processamento da rede. Assim como ocorre em um neurônio natural, estímulos advindos do exterior são aceitos como entradas. Os neurônios possuem uma central de análise dos dados que funciona como o núcleo celular.

Figura 5 - Representação de um neurônio artificial k , esquematizando os sinais de entrada, o combinador linear, a função de ativação e saída do neurônio



Fonte: Silva (2003).

Os dendritos de um determinado neurônio k são representados pelos n sinais de entrada x_1, x_2, \dots, x_n , enquanto que a saída y_k representa o axônio deste neurônio. Para representar o efeito gerado pelas sinapses, cada sinal de entrada é associado a um determinado peso ($w_{k1}, w_{k2}, \dots, w_{kn}$) e estes pesos, os pesos sinápticos, podem assumir tanto valores positivos quanto negativos, representando, desta forma, os efeitos excitatórios ou inibitórios sobre o neurônio (Figura 4). O núcleo de processamento do neurônio (o corpo celular) é representado matematicamente pela junção de um combinador linear com a função de ativação. Basicamente, este combinador linear faz o somatório de todas as entradas do neurônio, sendo que estas entradas são ponderadas pelos respectivos pesos sinápticos.

A função de ativação pode assumir várias formas, geralmente não lineares. Os pares de entradas $x_i w_i$ são combinados usando uma função (geralmente, mas não necessariamente, utiliza-se soma ou produto) para produzir um estado de ativação do neurônio que, por meio da função, produzirá a saída de ativação para a obtenção de uma resposta (identificação de certo tipo de odor, por exemplo).

A partir do registro de uma medida de uma grandeza, geralmente da tensão sobre o sensor contra o tempo, para uma dada concentração da amostra e temperatura de operação fixa, são formados os padrões para o classificador de aromas.

2.2.1 Características e vantagens de RNAs

As redes neurais artificiais (RNA) têm características que conferem a elas uma ferramenta bastante eficiente para executar tarefas semelhantes às realizadas pela estrutura biológica humana (classificação, aprendizado etc.). Dentre as muitas vantagens, podemos citar:

- Sua aprendizagem: as RNAs têm a capacidade de aprender por meio de uma fase chamada fase de aprendizagem. Trata-se de fornecer dados como entrada da RNA que, por sua vez, informa qual é a saída (resposta) esperada.
- Auto-organização: uma RNA cria sua própria representação de informação no seu interior.
- Tolerância a falhas: como um RNA armazena informações de forma redundante, pode continuar a responder de uma forma aceitável, mesmo que esteja parcialmente danificada. Caso um neurônio ou suas conexões sejam destruídas, 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.
- Flexibilidade: uma rede neural não pode lidar com grandes mudanças na informação de entrada, tais como sinais ruidosos ou outras alterações na entrada.

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.

Outro 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. Além disso, um sistema baseado em RNAs é considerado mais inteligente do que a abordagem estatística convencional devido à sua robustez a ruídos e inconsistências nos dados. Uma característica desta ferramenta diretamente relacionada à Análise Sensorial é que ela 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.

2.2.2 Fatores que influenciam no desempenho das RNAs

As RNAs são influenciadas por três fatores: (i) convergência; (ii) generalização e (iii) escalabilidade. A convergência está relacionada ao aprendizado da RNA de identificar padrões num conjunto de dados, o que é definido no procedimento de treinamento. A convergência mostra se o processo de treinamento é capaz de identificar os padrões não lineares numa série de dados, que será fundamental para previsões mais precisas. Esse fator merece muita atenção, pois se a rede não consegue atingir uma boa convergência, é porque não aprendeu as relações existentes e, conseqüentemente, não atingirá bons resultados na fase dos testes.

A generalização é a etapa onde as RNAs reconhecem os padrões não existentes nos dados de treinamento. Esse aspecto é determinante para identificar os valores fora de padrão. Não há um consenso que mostre as condições ideais para encontrar boas generalizações. A probabilidade de generalizações corretas depende do número total de redes consideradas, do conjunto de RNAs que fornecem boas soluções e do número de exemplos do treinamento. Geralmente, a redução do número de conexões da rede melhora os resultados de generalização. Porém, deve-se evitar uma redução grande, que pode empobrecer o resultado final da previsão.

2.2.3 Aprendizado (ou treinamento)

O aprendizado consiste na modificação dos pesos das conexões entre os neurônios, os pesos iniciais (sinapses) são modificados de forma iterativa, por um algoritmo que segue um dos seguintes paradigmas de aprendizado:

- **Aprendizado Supervisionado:** é apresentado um conjunto de treino, consistindo de entradas e correspondentes saídas desejadas. Neste caso, para cada estímulo de entrada (vetor de entrada), existe um estímulo de saída (vetor alvo de saída), que 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 e 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. 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 (CARVALHO, 2011).
- **Aprendizado Não-supervisionado:** a rede atualiza seus pesos sem o uso de pares entrada-saídas desejadas e sem indicações sobre a adequação das saídas produzidas. Também conhecido como paradigma autônomo ou auto-organizado. Nesse 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 (CARVALHO, 2011).
- **Aprendizado por Reforço:** está compreendido entre o aprendizado supervisionado e não supervisionado, no qual um

professor externo indica apenas se a resposta a uma entrada é boa ou ruim. 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 (CARVALHO, 2011).

2.2.4 Arquitetura e topologia das RNAs

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 (CARVALHO, 2011).


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 é 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.

As redes neurais artificiais podem ser classificadas 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 (SILVA, 2003). A Figura 6 apresenta o esquema de uma rede neural de camada única, com os sinais de entrada x_n e saída y_n .
- Redes de múltiplas camadas (ou multilayer): 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 (SILVA, 2003). A Figura 7 esquematiza uma rede neural com múltiplas camadas. Neste caso, os sinais de entrada x_n passam por neurônios situados em certo número de camadas ocultas até que o sinal seja emitido para a camada final e obtenha-se a saída y_n .

Figura 6 - Esquema de uma rede de camada única



Fonte: Silva (2003).

Figura 7 - Esquema de uma rede de múltiplas camadas (*multilayer*)



Fonte: Silva (2003).

Em relação às conexões, essas podem se apresentar de três formas (SILVA, 2003):

- Conexões intracamadas - em que as saídas de um nodo, situado na camada, alimentam outro nodo da mesma camada;

- Conexões intercamadas - em que as saídas de um nodo, situado na camada, 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 (SILVA, 2003):

- *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.

2.2.5 Desenvolvimento e treinamento de uma rede neural

A seguir são descritos passos para o desenvolvimento de uma rede neural:

Coleta de dados: os dois primeiros passos do processo de desenvolvimento de redes neurais artificiais são a coleta de dados relativos ao problema e a sua separação em um conjunto de treinamento e em um conjunto de testes. Esta tarefa requer uma análise cuidadosa sobre o problema para minimizar ambiguidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema; não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições nos limites do domínio do problema.

Separação em conjuntos: normalmente, os dados coletados são separados em duas categorias: dados de treinamento, que serão utilizados para o treinamento da rede; e dados de teste, que serão utilizados para verificar sua performance sob condições reais de utilização. Além dessa divisão, pode-se usar também uma subdivisão do

conjunto de treinamento, criando um conjunto de validação, utilizado para verificar a eficiência da rede quanto a sua capacidade de generalização durante o treinamento, e podendo ser empregado como critério de parada do treinamento. Depois de determinados estes conjuntos, eles são geralmente colocados em ordem aleatória para prevenção de tendências associadas à ordem de apresentação dos dados. Além disso, pode ser necessário pré-processar estes dados por meio de normalizações, escalonamentos e conversões de formato para torná-los mais apropriados à sua utilização na rede.

Configuração da rede: o terceiro passo é a definição da configuração da rede, que pode ser dividido em três etapas:

- Seleção do paradigma neural apropriado à aplicação.
- Determinação da topologia da rede a ser utilizada - o número de camadas, o número de unidades em cada camada etc.
- Determinação de parâmetros do algoritmo de treinamento e funções de ativação. Este passo tem um grande impacto na performance do sistema resultante. Normalmente as escolhas são feitas de forma empírica.

Treinamento: o quarto passo é o treinamento da rede. Nesta fase, seguindo o algoritmo de treinamento escolhido, serão ajustados os pesos das conexões. É importante considerar, nesta fase, alguns aspectos, tais como a inicialização da rede, o modo de treinamento e o tempo de treinamento.

Uma boa escolha dos valores iniciais dos pesos da rede pode diminuir o tempo necessário para o treinamento. Normalmente, os valores iniciais dos pesos da rede são números aleatórios uniformemente distribuídos, em um intervalo definido. A escolha errada destes pesos pode levar a uma saturação prematura.

Quanto ao modo de treinamento, na prática é mais utilizado o modo padrão devido ao menor armazenamento de dados, além de ser menos suscetível ao problema de mínimos locais, devido à pesquisa de natureza estocástica que realiza. Por outro lado, no modo *batch* se tem uma melhor estimativa do vetor gradiente, o que torna o treinamento mais estável. A eficiência relativa dos dois modos de treinamento depende do problema que está sendo tratado.

Quanto ao tempo de treinamento, vários fatores podem influenciar a sua duração, porém sempre será necessário utilizar algum

critério de parada. O critério de parada do algoritmo *backpropagation* não é bem definido, e geralmente é utilizado um número máximo de ciclos. No entanto, devem ser considerados a taxa de erro médio por ciclo, e a capacidade de generalização da rede. Pode ocorrer que em um determinado instante do treinamento a generalização comece a degenerar, causando o problema de *over-training*, ou seja, a rede se especializa no conjunto de dados do treinamento e perde a capacidade de generalização. O treinamento deve ser interrompido quando a rede apresentar uma boa capacidade de generalização e quando a taxa de erro for suficientemente pequena, ou seja, menor que um erro admissível. Assim, deve-se encontrar um ponto ótimo de parada com erro mínimo e capacidade de generalização máxima.

Teste: o conjunto de teste é utilizado para determinar a performance da rede com dados que não foram previamente utilizados. A performance da rede, medida nesta fase, é uma boa indicação de sua performance real. Devem ser considerados ainda outros testes como análise do comportamento da rede utilizando entradas especiais e análise dos pesos atuais da rede, pois se existirem valores muito pequenos, as conexões associadas podem ser consideradas insignificantes e assim serem eliminadas (*prunning*). De modo inverso, valores substantivamente maiores que os outros poderiam indicar que houve *overtraining* da rede.

Integração: finalmente, com a rede treinada e avaliada, ela pode ser integrada em um sistema do ambiente operacional da aplicação. Para maior eficiência da solução, este sistema deverá conter facilidades de utilização como interface conveniente e facilidades de aquisição de dados por meio de planilhas eletrônicas, interfaces com unidades de processamento de sinais, ou arquivos padronizados.

2.2.6 Aplicações de redes neurais

Devido aos inúmeros atributos inerentes à modelagem por meio de RNAs, estas estão sendo utilizadas por diversos pesquisadores de diferentes disciplinas científicas: neurociência, matemática, estatística, física, ciência da computação, engenharia, entre outras. Mais precisamente, as RNAs têm sido aplicadas em campos como modelagem, análise de séries temporais, reconhecimento de padrões, processamento de sinais e controle, para identificação de impressões

digitais, faces, assinaturas, previsão para o diagnóstico médico, economia, para prever o comportamento humano (MARCHIORI; WARGLIEN, 2008), entre outras tantas áreas, atuando de maneira multidisciplinar.

Redes neurais encontram aplicação significativa em 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.

Na Análise Sensorial, as RNAs 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; 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 RNAs 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 *feedforward*, 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 *backpropagation*, 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 prever 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.

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 RNAs 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.

2.2.7 Redes PNN

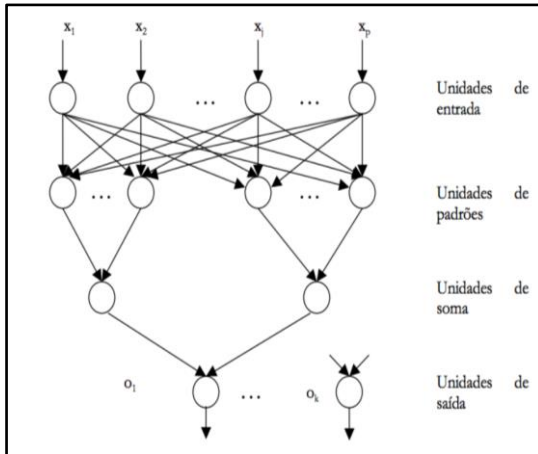
As redes PNN (*Probabilistic Neural Networks*) são uma variação das redes RBF. Estas redes separam os dados em um número específico de categorias de saída e são conhecidas por sua habilidade de treinamento rápido. Esta dissertação tem interesse nas redes PNN, pois, segundo Specht (1990), elas são indicadas para tarefas de classificação porque possuem vantagens em relação aos métodos de retropropagação do erro e, além disso, elas não foram utilizadas para criar sistemas de reconhecimento de padrões de odor em outros trabalhos. As principais vantagens das redes PNN são: treinamento é realizado em apenas um passo e garantia de que a superfície de decisão se aproxima dos limites de uma decisão Bayesiana ótima, à medida em que o número de exemplos de treinamento cresce (SPECHT, 1990). Outra grande motivação para a utilização das redes PNN é o curto tempo necessário para treiná-las, quando comparado com o tempo necessário para treinar redes MLP. A principal desvantagem das redes PNN é que todos os exemplos de treinamento devem ser armazenados e usados para classificar novos padrões. Entretanto, esta desvantagem não é um problema atualmente, pois o custo de memória é baixo e os computadores dispõem de grande capacidade de armazenamento.

As redes PNN implementam a estratégia de decisão Bayseana para classificar os vetores de entrada (SKAPURA, 1996). A Figura 8 mostra a arquitetura básica de uma rede PNN para classificação dos padrões de entrada X em duas classes. As redes PNN são divididas em quatro camadas: camada de unidades de entrada, camada de unidades de padrões, camada de unidades de soma e camada de unidades de saída. Como nas redes MLP, as unidades da camada de entrada não realizam operações sobre os vetores de entrada. As unidades da camada de padrões executam o produto interno do vetor de entrada X pelo vetor de pesos W_i , $Z_i = X \cdot W_i$, e então executam uma operação não linear em Z_i antes de enviar suas saídas para as unidades da camada de soma. A operação não linear utilizada é $\exp[-(Z_i - 1) / \sigma]$. As unidades da camada de soma executam simplesmente a soma de suas entradas. As entradas das unidades da camada de soma têm origem nas correspondentes unidades da camada de padrão de uma determinada classe. As unidades da camada de saída produzem uma saída binária, que é igual a 1 em apenas uma das unidade e igual a 0 nas demais (SPECHT, 1990).

A rede é treinada criando-se uma unidade na camada de padrões para cada um padrões do conjunto de treinamento e fazendo com que o vetor de peso dessas unidades seja igual ao correspondente padrão do conjunto de treinamento. Depois disso, as saídas das unidades da camada de padrão são conectadas com as unidades da camada de soma da classe correspondente.

Em essência, a rede opera pela soma das saídas dos nodos da camada de padrões que, devido à utilização de funções de ativação Gaussianas, agrupam os padrões de entrada em classes. Assim, a rede PNN calcula a função de distribuição da probabilidade a posteriori para uma classe simples, avaliando o ponto definido pelo padrão de entrada. Este ambiente é útil para aplicações de classificação, onde se deseja estimar a probabilidade de um novo padrão ser membro de alguma classe pré-definida.

Figura 8 - Arquitetura típica de uma rede PNN, evidenciando as unidades de entrada, unidades de padrões, unidades de soma e as unidades de saída



Fonte: Ferreira (2004).

2.3 ANÁLISE DOS COMPONENTES PRINCIPAIS (PCA)

A análise dos componentes principais, PCA, é uma técnica matemática de análise multivariada que torna possível investigações com um grande número de dados disponíveis (VICINI, 2005). Segundo Vasconcelos et al. (2010), “um método que tem por finalidade básica a análise dos dados usados visando sua redução, eliminação de sobreposições e a escolha das formas representativas de dados a partir de combinações lineares das variáveis originais”. É também denominada de Transformada Discreta de Karhuen-Loève (KLT). É um método matemático que transforma variáveis discretas em coeficientes descorrelacionados.

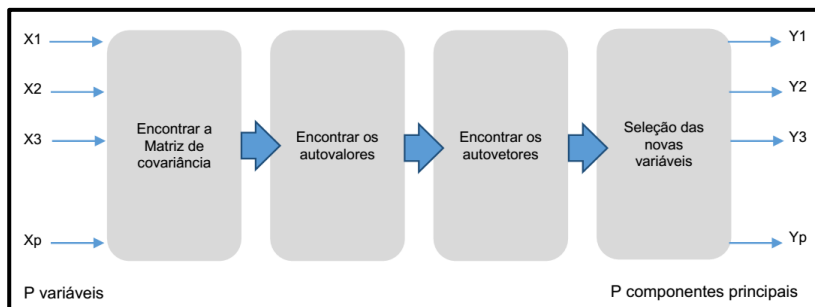
A PCA é um dos métodos estatísticos de múltiplas variáveis mais simples. A PCA é considerada a transformação linear ótima, se analisado o grupo de transformadas de imagens. É bastante utilizada pela comunidade de reconhecimento de padrões (VASCONCELOS et al., 2010).

A ideia principal da análise é reduzir o conjunto de dados a ser analisado, especialmente quando dados são constituídos de um grande número de variáveis inter-relacionadas. Objetiva-se redistribuir a variação nas variáveis (eixos originais) de forma a obter o conjunto ortogonal de eixos não correlacionados. Essa redução é feita transformando-se o conjunto de variáveis originais em um novo conjunto de variáveis que mantém, ao máximo, a variabilidade do

conjunto. Isto é, com a menor perda possível de informação. Além disso, esta técnica nos permite o agrupamento de indivíduos similares mediante exames visuais, em dispersões gráficas no espaço bi ou tridimensional, de fácil interpretação geométrica.

A análise de PCA tem como resultado um novo conjunto de variáveis (componentes principais) relacionados (combinação linear) com cada variável por meio dos fatores de carregamento. Da mesma forma, cada variável original se relaciona com as novas variáveis pelos fatores de carregamento. Em função da possível heterogeneidade das variáveis originais, os dados da amostra podem ser normalizados para facilitar a interpretação dos resultados gerados e extração dos componentes. Isto pode ser feito pela utilização da matriz de correlações entre as variáveis originais. A Figura 9 mostra um esquema em que as variáveis são submetidas a operações matemáticas e, a partir da técnica de PCA, transformadas em componentes principais.

Figura 9 - Esquema da aplicação da análise de componentes principais, evidenciando as etapas envolvidas




Fonte: Vicini (2005).

2.3.1 Componentes principais (PCS)

A componente principal é o arranjo que melhor representa a distribuição dos dados e a componente secundária é perpendicular à componente principal. A Figura 10 representa graficamente um conjunto de pontos (forma elíptica, que sugere a distribuição dos dados), a componente principal, representada pela linha azul e a componente secundária pela linha cinza.

Figura 10 - Componentes principal (CP1) e componente secundária (CP2)



Fonte: Vicini (2005).

Segundo Vansconcelos et al. (2010), os passos para cálculo das componentes principais são:

- Obter os dados ou as M amostras de vetores de dimensão n ;
- Calcular a média ou o vetor médio desses dados;
- Subtrair a média de todos os itens de dados;
- Calcular a matriz de covariância usando todas as subtrações. Ela é o resultado da média do produto de cada subtração por ela mesma e terá dimensão $n \times n$;
- Calcular os autovalores e os autovetores da matriz de covariância.
- Realizar o arranjo da matriz da Transformada de Hotelling, cujas linhas são formadas a partir dos auto vetores da matriz de covariância arranjados de modo que a primeira linha, o elemento $(0,0)$, seja o autovetor correspondente ao maior autovalor, e assim sucessivamente até que a última linha corresponda ao menor autovalor.

O autovetor com o maior autovalor associado corresponde à componente principal do conjunto de dados usado. Isso significa que essa é o relacionamento mais significativo entre as dimensões dos dados.

Para a geração das componentes principais, deve-se ter uma matriz de dimensão $n \times p$, na qual observa-se que X_1, X_2, \dots, X_p representam as variáveis, e cada uma das n unidades experimentais

representam os indivíduos, tratamentos etc. O conjunto de $n \times p$ medida origina uma matriz.

Tabela 1 - Matriz de dados de n indivíduos e p variáveis

INDIVÍDUOS	VARIÁVEIS							
	X_1	X_2	X_3	X_4	...	X_j	...	X_p
1	X_{11}	X_{12}	X_{13}	X_{14}	...	X_{1j}	...	X_{1p}
2	X_{21}	X_{22}	X_{23}	X_{24}	...	X_{2j}	...	X_{2p}
3	X_{31}	X_{32}	X_{33}	X_{34}	...	X_{3j}	...	X_{3p}
.
.
I	X_{i1}	X_{i2}	X_{i3}	X_{i4}	...	X_{ij}	.	X_{ip}
.
.
N	X_{n1}	X_{n2}	X_{n3}	X_{n4}	...	X_{n}	...	X_{np}

Fonte: Regazzi (2001).

O primeiro estágio da ACP é a conversão da matriz $n \times p$ de dados em uma matriz quadrada, onde n é o número de indivíduos e p representa um conjunto de variáveis.

Intuitivamente, percebe-se que, quanto maior for o número de variáveis, e quanto mais estas forem interdependentes entre si (algumas têm variância grande, algumas têm variância média, e outras têm variância pequena, e as correlações entre elas assumem valores muito diferentes entre si), será mais fácil comparar indivíduos baseando-se nos valores dessas variáveis originais (REGAZZI, 2001). Essa interdependência é representada pela matriz de variância covariância.

2.3.2 Matriz de covariância

Em estatística, existem várias análises que podem ser feitas sobre um conjunto de dados, como a média aritmética, o desvio padrão e a variância. Os dois últimos medem o quanto os dados estão afastados em relação à média (a variância é igual ao quadrado do desvio padrão).

Todas essas medidas, porém, consideram separadamente cada tipo de dados. Por sua vez, a covariância sempre é medida entre duas dimensões (calcular a covariância entre uma dimensão e ela mesma resulta na variância). A fórmula da covariância para dados de dimensão 2 (x e y) é:

$$cov(x, y) = \sum_{i=1}^n [(X_i - \bar{X}) \cdot (Y_i - \bar{Y})] \quad \text{Equação 1}$$

Na Equação 1, X e Y são listas de dados, onde X é a primeira e Y é a segunda dimensão. Os elementos \bar{X} e \bar{Y} são as médias das listas. A matriz de variância-covariância é expressa pelas ligações realizadas entre as p variáveis, tomadas duas a duas sendo, resumidas por suas covariâncias.

O conjunto de variância-covariância está representado na matriz S (Equação 2), chamada matriz de variância-covariância das p variáveis. Quando os dados possuem mais de duas dimensões, é necessário ter a covariância entre cada par de dimensões. Neste caso, emprega-se a matriz de covariância. Se forem usadas três dimensões (x , y e z), a matriz adquire a forma:

$$S = \begin{pmatrix} cov(x, x) & cov(x, y) & cov(x, z) \\ cov(y, x) & cov(y, y) & cov(y, z) \\ cov(z, x) & cov(z, y) & cov(z, z) \end{pmatrix} \quad \text{Equação 2}$$

A diagonal principal da matriz contém as variâncias e as demais posições a correlação entre as direções. Essa matriz é simétrica e real, de modo que é sempre possível encontrar um conjunto de autovetores ortonormais (ANTON; RORRES, 2004).

Para M amostras de vetores de um dado conjunto, o vetor médio é calculado a partir da Equação 3:

$$m_x = \frac{1}{M} \sum_{i=1}^M x_i \quad \text{Equação 3}$$

A matriz de variância é calculada subtraindo-se cada x_i de m_x .

2.3.3 Autoespaços, autovetores e autovalores

Um vetor v é um autovetor de uma matriz quadrada M quando essa matriz, multiplicada pelo vetor v , resulta num múltiplo de v , ou seja λv . Dessa forma, λ é chamado de autovalor de M associado ao autovetor v .

Ao se utilizar autovetores, tem-se em mente que a propriedade desejada é a direção do vetor, e então se utiliza um vetor com

comprimento igual a 1. Uma propriedade dos autovetores é que eles são perpendiculares (ortogonais) entre si. Essa propriedade é importante porque torna possível expressar os dados e termos dos autovetores, em vez de em termos dos eixos x , y e z . Para matrizes de dimensões 2×2 ou também 3×3 , os autovalores podem ser calculados usando a equação característica de M (Equação 4):

$$\det(M - \lambda \cdot I) = 0 \quad \text{Equação 4}$$

Onde I é a matriz identidade, M a matriz dada. Os escalares não nulos λ que a solucionam são os autovalores. No caso de uma matriz 2×2 :

$$\det \begin{pmatrix} m_{11} - \lambda & m_{12} \\ m_{21} & m_{22} - \lambda \end{pmatrix} = 0 \quad \text{Equação 5}$$

No caso de dimensões maiores, ou para algoritmos genéricos para qualquer número de dimensões, o usual é aplicar um algoritmo numérico iterativo. O último passo é ordenar os autovetores de acordo com os autovalores de maior valor (principais).

Os autovetores associados aos autovalores são os vetores não-nulos no espaço solução de $(\lambda I - M)v = 0$. Este espaço é chamado de autoespaço de M associado a λ . As bases para cada um destes autovetores são chamadas de bases do autoespaço.

2.3.4 Transformada de Hotelling

Uma vez que a matriz da covariância é real e simétrica, é sempre possível encontrar um conjunto de n autovetores ortonormais (ANTON; RORRES, 2004). Estes autovetores são arranjados de modo decrescentes de acordo com os valores dos n autovalores, e os demais componentes da matriz são nulos.

2.4 ANÁLISE DESCRITIVA QUANTITATIVA (ADQ)

2.4.1 Análise descritiva quantitativa (ADQ)

A análise descritiva quantitativa (ADQ) é um teste que identifica e quantifica, em ordem de ocorrência, as propriedades sensoriais (aparência, aroma, textura e sabor) de um produto (ABNT, 1998).

A NBR 14140 (ABNT, 1998) fixa os conceitos e procedimentos para a aplicação do teste de análise descritiva quantitativa (ADQ) em análise sensorial de alimentos e bebidas. A análise é aplicada no desenvolvimento, modificação e melhoramento de produtos; no controle de qualidade; no estudo da estabilidade de produtos durante o armazenamento; na caracterização das diferenças entre produtos; e na correlação entre medidas sensoriais e instrumentais. O teste é capaz de fornecer um perfil sensorial completo de um produto e permitir a análise estatística dos dados.

2.4.1.1 Requisitos

Sala de teste: para a realização da análise, uma sala de teste é requerida, com uma mesa, ao redor da qual os julgadores discutem as propriedades sensoriais e cabines para que os julgadores possam realizar os testes individualmente e com o mínimo de distração possível. A temperatura do local deve ser agradável ao julgador e livre de odores e ruídos.

Utensílios para apresentação das amostras: devem ser adequados ao tipo de produto e teste. Permite-se o uso de descartáveis.

Preparo e apresentação das amostras: o método de preparo deve ser apropriado ao produto e problema em questão. Deve haver uniformidade entre as amostras para cada julgador, e devem ser codificadas, utilizando-se números aleatórios de 3 dígitos. A codificação deve ser diferente para cada teste.

Julgadores: devem ser utilizados no mínimo oito julgadores treinados.

2.4.1.2 Procedimento do teste

Seleção dos julgadores: em média, são recomendados 25 candidatos, recrutados segundo os requisitos gerais de seleção e treinamento de julgadores e ausência de deficiências fisiológicas relacionadas com as propriedades sensoriais avaliadas, tais como anosmia, ageusia, prótese dentária, entre outros. Os candidatos com habilidade para descrever e discriminar os atributos são selecionados do grupo.

Treinamento: inicialmente, são desenvolvidos os termos descritivos relacionados ao produto individualmente. Posteriormente, sob orientação de um líder, as características sensoriais relevantes do produto são discutidas e identificadas, e os julgadores chegam a um consenso quanto aos descritores, seus significados e a sequência de avaliação. No decorrer das sessões, os materiais de referência são apresentados para dar noções qualitativas dos atributos avaliados. Para quantificar cada atributo sensorial uma escala não estruturada de 9 cm a 15 cm é utilizada. Recomenda-se apresentar as amostras representativas dos extremos de escala para cada atributo sensorial.

Avaliação do desempenho da equipe: de forma independente, cada julgador avalia as amostras teste. Os dados individuais são analisados e discutidos com a equipe, para prestar esclarecimentos com relação aos termos e intensidades percebidas. Nesta fase, por meio de análise estatística ou gráfica, pode-se dispensar os julgadores, cujas avaliações são discordantes dos demais membros da equipe. Recomenda-se que o desempenho de cada julgador seja avaliado por meio da análise de duas ou mais amostras diferentes do mesmo produto, em quatro repetições, utilizando-se como critério de seleção aqueles julgadores que tenham atingido probabilidade (p) menor ou igual a 0,50 na análise de variância para discriminar as amostras.

Análise dos resultados: os valores para cada atributo são obtidos pela medida da distância da extremidade esquerda da escala (zero) até a marca vertical assinalada pelo julgador. Os dados devem ser submetidos à análise de variância, podendo ser utilizados outros tratamentos estatísticos como técnicas de análise multivariada, de acordo com os objetivos do teste. Diferenças entre tratamentos devem ser analisadas após a avaliação do desempenho dos julgadores, utilizando-se testes de

comparação de médias, tais como Tukey, Duncan e SNK (Student-Newman-Keuls) (ou análise de regressão). Para a construção de uma representação gráfica, deve-se considerar a distância das linhas adiais para cada atributo como sendo o valor médio formado pela equipe.

2.4.2 Utilização de ADQ na literatura

A análise descritiva quantitativa encontra especial uso em pesquisas de avaliação sensorial de produtos, especialmente de novas composições. Iogurtes à base de diferentes proporções de leite caprino e bubalino, por exemplo, foram avaliados utilizando-se a ADQ (BEZERRA et al., 2012). Os autores avaliaram as características sensoriais e, associando os dados obtidos com testes de aceitação por escala hedônica, determinaram quais composições eram as mais apreciadas segundo o teste de aceitação.

Em outro estudo, a ADQ foi aplicada em mel de abelhas (MANTILLA et al., 2013). Os autores afirmam que o conhecimento das propriedades sensoriais do mel “é de grande valia para o controle de qualidade do mel produzido em determinada região e seus atributos devem ser descritos e quantificados para garantir a produção de méis com o mesmo padrão de qualidade”.

A ADQ foi utilizada, também, para avaliar o frescor de peixes (YAMAMOTO, 2011). No estudo, atributos relacionados ao à avaliação global de frescor foram escolhidos e submetidos à análise descritiva quantitativa.

2.5 APLICAÇÕES DE NARIZES ELETRÔNICOS

Os narizes eletrônicos possuem uma ampla aplicação em diferentes áreas, desde a alimentícia até a de diagnósticos médicos. Para cada aplicação, pode-se desenvolver uma técnica específica e sensores melhor adaptados para cada caso. Resumidamente, os narizes eletrônicos podem ser aplicados em:

- Detecção de vazamento de gases em indústrias: principalmente se esses gases forem tóxicos e nocivos à saúde humana. Os narizes eletrônicos são utilizados em controles ambientais, para a determinação da qualidade do ar ou da água. As aplicações ambientais dos narizes eletrônicos incluem a análise de misturas de combustíveis,

detecção de vazamentos de óleo, verificação da contaminação da água subterrânea pelos odores, e identificação de odores residenciais. Outras aplicações do nariz eletrônico incluem a identificação de resíduos tóxicos, monitoramento da qualidade do ar e dos fatores de emissões industriais (KELLER et al., 1995; OUELLETTE, 1999).

- Diagnósticos médicos: devido ao fato de que o olfato é um sentido importante à prática da medicina, os narizes eletrônicos têm sido usados para determinar os níveis de glicose em diabetes e para detectar condições patológicas, tais como a tuberculose. O nariz eletrônico poderia ser também ser aplicado como uma ferramenta de auxílio ao diagnóstico, como é o caso da análise de odores corporais (exalados pela respiração, feridas, líquidos, e assim por diante), identificando possíveis problemas. Os odores exalados na respiração podem ser indicativos de patologias, como diabetes, problemas gastrointestinais e do fígado. Além disso, as feridas e os tecidos infectados emitem odores bem distintos que podem ser detectados por um nariz eletrônico. É um exemplo dessa aplicação médica dos narizes eletrônicos a detecção de câncer de pulmão pela análise de compostos químicos expirados pelo paciente.
- Sistemas de segurança: o nariz eletrônico pode servir como a parte sensorial de um sistema inteligente de segurança, conectado a um computador central. Toda a mudança na atmosfera implica numa sequência de atividades. Se o sinal sugerir um fogo, haverá uma notificação imediata. Dependendo das respostas, o sistema pode escolher dentre uma escala de ações - notificar os responsáveis para que liguem ventiladores ou que se mude o sentido do fluxo de ar, colocar em operação medidas ou equipamentos de controle, entre outros. Como um dispositivo de segurança, o nariz eletrônico, com algumas modificações, pode ser usado verificar para ver se há acúmulos de gases em ambientes ou equipamentos. Entre outros exemplos, os trabalhadores em obras de saneamento poderiam ser

advertidos da existência de algum gás venenoso (SOHN, 2006).

- **Indústrias alimentícias:** as aplicações dos narizes eletrônicos na indústria alimentícia incluem a avaliação da qualidade da produção de alimentos, controle do cozimento de alimentos, inspeção do frescor dos pescados, monitoramento do processo de fermentação, verificação da qualidade da maionese, queijos e sucos, monitorando o alimento e a inspeção dos recipientes das bebidas.

A sessão seguinte descreve aplicações da tecnologia para a área de alimentos e bebidas.

2.5.1 Aplicação de narizes eletrônicos em análise de alimentos e cervejas

A principal aplicação de narizes eletrônicos está no controle de alimentos (PERIS, 2009). Cinco categorias, em especial, utilizam essa tecnologia, a saber: monitoramento do processo, investigação da vida de prateleira, avaliação do frescor, aviação da autenticidade e outros estudos sobre o controle de qualidade.

A cerveja é uma mistura de centenas de componentes responsáveis pelo seu sabor e aroma característico. A análise desses componentes individuais é muito complicada devido à necessidade do uso de métodos analíticos sofisticados.

O nariz humano é uma importante ferramenta para discriminar os odores exalados por alimentos, bebidas, perfumes etc. Entretanto, após um tempo de exposição ocorre perda de sensibilidade, bem como as respostas são subjetivas. Assim, a substituição do nariz humano por um conjunto de sensores de gás acoplados a um sistema de reconhecimento de padrões é uma saída interessante para que se padronizem vários tipos de análise sensorial e para que estas análises sejam rápidas e seguras.

Antes do advento dos narizes eletrônicos, a única análise possível instrumental de aromas (misturas de compostos voláteis presentes no *headspace* dos produtos) era a identificação/quantificação de compostos químicos individuais, após uma etapa de separação (por exemplo, GC-MS, GC- FID etc.). No entanto, a relação entre essa análise sequencial e a percepção do aroma global de um produto não é facilmente estabelecida, uma vez que as regras que regem a combinação de

compostos químicos individuais na geração de odores ainda não são totalmente compreendidas (GOSTELOW et al., 2001).

Em estudos recentes, Gruber et al. (2010) foram capazes de construir um nariz eletrônico simples de quatro sensores baixo custo, fácil de construir, portátil, de baixo consumo de energia e de resposta rápida (aproximadamente 30 segundos por análise) para diferentes tipos de cerveja. O nariz eletrônico polimérico desenvolvido mostrou-se eficiente na identificação e classificação de sete marcas diferentes de cerveja de vários tipos, como *lager*, *pilsen* e sem álcool.

Estudos empregaram Redes Neurais Probabilísticas (PNN) para a discriminação alcoólica da cerveja em termos de marcas e condições de armazenamento (TAO; LEI; TENG, 2008). Eles usaram um nariz eletrônico constituído de MOS. O método que eles usaram para amostragem foi o *headspace* dinâmico e um conjunto de três sensores de gás no sistema do nariz eletrônico foi empregado. Os resultados das experiências foram promissores e a técnica permitiu uma boa classificação e capacidade de generalização. O nariz eletrônico foi capaz separar todas as amostras em uma categoria de forma direta.

Estudos realizados com suco de tomate cereja utilizaram o nariz eletrônico PEN2 para determinar a adulteração de sucos de tomates cereja e exploraram a performance do nariz eletrônico na presença de carbonato de sódio anidro como agente dissecante para detecção em amostras líquidas (HONG et al., 2014). De acordo com seus estudos, o PEN2 detecta diferentes níveis de adulteração nos sucos de tomates cereja e esses níveis podem ser discriminados utilizando análise discriminante canônica. Além disso, as análises qualitativas e quantitativas demonstraram que o nariz eletrônico apresenta melhor performance quando não utiliza-se o agente dessecante. Estudos (CHATTERJEE et al., 2014) demonstraram a eficiência do nariz eletrônico na determinação do tempo de prateleira de batatas fritas com acurácia, chegando a resultados similares aos obtidos pelo ensaio convencional bioquímico.

Autores defendem a aplicação de narizes eletrônicos em indústrias cervejeiras (VARNAMKHASHI, 2011), e sugerem que a linha de sensores desempenha um papel fundamental na automação da produção. Recentemente, a combinação de língua com nariz eletrônico tem sido relatada na literatura (APETREI et al., 2010). Esta tecnologia pode ser aplicada em fábricas de cerveja, com um controle de odor e sabor da cerveja mais eficaz. Em um futuro próximo, quando as

questões básicas dos sensores de gás forem resolvidas, surgirão sensores de gás mais em linha implementadas na indústria cervejeira.

Um estudo recente utilizou narizes eletrônicos combinados com análise de componentes independentes e redes neurais artificiais para classificação de vinhos (AGUILERA et al., 2012). A característica sensorial mais importante no estudo da qualidade da bebida é seu aroma. O aroma de vinho possui uma complexidade química acentuada por ser produzido por variados compostos voláteis. Segundo os autores, a tecnologia de *e-noses* é capaz de analisar o perfil aromático da bebida. Na pesquisa, um painel sensorial foi construído por 30 pessoas com experiência prévia em análise de vinhos e treinadas para reconhecer 45 compostos aromáticos da bebida. Amostras de 26 vinhos foram analisadas. Os avaliadores definiram os aromas incluindo 10 descritores sensoriais (herbáceo, frutado, floral, picante, vegetal, 4 vinil guaiacol ou fenólico, microbiológico, químico, oxidação e amadeirado) e 5 parâmetros de qualidade (qualidade do vinho, intensidade aromática, alteração, persistência e *off-flavors*).

Os autores usaram um *e-nose* constituídos de sensores de gás, com arranjo de 16 filmes delgados de óxido de estanho sobre alumina e as amostras foram preparadas por meio do método de purga e *trapeheadspace* estático. Para o tratamento estatístico, o programa Matlab foi usado para empregar o método de análise de componentes independentes (ICA). O estudo introduziu o ICA como método alternativo à análise dos componentes principais (PCA). A ICA é uma técnica estatística e computacional para revelar fatores ocultos que estão escondidos em conjuntos de variáveis aleatórias ou de medições armazenadas em uma base de dados de amostras extensa. O objetivo do ICA é a decomposição de sinais multivariados em contribuições de componentes estatisticamente independentes, com perda mínima de informação.

O problema da identificação de uma amostra desconhecida, como de um conjunto de compostos odorantes aprendido previamente, foi abordada em tarefas de classificação. Em tarefas de regressão, o objetivo era prever um conjunto de propriedades (por exemplo, a concentração de um analito numa mistura complexa ou o valor de um descritor de painel sensorial) a partir de outras variáveis. Finalmente, em tarefas de agrupamento, o objetivo era aprender a relação estrutural entre os diferentes odores. A etapa final é a seleção de modelos e definição de parâmetros e a estimativa das taxas reais para um modelo treinado por meio de técnicas de validação.

No estudo, foi empregada uma rede neural artificial, um algoritmo de *backpropagation* e redes neurais probabilísticas, formadas por três camadas. Na primeira camada, 16 neurônios correspondentes aos 16 sensores foram usados. Um número variado foi usado na camada escondida e 9 foram empregados na camada de saída, o mesmo número de classes existentes. O estudo comparou os descritores do painel sensorial realizado pelos profissionais e as variáveis do *e-nose* na validação. A Tabela 2 mostra os coeficientes de correlação e o erro médio quadrado entre os descritores e as variáveis do *e-nose*.

Tabela 2 - Coeficientes de correlação e o erro médio quadrado entre os descritores e as variáveis do *e-nose* obtidas pela validação

PAINEL SENSORIAL	COEFICIENTE DE CORRELAÇÃO	ERRO MÉDIO QUADRADO
Alteração	0,919630	0,000560
Intensidade aromática	0,923276	0,001061
Químico	0,922897	0,000431
Floral	0,952748	0,001094
Frutado	0,879096	0,001142
Herbáceo	0,953079	0,000479
Microbiológico	0,882264	0,000499
<i>Off-flavors</i>	0,915963	0,000692
Oxidação	0,932035	0,000552
Persistência	0,940271	0,000701
4 vinyl guaiacol (Fenólico)	0,908509	0,000464
Qualidade	0,931305	0,000852
Picante	0,799893	0,000744
Vegetal	0,959348	0,000489
Amadeirado	0,508733	0,001286

Fonte: Aguilera et al. (2012).

Os resultados obtidos no estudo mostraram bons coeficientes de correção e baixos valores de erro médio quadrado. Os autores apontaram, ainda, que melhores valores poderiam ser obtidos com o treinamento dos modelos. Uma relação muito próxima entre os atributos do painel sensorial da avaliação sensorial e os estimados pelos modelos usando o *backpropagation*, como mostrado na matriz (Tabela 3).

Tabela 3 - Matriz obtida na validação da rede (*backpropagation*) para amostras de vinhos brancos novos

	W1	W2	W3	W4	W5	W6	W7
W1	5	0	0	0	0	0	0
W2	0	5	0	0	0	0	0
W3	0	0	5	0	0	0	0
W4	0	0	0	5	0	1	0
W5	0	0	0	0	4	0	0
W6	0	0	0	0	0	5	0
W7	0	0	0	0	0	0	5

Fonte: Aguilera et al. (2012).

O sucesso na classificação foi de 97% para vinhos brancos novos, 87% para vinhos tintos novos e 84% para vinhos tintos envelhecidos, demonstrando que o *e-nose* foi capaz de classificar as amostras de forma bastante semelhante à classificação por profissionais experientes.


2.6 BIOQUÍMICA DO PROCESSO CERVEJEIRO

2.6.1 Fermentação de açúcares por leveduras

Fermentação é um termo comum usado para designar a degradação anaeróbia da glicose ou de outros nutrientes orgânicos com a finalidade de se obter energia, que é armazenada sob a forma de trifosfato de adenosina - ATP (NELSON; COX, 2014). A fermentação alcoólica decorre da ação de leveduras em açúcares fermentescíveis contidos em solução. Reações de oxidação parcial são utilizadas para o crescimento da levedura e, em condições anaeróbias, ocorre a produção de álcool e CO₂ (LIMA; MARCONDES, 2002 apud PACHECO, 2010).

No metabolismo de sacarose por *Saccharomyces cerevisiae* existem duas vias metabólicas para o catabolismo da substância (BASSO, 2011) resumidas no esquema apresentado na Figura 11.

Figura 11 - Rota metabólica resumida das vias de degradação da sacarose extra e intracelular em *S. cerevisiae*. Legenda: SUC (sacarose), GLC (glicose), FRU (frutose), ETH (etanol), ATP (trifosfato de adenosina). 1. Transportadores Hxtp. 2. Transportadores Agt1p ou Malx1p. 3. H⁺- ATPase de membrana.



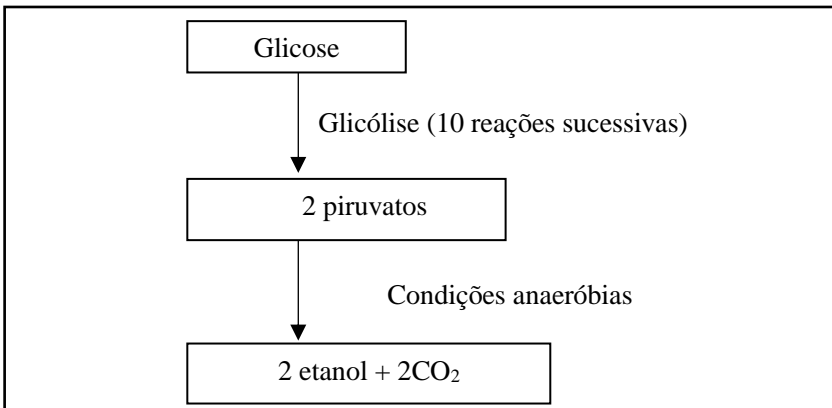
Fonte: Basso (2011).

Na primeira via, conhecida como via extracelular, a sacarose é hidrolisada no ambiente extracelular, especificamente no espaço periplasmático, por meio da enzima invertase codificada por genes SUC, produzindo glicose e frutose. Esses açúcares são então transportados para o interior celular por meio de permeases Hxtp (LAGUNA, 1993 apud BASSO, 2011) e, então, metabolizados na via glicolítica. Leveduras que contenham qualquer um dos genes SUC (SUC1-SUC5 e SUC-7) são capazes de produzir a enzima invertase (CARLSON;

BOTSTEIN, 1983 apud BASSO, 2011). Na segunda via, chamada de via intracelular, a sacarose é primeiramente transportada através da membrana plasmática da levedura e então hidrolisada no interior celular por invertases ou maltases. A sacarose pode ser transportada por meio de co-transporte de íons H^+ usando transportadores Malx1p e Agt1p.

A via bioquímica que leva à fermentação da glicose a etanol em microrganismos como leveduras está mostrada na Figura 12.

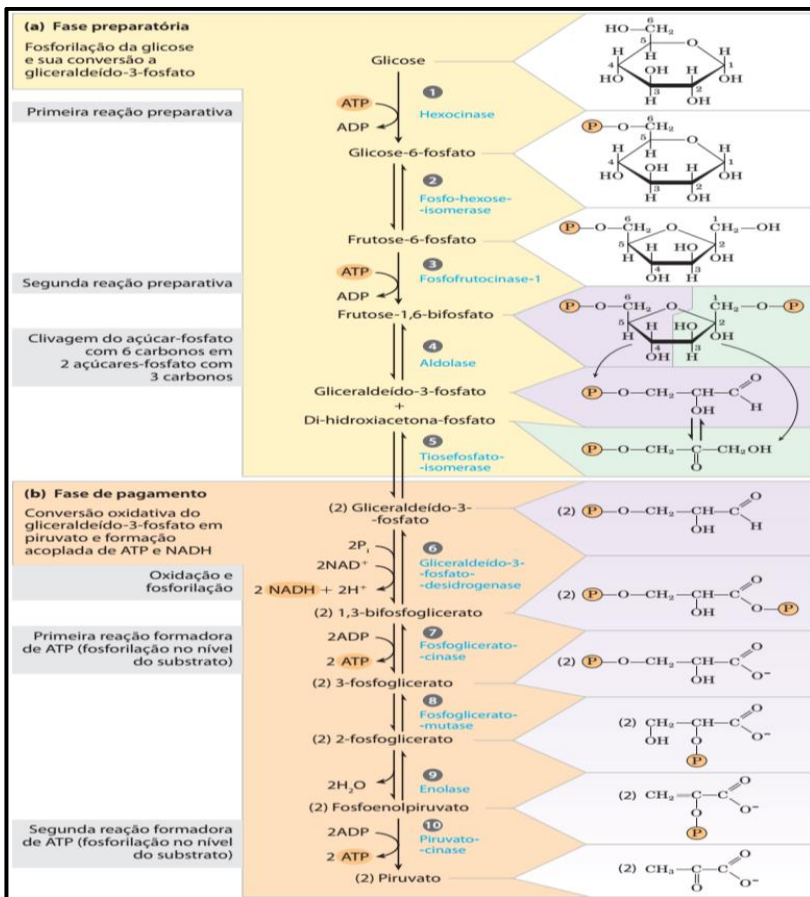
Figura 12 - Destino catabólico da glicose durante a fermentação alcoólica por levedura, gerando etanol e CO_2



Fonte: elaborado pela autora

A primeira fase da utilização da glicose por organismos fermentadores é a glicólise (Figura 13). A molécula de glicose é degradada em uma série de reações catalisadas por enzimas, gerando duas moléculas de piruvato como produto. A quebra ocorre em dez etapas, sendo que as cinco primeiras constituem a fase preparatória (Figura 13-a). A glicose é inicialmente fosforilada no grupo hidroxil ligado ao C-6 (etapa 1). A D-glicose -6-fosfato formada é transformada em D-frutose-6-fosfato (etapa 2), e novamente fosforilada, agora em C-1, para formar D-frutose-1,6-bifosfato (etapa 3). Esse composto é dividido em duas moléculas de três carbonos, a di-hidroxiacetona-fosfato e o gliceraldeído-3-fosfato (etapa 4), no que constitui a etapa de lise, que dá nome à glicólise. A di-hidroxiacetona-fosfato é isomerizada a uma segunda molécula de gliceraldeído-3-fosfato (etapa 5), finalizando a primeira fase da glicólise. Duas moléculas de ATP são utilizadas nessa fase.

Figura 13 - Representação Etapas da via metabólica da glicose proveniente de açúcares como sacarose, maltose, entre outros, até a obtenção do piruvato, evidenciando metabólitos e enzimas envolvidas. (a) Fase preparatória e (b) fase de pagamento.



Fonte: Michael e Cox (2014).

A segunda fase da glicólise é denominada pagamento (Figura 13-b) e constitui um ganho energético para o microrganismo fermentador. Cada molécula de gliceraldeído-3-fosfato é oxidada e fosforilada por fosfato inorgânico para formar 1,3-bisfosfoglicerato (etapa 6). As duas moléculas de 1,3-bisfosfoglicerato são então convertidas em duas moléculas de piruvato. A fase de pagamento gera 4 moléculas de ATP

para cada molécula de glicose. A reação total de glicólise possui rendimento energético líquido de duas moléculas de ATP e duas de NADH por molécula de glicose.

O piruvato é convertido, em hipóxia ou condições anaeróbias, em etanol e CO₂. O objetivo principal da levedura, ao metabolizar o açúcar em meio anaeróbio, é gerar ATP, que será utilizado em diversas funções fisiológicas (absorção, excreção e outras) e biossínteses necessárias à manutenção da vida, crescimento e multiplicação. O etanol e CO₂ gerados são produtos de excreção da levedura (PACHECO, 2011 apud LIMA, BASSO; AMORIM, 2001).

2.6.2 Produção de aromas

A fermentação é um dos processos mais importantes para o sabor e o aroma na cerveja (KUCK, 2008). Além da produção de etanol, outros compostos são produzidos durante a fermentação, sendo denominados produtos secundários do processo. São subprodutos que as leveduras produzem por meio de síntese de compostos necessários para o seu metabolismo, e terão impacto no sabor e aroma da cerveja. Concentração e composição do mosto, temperatura e duração da fermentação são variáveis que influenciam os padrões de crescimento celular e, assim, o teor desses compostos. Dentre esses compostos, são resumidamente descritos, a seguir, os ácidos orgânicos, álcoois alifáticos superiores, ésteres e aldeídos.

Ácidos orgânicos

A síntese de ácidos orgânicos tem relação com a assimilação de compostos nitrogenados pelas leveduras, especialmente pelo consumo de aminoácidos (ARAUJO; SILVA; MINIM, 2003 apud KUCK, 2008). A Tabela 4 lista os principais ácidos orgânicos formados durante a fermentação.

Ácido acético, ácido fórmico e sais de ácidos, como malato, D-lactato, L-lactato e citrato são os mais comuns. Além desses, são formados o ácido succínico, piroglutâmico e málico. São compostos que conferem à cerveja aroma frutado, amanteigado ou de queijo, além de reduzir o pH da bebida (KUCK, 2008).

Tabela 4 - Principais compostos orgânicos formados durante a fermentação por leveduras, incluindo ácidos orgânicos, álcoois alifáticos superiores, ésteres e aldeídos e suas concentrações típicas na cerveja

	COMPOSTO	CONCENTRAÇÃO
Ácidos ou sais orgânicos	Ácido acético	20-150 mg/L
	Ácido fórmico	20-40 mg/L
	malato	60-100 mg/L
	D-lactato	10-100 mg/L
	L-lactato	40-80 mg/L
	Citrato	110-200 mg/L
Álcoois superiores	n-propanol	2-10 mg/L
	n-butanol	0,4-0,6 mg/L
	Isobutanol	5-10 mg/L
	Álcool amflico	10-15 mg/L
	Álcool isoamflico	30-50 mg/L
	Álcool feniletílico	10-20 mg/L

Fonte: Reinold (1997 apud KUCK, 2008).

Álcoois alifáticos superiores

São subprodutos do metabolismo de levedura, formados durante a fermentação por vias anabólicas e catabólicas, sendo sua produção associada à assimilação de nitrogênio pela levedura e ao consumo ou síntese de aminoácidos. Formam-se por meio da desaminação ou descarboxilação dos aminoácidos. Em torno de 85% desses álcoois superiores são formados a partir dos aminoácidos L-leucina, L-isoleucina e L-valina (CARVALHO, 2005; REINOLD, 1997; VARNAN; SUTHERLAND, 1997 apud KUCK, 2008). A Tabela 4 lista os principais álcoois superiores formados durante a fermentação e suas concentrações típicas na cerveja. Esses compostos conferem à cerveja aroma alcoólico ou de solvente, e o álcool feniletílico, que está presente em quantidades consideráveis pode conferir aroma de fragrância à cerveja (CARVALHO, 2005 apud KUCK, 2008).

Ésteres

Os ésteres são formados pela união de ácidos orgânicos a álcoois, formando um composto volátil que são de grande importância para o

aroma da cerveja. A concentração de ésteres na cerveja é de 20 a 25 mg/L (REINOLD, 1997 apud KUCK, 2008). Alguns fatores como basicidade do mosto, aeração, tipo de levedura, temperatura de fermentação e quantidade de nitrogênio no mosto influenciam a formação de ésteres. Por exemplo, quanto mais básico o mosto, ou quanto maior a temperatura, ou ainda quanto mais nitrogênio no mosto, maior a síntese de ésteres (BRODERICK et al., 1977; REINOLD, 1997 apud KUCK, 2008), e quanto menor a aeração, maior é a formação de ésteres.

Os ésteres conferem à cerveja aromas frutado e floral à cerveja. Ésteres etílicos de ácidos graxos e acetatos são considerados os mais importantes e, dentre esses, cabe citar o acetato de etila, acetato de isoamila, acetato de isobutila, caproato de etila e acetato 2 feniletila (NÓBREGA, 2003; VARNAM; SUTHERLAND, 1997 apud KUCK, 2008).

Aldeídos

Os aldeídos podem ser formados no metabolismo da levedura, pela degradação de aminoácidos durante a cocção do mosto ou como resultado da descarboxilação de ácidos orgânicos (CARVALHO, 2005 apud KUCK, 2008). O aldeído mais importante para a cerveja é o acetaldeído, que pode ser reduzido a etanol ou oxidado a acetato. Os aldeídos possuem aroma de maçã verde e podem proporcionar aromas de vegetal verde, verniz velho, batata frita, repolho e gerar um flavor de amônia (CARVALHO, 2005; CARVALHO; ROSSI; SILVA, 2007 apud KUCK, 2008).

2.7 OFF-FLAVORS EM CERVEJAS

2.7.1 Qualidade sensorial da cerveja

Certos aspectos de qualidade mudam durante a estocagem de produtos alimentícios e bebidas. Os efeitos das mudanças sensoriais em produtos estocados, como a cerveja, principalmente no que diz respeito a aromas, têm sido investigados recentemente (VANDERHAEGEN et al., 2006).

Aparência, sabor e odor são as características que o consumidor avalia cada vez que toma um copo de cerveja. Cor, limpidez e formação de espuma são características de aparência que podem ser fisicamente

medidas, e também avaliadas, por meio de análise sensorial. Já as características de sabor e odor, de forma geral, não podem ser física ou quimicamente medidas, portanto, conta-se somente com a análise sensorial para avaliação desses atributos.

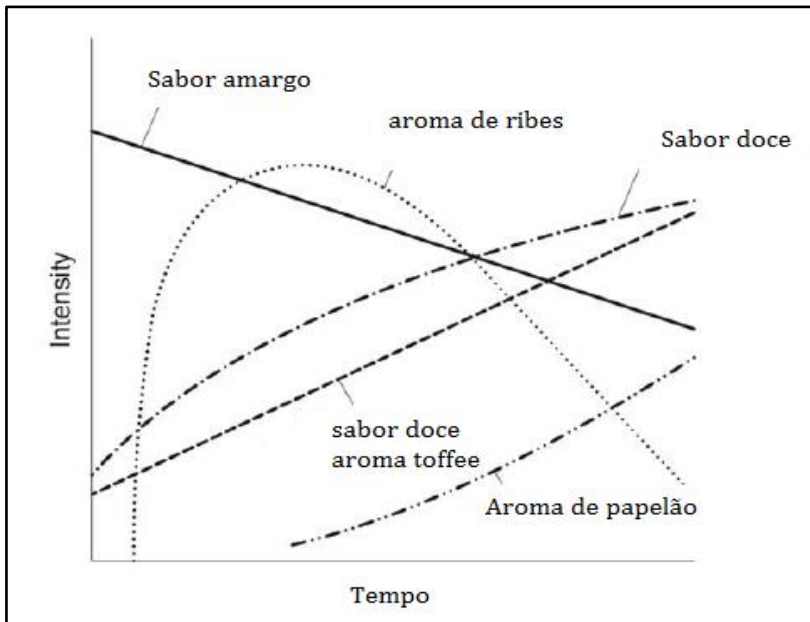
A cerveja é uma das bebidas mais frágeis e instáveis sob o ponto de vista sensorial. Possui sabor e aroma complexos, mas moderados, e apresenta uma estabilidade de sabor pobre, comparado a outras bebidas alcoólicas. Apesar de mais de 1000 componentes de sabor já terem sido identificados na cerveja, a maioria deles está em concentrações abaixo dos seus respectivos valores-limite. Ainda assim, todos esses componentes podem contribuir mais ou menos para o sabor do produto. O sabor da cerveja varia devido a uma ampla variedade de influências que ocorrem em todos os estágios do processo de preparação e durante a estocagem após a embalagem.

A prevenção contra o desenvolvimento dos *off-flavors* é um dos problemas mais sérios na indústria cervejeira, porque a maioria dos consumidores julga o produto principalmente pela qualidade do seu sabor. Existem dois fatores principais que causam os *off-flavors* na cerveja. Um é a oxidação, que pode ocorrer entre a filtração e o ponto de venda da cerveja. Esse tipo de *off-flavor* é geralmente chamado de sabor oxidado ou sabor rançoso/mofado (trans,trans-2,4 heptadienal/2,4,6 tricoanisole). O outro é a contaminação, que pode ocorrer pelo uso de materiais impróprios, aquisição de impurezas e introdução acidental de microrganismos prejudiciais.

O maior problema da qualidade sensorial da cerveja é a formação de *off-flavors* durante o processamento ou com o envelhecimento após envase (SOVRANO et al., 2006).

A cerveja é considerada uma solução água e etanol com centenas de diferentes compostos dissolvidos, originadas do processamento das matérias-primas. Porém, uma cerveja recém envasada não está em equilíbrio químico e é por isso que durante o tempo de armazenamento reações de transformações continuam ocorrendo, procurando chegar ao estado de menor energia e máxima entropia (VANDERHAEGEN et al., 2006). A Figura 14 evidencia a instabilidade do *flavor* da cerveja ao longo do envelhecimento, onde compostos vão se modificando e formando *off-flavors*. É essa instabilidade que determina a vida de prateleira do produto.

Figura 14 - Representação das mudanças sensoriais da cerveja durante o envelhecimento



Fonte: Dagliesh (1997).

Dagliesh (1977) apresentou um diagrama que mostra as mudanças sensoriais no sabor da cerveja devido ao envelhecimento (Figura 14). Há uma diminuição constante no amargor sensorial e um aumento correspondente no dulçor, de modo que o equilíbrio dulçor/amargor tenha uma inclinação para um sabor mais adocicado. Nas cervejas lager, além do amargor diminuir no armazenamento, a qualidade do amargor também muda.

As reações de oxidação parecem ser o principal mecanismo de deterioração da cerveja. Além do tempo, a temperatura também acelera as reações de oxidação, envelhecendo a bebida mais rapidamente. Para manter a estabilidade dos *flavors* da cerveja por mais tempo, as cervejarias devem selecionar matérias-primas de qualidade, processá-las adequadamente e armazenar o produto final em temperatura baixa (OETTERER et al., 2006).

O aumento do dulçor coincide com o desenvolvimento de aroma e sabor de *toffee*, açúcar queimado e caramelo. Dependendo do tipo de cerveja em que a mudança de sabor ocorrer, um aroma queimado ou de casca de pão pode se desenvolver de maneira similar. O desenvolvimento destas notas de queimado ou de *toffee* é mais

rapidamente discernível em cervejas claras. Por outro lado, essas características compõem o sabor natural de cervejas mais escuras. Geralmente, as cervejas tendem a perder os sabores agudos, pungentes e levemente adstringentes e desenvolver um sabor mais adocicado, enjoativo, excessivamente doce ou até de melado.

Enquanto o dulçor e o aroma de *toffee* se desenvolvem paralelamente, uma aceleração inicial ocorre na taxa de desenvolvimento do aroma doce correspondente, por exemplo, ao desenvolvimento adiantado do aroma de *ribes* em cervejas muito carbonatadas. As notas de *ribes* se desenvolvem na cerveja como resultado da deterioração oxidativa e podem ser evitadas ou drasticamente reduzidas ao restringir o contato excessivo da cerveja com o ar durante as operações finais da produção e de envasamento.

2.7.2 Tipos comuns de *off-flavor*

- Exposição à luz solar: a exposição à luz solar leva a formação de odor sulfuroso ou de gambá na cerveja. A luz ultravioleta (de comprimento de onda entre 350nm-500nm) quebra a cadeia lateral dos α -ácidos (derivados de compostos amargos do lúpulo), na posição C4 e produzem 3-metil-2-butenol. Este radical reage rapidamente com o tiol derivado dos aminoácidos sulfurosos na cerveja e produzem o metanotiol (mercaptano), 3-metil-2-butenol-1-tiol (prenilmercaptano), que pode ser detectável a valores de 0,1 ppb. A formação do *off-flavor* pode ser minimizada pela proteção contra a luz do sol, usando embalagens apropriadas (garrafas âmbar escuras e latas) (GUNST et al., 1978).
- DMS: o dimetilsulfureto (DMS) causa aroma e sabor de vegetais cozidos, notadamente o milho, aipo, repolho ou nabo. Em casos extremos o DMS pode também lembrar mariscos ou a água de cozimento de camarões. O DMS é normalmente produzido pela conversão de S-metilmetionina (SMM) induzida por calor, sendo que grande parte evapora durante uma fervura longa, vigorosa e aberta. Uma fervura curta, pouco intensa ou fechada, ou ainda o resfriamento demorado do mosto podem favorecer níveis anormais e elevados de DMS. O DMS é um dos que mais contribui para o sabor característico da cerveja lager. O limiar para detecção como

off-flavor de DMS é de cerca de 20 ppb. DMS é normalmente encontrado abaixo do limiar para detecção como *off-flavor* na cerveja. Em cervejas lager, por outro lado, a concentração de DMS é geralmente na gama de 20-100 ppb.

- O DMS deriva de um precursor de termolábil no malte, a s-metilmetionina, formadas durante a germinação da cevada (WHITE et al., 1977). O DMS ocorre durante a secagem do malte e na ebulição do mosto, mas uma grande quantidade é por evaporação, ou por oxidação a dimetilsulfóxido (DMSO). A decomposição de s-metilmetionina continua depois ebulição do mosto e DMS adicional surge do DMSO pela ação metabólica de leveduras (ANNESS, 1982).
- 4 vinil guaiacol (Fenólico): este é um aroma e sabor comumente comparado com o *band-aid*, armário de remédios ou desinfetante. Os clorofenóis são membros particularmente ofensivos desta família e possuem sabores associados a água sanitária, adicionalmente aos já enumerados. Níveis elevados de fenóis são geralmente produzidos por bactérias ou leveduras selvagens, indicando um problema de sanitização em ambos os casos. Fenóis também podem ser extraídos da casca dos grãos devido à moagem excessiva, à lavagem em demasia ou à lavagem com água muito quente ou alcalina. Resíduos de sanitizantes ou água com cloro também são possíveis fontes de clorofenóis. A cevada contém níveis relativamente altos de vários compostos fenólicos ácidos, incluindo o ácido hidrobenzóico e o hidrocínâmico, que podem ser transformados em fenóis por reações induzidas por aquecimento (McMURROUGH et al., 1984).
- Caprílico: ácidos graxos de cadeia linear (C₆-, C₈-, C₁₀-, C₁₂-) são produzidos pelo metabolismo de fungos durante a fermentação e acumulados na cerveja. Esses ácidos graxos possuem características de mofo, picante, gorduroso e odor rançoso que são descritos como aroma caprílico (CLAPPERTON, 1978). A intensidade do sabor está fortemente correlacionada com as concentrações dos ácidos octanóico e decanóico na cerveja (CLAPPERTON, 1978). Os valores-limite são 4,5-15 ppm de ácido octanóico e 1,5 - 10

ppm de ácido decanóico. Algumas cervejas contêm estes ácidos em níveis mais elevados do que as suas concentrações limite. Além disso, os efeitos destes ácidos sobre o aroma caprílico são aditivos. Embora a formação destes ácidos seja pouco influenciada pela composição do mosto, ela depende principalmente da natureza de levedura usada para a fermentação (CLARKE, 1981). Leveduras de baixa fermentação tendem a produzir significativamente níveis mais elevados destes ácidos graxos se comparadas a leveduras de alta fermentação (ARKIMA, 1969).

- Diacetil: O diacetil (DA, 2,3-butanodiona) e a 2,3-pentanodiona são compostos que conferem aroma de manteiga e podem chegar a ser um *off-flavor* em determinadas concentrações. Ocorre naturalmente em produtos derivados do leite, no óleo de louro e aparece durante a fermentação de produtos como cerveja e vinho. O *flavor* é também descrito como amanteigado, caramelo e *toffee* e pode ser frequentemente detectado em cervejas imaturos. O nível limite para 2,3 butanodiona (diacetil) é de 0,1 ppm na cerveja de baixa fermentação e muito maior em cervejas de alta fermentação, nas quais 0,5 ppm pode ser aceitável. A 2,3-pentanodiona possui um limite 10 vezes maior que o DA.
- Cheiro de gato (*p*-mentano-8 tiol-3-ona): este tipo de *off-flavor* se desenvolve rapidamente em algumas cervejas quando embaladas com alto conteúdo de ar. O *off-flavor* frequentemente alcança o pico após 4-8 semanas e, a partir de então, torna-se gradativamente menos notável (DALGLIESH, 1977). Estudos reportaram que a 4-metil-4-mercapto-pentan-2-ona é formada pela adição de sulfeto de hidrogênio à sua α,β -cetona insaturada. Esta mercaptocetona foi apontada como responsável pelo cheiro de gato (TRESSL, 1980). Presume-se que o decréscimo do *off-flavor* após várias semanas inicia a oxidação do grupo tiol para uma função menos ativa, como o dissulfeto (MEILGAARD, 1986).

Compostos presentes na cerveja podem funcionar tanto como aromas agradáveis e, portanto, desejáveis, quanto, quando em concentrações muito altas, *off-flavors*. Assim, o *threshold* aproximado

oferece uma boa estimativa de quando a presença de determinado composto passa a ser prejudicial. A Tabela 4 apresenta um resumo dos principais aromas e *off-flavors* presentes em cervejas, suas concentrações típicas e *threshold* aproximado.

3 MATERIAL E MÉTODOS

3.1 MATERIAL

Todos os reagentes analíticos utilizados no presente estudo foram de grau analítico. Os componentes de aromas foram fornecidos pela empresa Inglesa *Aroxa*®. As cervejas utilizadas no trabalho são do tipo pilsen.

3.1.1 Sensores utilizados

Os sensores utilizados nesse trabalho são do tipo *Mos* da marca *Figaro*, listados a seguir na Tabela 5.

Tabela 5 - Tipos de sensores que detectam os principais componentes que comprometem a qualidade da cerveja com base nos dados do fabricante *Figaro*

SENSORES	SENSIBILIDADE DESCRITA PELA <i>FIGARO</i>
TGS2180	Vapores de água
TGS2600	Contaminantes de ar
TGS2602	Contaminantes de ar e gases de odores
TGS2612	Metano e gases LP
TGS2620	Álcool e solventes
TGS6812	Hidrogênio e compostos de enxofre
LM35DZ	Sensor de temperatura

Fonte: elaborado pela autora com base nos dados do fabricante de sensores *Figaro*.

3.1.2 Placa de aquisição de dados *Arduino*

A placa de aquisição de dados é *Arduino* do modelo *Duemillanove*. O modelo conta com seis entradas analógicas, o que significa que ele pode facilmente ler seis sensores. Além das 6 portas analógicas já citadas, o aparelho tem 14 portas digitais (que podem ser usadas para entrada ou saída de dados). A alimentação é feita pela própria porta USB do computador (pode-se usá-lo sem conectar a um computador, necessitando-se, então, de uma fonte auxiliar).

3.1.3 Protoboard

Protoboard é a placa com um circuito básico pré-montado com um exterior plástico. Seu uso facilita a prototipagem, que é feita com a inserção dos componentes no protoboard. No protótipo realizado no escopo dessa tese de doutorado, protoboard é a placa branca com fios, leds, resistores e o sensor de temperatura conectados, fazendo a ligação entre os componentes para montar o circuito.


3.2 MÉTODOS

3.2.1 Características e funcionamento dos sensores empregados

Sensor DFRobot DHT11

O sensor DFRobot DHT11 (Figura 15) é um sensor de temperatura e umidade com uma saída de sinal digital calibrada que usa uma técnica de aquisição de sinal digital e tecnologia de sensor de umidade. O sensor inclui um componente resistente à umidade e um componente de medida de temperatura NTC, e é conectado a um micro controlador de alta performance 8-bits de alta resposta, habilidade anti-interferência e baixo custo.

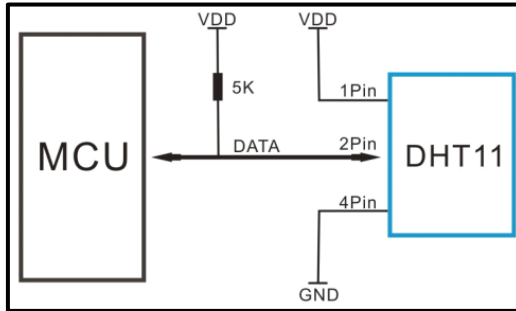
Figura 15 - Sensor DFRobot DHT11



Fonte: D-Robotics UK.


A partir de um sinal do microcomputador (MCU) (Figura 16), o DHT11 sai de seu estado de baixo consumo de energia e entra em seu estado de “*running mode*”. O sensor então envia um sinal de resposta de 40-bits que inclui informações de umidade relativa e temperatura para o MCU. Assim que os dados são coletados, o DHT11 muda novamente para o modo de baixo consumo de energia (Figura 17).

Figura 16 - Aplicação típica do sensor DHT11. 3Pin - null, MCU = unidade de microcomputador ou computador chip único.



Fonte: D-Robotics UK.

Figura 17 - Processo de comunicação geral do sensor DHT11




Fonte: Hanwei Eletronics Co.

Sensor MQ-4

O sensor MQ-4 possui alta sensibilidade a CH_4 , gás natural, pequena sensibilidade ao álcool e fumaça. Possui resposta rápida, é estável e possui vida longa. Pode ser usado em detecção de vazamento de gases. A estrutura e configuração do sensor de gás MQ-4 está mostrada na Figura 18 (configuração A ou B). O sensor é composto por um microtubo de cerâmica Al_2O_3 , uma cada sensível de dióxido de estanho (SnO_2), eletrodo de medição e aquecedor fixado em uma camada de plástico e aço inoxidável. O aquecedor fornece as condições de trabalho necessárias para o funcionamento dos componentes sensíveis. O MQ-4 envolto possui 6 pinos, sendo que 4 deles são usados para buscar sinais e outros 2 são usados para fornecer corrente para aquecimento.


Figura 18 - Estrutura e configuração do sensor de gás MQ-04 (configuração A ou B)



Fonte: Hanwei Eletronics Co.

A Figura 19 mostra as características de sensibilidade típicas do MQ-4 para vários gases na temperatura de 20° C, umidade de 65%, concentração de O₂ a 21% e RL=20kΩ.

Figura 19 - características de sensibilidade típicas do MQ-4 para vários gases na temperatura de 20° C, umidade de 65%, concentração de O₂ a 21% e RL=20kΩ. Ro: resistência do sensor a 1000ppm de CH₄ no ar limpo e Rs: resistência do sensor a várias concentrações de gases.




Fonte: Hanwei Eletronics Co.

Sensor de gás MQ-8

O sensor gás MQ-8 possui alta sensibilidade a hidrogênio (H₂), pequena sensibilidade ao álcool, LPG, fumaça de conzimento. É estável e possui vida longa. Também pode ser usado na detecção de vazamentos de gás.

A estrutura e configuração do sensor de gás MQ-4 está mostrada na Figura 20 (configuração A ou B). O sensor é composto por um microtubo de cerâmica Al₂O₃, uma cada sensível de dióxido de estanho (SnO₂), eletrodo de medição e aquecedor fixado em uma camada de plástico e aço inoxidável. O aquecedor fornece as condições de trabalho necessárias para o funcionamento dos componentes sensíveis. O MQ-4 envolto possui 6 pinos, sendo que 4 deles são usados para buscar sinais e outros 2 são usados para fornecer corrente para aquecimento.


Figura 20 - Estrutura e configuração do sensor de gás MQ-04 (configuração A ou B)



Fonte: Hanwei Eletronics Co.

A Figura 21 mostra as características de sensibilidade típicas do MQ-4 para vários gases na temperatura de 20° C, umidade de 65%, concentração de O₂ a 21% e RL=20kΩ.

Figura 21 - Características de sensibilidade típicas do MQ-4 para vários gases na temperatura de 20° C, umidade de 65%, concentração de O₂ a 21% e RL=20kΩ. Ro: resistência do sensor a 1000ppm de H₂ no ar limpo e Rs: resistência do sensor a várias concentrações de gases.



Fonte: Hanwei Eletronics Co.

3.2.2 Análise dos compostos aromáticos via protótipo

Os sensores de gases foram colocados em um circuito que foi desenvolvido para a realização destes experimentos. O sistema foi ligado aos sensores com uma entrada para ar fresco e esperou-se a estabilização deles. Após a estabilização dos sensores, uma amostra (15mL) de cerveja foi injetada por meio de uma seringa hipodérmica na câmara de ensaios. A resposta dos sensores foi convertida para a forma digital e os sinais gravados. Atributos são extraídos das respostas dos sensores. Estes atributos foram usados na entrada de uma rede neural artificial. A rede neural realiza a classificação da amostra de cerveja a partir de um prévio treinamento. Na saída da rede neural artificial tem-se

a classificação dos aromas presentes na cerveja, indicada por meio de algum código. Este código é convertido para uma forma que possa ser apresentado em um mostrador e interpretado por pessoas.

3.2.3 Reconhecimento de padrões e redes neurais artificiais

Para o reconhecimento de padrões de gases, frequentemente são construídos classificadores usando redes neurais artificiais. O sucesso das redes neurais na identificação de aromas decorre do fato de que o aprendizado é feito por padrões, não sendo necessário um modelo para descrever o comportamento dos sensores de gás.

Apesar de não existir uma definição para as redes neurais artificiais que seja aceita universalmente até o momento, reconhece-se que estas são formadas por uma grande quantidade de processadores simples, chamados de neurônios, unidades ou elementos processadores conectados entre si por canais de comunicação conhecidos como 'sinapses'. Pelas sinapses trafegam os dados numéricos, formando canais de comunicação entre as unidades. O aprendizado da rede é armazenado pelas sinapses na forma de intensidade de ligação entre as unidades.

3.2.4 Metodologia de treinamento das redes PNN

As redes PNN foram criadas com as condições apresentadas a seguir. Uma entrada de 6 nodos foi utilizada; os padrões de 37 nodos; camada de soma de 37 nodos; saída de 1 nodo e largura da base igual a duas vezes o desvio padrão.

3.2.5 Limiares de odor para *off flavor*

Os limiares de odor e sabor dos compostos *de off flavor* foram utilizados de acordo com a recomendação do fabricante Aroxa® para cada um dos compostos analisados, com base em cervejas do tipo pilsen (Tabela 6).

Tabela 6 - Limiares de odor e sabor dos compostos *de off flavor* na cerveja tipo pilsen

NOME USUAL	COMPOSTO QUÍMICO	THRESHOLD
Acetaldeído	-	5mg/l
Ácido acético	-	90 mg/l
Amêndoas	benzaldeído	10mg/l
Alcalino	bicarbonato de sódio	60mg/l
2-bromofenol	2-bromophenol	30mg/l
Ácido butírico	-	3mg/l
Caprilico	-	30mg/l
Gato	p-menthano-8 tiol-3-one	60mg/l
Clorofenol	2,6-diclorofenol	55ng/l
cebola/onion	dimetiltrisulfeto	45mg/l
Diacetil	2,3 butanodiona	40 ug/l
DMS	dimetil sulfito	50 ng/l
Terra - Etil fenchol	ethyl fenchol	20mg/l
Acetato de etila	-	10mg/l
Butirato de etila	etil butirato	10mg/l
Hexonoato de etila	-	200 ug/l
Gramma fresca	cis 3 hexenol	180 ug/l
Geraniol	-	120 ug/l
Mel	etil fenilacetato	160 ug/l
Óleo de lúpulo	extrato oleoso de lúpulo	250 ug/l
H ₂ S	Sulfeto de Hidrogênio	4 ug/l
Acetato de isoamila	-	1.1 mg/l
Isovalérico	ácido Isovalérico	1 mg/l
Ácido láctico	-	120 mg/l
<i>Light struck</i>	3-metil-2-butano-1-tiol	30 ng/l
Malte biscuit	2-acetyl pyridine	60 ug/l
Mercaptano	metanotiol	1.5 ng/l
Metálico	sulfato de ferro	2,7 mg/l
Methional	methional	5 ug/l
Mofado	2,4,6 tricoanisole	10 ng/l
Cebola	dimetil trisulfeto	40 ng/l
trans-2-nonenal (Papel)	trans-2-nonenal	250ng/l
Fenólico	4 vinil guaiaicol	300 ug/l
Baunilha	baunilha	35 ug/l
Plástico	Styrene	20 ug/l
Defumado	guaiaicol	33 ug/l
trans,trans-2,4 heptadienal (Ranço)	trans,trans-2,4 heptadienal	55mg/l

Fonte: elaborado pela autora.

3.2.6 Preparo da amostra para leitura no protótipo

As amostras do protótipo passaram pelo processo de decarbonatação para que as leituras de CO₂ não interferissem nas leituras dos demais compostos analisados. Para decarbonatação, as amostras foram filtradas em papel filtro por 2x (Figura 22).

Em seguida, adicionou-se o composto a ser analisado na concentração indicada pelo fabricante, a amostrava foi agitada e distribuída em tubos de ensaio de 15 mL para posterior leitura no protótipo.

Figura 22 - Decarbonatação das cervejas para leitura em protótipo



Fonte: elaborado pela autora.

3.2.7 Análise sensorial - avaliação descritiva quantitativa

Para a aplicação da análise descritiva quantitativa, baseando-se tanto em procedimentos citados por Stone et al. (1974), como também em técnicas cervejeiras internacionais (ASBC, 1996), foi necessário o cumprimento de diversas etapas, entre estas o recrutamento e seleção dos provadores, desenvolvimento de terminologia descritiva, treinamento dos provadores, teste sensorial das amostras.

Para a análise descritiva quantitativa, foi utilizada uma sala sensorial. Essa, composta de dez cabines individuais além de uma cozinha para o serviço, foi mantida, durante a aplicação dos testes, com iluminação padrão e temperatura controlada (25°C), conforme condição exigida de estudo. As amostras foram apresentadas aos provadores em copos escuros, específicos para o teste, codificados com três dígitos de modo casual e contendo aproximadamente 60 mL de amostra em temperatura de (12°C). Água e biscoitos isentos de sal, tipo *cream cracker*, foram servidos aos provadores entre cada amostra para enxágue e renovação do paladar.

Durante as provas de cerveja apresentadas de forma monádica, foi solicitado a cada provador que descrevesse na ficha de avaliação os parâmetros analisados, conforme apresentada na Figura 25.

3.2.8 Armazenamento das amostras

O armazenamento das amostras comerciais (garrafas) anteriormente à sua utilização foi sob refrigeração (4°C), condições similares às de comercialização, enquanto a amostra de cerveja preparada com os compostos segundo condições em estudo foi sob armazenada a uma temperatura de aproximadamente 8°C, mantida em câmara fria.

3.2.9 Teste de gostos básicos (para seleção de avaliadores)

Os provadores foram avaliados pela aplicação de testes de gostos básicos. Para realização desses testes foram preparadas soluções específicas, conforme apresentadas na Tabela 7 seguindo procedimentos da *American Society of Brewing Chemists - ASBC* (1996).

Tabela 7 - Soluções utilizadas na aplicação do teste de gostos básicos

CARACTERÍSTICAS	SUBSTÂNCIA	CONCENTRAÇÃO (G/L)
Doce	Sacarose	20,0
Ácido	Ácido cítrico	0,5
Amargo	Cafeína	1,5
Salgado	Cloreto de sódio	5,0

Metálico	Sulfato ferroso 7H ₂ O	0,01
Adstringente	Ácido tânico	1,0

Fonte: elaborado pela autora.

Aos candidatos foram apresentados 25 mL das respectivas soluções, utilizando-se de copos descartáveis de 60 mL identificados com códigos no formato de três dígitos, em duplicata e de forma aleatória, sendo solicitado o preenchimento da ficha de avaliação. Na avaliação dos testes de gostos básicos foi aplicado o critério de 75% de acertos para a continuidade do candidato na seleção.

3.2.10 Teste triangular

Na sequência, testes triangulares foram aplicados aos candidatos selecionados visando avaliar o poder discriminativo na detecção de atributos enfraquecidos. Para isto, foram utilizadas amostras de cerveja de uma mesma marca comercial, porém com diluição de 20% feita com água mineral natural na amostra diferenciada, valor este estabelecido por testes anteriormente realizados com diferentes provadores. Nesses testes foram considerados selecionados os candidatos que atingiram a região de acerto durante os dias de aplicação dos testes.

3.2.11 Familiarização com estímulos e avaliação do desempenho

Com o objetivo de um melhor levantamento de terminologia descritiva de cerveja em etapa a ser realizada posteriormente, os candidatos até então selecionados participaram de sessões onde foram disponibilizados 39 padrões de odores comumente encontrados na cerveja e 6 amostras de cervejas com características básicas intensificadas, conforme apresentados nas Tabelas 8 e 9, respectivamente. Todos os padrões de odores e de sabores utilizados estão referenciados na Roda de Aromas e Sabores (*The Flavor Wheel*), proposta por MEILGAARD et al. (1979) e na *American Society of Brewing Chemists - ASBC* (1996), conforme apresentado na Figura 23.

Tabela 8 - Definições e referências propostas pela *American Society of Brewing Chemists* para treinamento de provadores em avaliação de cerveja e as correspondentes classes e subclasses conforme apresentado no Círculo de Aromas e Sabores

CLASSE 1	AROMÁTICO, PERFUMADO, FRUTADO E FLORAL
-----------------	---

Subclasses	Definição	Referência
0110	Alcoólico	Vodka

Tabela 8 - (continuação) Definições e referências propostas pela *American Society of Brewing Chemists* para treinamento de provadores em avaliação de cerveja e as correspondentes classes e subclasses conforme apresentado no Círculo de Aromas e Sabores

0111	Condimentado	Eugenol
0123	Acetona	Acetona
0131	Acetato de isoamila	Acetato de isoamila
0133	Acetato de etila	Acetato de etila
0141	Cítrico	Cascas de laranja
0150	Acetaldeído	Acetaldeído
0160	Floral	Rosas
0172	Lúpulo seco	Pellets de lúpulo
0173	Óleo de lúpulo	Óleo de lúpulo

CLASSE 2 RESINOSO, NOZ, ERVA E VERDURA

Subclasses	Referência	Definição
0210	Resinoso	Serragem
0220	Nozes	Castanha do Pará
0224	Amêndoa	Benzaldeído
0231	Erva fresca cortada	Folhas verdes cortadas

CLASSE 3 CEREAL

Subclasses	Definição	Referência
0310	Grãos	Isobutiraldeído
0312	Grits de milho	Particulado de milho
0313	Farinhoso	Farinha de trigo
0320	Malte	Malte de cevada
0330	Mosto	Mosto cervejeiro

CLASSE 4 CAMELIZADO E QUEIMADO

Subclasses	Definição	Referência
0410	Caramelo	Açúcar queimado
0420	Queimado	Cevada tostada

CLASSE 5 FENÓLICO

Subclasses	Referência	Definição
0503	Carbólico	Fenol
0504	2,6-diclorofenol	Clorofórmio

Tabela 8 - (continuação) Definições e referências propostas pela *American Society of Brewing Chemists* para treinamento de provadores em avaliação de cerveja e as correspondentes classes e subclasses conforme apresentado no Círculo de Aromas e Sabores

CLASSE 6		
SABÃO, GORDUROSO, DIACETIL, OLEOSO E RANÇOSO		
Subclasses	Referência	Definição
0611	Caprílico	Ácido caprílico
0613	Isovalérico	Ácido isovalérico
0614	Butírico	Ácido butírico
0620	Diacetil	Diacetil
0641	Óleo vegetal	Óleo vegetal
0642	Óleo mineral	Óleo de máquina
CLASSE 7		
SULFUROSO		
Subclasses	Referência	Definição
0727	Vegetais cozidos	DMSO
0732	DMS	DMS (dimethylsulphite)
0733	Couve cozida	Couve cozida
0734	Milho cozido	Milho em conserva
0735	Tomate cozido	Ketchup de tomate
0740	Levedura	Levedura cervejeira
0741	Carne	Peptona
CLASSE 8		
OXIDADO, CHOCO E MOFADO		
Subclasses	Referência	Definição
0820	Papel	Trans 2 nonenal
0841	Terra	Etil fenchol
CLASSE 10		
DOCE		
Subclasses	Definição	Referência
1003	Baunilha	Baunilha

Fonte: Meilgaard et al. (1979) e ASBC (1996).

Tabela 9 - Definições e referências propostas pela *American Society of Brewing Chemists* (ASBC) para treinamento de provadores em avaliação de cerveja e as correspondentes classes e subclasses conforme apresentado no Círculo de Aromas e Sabores referências utilizadas para intensificação de sabores


CLASSE	SUBCLASSES	DEFINIÇÃO	REFERÊNCIA (CONC. UTILIZADA) *
1	0110	Alcoólico	Vodka (51,0 g/L)
2	0224	Amêndoa	Benzaldeído (0,003 g/L)
8	0800	Choca	Cerveja mantida a 40°C por 7 dias
9	0910	Ácido	Ácido acético (0,27 g/L)
10	1000	Doce	Sacarose (7,8 g/L)
11	1100	Salgado	Cloreto de Sódio (1,8 g/L)

* preparado com cervejas comerciais de garrafas no mínimo 12 h antes da avaliação.

Fonte: Meilgaard et al. (1979) e ASBC (1996).

Desta forma, todos os padrões de odores e/ou sabores especificados nas Tabelas 8 e 9, estes últimos adicionados diretamente no produto, foram submetidos à análise dos provadores, para que houvesse a familiarização com os respectivos estímulos.

Figura 23 - Roda de aromas e sabores, agrupando termos de classes e subclasses recomendados em análise sensorial de cerveja



Fonte: Meilgaard et al. (1979).

Inicialmente, as amostras de referências para odores, identificadas de acordo com a definição ou descritor fornecido por Meilgaard et al. (1979) e ASBC (1996), foram apresentadas aos candidatos em copos escuros, tampados e em sessões consecutivas. Aos candidatos foi solicitado realizarem aspirações normais e memorizarem os estímulos. Em seguida, foi apresentado a cada candidato em cabine individual, sob luz vermelha e temperatura controlada, todas as referências codificadas com números de três dígitos casualizados, dispostos novamente em potes escuros, tampados e em sessões realizadas com 8 amostras em cada. Após cada aspiração, foi solicitado ao candidato identificá-la utilizando a ficha do Teste de Reconhecimento de Odores, bem como neutralizar seu órgão sensitivo na própria pele.

Posteriormente, as amostras de cerveja contendo as devidas referências para sabores, identificadas de acordo com a definição ou descritor fornecido por Meilgaard et al. (1979) e ASBC (1996), foram apresentadas aos candidatos em taças ISO e em cabines individuais sob iluminação vermelha e em sessões consecutivas. Aos candidatos foi solicitado realizarem a degustação e memorizarem os estímulos. Em seguida, foi apresentado a cada candidato todas as referências codificadas com números de três dígitos casualizados, dispostos novamente em taças ISO em sessões realizadas com 3 amostras. Após cada degustação, foi solicitado ao candidato identificá-la utilizando a ficha do Teste de Reconhecimento de Aspectos da Cerveja, bem como neutralizar o sabor residual por consumo de biscoitos e enxágue da boca com água.

3.2.12 Treinamento dos provadores

A etapa de treinamento foi realizada até os provadores demonstrarem não possuir dificuldades em avaliar as amostras, visando a melhorar a padronização do uso de cada atributo ou descritor em termos qualitativos e quantitativos. Durante as sessões de treinamento, os provadores utilizaram-se da ficha de avaliação descritiva, da lista de definições consensuais dos termos descritivos, de amostras referências e das amostras dos produtos a serem avaliados.

3.2.13 Teste sensorial nas amostras

A avaliação descritiva de cada amostra foi realizada por todos os provadores selecionados e treinados conforme descrito anteriormente,

utilizando-se das Fichas de Avaliação Descritiva Quantitativa, conforme Dutcosky (1996). Todos os provadores, durante as avaliações, usaram a lista de definições consensuais dos termos descritivos como ativador da memória sensorial, bem como dos procedimentos de análise anteriormente estabelecidos.


Para evitar a fadiga sensorial, os provadores avaliaram as três diferentes amostras fornecidas em cinco sessões distribuídas ao longo de duas semanas de testes. Para cada amostra houve cinco repetições, sendo a ordem de apresentação balanceada entre os provadores e de forma monádica sucessiva, sob temperatura de consumo de 12°C e demais condições já descritas anteriormente .

3.2.14 Armazenamento e preparo das amostras para ADQ com compostos aromáticos

Para o teste de ADQ com os compostos a serem identificados pelo painel as garrafa das cervejas utilizadas como padrão eram abertas, adicionava-se o composto a ser analisado, a garrafa era lacrada novamente, agitada e mantida sob refrigeração até o momento de sua análise. Todos os compostos foram utilizados na faixa de concentração indicada pelo fabricante *Aroxa®*.

As mostram foram servidas sempre com uma amostra de referência R (*Berliner Pilsener*) e 3 amostras codificadas com 3 dígitos (Figura 24), sendo que cada amostra continha um composto diferente a ser analisado.

Figura 24 - Amostras codificadas em 3 dígitos, servidas sempre com a amostra de referência R



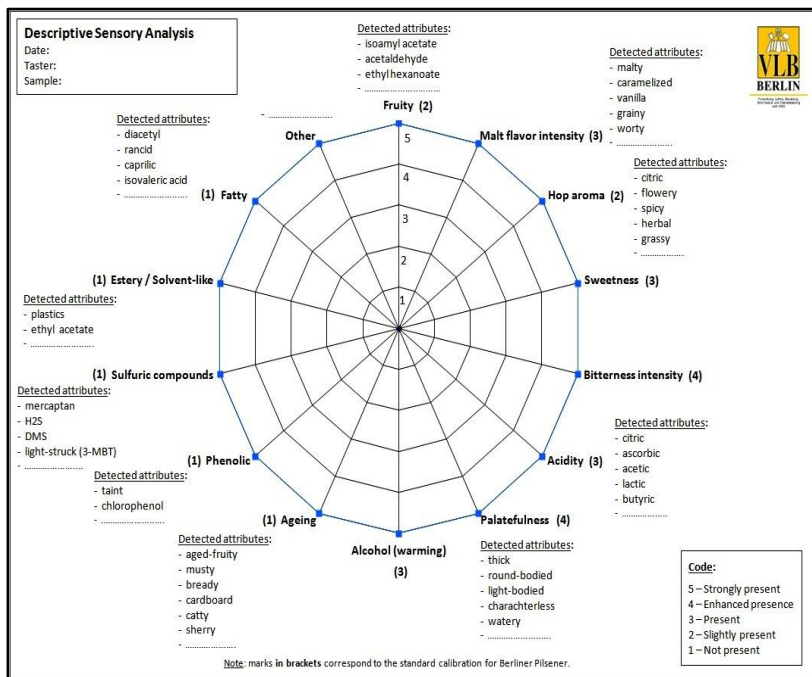
Fonte: elaborado pela autora.

3.2.15 ADQ para grupo não treinado

A análise descritiva quantitativa foi aplicada a um grupo de pessoas sem treino prévio. Foram selecionados alunos do curso Mestre Cervejeiro da Universidade VLB, todos eles com conhecimento prévio de processos cervejeiros e com hábito de analisar cerveja frequentemente.

O modelo da ficha utilizada em ambos os painéis é mostrada na Figura 25.

Figura 25 - Modelo de ficha utilizada para os testes de análise descritiva quantitativa das amostras com compostos aromaticos



Fonte: elaborado pela autora.

3.2.16 Análise físico-química da cerveja *Berliner Pilsner*

A Tabela 10 mostra os resultados analíticos da análise química feita com a cerveja *Berliner Pilsner*.

Tabela 10 - Resultados analíticos da cerveja, com o respectivo método empregado e unidades

RESULTADO	MÉTODO	UNIDADE	AMOSTRA 1
Álcool	MEBAK 2.10.2.3	%v/v	5,03
Densidade	MEBAK 2.10.2.3	g/cm ³	1,00498
Álcool	MEBAK 2.10.2.3	%w/w	3,95
Er (extrato real)	MEBAK 2.10.2.3	%w/w	3,58
Ea (extrato aparente)	MEBAK 2.10.2.3	%w/w	1,75
p (extrato original)	MEBAK 2.10.2.3	%Plato	11,27
RDF (grau real de ferm., <i>real deg. of ferm.</i>)	MEBAK 2.10.2.3	%	69,55
ADF (grau aparente de ferm., <i>apparent deg. of ferm.</i>)	MEBAK 2.10.2.3	%	84,52
Valor de coloração – fotométrico	MEBAK 2.13.2	EBC	5,6
Unidades de amargor	MEBAK 2.18.1	BU	28
Valor de pH	MEBAK 2.14	-	4,36

Fonte: Elaborado pela autora. Métodos analíticos: MEBAK, 2013.

Para formação do painel sensorial e treinamento será utilizada a metodologia Análise Descritiva Quantitativa ADQ e será analisada pelo método de Análise dos Componentes Principais PCA.

Componentes analisados

Foram analisados os principais compostos de aroma e sabor que comprometem a qualidade da cerveja, conforme apresentado na Tabela 11.

Os compostos de *off-flavors* listados na Tabela 11 foram escolhidos pois comprometem a qualidade sensorial de cervejas comerciais.

Tabela 11 - Compostos analisados


1	Ácido acético
2	Diacetil ou 2,3 butanodiona
3	H ₂ S ou sulfeto de hidrogênio
4	Acetato de isoamila
5	Ranço ou trans, trans-2,4 heptadienal
6	182 geosmina
7	Mel ou etil fenilacetato
8	Musty - 2,4,6 trichloroanisole
9	Methional
10	metanotiol (Mercaptano)
11	Malte buscuit
12	Terra molhada ou Ethil fenchol
13	Acetaldeído
14	Ácido láctico
15	Amêndoas ou benzaldeído
16	Acetato de etila
17	Baunilha
18	Caprílico
19	2,6 diclorofenol
20	Geraniol
21	Gramma fresca ou cis 3 hexanol
22	Óleo de lúpulo ou extrato oleoso de lúpulo
23	Papel ou trans-2-nonenal
24	Bicarbonato de sódio (alcalino)
25	Ácido butírico
26	2-bromofenol
27	Dimetiltrisulfeto (Cebola)
28	Dimetil sulfito (DMS)
29	Etilbutirato
30	Hexoato
31	3-metil-2-butano-1-tiol (<i>Light struck</i>)
32	Ácido Isovalérico
33	Sulfato de ferro (Metálico)
34	Styrene (Plástico)
35	Guaiacol (Defumado)
36	4 vinil guaiacol (Fenólico)
37	<i>p</i> -mentano-8 tiol-3-ona (Gato)

Fonte: Elaborado pela autora.

3.2.17 Funcionamento do *Arduino* com o protótipo

Para a utilização da placa *Arduino* (Figura 26), foi necessário conectar a sua interface para codagem e ligá-la ao computador por meio do cabo. Por exemplo, para o sensor de temperatura a mesma pode ser lida ativando-se o serial monitor (botão localizado à direita) do *software* do *Arduino*. Além de monitorar a temperatura pelo serial monitor, o led acenderá sempre que a temperatura passar de 20°C.

Figura 26 - *Software* do *Arduino* (em evidência, o botão para ligar o *serial monitor*)



Fonte: software Arduino.

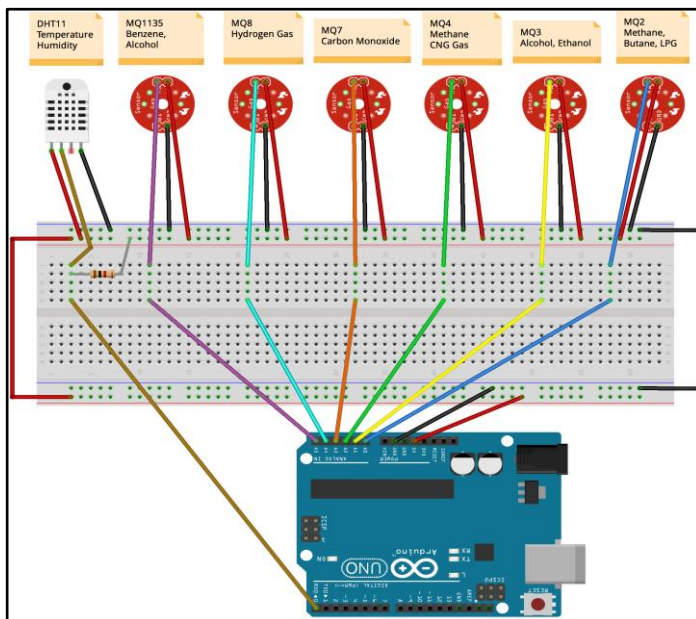
Programação para o microcontrolador *Arduino*

O *Arduino* foi programado na linguagem C++ com algumas modificações para facilitar o acesso ao processador do microcontrolador. As primeiras linhas do código servem para preparar o *Arduino* e a leitura começa a partir de 20°C, após isso, há um tempo de espera de 500 milissegundos e, então, leitura do *Arduino* é reiniciada.

Protótipo


A seguir pode ser visualizado o layout final do protótipo desenvolvido nesse trabalho. Nele existem diferentes sensores a gás e um sensor de temperatura e umidade ligados ao *proto-board*, que está conectado no *Arduino*, todos esses componentes formam o protótipo para leitura de compostos voláteis (Figuras 27-31).

Figura 27 - Visão geral do protótipo, evidenciando os diferentes sensores de gás empregados




Fonte: elaborado pela autora.

Figura 28 - Visão geral do circuito para teste do sensor de temperatura




Fonte: elaborado pela autora.

Figura 29 - O circuito do sensor de temperatura



Legenda: Vermelho: alimentação positiva; Preto: alimentação negativa; Verde: sinal do sensor que indica a temperatura.


Fonte: elaborado pela autora.

Figura 30 - Conexão do circuito do sensor no *Arduino*

Legenda: Vermelho: alimentação positiva - ligado no 5V; Preto: alimentação negativa - ligado no Gnd (*ground/terra*); Verde: sinal do sensor que indica a temperatura - ligado na entrada analógica número 0.

Fonte: elaborado pela autora.


Figura 31 - Conexão do circuito do led no *Arduino*



Legenda: Vermelho: alimentação positiva - ligado na saída digital número 13;
 Preto: alimentação negativa - ligado no Gnd (*ground/terra*).
 Fonte: elaborado pela autora.


Os sensores a gás devidamente com o circuito interligado são mostrados nas Figuras 32 e 33. A tela com leitura instantânea dos sensores é mostrada na Figura 34.

Figura 32 - Sensor a gas com circuito interligado



Legenda: Placa *Arduino* com sensor e circuito com alimentações ligados.
 Fonte: elaborado pela autora.

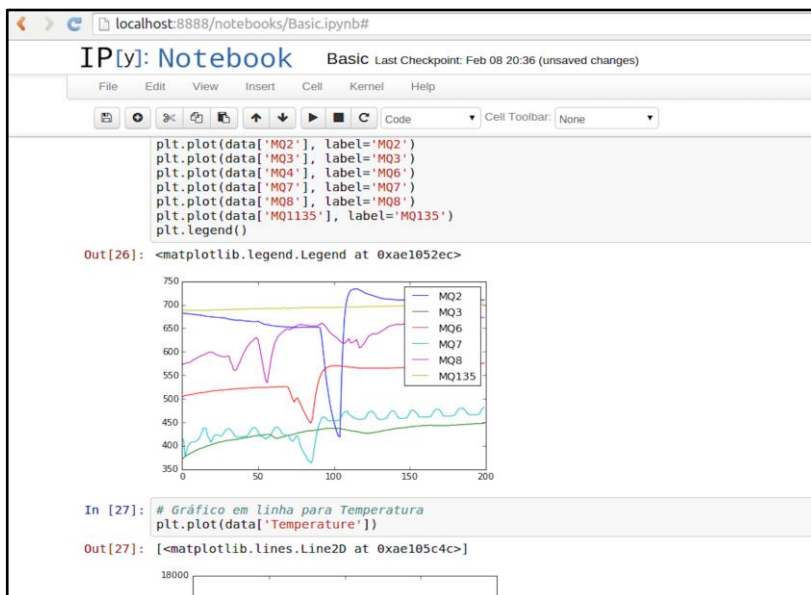
Figura 33 - Representação dos múltiplos sensores de gás para microcontrolador *Arduino*



Legenda: Visão geral do protótipo com sensores em funcionamento

Fonte: elaborado pela autora.

Figura 34 - Tela com leitura instantânea dos sensores




Legenda: a imagem mostra a leitura em tempo real em volts para cada um dos sensores.

Fonte: elaborado pela autora.

Leitura no protótipo

Para realizar as leituras no protótipo, as cervejas foram preparadas conforme o item 8.2.6. As garrafas foram retiradas da câmara fria com 2 horas de antecedência, aquecidas em banho-maria até atingirem a temperatura de 22°C. As amostras foram distribuídas em tubos de ensaio do tipo *falcon* de 15 mL até o volume máximo. E seguida, foram acopladas a um suporte com controle de temperatura. Os sensores foram posicionados de forma a ficarem em contato com o vapor de cerveja (Figura 35) permanecendo ali por 3 minutos.

Figura 35 - Leitura de compostos voláteis com múltiplos sensores



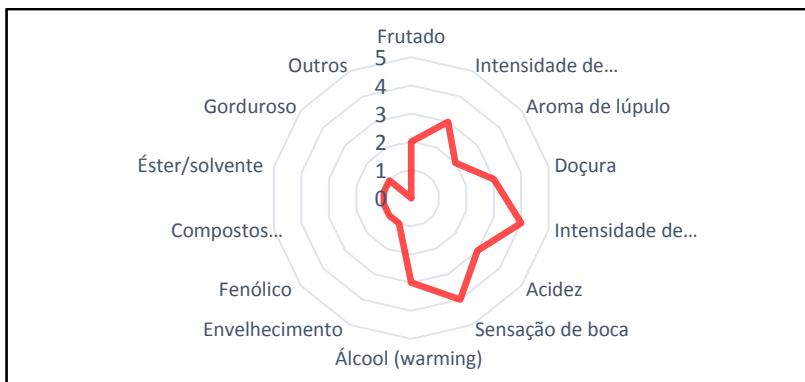
Fonte: elaborado pela autora.

4 RESULTADOS E DISCUSSÕES

4.1 PERFIL DA CERVEJA BASE DEFINIDA PELO PAINEL TREINADO

Com base nos testes descritivos aplicados aos analistas treinados, o resultado foi expresso pelo Gráfico 1. Esses valores foram utilizados como referência para os demais testes descritivos para o painel treinado e não treinado.

Gráfico 1 - Perfil *Berliner Pilsner*, com os diferentes atributos apresentados



Fonte: elaborado pela autora.

Para os atributos: gorduroso, éster, compostos sulfurados e 4 vinil guaiacol (fenólico), a intensidade foi definida com 1 (não presente); para os atributos relacionados ao lúpulo, foi perceptível uma maior intensidade, com notas 4 para amargor e 2 para aroma de lúpulo, mostrando a presença marcante do lúpulo neste tipo de cerveja. Para sensação de boca, a intensidade foi marcada como 4 para acidez e álcool; sabor de malte teve intensidade 3 e frutado teve intensidade 2.

Bosquioli (1996), quando na caracterização de cervejas pilsen nacionais, verificou que as cervejas disponíveis no mercado possuíam em sua maioria atributos diferenciados, principalmente quanto à cor, amargor e presença de 2,3 butanodiona (diacetil), características não encontradas nas amostras comerciais utilizadas neste trabalho. Segundo Zoecklein et al. (1994), a percepção de doçura derivada do álcool, polissacarídeos e açúcar deve estar em equilíbrio com a soma das percepções dos gostos ácido e amargo e da adstringência.

4.2 AVALIAÇÃO ENTRE O PAINEL TREINADO E NÃO TREINADO

As Tabelas 12 e 13 descrevem os resultados do estudo utilizando a média como parâmetro de medida central e o desvio padrão (DP) como medida de dispersão dos dados. Observa-se que a escala média de resposta para os testes de análise sensorial dos 37 compostos estudados variou de 1,79 (DP $\pm 0,43$), para o composto químico caprilico, até 2,37 (DP $\pm 0,28$) para o composto geosmina, ambos entre os participantes não treinados. Os valores médios de resposta da escala de análise sensorial esperados, contabilizados de acordo com o padrão variaram de 2,07 (DP $\pm 0,0001$) para o composto químico *musty*, e até 2,66 (DP $\pm 0,12$) para o composto benzaldeído (amêndoas).

Os desvios padrões obtidos para cada composto tanto do grupo treinado (GT) e não treinado (GNT) evidenciam como os dados coletados se dispersaram em relação à média. Para quase a totalidade dos compostos analisados, o desvio padrão do GT foi menor ou igual ao que foi o encontrado para o GNT, exceto para os compostos etil fenchol, acetato de etila e baunilha. Esses valores menores para o desvio padrão para o GT evidenciam avaliações mais precisas por parte dos julgadores com treinamento e avaliações mais dispersas para os participantes do GNT. Assim, o treinamento tem papel fundamental para tornar a avaliação mais homogênea quanto aos valores dados pelos participantes e assim, torna-la mais precisa.

Tabela 12 - Análise descritiva dos compostos

COMPOSTO	MÉDIA \pm DESVIO PADRÃO			
	DE ACORDO COM O GRUPO		DE ACORDO COM A RESPOSTA OU PADRÃO DA ESCALA	
	GT	GNT	RESPOSTA	PADRÃO ESPERADO
Ácido acético	2.26 \pm 0.22	2.13 \pm 0.33	2.19 \pm 0.28	2.21 \pm 0.03
Diacetil ou 2,3 butanodiona	2.23 \pm 0.15	2.29 \pm 0.23	2.26 \pm 0.19	2.36 \pm 0
H ₂ S ou sulfeto de hidrogênio	2.12 \pm 0.23	2.16 \pm 0.23	2.14 \pm 0.23	2.36 \pm 0
Acetato de isoamila	2.27 \pm 0.26	2.41 \pm 0.29	2.34 \pm 0.27	2.29 \pm 0
Ranco ou trans, trans-2,4 heptadienal	2.27 \pm 0.22	2.26 \pm 0.25	2.27 \pm 0.23	2.24 \pm 0.16
Geosmina	2.30 \pm 0.22	2.37 \pm 0.28	2.33 \pm 0.24	2.43 \pm 0

Tabela 12 - (continuação) Análise descritiva dos compostos. Fonte: elaborado pela autora.

Mel ou etil fenilacetato	2.21 ± 0.3	1.8 ± 0.85	2.01 ± 0.65	2.21 ± 0
Musty - 2,4,6 trichloroanisole	2.08 ± 0.34	2.16 ± 0.46	2.12 ± 0.39	2.07 ± 0
Methional	2.14 ± 0.16	2.17 ± 0.18	2.16 ± 0.17	2.21 ± 0.15
metanotiol (Mercaptano)	2.23 ± 0.15	1.98 ± 0.37	2.11 ± 0.3	2.36 ± 0
Malte buscuit	2.13 ± 0.23	1.96 ± 0.39	2.04 ± 0.32	2.22 ± 0.02
Terra molhada ou Ethil fenchol	2.17 ± 0.32	2.32 ± 0.25	2.25 ± 0.29	2.43 ± 0
Acetaldeído	2.15 ± 0.3	1.67 ± 0.74	1.91 ± 0.6	2.25 ± 0.18
Ácido láctico	2.20 ± 0.3	2.08 ± 0.31	2.14 ± 0.3	2.21 ± 0
Amêndoas ou benzaldeído	2.18 ± 0.28	2.26 ± 0.29	2.22 ± 0.28	2.66 ± 0.12
Acetato de etila	2.27 ± 0.38	2.17 ± 0.36	2.22 ± 0.36	2.57 ± 0
Baunilha	2.30 ± 0.35	2.24 ± 0.31	2.27 ± 0.32	2.54 ± 0.04
Caprilico	1.86 ± 0.42	1.79 ± 0.43	1.83 ± 0.41	2.36 ± 0
2,6 diclorofenol	2.19 ± 0.35	2.21 ± 0.38	2.20 ± 0.35	2.32 ± 0.1
Geraniol	2.22 ± 0.43	1.99 ± 0.5	2.11 ± 0.47	2.29 ± 0
Grama fresca ou cis 3 hexanol	2.46 ± 0.18	2.16 ± 0.46	2.31 ± 0.37	2.18 ± 0.11
Óleo de lúpulo ou extrato oleoso de lúpulo	2.36 ± 0.45	2.19 ± 0.5	2.27 ± 0.47	2.29 ± 0
Papel ou trans-2-nonenal	1.98 ± 0.36	2.15 ± 0.49	2.07 ± 0.42	2.35 ± 0.02
Bicarbonato de sódio (Alcalino)	2.22 ± 0.17	2.16 ± 0.22	2.19 ± 0.19	2.37 ± 0.32
Ácido Butírico	2.13 ± 0.24	1.99 ± 0.38	2.06 ± 0.32	2.21 ± 0
2-bromofenol	2.25 ± 0.22	2.03 ± 0.4	2.14 ± 0.34	2.34 ± 0.06
Dimetiltrisulfeto (Cebola)	2.20 ± 0.2	2.07 ± 0.33	2.14 ± 0.27	2.21 ± 0.15
Dimetil sulfito (DMS)	2.20 ± 0.17	2.05 ± 0.25	2.13 ± 0.22	2.36 ± 0
Etilbutirato	2.16 ± 0.35	1.99 ± 0.36	2.08 ± 0.36	2.29 ± 0
Hexoato	2.29 ± 0.11	2.53 ± 0.29	2.41 ± 0.25	2.29 ± 0
3-metil-2-butano-1-tiol (Light struck)	2.16 ± 0.18	2.36 ± 0.22	2.26 ± 0.22	2.36 ± 0
Ácido Isovalérico	2.24 ± 0.13	2.17 ± 0.38	2.21 ± 0.28	2.36 ± 0
Sulfato de ferro (Metálico)	2.33 ± 0.22	2.16 ± 0.37	2.25 ± 0.31	2.39 ± 0.13
Styrene (Plástico)	2.19 ± 0.2	2.14 ± 0.45	2.16 ± 0.34	2.09 ± 0.06
Guaiacol (Defumado)	2.34 ± 0.12	1.96 ± 0.36	2.15 ± 0.32	2.36 ± 0
4 vinil guaiacol (Fenólico)	2.02 ± 0.35	2.02 ± 0.35	2.02 ± 0.33	2.32 ± 0.1
p-mentano-8 tiol-3-ona (gato)	2.01 ± 0.44	2,00 ± 0.44	2,00 ± 0.42	2.36 ± 0

Tabela 13 - Análise descritiva dos atributos

COMPOSTOS	MÉDIA ± DESVIO PADRÃO			
	DE ACORDO COM O GRUPO		DE ACORDO COM A RESPOSTA OU PADRÃO DA ESCALA	
	GT	GNT	PAINEL DE RESPOSTAS	PADRÃO ESPERADO
Acidez	2.61 ± 0.26	2.80 ± 0.25	2.70 ± 0.26	3.21 ± 0.08
Álcool	2.56 ± 0.31	2.59 ± 0.27	2.57 ± 0.28	2.99 ± 0.02
Aroma de Lúpulo	2.12 ± 0.18	2.11 ± 0.17	2.11 ± 0.17	2.17 ± 0.1
Compostos sulfurados	1.55 ± 0.26	1.47 ± 0.34	1.51 ± 0.3	1.61 ± 0.17
Doçura	2.60 ± 0.28	2.59 ± 0.32	2.60 ± 0.29	3.04 ± 0.03
Envelhecimento	1.95 ± 0.32	1.71 ± 0.25	1.83 ± 0.31	1.24 ± 0.13
Ester / solvente	1.72 ± 0.19	1.72 ± 0.12	1.72 ± 0.15	1.28 ± 0.11
4 vinil guaiacol (Fenólico)	1.77 ± 0.16	1.60 ± 0.14	1.69 ± 0.17	1.40 ± 0.13
Frutado	2.06 ± 0.13	2.38 ± 0.18	2.22 ± 0.23	2.43 ± 0.16
Gorduroso	1.54 ± 0.17	1.55 ± 0.2	1.54 ± 0.18	1.48 ± 0.1
Intensidade e amargor	3.10 ± 0.18	3.32 ± 0.2	3.21 ± 0.22	4,00 ± 0.02
Intensidade do aroma de malte	2.45 ± 0.19	2.52 ± 0.24	2.48 ± 0.21	3.07 ± 0.04
Outros	0.75 ± 0.2	1.06 ± 0.19	0.91 ± 0.25	0.51 ± 0.2
Sensação de boca	3.09 ± 0.24	3.35 ± 0.24	3.22 ± 0.27	4,00 ± 0.03

Fonte: elaborado pela autora.

A percepção dos participantes quanto à intensidade do sabor dos componentes medido utilizando a escala de análise sensorial variou de 1,91 (DP ± 0,6), para o composto Acetaldeído, até 2,41 (DP ± 0,25) para o hexoato. Destaca-se na análise descritiva que a dispersão dos dados, medida por meio do desvio padrão, para os valores padrão foram negligenciáveis, sendo menores do que 0.0001 para diversos compostos, enquanto que para as respostas de análise sensorial, os valores indicam maior dispersão, embora pouco ampla de modo geral. Assim, justifica-se a utilização das análises estatísticas para dados paramétricos, uma vez que a distribuição dos dados foi simétrica. Em relação a escala média de análise sensorial para os atributos estudados, encontrou-se maior discrepância entre as médias para a intensidade de amargor e outros atributos, tais como doçura e sensação de boca mostrando que a percepção da intensidade de amargor foi mais alta, tanto para o grupo de participantes treinados quanto para os não treinados (3,1 ± 0,18, para o

grupo treinado, e $3,32 \pm 0,2$, para o grupo não treinado), e mais baixa para outros atributos ($0,75 \pm 0,2$, para o grupo treinado, e $1,06 \pm 0,19$, para o grupo não treinado).

As Tabelas 14, 15 e 16 mostram a diferença entre as médias de análise sensorial entre os grupos de participantes treinados e não treinados, e também entre a percepção sensorial relatada pelos participantes em comparação com o padrão adquirido da amostra base realizado pelo painel treinado. Ao comparar os resultados dos participantes treinados com os não treinados, quanto à percepção do sabor dos compostos (Tabela 14), observou-se que a escala média de análise sensorial no grupo treinado para os componentes trans,trans-2,4 heptadienal (ranço), metanotiol (mercaptano), bicarbonato de sódio (alcalino), hexanoato de etila e 3-metil-2-butano-1-tiol (*light struck*) foi, respectivamente, 6%, 7%, 12%, 5% e 4% menor do que no grupo de participantes não treinados. Por outro lado, na mesma comparação observou-se que a escala média de análise sensorial dos componentes ácido láctico, sulfato de ferro (metálico) e guaiacol (defumado) foram 18%, 6% e 8% maiores entre os participantes não treinados. Ao comparar a escala média de análise sensorial relatada pelos participantes com a escala média padrão, observou-se que a escala média relatada foi em geral menor do que a padrão esperado. Por exemplo, a escala média padrão foi 4% maior para o 2,3 butanodiona (diacetil) e 3-metil-2-butano-1-tiol (*light struck*) e 19% maior para o acetato de etila, que foi o composto que apresentou a maior diferença.

Tabela 14 - Análise descritiva dos compostos

COMPOSTO	MÉDIA (IC95%)					
	DE ACORDO COM O GRUPO		VALOR- <i>p</i>	DE ACORDO COM A RESPOSTA OU PADRÃO DA ESCALA		VALOR- <i>p</i>
	GNT	GT		RESPOSTA	PADRÃO ESPERADO	
Ácido acético	2.17 (2.09 - 2.26)	2.23 (2.14 - 2.31)	0,35	2.19 (2.11 - 2.28)	2.21 (2.12 - 2.29)	0,08
Diacetil ou 2,3 butanodiona	2.33 (2.26 - 2.39)	2.29 (2.23 - 2.35)	0,47	2.26 (2.2 - 2.32)	2.36 (2.3 - 2.42)	0,03
H ₂ S ou sulfeto de hidrogênio	2.26 (2.19 - 2.33)	2.24 (2.17 - 2.31)	0,66	2.14 (2.07 - 2.21)	2.36 (2.29 - 2.43)	0,00
Acetato de isoamila	2.35 (2.27 - 2.43)	2.28 (2.2 - 2.36)	0,22	2.34 (2.26 - 2.42)	2.29 (2.2 - 2.37)	0,33
Ranco ou trans, trans-2,4 heptadienal	2.32 (2.24 - 2.4)	2.19 (2.11 - 2.27)	0,02	2.27 (2.19 - 2.35)	2.24 (2.16 - 2.32)	0,61
182 geosmina	2.40 (2.31 - 2.49)	2.36 (2.28 - 2.45)	0,57	2.33 (2.25 - 2.42)	2.43 (2.34 - 2.52)	0,12
Mel ou etil fenilacetato	2.01 (1.8 - 2.22)	2.21 (2 - 2.43)	0,18	2.01 (1.8 - 2.22)	2.21 (2 - 2.43)	0,18
Musty - 2,4,6 trichloroanisole	2.39 (2.31 - 2.48)	2.36 (2.27 - 2.45)	0,57	2.33 (2.24 - 2.41)	2.42 (2.34 - 2.51)	0,12
Methional	2.12 (1.98 - 2.25)	2.08 (1.94 - 2.21)	0,67	2.12 (1.99 - 2.25)	2.07 (1.94 - 2.2)	0,60
Metanotiol (Mercaptano)	2.27 (2.21 - 2.33)	2.11 (2.05 - 2.17)	0,00	2.16 (2.1 - 2.22)	2.21 (2.15 - 2.27)	0,20
2-acetyl pyridine (Malte buscuit)	2.17 (2.08 - 2.26)	2.29 (2.2 - 2.38)	0,06	2.11 (2.02 - 2.2)	2.36 (2.27 - 2.45)	0,00
Terra molhada ou Ethil fenchol	2.08 (1.98 - 2.19)	2.18 (2.07 - 2.28)	0,22	2.04 (1.94 - 2.15)	2.22 (2.11 - 2.32)	0,02

Tabela 14 - (continuação) Análise descritiva dos compostos

COMPOSTO	MÉDIA (IC95%)					
	DE ACORDO COM O GRUPO		VALOR- <i>p</i>	DE ACORDO COM A RESPOSTA OU PADRÃO DA ESCALA		VALOR- <i>p</i>
	GNT	GT		RESPOSTA	PADRÃO ESPERADO	
Acetaldeído	2.38 (2.28 - 2.47)	2.3 (2.2 - 2.39)	0,27	2.25 (2.15 - 2.34)	2.43 (2.33 - 2.52)	0,01
Ácido láctico	1.87 (1.69 - 2.05)	2.29 (2.11 - 2.47)	0,00	1.91 (1.73 - 2.09)	2.25 (2.07 - 2.43)	0,01
Amêndoas ou benzaldeído	2.15 (2.06 - 2.24)	2.21 (2.12 - 2.3)	0,35	2.14 (2.05 - 2.23)	2.21 (2.12 - 2.31)	0,25
Acetato de etila	2.44 (2.34 - 2.54)	2.44 (2.34 - 2.54)	0,95	2.22 (2.12 - 2.32)	2.66 (2.56 - 2.76)	0,00
Baunilha	2.37 (2.26 - 2.48)	2.42 (2.31 - 2.53)	0,52	2.22 (2.11 - 2.33)	2.57 (2.46 - 2.68)	0,00
Caprilico	2.41 (2.31 - 2.51)	2.40 (2.3 - 2.5)	0,92	2.27 (2.17 - 2.37)	2.54 (2.44 - 2.63)	0,00
2,6 diclorofenol	2.08 (1.94 - 2.21)	2.11 (1.97 - 2.25)	0,75	1.83 (1.69 - 1.96)	2.36 (2.22 - 2.5)	0,00
Geraniol	2.27 (2.14 - 2.39)	2.25 (2.13 - 2.38)	0,88	2.20 (2.08 - 2.32)	2.32 (2.2 - 2.44)	0,18
Grama fresca ou cis 3 hexanol	2.14 (1.98 - 2.29)	2.25 (2.1 - 2.41)	0,30	2.11 (1.95 - 2.26)	2.29 (2.13 - 2.44)	0,11
Óleo de lúpulo ou extrato oleoso de lúpulo	2.24 (2.08 - 2.39)	2.32 (2.17 - 2.48)	0,45	2.27 (2.12 - 2.43)	2.29 (2.13 - 2.44)	0,91
Papel ou trans-2-nonenal	2.25 (2.11 - 2.39)	2.17 (2.03 - 2.31)	0,38	2.07 (1.93 - 2.21)	2.35 (2.21 - 2.49)	0,00
Bicarbonato de sódio (Alcalino)	2.42 (2.31 - 2.53)	2.15 (2.03 - 2.26)	0,00	2.19 (2.08 - 2.31)	2.37 (2.26 - 2.49)	0,03

Tabela 14 - (continuação) Análise descritiva dos compostos

COMPOSTO	MÉDIA (IC95%)					
	DE ACORDO COM O GRUPO		VALOR- <i>p</i>	DE ACORDO COM A RESPOSTA OU PADRÃO DA ESCALA		VALOR- <i>p</i>
	GNT	GT		RESPOSTA	PADRÃO ESPERADO	
Ácido butírico	2.10 (2.01 - 2.19)	2.17 (2.08 - 2.27)	0,30	2.06 (1.96 - 2.15)	2.21 (2.12 - 2.31)	0,02
2-bromofenol	2.19 (2.09 - 2.29)	2.29 (2.19 - 2.39)	0,19	2.14 (2.04 - 2.24)	2.34 (2.24 - 2.44)	0,01
dimetiltrisulfeto (Cebola)	2.21 (2.1 - 2.32)	2.14 (2.03 - 2.25)	0,33	2.14 (2.03 - 2.25)	2.21 (2.1 - 2.32)	0,33
dimetil sulfito (DMS)	2.2 (2.14 - 2.27)	2.28 (2.21 - 2.34)	0,11	2.13 (2.06 - 2.19)	2.36 (2.29 - 2.42)	0,00
Etilbutirato	2.14 (2.03 - 2.25)	2.22 (2.12 - 2.33)	0,28	2.08 (1.97 - 2.18)	2.29 (2.18 - 2.39)	0,01
Hexoato	2.41 (2.34 - 2.48)	2.29 (2.21 - 2.36)	0,02	2.41 (2.34 - 2.48)	2.29 (2.21 - 2.36)	0,02
3-metil-2-butano-1-tiol (<i>Light struck</i>)	2.36 (2.29 - 2.42)	2.26 (2.19 - 2.32)	0,03	2.26 (2.19 - 2.32)	2.36 (2.29 - 2.42)	0,03
Ácido Isovalérico	2.26 (2.18 - 2.35)	2.30 (2.22 - 2.38)	0,56	2.21 (2.12 - 2.29)	2.36 (2.27 - 2.44)	0,01
Sulfato de ferro (Metálico)	2.25 (2.15 - 2.34)	2.39 (2.29 - 2.48)	0,04	2.25 (2.15 - 2.34)	2.39 (2.29 - 2.48)	0,04
Styrene (Plástico)	2.12 (2.01 - 2.22)	2.13 (2.03 - 2.24)	0,85	2.16 (2.06 - 2.27)	2.09 (1.98 - 2.19)	0,30
Guaiacol (Defumado)	2.16 (2.05 - 2.26)	2.35 (2.24 - 2.45)	0,01	2.15 (2.04 - 2.25)	2.36 (2.25 - 2.46)	0,01
4 vinil guaiacol (Fenólico)	2.17 (2.05 - 2.29)	2.17 (2.05 - 2.29)	1,00	2.02 (1.9 - 2.13)	2.32 (2.2 - 2.44)	0,00
<i>p</i> -mentano-8 tiol-3-ona (gato)	2.18 (2.04 - 2.32)	2.18 (2.04 - 2.33)	0,97	2,00 (1.86 - 2.15)	2.36 (2.22 - 2.5)	0,00

Fonte: elaborado pela autora.

Tabela 15 - Avaliação da diferença na escala de análise sensorial para os 14 atributos estudados de acordo com o painel (treinado e não treinado)

COMPOSTOS	MÉDIA (IC95%)		VALOR- <i>p</i>
	GT	GNT	
Acidez	2.91 (2.83 - 2.99)	3,00 (2.92 - 3.08)	0,1
Álcool	2.78 (2.69 - 2.86)	2.79 (2.7 - 2.88)	0,8
Aroma de lúpulo	2.16 (2.1 - 2.22)	2.12 (2.07 - 2.18)	0,4
Compostos sulfurados	1.63 (1.53 - 1.73)	1.50 (1.4 - 1.6)	0,07
Doçura	2.82 (2.73 - 2.91)	2.81 (2.72 - 2.9)	0,9
Envelhecimento	1.63 (1.54 - 1.72)	1.45 (1.36 - 1.54)	0,01
Ester / solvente	1.50 (1.44 - 1.55)	1.50 (1.44 - 1.56)	0,9
4 vinil guaiacol (Fenólico)	1.61 (1.55 - 1.67)	1.48 (1.42 - 1.54)	0,002
Frutado	2.27 (2.19 - 2.35)	2.38 (2.3 - 2.46)	0,06
Gorduroso	1.53 (1.47 - 1.59)	1.49 (1.43 - 1.55)	0,3
Intensidade e amargor	3.55 (3.49 - 3.61)	3.66 (3.6 - 3.72)	0,01
Intensidade do aroma de malte	2.75 (2.68 - 2.81)	2.81 (2.75 - 2.87)	0,2
Outros	0.58 (0.51 - 0.66)	0.83 (0.75 - 0.91)	<0.001
Sensação de boca	3.54 (3.47 - 3.62)	3.67 (3.6 - 3.75)	0,01

Fonte: elaborado pela autora.

Ao comparar a diferença entre as médias de análise sensorial em relação aos atributos no grupo de participantes não treinados em comparação aos treinados (Tabela 15), observou-se que a intensidade dos sabores envelhecimento e 4 vinil guaiacol (fenólico) foram, respectivamente, 8% e 6% menores entre os participantes não treinados, e que a percepção dos sabores frutado, intensidade de amargor, outros, e sensação de boca foram, respectivamente, 5%, 5%, 11%, e 6% maiores entre os participantes não treinados. Considerando o painel de respostas de análise sensorial e o padrão de resposta esperados, observou-se que, de modo geral, a intensidade do sabor foi menor do que o padrão esperado para cada atributo (Tabela 15); com exceção apenas para os atributos aroma de lúpulo, compostos sulfurados e gorduroso, para os quais não houve diferença significativa, indicando que estes compostos são facilmente perceptíveis, tanto por participantes treinados quanto pelos não treinados, uma vez que a resposta dos participante não difere significativamente do padrão de resposta esperado (Tabela 16).

Para avaliar se houve diferença no relato da escala de análise sensorial entre os participantes, utilizou-se análise de cluster para agrupar os participantes de acordo com a similaridade das respostas de análise sensorial. Assim, quando os compostos ou atributos tiveram médias de análise sensorial similar entre os grupos e o valor para significância estatística foi maior do que 0,05, não houve diferença significativa na percepção de sabor entre os *clusters*.


Tabela 16 - Avaliação da diferença na escala de análise sensorial para os 14 atributos estudados e comparando as respostas observadas com os padrões de resposta esperados

COMPOSTOS	MÉDIA (IC95%)		VALOR- <i>p</i>
	PAINEL DE RESPOSTAS	PADRÃO ESPERADO	
Acidez	2.70 (2.62 - 2.78)	3.21 (3.13 - 3.29)	<0.001
Álcool	2.57 (2.49 - 2.66)	2.99 (2.91 - 3.08)	<0.001
Aroma de lúpulo	2.11 (2.06 - 2.17)	2.17 (2.11 - 2.23)	0,2
Compostos sulfurados	1.51 (1.41 - 1.61)	1.61 (1.51 - 1.71)	0,17
Doçura	2.60 (2.51 - 2.68)	3.04 (2.95 - 3.13)	<0.001
Envelhecimento	1.83 (1.74 - 1.92)	1.24 (1.15 - 1.34)	<0.001
Ester / solvente	1.72 (1.66 - 1.78)	1.28 (1.22 - 1.34)	<0.001
4 vinil guaiacol (Fenólico)	1.69 (1.63 - 1.74)	1.40 (1.35 - 1.46)	<0.001
Frutado	2.22 (2.14 - 2.3)	2.43 (2.35 - 2.51)	<0.001
Gorduroso	1.54 (1.48 - 1.61)	1.48 (1.41 - 1.54)	0,1
Intensidade e amargor	3.21 (3.15 - 3.27)	4,00 (3.93 - 4.06)	<0.001
Intensidade do aroma de malte	2.48 (2.42 - 2.55)	3.07 (3.01 - 3.14)	<0.001
Outros	0.91 (0.83 - 0.98)	0.51 (0.43 - 0.59)	<0.001
Sensação de boca	3.22 (3.14 - 3.3)	4.00 (3.92 - 4.07)	<0.001

Fonte: elaborado pela autora.

O Gráfico 2 mostra os três *clusters* de acordo com os 37 compostos químicos analisados. O *cluster* 1 teve como padrão o relato de menores médias de análise sensorial para os compostos caprílico, *p*-mentano-8 tiol-3-ona (gato), ácido butírico, etilbutirato e 2-acetyl pyridine (*malte biscuit*), do que os *clusters* 2 e 3 e maiores para 2,3 butanodiona (diacetil), 2-bromofenol, *musty* e cis 3 hexanol (grama fresca), caracterizando um padrão.

Gráfico 2 - Análise sensorial dos compostos na amostra completa




Fonte: elaborado pela autora.

O *cluster 2* teve como padrão o relato das médias menores de análise sensorial para os compostos acetaldeído, 4 vinil guaiacol (fenólico), *musty*, cis 3 hexanol (grama fresca), etil fenilacetato (mel), 2-bromofenol, ácido isovalérico, 2-acetyl pyridine (*malte buscuit*), dimetil sulfito (DMS) e 2,3 butanodiona (diacetil) do que os outros dois grupos, e maior sensibilidade ao sabor dos compostos styrene (plástico), ácido butírico, geosmina, metanotiol (mercaptano) e etil fenchol (terra molhada), caracterizando um padrão. O *cluster 3* apresentou um padrão de respostas intermediário entre os três.


De modo geral, na amostra completa o relato de análise sensorial dos componentes do *cluster 2* apresentaram maior variabilidade nas médias das respostas (Gráfico 2), o que foi bastante similar ao observado para os participantes não treinados (Gráfico 3), ao passo que os padrões de análise sensorial dos participantes treinados foi mais homogêneo (Gráfico 4).

Gráfico 3 - Análise sensorial dos compostos para participantes não treinados



Fonte: elaborado pela autora.


Gráfico 4 - Análise sensorial dos compostos para participantes treinados



Fonte: elaborado pela autora.

Demonstrou-se também que as médias de análise sensorial dos participantes do estudo (Gráfico 5) variaram significativamente mais do que o padrão esperado para as respostas (Gráfico 6) e que as médias de todos os *clusters* para os participantes treinados (Gráfico 4) foi a que mais se aproximou do padrão de resposta esperado (Gráfico 6), mostrando que, neste estudo, a percepção do sabor medido pela escala de análise sensorial de pessoas treinadas foi superior ao observado para as pessoas não treinadas.


Gráfico 5 - Análise sensorial dos compostos - painel de respostas para análise sensorial



Fonte: elaborado pela autora.

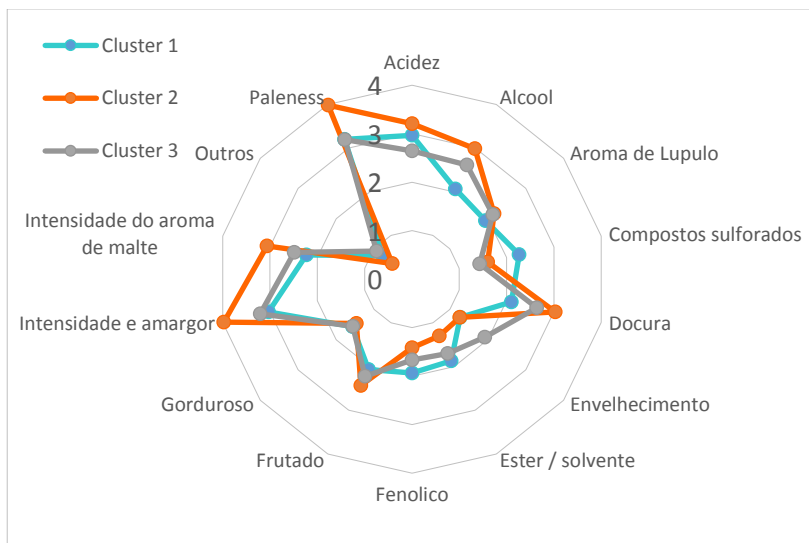
Em relação aos atributos na amostra completa, o *cluster 2* destacou-se por apresentar a maior média de análise sensorial para a maioria dos compostos analisados (Gráfico 7).

Gráfico 6 - Análise sensorial dos compostos para o padrão esperado de análise sensorial



Fonte: elaborado pela autora.

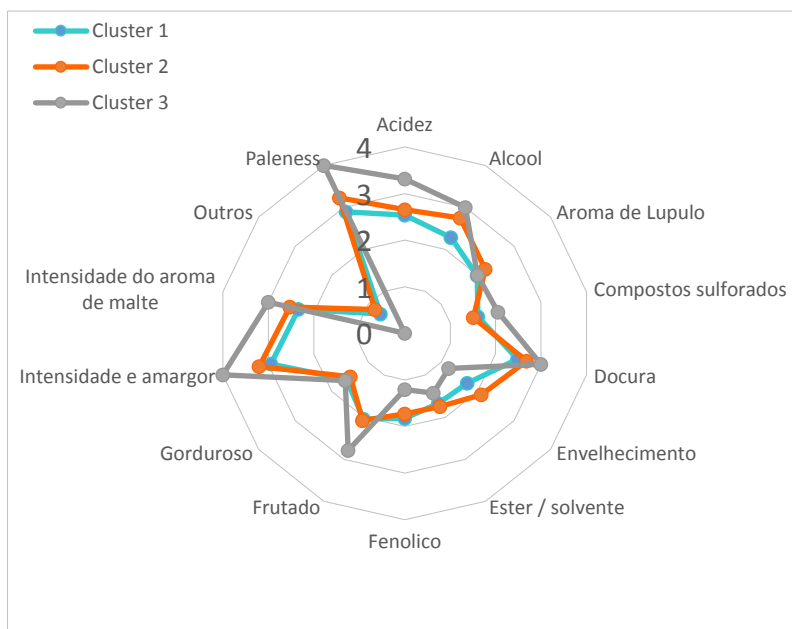
Gráfico 7 - Análise sensorial dos atributos na amostra completa



Fonte: elaborado pela autora.

Quando estratificados de acordo com o grupo de participantes treinados e não treinados, observou-se que as maiores médias de análise sensorial foram relatadas pelo *cluster* 3 (Gráfico 8), e entre o grupo de participantes treinados para o *cluster* 1 (Gráfico 9), o que indica que o padrão de percepção dos participantes diferiu significativamente quando comparado aos padrões de análise sensorial entre os grupos de participantes treinados e não treinados.


Gráfico 8 - Análise sensorial dos atributos para o grupo não treinado



Fonte: elaborado pela autora.


Por outro lado, a análise sensorial dos participantes do estudo (Gráfico 10), comparativamente com o padrão esperado de resposta (Gráfico 11) apresentaram padrões de análise sensorial similares.

Gráfico 9 - Análise sensorial dos atributos para o grupo treinado




Fonte: elaborado pela autora.

Gráfico 10 - Análise sensorial dos atributos para respostas de análise sensorial



Fonte: elaborado pela autora.

Gráfico 11 - Análise sensorial dos atributos para o padrão de respostas de análise sensorial esperado



Fonte: elaborado pela autora.

4.3 DESEMPENHO DO PROTÓTIPO AVALIANDO 6 SENSORES CONSIDERANDO 37 ATRIBUTOS

Na Tabela 17 e Figuras 36-40 a seguir são mostradas as médias de leituras expressas em volts para cada um dos 37 compostos analisados e dos 6 sensores testados.

Tabela 17 - Médias das leituras em volts para cada sensor e cada composto químico


SENSORES	MQ1135	MQ8	MQ7	MQ4	MQ2	MQ3
Referência cerveja Base	1,8	3,3	2,6	1,8	3,2	2,8
Ácido acético	4,3	2,8	3,5	4,2	3,6	3,4
Diacetil ou 2,3 butanodiona	3,6	4,2	2,9	2,7	4,3	2,9
H₂S ou sulfeto de hidrogênio	2,3	3,6	2,8	1,8	4,1	3,6
Acetato de isoamila	2,4	3,8	3,2	2,4	4,1	3,2
Ranco ou trans, trans-2,4 heptadienal	2,3	4,8	3,2	2,8	3,9	3,3
Geosmina	1,8	3,2	2,9	2,1	3,2	2,8
Mel ou etil fenilacetato	1,8	3,7	2,8	2,4	3,6	3,2

Tabela 17 - (continuação) Médias das leituras em volts para cada sensor e cada composto químico

SENSORES	MQ1135	MQ8	MQ7	MQ4	MQ2	MQ3
Musty - 2,4,6 trichloroanisole	4,7	3,3	2,8	3,2	3,9	2,9
Methional	2,2	3,4	2,6	2,2	3,6	4,1
metanotiol (Mercaptano)	1,8	3,3	3,1	4,1	4,3	2,8
2-acetyl pyridine (Malte biscuit)	2,2	3,4	2,6	1,8	3,6	3,1
Terra molhada ou Ethil fenchol	4,8	3,4	3,3	2,3	3,4	2,9
Acetaldeído	2,3	3,7	2,9	4,3	3,4	2,7
Ácido láctico	2,2	4,6	2,7	1,8	3,4	3,3
Amendoas ou benzaldeído	4,6	3,7	2,8	2,2	3,8	3,2
Acetato de etila	2,2	3,5	2,8	2,1	3,4	4,3
Baunilha	2,2	3,3	4,1	1,8	3,3	3,1
Caprilico	2,8	3,4	3,2	1,9	3,2	4,2
2,6 diclorofenol	2,8	3,3	2,8	1,9	3,2	3,1
Geraniol	4,6	3,5	2,8	2,2	3,2	3,1
Gramma fresca ou cis 3 hexanol	3,8	3,5	2,8	1,8	3,3	3,1
Óleo de lúpulo ou extrato oleoso de lúpulo	2,2	3,4	2,8	2,1	3,3	3,8
Papel ou trans-2-nonenal	3,8	3,7	2,8	1,9	3,2	2,9
Bicarbonato de sódio (Alcalino)	1,8	3,3	2,6	1,8	3,2	2,8
2-bromofenol	4,1	3,0	2,8	2,3	3,4	2,9
Dimetiltrisulfeto (Cebola)	2,1	3,4	2,8	3,4	4,6	3,1
Dimetil sulfito (DMS)	1,9	3,4	2,8	3,8	4,2	2,8
Ácido butírico	2,1	4,5	2,6	2,1	3,4	3,2
Etilbutirato	2,2	3,4	2,8	1,9	3,5	3,9
Hexoato	2,3	3,4	2,7	2,2	3,3	4,7
3-metil-2-butano-1-tiol (<i>Light struck</i>)	2,1	3,5	2,7	4,5	4,2	3,1
Ácido Isovalérico	2,3	4,8	2,5	2,3	3,5	3,1
Sulfato de ferro (Metálico)	1,8	3,3	2,6	1,8	3,2	2,8
Styrene (Plástico)	2,2	3,8	4,3	2,4	3,9	3,0
Guaiacol (Defumado)	2,2	3,5	3,8	2,3	4,3	3,4
4 vinil guaiacol (Fenólico)	4,9	3,6	2,8	2,2	3,5	2,8
<i>p</i> -mentano-8 tior-3-ona (gato)	3,5	3,8	3,2	2,4	3,5	3,5

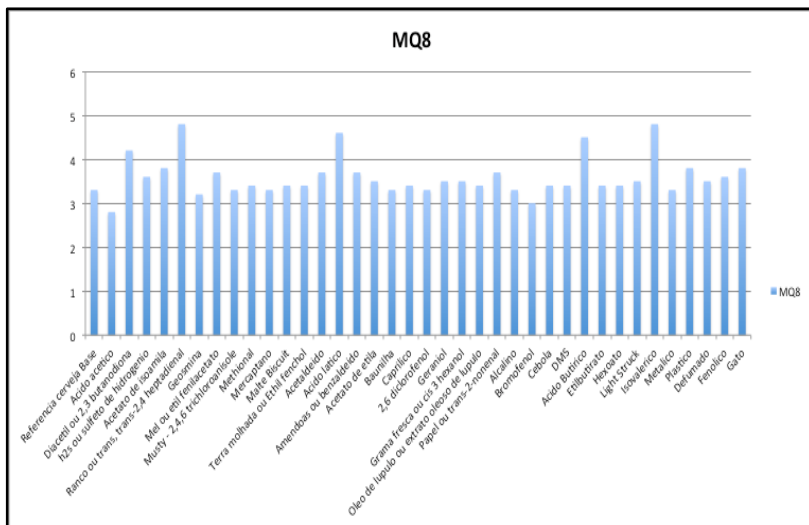
Fonte: elaborado pela autora.

Figura 36 - Médias de leitura em volts para 37 atributos referente ao sensor MQ1135




Fonte: elaborado pela autora.

Figura 37 - Médias de leitura em volts para 37 atributos referente ao sensor MQ8



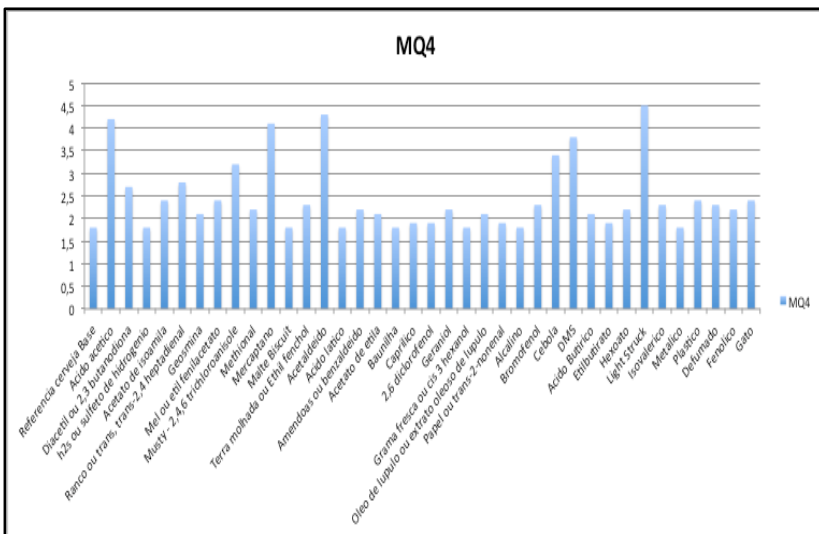
Fonte: elaborado pela autora.

Figura 38 - Médias de leitura em volts para 37 atributos referente ao sensor MQ7




Fonte: elaborado pela autora.

Figura 39 - Médias de leitura em volts para 37 atributos referente ao sensor MQ4




Fonte: elaborado pela autora.

Figura 40 - Médias de leitura em volts para 37 atributos referente ao sensor MQ2



Fonte: elaborado pela autora.

Figura 41 - Médias de leitura em volts para 37 atributos referente ao sensor MQ3



Fonte: elaborado pela autora.

Considerando as médias dos sensores, nota-se que eles apresentaram diferentes repostas de leitura para os diferentes compostos apresentados ao protótipo. Somente considerando as médias de leituras, podemos observar que alguns compostos não foram identificados pelo sensores, sendo eles: sulfato de ferro (metálico) e bicarbonato de sódio (alcalino), possivelmente por esses composto serem pouco voláteis. Pelo fato das medias serem muito próximas uma da outra, técnicas de reconhecimento de padrões com PNN e PCA foram aplicadas nesse trabalho.

4.4 ANÁLISE ESTATÍSTICA

Para descrição dos resultados obtidos do protótipo em cada sensor para cada atributo, foi considerada a média das três repetições efetuadas em 1 minuto, 2 minutos e 3 minutos. A análise da capacidade dos sensores para avaliar cada atributo foi efetuada considerando-se o modelo de análise de componentes principais. Para identificação do peso de cada atributo em cada um dos componentes, foram estimadas as correlações dos atributos avaliados com os componentes principais estimados e os dados foram analisados com o programa computacional IBM SPSS Statistics v. 20.0.

4.5 RESULTADOS PCA

Na Tabela 18 são apresentados os valores médios das três repetições (1 minuto, 2 minutos, 3 minutos) de cada um dos sensores considerados, para cada um dos atributos avaliados.

Tabela 18 - Valores médios das três repetições para cada tipo de sensor e atributo

ATRIBUTOS	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8
Ácido acético	4,3	4,2	3,6	3,4	3,5	2,8
Diacetil ou 2,3 butanodiona	3,6	2,7	4,3	3,0	2,9	4,2
H ₂ S ou sulfeto de hidrogênio	2,3	1,8	4,1	3,6	2,8	3,6
Acetato de isoamila	2,4	2,4	4,2	3,3	3,3	3,8
Ranço ou trans, trans-2,4 heptadienal	2,3	2,8	3,9	3,3	3,2	4,8
Geosmina	1,8	2,1	3,2	2,8	2,9	3,2


Tabela 18 - (continuação) Valores médios das três repetições para cada tipo de sensor e atributo

ATRIBUTOS	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8
Mel ou etil fenilacetato	1,8	2,4	3,6	3,2	2,8	3,7
Musty - 2,4,6 trichloroanisole	4,6	3,2	3,9	2,9	2,8	3,3
Methional	2,1	2,2	3,6	4,1	2,7	3,4
Metanotiol (Mercaptano)	1,8	4,1	4,3	2,8	3,1	3,3
2-acetyl pyridine (Malte buscuit)	2,2	1,8	3,6	3,1	2,6	3,4
Terra molhada ou Ethil fenchol	4,8	2,3	3,4	2,9	3,3	3,4
Acetaldeído	2,3	4,3	3,4	2,7	2,9	3,7
Ácido láctico	2,2	1,8	3,4	3,3	2,7	4,6
Amêndoas ou benzaldeído	4,6	2,2	3,8	3,2	2,8	3,7
Acetato de etila	2,2	2,1	3,4	4,3	2,8	3,5
Baunilha	2,2	1,8	3,3	3,1	4,1	3,3
Caprilico	2,8	1,9	3,2	4,2	3,2	3,4
2,6 diclorofenol	2,8	1,9	3,2	3,1	2,8	3,3
Geraniol	4,6	2,2	3,2	3,1	2,8	3,5
Grama fresca ou cis 3 hexanol	3,8	1,8	3,3	3,1	2,8	3,5
Óleo de lúpulo ou extrato oleoso de lúpulo	2,2	2,1	3,3	3,8	2,8	3,4
Papel ou trans-2-nonenal	3,8	1,9	3,2	2,9	2,8	3,7
Bicarbonato de sódio (Alcalino)	1,8	1,8	3,2	2,8	2,6	3,3
2-bromofenol	4,1	2,3	3,4	2,9	2,8	3,0
Dimetiltrisulfeto (Cebola)	2,1	3,4	4,6	3,1	2,8	3,4
dimetil sulfito (DMS)	1,9	3,8	4,2	2,8	2,8	3,4
Ácido Butírico	2,1	2,1	3,4	3,2	2,6	4,5
Etilbutirato	2,2	1,9	3,5	3,9	2,8	3,4
Hexoato	2,3	2,2	3,3	4,7	2,7	3,4
3-metil-2-butano-1-tiol (<i>Light struck</i>)	2,1	4,5	4,2	3,1	2,7	3,5
Ácido Isovalérico	2,3	2,3	3,5	3,1	2,5	4,8
Sulfato de ferro (Metálico)	1,8	1,8	3,2	2,8	2,6	3,3
Styrene (Plástico)	2,2	2,4	3,9	3,0	4,3	3,8
Guaiaacol (Defumado)	2,2	2,3	4,3	3,4	3,8	3,5
4 vinil guaiacol (Fenólico)	4,9	2,2	3,5	2,8	2,8	3,6
p-mentano-8 tiol-3-ona (Gato)	3,5	2,4	3,5	3,5	3,2	3,8

Fonte: elaborado pela autora.

Estas médias podem ser visualizadas no Gráfico 13, onde é apresentado o perfil descritivo dos sensores.

Gráfico 12 - Perfil descritivo dos sensores

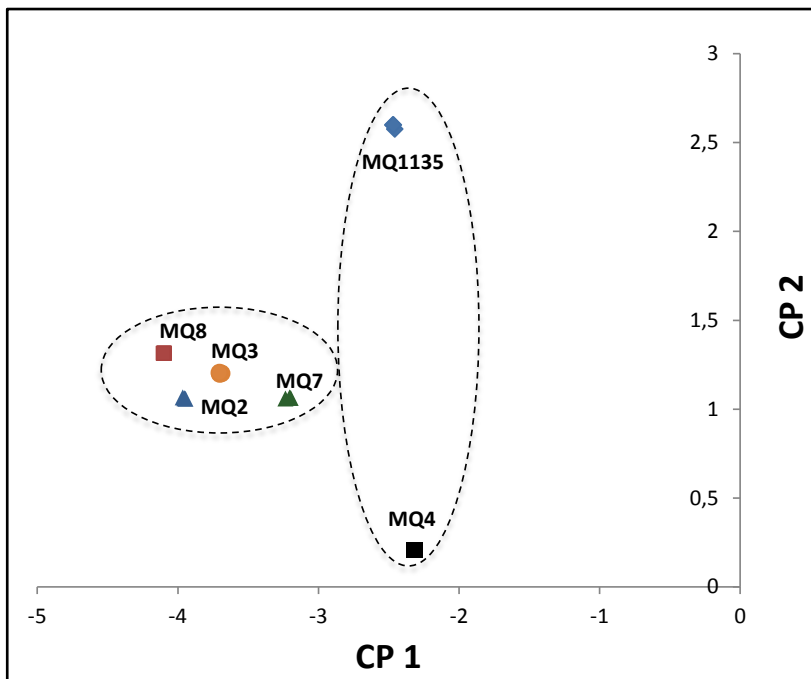


Fonte: elaborado pela autora.

Para sumarização dos resultados, em termos de comparação do poder de avaliação dos atributos por cada sensor, foi considerado o modelo de componentes principais. Com base na estimação destes componentes, identificou-se que os dois primeiros componentes explicam 80,9% da variabilidade total. O primeiro componente explica 51,9% da referida variabilidade enquanto que o segundo explica 29%.

No Gráfico 14 são apresentados os escores dos sensores avaliados, associados aos dois primeiros componentes principais estimados (CP1 e CP2).

Gráfico 13 - Escores dos sensores avaliados associados ao CP1 e ao CP2



Fonte: elaborado pela autora.

Como pode ser observado, os sensores MQ1135 e MQ4 não diferem em relação ao componente principal 1 e tem escores altos para este componente. Os sensores MQ7, MQ3, MQ2 e MQ8 apresentam escores menores no componente 1. Já em relação ao componente 2, MQ4 apresenta menores escores que os componentes MQ7, MQ3, MQ2 e MQ8. Por sua vez, o sensor MQ1135 apresenta maiores escores em relação ao componente 2.

Para avaliação do peso dos atributos em cada um dos componentes, foram estimadas as correlações de cada atributo com cada um dos componentes. Assim, na Tabela 19 são apresentadas as correlações de cada um dos atributos com os componentes principais 1 e 2. Nesta tabela estão destacadas as correlações maiores do que 0,7.

Tabela 19 - Correlações de cada um dos atributos com os componentes principais 1 e 2

ATRIBUTO	CP 1	CP 2
Ácido acético	0,886	0,107
Diacetil ou 2,3 butanodiona	-0,615	0,407
H ₂ S ou sulfeto de hidrogênio	-0,961	0,086
Acetato de isoamila	-0,936	-0,090
Ranco ou trans, trans-2,4 heptadienal	-0,874	-0,209
Geosmina	-0,934	-0,271
Mel ou etil fenilacetato	-0,937	-0,328
Musty - 2,4,6 trichloroanisole	0,250	0,699
Methional	-0,869	-0,110
metanotiol (Mercaptano)	-0,251	-0,830
2-acetyl pyridine (Malte buscuit)	-0,979	0,095
Terra molhada ou Ethil fenchol	0,069	0,964
Acetaldeído	0,010	-0,809
Ácido láctico	-0,931	0,097
Amêndoas ou benzaldeído	-0,220	0,920
Acetato de etila	-0,854	-0,033
Baunilha	-0,709	-0,003
Caprílico	-0,762	0,290
2,6 diclorofenol	-0,872	0,484
Geraniol	-0,035	0,984
Gramma fresca ou cis 3 hexanol	-0,455	0,886
Óleo de lúpulo ou extrato oleoso de lúpulo	-0,919	-0,033
Papel ou trans-2-nonenal	-0,426	0,868
Bicarbonato de sódio (Alcalino)	-0,990	-0,087
2-bromofenol	-0,024	0,934
Dimetiltrisulfeto (Cebola)	-0,557	-0,549
dimetil sulfito (DMS)	-0,359	-0,750
Ácido butírico	-0,914	-0,019
Etilbutirato	-0,926	0,032
Hexoato	-0,734	-0,020

Tabela 19 - (continuação) Correlações de cada um dos atributos com os componentes principais 1 e 2

ATRIBUTO	CP 1	CP 2
3-metil-2-butano-1-tiol (<i>Light struck</i>)	-0,137	-0,813
Ácido Isovalérico	-0,845	0,007
Sulfato de ferro (Metálico)	-0,990	-0,087
Styrene (Plástico)	-0,729	-0,215
Guaiaicol (Defumado)	-0,850	-0,187
4 vinil guaiacol (Fenólico)	-0,006	0,946
<i>p</i> -mentano-8 tiol-3-ona (Gato)	-0,734	0,673

Fonte: elaborado pela autora.

Como exemplo de interpretação, observa-se que Ácido acético tem correlação de 0,886 com o primeiro componente principal. Observando o Gráfico 13 notamos que os sensores MQ1135 e MQ4 têm escores altos com este componente, quando comparados com os demais sensores. Como ácido acético tem correlação positiva com este componente, portanto infere-se que a média de ácido acético é maior para os sensores MQ1135 e MQ4 do que aquelas observadas nos outros sensores, os quais apresentam menores escores neste componente.

As médias observadas para este atributo, para cada um dos sensores, são apresentadas na Tabela 20. Uma análise direta confirma a avaliação feita com base no gráfico dos escores e nas correlações deste atributo com o componente principal 1. Como pode ser observado, MQ1135 e MQ4 apresentam maiores médias neste atributo.

Tabela 20 - Médias observadas para o ácido acético em relação aos diferentes tipos de sensores

ATRIBUTOS	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8
Ácido acético	4,3	4,2	3,6	3,4	3,5	2,8

Fonte: elaborado pela autora.

Outro exemplo é o acetato de isoamila, que tem correlação -0,936 com o primeiro componente principal. Observando o Gráfico 13 notamos que os sensores MQ8 e MQ2 têm escores menores com este componente quando comparados com os demais sensores.

Como ácido de isoamila tem correlação negativa com este componente, infere-se que a média de ácido de isoamila é maior para os

sensores MQ8 e MQ2 do que aquelas observadas nos outros sensores, os quais apresentam maiores escores neste componente.

Tabela 21 - Médias observadas para o áde isoamila em relação aos diferentes tipos de sensores

ATRIBUTOS	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8
Acetato de isoamila	2,4	2,4	4,2	3,3	3,3	3,8

Fonte: elaborado pela autora.

Mais um exemplo é a terra molhada ou ethil fenhol, que tem correlação 0,964 com o segundo componente principal. Observando o Gráfico 13 percebemos que o sensor MQ1135 tem escore maior com este componente quando comparado com os demais sensores.

Como etil fenhol (terra molhada) tem correlação positiva com este componente, infere-se que a média de etil fenhol é maior para o sensor MQ1135 do que aquelas observadas nos outros sensores, os quais apresentam menores escores neste componente.

Tabela 22 - Médias observadas para terra molhada ou ethil fenhol em relação aos diferentes tipos de sensores

ATRIBUTOS	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8
Terra molhada ou Ethil fenhol	4,8	2,3	3,4	2,9	3,3	3,4

Fonte: elaborado pela autora.

Outro exemplo ainda é o 3-metil-2-butano-1-tiol (*light struck*), que tem correlação -0,813 com o segundo componente principal. Observando o Gráfico 13 notamos que o sensor MQ4 tem escore menor com este componente quando comparado com os demais sensores.

Como 3-metil-2-butano-1-tiol (*light struck*) tem correlação negativa com este componente infere-se que a média de 3-metil-2-butano-1-tiol (*light struck*) é maior para o sensor MQ4 do que aquelas observadas nos outros sensores, os quais apresentam maiores escores neste componente.

Tabela 23 - Médias observadas para 3-metil-2-butano-1-tiol (*light struck*) em relação aos diferentes tipos de sensores

ATRIBUTOS	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8
3-metil-2-butano-1-tiol (<i>Light struck</i>)	2,1	4,5	4,2	3,1	2,7	3,5

Fonte: elaborado pela autora.

Na Tabela 24 são apresentadas novamente as médias das avaliações para cada atributo de acordo com os sensores. Também são apresentados novamente e as correlações com os componentes principais 1 e 2, para cada um dos atributos.

4.6 REDE NEURAL PNN

Objetivando verificar uma identificação de padrões foi realizada a amostragem de leitura dos compostos, uma nova classificação foi testada com a rede PNN para cada 2 sensores, foi utilizando-se a técnica de *bootstrap* (reamostragem) Somente acertos acima de 80% de aprendizado foram plotados. Os resultados dessa classificação são ilustrados nas Figuras 42 a 47.

A técnica de *bootstrap* (reamostragem) consiste na obtenção de medidas de dispersão, (como a média, variância ou desvio-padrão) através da aplicação de métodos tradicionais, de inferência e estimação, a diversos conjuntos de dados obtidos a partir de um único conjunto original mediante a geração de dados aleatórios com a mesma média e desvio padrão dos originais (FERREYRA RAMÍREZ, 2005).

O Quadro 1 organiza as legendas para as figuras de PNN e compostos/atributos respectivos (Figuras 42-47).

Tabela 24 - Médias das avaliações dos sensores e correlação com os componentes

ATRIBUTOS	MÉDIAS DAS AVALIAÇÕES						CORRELAÇÕES COM OS COMPONENTES	
	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8	CP 1	CP 2
Ácido acético	4,3	4,2	3,6	3,4	3,5	2,8	0,886	0,107
Diacetil ou 2,3 butanodiona	3,6	2,7	4,3	3,0	2,9	4,2	-0,615	0,407
H ₂ S ou sulfeto de hidrogênio	2,3	1,8	4,1	3,6	2,8	3,6	-0,961	0,086
Acetato de isoamila	2,4	2,4	4,2	3,3	3,3	3,8	-0,936	-0,090
Ranço ou trans, trans-2,4 heptadienal	2,3	2,8	3,9	3,3	3,2	4,8	-0,874	-0,209
Geosmina	1,8	2,1	3,2	2,8	2,9	3,2	-0,934	-0,271
Mel ou etil fenilacetato	1,8	2,4	3,6	3,2	2,8	3,7	-0,937	-0,328
Musty - 2,4,6 trichloroanisole	4,6	3,2	3,9	2,9	2,8	3,3	0,250	0,699
Methional	2,1	2,2	3,6	4,1	2,7	3,4	-0,869	-0,110
Metanotiol (Mercaptano)	1,8	4,1	4,3	2,8	3,1	3,3	-0,251	-0,830
2-acetyl pyridine (Malte Buscuit)	2,2	1,8	3,6	3,1	2,6	3,4	-0,979	0,095
Terra molhada ou Ethil fenchol	4,8	2,3	3,4	2,9	3,3	3,4	0,069	0,964
Acetaldeído	2,3	4,3	3,4	2,7	2,9	3,7	0,010	-0,809

Tabela 24 - (continuação) Médias das avaliações dos sensores e correlação com os componentes

ATRIBUTOS	MÉDIAS DAS AVALIAÇÕES						CORRELAÇÕES COM OS COMPONENTES	
	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8	CP 1	CP 2
Ácido láctico	2,2	1,8	3,4	3,3	2,7	4,6	-0,931	0,097
Amêndoas ou benzaldeído	4,6	2,2	3,8	3,2	2,8	3,7	-0,220	0,920
Acetato de etila	2,2	2,1	3,4	4,3	2,8	3,5	-0,854	-0,033
Baunilha	2,2	1,8	3,3	3,1	4,1	3,3	-0,709	-0,003
Caprilico	2,8	1,9	3,2	4,2	3,2	3,4	-0,762	0,290
2,6 diclorofenol	2,8	1,9	3,2	3,1	2,8	3,3	-0,872	0,484
Gerânio	4,6	2,2	3,2	3,1	2,8	3,5	-0,035	0,984
Grama fresca ou cis 3 hexanol	3,8	1,8	3,3	3,1	2,8	3,5	-0,455	0,886
Óleo de lúpulo ou extrato oleoso de lúpulo	2,2	2,1	3,3	3,8	2,8	3,4	-0,919	-0,033
Papel ou trans-2-nonenal	3,8	1,9	3,2	2,9	2,8	3,7	-0,426	0,868
Bicarbonato de sódio (Alcalino)	1,8	1,8	3,2	2,8	2,6	3,3	-0,990	-0,087
2-bromofenol	4,1	2,3	3,4	2,9	2,8	3,0	-0,024	0,934
Dimetiltrisulfeto (Cebola)	2,1	3,4	4,6	3,1	2,8	3,4	-0,557	-0,549

Tabela 24 - (continuação) Médias das avaliações dos sensores e correlação com os componentes

ATRIBUTOS	MÉDIAS DAS AVALIAÇÕES						CORRELAÇÕES COM OS COMPONENTES	
	MQ1135	MQ4	MQ2	MQ3	MQ7	MQ8	CP 1	CP 2
dimetil sulfito (DMS)	1,9	3,8	4,2	2,8	2,8	3,4	-0,359	-0,750
Ácido Butírico	2,1	2,1	3,4	3,2	2,6	4,5	-0,914	-0,019
Etilbutirato	2,2	1,9	3,5	3,9	2,8	3,4	-0,926	0,032
Hexoato	2,3	2,2	3,3	4,7	2,7	3,4	-0,734	-0,020
3-metil-2-butano-1-tiol (<i>Light struck</i>)	2,1	4,5	4,2	3,1	2,7	3,5	-0,137	-0,813
Ácido Isovalérico	2,3	2,3	3,5	3,1	2,5	4,8	-0,845	0,007
Sulfato de ferro (Metálico)	1,8	1,8	3,2	2,8	2,6	3,3	-0,990	-0,087
Styrene (Plástico)	2,2	2,4	3,9	3,0	4,3	3,8	-0,729	-0,215
Guaiacol (Defumado)	2,2	2,3	4,3	3,4	3,8	3,5	-0,850	-0,187
4 vinil guaiacol (Fenólico)	4,9	2,2	3,5	2,8	2,8	3,6	-0,006	0,946
p-mentano-8 tiol-3-ona (Gato)	3,5	2,4	3,5	3,5	3,2	3,8	-0,734	0,673

Fonte:

elaborado

pela

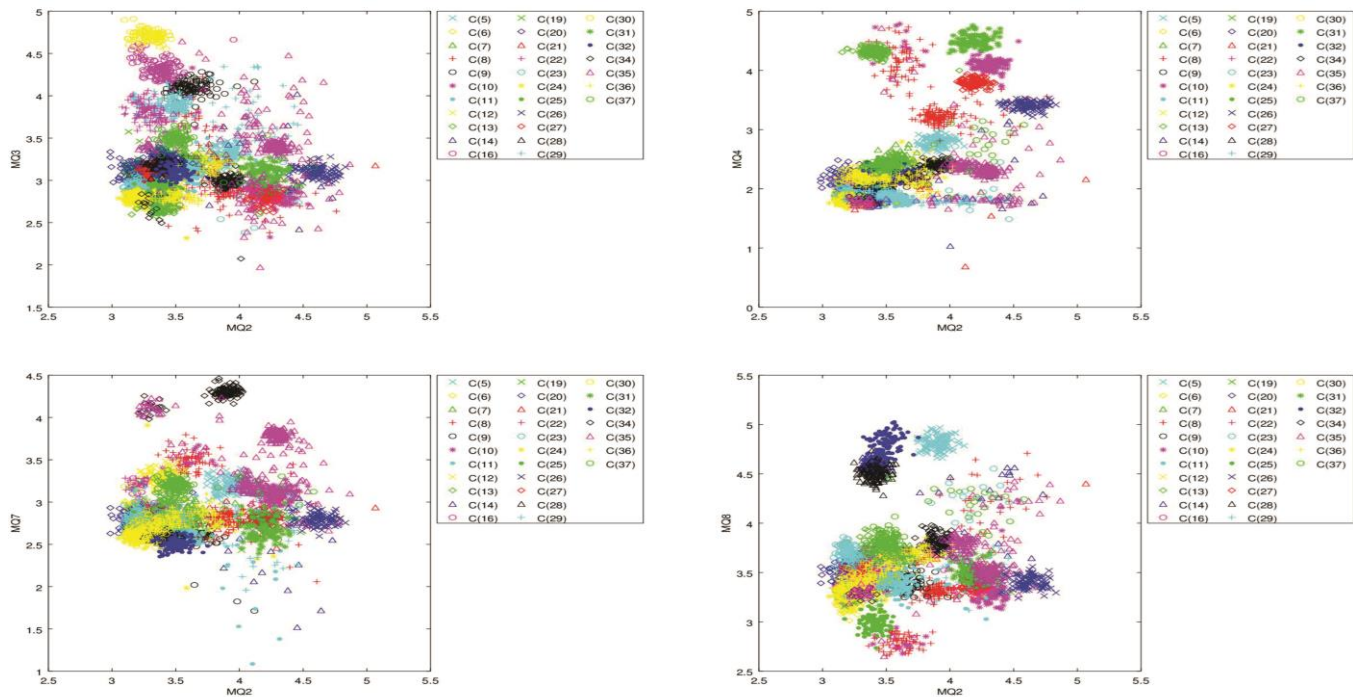
autora.

Quadro 1 - Legenda para as figuras de PNN e compostos/atributos respectivos

+ Acido acetico	△ Grama fresca ou cis 3 hexanol
○ Diacetil ou 2-3 butanodiona	+ Oleo de lupulo ou extrato oleoso de lupulo
* h ₂ s ou sulfeto de hidrogenio	○ Papel ou trans-2-nonenal
● Acetato de isoamila	* Alcalino
× Ranco ou trans-2-4 heptadienal	● Bromofenol
◇ Geosmina	× Cebola
△ Mel ou etil fenilacetato	◇ DMS
+ Musty - 2-4-6 trichloroanisole	△ Acido Butirico
○ Methional	+ Etilbutirato
* Mercaptano	○ Hexoato
● Malte Biscuit	* Light Struck
× Terra molhada ou Ethil fenchol	● Isovalerico
◇ Acetaldeido	× Metalico
△ Acido latico	◇ Plastico
+ Amendoas ou benzaldeido	△ Defumado
○ Acetato de etila	+ Fenolico
* Baunilha	○ Gato
● Caprilico	
× 2-6 diclorofenol	
◇ Geraniol	


Fonte: elaborado pela autora.

Figura 42 - PNN para classificação dos compostos sensores MQ2 e suas interações



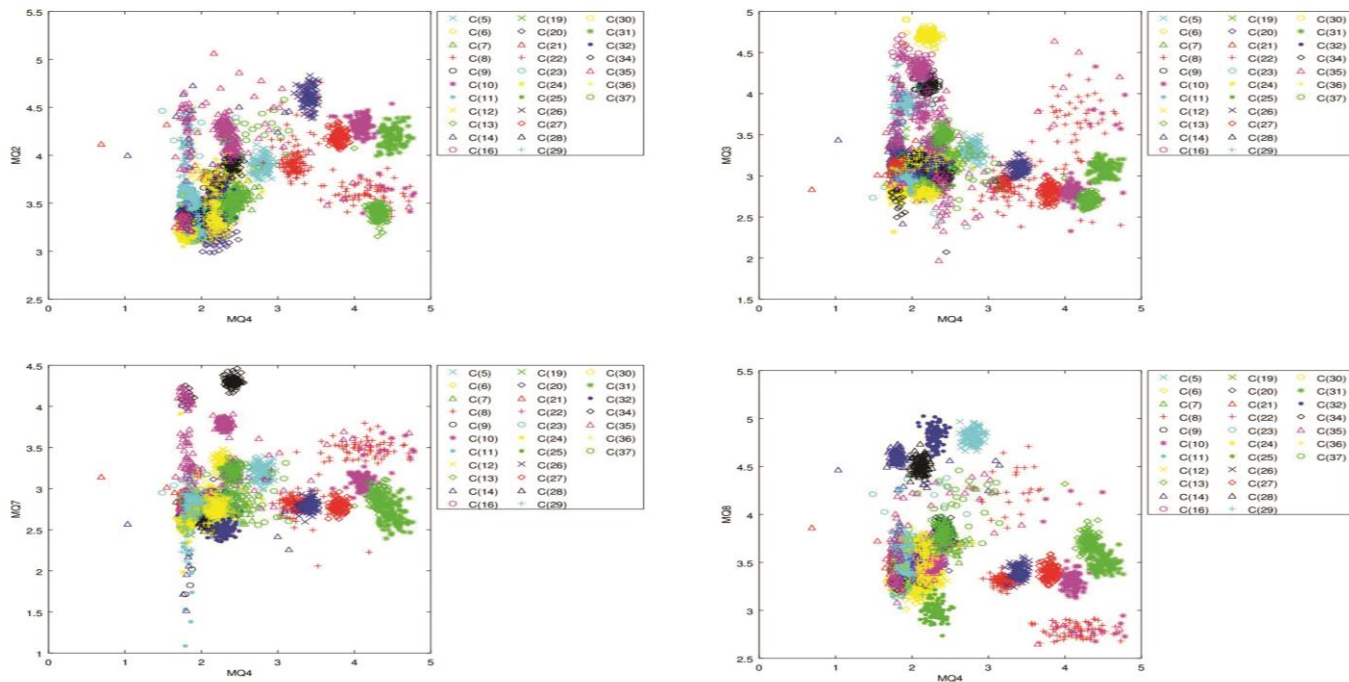
Fonte: elaborado pela autora.

Figura 43 - PNN para classificação dos compostos dos sensores MQ3 e e suas interações



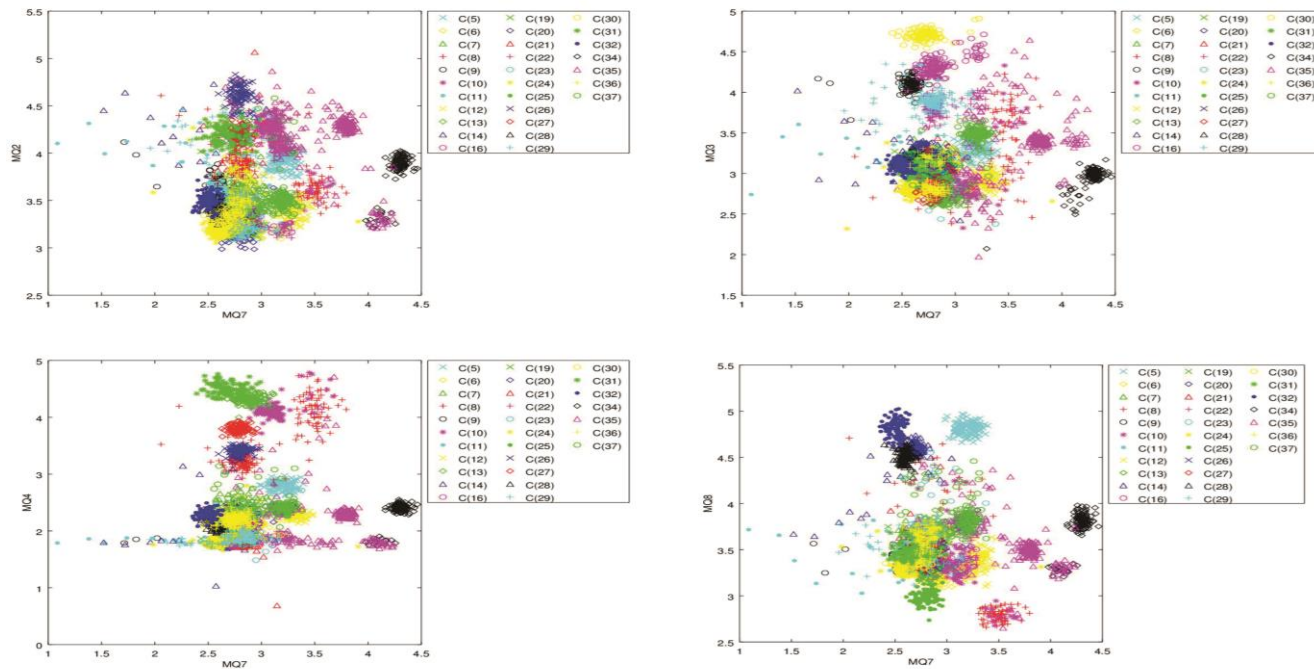
Fonte: elaborado pela autora.

Figura 44 - PNN para classificação dos compostos MQ4 e suas interações




Fonte: elaborado pela autora.

Figura 45 - PNN para classificação dos compostos sensores MQ7 e suas interaçõesF



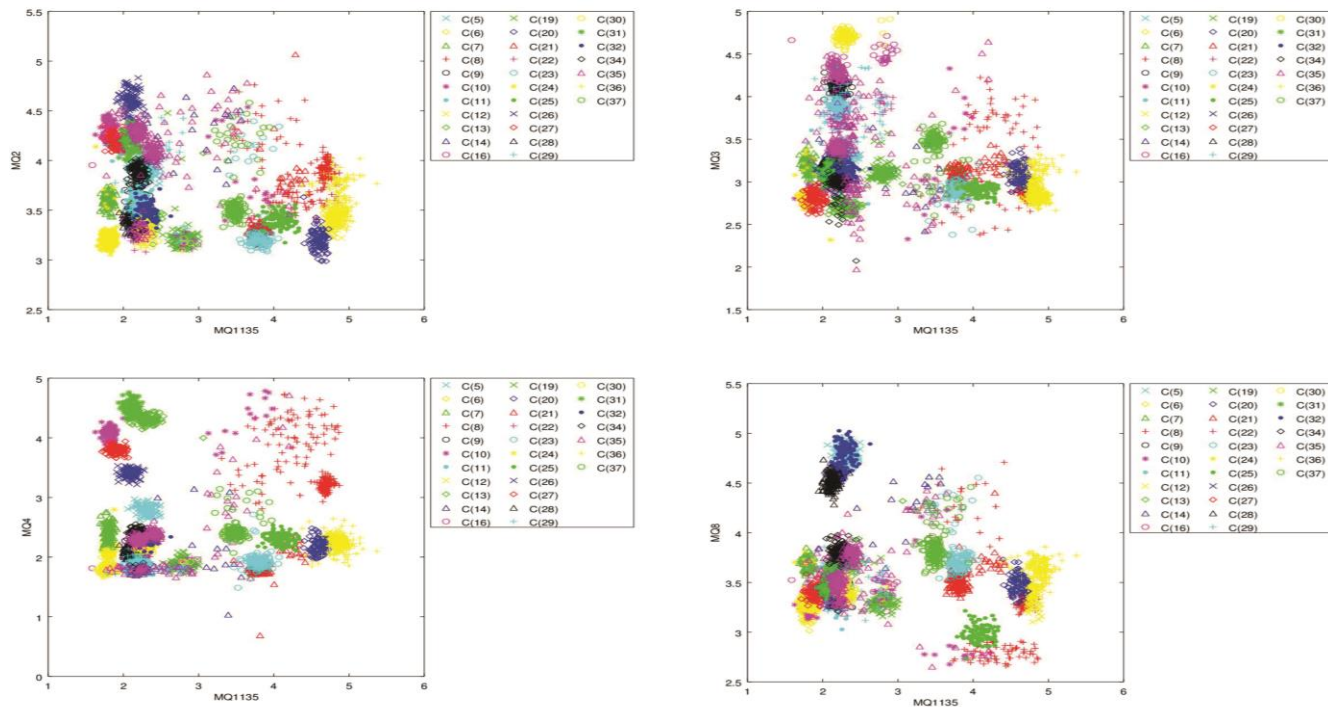
Fonte: elaborado pela autora.

Figura 46 - PNN para classificação dos compostos sensores MQ8 e suas interações



Fonte: elaborado pela autora.

Figura 47 - PNN para classificação dos compostos sensores MQ1135 e suas interações



Fonte: elaborado pela autora.

Pode-se observar que, para todas as combinações dos sensores, os compostos ácido acético, 2,3 butanodiona (diacetil), sulfeto de hidrogênio (H₂S), Acetato de isoamila, amêndoas, baunilha, caprílico e sulfato de ferro (metálico) tiveram baixo desempenho e não foram identificados nas combinações entre os sensores. O composto acetato de etila teve baixo índice de acerto (menor que 80%) para as combinações: MQ3 com MQ2 e MQ3 com MQ4. Os demais componentes tiveram alto índice de acerto pela rede, porém houve um *overlap* para boa parte dos compostos mostrando que as combinações dos sensores realizadas respondem de forma significativa para mais de um composto sugerindo que seria necessário mais sensores para melhor classificação desses compostos ou ainda testar diferentes combinações de sensores. A rede testada teve 86% de acertos do conjunto de teste. Segundo Bishop (1995), os métodos estatísticos de classificação têm seu desempenho limitado pela variabilidade dos dados e pela sobreposição das classes no espaço multidimensional das variáveis de entrada. Segundo Haykin (2001), um classificador MLP, usando a função logística como não-linearidade, aproxima-se de um classificador baseado em uma estatística baesiana, desde que o tamanho do conjunto de treinamento seja suficientemente grande e que o processo de aprendizagem por retropropagação não fique preso em um mínimo local. Durante a otimização dos parâmetros através da metodologia simplex sequencial foi observado que várias redes com arquiteturas diferentes convergiram para uma porcentagem de classificação correta em torno de 90% para a validação e 75% para o teste.

As técnicas de reconhecimento de padrões utilizadas por Santos (2000) foram redes neurais artificiais MLP, RBF e Elman. Yamazaki (2001) também fez uso da rede neural MLP e utilizou a rede TDNN para verificar a possível relação temporal existente na aquisição dos dados. Zanchettin (2004) também utilizou MLP e algumas redes com atraso no tempo, como redes *Feature-weighted detector* e *Evolving Fuzzy Neural Networks*. Ferreira (2004) comparou MLP, RBF, TDNN e PNN.

Em seu trabalho, Bona (2008) identificou que redes perceptron de múltiplas camadas apresentaram uma performance satisfatória para o apoio na tomada de decisão durante a classificação de cafés solúveis em diferentes bancos de dados utilizados. Para o banco de dados industrial, que continha vários produtos, ficou evidente que a maneira como as classes são representadas é fundamental para o sucesso do classificador.

A combinação do nariz eletrônico com as redes neurais artificiais mostrou ser uma alternativa promissora para o desenvolvimento de

novos produtos, comparação de similaridades entre produtos concorrentes e para o controle da qualidade aromática de café solúvel (BONA, 2008).

As possíveis técnicas de redes neurais que podem ser utilizadas são as mesmas utilizadas em trabalhos que fazem uso de bases de dados obtidas pelos protótipos de nariz artificial criados por Santos (2000), Yamazaki (2001), Zanchettin (2004) e Ferreira (2004).

A Tabela 25 sumariza as taxas de classificação correta utilizando a rede PNN no conjunto de treinamento e no conjunto teste, resumindo o desempenho da rede neural.

Tabela 25 - Resultados utilizando a rede PNN. Taxas de classificação correta para o conjunto treinamento e para o conjunto de teste

Números de neurônios selecionados	37
Smoothing parameter	0,1
Taxa de classificação correta (conjunto de treinamento)	91%
Taxa de classificação correta (conjunto de teste)	86%

Fonte: Elaborado pela autora.

As taxas de classificação correta de ambos os conjuntos demonstram que as redes PPN foram capazes de classificar corretamente um número apreciável de dados coletados pelo aparato do nariz eletrônico e apontam para o sucesso do emprego desse tipo de rede. Os resultados obtidos destacam a relevância de se utilizar redes do tipo PPN. Como já foi mencionado, essas redes possuem vantagens como treinamento, que é realizado em apenas um passo, e a garantia de que a superfície de decisão se aproxima dos limites de uma decisão Bayseana ótima, à medida em que o número de exemplos de treinamento cresce (SPECHT, 1990). Adicionalmente, o tempo de resposta dessas redes é um atrativo a mais, já que o curto tempo necessário para o treinamento pode ser um diferencial no funcionamento de um aparato como o *enose*. O presente estudo demonstrou que a rede PNN é uma ferramenta interessante para ser implementada em narizes eletrônicos, especialmente quando aliada a um poderoso banco de dados armazenando os exemplos de treinamento.

Por fim, A Tabela 26 apresenta a porcentagem de acertos dos painéis treinado e não treinado e do nariz eletrônico utilizando a rede PNN.

Tabela 26 - Resultados utilizando a rede PNN, apresentando a porcentagem de acertos do painel não treinado, painel treinado e nariz eletrônico com rede PNN

MÉTODO	PORCENTAGEM DE ACERTOS
Painel não treinado	28%
Painel treinado	47%
Nariz eletrônico com PNN	86%

Fonte: Elaborado pela autora.

A baixa porcentagem de acertos encontrada para o painel não treinado é, de certa forma, esperada. Avaliar amostras de cerveja quanto aos aromas percebidos é uma atividade que pode levar considerável tempo para que seja executada com acurácia. Um painel não treinado, desprovido da experiência necessária, pode ser levado a erros de avaliação grosseiros e não conseguir separar as diferentes percepções que levam a detecção dos aromas, criando um resultado difuso e pouco confiável.

O valor de porcentagem de acerto encontrado para o painel treinado revela a importância de aplicar treinos em uma equipe, sendo o resultado bem maior do que se obteve com o painel não treinado. Para avaliar de forma menos subjetiva a cerveja, faz-se necessário empregar técnicas e procedimentos que são apresentados de antemão ao julgador treinado que, por meio da experiência, vai assimilando os aromas e criando a habilidade de reconhecê-los mais prontamente e de maneira mais confiável. Como exemplo da importância do treinamento, cita-se aqui que Barnabé et al. (2007) utilizaram a análise descritiva quantitativa para avaliar vinhos produzidos com uva niágara rosada e bordô. Os autores submeteram um grupo a um treinamento prévio e seleção dos provadores antes de submeter as amostras à avaliação pelo painel. O treinamento consistiu em 8 avaliações de duas amostras de vinho, sendo que os provadores tinham a sua disposição prévia uma lista com os atributos e eram solicitados a provar as referências de cada atributo.

Embora a porcentagem encontrada para o painel treinado evidencie, por um lado, uma melhora indiscutível quanto ao painel não treinado, por outro lado deixa clara a pobreza de acertos, não chegando nem à metade do total. O painel treinado, embora seja composto por pessoas com conhecimento prévio e experiência em avaliar amostras e detectar aromas, enfrenta o problema da subjetividade do avaliador e susceptibilidade ao erro. É certo que o treinamento auxilia nas decisões

certadas, mas o resultado encontrado alerta para uma margem de erro grande, o que pode fazer com que a avaliação seja, em certo ponto, pouco confiável, como acontece com o painel não treinado. Salienta-se que o painel treinado leva tempo para ser formado e esforços, inclusive financeiros, são gastos para que ele de fato possa servir de avaliador de cervejas.

A tecnologia de nariz eletrônico é ainda mais atrativa quando as porcentagens de acerto são comparadas. A porcentagem de acerto para o equipamento é quase o dobro se comparada com o painel treinado, e tende a ser bem mais próxima de uma valor aceitável (em que 100% seria a melhor referência). A utilização do nariz eletrônico associado à rede PNN é, então, uma saída bastante interessante e representa um ganho real na confiabilidade da análise sensorial de cerveja.

5 CONCLUSÕES

A análise dos resultados obtidos no decorrer deste trabalho conduziu às seguintes conclusões:

O desenvolvimento do protótipo sugerido neste trabalho foi realizado com sucesso, sendo que todos os componentes do mesmo funcionaram adequadamente até o final dos testes.

Os testes realizados com diferentes grupos de painel sensorial sendo eles um grupo treinado e outro não treinado possibilitou comparar os resultados entre ambos grupos, onde o grupo treinado obteve maior desempenho de acertos comparado com o grupo sem treino, dessa forma podemos afirmar que quando o painel sensorial é utilizado como ferramenta para detectar aromas e sabores na cerveja o mesmo deve seguir treinamento prévio.

A PNN apresentou uma performance satisfatória para o apoio na tomada de decisão durante a classificação de compostos aromáticos da cerveja. O incremento na melhora da porcentagem de acerto, quando comparado com a porcentagem de acerto dos grupos não treinado e treinado evidenciam a potencialidade do aparato. Para aumentar o desempenho da do nariz eletrônico, espera-se que a adição de novos sensores desempenhe uma redução do *overlap* e possibilite, com adição de novos tipos, a caracterização de mais compostos, o que faria com que o sensor aumentasse sua capacidade de percepção.

A combinação do nariz eletrônico com PNN mostrou ser uma alternativa promissora para o desenvolvimento de novos produtos, comparação de compostos aromáticos que podem afetar a qualidade aromática de cervejas comerciais. Especialmente, espera-se uma melhora constante dos resultados fornecidos pela rede PNN à medida que o número de exemplos de treinamento cresce.

As pesquisas para desenvolvimento de equipamentos que simulem o olfato humano têm se desenvolvido bastante. Dentro deste contexto, este trabalho se concentra na investigação de diferentes técnicas que podem ser utilizadas para criação de sistemas de reconhecimento de padrões de odor para narizes artificiais.

Os narizes eletrônicos possuem aplicações futuras extremamente promissoras, pois atuam de uma forma que é de grande interesse para muitos setores da indústria alimentícia e área de saúde, no auxílio ao controle de qualidade, além do fato de evitar que a exposição humana a gases tóxicos. No tocante às indústrias cervejeiras, a tecnologia de narizes e línguas eletrônicos pode ser útil em mais de uma etapa do processo, e encontra aplicações que diminuem o tempo de análise,

custos com análises subjetivas e aumenta a eficiência, por se tratar de equipamentos que, se bem construídos, calibrados e educados podem fornecer resultados precisos e em escalas de sensibilidade além da humana. Eles são uma saída interessante, especialmente para a área de controle de qualidade (teste de aromas presentes no produto, sabores desagradáveis que comprometem grandes quantidades de cerveja produzida) e, para um processo de produção com rigoroso controle, têm sua aplicação nas diversas etapas, evitando que o produto tenha sua qualidade comprometida por meio das inspeções contínuas (e independentes) que esses instrumentos são capazes de realizar.

5.1 PERSPECTIVAS FUTURAS

Dado o resultado obtido neste trabalho, uma das perspectivas futuras é a possibilidade de utilizar outras abordagens de redes neurais artificiais adaptando-as a algum modelo biológico olfativo com a finalidade de verificar os resultados obtidos por essas técnicas e, até mesmo compará-los, com as técnicas utilizadas no presente trabalho. Algumas sugestões para trabalhos futuros são:

- Testar mais sensores;
- Testar diferentes tipos de Redes Neurais afim de verificar a que melhor define os padrões a serem identificados,
- Realizar teste com misturas de atributos,
- Testar diferentes bases de cerveja;
- Aumentar o banco de dados de compostos aromáticos.
- Desenvolver modelo comercial

REFERÊNCIAS

ABNT. ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 14140**: alimentos e bebidas - análise sensorial - teste de análise descritiva quantitativa (ADQ). Rio de Janeiro, 1988.

AGUILERA, T.; LOZANO, J.; PAREDES, J.; FERNANDO, J.; SUAREZ, J. Electronic nose based on independent component analysis combined with partial least squares and artificial neural networks for wine prediction. In: **Sensors**, v. 12, p. 8055-8072, 2012.

ALVISI, F. **Manual de treinamento técnico cervejeiro**. AmBev, 2011.

ANESS, B.J; BAMWORTH, C.W. Dimethyl sulphide - a review. In: **Journal of the Institute of Brewing**, v. 88, p. 244-252, 1982.

APETREI, C.; VILLANUEVA, S.; SAJA, J. Combination of an e-nose, an e-tongue and an e-eye for the characterisation of olive oils with different degree of bitterness. In: **Analytica Chimica Acta**, v. 663, n. 1, p. 91-7, 2010.

ARKIMA, V. Eur. **Brew. Conv.**, Proc. 12th Congr., Interlaken (1969), 507-514 p.

ASBC. AMERICAN SOCIETY OF BREWING CHEMISTS. **Methods of analysis of American Society of Brewing Chemists**. 8. ed. Saint Paul Minnesota, USA: ASBC, 1996.

BASSO, T. O. **Melhoramento da fermentação alcoólica de *Saccharomyces cerevisiae* por engenharia evolutiva**. Tese (Doutorado). São Paulo, 2011.

BLAKE, R.; SEKULER, R. **Perception**. 5. ed. Boston: McGraw-Hill, 2006.

BONA, Evandro. Integração de redes neurais artificiais ao nariz eletrônico: Avaliação aromática de café solúvel. 2008.

BOSQUIROLI, G. **Seleção, treinamento de jogadores e caracterização da cerveja pilsen nacional**. Tese (Doutorado)- Universidade Federal do Paraná, Curitiba, PR, 1996.

CHATTERJEE, D.; BHATTACHARJEE, P.; BHATTACHARYYA, N. Development of methodology for assessment of shelf-life of fried potato wedges using electronic noses: sensor screening by fuzzy logic analysis. In: **Journal of Food Engineering**, v. 133, p. 23-29, 2014.

CLAPPERTON, J.F.; BROWN, D. G. W. **Journal of the Institute of Brewing**, n. 84, 90p, 1978.

CLARKE, B.J.; DAVINE, B.F., HAWTHORNE, D.B; KAVANAGH, T.E.; MOULDER, P. J. Factors affecting the formation of medium chain fatty acids in beer and other fermented media. In: **Technique Quarterly Master Brewers Association of the Americas**, v. 18, p. 188-194, 1981.

DALGLIESH, C.E., **Eur. Brew. Conv.** , Proc. 16th Congr. ,Amsterdam (1977), 623-659 p.

DIPAN CHATTERJEE et al. Development of methodology for assessment of shelf-life of fried potato wedges using electronic noses: Sensor screening by fuzzy logic analysis. In: **Journal of Food Engineering**, v. 133, p. 23-29, fev. 2014.

D-ROBOTICS UK. **DHT11 Humidity & Temperature Sensor**, 2010.

FERREIRA, A.A. 2004. **Comparação de arquiteturas de redes neurais para sistemas de reconhecimento de padrões em narizes artificiais**. Dissertação (Mestrado)- Centro de Informática, Universidade Federal de Pernambuco - UFPE, Recife, PE, 2004.

FERREIRA, A.G; ACAR, A. Olfato - atualização (2.^a parte). In: **Revista Brasileira de Otorrinolaringologia**, v. 41, ed. 3, set.-dez. 1975.

FERREYRA RAMÍREZ, E. F. Modelo conexcionista para avaliação de propostas para aquisição de equipamentos médico-hospitalares. Campinas, 2005. Tese de Doutorado, (Universidade de Campinas)

GOSTELOW, P.; PARSONS, S. A.; STUETZ, R. M. Odour measurements for sewage treatment work. In: **Water Research**, v. 35, n. 3, p. 579-597, fev. 2001.

GREB, R. Microelectronic nose detects and recognizes gases to save lives. In: **Planeering Science and Technology**, v. 20, n. 3, 2002.

GRUBER, J. et al. Nariz eletrônico polimérico para discriminar diferentes tipos de cerveja. Sociedade Brasileira de Química (SBQ). In: **33ª Reunião Anual da Sociedade Brasileira de Química**, 2010.

GUNST, F.; VERZELE, M. On the sunstruckflavour of beer. In: **Journal of the Institute of Brewing**, v. 84, p. 291-292, 1978.

HANWEI ELETRONICS CO. **MQ-4 technical data**.

HANWEI ELETRONICS CO. **MQ-8 technical data**.

HAYKIN, S. **Neural networks: a comprehensive foundation**. New Jersey: Macmillan Publishing Company, 1994.

HERMIA, J.; TERMONIA, M.; VIGNERON, S. **VOC measurements in paint workshops**. Characterization and control of odours and VOC in the process industries. Amsterdam: Elsevier, 1994. p. 77-90.

HONG, X.; WANG, J. Application of e-nose and e-tongue to measure the freshness of cherry tomatoes squeezed for juice consumption. In: **Analytical Methods**, v. 6, p. 3133-3138, 2014.

HONG, X.; WANG, J. Detection of adulteration in cherry tomato juices based on electronic nose and tongue: comparison of different data fusion approaches. In: **Journal of Food Engineering**, v. 126, p. 89-97, fev. 2014.

KELLER, P. E.; PRIDDY, K. L. Physiologically inspired pattern recognition for electronic noses. In: KELLER, P.E.; FOGEL, D.B.; BEZDEK, J. C.(Eds.). **Proceedings of SPIE on the applications and science of computational intelligence II**, v. 3722, n. 13, p. 144-152, 1999.

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

KUCK, L. S. **Cerveja: sabor e aroma**. 2008. 46f. Trabalho acadêmico - Graduação em Química de Alimentos. Universidade Federal de Pelotas, Pelotas.

LISBOA, H.; PAGE, T.; GUY, C. Gestão de odores: fundamentos do nariz eletrônico. In: **Engenharia Sanitária Ambiental**, v. 14, n. 1, p. 9-18, 2009.

LIU, X.; CHENG, S.; LIU, H.; et al. A Survey on Gas Sensing Technology. **Sensors** 2012.

MALAKA, R.; RAGG, T. Artificial neural networks for modelling chemosensoryreception. In: DAGLI, C.H.; FERNÁNDEZ, B.; GHOSH, J.; KUMARA,S.R.T. (Eds). **Intelligent engineering systems through artificial neuralnetworks**. v. 4. New York: ASME Press, 19??. 61-68 p.

MARCHIORI, D.; WARGLIEN, M. Predicting human interactive learning by regret-driven neural networks. In: **Science**, v. 319, n. 5866, p. 1111-1113, 2008.

MARSILI, R. **The electronic nose**. Food Product Design, 1995.

McMURROUGH, I.; ROCHE, G.P.; CLERY, K.G. In: **Journal of the Institute of Brewing**, v. 90, p. 181-187, 1984.

MEBAK, Selbstverl. der. **Wort, Beer, Beer-based Beverages: Collection of Brewing Analysis Methods of the Mitteleuropäische Brautechnische Analysenkommission**. Editor Fritz Jacob. 2013.

MEDELIUS, P.J. Nano sensors for gas detection in space and ground support applications (ASRC Aerospace Corporation, M/SASRC-19). In: **Proceedings of MNT for Aerospace Applications**, CANEUS, 2006.

MEILGAARD, M.C.; PEPPARD, T.L. In: MORTON, I.D.; MACLEOD, M.J. (Eds). **Food Flavours**. Part B: the flavour of beverages. Amsterdam: Elsevier, 1986. 147p.

OETTERER, M.; REGITANO-D'ARCE, M. A. B.; SPOTO, M.H.F. **Fundamentos de ciência e tecnologia de alimentos**. Barueri: Manole, 2006. 613p.

ORTEGA, F. Neurosciences, neuroculture and cerebral self-help. In: **Interface - Comunic., Saude, Educ.**, v. 13, n. 31, p.247-60, out./dez. 2009.

OUELLETTE, J. Electronic noses sniff out new markets. In: **The Industrial Physicist**, v. 5, n.1, p. 26-29, 1999.

PACHECO, T. F. **Fermentação alcoólica com leveduras de características floculantes em reator tipo torre com escoamento ascendente**. Dissertação (Mestrado). Uberlândia, 2010.

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

PAVIA, D.L.; LAMPMAN G.M.; KRITZ, G.S.; RANDALL, G. ENGEL. **Introduction to organic laboratory techniques**. 4. ed. Thomson Brooks/Cole: 2006. p. 797-817.

PERIS, M.; ESCUDER-GILABERT, L. A 21st century technique for food control: electronic noses. In: **Analytica Chimica Acta**, v. 638, p. 1-15, 2009.

PIAGGIO, G. **The electronic nose**. Electronic book. Pisa: Università di Pisa, 2009.

REGAZZI, A. J. **Análise multivariada**. Viçosa: Universidade Federal de Viçosa, Centro de Ciências Exatas e Tecnológicas. Departamento de Informática, 2001. 166p.

RIUL JR, A. A ciência imitando o corpo humano. In: **Revista Physicae** - Revista da Associação dos Pós-Graduandos em Física da Universidade Estadual de Campinas, n. 3, p. 39-46, 2002. .

RIUL JR, A. et al. An artificial taste sensor based on conducting polymers. In: **Biosensors and Bioelectronics**, v. 18, p. 1365-1369, 2003.

RÖCK, F.; BARSAN, N.; WEIMAR, U. In: **Chemical Reviews**, v. 108, p. 705, 2008.

SANTOS, M. S. 2000. **Construção de um nariz artificial usando redes Neurais**. Tese (Doutorado)- Centro de Informática, Universidade Federal de Pernambuco - UFPE, Recife, PE, 2000.

SHAFIQL, I. A. 2007. **Fabrication of electronic nose and its application for the verification of euricomalongifolia extracts**. Tese (Doutorado)- Universiti Sains, Malaysia, 2007.

SHVARTSBURG, A. **Differential ion mobility spectrometry: nonlinear ion transport and fundamentals of faims**. 2. ed. Boca Raton, FL, USA: CRC Press, 2008.

SILVA, L. 2003. **Modelo de rede neural artificial treinada com o algoritmo backpropagation**. Monografia (Graduação)- Universidade Federal de Juiz de Fora, Juiz de Fora, MG, 2003.

SILVA, L.; DONNICI, C. Traçadores: o uso de agentes químicos para estudos hidrológicos, ambientais, petroquímicos e biológicos. In: **Química Nova**, v. 32, n. 6, São Paulo, p. 1-10, 2009.

SOHN, J.H.; SMITH, R.J.; YOONG, E. Process studies of odour emissions from effluent ponds using machine-based odour measurement. In: **Atmospheric Environment**, v. 40, n. 7, p. 1230-1241, 2006.

SOVRANO, S.; BUIATTI, S.; ANESE, M. Influence of malt browning degree on lipoxigenase activity. In: **Food Chemistry**, v. 99, p. 711-717, 2006.

STITZEL, S.; AERNECKE, M.; WALT, D. Artificial noses. In: **Annual Review of Biomedical Engineering**, v. 13, p. 1-25, 2011.

STONE, H.; SIDEL, J.L. Descriptive analysis. In: STONE, H.; SIDEL, J.L. **Sensory evaluation practices**. Capítulo 6. London: Academic Press, 1985. p. 202-226.

STONE, H.; SIDEL, J.L.; BLOOMQUIST, T.J. Quantitative descriptive analysis. In: **Cereal Foods World**, v. 25, n. 10, p. 642-644, 1980.

STONE, H.; SIDEL, J.L.; OLIVER, S.; WOOLSEY, A.; SINGLETON, R.C. Sensory evaluation by quantitative descriptive analysis. In: **Food Technology**, v. 28, n.11, p. 24-37, 1974.

SUSLICK, K. S. An optoelectronic nose: colorimetric sensor arrays. In: **MRS Bulletin**, v. 29, p. 720-725, 2004.

TAN, T.T.; SCHMITT, V.O.; LUCAS, O.; ISZ, S. Electronic noses and electronic tongues, In: **Lab-Plus International**, p. 16-19, 2001.

TAO, Z.; LEI, W.; TENG, J. Pattern recognition of the universal electronic nose. In: **Second International Symposium on Intelligent Information Technology Application**, p. 249-253, 2008.

TRESSL, R.; BAHRI, D.; KOSSA, M. In: CHARALAMBOUS, G. (Ed.). **The analysis and control of less desirable flavors in foods and beverages**. New York: Academic Press, 1980. 315p.

VARNAMAMKHASTI, M. Ghasemi et al. Potential application of electronic nose technology in brewery. In: **Trends in Food Science & Technology**, v. 22, p. 165-174, 2011.

VASCONCELOS, S. **Análise dos componentes principais (PCA)**. Rio de Janeiro, RJ: Universidade Federal Fluminense (UFF), 2010. 1-17p.

VENDERHAEGEN, B. et al. The chemistry of beer aging - a critical review. In: **Food Chemistry**, v. 95, p. 357-381, 2006.

VICINI, Lorena. 2005. **Análise multivariada da teoria à prática**. 2015f. Monografia (Especialização)- Universidade Federal de Santa Maria, UFSM, Santa Maria, RS, 2005.

WHITE, F.H.; WAINWRIGHT, T. The Presence of two dimethyl sulfide precursors in malt, their control by malt kilning conditions, and their effect on beer DMS levels. In: **Journal of the Institute of Brewing**, v. 83, p. 224-230, 1977.

YAMAZAKI, A. 2001. **Reconhecimento de padrões em um nariz artificial por redes neurais**. Dissertação (Mestrado)- Centro de Informática, Universidade Federal de Pernambuco - UFPE, Recife, PE, 2001.

ZANCHETTIN, C.; LUDERMIR, T.B. Sistemas neurais híbridos para reconhecimento de padrões em narizes artificiais. In: **Sba Controle & Automação**, Campinas, v. 16, n. 2, 2005. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0103-17592005000200005&lng=en&nrm=iso>. Acesso em: 15 abr. 2016

ZOECKLEIN, B. W. et al. **Wine analysis and production**. New York: Chapman & Hall, 1994. 621.

ANEXOS

ANEXO A - GRÁFICOS DE ANÁLISE EXPLORATÓRIA

Figura A 1 - Análise sensorial dos compostos na amostra com adição de diacetil

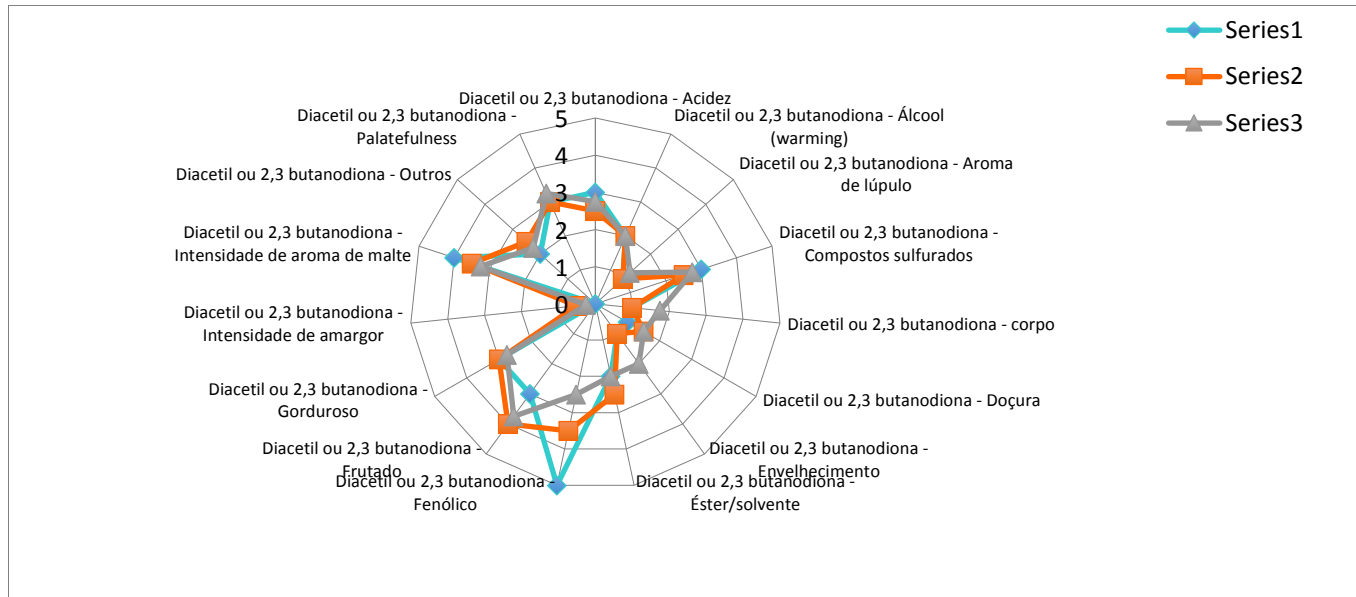


Figura A 2 - Análise sensorial dos compostos na amostra com adição de sulfeto de hidrogênio (H₂S)




Figura A 3 - Análise sensorial dos compostos na amostra com adição de ácido acético




Figura A 4 - Análise sensorial dos compostos na amostra com adição de acetato de isoamila




Figura A 5 - Análise sensorial dos compostos na amostra com adição de trans-2,4 heptadienal (ranço)




Figura A 6 - Análise sensorial dos compostos na amostra com adição de mel




Figura A 7 - Análise sensorial dos compostos na amostra com adição de 2,4,6 trichloroanisole




Figura A 8 - Análise sensorial dos compostos na amostra com adição de metional




Figura A 9 - Análise sensorial dos compostos na amostra com adição de mercaptano




Figura A 10 - Análise sensorial dos compostos na amostra com adição de malte biscuit




Figura A 11 - Análise sensorial dos compostos na amostra com adição de etil fenfol (terra molhada)

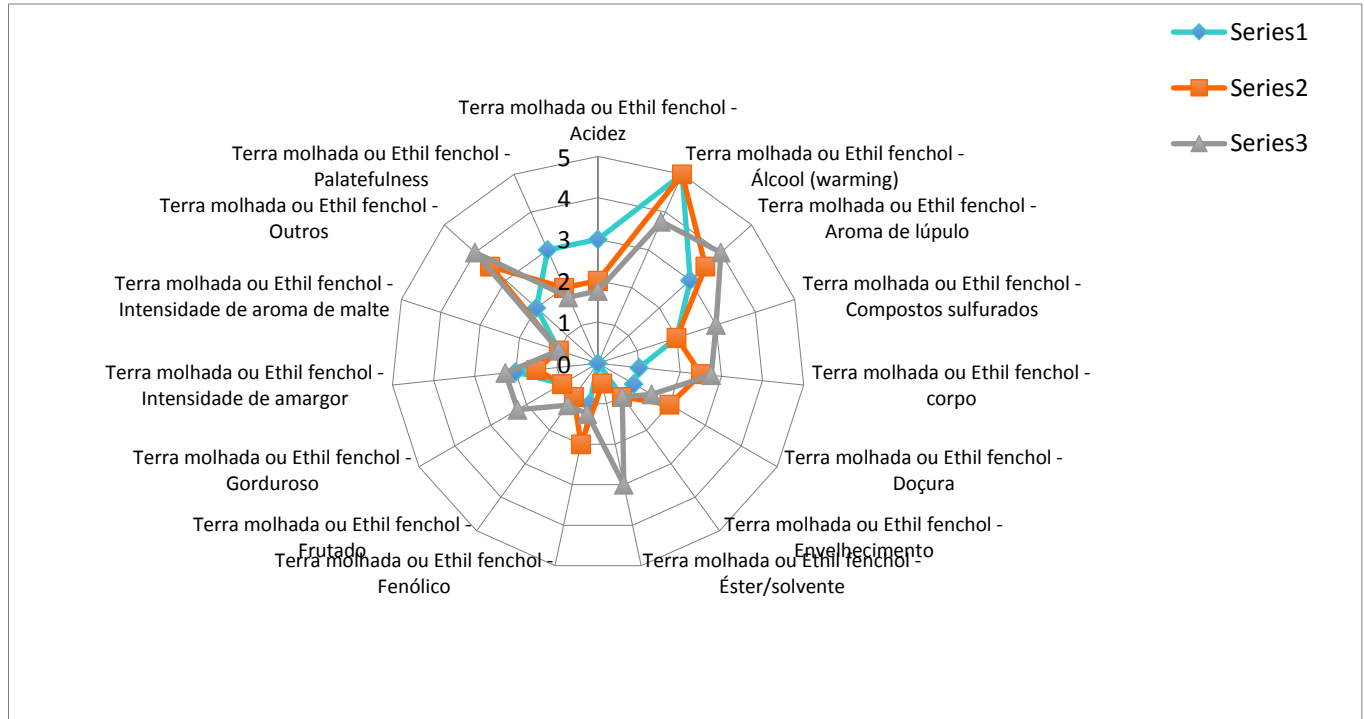


Figura A 12 - Análise sensorial dos compostos na amostra com adição de acetaldeído




Figura A 13 - Análise sensorial dos compostos na amostra com adição de ácido láctico




Figura A 14 - Análise sensorial dos compostos na amostra com adição de benzaldeído (amêndoas)

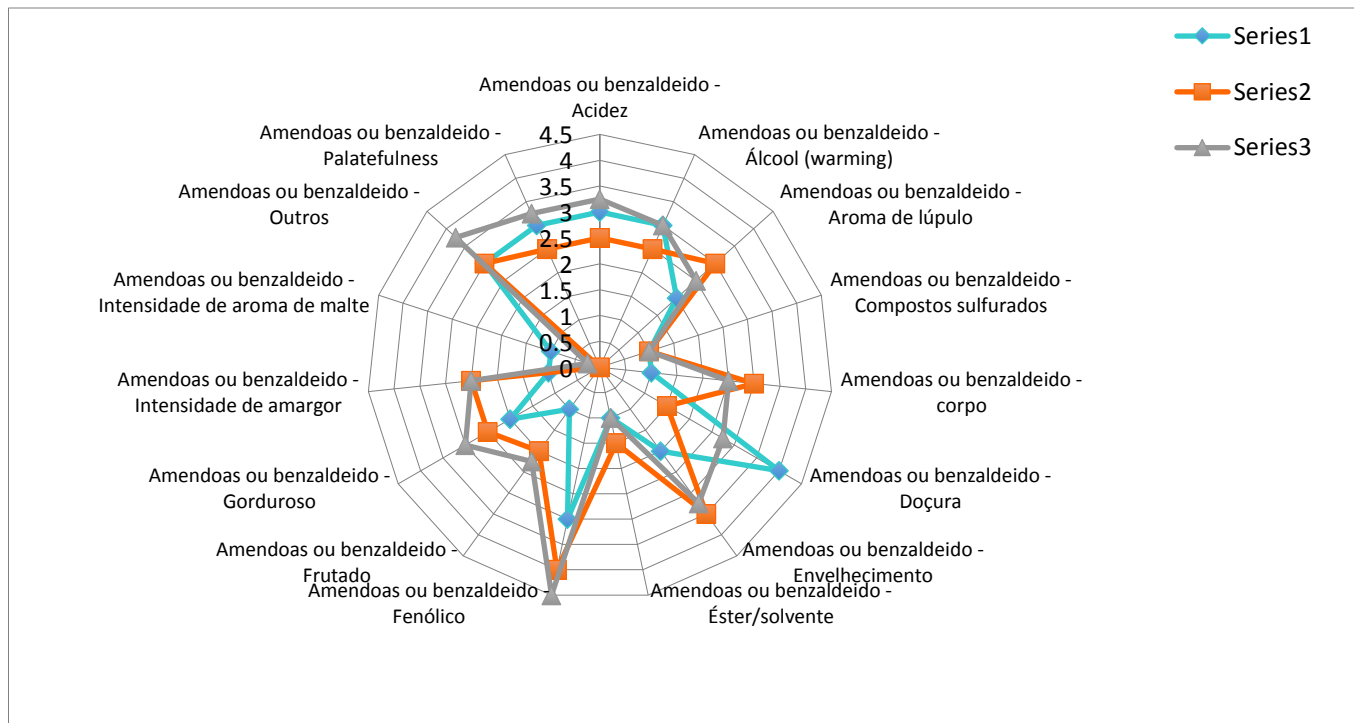


Figura A 15 - Análise sensorial dos compostos na amostra com adição de acetato de etila

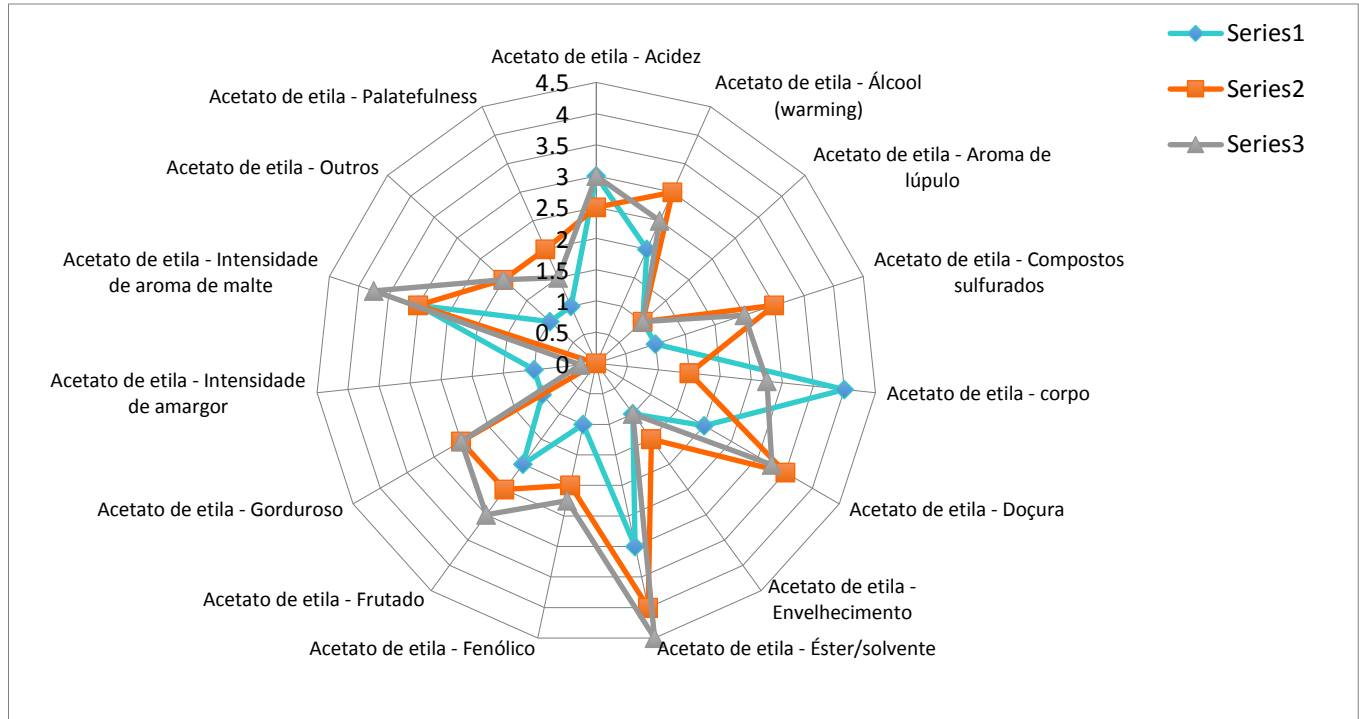


Figura A 16 - Análise sensorial dos compostos na amostra com adição de baunilha

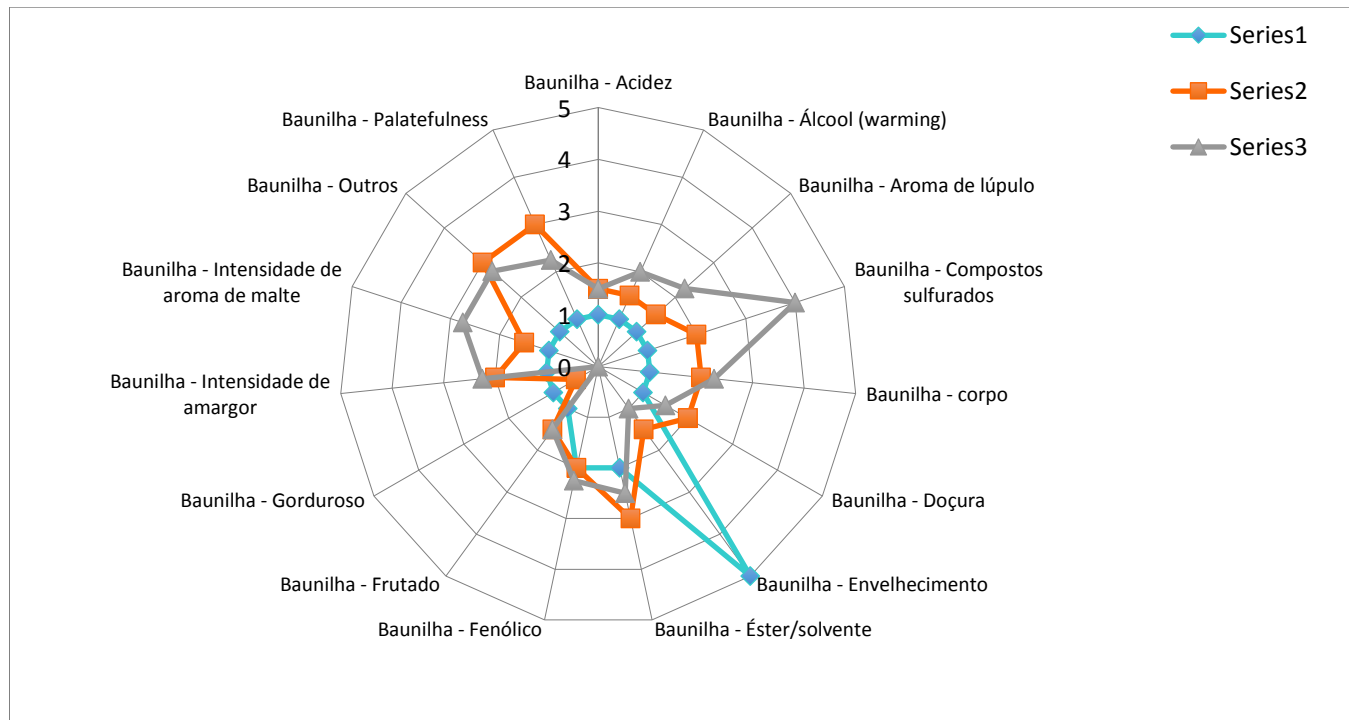


Figura A 17 - Análise sensorial dos compostos na amostra com adição de caprílico




Figura A 18 - Análise sensorial dos compostos na amostra com adição de 2,6 diclorofenol




Figura A 19 - Análise sensorial dos compostos na amostra com adição de geraniol




Figura A 20 - Análise sensorial dos compostos na amostra com adição de grama fresca




Figura A 21 - Análise sensorial dos compostos na amostra com adição de óleo de lúpulo ou extrato oleoso de lúpulo

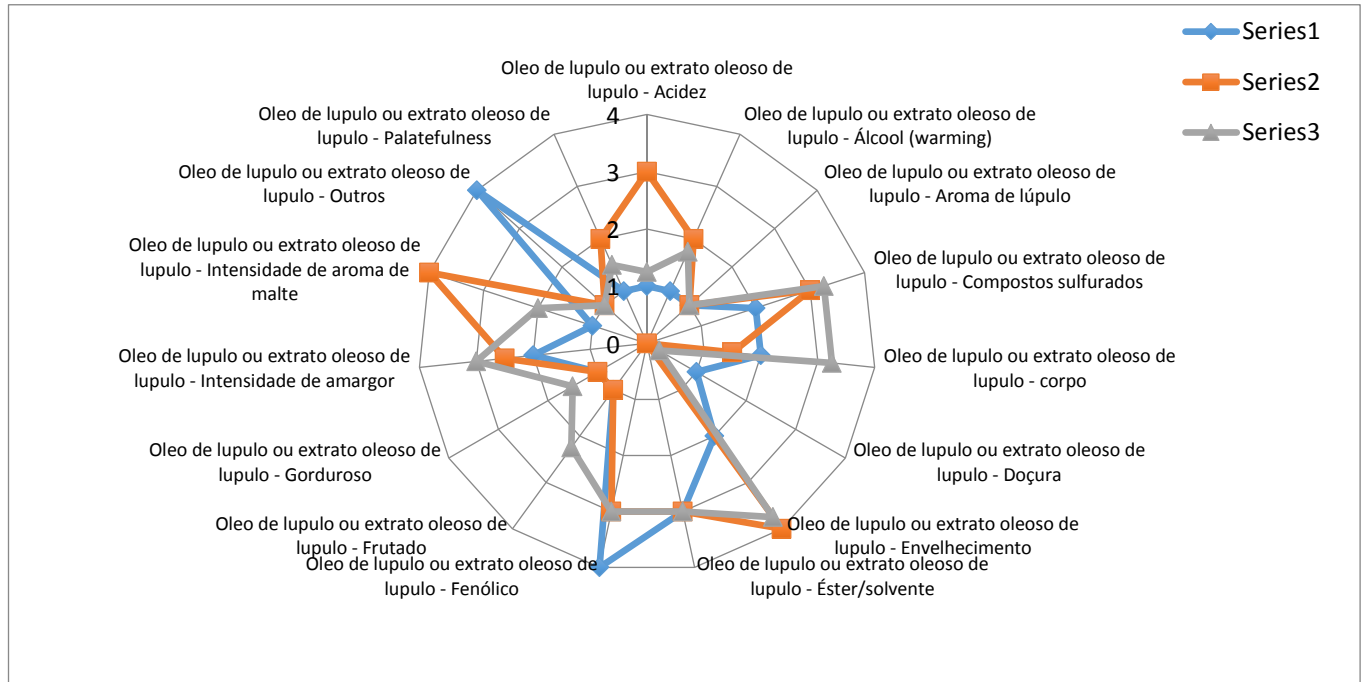


Figura A 22 - Análise sensorial dos compostos na amostra com adição de trans-2-nonenal (papel)




Figura A 23 - Análise sensorial dos compostos na amostra com adição de bicarbonato de sódio (alcalino)




Figura A 24 - Análise sensorial dos compostos na amostra com adição de ácido butírico

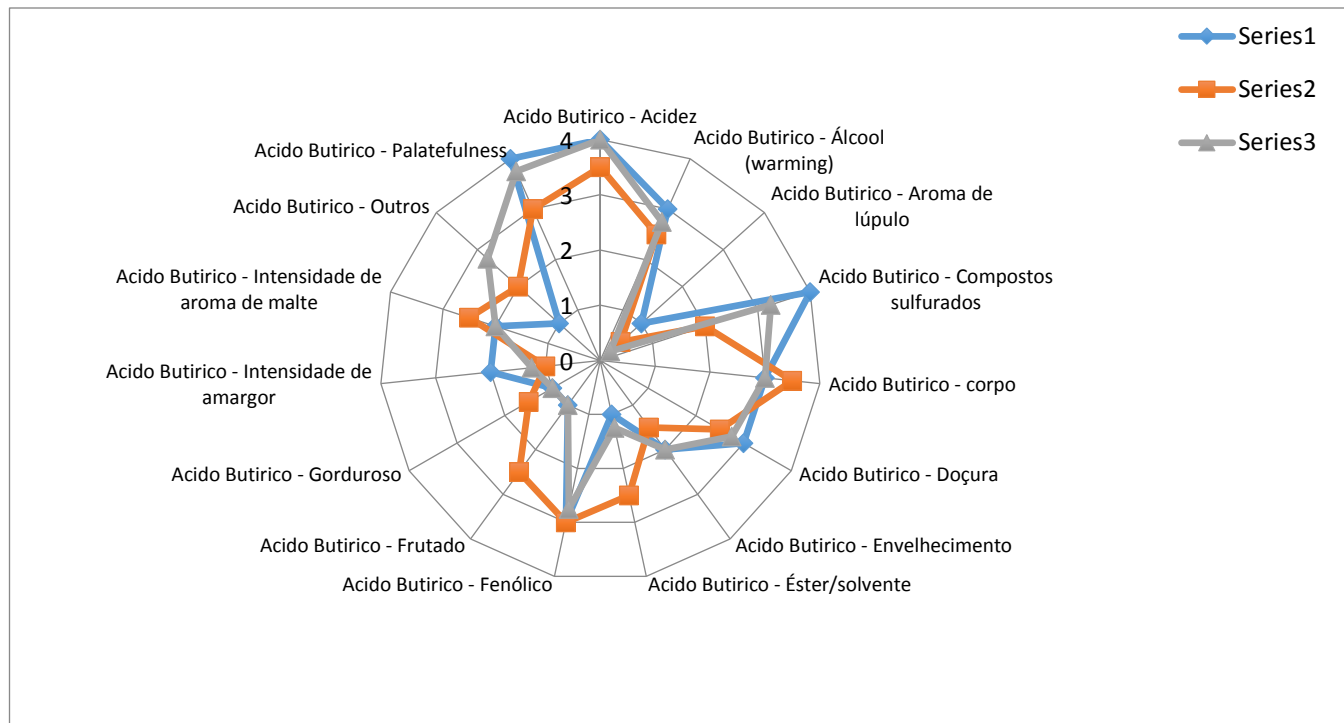


Figura A 25 - Resultados para o grupo treinado (escala de análise sensorial x compostos)




Figura A 26 - Resultados para o grupo não treinado (escala de análise sensorial x compostos)




Figura A 27 - Resultados para o grupo treinado (escala de análise sensorial x compostos)





Figura A 28 - Resultados para o grupo treinado (escala de análise sensorial x compostos)



ANEXO B - RESULTADO INDIVIDUAL PARA CADA COMPOSTO QUÍMICO

As Tabelas B 1 a B 37 se referem ao resultado individual para os diferentes compostos utilizando os sensores MQ1135, MQ8, MQ7, MQ4, MQ2 e MQ3. As tabelas apresentam os valores de médias de tempo (em minutos) do tempo 1, tempo 2 e tempo 3.

Tabela B 1 - Resultado para o Ácido acético para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Acido acético						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	4,3	± 0,28	4,3	±	4,3	±
MQ8	3,3	2,8	± 0,03	2,8	± 0,03	2,8	± 0,03
MQ7	2,6	3,6	± 0,06	3,5	± 0,05	3,5	± 0,05
MQ4	1,8	4,2	± 0,23	4,2	± 0,23	4,2	± 0,23
MQ2	3,2	3,7	± 0,05	3,6	± 0,05	3,5	± 0,03
MQ3	2,8	3,4	± 0,44	3,2	± 0,42	3,6	± 0,37
Umidade e Temperatura 22°C / 95%							

Tabela B 2 - Resultado para o 2,3 butanodiona (diacetil) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Diacetil ou 2,3 butanodiona						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	3,6	± 0,31	3,6	± 0,31	3,6	± 0,31
MQ8	3,3	4,2	± 0,13	4,2	± 0,13	4,2	± 0,13
MQ7	2,6	2,8	± 0,27	2,9	± 0,23	2,9	± 0,23
MQ4	1,8	2,7	± 0,63	2,7	± 0,63	2,7	± 0,63
MQ2	3,2	4,3	± 0,18	4,3	± 0,18	4,3	± 0,18
MQ3	2,8	2,9	± 0,19	2,9	± 0,19	3,1	± 0,19
Umidade e Temperatura 22°C / 95%							

Tabela B 3 - Resultado para o Sulfeto de hidrogênio (H₂S) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	H ₂ S ou sulfeto de hidrogênio						
Sensores		Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,3	± 0,23	2,3	± 0,23	2,3	± 0,23
MQ8	3,3	3,6	± 0,16	3,6	± 0,16	3,6	± 0,16
MQ7	2,6	2,8	± 0,5	2,8	± 0,5	2,8	± 0,5
MQ4	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ2	3,2	4,1	± 0,22	4,1	± 0,22	4,1	± 0,22
MQ3	2,8	3,6	± 0,35	3,6	± 0,35	3,6	± 0,35
Umidade e Temperatura 22°C / 95%							

Tabela B 4 - Resultado para o Acetato de isoamila para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo

3

Atributo:	Acetato de isoamila						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,4	± 0,026	2,5	± 0,026	2,4	± 0,026
MQ8	3,3	3,8	± 0,022	3,8	± 0,022	3,9	± 0,022
MQ7	2,6	3,2	± 0,031	3,2	± 0,031	3,6	± 0,031
MQ4	1,8	2,4	± 0,016	2,4	± 0,016	2,4	± 0,016
MQ2	3,2	4,1	± 0,018	4,1	± 0,018	4,3	± 0,018
MQ3	2,8	3,2	± 00,34	3,2	± 00,34	3,4	± 00,34
Umidade e Temperatura 22°C / 95%							

Tabela B 5 - Resultado para o Ranco ou trans, trans-2,4 heptadienal para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Ranco ou trans, trans-2,4 heptadienal						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,3	± 0,04	2,3	± 0,04	2,3	± 0,04
MQ8	3,3	4,8	± 0,02	4,8	± 0,02	4,8	± 0,02
MQ7	2,6	3,2	± 0,047	3,2	± 0,047	3,2	± 0,047
MQ4	1,8	2,8	± 0,037	2,8	± 0,037	2,8	± 0,037
MQ2	3,2	3,9	± 0,041	3,9	± 0,041	3,9	± 0,041
MQ3	2,8	3,3	± 0,036	3,3	± 0,036	3,3	± 0,036
Umidade e Temperatura 22°C / 95%							

Tabela B 6 - Resultado para Geosmina para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Geosmina						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ8	3,3	3,2	± 0,016	3,2	± 0,016	3,2	± 0,016
MQ7	2,6	2,9	± 0,022	2,9	± 0,022	2,9	± 0,022
MQ4	1,8	2,1	± 0,024	2,1	± 0,024	2,1	± 0,024
MQ2	3,2	3,2	± 0	3,2	± 0	3,2	± 0
MQ3	2,8	2,8	± 0	2,8	± 0	2,8	± 0
Umidade e Temperatura 22°C / 95%							

Tabela B 7 - Resultado para o Etil fenilacetato (mel) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Mel ou etil fenilacetato						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ8	3,3	3,7	± 0,012	3,7	± 0,012	3,7	± 0,012
MQ7	2,6	2,8	± 0,07	2,8	± 0,07	2,8	± 0,07
MQ4	1,8	2,4	± 0,11	2,4	± 0,11	2,4	± 0,11
MQ2	3,2	3,6	± 0,015	3,6	± 0,015	3,6	± 0,015
MQ3	2,8	3,2	± 0,031	3,2	± 0,031	3,2	± 0,031
Umidade e Temperatura 22°C / 95%							

Tabela B 8 - Resultado para o Musty - 2,4,6 trichloroanisole para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Musty - 2,4,6 trichloroanisole						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	4,3	± 0,012	4,7	± 0,022	4,7	± 0,022
MQ8	3,3	3,3	± 0	3,3	± 0	3,3	± 0
MQ7	2,6	2,8	± 0,018	2,8	± 0,018	2,8	± 0,018
MQ4	1,8	3,2	± 0,031	3,2	± 0,031	3,2	± 0,031
MQ2	3,2	3,8	± 0,028	3,9	± 0,028	4	± 0,032
MQ3	2,8	2,9	± 0,025	2,9	± 0,025	2,9	± 0,025
Umidade e Temperatura 22°C / 95%							

Tabela B 9 - Resultado para o Methional para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Methional						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	1,9	± 0,016	2,2	± 0,016	2,2	± 0,016
MQ8	3,3	3,4	± 0,016	3,4	± 0,016	3,4	± 0,016
MQ7	2,6	2,6	± 0	2,6	± 0	2,8	± 0
MQ4	1,8	2,2	± 0,015	2,2	± 0,015	2,2	± 0,015
MQ2	3,2	3,6	± 0,06	3,6	± 0,06	3,6	± 0,06
MQ3	2,8	4,1	± 0,027	4,1	± 0,027	4,2	± 0,032
Umidade e Temperatura 22°C / 95%							

Tabela B 10 - Resultado para o Metanotiol (Mercaptano) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Metanotiol (Mercaptano)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ8	3,3	3,3	± 0,027	3,3	± 0	3,3	± 0
MQ7	2,6	3,1	± 0,025	3,1	± 0,025	3,1	± 0,025
MQ4	1,8	4,1	± 0,027	4,1	± 0,027	4,1	± 0,027
MQ2	3,2	4,3	± 0,032	4,3	± 0,032	4,3	± 0,032
MQ3	2,8	2,8	± 0	2,8	± 0	2,8	± 0
Umidade e Temperatura 22°C / 95%							

Tabela B 11 - Resultado para o 2-acetyl pyridine (Malte biscuit) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	2-acetyl pyridine (Malte biscuit)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,2	± 0,043	2,2	± 0,043	2,2	± 0,043
MQ8	3,3	3,4	± 0,035	3,4	± 0,035	3,4	± 0,035
MQ7	2,6	2,6	± 0	2,6	± 0	2,6	± 0
MQ4	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ2	3,2	3,6	± 0,016	3,6	± 0,016	3,6	± 0,016
MQ3	2,8	3,1	± 0,024	3,1	± 0,024	3,1	± 0,024
Umidade e Temperatura 22°C / 95%							

Tabela B 12 - Resultado para o Ethil fenhol (terra molhada) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Terra molhada ou Ethil fenhol						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	4,8	± 0,012	4,8	± 0,012	4,8	± 0,012
MQ8	3,3	3,4	±0,06	3,4	0,06	3,4	0,06
MQ7	2,6	3,3	± 0,025	3,3	± 0,025	3,3	± 0,025
MQ4	1,8	2,3	± 0,015	2,3	± 0,015	2,3	± 0,015
MQ2	3,2	3,4	± 0,023	3,4	± 0,023	3,4	± 0,023
MQ3	2,8	2,9	± 0,03	2,9	± 0,03	2,9	± 0,03
Umidade e Temperatura 22°C / 95%							

Tabela B 13 - Resultado para o Acetaldeído para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Acetaldeído						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,3	± 0,043	2,3	± 0,043	2,3	± 0,043
MQ8	3,3	3,7	± 0,029	3,7	± 0,029	3,7	± 0,029
MQ7	2,6	2,9	± 0,036	2,9	± 0,036	2,9	± 0,036
MQ4	1,8	4,3	± 0,018	4,3	± 0,018	4,3	± 0,018
MQ2	3,2	3,4	± 0,022	3,4	± 0,022	3,4	± 0,022
MQ3	2,8	2,7	± 0,012	2,7	± 0,012	2,7	± 0,012
Umidade e Temperatura 22°C / 95%							

Tabela B 14 - Resultado para o Ácido lático para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Ácido lático						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,2	±	2,2	±	2,2	±
MQ8	3,3	4,6	±	4,6	±	4,6	±
MQ7	2,6	2,7	±	2,7	±	2,7	±
MQ4	1,8	1,8	±	1,8	±	1,8	±
MQ2	3,2	3,4	±	3,4	±	3,4	±
MQ3	2,8	3,3	±	3,3	±	3,3	±
Umidade e Temperatura 22°C / 95%							

Tabela B 15 - Resultado para o Benzaldeído (amêndoas) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Benzaldeído (amêndoas)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	4,6	± 0,22	4,6	± 0,22	4,6	± 0,22
MQ8	3,3	3,7	± 0,012	3,7	± 0,012	3,7	± 0,012
MQ7	2,6	2,8	± 0,07	2,8	± 0,07	2,8	± 0,07
MQ4	1,8	2,2	± 0,11	2,2	± 0,11	2,2	± 0,11
MQ2	3,2	3,8	± 0,015	3,8	± 0,015	3,8	± 0,015
MQ3	2,8	3,2	± 0,031	3,2	± 0,031	3,2	± 0,031
Umidade e Temperatura 22°C / 95%							

Tabela B 16 - Resultado para o Acetato de etila para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Acetato de etila						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,2	± 0,012	2,2	± 0,012	2,2	± 0,012
MQ8	3,3	3,5	±0,062	3,5	±0,062	3,5	±0,062
MQ7	2,6	2,8	± 0,025	2,8	± 0,025	2,8	± 0,025
MQ4	1,8	2,1	± 0,015	2,1	± 0,015	2,1	± 0,015
MQ2	3,2	3,4	± 0,023	3,4	± 0,023	3,4	± 0,023
MQ3	2,8	4,3	± 0,03	4,3	± 0,03	4,3	± 0,03
Umidade e Temperatura 22°C / 95%							

Tabela B 17 - Resultado para a Baunilha para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Baunilha						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,2	± 0,022	2,2	± 0,022	2,2	± 0,022
MQ8	3,3	3,3	± 0	3,3	± 0	3,3	± 0
MQ7	2,6	4,1	±0,017	4,1	±0,017	4,1	±0,017
MQ4	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ2	3,2	3,3	± 0,012	3,3	± 0,012	3,3	± 0,012
MQ3	2,8	3,1	± 0,23	3,1	± 0,23	3,1	± 0,23
Umidade e Temperatura 22°C / 95%							

Tabela B 18 - Resultado para o ácido caprílico para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Ácido Caprílico						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,8	± 0,024	2,8	± 0,024	2,8	± 0,024
MQ8	3,3	3,4	± 0,064	3,4	± 0,064	3,4	± 0,064
MQ7	2,6	3,2	± 0,045	3,2	± 0,045	3,2	± 0,045
MQ4	1,8	1,9	± 0	1,9	± 0	1,9	± 0
MQ2	3,2	3,2	± 0	3,2	± 0	3,2	± 0
MQ3	2,8	4,2	± 0,23	4,2	± 0,23	4,2	± 0,23
Umidade e Temperatura 22°C / 95%							

Tabela B 19 - Resultado para o 2,6 diclorofenol para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	2,6 diclorofenol		Média do tempo 1 min.		Média do tempo 2 min.		Média do tempo 3 min.	
Sensores	Referência cerveja Base		Std		Std		Std	
MQ1135	1,8	2,8	± 0,043	2,8	± 0,043	2,8	± 0,043	
MQ8	3,3	3,3	± 0	3,3	± 0	3,3	± 0	
MQ7	2,6	2,8	± 0,036	2,8	± 0,036	2,8	± 0,036	
MQ4	1,8	1,9	± 0,018	1,9	± 0,018	1,9	± 0,018	
MQ2	3,2	3,2	± 0	3,2	± 0	3,2	± 0	
MQ3	2,8	3,1	± 0,012	3,1	± 0,012	3,1	± 0,012	
Umidade e Temperatura 22°C / 95%								

Tabela B 20 - Resultado para o Geraniol para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Geraniol						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	4,6	± 0,016	4,6	± 0,016	4,6	± 0,016
MQ8	3,3	3,5	± 0,032	3,5	± 0,032	3,5	± 0,032
MQ7	2,6	2,8	± 0,047	2,8	± 0,047	2,8	± 0,047
MQ4	1,8	2,2	± 0,052	2,2	± 0,052	2,2	± 0,052
MQ2	3,2	3,2	± 0,031	3,2	± 0,031	3,2	± 0,031
MQ3	2,8	3,1	± 0,048	3,1	± 0,048	3,1	± 0,048
Umidade e Temperatura 22°C / 95%							

Tabela B 21 - Resultado para o cis 3 hexanol (grama fresca) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Gramma fresca ou cis 3 hexanol						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	3,8	± 0,024	3,8	± 0,024	3,8	± 0,024
MQ8	3,3	3,5	± 0,022	3,5	± 0,022	3,5	± 0,022
MQ7	2,6	2,8	± 0,031	2,8	± 0,031	2,8	± 0,031
MQ4	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ2	3,2	3,3	± 0	3,3	± 0	3,3	± 0
MQ3	2,8	3,1	± 0,016	3,1	± 0,016	3,1	± 0,016
Umidade e Temperatura 22°C / 95%							

Tabela B 22 - Resultado para o Óleo de lúpulo ou extrato oleoso de lúpulo para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Óleo de lúpulo ou extrato oleoso de lúpulo						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,2	± 0,012	2,2	± 0,012	2,2	± 0,012
MQ8	3,3	3,4	± 0,006	3,4	± 0,006	3,4	± 0,006
MQ7	2,6	2,8	± 0,003	2,8	± 0,003	2,8	± 0,003
MQ4	1,8	2,1	± 0,023	2,1	± 0,023	2,1	± 0,023
MQ2	3,2	3,3	± 0,037	3,3	± 0,037	3,3	± 0,037
MQ3	2,8	3,8	± 0,032	3,8	± 0,032	3,8	± 0,032
Umidade e Temperatura 22°C / 95%							

Tabela B 23 - Resultado para o trans-2-nonenal (papel) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Papel ou trans-2-nonenal						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	3,8	± 0,043	3,8	± 0,043	3,8	± 0,043
MQ8	3,3	3,7	± 0,029	3,7	± 0,029	3,7	± 0,029
MQ7	2,6	2,8	± 0,036	2,8	± 0,036	2,8	± 0,036
MQ4	1,8	1,9	± 0,018	1,9	± 0,018	1,9	± 0,018
MQ2	3,2	3,2	± 0	3,2	± 0	3,2	± 0
MQ3	2,8	2,9	± 0,012	2,9	± 0,012	2,9	± 0,012
Umidade e Temperatura 22°C / 95%							

Tabela B 24 - Resultado para o Bicarbonato de sódio (Alcalino) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Bicarbonato de sódio (Alcalino)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ8	3,3	3,3	± 0	3,3	± 0	3,3	± 0
MQ7	2,6	2,6	± 0	2,6	± 0	2,6	± 0
MQ4	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ2	3,2	3,2	± 0	3,2	± 0	3,2	± 0
MQ3	2,8	2,8	± 0	2,8	± 0	2,8	± 0
Umidade e Temperatura 22°C / 95%							

Tabela B 25 - Resultado para o 2-bromofenol para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	2-bromofenol		Média do tempo 1 min.		Média do tempo 2 min.		Média do tempo 3 min.	
Sensores	Referência cerveja Base		Std		Std		Std	
MQ1135	1,8	4,1	± 0,063	4,1	± 0,063	4,1	± 0,063	
MQ8	3,3	3,0	± 0,027	3,0	± 0,027	3,0	± 0,027	
MQ7	2,6	2,8	± 0,036	2,8	± 0,036	2,8	± 0,036	
MQ4	1,8	2,3	± 0,045	2,3	± 0,045	2,3	± 0,045	
MQ2	3,2	3,4	± 0,016	3,4	± 0,016	3,4	± 0,016	
MQ3	2,8	2,9	± 0,003	2,9	± 0,003	2,9	± 0,003	
Umidade e Temperatura 22°C / 95%								

Tabela B 26 - Resultado para o Dimetiltrisulfeto (Cebola) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Dimetiltrisulfeto (Cebola)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,1	± 0,023	2,1	± 0,023	2,1	± 0,023
MQ8	3,3	3,4	± 0,025	3,4	± 0,025	3,4	± 0,025
MQ7	2,6	2,8	± 0,021	2,8	± 0,021	2,8	± 0,021
MQ4	1,8	3,4	± 0,016	3,4	± 0,016	3,4	± 0,016
MQ2	3,2	4,6	± 0,045	4,6	± 0,045	4,6	± 0,045
MQ3	2,8	3,1	± 0,016	3,1	± 0,016	3,1	± 0,016
Umidade e Temperatura 22°C / 95%							

Tabela B 27 - Resultado para o Dimetil sulfito (DMS) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Dimetil sulfito (DMS)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	1,9	± 0,03	1,9	± 0,03	1,9	± 0,03
MQ8	3,3	3,4	± 0,021	3,4	± 0,021	3,4	± 0,021
MQ7	2,6	2,8	±0,013	2,8	±0,013	2,8	±0,013
MQ4	1,8	3,8	± 0,017	3,8	± 0,017	3,8	± 0,017
MQ2	3,2	4,2	± 0,024	4,2	± 0,024	4,2	± 0,024
MQ3	2,8	2,8	± 0,035	2,8	± 0,035	2,8	± 0,035
Umidade e Temperatura 22°C / 95%							

Tabela B 28 - Resultado para o Ácido Butírico para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Ácido Butírico						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,1	± 0,015	2,1	± 0,015	2,1	± 0,015
MQ8	3,3	4,5	± 0,018	4,5	± 0,018	4,5	± 0,018
MQ7	2,6	2,6	± 0	2,6	± 0	2,6	± 0
MQ4	1,8	2,1	± 0,023	2,1	± 0,023	2,1	± 0,023
MQ2	3,2	3,4	± 0,016	3,4	± 0,016	3,4	± 0,016
MQ3	2,8	3,2	± 0,003	3,2	± 0,003	3,2	± 0,003
Umidade e Temperatura 22°C / 95%							

Tabela B 29 - Resultado para o Etilbutirato para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Etilbutirato						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,2	± 0,011	2,2	± 0,011	2,2	± 0,011
MQ8	3,3	3,4	± 0,012	3,4	± 0,012	3,4	± 0,012
MQ7	2,6	2,8	± 0,018	2,8	± 0,018	2,8	± 0,018
MQ4	1,8	1,9	± 0,003	1,9	± 0,003	1,9	± 0,003
MQ2	3,2	3,5	± 0,006	3,5	± 0,006	3,5	± 0,006
MQ3	2,8	3,9	± 0,023	3,9	± 0,023	3,9	± 0,023
Umidade e Temperatura 22°C / 95%							

Tabela B 30 - Resultado para o Hexanoato para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Hexanoato						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,3	± 0,023	2,3	± 0,023	2,3	± 0,023
MQ8	3,3	3,4	± 0,023	3,4	± 0,023	3,4	± 0,023
MQ7	2,6	2,7	± 0,037	2,7	± 0,037	2,7	± 0,037
MQ4	1,8	2,2	± 0,026	2,2	± 0,026	2,2	± 0,026
MQ2	3,2	3,3	± 0,032	3,3	± 0,032	3,3	± 0,032
MQ3	2,8	4,7	± 0,016	4,7	± 0,016	4,7	± 0,016
Umidade e Temperatura 22°C / 95%							

Tabela B 31 - Resultado para o 3-metil-2-butano-1-tiol (*Light struck*) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	3-metil-2-butano-1-tiol (<i>Light struck</i>)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,1	± 0,023	2,1	± 0,023	2,1	± 0,023
MQ8	3,3	3,5	± 0,035	3,5	± 0,035	3,5	± 0,035
MQ7	2,6	2,7	± 0,067	2,7	± 0,067	2,7	± 0,067
MQ4	1,8	4,5	± 0,052	4,5	± 0,052	4,5	± 0,052
MQ2	3,2	4,2	± 0,06	4,2	± 0,06	4,2	± 0,06
MQ3	2,8	3,1	± 0,034	3,1	± 0,034	3,1	± 0,034
Umidade e Temperatura 22°C / 95%							

Tabela B 32 - Resultado para o Ácido Isovalérico para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo

3

Atributo:	Ácido Isovalérico						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,3	± 0,036	2,3	± 0,036	2,3	± 0,036
MQ8	3,3	4,8	± 0,045	4,8	± 0,045	4,8	± 0,045
MQ7	2,6	2,5	± 0,018	2,5	± 0,018	2,5	± 0,018
MQ4	1,8	2,3	± 0,024	2,3	± 0,024	2,3	± 0,024
MQ2	3,2	3,5	± 0,036	3,5	± 0,036	3,5	± 0,036
MQ3	2,8	3,1	± 0,012	3,1	± 0,012	3,1	± 0,012
Umidade e Temperatura 22°C / 95%							

Tabela B 33 - Resultado para o Sulfato de ferro (Metálico) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Sulfato de ferro (Metálico)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ8	3,3	3,3	± 0	3,3	± 0	3,3	± 0
MQ7	2,6	2,6	± 0	2,6	± 0	2,6	± 0
MQ4	1,8	1,8	± 0	1,8	± 0	1,8	± 0
MQ2	3,2	3,2	± 0	3,2	± 0	3,2	± 0
MQ3	2,8	2,8	± 0	2,8	± 0	2,8	± 0
Umidade e Temperatura 22°C / 95%							

Tabela B 34 - Resultado para o *Styrene* (Plástico) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo

3

Atributo:	<i>Styrene</i> (Plástico)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	2,2	± 0,011	2,2	± 0,011	2,2	± 0,011
MQ8	3,3	3,8	± 0,018	3,8	± 0,018	3,8	± 0,018
MQ7	2,6	4,3	± 0,006	4,3	± 0,006	4,3	± 0,006
MQ4	1,8	2,4	± 0,003	2,4	± 0,003	2,4	± 0,003
MQ2	3,2	3,9	± 0,016	3,9	± 0,016	3,9	± 0,016
MQ3	2,8	3	± 0,0012	3	± 0,0012	3	± 0,0012
Umidade e Temperatura 22°C / 95%							

Tabela B 35 - Resultado para o Guaiacol (Defumado) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	Guaiacol (Defumado)		Média do tempo 1		Média do tempo 2		Média do tempo 3	
Sensores	Referência cerveja Base	min.	Std	min.	Std	min.	Std	
MQ1135	1,8	2,2	±	2,2	±	2,2	±	
MQ8	3,3	3,5	±	3,5	±	3,5	±	
MQ7	2,6	3,8	±	3,8	±	3,8	±	
MQ4	1,8	2,3	±	2,3	±	2,3	±	
MQ2	3,2	4,2	±	4,3	±	4,3	±	
MQ3	2,8	3,3	±	3,4	±	3,4	±	
Umidade e Temperatura 22°C / 95%								

Tabela B 36 - Resultado para o 4 vinil guaiacol (Fenólico) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	4 vinil guaiacol (Fenólico)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	4,9	± 0,036	4,9	± 0,036	4,9	± 0,036
MQ8	3,3	3,6	± 0,045	3,6	± 0,045	3,6	± 0,045
MQ7	2,6	2,8	± 0,018	2,8	± 0,018	2,8	± 0,018
MQ4	1,8	2,2	± 0,024	2,2	± 0,024	2,2	± 0,024
MQ2	3,2	3,5	± 0,036	3,5	± 0,036	3,5	± 0,036
MQ3	2,8	2,8	± 0	2,8	± 0	2,8	± 0
Umidade e Temperatura 22°C / 95%							

Tabela B 37 - Resultado para o *p*-mentano-8 tiol-3-ona (Gato) para os diferentes sensores, apresentando a média do tempo 1, tempo 2 e tempo 3

Atributo:	<i>p</i> -mentano-8 tiol-3-ona (Gato)						
Sensores	Referência cerveja Base	Média do tempo 1 min.	Std	Média do tempo 2 min.	Std	Média do tempo 3 min.	Std
MQ1135	1,8	3,5	± 0,018	3,5	± 0,018	3,5	± 0,018
MQ8	3,3	3,8	± 0,032	3,8	± 0,032	3,8	± 0,032
MQ7	2,6	3,2	± 0,023	3,2	± 0,023	3,2	± 0,023
MQ4	1,8	2,4	± 0,011	2,4	± 0,011	2,4	± 0,011
MQ2	3,2	3,5	± 0,018	3,5	± 0,018	3,5	± 0,018
MQ3	2,8	3,5	± 0,023	3,5	± 0,023	3,5	± 0,023
Umidade e Temperatura 22°C / 95%							

ANEXO C - CÓDIGO DE PROGRAMAÇÃO *ARDUINO*

* Multiple gas sensors collector for Amanda's project.

*/

```
#include <dht.h>
```

```
dht DHT;
```

```
/* Basic settings */
```

```
#define PULSE_TIME 1000
```

```
#define INVALID_TEMP_HUMD 999999 // this
```

```
/* Output analog pins */
```

```
#define MQ2_PIN 0
```

```
#define MQ3_PIN 1
```

```
#define MQ4_PIN 2
```

```
#define MQ7_PIN 3
```

```
#define MQ8_PIN 4
```

```
#define MQ135_PIN 5
```

```
#define MQ5_PIN 6
```

```
/* Output digital pins */
```

```
#define DHT11_PIN 4
```

```
#define BLINK_PIN 13
```

```
/* Output values */
```

```
int temperature;
```

```
int humidity;
```

```
int mq2;
```

```
int mq3;
```

```
int mq4;
```

```
int mq7;
int mq8;
int mq135;
int mq5;

float mq2_volt;
float mq3_volt;
float mq4_volt;
float mq7_volt;
float mq8_volt;
float mq135_volt;
float mq5_volt;

void setup() {
  Serial.begin(9600);
  pinMode(BLINK_PIN, OUTPUT); // Blinking led
}

void loop() {
  // Led on
  digitalWrite(BLINK_PIN, HIGH);

  // DHT11
  int chk = DHT.read11(DHT11_PIN);
  switch (chk)
  {
    case DHTLIB_OK:
      temperature = int(DHT.temperature * 100);
      humidity = int(DHT.humidity * 100);
      break;
    //case DHTLIB_ERROR_CHECKSUM:
```

```
//case DHTLIB_ERROR_TIMEOUT:
default:
  temperature = INVALID_TEMP_HUMD;
  humidity = INVALID_TEMP_HUMD;
  break;
}
```

```
// MQ2
mq2 = analogRead(MQ2_PIN);
mq2_volt = (float)mq2 / 1024 * 5.0;
```

```
// MQ3
mq3 = analogRead(MQ3_PIN);
mq3_volt = (float)mq3 / 1024 * 5.0;
```

```
// MQ4
mq4 = analogRead(MQ4_PIN);
mq4_volt = (float)mq4 / 1024 * 5.0;
```

```
// MQ7
mq7 = analogRead(MQ7_PIN);
mq7_volt = (float)mq7 / 1024 * 5.0;
```

```
// MQ8
mq8 = analogRead(MQ8_PIN);
mq8_volt = (float)mq8 / 1024 * 5.0;
```

```
// mq135
mq135 = analogRead(MQ135_PIN);
mq135_volt = (float)mq135 / 1024 * 5.0;
```

```

// mq5
mq5 = analogRead(MQ5_PIN);
mq5_volt = (float)mq5 / 1024 * 5.0;

// Output data
//          Format:          Temperature          (C),Humidity
(%) ,MQ2,MQ3,MQ4,MQ7,MQ8,mq135
Serial.print(temperature);
Serial.print(",");
Serial.print(humidity);
Serial.print(",");
Serial.print(mq2_volt);
Serial.print(",");
Serial.print(mq3_volt);
Serial.print(",");
Serial.print(mq4_volt);
Serial.print(",");
Serial.print(mq7_volt);
Serial.print(",");
Serial.print(mq8_volt);
Serial.print(",");
Serial.print(mq135_volt);
Serial.print(",");
Serial.print(mq5_volt);
Serial.print("\n");

// Led off
digitalWrite(BLINK_PIN, LOW);
delay(PULSE_TIME);

```

Código do Matlab

```

clc

```

```

clear all

MU = csvread('average_sensors.dat',1,1);
STD = csvread('std_sensors.dat',1,1);

MU_size = size(MU) ;

for i=1: MU_size(1,1)/2
    for j = 1:MU_size(1,2)
        MMU(i,j) = MU(2*i,j);
    end
end
MMU_size = size(MMU) ;
MSTD = STD;
MSTD(MSTD == 0)=0.0001;

CS = [];
P = [];

C = cov(MMU);
for i=1:MMU_size(1,1)
    i
    mu = MMU(i,:);
    sigma = MSTD(i,:);
    for ii=1:length(sigma)
        C(ii)=sigma(ii);
    end
    C = diag(sigma.^2); % replacediag(C, sigma);
    CS = [CS; C];
    % Populate
    Sample = mvnrnd(mu,C,300);
    % Classify
    Sample = [Sample, ones(300,1)*i];
    P = [P; Sample];
end

P_size = size(P)

% Shuffle samples
Shuffled = P(randperm(P_size(1,1)), :);

```



```

Train_Set = Shuffled(1:end*0.4,:);
Test_Set = Shuffled(1:end*0.5,:);

Test_Set_size = size(Test_Set)

Target_Set                                     =
Shuffled(Test_Set_size(1,1)+1:end,:);

options = statset('MaxIter',1000);
k = 37;
X = Test_Set(:,1:end-1);
T = Target_Set(:,1:end-1);
F = Shuffled(:,1:end-1);
gmfit                                           =
fitgmdist(F,k,'CovarianceType','diagonal',...
           'SharedCovariance',false, 'Regularize' ,
0.000001);
clusterX = cluster(gmfit,X)
mahalDist = mahal(gmfit,T);

classes = cluster(gmfit, MMU)

result = cluster(gmfit, T);

% Convert to my indexing
for i=1:length(classes)
    result(result==classes(i))=i;
end

class_result = sum(Target_Set(:,end) == result)

% Another

T_size = size(T)

DM = zeros(T_size(1,1),MMU_size(1,1));
for j=1:T_size(1,1)
    pattern = T(j,:);
    for i=1:MMU_size(1,1)
        mu = MMU(i,:);
        sigma = MSTD(i,:);
    end
end

```

```
    DM(j,i)      =      mmahaldist(pattern,      mu,  
diag(sigma.^2));  
    end  
end  
  
[V, IDX] = min(DM, [], 2);  
  
class_result = sum(Target_Set(:,end) == IDX)
```

ANEXO D - FUNÇÕES DE ATIVAÇÃO

A Tabela D 1 apresenta as funções ativação mais comuns utilizadas em redes neurais artificiais, com o tipo de algoritmo e sua equação respectiva.

Tabela D 1 - Funções de ativação mais comuns utilizadas em redes neurais artificiais

ALGORITMO	EQUAÇÃO
Condutância relativa	$\frac{G_{gas}}{G_{ar}}$
Varição fracional da condutância	$\frac{G_{gas} - G_{ar}}{G_{ar}}$
Logaritmo da condutância relativa	$\log\left(\frac{G_{gas}}{G_{ar}}\right)$
Logaritmo da variação absoluta da condutância	$\log\left(G_{gas} - G_{ar} \right)$
Varição fracional da condutância normalizada	$\frac{\frac{G_{gas} - G_{ar}}{G_{ar}}}{\sqrt{\sum \frac{(G_{gas} - G_{ar})^2}{(G_{ar})^2}}}$
Logaritmo da variação absoluta da condutância normalizado	$\frac{\log\left(G_{gas} - G_{ar} \right)}{\left(\frac{\sum \left(G_{gas} - G_{ar} \right)}{n}\right)}$

ANEXO E - *DATASHEET* DOS SENSORES UTILIZADOS

Tabela E 1- Especificações do Sensor MQ-4. A. Condições padrão de trabalho, B. condição do ambiente e C. Característica de sensibilidade

A. Standard work condition

Symbol	Parameter name	Technical condition	Remarks
V _c	Circuit voltage	5V±0.1	AC OR DC
V _H	Heating voltage	5V±0.1	AC OR DC
P _L	Load resistance	20K Ω	
R _H	Heater resistance	33 Ω ± 5%	Room Tem
P _H	Heating consumption	less than 750mw	

B. Environment condition

Symbol	Parameter name	Technical condition	Remarks
T _{ao}	Using Tem	-10°C-50°C	
T _{as}	Storage Tem	-20°C-70°C	
R _H	Related humidity	less than 95%Rh	
O ₂	Oxygen concentration	21%(standard condition)Oxygen concentration can affect sensitivity	minimum value is over 2%

C. Sensitivity characteristic

Symbol	Parameter name	Technical parameter	Remark 2
R _s	Sensing Resistance	10K Ω - 60K Ω (1000ppm CH ₄)	Detecting concentration scope: 200-10000ppm CH ₄ , natural gas
α (1000ppm/ 5000ppm CH ₄)	Concentration slope rate	≤0.6	
Standard detecting condition	Temp: 20°C ± 2°C Humidity: 65%±5%	V _c :5V±0.1 V _H : 5V±0.1	
Preheat time	Over 24 hour		

Tabela E 2 - Especificações do Sensor MQ-8. A. Condições padrão de trabalho, B. condição do ambiente e C. Característica de sensibilidade

A. Standard work condition

Symbol	Parameter name	Technical condition	Remarks
V _c	Circuit voltage	5V±0.1	AC OR DC
V _H	Heating voltage	5V±0.1	AC OR DC
P _L	Load resistance	10K Ω	
R _H	Heater resistance	31 ± 5%	Room Tem
P _H	Heating consumption	less than 800mW	

B. Environment condition

Symbol	Parameter name	Technical condition	Remarks
T _{ao}	Using Tem	-10°C-50°C	
T _{as}	Storage Tem	-20°C-70°C	
R _H	Related humidity	less than 95%Rh	
O ₂	Oxygen concentration	21%(standard condition)Oxygen concentration can affect sensitivity	minimum value is over 2%

C. Sensitivity characteristic

Symbol	Parameter name	Technical parameter	Remark 2
R _s	Sensing Resistance	10K Ω - 60K Ω (1000ppm H ₂)	Detecting concentration scope: 100-10000ppm Hydrogen (H ₂)
α (1000ppm/ 500ppmH ₂)	Concentration slope rate	≤0.6	
Standard detecting condition	Temp: 20°C ± 2°C Humidity: 65%±5%	Vc: 5V±0.1 Vh: 5V±0.1	
Preheat time	Over 24 hour		

Tabela E 3 - Especificações do Sensor DHT11

Parameters	Conditions	Minimum	Typical	Maximum
Humidity				
Resolution		1%RH	1%RH	1%RH
			8 Bit	
Repeatability			± 1%RH	
Accuracy	25 °C		± 4%RH	
	0-50 °C			± 5%RH
Interchangeability	Fully Interchangeable			
Measurement Range	0 °C	30%RH		90%RH
	25 °C	20%RH		90%RH
	50 °C	20%RH		80%RH
Response Time (Seconds)	1/e(63%)25 °C , 1m/s Air	6 S	10 S	15 S
Hysteresis			± 1%RH	
Long-Term Stability	Typical		± 1%RH/year	
Temperature				
Resolution		1 °C	1 °C	1 °C
		8 Bit	8 Bit	8 Bit
Repeatability			± 1 °C	
Accuracy		± 1 °C		± 2 °C
Measurement Range		0 °C		50 °C
Response Time (Seconds)	1/e(63%)	6 S		30 S

ANEXO F - TABELA DE *OFF-FLAVORS* ENCONTRADOS NA CERVEJATabela F 1 - *Off-flavors* comuns na cerveja, organizada por composto, seus termos associados, importância, origem, tipo de análise para detecção, concentração típica e *threshold* aproximado

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
Acetaldeído	Maçãs verdes, solvente de tintas	Presente em todas as cervejas. <i>Off-flavor</i> em concentrações altas. Contribuição positiva ao sabor de algumas cervejas.	Produzido pela levedura durante a fermentação. Indicador de altas concentrações de O ₂ dissolvido na cerveja. Pode ser também produzido por bactérias contaminantes.	Cromatografia gasosa, teste enzimático	2 - 15 mg/l	5 - 15 mg/l. Interage com o sulfito na cerveja, reduzindo a atividade de ambas as substâncias
Acetato de isoamila	Éster, frutado, banana, solvente	Presente em todas as cervejas. Possui importante papel no aroma global. As concentrações variam bastante entre os diversos tipos de cerveja. Acetato de isoamila é uma das principais características das cervejas de trigo.	Produzido pela levedura durante a fermentação.	Cromatografia gasosa	0,8 - 6,6 mg/l	1,4 mg/l

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
Acético	Vinagre, ácido	Presente em todas as cervejas. <i>Off-flavor</i> em concentrações altas.	Produzido pela levedura durante a fermentação. Altas concentrações podem ser produzidas na cerveja por bactérias contaminantes (ex. acetobacter).	Cromatografia gasosa, HPLC	30 - 200 mg/l	130 mg/l
Ácido	Ácido, limão, leite azedo	Todas cervejas são ácidas. Em excesso, esta característica é desagradável ao paladar. O pH influencia indiretamente a atividade de diversos aromas e sabores.	Matérias-primas, fermentação, contaminação bacteriana.	Titulação, medição de pH	90 - 300 mg/l (eq. ácido cítrico)	170 mg/l
Amêndoa	Marzipan, frangélico (licor)	<i>Off-flavor</i> ocasional na cerveja. Característica de algumas cervejas frutadas.	Pode ser formado no armazenamento da cerveja.	Cromatografia gasosa, HPLC	1 - 10 mg/l	1 mg/l

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
Butírico	Vômito, pútrido	<i>Off-flavor</i> na cerveja.	Formado por bactérias (ex: Clostridium), na produção do mosto ou nos xaropes de açúcar (durante a estocagem). Ocasionalmente formado por contaminação na cerveja envasada.	Cromatografia gasosa	0,5 - 1,5 mg/l	2 - 3 mg/l. Atividade fortemente dependente do pH, sendo maior em pH mais baixo
Caprílico	Sabão, couro, parafina, gorduroso, reação de ácido/cloro	<i>Off-flavor</i> na cerveja, quando em altas concentrações. Característica desejável em algumas cervejas claras.	Produzido pela levedura na maturação.	Cromatografia gasosa	2 - 8 mg/l	
Catty	Maracujá, urina de gato, jaula de zoológico	Aroma <i>catty</i> pode ser encontrado frequentemente nos estágios iniciais da oxidação. É geralmente considerado <i>off-flavor</i> na cerveja.	Contaminação de matérias primas com um precursor do aroma <i>catty</i> (ex: pinturas contendo óxido de mesitila).	Cromatografia gasosa. (muito difícil detecção)	15 ng/l. Outros compostos além do exemplificado podem ser responsáveis por este aroma na cerveja.	-

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
dimetiltrisulfeto (Cebola)	Cebola cozida, alho	Componente do caráter sulfurado das cervejas claras. <i>Off-flavor</i> em altas concentrações.	Produzido por aminoácidos contendo enxofre, durante a fervura. Eliminado da cerveja durante a fermentação pelo CO ₂ produzido. Também encontrado no óleo de lúpulo.	Cromatografia gasosa.	0,05 - 0,3 µg/l	0,1 µg/l
2,6 diclorofenol	Hospital, antiseptic	Aroma proveniente de fatores externos ao processo.	Contaminação de matérias primas e/ou embalagens com clorofenóis. Contato da cerveja com água clorada.	Cromatografia gasosa, teste colorimétrico	Não detectado em cerveja normal	
2,3 butanodiona (Diacetil)	Manteiga, Manteiga rançosa, iogurte	Normalmente um <i>off-flavor</i>, especialmente em cervejas claras. Em alguns tipos de cerveja traz uma contribuição positiva (ex. ales, stouts).	Formado na cerveja por precursor produzido pela levedura na fermentação. Formado também por bactérias contaminantes (ex. pediococos, lactobacilos).	Cromatografia gasosa, teste colorimétrico	0,008 - 0,6 mg/l	0,04 mg/l.

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
Dimetil sulfito (DMS)	Milho, vegetais cozidos	Característica desejável em alguns estilos de cervejas claras. Na maior parte destas é considerado <i>off-flavor</i> .	Formado na produção de mosto a partir de um precursor derivado do malte. Pode ser também produzido por bactérias contaminantes na fermentação.	Cromatografia gasosa	0,01 -0,15 mg/l	0,025 mg/l
4 vinil guaiacol (Fenólico)	Cravo, tempero, herbal, medicinal	Usualmente indesejável. Em algumas cervejas, como as de trigo (Weissbier), é característica principal.	Formado por leveduras especiais ou por leveduras selvagens.	Espectrofotometria, HPLC	0,05 - 0,55 mg/l	0,2 mg/l
Geraniol	Floral, rosas, erva cidreira	O geraniol contribui de modo importante para o aroma de algumas cervejas. É parcialmente responsável pelo componente floral do aroma de lúpulo.	Proveniente do lúpulo. Sua concentração na cerveja é determinada pela variedade de lúpulo, processo de dosagem, condições de fervura e de fermentação.	Cromatografia gasosa	0 - 100 µg/l	Um terço da população tem um <i>threshold</i> em torno de 18 µg/l. O restante tem <i>thresholds</i> em torno de 350 µg/l .

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
cis 3 hexanol (Gramma verde cortada)	Gramma, folhas, plantas cortadas	Desejável em algumas cervejas. <i>Off-flavor</i> em altas concentrações.	Diversos compostos trazem estas características para a cerveja. Sua presença é influenciada pela fervura do mosto e variedade de lúpulo.	Cromatografia gasosa	Não aplicável.	15 mg/l. Hexenol é um dos compostos que produzem este aroma. Não é o único.
H₂S	Ovo podre	Em baixas concentrações, contribui para o frescor da cerveja. Em concentrações mais elevadas é aroma indesejável.	Produzido pela levedura durante a fermentação e às vezes na maturação. Pode ser formado também por bactérias contaminantes se a assepsia for deficiente.	Cromatografia gasosa, testes colorimétricos e titulação	0,001 - 0,2 mg/l	4 µg/l
Hexanoato de etila	Maçã vermelha, ki-suco	Presente em todas as cervejas. Possui um importante papel no balanço geral de aromas. As concentrações encontradas variam consideravelmente de acordo com o tipo de cerveja. <i>Off-flavor</i> quando em grandes concentrações (condições de fermentação inadequadas).	Produzido pela levedura durante a fermentação.	Cromatografia gasosa	0,07 - 0,5 mg/l.	0,2 mg/l.

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
Ácido Isovalérico	Queijo, lúpulo velho, nata passada, chulé	<i>Off-flavor</i> na cerveja.	Pode ser originário pelo uso de lúpulo mal conservado.	Cromatografia gasosa	0,2 - 1,5 mg/l	1 mg/l
3-metil-2-butano-1-tiol (Light struck)	<i>Skunky</i> luz	<i>Off-flavor</i> na cerveja.	Formado na cerveja pela exposição desta à luz natural ou artificial. Algumas cervejas recebem exclusivamente lúpulos quimicamente modificados evitando o desenvolvimento deste aroma.	Cromatografia gasosa, análise sensorial	1 - 5 ng/l (cervejas mantidas no escuro) 0,01 - 1,5 µg/l (cervejas expostas à luz)	4 ng/l
Lúpulo condimentado	Condimentado, casca de laranja, Curaçao	Característica desejável em algumas cervejas claras.	Característica proveniente da adição de lúpulo próximo ao final da fervura, ou então na forma de essência antes do envasamento.	Difícil análise	0,01 - 0,2 mg/l	0,04 mg/l (variável)
Mercaptana	Ralos, esgotos, vegetais podres, lixo, gás de cozinha	Componente do caráter sulfurado da cerveja. Se presente em excesso é considerado <i>off-flavor</i>.	Formado pela levedura durante a fermentação. Também produzido por autólise da levedura durante a maturação.	Cromatografia gasosa, titulação	0 - 0,5µg/l	1 µg/l

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
Sulfato de ferro (Metálico)	Tinta, sangue, ferro, metal, água parada em torneira de metal	Sabor indesejado. Altas concentrações de íons metálicos na cerveja afetam também a qualidade da espuma e favorecem as reações de oxidação (sabores indesejáveis).	Derivado do contato da cerveja com materiais que contém metais (tubulações e equipamentos, matérias-primas). Também podem ser derivados de produtos da oxidação de lipídeos.	Espectrofotometria de absorção atômica ou plasma	< 0,5 mg/l (íons ferro)	1 mg/l
Mofo	Mofado, cortiça, adega úmida	Aroma proveniente de fator externo, extremamente ativo.	Contaminação de matérias-primas e/ou embalagens. Cloroanísóis podem migrar pelas embalagens contaminando adjuvantes, matérias-primas e a própria cerveja.	Cromatografia gasosa, análise sensorial	Não detectado na cerveja normal	25 ng/l
Óleo de lúpulo	Lúpulo, lupulado	Característica importante conferida a algumas cervejas especiais pela adição de óleo de lúpulo.	Óleo essencial de lúpulo obtido por destilação a vapor.	Cromatografia	0,05 - 3 mg/l	Variável, em torno de 0,16 mg/l

COMPOSTO	TERMOS ASSOCIADOS	IMPORTÂNCIA	ORIGENS	ANÁLISE	CONCENTRAÇÃO TÍPICA	THRESHOLD APROXIMADO
trans-2-nonenal (Papal)	Papelão, oxidado, cascudo serrador	<i>Off-flavor</i> relacionado ao envelhecimento da cerveja.	Formado na estocagem da cerveja. O desenvolvimento desta característica depende do tempo e temperatura da estocagem, além do teor de oxigênio na cerveja envasada.	Cromatografia gasosa.	<50 µg/l (cerveja nova) >0,2 mg/l (cerveja envelhecida)	50 - 100 µg/l
Terra	Terra molhada	<i>Off-flavor</i> na cerveja.	Produzido por microrganismos na água. O aroma pode também ser produzido por micro-organismos em paredes úmidas e posteriormente migrar para a cerveja.	Cromatografia gasosa	Não detectado na cerveja normal.	5 µg/l.

Fonte: elaborado pela autora.