

# Cachaça type identification using color information and computer vision

Bruno Urbano Rodrigues\*, Ronaldo Martins da Costa\*, Rogerio Salvini\*, Anderson da Silva Soares\*, Flávio Alves da Silva†, Márcio Caliarí†, Karla Cristina R. Cardoso† e Tânia Isabel M. Ribeiro‡

\*Instituto de Informática

Universidade Federal de Goiás

Email: brunourb@gmail.com, ronaldocosta@inf.ufg.br,

rogeriosalvini@inf.ufg.br, anderson@inf.ufg.br

†Escola de Agronomia e Engenharia de Alimentos

Universidade Federal de Goiás

Email: flaviocamp@ufg.br, macaliari@ig.com.br, karlagropan@hotmail.com

‡Escola Superior Agrária

Instituto Politécnico de Bragança

Email: tania.im.ribeiro@gmail.com

**Abstract**—Cachaça is a type of distilled drink from sugarcane with great economic importance. Its classification includes three types: aged, premium and extra premium. These three classifications are related to the aging time of the drink in wooden casks. Besides the aging time, it is important to know what kind of wood were used in the barrel storage in order to inform the correct properties for each drink. This paper shows a method for automatic recognition of wood type using color information from a computer vision system. The results showed that information color have relevant information to identify a cachaça. It's a better method when compare chemical features method. In the study case using two classifiers, LDA (Linear Discriminant Analysis) and QDA (Quadratic Discriminant Analysis). Comparing both classifiers, the LDA and QDA had 98.13% and 99.03% of accuracy, respectively, using just color information.

## I. INTRODUÇÃO

A cachaça é o destilado mais consumido entre as bebidas alcoólicas brasileiras. É um tipo de bebida especial produzida a partir da cana-de-açúcar (*Saccharum sp*) similar ao rum. Tem como diferencial o uso de diferentes tipos de madeira em seu processo de envelhecimento.

O envelhecimento consiste em armazenar a cachaça em barris ou tonéis de madeira por um tempo determinado. Tal processo produz alterações na composição química, no aroma, no sabor e na cor da bebida [1]. A legislação classifica a cachaça em três tipos: cachaça envelhecida, cachaça *premium* e cachaça *extra premium*. A diferença entre os tipos está relacionado ao quantitativo de armazenagem e ao tempo de armazenamento. A cachaça envelhecida e a cachaça *premium* tem período de envelhecimento de no mínimo 1 ano. Na composição da cachaça envelhecida 50% deve ser envelhecida e os outros 50% utiliza-se de cachaça não-envelhecida através do processo chamado *blend*, onde é realizada mistura de cachaças. Por sua vez a cachaça *premium* possui 100% de cachaça envelhecida. A cachaça *extra-premium* tem período de envelhecimento de no mínimo 3 anos e contém somente cachaça envelhecida. Diferentemente das bebidas mais famosas do mundo como uísques, *brandies* e vinhos que são armazenados somente em barris de carvalho, a cachaça é a única que usa

diferentes madeiras para o processo de envelhecimento[1][2]. Cada madeira confere à bebida uma análise sensorial que envolve a medição, interpretação e compreensão das respostas humanas para as propriedades percebidas pelos sentidos (paladar - sabor, olfato - aroma, visão - cor). O conhecimento detalhado da composição química e sensorial da cachaça, bem como o tempo de maturação constituem fatores importantes no controle de qualidade da bebida e avaliação das alterações que possam contribuir para a melhoria de processos de produção.[1]

## A. Trabalhos correlatos

Nesta seção apresentamos alguns trabalhos correlatos a classificação e caracterização de destilados que abrangem os seguintes temas: cromatografia gasosa, espectrometria, visão computacional, redes neurais, algoritmos genéticos, análise discriminante e análise de componentes principais.

O trabalho de De Souza[3] utilizou cromatografia gasosa - olfatometria - para separar e caracterizar os odores presentes na cachaça e rum. Estes dois produtos de cana de açúcar foram comparados e os padrões identificados a partir de uma análise sensorial descritiva. A desvantagem da utilização deste método é a manutenção, pois possui alto custo. Augusti[4] demonstrou a diferenciação entre cachaça artesanal e o rum utilizando espectrometria de massa por ionização. Utilizou a análise de componentes principais (PCA), abordagem estatística na qual os dados são representados por um subconjunto de seus autovetores, observando tipo de madeiras (*Amburana cearensis* e jequitibá - *Cariniana legalis*). Seu trabalho contribui para que novos estudos possam utilizar esta técnica para a identificação de cachaças artesanais e industriais bem como a detecção de adulterações pela adição de caramelo e outras substâncias como corantes.

Wan[5] utilizou a visão computacional combinada com redes neurais artificiais. Foi utilizada uma abordagem à nível estrutural e microscópico dos vinhos a serem classificados, por meio da análise da microestrutura e características da textura, fator que influencia na atribuição da cor à amostra.

Partindo da idéia de que os diferentes vinhos têm variação na microestrutura(microscopia) e micrografias(partículas), o estudo objetivou a extração de características em comum para delimitar um padrão. Para tal, utilizaram redes neurais para a classificação das amostras. Os resultados apresentados confirmam que é possível a classificação do vinho através da sua micrografia, possibilitando a utilização das características em outros contextos.

Manuel[6] utiliza método baseado na análise discriminante quadrática(QDA) combinado com a transformada quadrática de Fisher para a classificação de vinhos. A análise discriminantes quadrática é utilizada como esquema de classificação e para fins de comparação foi usado outros três métodos de extração de características: transformada linear de Fisher, transformada de Fourier e transformada Wavelet. Em seus resultados foi apresentado ganho na utilização da discriminante quadrática como método de classificação combinada com a transformada de Fisher para a extração de características do vinho.

Boisier[7] utiliza o  $\Delta E$  baseado no espaço de cores CIELab nas amostras e demonstra o agrupamento de acordo com as tonalidades classificadas. O  $\Delta E$  mede a distância entre duas cores utilizando a métrica euclidiana. O objetivo proposto foi representar as cores dos vinhos com número limitado de cores que foram chamadas de *nuances*. A aplicação do  $\Delta E$  objetivou realizar um comparativo com o modelo de cor HVS (*hue, saturation e value*), observando o brilho, cromaticidade e saturação. Assim, analisar o espectro de cor, classificar e agrupar de acordo com a tonalidade. Os resultados obtidos são encorajadores na medida em que permitem uma caracterização exata e reprodução da cor do vinho. O modelo de cor RGB é um sistema de cores aditivas formado por Vermelho (Red), Verde (Green) e Azul (Blue). Cores aditivas são cores emitidas ou projetadas. A cor é gerada pela mistura de vários comprimentos de onda luminosa, provocando uma sensação de cor quando atinge o olho. Formatos RGB, também conhecidos por *true-color*, usam 8-bits por canal. O modelo de cor CIELab é um sistema de cores subtrativo. CIELab descreve as cores básicas em três qualidades:  $L^*$  é luminosidade,  $a^*$  e  $b^*$  contem a informação de croma.  $L^*$  é luminância, medida da densidade e intensidade de uma luz refletida numa dada direção. As informações  $a^*$  e  $b^*$ , referem-se ao valor das cores[8]. Qiongshuai[9], em sua análise demonstra o ganho da utilização de algoritmos genéticos na preleção e classificação de vinhos, combinada com visão computacional. Kruzlicova[10], avalia dados por meio de uma rede neural artificial e para método comparativo utiliza a análise de variância (ANOVA). Cozzolino[11] propôs investigar a relação entre a análise sensorial, visibilidade (VIS) e espectroscopia de infravermelho (NIR) para avaliar as propriedades sensoriais de variedades comerciais de vinhos australianos utilizando PCA.

Os métodos descritos nos artigos relacionados não abordam a multiplicidade de madeiras que podem ser utilizadas, bem como o uso agregado dos valores de dados químicos, valores obtidos pelo colorímetro e não há relação, até então, de fotografias digitais das amostras utilizando-se do modelo de cor RGB. Ora os trabalhos utilizam apenas os dados químicos, ora utilizam apenas os dados do colorímetro (modelo de cor CIELab). Quando utilizam dados químicos e dados do colorímetro, não observam o modelo de cor RGB. O

colorímetro é um equipamento que caracteriza amostras de cores para obter uma medida objetiva das características da cor. Este equipamento geralmente está disponível somente em laboratórios de pesquisa e indústrias. Um ponto relevante é tornar acessível esta tecnologia independente do produtor. Observando os métodos instrumentais, o custo, a manutenibilidade e manuseio é feito por um especialista. Com os métodos computacionais pode-se trazer resultados otimizando tempo e recursos para quaisquer usuário seja ele um especialista ou produtor.

Portanto, neste trabalho é proposto um método de classificação de amostras de cachaça armazenadas em tipos de madeiras diferentes a fim de definir a identidade da cachaça baseado em suas características de cor. Sendo assim, catalogar cores a partir da madeira na qual a cachaça foi armazenada. Será realizado cruzamento das informações obtidas na análise química, nas informações extraídas de colorímetros bem como dados obtidos através da aplicação de algoritmos de processamento digital de imagens, executados sobre as fotografias digitais de amostras da cachaça. Foi utilizada a técnica de Análise de Componentes Principais (PCA), para tratar problemas de mal condicionamento de variáveis e são utilizados 2 classificadores: Análise Discriminante Linear(LDA) e Análise Discriminante Quadrática(QDA).

## II. MATERIAIS E MÉTODOS

### A. Amostras

Foram avaliadas amostras de cachaça com até 36 meses de envelhecimento em tonéis de Amburana (*Amburana cearensis*), Carvalho (*Quercus spp*) e Castanheira (*Bertholletia excelsa H.B.K*). O tempo de envelhecimento foi acompanhado a cada 4 meses e as amostras avaliadas são de 4 tonéis para cada tipo de madeira. Desta maneira o total de amostras que serão analisadas são de 36 amostras por madeira conforme é demonstrado na Tabela I.

Madreira	Amostras (meses)	Total
amburana ( <i>Amburana cearensis</i> ),	4 - 8 - 12 - 16 - 20 - 24 - 28 - 32 - 36	36
carvalho ( <i>Quercus spp</i> )	4 - 8 - 12 - 16 - 20 - 24 - 28 - 32 - 36	36
castanheira ( <i>Bertholletia excelsa H.B.K</i> )	4 - 8 - 12 - 16 - 20 - 24 - 28 - 32 - 36	36
Total de amostras		108

Tabela I: Amostras de cachaça analisadas no período de 36 meses.

As análises físicas e químicas foram realizadas nos laboratórios de tecnologia de bebidas e de análise físico-químicas, da Escola de Agronomia da Universidade Federal de Goiás. Estas análises seguem parâmetros estabelecidos pela Instrução Normativa nº 13 do MAPA (Ministério da Agricultura, Pecuária e Abastecimento)[12] que define diretrizes sobre o consumo e comercialização.

A determinação do pH, densidade, teor alcoólico real a 20°C, acidez volátil fixa e total, extrato seco, compostos fenólicos, cor e atividade antioxidante foram realizadas nos tempos 0, 2, 4, 6, 8, 10 e 12, ou seja, de 2 em 2 meses de armazenamento para que fossem observadas as alterações,

durante o período de envelhecimento. Na análise foram levantados os atributos a serem utilizados no modelo. Os atributos são descritos na Tabela II.

Descrição dos atributos químicos		Descrição dos atributos químicos	
Atributo 1	Álcool Aparente	Atributo 8	n-propil
Atributo 2	Álcool Real	Atributo 9	Isobutanol
Atributo 3	Esteres Totais	Atributo 10	Isoamílico
Atributo 4	Acetato Etila	Atributo 11	1-Butanol
Atributo 5	Lactato Etila	Atributo 12	2-Butanol
Atributo 6	Aldeídos	Atributo 13	Álcool Metílico
Atributo 7	Alcoois Totais	Atributo 14	Furfural

Tabela II: Atributos químicos extraídos da análise das amostras

### B. Sistema de visão computacional

Por seguinte, as amostras foram fotografadas pela câmera digital *Canon EOS REBEL XS* com configuração de ISO 100, abertura a 4.0mm e formato de imagem configurada para RAW que contém a totalidade dos dados da imagem tal como captada pelo sensor da câmera fotográfica. A luz do ambiente para fotografar as amostras foi controlada através de um dispositivo que permite a incidência da luz na posição contrária à lente da câmera fotográfica. Um filtro especial foi utilizado para evitar reflexos no líquido e permitir a captura de uma imagem digital adequada para o processamento.




Figura 1: Sistema para captura das fotografias digitais

A Figura 1 apresenta o projeto do dispositivo desenvolvido que foi utilizado neste trabalho. A técnica foi inspirada por Sun[13] em seu trabalho de classificação de carne bovina. O objetivo do dispositivo é controlar o ambiente da fotografia digital para uma melhor absorção das cores do objeto alvo, neste contexto a cachaça, com o propósito de observar uma correlação entre as características de cores obtidas pelo colorímetro (modelo CIELab  $L^*a^*b^*$  - *Lightness, redness and yellowness*) e da câmera digital (modelo RGB) (*Red, Green and Blue*).

Descrição dos atributos para CIELab		Descrição dos atributos para RGB	
Atributo 15	<i>Lightness</i>	Atributo 18	<i>Red</i>
Atributo 16	<i>Redness</i>	Atributo 19	<i>Green</i>
Atributo 17	<i>Yellowness</i>	Atributo 20	<i>Blue</i>

Tabela III: Representação dos atributos para os modelos de cores CIELab(a) e RGB(b) com seus respectivos números e descrição.

Acima é apresentada as propriedades utilizadas no modelo CIELab e RGB apresentadas. Assim como na análise química, as propriedades do modelo de cor CIELab e RGB foram nomeadas e separadas para serem utilizadas no classificador.

### C. Validação cruzada

Para validação do modelo obtido usou-se procedimento de validação cruzada (*cross-validation*), técnica que avalia a capacidade de generalização de um modelo, a partir de um conjunto de dados.[14] Devido ao número limitado de amostras, a técnica de validação cruzada foi utilizada para se medir a acurácia dos classificadores. Envolve o uso de uma única observação a partir da amostra original, como os dados de validação e dados de treinamento. Neste trabalho utilizou-se o método chamado *leave-and-out*, onde  $n$  é igual ao número total de dados(N). Isto é, são construídos  $n$  classificadores, onde  $n$  é o número de exemplos de treinamento e aproveita-se ao máximo os dados e não envolve sub-amostragem aleatória.

### D. Análise de Componentes Principais

O método para extração de características utilizado foi a análise de componentes principais (PCA). Técnica da estatística multivariada que consiste em transformar um conjunto de variáveis originais em outro conjunto de variáveis de mesma dimensão denominadas de componentes principais. A análise de componentes principais é associada à redução de um conjunto de variáveis, com menor perda possível da informação, onde os componentes principais é uma combinação linear de todas as variáveis originais. São independentes entre si e estimados com o propósito de reter, em ordem de estimação, o máximo de informação, em termos da variação total contida nos dados.[15]

### E. Classificadores utilizados

Para a classificação das amostras de cachaça foi utilizada a Análise Discriminante Linear (LDA - *Linear Discriminant Analysis*) e Análise Discriminante Quadrática (QDA - *Quadratic Discriminant Analysis*). O objetivo de ambas consiste em obter funções matemáticas capazes de classificar um objeto em uma de suas classes, com base nas características consideradas, buscando minimizar a probabilidade de classificação errada.

Na análise discriminante linear considera que a diferença entre as classes está relacionada apenas com o vetor média das classes, visto que a matriz de covariância é igual para todas as classes. A fronteira de decisão fica definida por uma função linear e uma razoável acurácia pode ser obtida, desde que haja uma diferença razoável entre os vetores média de cada classe. Se os vetores médias forem muito próximos ou quase iguais, o classificador linear fornecerá resultados pobres. Por sua vez, a análise discriminante quadrática estima que cada classe tem vetor média e matriz de covariâncias próprios, resultando em funções de decisão quadráticas[16][17]. A métrica utilizada foi a distância de *Mahalanobis* que difere da distância Euclidiana por levar em consideração a correlação entre os conjuntos de dados.

### F. Resultados e discussão

Foram realizados experimentos para verificar quais informações são mais importantes para o problema de classificação do tipo de madeira para o envelhecimento de cachaça. As informações obtidas pelo estudo foram divididas em duas partes: dados químicos e dados de informações do modelo de cores (CIELab e RGB).

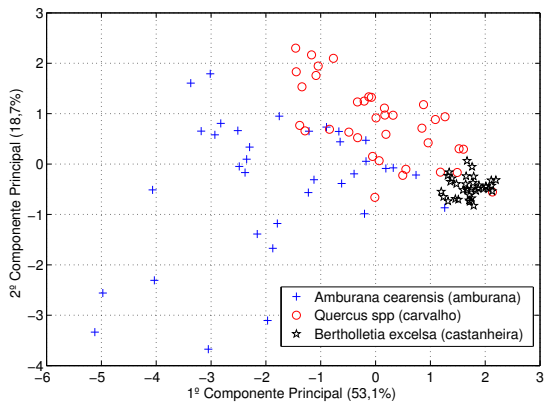


Figura 2: Gráfico de dispersão de objetos utilizando as duas componentes principais de maior variância

A Figura 2 apresenta a dispersão dos objetos das 3 classes consideradas projetadas sobre as 2 primeiras componentes principais de maior variância. As componentes principais foram calculadas sobre todas as variáveis disponíveis, isto é, dados químicos e dados de informação de cor referenciados na Tabela II e Tabela III. É possível observar que o uso de componentes principais não permite uma boa discriminação das classes, visto que há uma sobreposição entre os objetos de diferentes classes. Para os dois grupos de dados medidos, foi calculada a discriminabilidade de Fisher univariada. Tal medida indica o quanto uma variável discrimina as classes consideradas. O resultado é apresentado na Figura 3.

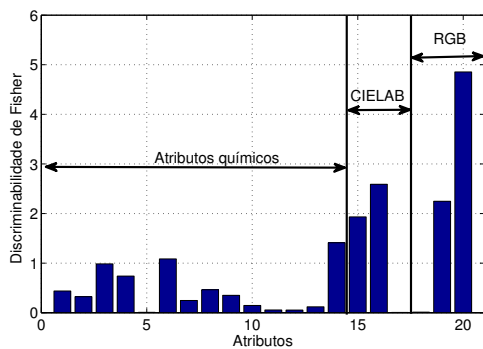


Figura 3: Discriminabilidade de Fisher utilizando atributos químicos, modelo de cores CIELab e RGB para o problema de classificação do tipo de madeira para envelhecimento de cachaça.

Como se pode notar os atributos relacionados a informação de cor tem maior discriminabilidade para o problema de classificação do tipo de madeira. Vale ressaltar que a discriminabilidade de Fisher considera o atributo de forma univariada, assim o uso dos atributos de maior discriminabilidade não implica em um bom modelo de classificação.

Identificados os atributos de maior discriminabilidade (Atributos 16 e 20), conduziu-se os experimentos utilizando

classificador discriminante linear e quadrático. Para cada classificador foi utilizado atributos químicos e informações dos modelos de cores. Ao analisar a taxa de acerto das análises discriminantes na Tabela IV, foi verificado que a análise discriminante quadrática (QDA), obteve o melhor resultado (99,06%) utilizando dados de informações do modelo de cores (CIELab e RGB).

Usando atributos químicos		
	LDA	QDA
Taxa de acerto(%)	93,45%	~*
número de erros	7	-
Usando modelo de cores		
	LDA	QDA
Taxa de acerto(%)	98,13%	99,06%
número de erros	2	1

Tabela IV: Taxa de acerto para as análises discriminantes linear e quadrática

\*Não foi possível obter os resultados do classificador de análise discriminante quadrática (QDA) utilizando atributos químicos em razão da presença de colinearidade dos atributos considerados e que não permitiu a inversão da matriz de covariância que é utilizada na construção do classificador.

Uma das vantagens do uso de classificadores como de análise discriminante é a possibilidade de extrair o conhecimento acerca de como a classificação é realizada. Neste caso em particular é possível visualizar as fronteiras de decisão geradas pelo classificador através de hiperplanos. Os hiperplanos dividem o espaço em diversas regiões e estas divisões determinam a fronteira de decisão que distingue as classes. Para que os hiperplanos consigam separar as classes corretamente, não pode haver pontos de classes distintas numa mesma região.

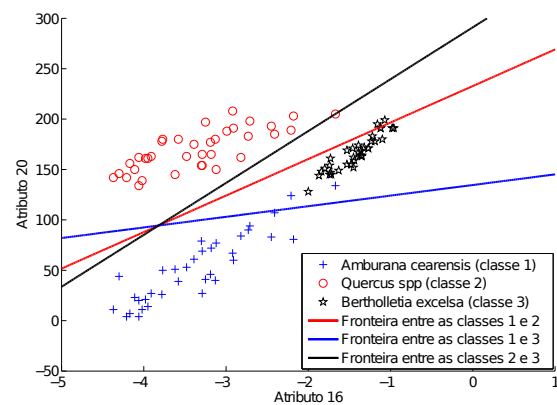


Figura 4: Gráfico de dispersão de objetos com hiperplano de separação de classes obtidos por discriminante linear

Na Figura 4 é apresentado 3 hiperplanos e 3 classes que correspondem as madeiras Amburana (classe 1 - *Amburana cearensis*), Carvalho (classe 2 - *Quercus spp*) e Castanheira (classe 3 - *Bertholletia excelsa H.B.K.*). O hiperplano de cor vermelha faz a separação entre as classes 1 e 2, o hiperplano de cor azul faz a separação entre as classes 1 e 3, e o hiperplano de cor preta faz a separação entre as classes 2 e 3. Nota-se que os hiperplanos mostram que as classes são linearmente separáveis, pois não há sobreposição das classes identificadas nas fronteiras de decisão.

Posteriormente foi realizado experimento utilizando a análise discriminante quadrática. Com a análise discriminante quadrática, pode-se utilizar além de hiperplanos, elipsóides determinando regiões de classes mais precisas. Na Figura 5, são identificadas três regiões segmentadas por hiperplanos, cada qual apresenta as classes identificadas. O hiperplano de cor vermelha faz a distinção entre as classes 1 e 2, seu traçado é linear pois o seu componente quadrático é igual a zero. Diferente dos hiperplanos de cor azul e preta. O hiperplano azul distingue as classes 1 e 3, e neste cenário há uma maior delimitação da região que identificada a classe 3. No hiperplano de cor preta a distinção está para as classes 2 e 3.




Figura 5: Gráfico de dispersão de objetos com hiperplano de separação de classes obtidos por discriminante linear quadrática

Fazendo um comparativo entre as fronteiras observadas nas figuras 4 e 5, nota-se que o classificador de discriminante quadrático gerou uma fronteira de área menor para a classe 3. Tal resultado é explicado em razão da discriminante quadrática utilizar matrizes de covariâncias individuais para cada classe o que permite que a dispersão dos objetos seja considerada de forma individual, ao contrário do discriminante linear.

### G. Conclusão

O artigo proposto demonstra que a utilização de informações de cores para o problema de identificação do tipo de madeira para classificação de amostra de cachaça apresenta melhores resultados do que a classificação utilizando dados químicos. O custo inerente a utilização de dados químicos é alto. A mão-de-obra deve ser especializada e o seu alto custo é restrito a laboratórios de pesquisa e desenvolvimento. Assim a utilização de um método que observa o modelo de cores (RGB e CIELab) é factível na substituição dos atributos químicos, seja pelo custeio e taxa de acerto. Como todo processo de produção sua aplicação deve ser em ambiente controlado para evitar falhas e fraudes.

### AGRADECIMENTOS

Os autores da pesquisa agradecem a CAPES, FAPEG e Escola de Agricultura do Instituto Politécnico de Bragança pelo suporte financeiro provido para a pesquisa.

### REFERENCES

- [1] F. W. B. Aquino, R. F. Nascimento, S. Rodrigues, and A. R. S. Casemiro, "Determinação de marcadores de envelhecimento em cachaças," *Food Science and Technology (Campinas)*, vol. 26, pp. 145 – 149, 03 2006. [Online]. Available: <http://dx.doi.org/10.1590/S0101-20612006000100024>
- [2] J. B. Faria, D. W. Franco, and J. R. Piggott, "The quality challenge: cachaça for export in the 21st century," in *Distilled spirits: tradition and innovation 2004*. Nottingham University Press, Nottingham, UK, 2004, pp. 215–221.
- [3] M. D. C. A. de Souza, P. Vásquez, N. L. del Mastro, T. E. Acree, and E. H. Lavin, "Characterization of cachaça and rum aroma," *Journal of Agricultural and Food Chemistry*, vol. 54, no. 2, pp. 485–488, 2006, pMID: 16417309. [Online]. Available: <http://pubs.acs.org/doi/abs/10.1021/jf0511190>
- [4] P. P. de Souza, D. V. Augusti, R. R. Catharino, H. G. L. Siebald, M. N. Eberlin, and R. Augusti, "Differentiation of rum and brazilian artisan cachaça via electrospray ionization mass spectrometry fingerprinting," *Journal of Mass Spectrometry*, vol. 42, no. 10, pp. 1294–1299, 2007. [Online]. Available: <http://dx.doi.org/10.1002/jms.1197>
- [5] Y. Wan, X. Sun, and R. Guo, "Shape and structure features based chinese wine classification," in *Computational Intelligence and Natural Computing, 2009. CINC '09. International Conference on*, vol. 2, 2009, pp. 39–43.
- [6] M. A. Duarte-Mermoud, N. H. Beltrán, and M. A. Bustos, "Chilean wine varietal classification using quadratic fisher transformation," *Pattern Anal. Appl.*, vol. 13, no. 2, pp. 181–188, 2010.
- [7] B. Boisier, A. Mansouri, P. Gouton, and P. Trollat, "Wine color characterization and classification for nuances reproduction," in *Signal-Image Technology Internet-Based Systems (SITIS), 2009 Fifth International Conference on*, 2009, pp. 93–98.
- [8] R. C. Gonzalez and R. E. Woods, *Digital Image Processing (3rd Edition)*. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006.
- [9] L. Qiongshuai and W. Shiqing, "A hybrid model of neural network and classification in wine," in *Computer Research and Development (ICCRD), 2011 3rd International Conference on*, vol. 3, 2011, pp. 58–61.
- [10] D. Kruzlicova, J. Mocak, B. Balla, J. Petka, M. Farkova, and J. Havel, "Classification of slovak white wines using artificial neural networks and discriminant techniques," *Food Chemistry*, vol. 112, no. 4, pp. 1046 – 1052, 2009. [Online]. Available: <http://dx.doi.org/10.1016/j.foodchem.2008.06.047>
- [11] D. Cozzolino, G. Cowey, K. Lattey, P. Godden, W. Cynkar, R. Damberg, L. Janik, and M. Gishen, "Relationship between wine scores and visible-near-infrared spectra of australian red wines," *Analytical and Bioanalytical Chemistry*, vol. 391, no. 3, pp. 975–981, 2008. [Online]. Available: <http://dx.doi.org/10.1007/s00216-008-2071-3>
- [12] M. Ministério da Agricultura, Pecuária e Abastecimento, "Instrução normativa nº 13, de 29 de junho de 2005," [online], Jan. 2014, <http://goo.gl/1DjmwL>.
- [13] X. Sun, H. J. Gong, F. Zhang, and K. J. Chen, "A digital image method for measuring and analyzing color characteristics of various color scores of beef," in *Image and Signal Processing, 2009. CISP '09. 2nd International Congress on*, 2009, pp. 1–6.
- [14] R. Kohavi, "A study of cross-validation and bootstrap for accuracy estimation and model selection." Morgan Kaufmann, 1995, pp. 1137–1143.
- [15] W. Härdle and L. Simar, *Applied Multivariate Statistical Analysis*. Springer, 2012.
- [16] M. Erbert, "Uso da análise discriminante regularizada (rda) no reconhecimento de padrões em imagens digitais hiperespectral de sensoramento remoto," Master's thesis, Universidade Federal do Rio Grande do Sul - UFRGS, 2001.
- [17] R. A. Fisher. "The use of multiple measurements in taxonomic problems," *Annals of Eugenics*, vol. 7, no. 7, pp. 179–188, 1936.