

ALGORITMO DE ESTRATIFICAÇÃO DE PORÇÕES ALIMENTARES BASEADO EM IMAGEM

Y. M. Shiga*, K. S. Coelho**, J. S. Dias* e G. L. Ferrari*

*Departamento de Engenharia Elétrica – Universidade Federal do Paraná, Curitiba, Brasil

**Departamento de Alimentos e Nutrição Experimental / Faculdade de Ciências Farmacêuticas –
Universidade de São Paulo, São Paulo, Brasil
e-mail: yurishiga@gmail.com

Resumo: Este artigo apresenta um método de estratificação de alimentos baseado em imagens de porções alimentares, onde é possível separar os diferentes elementos da porção alimentar no prato utilizando algoritmos de quantização de cores e crescimento de regiões. Cada elemento identificado é classificado com base na sua coloração e na sua textura utilizando redes bayesianas, que ao final da execução de testes obteve-se uma classificação com 89,6% de aproveitamento.

Palavras-chave: Segmentação, classificação, processamento digital de imagens, redes bayesianas, porções alimentares.

Abstract: *This paper presents a method of stratification of food based on images of food portions, where it is possible to separate the different elements of food portions on plate using color quantization and growing regions algorithms. Each element identified is classified based on its color and its texture using Bayesian networks, at the end of the running tests there was obtained a rating 89.6% yield.*

Keywords: *Segmentation, classification, digital image processing, Bayesian networks, food portions.*

Introdução

As ações de saúde pública, voltadas principalmente para suprir o déficit nutricional, também se voltam à elaboração de diretrizes alimentares para diminuição de risco de doenças crônicas não transmissíveis [1]. Diversos estudos mostram que a melhora da alimentação e, conseqüente, do estado nutricional é a chave para proporcionar benefícios à saúde da população, bem como reduzir gastos públicos [2].

O desenvolvimento de ferramentas computacionais, voltadas ao apoio à decisão, têm sido propostas nos últimos anos e, seu objetivo principal é auxiliar os indivíduos a calcular sua ingestão de calorias. Como por exemplo, o sistema proposto por Buisson [3], que associa nutrição e conjuntos fuzzy para calcular conjuntos de ações para auxiliar o balanceamento da alimentação de um indivíduo.

Outra proposta contributiva é analisar os valores calóricos das refeições consumidas por um indivíduo, para que o mesmo possa controlar seus hábitos alimentares e cuidar de sua saúde. Porém nem sempre

estes valores podem ser calculados com precisão, como em restaurantes, por exemplo, em que cada indivíduo prepara o seu prato com os alimentos e a quantidade que desejar, sem que haja uma maneira trivial de calcular os valores calóricos do que se está ingerindo.

Este artigo propõe um algoritmo com a capacidade de segmentar e classificar diferentes alimentos, baseado em imagens de porções alimentares. Trata-se de um estudo inicial com a finalidade de identificar e extrair as características de cada alimento, sendo assim, a primeira etapa do desenvolvimento de uma ferramenta computacional capaz de calcular o valor calórico de cada porção alimentar que compõem o prato.

Materiais e métodos

Aquisição e grupo de teste – Para o desenvolvimento do algoritmo, foram adquiridas imagens de nove porções alimentares de diferentes grupos de alimentos que compõe a Pirâmide Brasileira dos Alimentos [4]:

- grupo do arroz, pão, massa, batata, mandioca – utilizou-se arroz branco e batata frita;
- verduras e legumes – utilizou-se alface, rúcula, tomate e cenoura;
- carnes e ovos – utilizou-se carne bovina e ave;
- feijões – utilizou-se feijão preto.

Todas as imagens foram adquiridas em um mesmo ambiente, posicionando a câmera sobre o prato em um ângulo de 90°, a uma distância de 60 cm, com a câmera de 5 megapixels de um smartphone Motorola® Moto G XT1033.

As imagens foram obtidas de pratos contendo apenas os alimentos propostos separadamente para o grupo de treino, e de pratos contendo vários destes alimentos juntos para o grupo de testes.

Algoritmo – O algoritmo proposto, implementado em MATLAB®, necessita que as porções alimentares estejam devidamente separadas no prato, pois o sistema ainda não possui a capacidade de prever a sobreposição e a mistura dos alimentos. As suas principais etapas são: pré-processamento da imagem, segmentação, extração de características e classificação. A Figura 1 apresenta seu diagrama em blocos.




Figura 1: Diagrama em blocos do algoritmo proposto.

Pré-processamento da imagem – A primeira etapa do algoritmo é responsável pela rotação da imagem para a posição horizontal, caso necessário, e pelo seu redimensionamento para 600 pixels de altura, mantendo assim, um padrão para o tamanho da imagem, sem sobrecarregar o sistema caso a imagem tenha uma resolução muito alta.

Em seguida, o algoritmo busca a região de interesse utilizando a Transformada Circular de Hough [5] com os parâmetros polaridade clara e sensibilidade de 95%, isto é, o algoritmo encontra o maior círculo de tom claro na imagem, ou seja, a borda do prato. Assim, consegue-se separar a região de interesse, eliminando o fundo da imagem. A Figura 2 mostra um exemplo de uma imagem de um prato com as porções alimentares antes e depois deste processo.



(a)



(b)

Figura 2: (a) Imagem original do prato de alimentos. (b) Prato de alimentos sem o fundo da imagem.

Segmentação – Após o pré-processamento, a imagem é segmentada utilizando o JSEG [6], um algoritmo criado com o intuito de segmentar imagens de maneira totalmente automática. Este algoritmo consiste em duas etapas independentes: quantização de cores e rotulação por segmentação espacial.

A primeira etapa, a quantização, é responsável por limitar os níveis de cores da imagem, a fim de facilitar a distinção das diferentes regiões. Neste trabalho usou-se o parâmetro de quantização sugerido pelos desenvolvedores do JSEG [6], ou seja, 16 níveis de cores. A Figura 3 apresenta o resultado do processo de quantização com 16 níveis de cores do algoritmo JSEG.



Figura 3: Imagem quantizada para 16 níveis de cores.

A segunda etapa do algoritmo é responsável pela rotulação da imagem. Após a etapa de quantização, os pixels da imagem são substituídos por seus rótulos correspondentes, utilizando técnicas de segmentação espacial por crescimento de regiões, formando, assim, um mapa de classe da imagem, conforme Figura 4, no qual é possível distinguir os diferentes alimentos da imagem da porção alimentar.



(a)



(b)

Figura 4: (a) Rótulo da segmentação da imagem. (b) Imagem com o rótulo aplicado sobre ela.

Extração de características – Para cada segmento obtido têm-se suas características extraídas com base em sua cor e textura. Para distinguir as cores, são extraídas as médias RGB da imagem, ou seja, o valor médio dos pixels nas cores vermelho, verde e azul.

Já para as características de textura, é criada a matriz de co-ocorrência dos níveis de cinza (GLCM) da imagem. Esta matriz é gerada calculando quantas vezes um pixel com nível de cinza valor i ocorre horizontalmente adjacente a um pixel com o valor j , e por fim, baseadas na GLCM, são extraídas algumas das medidas propostas por Haralick [7]. Estas medidas são:

- Contraste: intensidade de contraste entre um pixel e seu vizinho;
- Correlação: o quão correlato um pixel é a seu vizinho;
- Energia ou uniformidade: soma de elementos quadrados no GLCM;
- Homogeneidade: proximidade da distribuição dos elementos no GLCM ao GLCM diagonal.

As Tabelas 1 e 2 apresentam um exemplo com as características extraídas de um prato com as porções alimentares apresentado na Figura 2.

Tabela 1: Características relacionadas à cor.

	Média RED	Média GREEN	Média BLUE
Alface	79	89	23
Arroz	171	133	90
Carne	96	47	20
Cenoura	201	53	23
Feijão	34	19	13
Frango	166	98	44

Tabela 2: Características relacionadas à textura.

	Contraste	Correlação	Energia	Homogeneidade
Alface	0,1510	0,8915	0,3026	0,9327
Arroz	0,1411	0,8618	0,3552	0,9330
Carne	0,1634	0,7707	0,4291	0,9313
Cenoura	0,2027	0,8211	0,3247	0,9092
Feijão	0,1009	0,8547	0,6906	0,9605
Frango	0,2159	0,7659	0,3258	0,9027

Classificação – A classificação dos alimentos é realizada utilizando redes bayesianas [8], que são modelos usados em inteligência artificial nas mais diferentes aplicações, principalmente em problemas onde os dados/informações necessários ao processo de tomada de decisão apresentam a necessidade da manipulação de incerteza [9].

As características extraídas de cada segmento são analisadas por uma rede bayesiana pré-treinada, e, finalmente, classificadas conforme a análise da rede, ou seja, o algoritmo rotula cada elemento obtido na segmentação, de acordo com o alimento correspondente (alface, arroz, carne, etc.), inclusive no caso de não ser um alimento, como um espaço vazio ou as bordas do prato.

Resultados

Para analisar a eficácia do algoritmo proposto, cada imagem foi segmentada e teve suas características extraídas conforme o algoritmo descrito. Foram utilizadas, para o treinamento da rede, quinze imagens de cada alimento em pratos distintos, e para os testes, quinze imagens destes mesmos alimentos, extraídas de imagens de pratos contendo diversas porções alimentares.

Após este processo, foi realizado a classificação manual de todos os elementos obtidos de cada porção alimentar. Em seguida, as imagens selecionadas para o grupo de treino foram utilizadas para treinar uma rede bayesiana, com o algoritmo de busca K2 e estimador simples, utilizando o Weka [10], um programa desenvolvido em plataforma Java para resolver problemas de mineração de dados baseado em aprendizagem de máquinas.

Com a rede treinada, foram realizados testes comparando o grupo de treino ao grupo de testes. O sistema classificou corretamente 89,6% dos elementos selecionados com um tempo de processamento total de 0,49 segundos, em uma máquina com processador Intel® Core™ i5-2500K CPU 3,3GHz com 8GB de memória RAM.

Conforme a Tabela 3, os testes realizados mostram que, das amostras adquiridas de cada alimento, a taxa de acerto do arroz, da cenoura, do feijão e do tomate foi de 100%. Já a rúcula foi o que se obteve o pior resultado, com uma taxa de acerto de 66,7%.

Tabela 3: Taxa de acerto de cada alimento testado.

Alimento	Taxa de acerto
Alface	93,3%
Arroz	100%
Batata	80%
Carne	93,3%
Cenoura	100%
Feijão	100%
Frango	73,3%
Rúcula	66,7%
Tomate	100%

Discussão

Apesar do baixo número de amostras coletadas para os testes com o algoritmo, foi possível visualizar que a segmentação das porções alimentares foi realizada de forma satisfatória, detectando e separando corretamente os diferentes alimentos, quando devidamente organizados no prato.

Na classificação, o sistema classificou alguns alimentos incorretamente, como por exemplo, a rúcula, que de quinze amostras testadas, quatro foram classificadas como alface. Isto se dá devido a certas similaridades entre as características extraídas destes alimentos conforme mostra a Tabela 4, pois nas imagens obtidas, ambos possuem algumas semelhanças em sua coloração e textura.

Tabela 4: Exemplo de características extraídas dos alimentos rúcula e alface.

	Rúcula	Alface
Média RED	89	79
Média GREEN	84	89
Média Blue	27	23
Contraste	0,1527	0,1510
Correlação	0,9654	0,8915
Energia	0,2308	0,3026
Homogeneidade	0,9295	0,9327

Conclusão

O algoritmo proposto neste artigo para estratificação de porções alimentares baseado em imagens apresentou uma taxa de acerto de 89,6%. Para os alimentos arroz,

cenoura, feijão e tomate teve uma taxa de acerto de 100% e para rúcula, o pior caso, de 66,7%.

A fim de melhorar o algoritmo proposto e torná-lo mais robusto, é necessário aumentar a base de dados, tanto para um grupo maior de alimentos, quanto para o número de amostras de um mesmo elemento.

Mesmo tratando-se de um estudo preliminar, os resultados obtidos evidenciam que o algoritmo é capaz de identificar diferentes tipos de alimentos através das características de cor e textura. Porém, ainda será necessário fazer análises de porções alimentares com sobreposição de alimentos e também estudar métodos para estimar o volume de cada porção alimentar.

Referências

- [1] Mota JF, Rinaldi AEM, Pereira AF, Maestá N, Scarpin MM, Burini RC. Adaptação do índice de alimentação saudável ao guia alimentar da população brasileira. *Revista de Nutrição*. 2008; 21(5):545-52.
- [2] Kennedy ET, Ohls J, Carlson S, Fleming K. The Healthy Eating Index: design and applications. *J Am Diet Assoc*. 1995; 95(10):1103-8.
- [3] Buisson JC. Nutri-Educ, a nutrition software application for balancing meals, using fuzzy arithmetic and heuristic search algorithms. *Artificial Intelligence in Medicine*. 2008; 42(3):213-27.
- [4] Philippi ST. Pirâmide dos alimentos: fundamentos básicos da nutrição. 1ª ed. Editora Manole; 2008.
- [5] Atherton TJ, Kerbyson DJ. Size invariant circle detection. *Image and Vision Computing*. 1999; 17(11):795-803.
- [6] Deng Y, Manjunath BS, Shin H. Color image segmentation. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition CVPR'99*. 1999; 2(1):446-51.
- [7] Haralick RM, Shanmugam K, Dinstein I. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*. 1973; 3(6):610-21.
- [8] Korb KB, Nicholson AE. Bayesian Artificial Intelligence. 1ª ed. Editora CRC Press; 2003.
- [9] Perazzo MJ, Cozman FG. Derivadas em redes bayesianas usando eliminação de variáveis. Em: *Anais do Congresso Brasileiro de Automática*; 2004 Sep 21-24; Gramado, RS, Brasil. 2004. p. 6pags.
- [10] Witten IH, Frank E, Hall MA. Data Mining: Practical Machine Learning Tools and Techniques. 3ª ed. Editora Morgan Kaufmann; 2011.