

(12) PEDIDO INTERNACIONAL PUBLICADO SOB O TRATADO DE COOPERAÇÃO EM MATÉRIA DE PATENTES (PCT)

(19) Organização Mundial da Propriedade Intelectual

Secretaria Internacional



(10) Número de Publicação Internacional  
**WO 2011/106854 A1**

(43) Data de Publicação Internacional  
9 de Setembro de 2011 (09.09.2011)

PCT

- (51) Classificação Internacional de Patentes :  
*G06K 9/00* (2006.01) *G06K 9/46* (2006.01)  
*G06K 9/62* (2006.01)
- (21) Número do Pedido Internacional :  
PCT/BR2010/000073
- (22) Data do Depósito Internacional :  
3 de Março de 2010 (03.03.2010)
- (25) Língua de Depósito Internacional : Português
- (26) Língua de Publicação : Português
- (71) Requerente (para todos os Estados designados, exceto US) : **AGÊNCIA DE INOVAÇÃO - INOVA - UNIVERSIDADE ESTADUAL DE CAMPINAS - UNICAMP** [BR/BR]; Av. Roxo Moreira, 1831, CEP 13083-970 - Campinas, SP (BR).
- (72) Inventores; e
- (75) Inventores/Requerentes (para US unicamente) : **ANDERSON DE REZENDE, Rocha** [BR/BR]; Travessa Jorge Norton, 40, apto. 44A, Bairro Bosque, CEP 13026-063 - Campinas, SP (BR). **DANIEL CABRINI, Hauagge** [BR/BR]; 820A, Harshow Road, Ithaca, NY 14850 (US). **JACQUES, Wainer** [BR/BR]; Rua Luiz Anhaia, 86, CEP 05433-020, São Paulo - SP (BR). **SIOME KLEIN, Goldenstein** [BR/BR]; Rua Fernão Lopes, 1400, Apto. 313, Pq. Taquaral, CEP 13087-051, Campinas, SP (BR).
- (74) Mandatário : **BITTAR MAGNANI, Rosa Maria**; Av. Roxo Moreira, 1831, CEP 13083-970 - Campinas, SP (BR).
- (81) Estados Designados (sem indicação contrária, para todos os tipos de proteção nacional existentes) : AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IS, JP, KE, KG, KM, KN, KP, KR, KZ, LA, LC, LK, LR, LS, LT, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PE, PG, PH, PL, PT, RO, RS, RU, SC, SD, SE, SG, SK, SL, SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, ZA, ZM, ZW.
- (84) Estados Designados (sem indicação contrária, para todos os tipos de proteção regional existentes) : ARIPO (BW, GH, GM, KE, LS, MW, MZ, NA, SD, SL, SZ, TZ, UG, ZM, ZW), Eurasiático (AM, AZ, BY, KG, KZ, MD, RU, TJ, TM), Europeu (AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, ML, MR, NE, SN, TD, TG).
- Publicado:  
— com relatório de pesquisa internacional (Art. 21(3))

(54) Title : METHOD AND SYSTEM FOR RECOGNITION AND CLASSIFICATION OF OBJECTS IN SEMI-CONTROLLED ENVIRONMENTS

(54) Título : MÉTODO E SISTEMA PARA RECONHECIMENTO E CLASSIFICAÇÃO DE OBJETOS EM AMBIANTES SEMI-CONTROLADOS

(57) Abstract : The present invention relates to a method, namely a system for recognition and categorization of objects (e.g. fruit, legumes, vegetables, flowers, boxes, etc.) in semi-controlled environments, where there is no use of diverse sources of light of different wavelengths (e.g. supermarkets, fairs, distribution centres). The present technology allows the extraction of descriptive characteristics of a dataset (e.g. images of the objects to be categorized) and combination thereof for the purpose of generating a more robust and flexible classifier. This invention relates to the combination of different types of descriptors and also the association of various types of classifiers, each specialized and better configured for a set of characteristics or types in a confused classification. There is an intelligent combination of binary classifiers that divide the greater multi-type classification problem into small problems. The present invention is capable of aggregating the information extracted from various types of media with a view to solving the problem of classifying objects in internal environments, such as a distribution centre or a supermarket, with the aim of automating the purchasing process.

(57) Resumo : A presente invenção trata-se de um método, sistema para reconhecimento e categorização de objetos (e.g., frutas, legumes, verduras, flores, caixas, etc.) em ambientes semi-controlados, os quais não utilizam diversas fontes de luz de diferentes comprimentos de onda (e.g., supermercados, feiras, centros de distribuição). A presente tecnologia possibilita a extração de características descritivas de um conjunto de dados (e.g., imagens dos objetos a serem categorizados) e combinação para geração de um classificador mais robusto e flexível. Tal invenção refere-se à combinação de diferentes tipos de descritores assim como a associação de diferentes tipos de classificadores, cada um, especializado e melhor configurado para um conjunto de características ou classes em confusão de classificação. Há uma combinação inteligente de classificadores binários que dividem o problema maior de classificação multi-classe em pequenos problemas. A presente invenção é capaz de agregar as informações extraídas de várias classes de mídias para resolver o problema de classificação de objetos em ambientes internos tais como um centro de distribuição ou um supermercado, visando automatização do processo de compras.



WO 2011/106854 A1

**“MÉTODO E SISTEMA PARA RECONHECIMENTO E CLASSIFICAÇÃO DE  
OBJETOS EM AMBIENTES SEMI-CONTROLADOS”  
CAMPO DA INVENÇÃO**

A presente invenção trata-se de um método, sistema para reconhecimento e categorização de objetos (e.g., frutas, legumes, verduras, flores, caixas, etc.) em ambientes semi-controlados, os quais não utilizam diversas fontes de luz de diferentes comprimentos de onda (e.g., supermercados, feiras, centros de distribuição). A presente tecnologia possibilita a extração de características descritivas de um conjunto de dados (e.g., imagens dos objetos a serem categorizados) e combinação para geração de um classificador mais robusto e flexível.

Tal invenção refere-se a combinação de diferentes tipos de descritores assim como a associação de diferentes tipos de classificadores, cada um, especializado e melhor configurado para um conjunto de características ou classes em confusão de classificação. Há uma combinação inteligente de classificadores binários que dividem o problema maior de classificação multi-classe em pequenos problemas.

A presente invenção é capaz de agregar as informações extraídas de várias classes de mídias para resolver o problema de classificação de objetos em ambientes internos tais como um centro de distribuição ou um supermercado, visando automatização do processo de compras.

**FUNDAMENTOS DA INVENÇÃO**

O reconhecimento e classificação de diferentes tipos de produtos tais como frutas, verduras, legumes etc., é uma tarefa recorrente em supermercados e centros de distribuição, onde o operador de caixa precisa ser capaz de apontar não apenas a espécie de um produto em particular (e.g., banana, maçã, pêra), mas também sua variedade (i.e., *Golden Delicious*, *Jonagold*, *Fuji*, etc.). Conseqüentemente, o preço está diretamente ligado à determinação correta da espécie/variedade em questão.

O uso de sistemas baseados em códigos de barras praticamente acabou com esse problema para produtos embalados. No entanto, no caso particular de frutas, legumes e verduras os consumidores desejam escolher seus produtos um a um tocando-os e verificando os que possuem melhores condições. Esse procedimento dificulta o empacotamento a priori e leva à pesagem sob demanda. Uma solução comum para esse

problema na maioria dos estabelecimentos comerciais consiste em utilizar códigos para cada tipo de produto o que pode resultar em problemas de memorização dos códigos.

Como um auxílio ao operador do caixa, alguns estabelecimentos utilizam um pequeno caderno de códigos e figuras. O problema com esse paliativo é que ele  
5 consome tempo em tempo de operação ocasionando filas nos estabelecimentos.

Nesse sentido, a presente invenção propõe a resolução deste problema adaptando uma câmera capaz de capturar imagens do produto a ser categorizado ao sistema de pesagem (e.g., balança) em estabelecimentos comerciais. O sistema é capaz de fazer a extração de diversos elementos de informação (e.g., cor, forma, textura,  
10 silhueta) a respeito do produto e combiná-los de forma a criar um discriminador poderoso para aquele produto. Especificamente, as características de cor podem ser representadas, por exemplo, por histogramas de cor relativas ao objeto em análise. A texturas podem ser representadas por padrões repetitivos ao longo da superfície do objeto. A forma do objeto pode ser descrita por informações de contorno. A silhueta  
15 pode ser representada por um modelo de aparência simplificado do objeto. Formalmente, dado um produto em um ambiente semi-controlado tal como um centro de distribuição ou supermercado, de apenas uma variedade, em posição e quantidade arbitrárias, o sistema deve ser capaz de retornar uma lista de possíveis candidatos na forma (espécie, variedade) ao operador do caixa que, conseqüentemente, confirma o  
20 resultado mais conveniente (ambiente semi-controlado). Algumas vezes, o objeto em questão pode estar em embalagens plásticas que podem adicionar reflexões especulares e mudanças de tom na imagem capturada dos produtos.

Devido à grande variedade e à impossibilidade de prever quais os tipos de produtos são vendidos nos mais diversos estabelecimentos comerciais, a presente  
25 invenção baseia-se em uma solução que prioriza o treinamento simplificado podendo ser realizado por um indivíduo com pouco ou nenhum conhecimento técnico.

O sistema apresenta bons resultados de reconhecimento mesmo quando apresentado à poucos exemplos de treinamento (e.g., menos de 30 imagens por produto). A abordagem proposta apresenta as condições necessárias para permitir o  
30 aprendizado semi-supervisionado em que classificações em tempo de execução, ao serem confirmadas pelo operador do caixa, podem ser incorporadas ao sistema.

A abordagem permite a combinação de diversas características e classificadores especializados em partes do problema que requerem menos treinamento que abordagens tradicionais disponíveis que simplesmente consideram as diversas características como tendo as mesmas propriedades e as combinam em um grande vetor de descrição.

A abordagem proposta também possui a habilidade de incorporar novas classes de produtos de forma a requerer apenas treinamento parcial em relação às novas adições. Finalmente, se novas características de descrição tornam-se disponíveis, a abordagem é capaz de incorporá-las exigindo, para isso, apenas o treinamento em relação às adições.

A presente invenção se enquadra no campo de pesquisa conhecido como *Categorização de Imagens*. Abordagens anteriores para resolver problemas de categorização consideraram soluções baseadas em propriedades de cor, borda e textura (Pass et al., 1997; Stehling et al., 2002; Unser, 1986); características de baixo e médio nível (Cutzu et al, 2005; Lyu & Farid, 2005; Rocha & Goldenstein, 2007; Serrano et al., 2002). Adicionalmente, (Heidemann, 2004) apresentou uma abordagem para estabelecimento automático de categorias de imagens a partir de descritores de cor e forma utilizando um método de aprendizado não supervisionado.

Diretamente relacionada à presente invenção, o sistema *VeggieVision* (Bolle et al., 1996) foi a primeira tentativa de um sistema automático de reconhecimento de produtos em supermercados. O sistema proposto baseia-se em propriedades de cor, textura e densidade (requerendo informações extras da balança/sistema). Entretanto, como o sistema foi proposto há bastante tempo, ele não tem as vantagens de descritores modernos e poderosos propostos na literatura recente. O acerto reportado pelo sistema *VeggieVision* é de aproximadamente 95% em alguns cenários. No entanto, para atingir esse resultado, o sistema considera as quatro respostas mais prováveis. Tal sistema também incorpora no equipamento de aquisição dos dados mecanismos especiais para lidar com variações em iluminação e supressão de reflexões especulares. Em um cenário real, tais mecanismos poderiam levar ao encarecimento do sistema final. Comparativamente, a invenção aqui proposta, consegue um acerto de aproximadamente

99% de qualidade considerando as duas respostas mais prováveis para um determinado produto.

Diversos tipos de abordagens para categorização de objetos são descritos no estado da técnica. Em (Turk & Pentland, 1991) os autores utilizam análise de componentes principais para medir o erro de reconstrução da projeção da imagem analisada em um sub-espço e retornando para o espaço original. Esta abordagem não é interessante para a categorização de produtos (e.g., frutas, legumes, verduras) devido às mudanças de iluminação, posição e forma presentes no problema aqui relatado.

Em (Viola & Jones, 2004), os autores apresentam uma abordagem rápida e eficiente para localização e categorização de objetos empregando uma cascata de classificadores composta por características simples. O treinamento do sistema de classificação proposto é feito com a técnica *Adaboost* (Bishop, 2006). A grande desvantagem dessa abordagem é o alto custo computacional requerido para o treinamento (geralmente na ordem de milhares de imagens). Adicionalmente, a incorporação de novas categorias ao modelo não é direta.

Em (Agarwal et al., 2004) e (Jurie & Triggs, 2005), os autores apresentam abordagens que consideram o problema geral de categorização como problemas de reconhecimento de partes específicas de cada classe de objetos analisada. Essas técnicas são geralmente conhecidas no estado da técnica como *bag-of-features*. A principal limitação de tais soluções para o problema aqui relatado reside na dificuldade de definição de partes representativas quando há presença de variações abruptas de pose e iluminação nas imagens dos objetos. Adicionalmente, o custo computacional de tais técnicas é alto e é diretamente proporcional ao número de classes analisadas. Finalmente, tais abordagens não consideram os relacionamentos espaciais existentes entre as características.

Em (Weber, 2000), o autor propõe uma solução para categorização que leva em conta o relacionamento espacial das características (partes) analisadas utilizando um modelo de constelação generativo. A abordagem proposta tem a habilidade de lidar com oclusões parciais dos objetos em análise. No entanto, a solução é computacionalmente cara sendo sua complexidade tipicamente exponencial em relação ao número de partes (características) presentes no modelo de constelação. Uma extensão da abordagem de

(Weber, 2000) foi proposta por (Fei-Fei et al., 2006). Em tal extensão os autores propõe a utilização de conhecimento a priori (*prior*) na estimação da distribuição, reduzindo o número de exemplos de treinamento por classe necessários para o funcionamento da técnica para em torno de 10 imagens por classe. Entretanto, mesmo considerando esta  
5 extensão, o problema do crescimento exponencial do modelo em relação ao número de partes analisadas o torna não prático para a utilização no cenário de categorização aqui tratado.

Em (Berg et al., 2005), os autores apresentam uma abordagem para categorização de objetos baseada em pontos característicos calculados no gradiente da  
10 imagem em análise. Os pontos encontrados são conectados por um link e um casamento de padrões (reconhecimento do objeto) é feito quando o contorno achado é similar a um outro contorno presente no banco de dados de treinamento. Uma desvantagem desse método é a necessidade de uma etapa de otimização não linear para achar o melhor contorno. Adicionalmente, tal abordagem utiliza fortemente informações de silhueta dos  
15 objetos, o que não é uma característica muito informativa para produtos como limões laranjas, ou melões.

Em (Liu et al., 2005), os autores utilizam informações presentes nos cabeçalhos EXIF das imagens para resolver o problema de categorização de cenas. No problema resolvido pela invenção descrita neste documento, não há informações EXIF  
20 relevantes para as imagens analisadas tornando a solução de (Liu et al., 2005) inviável.

Em (Wang & Zhang, 2005), os autores apresentam uma solução para categorização de objetos que utiliza uma técnica conhecida como realimentação de relevância. No entanto, tal abordagem iterativa em um cenário de supermercado com  
25 diversas classes de objetos a serem categorizados em tempo real, essa abordagem torna-se não prática.

O documento de patente nº US 5,791,497 descreve um método para separação automática de frutas selecionadas. O método consiste em analisar a reflexividade à clorofila das frutas através de um sistema automatizado de iluminação por infra-vermelho, luz controlada e análise quanto à presença de clorofila. O sistema  
30 basicamente é capaz de separar frutas que foram atacadas por bactérias de outras frutas saudáveis. O trabalho em questão consegue separar uma classe de frutas defeituosas em

relação às outras não sendo adequado ao cenário geral de classificação de produtos em um cenário que envolve multi-classes e diversas propriedades de caracterização dos produtos.

5 O documento de patente nº US 4,741,042 descreve um método para classificação de fermentos e manchas em frutas. O sistema utiliza imagens em tons de cinza e trabalha num cenário simplificado.

10 O documento de patente nº US 7,151,606 apresenta um método para avaliação de qualidade de frutas e legumes. Não é um método de classificação em categorias e sim de avaliação de qualidade para posterior envio a diferentes pontos de venda. Para atingir seu objetivo, o sistema utiliza várias fontes de luz de diferentes comprimentos de onda em um ambiente controlado.

15 O documento de patente nº US 5,845,002 introduz um sistema para classificação de frutas cítricas em diferentes tipos segundo a presença e frequência de defeitos na casca. O sistema utiliza fonte de luz controlada. Para tal fim, a abordagem utiliza diferentes filtros para capturar diferentes defeitos. Esse é um sistema basicamente de avaliação de qualidade por defeitos no domínio limitado de frutas cítricas e não seria adequado ao cenário geral de multi-classificação de produtos tal como a abordagem aqui apresentada discutido neste texto de patente.

20 O documento de patente nº US 7,103,207 apresenta um sistema para classificação e avaliação de frutas. O sistema é voltado à avaliação de qualidade de um conjunto específico de frutas. Para tal finalidade, o sistema utiliza sensores espectrais de infravermelho e um espectômetro.

25 O documento de patente US 7,651,028 apresenta um sistema para reconhecimento de objetos em um ambiente de vendas que utiliza um ambiente controlado de luz omni-direcionais e um conjunto de equipamentos de iluminação e imageamento. O sistema necessita, também, identificar se o objeto está sobre a área de interesse para, então, acionar as luzes e sensores omnidirecionais. O sistema propõe a reconstrução do modelo tridimensional da imagem coletada para posterior reconhecimento. Não é muito claro se o sistema consegue atuar em um ambiente multi-  
30 classe, sem controle da iluminação ambiente, mais de um objeto a ser analisado ao mesmo tempo e com a presença de sombras e oclusões.

O documento de patente US 7,614,560 apresenta um sistema de iluminação para ambiente semi-controlados tais como supermercados para auxiliar no processo de classificação de produtos. No entanto, o sistema proposto utiliza luz multi-espectral para possibilitar a captura dos objetos sob análise. Não é um sistema de classificação de produtos e sim um sistema para controle de iluminação em um possível sistema de classificação.

O documento de patente EP n° 2,140,826 cobre técnica de identificação de produtos e objetos. No entanto, trata-se de um equipamento com foco em produtos médicos e cirúrgicos. Para tal atividade, utiliza informações coletadas por um Raio-X.

O documento de patente US n° 2009,222,928 descreve um equipamento genérico para processamento de imagens e dados, em geral aplicado em um contexto de fax e scanner.

O documento de patente CN n° 201,186,270 descreve um sistema para seleção e separação automática de frutas baseado em visão computacional, para automatização de uma planta industrial. Trata-se de um equipamento capaz de selecionar um tipo particular de objeto em relação ao restante para atribuição de ranks (notas). Pode ser utilizado em um esteira, por exemplo, onde alguns tipos de produtos precisam ser separados de outros. É diferente da presente invenção no sentido de que não é um sistema voltado à classificação multi-classe de produtos em ambientes semi-controlados em que não há controle da quantidade de produtos a ser analisada, bem como condições de iluminação, sombra, pontos de vista e oclusão. Outro documento de patente relacionado pode ser encontrado em em DE 19,755,583 que utiliza luz estroboscópica para classificação de frutas e verduras em uma esteira rolante. Este, também, trata-se de um trabalho para separação de um determinado espécime objetivo e não de um sistema de classificação multi-classe. Em ainda outro trabalho para seleção de produtos específicos em uma esteira rolante, encontra-se o documento de patente JP 6,007,748 que discute um método que utiliza informações de forma e peso, obtidas através de uma câmera e uma balança eletrônica, para determinar a classificação e o preço de uma fruta ou verdura em uma esteira rolante.

O documento de patente JP 1,293,174 utiliza uma câmera para separar frutas ou verduras em uma esteira rolante por sua similaridade de cor, para que cada lote



tenha todos os elementos parecidos entre si. Trata-se de um sistema simplificado de classificação baseado em informações apenas de cor que separa os elementos de modo que os similares fiquem agrupados para posterior empacotamento, por exemplo. Não resolve o problema de multi-classificação de produtos onde a informação de cor é apenas um dos pontos caracterizadores do objeto alvo.

Os documentos de patente US 5,546,475, US 6,005,959 e US6,310,964, apresentam um sistema que usa duas imagens, capturadas com intensidades de iluminação diferentes. O sistema extrai o fundo, identifica o tamanho dos objetos independente do número de objetos na cena, e compara com referências. Em ainda outro documento de patente relacionado, US 6,313,917, é apresentada uma técnica para classificação de verduras que utiliza assinatura da forma de onda espectral da luz. Para isso, o sistema utiliza um espectômetro. Ainda outro documento relacionado, US 6,332,573 apresenta uma técnica para classificação de verduras através de dispositivo ótico para divisão da luz em diferentes comprimentos de onda e posterior análise. Utilizado para cálculo de valor do produto. Não é claro como seria o comportamento das técnicas descritas em US 6,313,917 e US 6,332,573 quando em um cenário em que diversos objetos são apresentados simultaneamente e sob variações de iluminação e pose.

O documento de patente US 6,501,547 apresenta um dispositivo manual para iluminação, separação nas diferentes bandas de luz, e classificação de verduras. Note que o dispositivo descrito é manual tornando-se não propício a ambiente de tempo real como os descritos neste documento de patente. Em outro documento relacionado, US 6,606,579, descreve-se um método que combina informações espectrais e não espectrais para classificação de verduras. Para um ambiente totalmente controlado, em US 5,791,497 descreve-se um sistema que utiliza luz controlada e reflectância em diversos comprimentos de onda para separar diferentes tipos de frutas.

O documento de patente CN nº 1,603,013 descreve um mecanismo que para análise de frutas que, mecanicamente, gira as frutas e garante que o sistema captura nove imagens, de 240 graus. Com isso, eles fazem fusão de informações e tomada de decisões da planta industrial. Tal solução diferencia-se da presente invenção no sentido de que o cenário de atuação desta última é um ambiente não controlado e não há tempo

para captura de diversas imagens em ângulos diferentes. Além disso, o problema resolvido pela presente invenção é um problema multi-classe em que diversos produtos de um mesmo tipo podem estar sobre a balança simultaneamente tornando a captura complexa sem a inserção de diversos equipamentos adicionais que encareceriam o processo.

O documento de patente FR nº 2,789,608 descreve um sistema integrado para separação e classificação de produtos frágeis que vai desde caminhões até esteiras rolantes. Tal sistema utiliza a separação específica de um determinado produto.

O documento de patente US 6,296,186 apresenta um sistema para reconhecimento de produtos agrícolas baseado em luz estruturada (análise da foto de uma projeção de padrões conhecidos sobre a superfície 3D do objeto).

A presente invenção possui vantagens em relação ao estado da técnica tais como:

(1) Ao combinar características informativas de descrição de forma independente preservando o valor discriminatório individual dos descritores, há uma maior confiança no resultado produzido dado que esse é calculado a partir de mais de uma característica. Assim, o método possui um mecanismo de correção de erros intrínsecos que pode ser resistente a certos tipos de erros pontuais de classificação.

(2) Se alguma classe em confusão é achada, e conseqüentemente, está levando a um resultado de classificação não satisfatório, classificadores binários bem como características especiais específicos para essa parte do problema podem ser desenvolvidos e incorporados ao sistema.

(3) As características que não contribuem muito para a produção do resultado final podem ser detectadas e substituídas por outras mais discriminantes. A seleção pode ser feita, por exemplo, considerando os dados resultantes nas etapas parciais relacionadas ao processo de treinamento. Durante o processo de treinamento, aquelas características que estiverem contribuindo menos, i.e., resultando em um acerto menor, podem ser eliminadas e substituídas por outras mais representativas. A substituição pode, também, apenas reduzir o peso ou impacto relacionado às características menos representativas e aumentar o peso relativo às mais representativas.

(4) A adição de novas classes (diferentes produtos a serem classificados ainda não registrados na base de conhecimento) podem ser incorporadas exigindo apenas re-treinamento parcial para os classificadores binários relativos às classes adicionadas. Neste caso, re-treinamento parcial é relativo à possibilidade de apenas 5 treinar novos classificadores e características relacionados às novas classes sendo adicionadas e não ao conjunto total de classes.

(5) Similarmente, novas características discriminantes podem ser incorporadas ao sistema exigindo apenas re-treinamento parcial.

(6) Como as características são tratadas de forma independente preservando-se suas propriedades ao invés de combinar todas as características utilizando apenas um 10 classificador de padrões, a técnica aqui descrita é menos sensível ao problema conhecido no estado da técnica como *maldição da dimensionalidade*. Tal fenômeno diz respeito ao crescimento exponencial do número de exemplos necessários ao treinamento em relação ao espaço de características (Bishop, 2006).

Adicionalmente, a tecnologia proposta não faz restrições quanto às 15 condições de iluminação do ambiente de operação, atua em um cenário semi-controlado em que a interação com o sistema ocorre apenas no momento de confirmar uma lista de opções de classificação do sistema por parte do operador do mesmo. Não faz restrições em relação ao número de objetos analisados. Não necessita de sensores adicionais 20 acoplados ao sistema (e.g., sensores de infra-vermelho ou de captura multi-espectral). Pode ser conectado a uma balança para captura e combinação de informações de peso.

A categorização de produtos multi-classe em ambientes semi-controlados é resolvida hoje basicamente acoplando-se sensores adicionais no ambiente de operação e fazendo-se a combinação dessas informações. Algumas vezes, essas combinações 25 requerem sistemas complexos de aquisição (e.g., luz infra-vermelho etc.) ou fazem restrições quanto à iluminação do ambiente de operação. É comum as soluções restringirem o tipo de características a serem utilizadas na caracterização dos produtos (e.g., frutas, legumes etc.) a algumas poucas tais como cor, forma, ou textura. Isso se deve à difícil tarefa de combinar tais informações no sistema para produzir um resultado 30 mais confiável de classificação. Na presente invenção, apresenta-se um sistema capaz

de caracterizar imagens de objetos a partir de diversas informações (cor, forma, textura, aparência etc.) e combiná-las de maneira rápida e eficaz.

Outro problema presente na literatura diz respeito ao tipo de classificador a ser utilizado. As abordagens tradicionais escolhem um ou outro classificador para todos os produtos analisados. Isso pode não ser a melhor maneira. A presente invenção resolve esse problema de modo a permitir que tipos específicos de produtos possam ser caracterizados por diferentes classificadores. Por exemplo se dois produtos são melhor diferenciados utilizando informações de forma e aparência, não necessariamente um mesmo classificador precisa ser utilizado sobre as duas características importante. O sistema permite que um classificador de forma com melhor resultado seja combinado com um de aparência diferente que também apresentou o melhor resultado sobre outros classificadores de aparência.

### **BREVE DESCRIÇÃO DA INVENÇÃO**

A presente invenção trata de um processo e equipamento para categorização de objetos (e.g., frutas, legumes, verduras, caixas. etc.) em ambientes semi-controlados (e.g., supermercados, feiras, centros de distribuição).

A presente invenção trata de um processo capaz de extrair características descritivas de um conjunto de dados (e.g., imagens dos objetos a serem categorizados). As características extraídas podem ser combinadas de maneira a obter o maior grau de discriminação de cada uma ao mesmo tempo que permitindo a utilização de diferentes classificadores (cada qual especializado em partes do problema).

A novidade da abordagem está na maneira de combinar os mais diferentes classificadores e as mais diversas características de cor, textura, forma, silhueta etc., sem impor restrições de normalização tal como na geração de um único vetor descritivo. A abordagem utiliza binarização de classes, método que divide o problema de categorização multi-classe em problemas menores e mais tratáveis onde pode-se utilizar classificadores especializados em partes do problema bem como características de descrição mais apropriadas.

Esse processo pode ser embarcado nos mais variados dispositivos e associado a dispositivos adicionais, como uma balança, por exemplo, para prover

informações adicionais como peso, precagem etc. e automatizar o processo de compras desses objetos nos ambientes propostos.

O processo e equipamento propostos podem ser utilizados em ambientes semi-controlados (em que existe interação) tais como caixas de supermercado e centros de distribuição, por exemplo.

### BREVE DESCRIÇÃO DAS FIGURAS

A Figura 1 apresenta o diagrama geral de atuação do sistema e seus componentes associados no cenário de um ambiente semi-controlado. O sistema de aquisição aqui ilustrado, consiste de (1) um dispositivo (e.g., balança) que pode coletar dados adicionais do objeto tais como seu peso; (2) o objeto a ser categorizado (e.g., fruta, legume, verdura, etc.); (3) a tela do sistema para interação com o operador; (4) o sistema em si; (5) o sistema de captura (e.g., uma ou mais câmeras) responsáveis pelo imageamento do produto a ser categorizado; e (6) o braço de suporte do sistema de captura.

A Figura 2 apresenta um diagrama geral da abordagem de caracterização e classificação via fusão de classificadores e característica via combinação por binarização de classes de interesse aqui proposto. O diagrama consiste no imageamento do produto a ser categorizado, passando por um conjunto de métodos referentes ao pré-processamento da imagem. Essa imagem, em seguida, passa à (1) etapa de descrição onde são coletados descritores de características importantes do produto em questão tais como informações de cor, forma, aparência, silhueta, textura etc. Essas informações passam à (2) etapa de classificação e fusão onde, por binarização de classes, classificadores e características são combinados de modo a produzir resultados de classificação eficientes e eficazes. Quando na etapa de teste, os parâmetros referentes à classificação e fusão provém da (3) base de aprendizado do sistema. Quando na etapa de treinamento, onde o sistema ainda está sendo implantado, os melhores parâmetros referentes à classificação são incorporados construindo a base de conhecimentos inicial. Essa base de conhecimentos é dinâmica no sentido de poder receber mais informações (conhecimentos) provenientes de interações (em tempo de execução/teste) do (4) operador do sistema.

A Figura 3 apresenta detalhes da (1) tela do sistema disponível ao operador. Nesta tela, o operador tem acesso à (2) lista de resultados mais prováveis de categorização do produto sendo analisado pelo sistema. Cabe ao operador confirmar o resultado ou escolher, dentre a lista de opções (3), a correta classificação do produto. 5 Mediante a interação do usuário e (5) informações adicionais tais como o peso do produto, o sistema pode exibir o (4) preço calculado.

A Figura 4 apresenta uma visão geral do processo aqui descrito para categorização de produtos em ambientes semi-controlados mediante fusão de características e classificadores por binarização de classes. O sistema consiste de uma 10 (1) base de conhecimento com informações das classes de produtos conhecidos e suas respectivas identificações (e.g., [1,1,0], [-1,0,1], etc.). Quando (3) um produto chega para ser categorizado, várias informações (5) são coletadas tais como descrições de forma, textura, cor. Essas informações são combinadas (2) com os classificadores mais efetivos para cada uma utilizando o processo de binarização de classes com o 15 mecanismo intrínseco de correção de erro aqui descrito. Os parâmetros de escolha dos classificadores bem como de quais características a serem utilizadas provém da base de conhecimento. Os resultados das classificações parciais obtidas são (4) combinados e produzem uma saída binária ou probabilística para cada classificador. Para obter a decisão final da classificação, compara-se estes resultados binários aos (6) 20 identificadores de classe de objeto e seleciona-se os mais prováveis para apresentação ao operador do sistema.

A Figura 5 apresenta uma visão geral do processo aqui descrito para categorização de produtos em ambientes semi-controlados mediante fusão de características e classificadores por binarização de classes. O sistema consiste de uma 25 (1) base de conhecimento com informações das classes de produtos conhecidos e suas respectivas identificações (e.g., [+1,+1,+1,0,0,0,...], [-1,0,0,+1,+1,0,...], etc.). Quando (3) um produto chega para ser categorizado, várias informações (5) são coletadas tais como descrições de forma, textura, cor. Essas informações são combinadas (2) com os classificadores mais efetivos para cada uma utilizando o processo de binarização de 30 classes com o mecanismo intrínseco de correção de erro aqui descrito. Os parâmetros de escolha dos classificadores bem como de quais características a serem utilizadas provém

da base de conhecimento. Os resultados das classificações parciais obtidas são (4) combinados e produzem uma saída binária ou probabilística para cada classificador. Para obter a decisão final da classificação, compara-se estes resultados binários ou probabilísticos aos (6) identificadores de classe de objeto e seleciona-se os mais prováveis para apresentação ao operador do sistema.

A Figura 6 apresenta alguns resultados de categorização da técnica proposta em comparação a outras disponíveis no estado da técnica. Os produtos testados são imagens coletadas na Central de Abastecimento de Alimentos de Campinas, SP (CEASA). No total foram testadas 2.633 imagens de frutas e legumes distribuídas em 15 classes de produtos (Rocha et al., 2008). As 15 classes testadas foram: (1) pêssego diamante, (2) melão honeydew, (3) cebola piedade, (4) pêra espanhola williams, (5) batata roxa asterix, (6) maçã fuji, (7) kiwi, (8) laranja pêra, (9) limão taiti, (10) caju, (11) maçã grany-smith, (12) nectarina, (13) ameixa, (14) melancia e (15) batata ágata.

Não é difícil ver a superioridade do método em relação ao estado da técnica aqui mostrado. No texto mostrado, os descritores utilizados para obter informações dos produtos foram: descritor global de histograma (Gonzalez & Woods), descritor de textura baseado em somas e diferenças de histogramas (Unser, 1986), descritor de cor baseado em coerência de componentes conexos (Pass et al., 1997). Dois conjuntos de classificadores foram utilizados: *Linear Discriminant Analysis* (LDA) e *Support Vector Machines* (SVMs) (Bishop, 2006). Na Figura, quanto menor o erro, melhor a classificação, o que está relacionado com o número de exemplares no treinamento por classe. Os resultados diferentes em relação a cada classificador são indicadores de que a combinação de cada característica com um classificador mais adaptado a essa característica é essencial. A técnica aqui descrita torna essa combinação possível conforme ilustrado pela linha com traço único e na legenda “SVM (GCH, Unser, CCV)” e LDA (GCH, Unser, CCV) em negrito na Figura.

A Figura 7 mostra alguns resultados da técnica proposta em um cenário com outros descritores. As 15 classes testadas foram: (1) pêssego diamante, (2) melão honeydew, (3) cebola piedade, (4) pêra espanhola williams, (5) batata roxa asterix, (6) maçã fuji, (7) kiwi, (8) laranja pêra, (9) limão taiti, (10) caju, (11) maçã grany-smith, (12) nectarina, (13) ameixa, (14) melancia e (15) batata ágata. Neste cenário, os

descritores utilizados foram: descritor de cor baseado em classificação de pixels de borda/interior (Stehling et al., 2002), descritor de textura baseado em somas e diferenças de histogramas (Unser, 1986), descritor de cor baseado em coerência de componentes conexos (Pass et al., 1997). Os classificadores utilizados foram *Bagging of Linear*  
5 *Discriminant Analysis* (BLDA) e Árvore de Classificação (CTREE) (Bishop, 2006). Claramente, a técnica proposta produz resultados muito superiores. Na Figura, quanto menor o erro, melhor a classificação, o que está relacionado com o número de exemplares no treinamento por classe. Os resultados diferentes em relação a cada classificador são indicadores de que a combinação de cada característica com um  
10 classificador mais adaptado a essa característica é essencial. A técnica aqui descrita torna essa combinação possível conforme ilustrado pela linha com traço único e na legenda “BLDA-17 (BIC, Unser, CCV)” em negrito e “CTREE (BIC, Unser, CCV)” na Figura.

### DESCRIÇÃO DETALHADA DA INVENÇÃO

15 Em geral, técnicas de categorização de imagens baseiam-se em combinações de abordagens estatísticas, estruturais e espectrais. Em abordagens estatísticas, os objetos são descritos utilizando descritores globais e locais tais como média, variância, entropia etc. Em abordagens estruturais, os objetos são representados por primitivas conhecidas tais como suas partes constituintes. Finalmente, em abordagens espectrais,  
20 os objetos são descritos utilizando uma representação do objeto em algum espaço espectral, como por exemplo, o espectro de Fourier (Gonzalez & Woods, 2007).

A presente invenção resolve o problema de categorização de objetos em ambientes semi-controlados tais como um centro de distribuição de frutas, legumes e verduras ou um supermercado utilizando uma combinação de descritores estatísticos de  
25 cor, textura e forma bem como descritores de estrutura e aparência.

A presente invenção tem um campo de aplicações muito amplo podendo ser utilizada para reconhecimento e classificação automática ou semi-automática de produtos tais como frutas, legumes, verduras, flores em centros de distribuição e supermercados ou outro tipo de objeto. Basicamente, a tecnologia proposta pode  
30 funcionar para diferentes objetos desde que estes possam ser caracterizados por descritores de cor, forma, textura, aparência, silhueta e etc.



O método e sistema podem ser associados a dispositivos de pesagem (e.g., balança) automatizando o processo de reconhecimento de produtos de produtos não embalados ou sem códigos de barra, por exemplo.

A presente invenção torna possível a combinação de diversos descritores de imagens bem como os classificadores mais apropriados a cada conjunto de características de modo a produzir um índice de acerto de 90 a 99,9% de classificação com baixo ônus computacional. A abordagem apresentada é capaz de combinar as melhores características de descrição das imagens analisadas sem incorrer no problema conhecido no estado da técnica como *maldição da dimensionalidade* (Bishop, 2006). Isso é conseguido dado que as características de descrição não são consideradas como apenas um grande vetor de descrição durante o processo de combinação. Além disso, dado que cada conjunto de características é tratado separadamente, a abordagem aqui proposta permite a combinação dos classificadores melhor adaptados a cada característica de descrição.

De forma geral, a presente tecnologia aqui descrita possui até cinco estágios de treinamento da categorização multi-classe a partir de múltiplos classificadores binários: (1) aquisição das imagens dos objetos a serem analisados; (2) pré-processamento (e.g., subtração de informações irrelevantes de fundo), o invento pode ser utilizado sem esta etapa, porém com ela os resultados são potencialmente melhores devido à eliminação de informações de fundo não interessante à análise dos objetos; (3) extração de características; (4) divisão do problema de categorização multi-classe em problemas de duas classes (dividir para conquistar); (5) combinação de classificadores e características;

#### **Estágio 1. Aquisição das imagens dos objetos a serem analisados.**

Consiste na formação de um espaço amostral de imagens  $S$  com exemplos de imagens representativas do problema a ser resolvido, que pode-se aplicar a diferentes tipos de objetos. Para cada imagem  $s$  presente no conjunto de imagens  $S$ , aplicar os estágios descritos em 2-6. As imagens capturadas possuíam uma resolução de 1024x728, e trabalhadas com uma resolução de 640 x 480 para o estágio de pré-processamento. A presente tecnologia possibilita analisar imagens em uma resolução de 320 x 240, abaixo desse valor, informações relevantes podem deixar de ser coletadas. Imagens com

resoluções maiores trarão um maior número de informações, porém, irão necessitar de maior capacidade computacional, algo que a presente tecnologia não necessita. Tais valores de resolução tem o intuito de ilustrar algumas das maneiras de realizar a invenção, sem limitar o escopo da mesma. Dentre os dispositivos para capturar imagens, há possibilidade de se utilizar câmera fotográfica digital, filmadora, sensores de escaneamento tridimensional, sensores de captura de informações espectrais, volumétricos e a associação de dois ou mais meios de captura.

**Estágio 2. Pré-processamento.** Consiste em pré-processar as imagens coletadas de modo a eliminar informações que não são necessárias ou úteis ao processo de categorização. Durante essa etapa, pode-se aplicar procedimentos de normalização fotométrica das imagens para redução dos efeitos de variações de iluminação. Pode-se também aplicar abordagens de extração de fundo para eliminar as informações de fundo (não referentes ao objeto sendo classificado).

Para aumentar as probabilidades de sucesso na classificação, alguns procedimentos simples de normalização (e.g., cromática) podem ser aplicados neste estágio. Por exemplo, pode-se transformar as imagens em análise para um espaço de cores mais informativo como o espaço HSV que é mais robusto a mudanças em iluminação. HSV é a abreviatura para o sistema de cores formadas pelas componentes hue (matiz), saturation (saturação) e value (valor). Nesta etapa, pode-se também isolar o objeto em análise na imagem de modo a eliminar informações que não são úteis ao processo de classificação. Diferentes abordagens de segmentação e eliminação de fundo existem e podem ser aplicadas. É importante notar que a escolha da abordagem influencia diretamente o tempo de cálculo bem como o acerto final do sistema. Algumas abordagens testadas com sucesso são: *Otsu* (Otsu, 1979) produz uma segmentação razoável em 0,3 segundos/imagem; *Meanshift* (Comaniciu & Meer, 2002), custa 1,5 segundos por imagem; *Normalized Cuts* (Shi & Malik, 2000), custa aproximadamente 5 segundos por imagem. O melhor custo/benefício testado consiste em uma abordagem proposta no próprio método como parte do processo do presente invento. Na presente tecnologia, o algoritmo de segmentação produz um resultado de segmentação em menos de um segundo sendo propício ao uso em um ambiente semi-controlado e de alta vazão. O método de extração de fundo aqui proposto consiste em:

1. Reamostrar a imagem a entre 15 a 40% do tamanho original por interpolação simples, preferencialmente;

2. Utilizar o canal *S* da representação HSV da imagem e considerá-lo como um vetor unidimensional *V* de intensidade de *pixels*;

5 3. Fazer uma clusterização baseada em *k-means* (Gonzalez & Woods, 2007), com  $k = 2$  (fundo e objeto);

4. Fazer o mapeamento de volta da imagem binária resultante da clusterização para o espaço de imagem;

5. Re-amostrar a imagem mapeada de volta para 100% (640 x 480); e

10 6. Aplicar o operador morfológico de fechamento (*close*) com um elemento estruturante em forma de disco de tamanho que varia de 3 a *n*, preferencialmente 7 *pixels*, para fechar pequenos buracos.

Com o procedimento anterior, tem-se uma imagem em que o objeto está em destaque e os elementos de fundo são, basicamente, descartados.

15 **Estágio 3. Extração de características.** Consiste na descrição das imagens utilizando descritores de características baseados em cor, forma, silhueta, textura, aparência, partes representativas etc. Nesta etapa é importante caracterizar a imagem quanto a informações de cor, forma, silhueta, textura, aparência entre outros. A descrição precisa ser compacta (simples e pequena) para evitar-se os problemas  
20 decorrentes da alta dimensionalidade, e rápida. Alguns descritores testados que produzem bons resultados enquanto mantendo a eficiência são: descritor global de histograma (Gonzalez & Woods), descritor de textura baseado em somas e diferenças de histogramas (Unser, 1986), descritor de cor baseado em coerência de componentes conexos (Pass et al., 1997), descritor de cor baseado em classificação de pixels de  
25 borda/interior (Stehling et al., 2002), descritores de aparência (Agarwal et al., 2004; Jurie & Triggs, 2005). O descritor global de histograma, por exemplo, consiste em quantificar as cores presentes no objeto utilizando um histograma. O descritor de textura baseado em somas e diferenças, consiste em calcular deltas (somas e diferenças) entre pontos da imagem e seus vizinhos e representar os resultados em dois histogramas finais  
30 de somas e diferenças. O descritor de borda e interior classifica cada pixel da imagem como borda ou interior baseado na classificação dos pixels vizinhos. Por exemplo, se

um pixel tem todos os seus vizinhos como borda ele é classificado como borda. O descritor de aparência consiste em representar o objeto por pequenas regiões representativas destes objetos, como por exemplo, o cabo e a cavidade da maçã, a protuberância na parte inferior do limão, os padrões repetitivos na superfície da melancia, os brotos da batata etc.

O resultado dessa etapa são vetores de descrição para cada imagem de treinamento coletada. As descrições do treinamento são armazenadas para serem combinadas na etapa seguinte.

**Estágio 4. Divisão do problema de categorização multi-classe em problemas de duas classes.** Consiste na divisão do problema de categorização multi-classe (mais de duas classes de objetos a serem categorizados) em problemas binários de natureza mais simples e localizada e a subsequente combinação dos seus resultados para a derivação da predição multi-classe.

Essa divisão permite a combinação de classificadores mais adaptados a cada conjunto de características. Pode-se fazer isso tomando-se algumas classes como exemplos de uma classe virtual positiva e outras como representantes de uma classe virtual negativa e formando um classificador simples e binário chamado de classificador-base. Isso pode ser repetido para diferentes combinações de classes até um critério de convergência ser atingido. Um critério possível de convergência é o acerto no conjunto de treinamento. Maiores acertos indicam boas combinações dos classificadores binários utilizados. Outra forma de binarização também testada consiste em tomar uma classe de cada vez como exemplo de uma classe positiva e outra classe como exemplo de uma classe negativa. Isso é repetido para diferentes pares de classes obtendo-se um classificador-base para cada combinação. Normalmente, a escolha da primeira abordagem conduz a resultados melhores mas com mais combinações necessárias para o método. Na segunda abordagem, tem-se um resultado de classificação próximo ao primeiro, mas com menos classificadores binários requeridos. Essa explicação refere-se às Figuras 4 e 5.

**Estágio 5. Combinação dos melhores classificadores e características.** Os classificadores definidos na Estágio 4 que dividem o problema de categorização multi-classe em diversos problemas binários são treinados nas imagens de treinamento

coletadas na Etapa 1 e pré-processadas na Etapa 2. Os parâmetros de aprendizado são armazenados para a execução do método em tempo execução e constituem a base de conhecimento da abordagem.

Os classificadores binários podem ser referenciados como classificadores básicos. A binarização de classes nunca foi utilizada no contexto de combinação de características para categorização. No entanto, tem-se referências no estado da técnica onde tais abordagens foram utilizadas em problemas de classificação baseados em características específicas (Anand et al., 1995; Dietterich & Bakiri, 1996; Narasimhamurthy, 2005).

Após as etapas de treinamento, o sistema tem conhecimento dos tipos de produtos que deverá classificar em tempo de execução. A abordagem possui até sete estágios execução/teste a partir de múltiplos classificadores binários: (1) aquisição da imagem do objeto a ser analisado; (2) pré-processamento; (3) extração das características definidas na etapa de treinamento; (4) combinação das características e classificadores definidos no treinamento; (5) classificação do objeto; (6) apresentação dos resultados mais prováveis ao operador; (7) confirmação do resultado.

Os modelos e parâmetros aprendidos durante os estágios de treinamento são armazenados constituindo a base de conhecimentos do sistema. Em tempo de operação, esta base pode ser atualizada e estendida com novas categorias. Em tempo de operação, uma imagem que chega para teste, deve seguir os estágios de teste para ser classificada. Inicialmente, a imagem deve ser coletada (Estágio 1). Logo em seguida, no Estágio (2), a imagem é pré-processada seguindo os mesmos critérios adotados para as imagens de treinamento. O invento pode ser utilizado sem esta etapa, porém com ela os resultados são potencialmente melhores devido à eliminação de informações de fundo não interessante à análise dos objetos. Após o pré-processamento, as imagens são descritas no Estágio (3), utilizando-se os descritores definidos no treinamento. As informações de descrição do Estágio (3) são combinadas às informações provenientes do treinamento para fazer a combinação dos descritores e classificadores no Estágio (4). Logo em seguida, é feita uma classificação inicial do objeto em análise. Os resultados mais prováveis da classificação são mostradas ao operador do sistema que deverá confirmar a

classe correta ao sistema nos Estágios (5) e (6), respectivamente. Finalmente, no Estágio (7), a resposta de confirmação do operador.

**Estágio 1. Aquisição da imagem do objeto a ser analisado.** Consiste em adquirir imagens do objeto a ser classificado baseado nos parâmetros aprendidos nos 5 estágios de treinamento.

**Estágio 2. Pré-processamento.** Consiste em aplicar as mesmas operações de pré-processamento definidas nas etapas de treinamento do sistema.

**Estágio 3. Extração das características.** Consiste na extração de características definidas nas etapas de treinamento do sistema.

10 **Estágio 4. Combinação das características e classificadores.** Consiste em utilizar os classificadores definidos nas etapas de treinamento para combinar as características extraídas a partir de informações presentes na base de conhecimentos do sistema.

**Estágio 5. Classificação do objeto.** Consiste em apontar as classes mais 15 prováveis as quais o objeto pode pertencer baseado na base conhecimentos do sistema e dos resultados da etapa de combinação e classificação do Estágio 4. A indicação das classes mais prováveis pode ser feita utilizando-se a proporcionalidade dos votos que as classes receberam ou o grau de confiabilidade para cada resposta retornada por um classificador, como por exemplo, a distância de margem em um classificador do tipo 20 SVM.

**Estágio 6. Apresentação dos resultados mais prováveis ao operador.** Consiste em mostrar ao operador do sistema as classes mais prováveis as quais o objeto pode pertencer. O sistema permite a enumeração de diversas classes ao operador. No 25 entanto, visando a simplificação do processo de operação, é interessante limitar esse número de possibilidade de respostas possíveis. Essa limitação não representa prejuízo ao funcionamento do método.

**Estágio 7. Confirmação do resultado.** O operador do sistema confirma a classe do objeto selecionando entre as mais prováveis que lhe são apresentadas.

## EXEMPLOS

30 Os exemplos aqui mostrado têm o intuito somente de mostrar algumas das inúmeras maneiras de se realizar a invenção, contudo, sem limitar o escopo da mesma.

Visando que as variações e modificações compatíveis com o descrito no presente documento, estão dentro do escopo da presente invenção.

### EXEMPLO 1

Neste exemplo foi realizado um o reconhecimento e classificação em três classes. Neste caso, uma binarização possível consiste em treinar três classificadores simples, cada um considerando duas classes por vez. O  $ij$ -ésimo classificador simples utiliza os padrões referentes à classe  $i$  como exemplos positivos e os padrões referentes à classe  $j$  como exemplos negativos. Para obter a resposta final, pode-se calcular a menor distância do vetor de respostas binárias ou probabilísticas (e.g., considerando distâncias de margem) dos classificadores simples para identificadores binários representando cada classe.

Três produtos foram analisados, sendo que as categorias possíveis eram: (1) Objetos triangulares, (2) Objetos circulares e (3) Objetos quadrados. Os objetos triangulares eram de cor laranja e com uma superfície com pequenas ranhuras. Os objetos circulares eram de cor em tons de cinza com uma textura em forma de escamas de peixe. Os objetos quadrados eram de cor em tons de vermelho e uma textura em forma de folhagens (Figura 4).

No problema descrito acima, abordagens tradicionais de categorização considerariam apenas uma informação dada ou considerariam todas as informações como tendo as mesmas propriedades. Isso levaria à uma solução do problema restringindo o uso de um classificador específico para todas as classes de produtos (triângulos, quadrados e círculos em análise) bem como para as características disponíveis (cor, forma e textura).

A presente invenção consiste em combinar essas características de forma a manter suas propriedades discriminatórias e, ao mesmo tempo, tornar possível a escolha dos classificadores mais adaptados a cada tipo de característica. Para isso, inicialmente cada classe em análise recebe um identificador binário de classe. Suponha que para as classes de exemplo, os identificadores sejam: triângulos (1,1,0); círculos (-1,0,1) e quadrados (0, -1, -1). O valor zero indica um valor sem importância. O valor 1 indica que um classificador binário em que aquele padrão apareça, seus exemplos devem ser considerados como positivos. Complementarmente, o valor -1 que um

classificador binário em que aquele padrão apareça, seus exemplos devem ser considerados como negativos.

No problema-exemplo relatado, várias informações de descrição dos objetos em questão podem ser utilizadas tais como: suas formas, cores e textura. Após a atribuição de identificadores para os classificadores binários definidos, a presente técnica utiliza cada classificador binário sobre uma determinada característica (cor, forma, textura). Para cada classificação, uma resposta binária é obtida. Para cada classificador binário ao longo das diversas características analisadas tem-se um conjunto de resultados binários (+1/-1) ou probabilísticos para o exemplo classificado.

Aplica-se então um procedimento para verificar a resposta mais provável para cada um dos conjuntos de classificadores. Ao final, tem-se uma resposta mais provável para cada classificador binário ao longo das várias características por ele analisada. Esse conjunto final de respostas binárias é comparado aos identificadores de classes definidos no início do processo e o resultado final de classificação é obtido.

Para melhor entendimento, considere que o sistema acaba de capturar a imagem de um produto triangular, com ranhuras e de cor alaranjada e o operador deseja que o sistema faça a classificação desse produto. O sistema utiliza os classificadores binários definidos para verificar se o produto a ser categorizado é um triângulo ou um círculo utilizando para isso informações de forma, textura e cor. Cada classificador (triângulo  $\times$  círculo) sobre uma característica em específico (e.g., forma) produz uma resposta binária. Ao aplicar para todas as características disponíveis (cor, forma e textura) obtém três respostas binárias, por exemplo, (+1, +1, -1) para o classificador binário (triângulo  $\times$  círculo). Em seguida, pode-se utilizar diversas abordagens para definir qual a saída mais provável (e.g., voto majoritário). O procedimento é repetido para cada classificador binário restante sobre as mesmas características, ou seja, testa-se se o objeto a ser categorizado é um triângulo ou um quadrado, e se o objeto é um quadrado ou um círculo utilizando sempre as informações de cor, forma e textura.

Ao terminar os testes, o sistema possui um vetor binário de respostas parciais. A resposta final é obtida comparando-se esse vetor de respostas com cada identificador de classe definido no início do procedimento. Essa comparação pode ser



tão simples quanto a mínima distância entre os identificadores e o vetor de respostas parciais.

As respostas mais prováveis, menores distâncias de forma ordenada dos vetores de respostas parciais aos identificadores de classes, podem ser apresentadas ao operador. Este, por sua vez, pode confirmar o resultado. O resultado confirmado pode ser incorporado na base de conhecimentos do sistema tornando-o adaptativo.

### EXEMPLO 2

Neste exemplo 2 foi realizado um o reconhecimento e classificação no cenário de reconhecimento de frutas com 15 classes. Neste caso, uma binarização possível consiste em treinar diversos classificadores simples, cada um considerando duas classes por vez. O  $ij$ -ésimo classificador simples utiliza os padrões referentes à classe  $i$  como exemplos positivos e os padrões referentes à classe  $j$  como exemplos negativos. Para obter a resposta final, pode-se calcular a menor distância do vetor de respostas binárias ou probabilísticas (e.g., considerando distâncias de margem) dos classificadores simples para identificadores binários representando cada classe.

Nesta caso específico sem prejuízo de generalidade, testou-se 15 classes de frutas (produtos), sendo que as categorias possíveis foram: (1) pêssego diamante, (2) melão honneydew, (3) cebola piedade, (4) pêra espanhola williams, (5) batata roxa asterix, (6) maçã fuji, (7) kiwi, (8) laranja pêra, (9) limão taiti, (10) caju, (11) maçã grany-smith, (12) nectarina, (13) ameixa, (14) melancia e (15) batata ágata conforme ilustra a Figura 5.

No problema descrito acima, abordagens tradicionais de categorização considerariam apenas uma informação dada ou considerariam todas as informações como tendo as mesmas propriedades. Isso levaria à uma solução do problema restringindo o uso de um classificador específico para todas as classes de produtos (laranjas, maçãs, pêras, etc.) bem como para as características disponíveis (cor, forma e textura).

A presente invenção consiste em combinar essas características de forma a manter suas propriedades discriminatórias e, ao mesmo tempo, tornar possível a escolha dos classificadores mais adaptados a cada tipo de característica. Para isso, inicialmente cada classe em análise recebe um identificador binário de classe. Suponha que para as

classes de exemplo, os identificadores sejam: caju (1,1,1,0,0,0,...); batata ágata (-1,0,0,1,1,0,...), laranja pêra (0,-1,0,-1,0,1,...), pêssego diamante (0,0,-1,0,-1,-1,...) e assim por diante. Neste caso, uma classe recebe o identificador +1 se ela é considerada primeiro em um par de  
5 combinação. Por exemplo, caju vs. batata ágata resulta o número parcial de identificação +1 para a classe caju e -1 para a classe batata ágata. O valor zero indica um valor sem importância. O valor 1 indica que um classificador binário em que aquele padrão apareça, seus exemplos devem ser considerados como positivos. Complementarmente, o valor -1 que um classificador binário em que aquele padrão  
10 apareça, seus exemplos devem ser considerados como negativos.

No Exemplo 2, várias informações de descrição dos objetos em questão podem ser utilizadas tais como: suas formas, cores e textura. Após a atribuição de identificadores para os classificadores binários definidos, a presente técnica utiliza cada classificador binário sobre uma determinada característica (e.g., cor, forma, textura).  
15 Para cada classificação, uma resposta binária ou probabilística é obtida. Para cada classificador binário ao longo das diversas características analisadas tem-se um conjunto de resultados binários (+1/-1) ou probabilísticos para o exemplo classificado.

Aplica-se então um procedimento para verificar a resposta mais provável para cada um dos conjuntos de classificadores. Ao final, tem-se uma resposta mais  
20 provável para cada classificador binário ao longo das várias características por ele analisada. Esse conjunto final de respostas binárias é comparado aos identificadores de classes definidos no início do processo e o resultado final de classificação é obtido.

Para melhor entendimento, considere que o sistema acaba de capturar a imagem de um produto da classe caju e o operador deseja que o sistema faça a  
25 classificação desse produto. O sistema utiliza os classificadores binários definidos para verificar se o produto a ser categorizado é caju ou batata ágata utilizando para isso informações de forma, textura e cor. Cada classificador (caju x batata ágata) sobre uma característica em específico (e.g., forma) produz uma resposta binária ou probabilística. Ao aplicar para todas as características disponíveis (e.g., cor, forma e textura) obtém-se  
30 um conjunto de respostas binárias, por exemplo, (+1, +1, -1) para o classificador binário (caju x batata ágata). Em seguida, pode-se utilizar diversas abordagens para definir qual

a saída mais provável (e.g., voto majoritário). O procedimento é repetido para cada classificador binário restante sobre as mesmas características, ou seja, testa-se se o objeto a ser categorizado é caju ou laranja, caju ou pêsego, batata ágata ou laranja pêra, batata ágata ou pêsego, laranja pêra ou pêsego e assim sucessivamente utilizando sempre as informações de cor, forma e textura, por exemplo.

Ao terminar os testes, o sistema possui um vetor binário de respostas parciais ou um vetor de respostas probabilísticas. A resposta final é obtida comparando-se esse vetor de respostas com cada identificador de classe definido no início do procedimento. Essa comparação pode ser tão simples quanto a mínima distância entre os identificadores e o vetor de respostas parciais.

As respostas mais prováveis, menores distâncias de forma ordenada dos vetores de respostas parciais aos identificadores de classes, podem ser apresentadas ao operador. Este, por sua vez, pode confirmar o resultado. O resultado confirmado pode ser incorporado na base de conhecimentos do sistema tornando-o adaptativo.

## REIVINDICAÇÕES

1. Método de reconhecimento e classificação de objetos, caracterizado por compreender :

5 - Um Estágio 1 de treinamento compreendendo as seguintes etapas:

(a) meios para aquisição de imagem com ou sem envoltório protetor transparente de objetos a serem analisados;

10 (b) meios para pré-processar imagem capturada na etapa anterior;

(c) meios para extrair características;

(d) meios para dividir a imagem de categoria multi-classe em problema de duas classes; e

(e) meios para combinar características e classificadores.

15 - Um Estágio 2 de execução/teste:

(a) meios para aquisição de imagem do objeto a ser analisado;

(b) meios para pré-processar imagem;

(c) meios para extrair características definidas na etapa de treinamento;

20 (d) meios para combinar características e classificadores definidos na etapa de treinamento;

(e) meios para classificar o objeto;

(f) obtenção e confirmação dos resultados mais prováveis;

25 2. Método de reconhecimento e classificação de objetos, caracterizado por compreender :

- Um Estágio 1 de treinamento compreendendo as seguintes etapas:

(a) meios para aquisição de imagem com ou sem envoltório protetor transparente de objetos a serem analisados;

30 (b) meios para extrair características;

(c) meios para dividir a imagem de categoria multi-classe em problema de duas classes; e

(d) meios para combinar características e classificadores.

- Um Estágio 2 de execução/teste:

5 (a) meios para aquisição de imagem do objeto a ser analisado;  
(b) meios para extrair características definidas na etapa de treinamento;

(c) meios para combinar características e classificadores definidos na etapa de treinamento;

10 (d) meios para classificar o objeto;

(e) obtenção dos resultados mais prováveis;

3. Método de reconhecimento e classificação de objetos, de acordo com as reivindicações 1 e 2, caracterizado pelo estágio 1 de treinamento ocorrer ao menos uma vez antes do estágio 2 de execução/teste.

15 4. Método de reconhecimento e classificação de objetos, de acordo com as reivindicações 1 ou 2 e 3, caracterizado pelo estágio de execução ser realizado de forma independente do estágio 1, desde que de o estágio 1 tenha ocorrida pelo menos uma vez previamente.

5. Método de reconhecimento e classificação de objetos, de  
20 acordo com a reivindicação 1 ou 2, caracterizado pelos objetos compreenderem ao menos um descritor de forma, cor, textura, aparência e silhueta.

6. Método de reconhecimento e classificação de objetos, de  
25 acordo com a reivindicação 4, caracterizado pelos objetos serem selecionados dentre frutas, verduras, legumes, flores, caixas e carnes.

7. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 5, caracterizado pelos objetos serem preferencialmente frutas e legumes.

8. Método de reconhecimento e classificação de objetos, de  
30 acordo com a reivindicação 1 ou 2, caracterizado pelos meios para captura de imagem serem selecionados dentre câmera fotográfica digital, filmadora,

sensores de escaneamento tridimensional, sensores de captura de informações espectrais, volumétricos e a associação de dois ou mais meios de captura.

5 9. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 1, caracterizado pelos meios de pré-processar serem selecionados dentre normalização fotométrica, extração de fundo e a associação de dois ou mais meios de pré-processar.

10 10. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 1 ou 2, caracterizado pelos meios de extração de características compreender ao menos um descritor selecionado dentre cor, forma, silhueta, textura e aparência.

15 11. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 1 ou 2, caracterizado pelo meio de dividir a imagem de categoria multi-classe em problemas de duas classes ser um classificador-base.

12. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 1 ou 2, caracterizado pelos meios para combinar características e classificadores compreender binarização de classes de imagens.

20 13. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 1 ou 2, caracterizado pelos meios para classificação da estágio de execução (2) ser selecionado dentre indicação das classes com maior proporcionalidade de votos e, grau de confiabilidade.

25 14. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 1, caracterizado pela etapa de pré-processamento compreender sub-etapas de:

(a) reamostrar uma imagem capturada de 15 a 40% de seu tamanho original por interpolação simples, preferencialmente 25%;

30 (b) utilizar um canal S da representação HSV da imagem em que o dito canal

corresponde a um vetor unidimensional  $V$  de intensidade de pixels;

(c) realizar uma clusterização do fundo e objeto baseada em *k-means*, com  $k=2$ ;

(d) mapear a volta da imagem binária obtida na sub-etapa (c) da para um espaço de imagem;

(e) reamostrar a dita imagem mapeada de volta para 100% de seu tamanho original; e

(f) aplicar um operador morfológico de fechamento com um elemento estruturante em forma de disco, de tamanho a partir de 3 *pixels*, preferencialmente 7 *pixels*.

15. Método de reconhecimento e classificação de objetos, de acordo com a reivindicação 1 ou 2, caracterizado pelo estágio de treinamento (1) compreender ao menos 8 imagens, preferencialmente de 8 a 64 imagens.

16. Método de reconhecimento e classificação de objetos, de acordo com as reivindicações 1, 3 a 14, caracterizado por permitir um acerto de 90% a 99,9%, com baixo ônus computacional.

17. Método de reconhecimento e classificação de objetos, de acordo com as reivindicações 2, 3 a 14 caracterizado por permitir um acerto 90% a 99,9%, com baixo ônus computacional.

18. Sistema de reconhecimento e classificação de objetos, caracterizado por compreender:

- Um dispositivo de captura de imagens de objetos a serem analisados;

- Um sistema computacional para pré-processar imagens, extrair características, dividir imagens de categoria multi-classe

em duas classes, combinar características e classificadores mais apropriados, classificar e apontar os resultados mais prováveis; e

- Um *display* para apresentação de informações.



FIGURAS




FIGURA 1

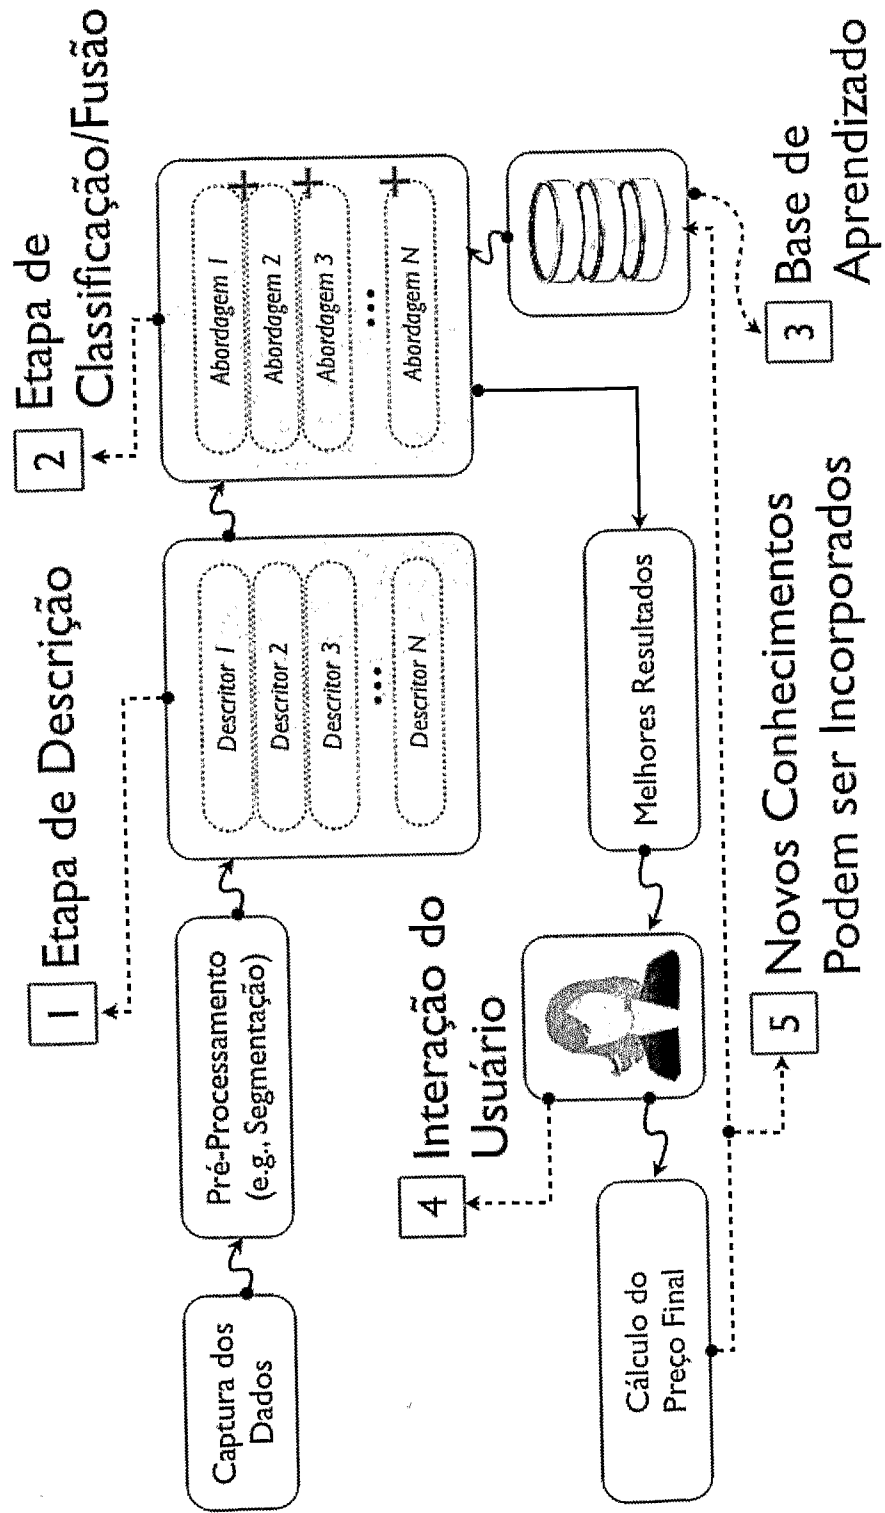


FIGURA 2




FIGURA 3



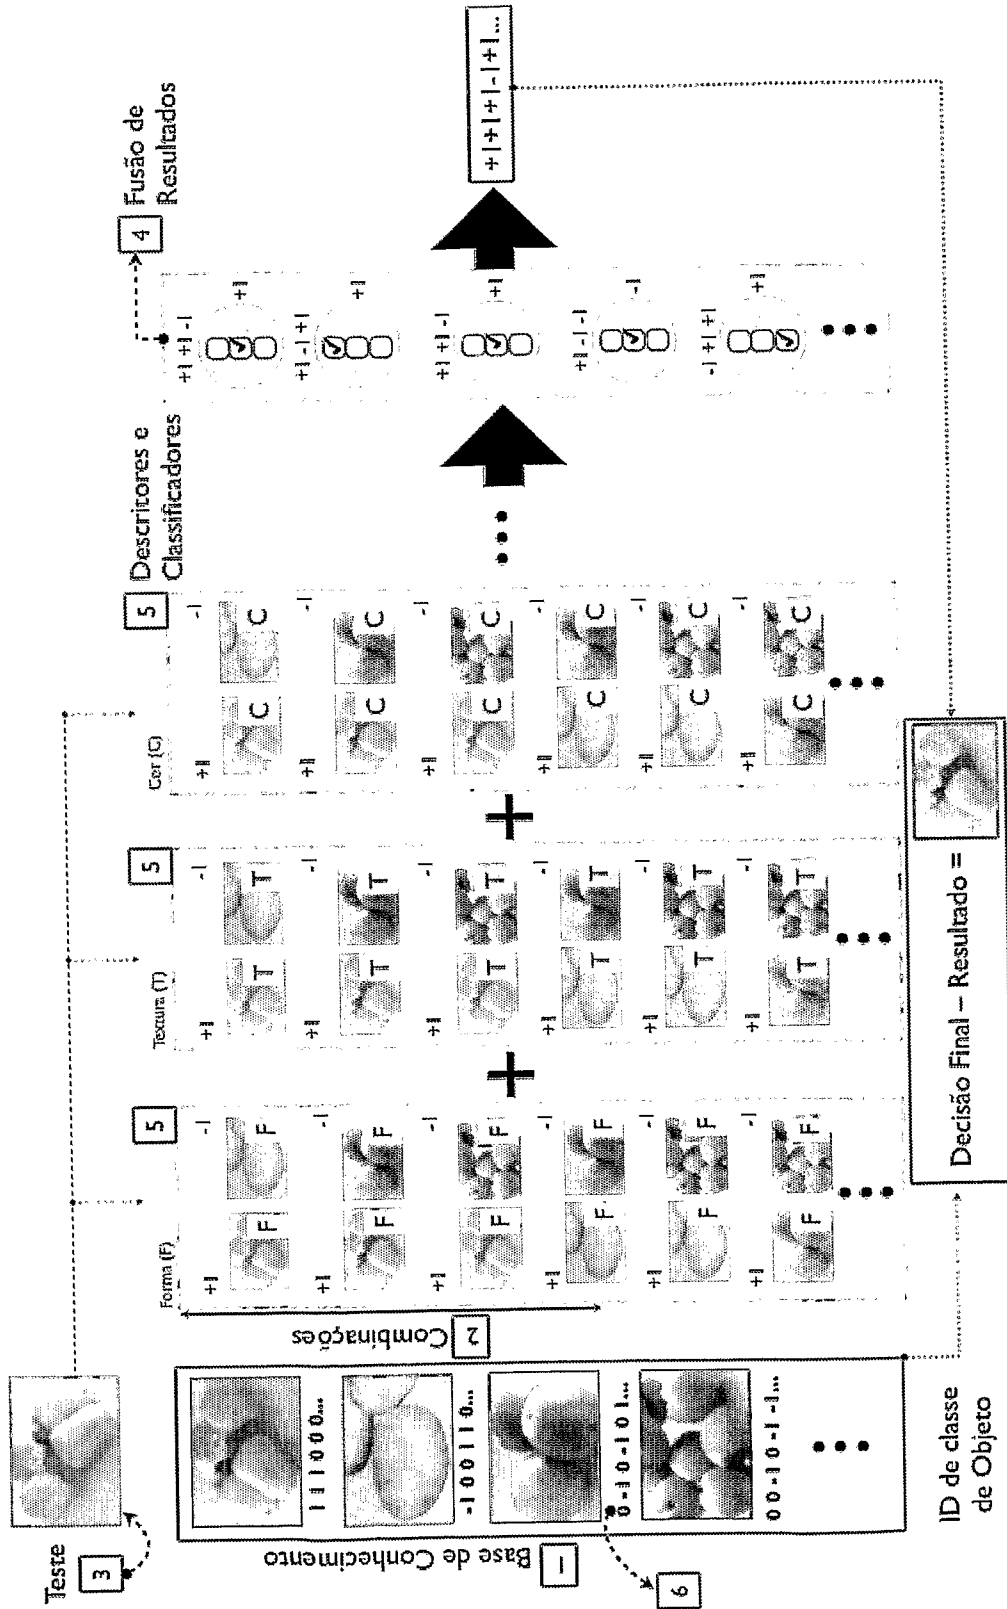




FIGURA 5




Número de Exemplares no Treinamento por Classe




Número de Exemplares no Treinamento por Classe

FIGURA 6



Número de Exemplos no Treinamento por Classe



Número de Exemplos no Treinamento por Classe

FIGURA 7

## INTERNATIONAL SEARCH REPORT

International application No.

PCT/BR2010/000073

A. CLASSIFICATION OF SUBJECT MATTER		
<b>IPC (2010.01) G06K 9/00, G06K 9/62, G06K 9/46</b>		
According to International Patent Classification (IPC) or to both national classification and IPC		
B. FIELDS SEARCHED		
Minimum documentation searched (classification system followed by classification symbols)		
Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched		
Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)		
<b>EPOQUE keywords: class+, image, LDA, SVM, fruit.</b>		
C. DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y	US 2007122009 A1 31 May 2007 (2007-05-31)	1, 3--13, 18
Y	CN 101125333 A (UNIV ZHEJIANG [CN]) 20 February 2008 (2008-02-20)	1, 3--13
Y	US 2007160296 A1 (SAMSUNG ELECTRONICS CO LTD [KR]) 12 July 2007 (2007-07-12)	14,15
Y	CN 101091649 A (UNIV ZHONGNAN [CN]) 26 December 2007 (2007-12-26)	14,15
A	CN 101034440 A (UNIV ZHEJIANG TECHNOLOGY [CN]) 12 September 2007 (2007-09-12)	-----
A	CN 1868610 A (JIANGXI UNIV OF AGRICULTURE [CN]) 29 November 2006 (2006-11-29)	-----
<input type="checkbox"/> Further documents are listed in the continuation of Box C. <input checked="" type="checkbox"/> See patent family annex.		
* Special categories of cited documents:	"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention	
"A" document defining the general state of the art which is not considered to be of particular relevance	"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone	
"E" earlier application or patent but published on or after the international filing date	"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art	
"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)	"&" document member of the same patent family	
"O" document referring to an oral disclosure, use, exhibition or other means		
"P" document published prior to the international filing date but later than the priority date claimed		
Date of the actual completion of the international search	Date of mailing of the international search report	
<b>25 March 2010</b>	<b>31 March 2010</b>	
Name and mailing address of the ISA/ INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL Rua Marink Veiga nº 9, 18º andar cep: 20090-050, Centro - Rio de Janeiro/RJ	Authorized officer <b>Lin Jwo Min</b>	
Facsimile No.	Telephone No. <b>+55 21 2139-3686/3742</b>	



INTERNATIONAL SEARCH REPORT  
Information on patent family members

International application No.

PCT/BR2010/000073

US 2007122009 A1	2007-05-31	KR 20070055653 A	2007-05-31
-----	-----	KR 100734849 B1	2007-07-02
CN 101125333 A	2008-02-20	-----	-----
-----	-----	CN 100534642 C	2009-09-02
US 2007160296 A1	2007-07-12	-----	-----
-----	-----	KR 100714726 B1	2007-04-27
CN 101091649 A	2007-12-26	-----	-----
-----	-----	None	-----
CN 101034440 A	2007-09-12	-----	-----
-----	-----	CN 100463001 C	09-02-18
CN 1868610 A	2006-11-29	-----	-----
-----	-----	None	-----

RELATÓRIO DE PESQUISA INTERNACIONAL

Depósito internacional Nº

PCT/BR2010/000073

<p>A. CLASSIFICAÇÃO DO OBJETO</p> <p><b>IPC (2010.01) G06K 9/00, G06K 9/62, G06K 9/46</b></p> <p>De acordo com a Classificação Internacional de Patentes (IPC) ou conforme a classificação nacional e IPC</p>																							
<p>B. DOMÍNIOS ABRANGIDOS PELA PESQUISA</p> <p>Documentação mínima pesquisada (sistema de classificação seguido pelo símbolo da classificação)</p> <p>Documentação adicional pesquisada, além da mínima, na medida em que tais documentos estão incluídos nos domínios pesquisados</p> <p>Base de dados eletrônica consultada durante a pesquisa internacional (nome da base de dados e, se necessário, termos usados na pesquisa)</p> <p><b>EPOQUE keywords: class+, image, LDA, SVM, fruit.</b></p>																							
<p>C. DOCUMENTOS CONSIDERADOS RELEVANTES</p> <table border="1"> <thead> <tr> <th>Categoria*</th> <th>Documentos citados, com indicação de partes relevantes, se apropriado</th> <th>Relevante para as reivindicações Nº</th> </tr> </thead> <tbody> <tr> <td>Y</td> <td>US 2007122009 A1 31 maio 2007 (2007-05-31)</td> <td>1, 3--13, 18</td> </tr> <tr> <td>Y</td> <td>CN 101125333 A (UNIV ZHEJIANG [CN]) 20 fevereiro 2008 (2008-02-20)</td> <td>1, 3--13</td> </tr> <tr> <td>Y</td> <td>US 2007160296 A1 (SAMSUNG ELECTRONICS CO LTD [KR]) 12 julho 2007 (2007-07-12)</td> <td>14,15</td> </tr> <tr> <td>Y</td> <td>CN 101091649 A (UNIV ZHONGNAN [CN]) 26 dezembro 2007 (2007-12-26)</td> <td>14,15</td> </tr> <tr> <td>A</td> <td>CN 101034440 A (UNIV ZHEJIANG TECHNOLOGY [CN]) 12 setembro 2007 (2007-09-12)</td> <td>-----</td> </tr> <tr> <td>A</td> <td>CN 1868610 A (JIANGXI UNIV OF AGRICULTURE [CN]) 29 novembro 2006 (2006-11-29)</td> <td>-----</td> </tr> </tbody> </table>			Categoria*	Documentos citados, com indicação de partes relevantes, se apropriado	Relevante para as reivindicações Nº	Y	US 2007122009 A1 31 maio 2007 (2007-05-31)	1, 3--13, 18	Y	CN 101125333 A (UNIV ZHEJIANG [CN]) 20 fevereiro 2008 (2008-02-20)	1, 3--13	Y	US 2007160296 A1 (SAMSUNG ELECTRONICS CO LTD [KR]) 12 julho 2007 (2007-07-12)	14,15	Y	CN 101091649 A (UNIV ZHONGNAN [CN]) 26 dezembro 2007 (2007-12-26)	14,15	A	CN 101034440 A (UNIV ZHEJIANG TECHNOLOGY [CN]) 12 setembro 2007 (2007-09-12)	-----	A	CN 1868610 A (JIANGXI UNIV OF AGRICULTURE [CN]) 29 novembro 2006 (2006-11-29)	-----
Categoria*	Documentos citados, com indicação de partes relevantes, se apropriado	Relevante para as reivindicações Nº																					
Y	US 2007122009 A1 31 maio 2007 (2007-05-31)	1, 3--13, 18																					
Y	CN 101125333 A (UNIV ZHEJIANG [CN]) 20 fevereiro 2008 (2008-02-20)	1, 3--13																					
Y	US 2007160296 A1 (SAMSUNG ELECTRONICS CO LTD [KR]) 12 julho 2007 (2007-07-12)	14,15																					
Y	CN 101091649 A (UNIV ZHONGNAN [CN]) 26 dezembro 2007 (2007-12-26)	14,15																					
A	CN 101034440 A (UNIV ZHEJIANG TECHNOLOGY [CN]) 12 setembro 2007 (2007-09-12)	-----																					
A	CN 1868610 A (JIANGXI UNIV OF AGRICULTURE [CN]) 29 novembro 2006 (2006-11-29)	-----																					
<p><input type="checkbox"/> Documentos adicionais estão listados na continuação do quadro C      <input checked="" type="checkbox"/> Ver o anexo de famílias das patentes</p>																							
<p>* Categorias especiais dos documentos citados:</p> <p>"A" documento que define o estado geral da técnica, mas não é considerado de particular relevância.</p> <p>"E" pedido ou patente anterior, mas publicada após ou na data do depósito internacional</p> <p>"L" documento que pode lançar dúvida na(s) reivindicação(ões) de prioridade ou na qual é citado para determinar a data de outra citação ou por outra razão especial</p> <p>"O" documento referente a uma divulgação oral, uso, exibição ou por outros meios.</p> <p>"P" documento publicado antes do depósito internacional, porém posterior a data de prioridade reivindicada.</p> <p>"I" documento publicado depois da data de depósito internacional, ou de prioridade e que não conflita com o depósito, porém citado para entender o princípio ou teoria na qual se baseia a invenção.</p> <p>"X" documento de particular relevância; a invenção reivindicada não pode ser considerada nova e não pode ser considerada envolver uma atividade inventiva quando o documento é considerado isoladamente.</p> <p>"Y" documento de particular relevância; a invenção reivindicada não pode ser considerada envolver atividade inventiva quando o documento é combinado com um outro documento ou mais de um, tal combinação sendo óbvia para um técnico no assunto.</p> <p>"&amp;" documento membro da mesma família de patentes.</p>																							
<p>Data da conclusão da pesquisa internacional</p> <p><b>25 março 2010</b></p>		<p>Data do envio do relatório de pesquisa internacional:</p> <p><b>31/03/2010</b></p>																					
<p>Nome e endereço postal da ISA/BR</p> <p>INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL Rua Marink Veiga nº 9, 18º andar cep: 20090-050, Centro - Rio de Janeiro/RJ</p> <p>Nº de fax: +55 21 2139-3663</p>		<p>Funcionário autorizado</p> <p><b>Lin Jwo Min</b></p> <p>Nº de telefone: +55 21 2139-3686/3742</p>																					

**RELATÓRIO DE PESQUISA INTERNACIONAL**  
 Informação relativa a membros da família de patentes

Depósito internacional Nº

PCT/BR2010/000073

Documentos de patente citados no relatório de pesquisa	Data de publicação	Membro(s) da família de patentes	Data de publicação
US 2007122009 A1	2007-05-31	KR 20070055653 A KR 100734849 B1	2007-05-31 2007-07-02
CN 101125333 A	2008-02-20	CN 100534642 C	2009-09-02
US 2007160296 A1	2007-07-12	KR 100714726 B1	2007-04-27
CN 101091649 A	2007-12-26	Nenhum	
CN 101034440 A	2007-09-12	CN 100463001 C	2009-02-18
CN 1868610 A	2006-11-29	Nenhum	