

# Método para auxiliar o reconhecimento de cédulas monetárias pelos deficientes visuais

Victor Vequetine. Teixeira<sup>1</sup>, Marcelo Zanchetta do Nascimento<sup>2</sup>, Juliana Cristina Braga<sup>1</sup>

<sup>1</sup>Centro de Matemática, Computação e Cognição (CMCC) – Universidade Federal do ABC (UFABC) – Santo André – SP – Brasil

<sup>2</sup>Faculdade de Computação (FACOM) - Universidade Federal de Uberlândia (UFU) - Uberlândia - MG - Brasil– Uberlândia – MG - Brasil

victor.teixeira@aluno.ufabc.edu.br, [nascimento@facom.ufu.br](mailto:nascimento@facom.ufu.br),  
juliana.braga@ufabc.edu.br

**Resumo.** *Existe um grande número de deficientes visuais no Brasil, mas muitos deles ainda encontram problemas de acessibilidade. Muitas dessas dificuldades podem diminuir através do uso das tecnologias assistivas. O potencial de uso dessas tecnologias pelos deficientes visuais é grande, mas poucos são os esforços para que elas sejam desenvolvidas. Em face da necessidade de desenvolvimento de tecnologias assistivas que auxiliam na vida dos deficientes visuais juntamente com a importância e benefícios que elas trazem para essas pessoas, os objetivos desse estudo é contribuir para a inclusão social e digital dos deficientes visuais brasileiros propondo um algoritmo capaz de auxiliar os deficientes visuais no reconhecimento do valor de cédulas monetárias.*

**Abstract.** *There are many visually impaired people in Brazil, and most of them still have troubles with accessibility. It's possible to help with most of those difficulties using assistive technologies. The potential of visually impaired people using these technologies is good, but there are few efforts to develop them. Knowing the necessity to develop assistive technologies to help visually impaired people in their daily tasks and the benefits it might bring to them, the objective of this work is to contribute to the social and digital inclusion of visually impaired brazilians, proposing an algorithm capable of help them in recognize money bills.*

## 1. Introdução

Segundo o censo do Instituto Brasileiro de Geografia e Estatística (IBGE) de 2010 havia no Brasil uma população de mais de 190 milhões de pessoas, sendo que dessas 45,6 milhões (23,9%) apresentaram algum tipo de deficiência. Dentre o número de deficientes, há cerca de 35,8 milhões de pessoas com dificuldade para enxergar, sendo que 506,3 mil se declararam totalmente cegos. Apesar do grande número de deficientes visuais em nosso país, muitos deles ainda encontram problemas de acessibilidade como, por exemplo, dificuldades ao caminhar pelas ruas, realizar compras, utilizar recursos tecnológicos como: computadores, celulares, tablets, etc.

Algumas das dificuldades encontradas pelos deficientes visuais podem diminuir por meio do uso de Tecnologias de Informação e Comunicação (TICs). A apropriação de recursos tecnológicos modifica significativamente o estilo de vida, as interações e a conduta social ao inovar hábitos e atitudes em relação à educação, ao lazer e ao trabalho, à vida familiar e comunitária. Um exemplo disso são os cegos ou com baixa visão que usam os computadores para ler jornais, realizar pesquisas acadêmicas, fazer inscrição em concursos públicos, verificar resultados, ou simplesmente para treinar a digitação e o domínio do teclado. Desde a invenção do Código Braille, em 1829, nada teve tanto impacto nos programas de educação, reabilitação e emprego quanto o desenvolvimento dessas tecnologias para deficientes visuais (Campbell, 2001). Isso pode ser justificado pelo fato das TICs contribuírem para que esses deficientes tenham maior independência, qualidade de vida e inclusão na vida social através do suplemento, manutenção ou devolução de suas capacidades funcionais. As TICs ampliam as possibilidades de comunicação e de autonomia pessoal, minimizam ou compensam as restrições decorrentes da falta da visão. De acordo o livro “Internet para Necessidades visuais” (UTDAD/Guia, 1999) para a maioria das pessoas a tecnologia torna a vida mais fácil, para uma pessoa com necessidades especiais, a tecnologia torna as coisas possíveis.

Um recente estudo (Braga, 2012) realizado pelo grupo de pesquisa INTERA da UFABC teve como objetivo estudar o uso das TICs no cotidiano dos deficientes visuais e identificar demandas para o desenvolvimento de novas tecnologias. Um dos resultados dessa pesquisa foi a identificação da necessidade de um aplicativo que fosse capaz de identificar as cédulas monetárias (Real). Os entrevistados relataram uma grande dificuldade em identificar os valores das notas, sendo que essa dificuldade implica na exclusão social desses deficientes em realizar tarefas corriqueiras como: realização de compras, pagamento de meios de transporte (taxi), realização de serviços bancários, etc. Alguns deficientes também relataram terem sofrido de golpes motivados pelo fato de não conseguirem identificar os valores das cédulas financeiras.

Diante da necessidade de desenvolvimento de TICs que auxiliam na vida dos deficientes visuais juntamente com a importância e benefícios que elas trazem para essas pessoas, o objetivo desse estudo é contribuir para a inclusão social e digital dos deficientes visuais brasileiros. Para tal o presente trabalho propõe o desenvolvimento de um método capaz de auxiliar os deficientes visuais no reconhecimento do valor de cédulas monetárias. O método proposto foi dividido em três principais etapas: o pré-processamento da nota a ser reconhecida, a extração de características da imagem e por último sua classificação. O pré-processamento consiste na conversão da imagem para escalas de cinza. A etapa de extração de características é baseada no algoritmo SURF (Bay, 2008) que procura por pontos na imagem que são invariáveis independentemente de como a imagem é capturada (distância da nota, rotação, iluminação). Na última etapa, o classificador *SVM* (Cortes, 1995) é aplicado nas características encontradas para o reconhecimento do valor da nota. Um banco de imagens contendo 1440 imagens foi utilizado na etapa de avaliação do método proposto.

## **2. Materiais e Métodos**

O objetivo desse trabalho foi identificar qual o melhor algoritmo de processamento de imagem para reconhecimento de cédulas. O trabalho foi desenvolvido em linguagem *Java* e utilizou a biblioteca *OpenCV* na versão 2.4.0 (*OpenCV*, 2013) para auxiliar no

pré-processamento (e.g. conversão para escalas de cinza) e extração de características. Para a etapa de classificação, foi utilizada a plataforma *WEKA* (*Waikato Environment for Knowledge Analysis*) (Waikato, 2013). As principais etapas do algoritmo são: pré-processamento, extração de características e classificação. A Figura 1 ilustra o algoritmo de forma simplificada.

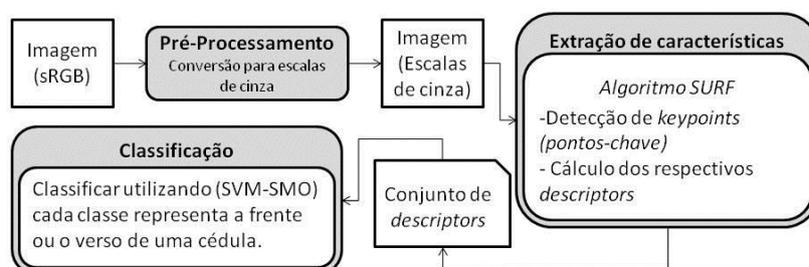


Figura 1. Diagrama do funcionamento simplificado do algoritmo.

## 2.1. Banco de Imagens

O banco de imagens foi elaborado com 1440 imagens digitais, sendo 240 para cada cédula monetária brasileira (primeira família de cédulas do Real<sup>1</sup>, com exceção da cédula de um real). As imagens foram capturadas em um ambiente controlado, com iluminação artificial de uma lâmpada fluorescente de 20 Watts. O dispositivo utilizado na captura foi um celular<sup>2</sup> com uma câmera com resolução máxima de 5 megapixels. O tamanho da imagem é de 2592 x 1944 pixels, com extensão JPEG e no padrão sRGB, sendo a resolução horizontal e vertical da imagem de 72 dpi e a intensidade de 24 bits.

Nesse banco foram utilizadas 30 imagens de cada cédula (valor monetário: dois, cinco, vinte, cinquenta e cem reais), sendo que cada nota possui oito imagens, variando a posição, horizontal e vertical em relação à câmera, o lado, frente e verso da nota, e uma distância de 10 e 15 centímetros na captura com a câmera.

## 2.2. Método proposto

A seguir, a descrição mais detalhada das etapas do método proposto para auxiliar o reconhecimento de cédulas monetárias pelos deficientes visuais.

### 2.2.1. Algoritmo de pré-processamento

A etapa de pré-processamento consistiu na conversão da imagem contendo a nota do espaço de cores sRGB para escalas de cinza. Então, foi utilizado a função “*cvtColor()*” contida na biblioteca *OpenCV* que utiliza Equação (1) para a conversão (Bradski, 2008).

$$Y = (0.299) * R + (0.587) * G + (0.114) * B \quad (1)$$

sendo, R, G e B os respectivos valores dos canais *red*, *green* e *blue* do *pixel* no espaço sRGB. Note que o valor *Alpha* não é utilizado na etapa dessa conversão.

### 2.2.3. Extração de características utilizando o algoritmo SURF

1. Cédulas monetárias em circulação no Brasil, estão sendo substituídas aos poucos pela Segunda Família do Real, porém continuarão válidas. A Primeira Família do Real conta com as notas de um (fora de circulação), dois, cinco, dez, vinte, cinquenta e cem reais (Novas Notas, 2013).

2. Neste trabalho utilizamos um celular *Sony Xperia U* (Sony XPeria, 2013).

O algoritmo SURF (*Speeded Up Robust Features*) (Bay, 2009 e Cortes, 1995) é um descritor invariante à rotação e aos efeitos de *escala* apresentado recentemente por (Bay, 2008) Essa técnica procura detectar e descrever pontos-chave (*keypoints*) da imagem para etapa de classificação.

Cada *keypoint* é selecionado de uma localização distinta da imagem. Sua característica mais importante é poder ser detectado, independentemente, da condição em que a imagem foi capturada, ou seja, em escala ou rotação diferente. A vizinhança do *keypoint* é representada por um vetor de atributos denominados *descriptors*, que são distintos, robustos a ruídos, a erros de detecção e deformações geométricas.

A detecção de *keypoints* baseia-se em aproximações da matriz Hessiana para um dado ponto na imagem, que deve estar em escalas de cinza. São detectadas estruturas em forma de borrão (*blob*), onde o determinante da matriz é máximo. A seguir as respostas das *wavelets* de *Haar* foram calculadas em torno do *keypoint* para determinar sua orientação dominante.

A descrição de características do *keypoint* pode ser dividida em duas principais etapas. A primeira é calcular a orientação resultante para uma dada região circular em torno do *keypoint* que seja invariante a rotação. Para tal as respostas das *wavelets* de *Haar* (Mallat, 1996) dentro da região circular dada são calculadas tanto na horizontal como na vertical. A orientação local dominante é estimada pela soma de todas as respostas dentro de uma fatia da região circular de tamanho  $\pi/3$ , gerando um vetor da orientação. A orientação global do *keypoint* é determinada pelo maior vetor de orientação de todas as fatias. A segunda consiste em criar o *descriptor*, que será um vetor de valores. Primeiramente é construída uma região quadrada centrada no *keypoint* e orientada pelo vetor de orientação descrito na etapa anterior. Um filtro Gaussiano é aplicado (centrado no *keypoint*) para remover deformações geométricas. A região é dividida em quatro sub-regiões iguais, para cada sub-região são calculadas as respostas da *wavelet* de *Haar* na horizontal e na vertical. O vetor *descriptor* resultante é a concatenação das quatro somas das respostas e seus respectivos módulos (chamemos de  $i$ ), sendo  $i$  definido por (2).

$$i = (\sum d_x, \sum d_y, \sum |d_x|, \sum |d_y|) \quad (2)$$

O *descriptor* resultante é um vetor de 64 valores. Para este trabalho foi utilizado uma variação do algoritmo que calcula esse vetor com 128 valores, o que deixa o processamento mais lento, porém os valores dos *descriptors* ficam mais distintos entre si, permitindo uma melhor definição de padrões para a classificação.

Nesse estudo, foram elaborados o vetor contendo os atributos de cada *keypoint* da imagem e um segundo contendo os seus respectivos *descriptors*. Cada *keypoint* possui seis atributos, um ponto (localização de onde ele foi encontrado na imagem com coordenadas  $x$  e  $y$ ), o tamanho (*size*) da característica, o ângulo que varia de 0 a 360, o atributo *response* (ou *hessian*) que representa o quão proeminente um *keypoint* é, ou seja, *keypoints* com maior *response* são características mais robustas da imagem, o *octave* (ou oitavas, relacionado à escala em que o ponto foi detectado, pode estar relacionado ao atributo *size*) e *class\_id* relacionado com o valor laplaciano, sendo que pontos com os valores laplacianos diferentes não podem ser homólogos (*OpenCV*, 3012). Para cada *keypoint* deve ser calculado um *descriptor*, que de forma simplificada,

é um vetor de 128 valores contendo a descrição do *keypoint* e sua vizinhança (Bay, 2008).

Seja um *keypoint* detectado em uma imagem “*k*”, seu respectivo *descriptor* representado por “*f(k)*”, tem-se para cada imagem um conjunto de dados formados pelos pares de *keypoint* e seu respectivo *descriptor* representado por “(*k*, *f(k)*)”.

Para a classificação é necessário um número igual de dados (*k*, *f(k)*) para cada imagem, porém o número *n* de (*k*, *f(k)*) detectados pelo algoritmo SURF varia de imagem para imagem. A solução proposta neste trabalho foi selecionar um número fixo de dados para cada imagem, para tal, primeiramente foi verificado o número mínimo de detecções de uma imagem (neste trabalho a imagem com menos detecções possuía *n* = 89), depois foram selecionados os *n* melhores pares detectados de cada imagem. A seleção filtrou os *n* pares que possuem *keypoints* com os maiores valores de *threshold* dentro do conjunto, ou seja, os *keypoints* e seus respectivos *descriptors* mais robustos de cada imagem.

O grupo de dados resultante foi dividido em duas partes, um conjunto contendo apenas *keypoints* e outro contendo apenas *descriptors*. Esses dois conjuntos foram utilizados para a classificação na *SVM*.

#### 2.2.4. Classificação SVM

No contexto de classificação, o classificador *Support Vector Machines-Sequential Minimal Optimization (SVM-SMO)* (Cortes, 1995 e Lorena, 2007) vem sendo usado para a classificação de características calculadas por algoritmos como SURF e SIFT (*Scale-invariant feature transform*) (Lowe, 2004) como visto em Silva (2012).

O *SVM* é uma das técnicas de aprendizado de máquina e se baseia na teoria de aprendizagem estatística, tendo por objetivo a separação ótima de dados entre classes distintas, buscando sempre a maior minimização de erros possível. A separação ótima ocorre em um hiperplano condicional, de forma que o plano é orientado a maximizar a distância entre as bordas das diferentes classes, utilizando seus pontos mais próximos. Caso os dados não sejam linearmente separáveis, a *SVM* mapeia os dados utilizando uma função *Kernel*, em um espaço de características de dimensão mais elevada, onde os dados se tornam linearmente separáveis (Osta, 2008). A Figura 2 mostra um exemplo de separação de classes com o algoritmo *SVM*.

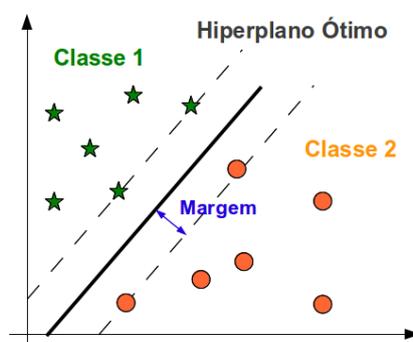


Figura 2. Ilustração da aplicação do algoritmo SVM. Fonte: Jacomini, et al. (2012).

Neste trabalho foi testado o conjunto de dados dos *keypoints* e *descriptors* de uma dada imagem. Nessa etapa, o método de rotação (*n-fold cross validation*) foi aplicado com o valor  $n = 10$ . Esse método utiliza 90% dos dados para treinamento e o restante, 10% dos dados para etapa de teste.

Para avaliar o desempenho do método proposto foram calculados os seguintes parâmetros: sensibilidade e especificidade. A sensibilidade representa a frequência com que o teste detectará o que está sendo testado, ou seja, num teste com sensibilidade de 90% dará um resultado positivo em 90 das 100 amostras que efetivamente apresentam o que está sendo investigado. A especificidade representa a frequência com que o resultado negativo está correto.

Também foi obtida a área sob a curva *ROC* (*Receiver Operating Characteristic*). A curva *ROC* (Fan, et al. 2006). Understanding receiver operating characteristic (roc) curves. Canadian Journal of

Emergency Medicine, 8(1), 19–20. é criada em um gráfico de verdadeiro-positivos (eixo *y*) versus os falso-positivos (eixo *x*). A área abaixo da curva serve como medida de precisão do desempenho de um classificador, sendo que uma área de 1.0 uma classificação perfeita e 0.0 um classificação completamente errônea.

**Tabela 1: Medida do desempenho da classificação.**

Medida	Definição
Sensibilidade	Verdadeiro Positivo / Total de Positivos
Especificidade	Verdadeiro Negativo / Total de Negativos

### 3. Resultados e Discussões

Essa seção apresenta os resultados de validação do método proposto nesse artigo. Para essa validação, executou-se a implementação do método considerando como entrada de dados todas as notas contidas no banco de imagens descrito na seção 2.1. O método foi aplicado em 30 imagens de cada valor monetário de cédula (dois, cinco, vinte, cinquenta e cem reais, sendo considerada tanto a frente quanto o verso de cada imagem). A Tabela 2 mostra os resultados da validação do método para o uso dos *keypoints*. Esses resultados são apresentados por classes de valores de cédulas. Essas classes foram categorizadas na primeira coluna da Tabela 2 e classificadas como segue: classe (**a**): *dois-frente*; classe (**b**): *dois-verso*; classe (**c**): *cinco-frente*; classe (**d**): *cinco-verso*; classe (**e**): *dez-frente*; classe (**f**): *dez-verso*; classe (**g**): *vinte-frente*; classe (**h**): *vinte-verso*; classe (**i**): *cinquenta-frente*; classe (**j**): *cinquenta-verso*; classe (**k**): *cem-frente*; classe (**l**): *cem-verso*.

**Tabela 2. Resultados da SVM usando o conjunto de keypoints.**

Classe	Especificidade	Sensibilidade	Área sobre curva ROC
<i>a</i>	0.429	0.525	0.885
<i>b</i>	0.570	0.642	0.926

<i>c</i>	0.377	0.433	0.859
<i>d</i>	<b>0.311</b>	0.350	0.774
<i>e</i>	0.313	<b>0.342</b>	0.762
<i>f</i>	0.546	0.492	0.890
<i>g</i>	0.733	<b>0.733</b>	0.964
<i>h</i>	0.350	0.358	0.811
<i>i</i>	0.509	0.467	0.899
<i>j</i>	0.620	0.558	0.942
<i>k</i>	<b>0.845</b>	0.683	0.976
<i>l</i>	0.545	0.400	0.868
Média	0,512	0,498	0,879

Com relação à sensibilidade, que mede a exatidão entre as instâncias positivas, a nota de vinte-frente proporcionou melhores resultados, onde obteve desempenho superior a 0,391 em relação a nota de dez-frente. Para avaliar a exatidão entre instâncias negativas, medida pela especificidade, observa-se um desempenho diferente para as notas avaliadas, sendo as notas de cinco-verso as de piores valores.

A Tabela 3 representa os resultados obtidos utilizando o conjunto de dados dos *descriptors* para classificação na *SVM*.

**Tabela 3. Métricas obtidas com o classificador *SVM* usando o conjunto de informações obtidas por meio dos *descriptors*.**

Classe	Especificidade	Sensibilidade	Área sobre curva <i>ROC</i>
<i>a</i>	<b>0.915</b>	0,983	0.996
<i>b</i>	0.983	0,975	0.998
<i>c</i>	0.974	<b>0,942</b>	0.994
<i>d</i>	0.992	0,975	0.999
<i>e</i>	0.975	0,967	0.991
<i>f</i>	<b>1.000</b>	0.992	0.999
<i>g</i>	<b>1.000</b>	0.975	0.998
<i>h</i>	0.992	0.983	0.995
<i>i</i>	0.944	0.983	1.000
<i>j</i>	<b>1.000</b>	<b>1,000</b>	0.999
<i>k</i>	0.992	0,992	1.000
<i>l</i>	<b>1.000</b>	0,992	0.997
Média	0,980	0,979	0,997

Com relação à sensibilidade, a nota de cinquenta-verso proporcionou melhores resultados, onde obteve desempenho superior as demais notas avaliadas. Para avaliar a especificidade, observa-se que há várias notas com valor ideal para o sistema na classificação. Nesse caso, os piores resultados foram obtidos com a nota dois-frente com

especificidade de 0,915. Ressalta-se que esse tipo de características, *descriptors*, é superior aos *keypoints*.

De acordo com os valores de área sobre a curva *ROC*, nota-se que o uso das características obtidas pelos *descriptors* o sistema proposto foi mais eficiente para avaliação das notas monetárias tendo uma taxa média de área sobre a curva *ROC* de 0,997, o que representa uma diferença de 0,118 superior na comparação com os *keypoints*.

#### 4. Conclusão e Trabalhos Futuros

Diante da necessidade de desenvolvimento de tecnologias que auxiliam na vida dos deficientes visuais juntamente com a importância e benefícios que elas trazem para essas pessoas, o objetivo desse estudo foi contribuir para a inclusão social e digital dos deficientes visuais brasileiros propondo um método capaz de auxiliar os deficientes visuais no reconhecimento do valor de cédulas monetárias. Para implementação desse método utilizou-se a linguagem *Java* juntamente com a biblioteca *OpenCV*. Para a etapa de classificação, foi utilizada a plataforma *WEKA* e para extração de características foi utilizado o algoritmo *SURF* combinado a um classificador *SVM*. O método proposto foi aplicado sobre um ambiente de iluminação controlada e um único modelo de câmera. Em trabalhos futuros, esses parâmetros serão avaliadas sobre diferentes condições. Os testes realizados abrangeram uma quantidade razoável de cédulas (180 cédulas diferentes, com oito variações de foto para cada cédula) e obtiveram bons resultados de uma taxa média de área sobre a curva *ROC* de 0,997. Recomenda-se a utilização do método utilizado para a identificação de cédulas monetárias. Este método será utilizado nas próximas etapas do trabalho, e será utilizado na implementação de um aplicativo *Android* com controles de voz para auxiliar os deficientes visuais na tarefa de identificação do valor da nota. A usabilidade do referido aplicativo também será testado por usuários portadores de deficiência visual.

#### Referências

- Apple iOS (2013). Disponível em: <<http://www.apple.com/br/ios/>>. Acesso em: 20/03/2013
- Android (2013). Disponível em: <<http://www.android.com/>>. Acesso em: 20/03/2013
- Bay H. ; Ess, A. ; Tuytelaars T. ; Gool, L. V. "SURF: Speeded Up Robust Features", 2008. Computer Vision and Image Understanding (CVIU), vol. 110, n. 3, p. 346-359.
- Bay, et al., 2008 Bay, H. Ess, A. Tuytelaars, T. e Van Gool, L., 2008. SURF: Speeded Up Robust Features, Computer Vision and Image. Understanding (CVIU), Vol. 110, N. 3, pp. 346-359. [Online] Disponível em: [ftp://ftp.vision.ee.ethz.ch/publications/articles/eth\\_biwi\\_00517.pdf](ftp://ftp.vision.ee.ethz.ch/publications/articles/eth_biwi_00517.pdf)
- Bradski, G. ; Kaehler A. "Learning OpenCV: Computer Vision with the OpenCV Library. O'Reilly Media, 2008. p. 58-60.
- Braga, J. C. ; Campi, J, A. ; Damasceno, R. P. ; Albenarz, N. H. C. . Estudo e Relato sobre a Utilização da Tecnologia pelos Deficientes Visuais. In: Simpósio Brasileiro

- de Fatores Humanos em Sistemas Computacionais 12, 2012, Cuiabá. Anais do Simpósio Brasileiro de Fatores Humanos em Sistemas Computacionais, 2012.
- Campbell, L. Trabalho e cultura: meios de fortalecimento da cidadania e do desenvolvimento humano. Revista Contato – Conversas sobre Deficiência Visual – Edição Especial. Ano 5, número 7 – Dezembro de 2001.
- Comma separated value file format (2013). Disponível em: < <http://www.creativyst.com/Doc/Articles/CSV/CSV01.htm>>.
- Cortes C. ; Vapnik V. “Support-vector network”, 1995. Machine Learning, vol. 20, p. 273-297.
- LookTel Money Reader (2013). Disponível em: <<http://www.looktel.com/moneyreader>>. Acesso em: 20/03/2013
- Java (2013). Disponível em: < <http://www.java.com>>. Acesso em: 20/03/2013
- Jacomini, R. S. ; Nascimento, M. Z. ; Dantas, R. D. . Empregando padrões binários locais em domínio wavelet para classificação de lesões benigna e maligna em mamogramas. In: VIII Workshop de Visão Computacional, 2012, Goiania. VIII Workshop de Visão Computacional, 2012. p. 1-6.
- Lorena, A. C. ; Carvalho, A. C. P. L. F. “Uma introdução às Support Vector Machines”. Revista de Informática Teórica e Aplicada, v. 14, p. 43-67, 2007.
- Lowe, D.G. “Distinctive Image Features from Scale-Invariant Keypoints”, 2004. International Journal of Computer Vision, vol. 60, n. 2, p. 91-110.
- Mallat, S. (1996). Wavelets for a vision, Proceedings of the IEEE 84(4): 604–614.
- Siller, F. ; Braga, J. C. “GPS para deficientes visuais. In: Simpósio de Fatores Humanos em Sistemas Computacionais”, 2010. Belo Horizonte. Anais Estendidos do IX Simpósio de Fatores Humanos em Sistemas Computacionais. Porto Alegre: Sociedade Brasileira de Computação, 2010. v. 2. p. 1-162.
- OpenCV (2013). Disponível em: < <http://opencv.org/>>. Acesso em: 20/03/2013
- OpenCV’s Keypoint Structure (2013). Disponível em: < [http://opencv.willowgarage.com/documentation/cpp/feature\\_detection.html](http://opencv.willowgarage.com/documentation/cpp/feature_detection.html)>. Acesso em 21/03/2013
- Osta H. ; Qahwaji R. ; Ipsons S. “Comparisons of feature selection methods using discrete wavelet transforms and support vector machines for mammogram images”, 2008. Systems, Signals and Devices. IEEE SSD 2008. 5th International Multi-Conference. p. 1 –6.
- Novas Notas - Primeira Família do Real (2013). Disponível em: < <http://novasnotas.bcb.gov.br/primeira-familia.html>>. Acesso em 26/03/2013
- Silva, F. A. ; Artero, A. O. ; Veludo, M. S. P. ; Barbosa, R. L. “Uma Metodologia Para Detectar E Reconhecer Placas De Sinalização De Trânsito”, 2012. Goiania. Anais Do Viii Workshop De Visão Computacional, 2012.
- Sony Xperia U (2013). Disponível em: < <http://www.sonymobile.com/br/products/phones/xperia-u/>>. Acesso em: 27/03/2013

Viola, P.; Jones M. "Robust real-time object detection" (2002). International Journal of Computer Vision, 2002.

Waikato Environment for Knowledge Analysis (2013). Disponível em: <<http://www.cs.waikato.ac.nz/ml/index.html>>. Acesso em: 20/03/2013