

Sistema Inteligente para Interpretação de Imagens para Medição de Erros Refrativos Oculares

Antonio Valeiro Netto^{1,2}, André C. P. L. F. de Carvalho¹, Maria C. F. de Oliveira¹

¹Instituto de Ciências Matemáticas e de Computação – Universidade de São Paulo
Av. Trabalhador São-carlense, 400 – CEP: 13560-970, São Carlos São Paulo, Brasil

² Cientistas Associados Ltda.

Rua Alfredo Lopes, 1717 – CEP: 13560-460, São Carlos, São Paulo, Brasil
antonio.valerio@cientistasassociados.com.br, {andre, cristina}@icmc.usp.br

Abstract. *This work presents a computational system that uses Machine Learning (ML) techniques to assist in ophthalmological diagnosis. The system produces objective and automatic measures of ocular refraction errors, namely astigmatism, hypermetropia and myopia from functional images of the human eye acquired with a technique known as Hartmann-Shack (HS). In addition to implementing a novel approach for measuring ocular refraction errors and introducing ML techniques for analyzing ophthalmological images, this work is an investigation on the use of Artificial Neural Networks and Support Vector Machines (SVM) for tasks in Image Understanding.*

Resumo. *Este trabalho apresenta um sistema computacional que utiliza técnicas de Aprendizado de Máquina (AM) para auxiliar o diagnóstico oftalmológico. Trata-se de um sistema de medidas objetivas e automáticas dos principais vícios de refração ocular, astigmatismo, hipermetropia e miopia. Além da implementação de uma nova abordagem para a medição dos vícios refrativos e da introdução de técnicas de AM na análise de imagens oftalmológicas, o trabalho contribui para a investigação da utilização de Support Vector Machines (SVM) e Redes Neurais Artificiais em sistemas de Entendimento/Interpretação de Imagens (Image Understanding).*

1. Introdução

Neste trabalho foi investigada uma abordagem inédita para a medição dos vícios refrativos baseada em análise de imagens utilizando técnicas de Aprendizado de Máquina. O Aprendizado de Máquina (AM) é um campo de pesquisa da Inteligência Computacional cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado, bem como a construção de sistemas capazes de adquirir conhecimento de forma automática. Um sistema de aprendizado é um programa de computador que toma decisões baseadas em experiências acumuladas por meio da solução bem sucedida de problemas anteriores [Monard & Baranauskas 2003]. Muitas aplicações práticas certificam a eficiência dessas técnicas em extrair conhecimento a partir de amostras de dados [Mitchell 1997], particularmente no caso de Redes Neurais Artificiais (RNAs) [Rumelhart et al. 1986] e Máquinas de Vetores Suporte (Support Vector Machines – SVMs) [Joachims 1999].

O sistema funcional desenvolvido aplica técnicas convencionais de processamento a imagens do olho humano fornecidas por uma técnica de aquisição chamada Hartmann -Shack, com o objetivo de extrair e enquadrar a região de interesse e remover ruídos. Em seguida, vetores de características são extraídos dessas imagens pela técnica de transformada *wavelet* de Gabor e, posteriormente, analisados por técnicas de AM para diagnosticar os possíveis vícios refrativos presentes no globo ocular representado. Os resultados obtidos indicam a potencialidade dessa abordagem para a interpretação de imagens de HS de forma que, futuramente, outros problemas oculares possam ser detectados e medidos a partir dessas imagens.

A seguir, na Seção 2 são apresentadas informações iniciais sobre as motivações para o desenvolvimento do projeto. Na Seção 3, uma descrição geral do sistema de medição dos vícios refrativos é apresentada. Na Seção 4 são abordadas as metodologias utilizadas para o desenvolvimento e os principais resultados do projeto. Por fim, na Seção 5 são discutidas as principais contribuições e apresentadas algumas considerações sobre o trabalho desenvolvido e suas limitações.

2. Considerações Iniciais

O primeiro desafio consistiu em identificar uma técnica de aquisição das informações funcionais sobre o olho humano que permitisse o diagnóstico dos vícios refrativos. Imagens digitalizadas da íris ou da retina não contêm informações funcionais para o diagnóstico. Aprofundando o estudo na área de Optometria, em busca de soluções, deparou-se com algumas técnicas de aquisição, até a descoberta da técnica Hartmann-Shack (HS) ou Shack-Hartmann (SH). Essa técnica vem inovando as pesquisas na área de Optometria e, na opinião de especialistas, o medidor de anomalias (*aberrometer*) baseado no princípio de HS é o mais promissor dos vários métodos existentes [Thibos & Hong 1999]. A primeira aplicação desse princípio na medição de anomalias do olho humano ocorreu em 1994 [Liang et al. 1994]. Desde então, vários pesquisadores têm se dedicado à melhoria da técnica, propondo modificações, adaptações e sugerindo novas formas de aplicação para outras condições clínicas. Essa tecnologia de aquisição de dados do olho já é utilizada em equipamentos que representam a nova geração de instrumentos para auxiliar nas cirurgias refrativas a laser (*Photorefractive Keratoplasty* - PRK).

Este contexto motivou a utilização de imagens do olho adquiridas pela técnica de HS. Em vista da inviabilidade técnica e financeira de montar um protótipo do *hardware* de aquisição, buscou-se uma parceria com uma das instituições de pesquisa no exterior que, à época, possuía o *hardware* de aquisição. Foram realizados contatos com o grupo de Optometria da Universidade de Indiana (EUA), coordenado pelo Prof. Dr. Larry Thibos, que disponibilizou seu banco de imagens contendo 600 imagens de olhos de 100 indivíduos obtidas com o equipamento de aquisição desenvolvido no seu grupo.

O reconhecimento e análise das características do globo ocular utilizando algoritmos de AM pode viabilizar não apenas o diagnóstico dos vícios de refração, como também a obtenção de outras informações sobre o olho a partir da mesma imagem de HS [Valerio Netto 2001]. Os sistemas de análise atuais baseados na técnica de HS utilizam um globo artificial emétrepe para calibrar o equipamento, isto é, dados são extraídos da imagem do

globo artificial e comparados com os dados correspondentes extraídos das imagens obtidas do olho sob exame para verificar a presença de anomalias. Esse é o caso da técnica utilizada por Liang et al. [1994], que utiliza polinômios de Zernike para realizar a medição. Com isso, muitas informações contidas nas imagens são ignoradas no processo de análise. A proposta de utilizar técnicas de AM para a análise e interpretação de imagens de HS busca proporcionar um sistema de medição capaz de considerar o conteúdo da imagem como um todo, e não apenas comparar dados discretos extraídos da mesma com dados de referência, como é feito hoje. A interpretação da imagem como um todo torna possível, em princípio, medir outras enfermidades do olho, como é o caso do “Tears Film Breakup” [Himebaugh et al. 2001] o que é inviável atualmente. A abordagem adotada difere da que vem sendo usada pelos especialistas em Optometria/Oftalmologia para a medição de anomalias a partir de imagens [Valerio Netto & Oliveira 2002], e oferece um leque de possibilidades em termos de pesquisa acadêmica e tecnológica voltada à interpretação de informações de um globo ocular. Técnicas de AM também podem ser aplicadas a imagens adquiridas por outras técnicas, como *Fluorescein*, *Retro-illumination* e *Optical scatter map* [Thibos 2002]. Até onde se tem conhecimento, este trabalho é pioneiro na utilização de técnicas de AM em Optometria/Oftalmologia, podendo dar início a uma maior aproximação entre as áreas de Computação e Optometria.

3. Visão Geral do Sistema Inteligente

O sistema de medição foi desenvolvido em Plataforma Linux e engloba quatro etapas distintas, apresentadas na Figura 1. As Etapas 1, 2 e 3 são realizadas por módulos desenvolvidos no âmbito deste trabalho, e a Etapa 0 está sendo realizada externamente.




Figura 1. Visão geral do sistema de medição dos vícios refrativos [Valerio Netto 2003].

- Etapa 0: Módulo de aquisição de imagens. A aquisição das imagens oftalmológicas pela técnica de Hartmann-Shack (HS) foi feita com o equipamento construído por pesquisadores do Grupo de Optometria da Universidade de Indiana (EUA). Um banco de imagens já disponível, cedido pelo professor responsável pelo Grupo, foi utilizado para desenvolver e testar os demais módulos do sistema.
- Etapa 1: Módulo de pré-processamento de imagens. As imagens oftalmológicas não são geradas em um padrão que permita a sua utilização imediata. É necessário identificar e extrair a região de interesse em cada uma delas, padronizá-las e, posteriormente, eliminar

ruídos que podem distorcer os resultados do processo de extração de características. Foram implementados algoritmos específicos de processamento de imagens inspirados no método de análise de histograma e que utilizam informações espaciais e geométricas derivadas do conhecimento do domínio da aplicação.

- Etapa 2: Módulo de extração de características. O objetivo da extração é diminuir a quantidade de dados de entrada para o módulo de análise. Duas técnicas de dois métodos diferentes foram implementadas e testadas. Do método de análise multivariada foi implementada a técnica de análise de componentes principais (*Principal Component Analysis* – PCA); do método de transformada de *wavelet* foi implementada a transformada de Gabor.
- Etapa 3: Módulo de análise. É responsável pela interpretação dos atributos gerados pelo módulo de extração de características. Foram realizados experimentos com duas técnicas de AM, a saber, *Support Vector Machines* (SVMs) e Redes Neurais Artificiais (RNAs), especificamente redes RBF.

4. Metodologia e resultados

O processo de aquisição das imagens de HS utilizou o equipamento construído na *School of Optometry* conhecido por “Aberrometer”. As imagens, após a aquisição, passam por uma fase de pré-processamento, cujo intuito é corrigir artefatos e ruídos introduzidos na aquisição. O banco de imagens disponível possui imagens de olhos de 100 pacientes, seis por paciente, três imagens do olho direito e três do olho esquerdo, totalizando 600 imagens. Cada imagem é associada a três medidas que caracterizam os vícios refrativos – esférica (S), cilíndrica (C) e eixo do astigmatismo (A). Essas medidas associadas às imagens foram determinadas com precisão de 0.25 D (Dioptrias) para esférica e cilíndrica (miopia, hipermetropia e astigmatismo) e 5° para o eixo do astigmatismo, utilizando a abordagem de Liang et al. [1994]. Essas medidas foram usadas como referência de comparação na avaliação do sistema desenvolvido neste trabalho.

Antes da análise pelo módulo de AM, um vetor de características é extraído de cada imagem. Inicialmente, foi utilizada a técnica da PCA e, posteriormente, a técnica de transformada de Gabor para reduzir as informações de cada imagem abstraindo as características relevantes. Os experimentos realizados, posteriormente, com as diferentes configurações do módulo de análise indicam que a transformada de Gabor produz os melhores resultados, e por isso ela foi adotada para ser utilizada no módulo de extração do sistema. Informações adicionais sobre essa verificação são apresentadas em Valerio Netto [2003].

Para a concepção e implementação do módulo de análise dos vícios refrativos foram investigadas várias alternativas, buscando identificar a configuração de algoritmo (RNA/SVM) e parâmetros mais adequada ao sistema de medição. Foram realizados inúmeros experimentos e testes com diferentes modelos e arquiteturas de RNAs (Redes MLP e RBF), e diferentes quantidades de atributos de entrada (tamanho do vetor de características), tanto para as RNAs quanto para as SVMs. Isto proporcionou um aprimoramento técnico gradual que permitiu definir a arquitetura descrita a seguir para o módulo de análise, que utiliza SVM e apresentou os melhores resultados de saída.

O módulo de análise baseado em SVM foi implementado com a ferramenta Torch [Torch 2002]. Diversos parâmetros das SVMs foram manipulados nos experimentos, como o tipo de *kernel* (linear, polinomial, gaussiano e sigmoidal), o critério de parada e os parâmetros dos *kernels*. Para o treinamento, o conjunto de dados (426 exemplos, i.e., vetores de características das imagens de entrada, após a retirada de padrões que apresentavam problemas de medição) foi dividido em 10 partições. Cada partição contém dois subconjuntos, o de treinamento e validação com 80% dos exemplos, e o de teste com 20% dos exemplos. Para cada medida (*S*, *C* e *A*) foi projetado e desenvolvido um módulo de análise independente. Para o treinamento as medidas *S*, *C* e *A* foram divididas em classes de acordo com um intervalo fixo. Para esférica (*S*) foram criadas 9 classes (as medidas variam entre $-1.75 D$ e $+0.25 D$ com intervalos de $0,25 D$), para cilíndrica (*C*) foram criadas 6 classes (as medidas variam entre $0.0 D$ e $1.25 D$ com intervalos de $0,25 D$) e para o eixo do astigmatismo (*A*) foram criadas 25 classes (as medidas variam entre 0° e 180° com intervalos de 5°).

Os melhores resultados obtidos com o conjunto de testes são apresentados na Tabela 1. A segunda coluna da tabela apresenta a quantidade de exemplos de cada uma das medidas presentes em cada conjunto de teste. Na coluna com o título “Medida exata” são apresentadas as taxas médias (em porcentagem) e o desvio padrão (em porcentagem) do erro das SVMs para as medidas de *S*, *C* e *A*. A coluna com o título “Propagação do erro” também apresenta o erro médio e desvio padrão, porém considerando uma tolerância do erro das medidas de *S* e *C* de $\pm 0.25 D$, e uma tolerância do erro de *A* de $\pm 5^\circ$. Isso significa que, se uma medida *S* ou *C* possui valor igual a $0.5 D$, são computados como acertos do classificador os valores $0.5 D$, $0.25 D$ ou $0.75 D$. Para uma medida *A* cujo valor exato é 30° são computados como acertos os valores 30° , 25° ou 35° .

Tabela 1. Resultados da arquitetura de classificação utilizando SVM.

	Exemplos	Medida Exata		Propagação do erro	
		Erro Médio	Desvio Padrão	Erro Médio	Desvio Padrão
<i>S</i>	82	62.20%	$\pm 1.10\%$	18.29%	$\pm 1.12\%$
<i>C</i>	83	42.17%	$\pm 1.02\%$	9.64%	$\pm 1.00\%$
<i>A</i>	70	81.43%	$\pm 1.61\%$	70.00%	$\pm 1.64\%$

Com o intuito de verificar quanto os resultados obtidos são influenciados pelo desbalanceamento das classes, i.e., pelas diferentes quantidades de exemplos por classe, buscou-se balancear a quantidade de exemplos em cada classe de medidas antes de apresentá-los ao módulo de análise. Foram montadas 10 novas partições dos exemplos de entrada, contendo dois conjuntos cada: um conjunto de treinamento e validação, com 80% dos exemplos, e um conjunto de teste, com 20% dos exemplos. Para as medidas de *S* e *C* os conjuntos foram constituídos por classes com mais de 30 exemplos, e para as medidas de *A* os conjuntos foram constituídos por classes com mais de 25 exemplos. Foram escolhidas cinco classes para *S*, quatro classes para *C* e quatro classes para *A*. Os resultados são apresentados na Tabela 2.

Tabela 2. Resultados da arquitetura com balanceamento artificial.

	Exemplos	Medida Exata		Propagação do erro	
		Erro Médio	Desvio Padrão	Erro Médio	Desvio Padrão
S	82	56.67%	$\pm 1.70\%$	13.33%	$\pm 1.64\%$
C	83	41.67%	$\pm 2.12\%$	20.83%	$\pm 2.09\%$
A	70	30.00%	$\pm 2.40\%$	0.00%	$+ 2.12\%$

Os resultados obtidos indicam a importância de balancear o banco de imagens para facilitar o treinamento e, conseqüentemente, obter um melhor desempenho na fase de teste, principalmente se existir um grande número de classes (observar a diferença entre os resultados da medida A). Esse fator deve ser considerado no momento da construção de um banco de imagens para teste. Contudo, observou-se que os resultados da medida C foram inferiores aos resultados apresentados na Tabela 1. Isso pode estar ocorrendo devido a duas das classes originais (medidas iguais a 0.25 D e 0.50 D) possuírem uma quantidade de exemplos muito elevada em comparação às demais classes. O alto índice de acerto é decorrente da maior quantidade de exemplos dessas classes nos conjuntos de teste.

5. Conclusões

Este trabalho explora uma nova abordagem para a medição dos vícios de refração ocular que utiliza técnicas de AM para a análise de imagens oftalmológicas. É proposto um sistema de análise que explora técnicas e conceitos de Entendimento/Interpretação de Imagens (*Image Understanding*), área na qual existem ainda poucos projetos práticos realizados que utilizam SVMs e RNAs. O processo de desenvolvimento e os resultados obtidos podem servir como um estudo de caso para os pesquisadores interessados em verificar a adequação dessas técnicas de AM para a execução de tarefas no campo do Entendimento/Interpretação da Imagem. Adicionalmente, este trabalho estabelece as bases para a geração de conhecimento em uma área multidisciplinar (computação, física, optometria e engenharia biomédica) capaz de viabilizar, no futuro, o desenvolvimento de um equipamento nacional de medição ocular. Além da capacitação da indústria nacional, isso pode representar equipamentos a um menor custo, ampliando o número de pacientes que podem ser atendidos.

Os resultados obtidos permitem afirmar que os objetivos propostos foram atingidos com êxito. Foi efetuada a concepção técnica de um sistema computacional para a medição dos vícios refrativos a partir de imagens funcionais do olho. O sistema de medidas apresentou melhor desempenho quando utilizada a transformada de Gabor para a extração de vetores de características das imagens e SVMs para a análise desses vetores. Entretanto, todo o desenvolvimento teve como base o banco de imagens de Hartmann -Shack obtido junto ao grupo de Optometria da Universidade de Indiana (EUA), o qual, apesar de ter se mostrado suficiente para validar a metodologia, apresenta diversas limitações.

As amostras disponíveis são em pouca quantidade e apresentam um espectro de medidas bastante reduzido: para esférica (S) o espectro varia entre -1.75 D e + 0.25 D; e para cilíndrica (C) varia entre 0.0 D e 1.25 D (resolução 0.25 D), com o eixo (A) variando

entre 5° e 180° (resolução de 5°). Dentro desse espectro existem poucos exemplos de cada classe para o treinamento. Esse foi um dos fatores responsáveis pela dificuldade apresentada pelo módulo de análise em abstrair um modelo adequado para a interpretação dos atributos. Acredita-se que um maior número de exemplos representativos distribuídos uniformemente pelo espectro de medidas possível permitiria melhorar o desempenho do módulo de análise. Além disso, o banco de imagens deveria ser balanceado em relação às classes de medidas, i.e., possuir um número semelhante de exemplos em cada classe. Outro fator limitante da base que prejudicou o desempenho do módulo de análise foi à diferença constatada entre as medidas fornecidas de S , C e A relativas às três imagens do olho de um mesmo paciente. Para dar continuidade à pesquisa seria necessário adquirir um novo banco de imagens com maior número de exemplos de cada olho e com medidas que apresentem menor variação. Uma possibilidade seria adquirir um banco de imagens com, pelo menos, 30 imagens HS de cada olho, e o mesmo olho ser medido por um optômetro mecânico de boa precisão. Dessa forma, o banco teria 30 imagens de cada olho e uma única medida de S , C e A associada, facilitando a fase de treinamento. A experiência adquirida nesse trabalho sugere que, se este procedimento for executado para um espectro de medição mais amplo, o módulo de análise provavelmente produzirá resultados superiores aos obtidos.

No início da pesquisa foi investigada uma arquitetura do módulo de análise utilizando regressão, que apresentou resultados inferiores aos produzidos pelo modelo de classificação adotado. Entretanto, o baixo desempenho apresentado para o conjunto de imagens testadas não invalida a utilização desse modelo em um sistema de medição. Provavelmente, o número insuficiente de exemplos representativos no espectro impediu a abstração de um modelo correto para generalização, sendo decisivo para o baixo desempenho. Também foi decisiva a diferença entre as medidas de S , C e A relativas às três imagens de cada olho. Apesar de todas as limitações do banco de imagens para utilização por técnicas de AM, já que ele não foi criado levando em consideração pontos importantes como balanceamento, quantidade de exemplos, e ausência de ambigüidade, o comportamento tanto das SVMs quanto das RNAs demonstrou que as mesmas conseguem responder bem às adversidades de um banco de imagens obtido por um sistema real. Na área médica pode ser difícil obter um espectro adequado no qual todas as classes estão representadas em quantidade suficiente para permitir um desempenho satisfatório no módulo de análise.

Observando a facilidade das SVMs e RNAs em relacionar entradas e saídas, é possível vislumbrar uma oportunidade promissora de reproduzir, em um sistema computacional de baixo custo, os resultados de sistemas comerciais complexos e custosos. O mesmo arcabouço básico desenvolvido para a medição de vícios de refração ocular seria aplicável à detecção de outras doenças do olho presentes em imagens HS. A medição utilizando SVMs ou RNAs permite vislumbrar a possibilidade de analisar imagens oftalmológicas provenientes de outras técnicas de imageamento, como *Fluorescein*, *Retro-illumination* e *Optical scatter map* para identificar outros problemas oculares. No caso de imagens adquiridas pela técnica de HS, acredita-se que a abordagem adotada é aplicável para medir e avaliar outras enfermidades do olho humano, como é o caso do “Tears Film Breakup”, o que é inviável utilizando a técnica convencional para avaliação das imagens de HS baseada em polinômios de Zernike.

Por se tratar de um trabalho pioneiro, existem muitas oportunidades de continuidade na área de atuação desta tese. Maiores informações podem ser encontradas em Valerio Netto [2003].

Agradecimentos

Os autores agradecem ao Prof. L. Thibos da *School of Optometry, Indiana University, USA*, ao Prof. Dr. João E.S.B. Neto do ICMC/USP; e o suporte financeiro da FAPESP (processos 00/04779-2, 01/09540-0 e 02/08038-2) e CNPq (processos 09540-0 e 521931/97-5).

Referências Bibliográficas

- Himebaugh, N., Thibos, L. N., Hong, X. (2001) "Comparison of Fluorescein and Hartmann - Shack wavefront sensing methods for monitoring tear film breakup", <http://research.opt.indiana.edu/>
- Joachims, T. (1999) "Making large-scale SVM learning practical". In: Schölkopf et al. *Advances in kernel methods – support vector learning*. MIT Press.
- Liang, J., Grimm, B., Goelz, S., Bille, J. F., (1994) Objective measurement of wave aberrations of the human eye with the use of a Hartmann -Shack wave-front sensor. 'J. Opt. Soc. Am.', Vol. 14, No. 11/ July, pp. 1949-1957.
- Mitchell, T. (1997) "Machine Learning". McGraw Hill.
- Monard, M. & Baranauskas, J. (2003) "Conceitos sobre aprendizado de máquinas". Em *Sistemas Inteligentes: Fundamentos e Aplicações*, Cap. 4, Editora Manole, 512 Pp.
- Rumelhart, D.E et al. (1986) "Learning internal representations by error propagation", v.1, Cambridge, MA. MIT Press.
- Thibos, L. N. & Hong, X. (1999) Clinical applications of the Shack -Hartmann aberrometer, "Optometry and vision science", vol. 76, no. 12, pp. 817-825.
- Thibos, L. N. (2002) "Research Computing Laboratory – School of Optometry", <http://research.opt.indiana.edu/>
- Torch (2002) "Torch: a modular machine learning software library" . <http://www.torch.ch/>
- Valerio Netto, A. (2001) "Proposal to use artificial intelligence in the field of ophthalmology" , Oxyopia: Vision Science Seminar, Indiana - USA, October.
- Valerio Netto, A. & Oliveira, M. C. F. (2002). Using neural nets to measure ocular refractive errors - a proposal, "Proceeding SPIE Conference", Seattle, EUA, December.
- Valerio Netto, A. (2003) 'Processamento e análise de imagens para medição de vícios de refração ocular', Tese (doutorado), ICMC/USP, São Carlos, SP, Julho. 140Pp.