

Aplicação de Redes Neurais na Implementação de um Sistema de Auxílio ao Diagnóstico em um Instrumento Médico-Hospitalar*

Luis Alberto Vieira de Carvalho[†]

Instituto de Física de São Carlos (IFSC-USP), Av. Dr. Carlos Botelho, 1465, 13560-250 São Carlos, SP, Brasil

Recebido em 04 de Abril, 2003. Versão final recebida em 16 de Novembro, 2003.

A partir da década de 80 do século passado houve um grande número de publicações relacionadas à modelos e teorias sobre o funcionamento cognitivo do cérebro humano, ramo que mais tarde ficou conhecido como Inteligência Artificial (IA). Alguns destes modelos ficaram genericamente conhecidos como Redes Neurais (RN), pois continham elementos básicos com objetivo de simular o neurônio biológico. Desde então várias aplicações em diferentes áreas foram implementadas com sucesso, mostrando a eficiência destes modelos no auxílio à tomada de decisão. Há instrumentos comerciais de diagnóstico da córnea genericamente conhecidos como *topógrafos de córnea*. A função principal destes aparelhos é permitir uma análise quantitativa e objetiva da superfície da córnea. Em caso de intervenção cirúrgica, com este exame o oftalmologista pode decidir entre operar ou não uma determinada córnea. Para alguns casos patológicos não é aconselhável a intervenção cirúrgica e caso seja realizada pode até mesmo vir a causar cegueira ou necessidade de transplante de córnea (*ceratoplastia*). No entanto, o diagnóstico de patologias como estas não é uma tarefa trivial, e na maioria das vezes exige anos de treinamento e experiência por parte do médico. Neste sentido, é de anseio da sociedade oftalmica algum tipo de algoritmo implementado em software que leia ou contenha exemplos de córneas e que possa ajudar na interpretação destes exames. Com base nestas necessidades, foi desenvolvido e implementado neste trabalho uma RN para análise e classificações de mapas topográficos da córnea. Utilizando ferramentas de modelamento foi implementado uma RN do tipo alimentada adiante com duas camadas e retro-propagação. 80 córneas foram mensuradas em um topógrafo comercial e depois classificadas por clínicos experientes em um total de 5 diferentes categorias. 50% destas córneas foram utilizadas para “treinar” a RN e os outros 50% foram alimentados na RN para testar sua eficiência. As respostas da RN foram analisadas estatisticamente em termos de *sensibilidade* (verdadeiro positivo/[verdadeiro positivo+falso negativo]), *especificidade* (verdadeiro negativo/[verdadeiro negativo+falso positivo]), e *precisão* ([verdadeiro positivo+verdadeiro negativo]/total de casos). O valor médio destes números foi, respectivamente, 78,75%, 97,81% e 94,00%. Considerando o baixo número de casos usados para treinar a RN estes resultados iniciais podem ser considerados bastante promissores. Com os resultados preliminares obtidos neste primeiro trabalho pode-se considerar a aplicação deste sistema tanto como um módulo de treinamento para estudantes de medicina como um suporte a decisões para médicos mais experientes, ou seja, na forma de uma “segunda opinião”, aumentando assim as chances de um diagnóstico correto.

1 Introdução

Nos anos 80 e 90, com o barateamento e aprimoramento dos microcomputadores, vários instrumentos médicos puderam ser automatizados. Dentre estes podemos citar os tomógrafos computadorizados, equipamentos para ultrassonografia, e mais especificamente na área oftalmica, podemos citar os auto-refratores, auto-ceratômetros, e também os modernos *Topógrafos de Córnea*, ou, mais precisamente, *Videoceratógrafos* (VC). Podemos afirmar que os VC originaram-se da automatização dos antigos fotoceratoscópios dos anos 50 [Mandell & York, 1969], com o

acoplamento de câmeras de vídeo para substituição das tradicionais câmeras fotográficas, e placas de captura de imagens instaladas nos microcomputadores. Com estas mudanças vários processos antes demorados e trabalhosos passaram a levar poucos segundos, consequentemente dando ao médico mais tempo para tarefas mais pertinentes. O processamento de imagens de Plácido¹, antes uma tarefa árdua, feita manualmente em fotografias convencionais, um processo que às vezes levava dias, passou a ser realizado em poucos segundos por sofisticados algoritmos de processamento de imagens [Gonzales & Woods, 1992; Carvalho et al, 1996, 1999, 2001]; a impressão dos mapas de curvat-

* Esta pesquisa foi parcialmente financiada pela FAPESP, processo #01/03132-8.

[†]lavcf@if.sc.usp.br

¹Imagens de Plácido são simplesmente o reflexo de discos pretos e brancos intercalados que formam um padrão quando posicionados em frente à córnea, que receberam este nome segundo seu inventor [Plácido, 1880].

uras, de simples folhas com tabelas ou números preenchidos à mão, passou a ser impresso em diversas formas, na tela colorida do monitor ou em impressoras coloridas de baixo custo. Os tradicionais mapas *axiais* e *tangenciais* puderam ser codificados por cor, assim como mapas tridimensionais da elevação relativa da córnea [Salmon et al, 1995], facilitando a interpretação por parte do médico e aprimorando as opções didáticas no momento da explicação da patologia ao paciente e sua família.

Durante os anos 90 os microcomputadores ficaram ainda mais rápidos e robustos, assim como os sistemas operacionais, aumentando ainda mais a relação custo/benefício destes equipamentos. A disponibilidade de processadores mais rápidos, placas gráficas de alto desempenho, gravadores de CD-ROM, alta capacidade em memória RAM e memória de vídeo, entre outros, motivou o desenvolvimento de softwares mais elaborados, no sentido de aprimorar ainda mais o processo de exame. Dentre estes aprimoramentos recentes podemos citar módulos de softwares para o auxílio ao diagnóstico, como os mapas STAR e *Holladay Diagnosis Summary indices* [Philippe et al, 2000] do instrumento Eyesys, ou o Klyce/Maeda [Maeda et al, 1998; Klyce et al, 2000] ou Rabinovitz [Rabinovitz, 1999] para auxílio na detecção de ceratocone^{2*}. Todos estes softwares para diagnóstico, embora relativamente recentes, dependem de uma maneira ou de outra da experiência do usuário, pois geralmente relacionam uma série de índices em diferentes telas do computador para análise final do médico.

Depois de vários anos trabalhando no desenvolvimento de *hardware* e *software* para topografia de córnea [Carvalho, 1995-2002], nossa proposta no atual trabalho foi dar um passo adiante nos sistemas para diagnóstico de video-ceratografias. Fizemos isto pesquisando e implementando técnicas que utilizam os conceitos da *Inteligência Artificial* (IA) e *Redes Neurais* (RN) com o objetivo de oferecer ao médico um software para diagnóstico na forma mais didática possível, ou seja, classificando esta ou aquela córnea em uma linguagem do dia-a-dia, ou seja, *ceratocone, normal, astigmatismo a favor da regra*, e assim por diante. Este objetivo vem de encontro à crescente capacidade de cálculo disponível nos atuais microcomputadores e também aos anseios do número cada vez maior de médicos oftalmologistas que adquirem topógrafos de córnea sem prévia experiência. Neste sentido acreditamos que um *software* com tais características também sirva bem ao propósito de “tutor” para os iniciantes e uma “segunda opinião” no caso daqueles com maior experiência.

Podemos afirmar que a IA e as RN são teorias que se complementam no sentido de nos permitir construir modelos de nossas capacidades cognitivas. Apesar das teorias sobre IA existirem desde os anos 40, o sólido desenvolvimento teórico sobre RN deu-se principalmente após os anos 80. Estes modelos artificiais são testados com relação à eficiência na solução de problemas específicos. São construídas com o propósito de modelar nossas ca-

pacidades cognitivas, espelhando-se em dados colhidos da anatomia do cérebro biológico, de seus neurônios e suas conexões sinápticas. Para a construção de RN artificiais procura-se gerar redes artificiais que modelem a maneira como nossos neurônios biológicos realizam sinapses e como se organizam e se relacionam para que, dado uma série de informações ou “entradas”, haja uma ou mais respostas de “saída”, ou seja, a *tomada de decisão*.

Toda esta tecnologia da IA e RN, até recentemente, estava disponível apenas na teoria, pela dificuldade de se construir *hardware/software* a preços acessíveis para aplicações em áreas do dia-a-dia. Devido a esse fato as aplicações até então foram em projetos bem específicos (muitas vezes de uso industrial ou militar) e exigiam altos investimentos. Com a popularização e alto desempenho da capacidade computacional na segunda metade dos anos 90, iniciou-se um processo crescente de aplicações de algoritmos e hardware construídos usando a teoria da IA e as RN para solução de problemas ou no auxílio à tomada de decisões em aplicações onde antes seria inimaginável tal nível de sofisticação. Esta tecnologia tornou-se mais acessível somente recentemente, pelo alto desempenho necessário dos sistemas computacionais e pelo sólido desenvolvimento teórico que se deu na teoria de RN principalmente após os anos 80 com o trabalho pioneiro de Hopfield [Hopfield et al, 1982]. Neste sentido, temos hoje a possibilidade de levar a tecnologia da IA e RN ao diagnóstico em topografias de córnea, agregando-a a todas tecnologias para ceratoscopia, ceratografia, fotoceratoscopia e finalmente video-ceratografia fazem parte da evolução dos topógrafos de córnea e que vêm se aprimorando ao longo de mais de um século, desde as primeiras experiências de Plácido em 1880 [Plácido, 1880].

Foi deste desafio que surgiu o atual projeto, com interação entre o Departamento de Oftalmologia da Escola Paulista de Medicina - UNIFESP, o Grupo de Óptica do Instituto de Física de São Carlos-USP e a empresa Eyetec Equipamentos Oftálmicos, no sentido de desenvolver algoritmos integralmente nacionais para o auxílio ao diagnóstico em topografias de córnea realizadas no aparelho comercial *Eyetec CT2000*.

Na seção (2.0) deste manuscrito introduzimos conceitos básicos sobre modelamento de neurônios e na seção (3.0) falamos sobre as RN e suas diferentes arquiteturas. Na seção (4.0) expomos os materiais e métodos utilizados para desenvolvimento do software para diagnóstico e na seção (5.0) mostramos os resultados obtidos e análises estatísticas da eficiência de nossa RN. Finalmente, na seção (6.0) fazemos uma discussão dos principais aspectos do trabalho e sugestões para pesquisas futuras.

2 Modelando os Neurônios

O neurônio é uma unidade de processamento de informação fundamental para o funcionamento de uma RN. O diagrama

²Patologia na superfície da córnea que confere a esta altas curvaturas localizadas.

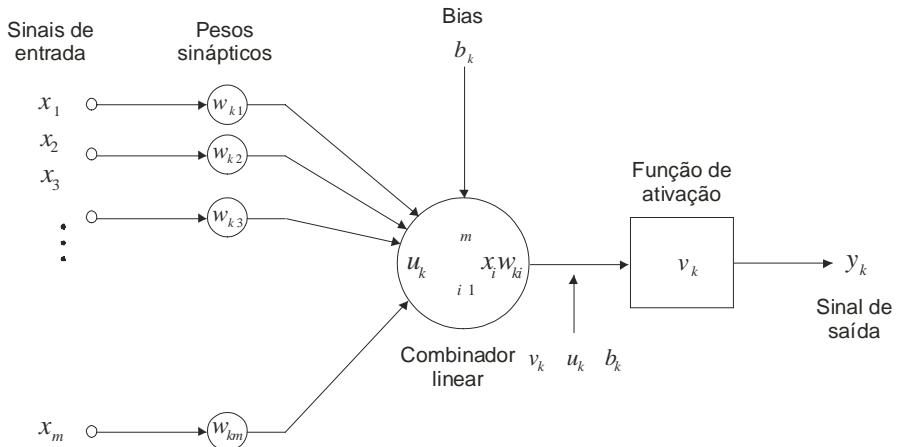


Figura 1. Modelo não-linear de um neurônio.

em blocos da Figura 1 mostra o modelo de um neurônio, que forma forma a base para um projeto de RN. Podemos aqui identificar três elementos básicos do modelo neuronal:

Um conjunto de sinapses caracterizadas por pesos próprios. Mais especificamente, um sinal x_j é inserido pela sinapse j conectada ao neurônio k . Este sinal é multiplicado por um peso, w_{kj} , que é específico daquela sinapse e daquele neurônio. Ao contrário de uma sinapse no cérebro, os pesos para um neurônio artificial podem assumir valores positivos, negativos ou nulo.

Um somador responsável pela adição dos sinais de entrada ponderados pelos respectivos pesos de cada sinapse. Este somador caracteriza um *combinador linear*.

Uma função de ativação, φ , para restringir a amplitude de saída de um neurônio. Mais adiante veremos exemplos desta função.

Também incluído no modelo mostrado na Figura 1 está um “bias” aplicado externamente, representado por b_k . O bias tem simplesmente a função de aumentar ou diminuir a entrada líquida da função de ativação. Formalizando o modelo descrito pela Figura 1 e pelos itens (1) –(3) anteriores, podemos escrever a saída do combinador linear como:

$$u_k = \sum_{j=1}^m x_j w_{kj} \quad (1)$$

e a saída final do neurônio como

$$y_k = \varphi(u_k + b_k) \quad (2)$$

onde $v_k = u_k + b_k$ é o *campo local induzido*. Dependendo dos valores assumidos pelo bias (zero, negativo ou positivo) o campo local induzido pode variar linearmente com a saída do combinador linear, mas cruzando o eixo das abscissas em diferentes pontos.

3 Arquiteturas de Redes Neurais

A maneira pela qual os neurônios de uma RN estão estruturados está intimamente relacionado ao algoritmo de aprendizagem usado para treinar a rede. Mais adiante vamos explicar como nossa rede neural para classificação de toplografias de córnea foi treinada e nesta seção falaremos de diferentes tipos de estruturas (ou arquiteturas) de RN utilizadas em IA.

Em geral podemos identificar três classes de arquiteturas de rede fundamentalmente diferentes:

(1) Redes Alimentadas Adiante com Camada Única

Na forma mais simples de uma RN organizada em camadas temos uma *camada de entrada* e uma *camada de saída* (veja Figura 3), mas não há sinais de retorno ou de re-alimentação, por esse motivo esta rede é também classificada como *alimentada adiante*.

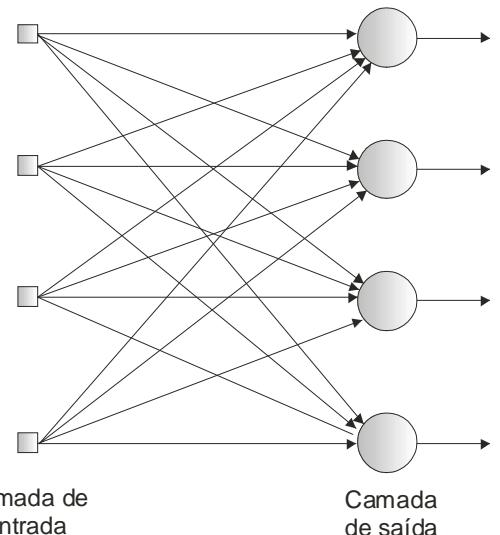


Figura 3. Rede alimentada adiante com uma única camada de neurônios. A camada de entrada (também denominada de *nós de fonte*) não é considerada como uma das camadas da rede por não realizar cálculos.

Na Figura 3 podemos ver um exemplo de uma rede de deste tipo com apenas quatro nós tanto na camada de entrada como na de saída. Esta rede é chamada *rede de camada única*, sendo que o termo “camada única” se refere à camada de saída dos nós computacionais. Não contamos a camada de entrada de nós de fonte, porque lá não é realizada qualquer computação.

(2) Redes Alimentadas Diretamente com Múltiplas Camadas

A segunda classe de redes alimentadas adiante se distingue pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados de *neurônios ocultos*. A função destas camadas de neurônios ocultos é intervir entre o sinal de entrada externo e a saída da rede de maneira a favorecer sua eficiência. De maneira bastante generalizada, podemos afirmar que as camadas ocultas conferem à RN uma perspectiva mais *global*, apesar de suas conexões locais, devido ao conjunto extra de conexões sinápticas e da dimensão extra de interações neurais. A habilidade dos neurônios de camadas ocultas extraírem estatísticas de ordem elevada possibilita que a rede seja treinada para resolver problemas mais sofisticados. De maneira bastante simplificada e resumida, podemos afirmar que o objetivo principal da arquitetura e dos pesos sinápticos é transformar a RN em um classificador de alto nível. Este classificador é regido por regras estatísticas sofisticadas e transparentes ao usuário. O treinamento, então, da RN pode ser entendido como o aprimoramento das relações e interconexões dos neurônios para que estes gerem resultados estatísticos os mais eficientes possíveis.

O grafo arquitetural da Figura 4 ilustra a planta de uma RN de múltiplas camadas alimentada adiante para o caso de uma única camada oculta.

Como outro exemplo podemos citar uma rede com m nós de fonte de entrada, h_1 neurônios na primeira camada oculta, h_2 neurônios na segunda camada oculta, e q neurônios na camada de saída (dita uma rede $m - h_1 - h_2 - q$). A rede mostrada na Figura 4 é dita *totalmente conectada*, no sentido de que cada um dos nós de uma camada está conectado aos nós da camada adjacente, entretanto se algumas das conexões sinápticas estiverem faltando, dizemos que a rede é *parcialmente conectada*.

Além destes dois tipos de RN mostrados aqui existem vários outros, com as mais variadas formas de alimentação, camadas ocultas e de saída, retro-alimentação e sistemas de atraso (para redes que levam em conta a informação do tempo decorrido). Como não é do escopo do atual trabalho uma explanação completa e detalhada dos vários tipos de RN existentes, sugerimos ao leitor o trabalho de Haykin [Haykin, 2001], que contém vários exemplos de arquiteturas de RN. A seguir descrevemos a parte prática deste projeto, onde iremos mostrar qual o tipo de arquitetura de RN utilizado, como esta rede foi treinada e, mais adiante na seção (5), apresentamos os casos analisados e os resultados de nossa RN.

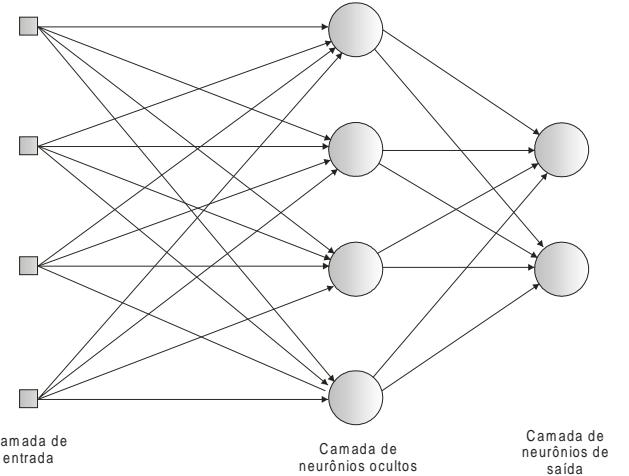


Figura 4. Rede alimentada adiante com uma única camada oculta. Como veremos na seção (4.2) foi este tipo de rede que utilizamos para construir nosso classificador de córneas.

4 Material e Métodos

4.1 4.1 Representação da Córnea como uma somatória de Polinômios de Zernike

Em sistemas que utilizam Discos de Plácido para aferir a topografia e/ou curvatura (proporcional ao poder dióptrico) da córnea, normalmente os arquivos que armazenam os dados do exame contém dados proporcionais ao número de anéis nos discos de Plácido. Em nosso caso utilizamos um topógrafo de Córnea Eyetec CT2000 com software versão 3.1. Para este modelo temos 16 anéis (bordas) para 360 ângulos polares no plano da imagem de Plácido, caracterizando 5760 pontos. Sabemos de antemão que seria uma árdua tarefa construir uma RN que permitisse a entrada de tantos dados, e também sabíamos que normalmente a geração de outros índices é complicada, principalmente pela má documentação de seus inventores [Klein et al, 1996; Smolek et al, 1997; Maeda et al, 1998] e também pelo fato de serem de propriedade de empresas fabricantes de outros sistemas topográficos. Por estes motivos resolvemos propor um método inovador para facilitar a entrada de dados em nossa RN. Este método constitui-se da aproximação de todos os 5760 dados da elevação da córnea por Polinômios de Zernike [Born & Wolf, 1975] (veja Tabela 1 e Figura 5). Embora comumente usados para descrever aberrações de frentes-de-onda estes polinômios são perfeitamente suscetíveis para aplicações em topografia de córnea [Guirao & Artal, 2000]. Apesar dos cálculos matemáticos não serem simples, a aplicação deste método nos permite reduzir significativamente o número de neurônios da camada de entrada de nossa RN, simplificando, portanto, sua implementação.

Tabela 1. Primeiros 15 Polinômios de Zernike. Repare que cada termo está associado a um tipo de aberração. Estes dados valem no caso da descrição de aberrações ópticas. No caso da elevação propriamente dita da córnea passam a ter associação direta somente com a forma da superfície.

Termo	Representação em coordenadas polares	Representação em coordenadas cartesianas	Significado
$Z_0 (x, y)$	1	1	Termo constante
$Z_1 (x, y)$	$\rho \operatorname{sen} \theta$	x	Inclinação na direção x
$Z_2 (x, y)$	$\rho \cos \theta$	y	Inclinação na direção y
$Z_3 (x, y)$	$\rho^2 \operatorname{sen} (2\theta)$	$2xy$	Astigmatismo com eixo a $\pm 45^0$
$Z_4 (x, y)$	$2\rho^2 - 1$	$-1 + 2y^2 + 2x^2$	Aberração focal (miopia ou hipermetropia)
$Z_5 (x, y)$	$\rho^2 \cos (2\theta)$	$y^2 - x^2$	Astigmatismo com eixo a $\pm 90^0$
$Z_6 (x, y)$	$\rho^3 \operatorname{sen} (3\theta)$	$3xy^2 - x^3$	
$Z_7 (x, y)$	$(3\rho^3 - 2\rho) \operatorname{sen} \theta$	$-2x + 3xy^2 + 3x^3$	Coma de 3 ^a ordem no eixo x
$Z_8 (x, y)$	$(3\rho^3 - 2\rho) \cos \theta$	$-2y + 3y^3 + 3x^2y$	Coma de 3 ^a ordem no eixo y
$Z_9 (x, y)$	$\rho^3 \cos (3\theta)$	$y^3 - 3x^2y$	
$Z_{10} (x, y)$	$\rho^4 \operatorname{sen} (4\theta)$	$4y^3x - 4x^3y$	
$Z_{11} (x, y)$	$(4\rho^4 - 3\rho^2) \operatorname{sen} (2\theta)$	$-6xy + 8y^3x + 8x^3y$	
$Z_{12} (x, y)$	$6\rho^4 - 6\rho^2 + 1$	$1 - 6y^2 - 6x^2 + 6y^4 + 12x^2y^2 - 6x^4$	Aberração esférica de 3 ^a ordem
$Z_{13} (x, y)$	$(4\rho^4 - 3\rho^2) \cos (2\theta)$	$-3y^2 + 3x^2 + 4y^4 - 4x^2y^2 - 4x^4$	
$Z_{14} (x, y)$	$\rho^4 \cos (4\theta)$	$y^4 - 6x^2y^2 + x^4$	

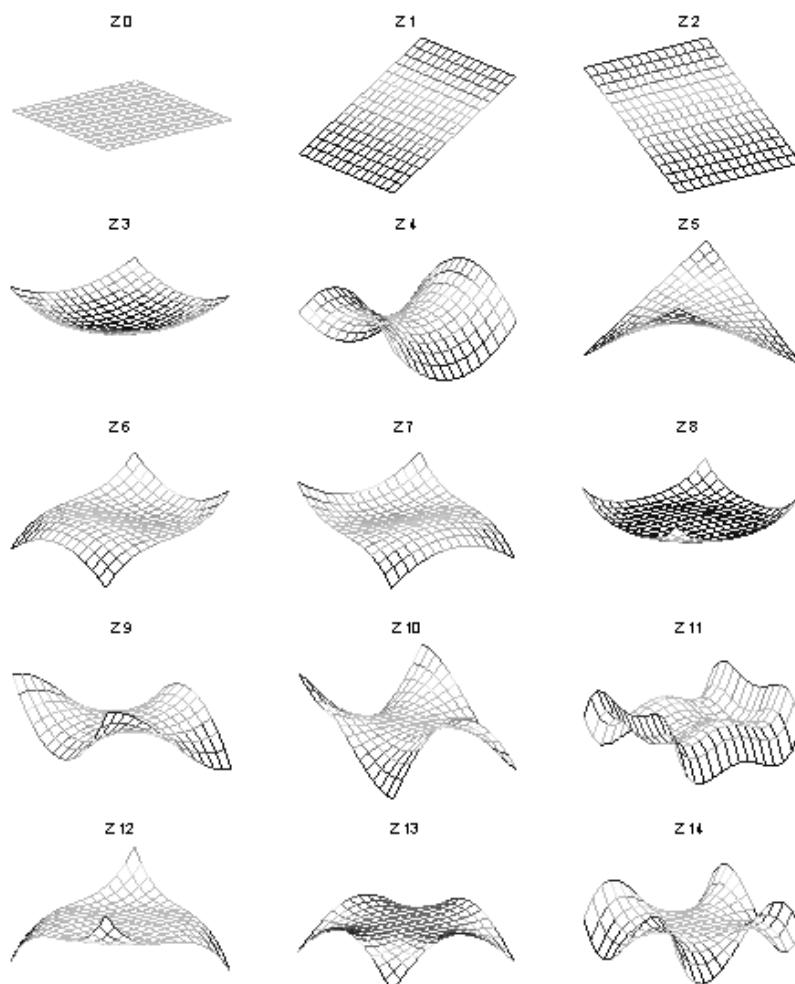


Figura 5. Representação gráfica tridimensional dos primeiros 15 polinômios de Zernike. Estes polinômios são largamente utilizados para descrever superfícies de lentes em estudos e projetos em óptica e também podem ser utilizados para descrever nossa superfície óptica do olho, que é a córnea. O somatório destes polinômios com diferentes pesos para cada um pode aproximar a forma da superfície da córnea com alta precisão [Guirao & Artal, 2000].

Para representar cada córnea como uma somatória de Polinômios de Zernike fizemos uma aproximação dos dados de elevação do topógrafo $h(\rho, \theta)$ e passamos a representá-la como uma somatória destes polinômios. Usando um sistema de coordenadas cilíndrico, representamos a elevação pela letra h as coordenadas da borda de um certo ponto sobre um dos Discos de Plácido pelo par ordenado ρ, θ , como mostrado no esquema da Figura 6.

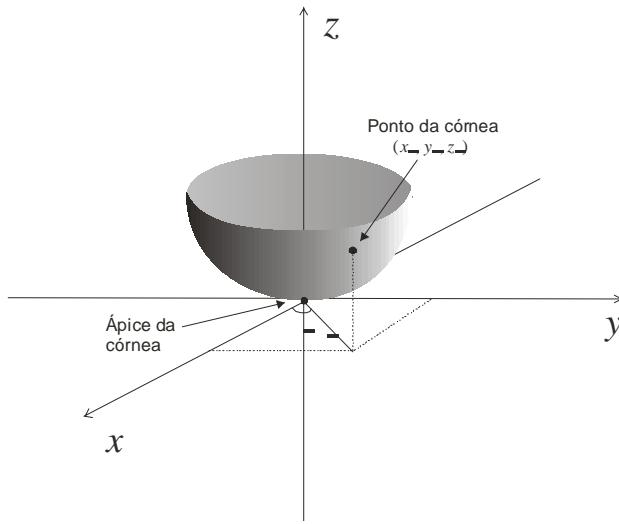


Figure 6. Sistema de coordenadas cilíndricas para representação da córnea como uma somatória de Polinômios de Zernike.

Desta maneira a superfície da córnea pode ser representada pela somatória:

$$h(\rho, \theta) = \sum_{i=0}^{14} C_i Z_i(\rho, \theta) \quad (3)$$

Para encontrar os coeficientes C_i utilizamos o *Método dos Mínimos Quadrados* [Press et al, 1989]. Para tal minimizamos o termo:

$$S = \left[h(\rho, \theta) - \sum_{i=0}^{14} C_i Z_i(\rho, \theta) \right]^2 \quad (4)$$

onde o termo à esquerda dentro do colchete representa a elevação da córnea obtida através do VC e o termo à direita representa a somatória de cada Polinômio de Zernike (Z_i) multiplicado por seu respectivo coeficiente (C_i). Como pode ser visto estamos utilizando os 15 primeiros termos de Zernike, embora estes polinômios possam ser gerados até a ordem que se desejar [Born & Wolf, 1975]. A utilização dos primeiros 15 termos não é uma imposição nossa, é apenas o número comumente sugerido na literatura para aproximações de dados referentes às aberrações do olho e que podem também ser perfeitamente utilizadas para descrever a topografia da córnea [Schwigerling, 1995].

Para minimizar o termo S da equação (4) aplicamos a primeira derivada com relação a todos os coeficientes e igualamos a zero (ponto de mínimo):

$$\frac{dS}{dC_i} = 0 \quad (5)$$

Quando fazemos isso montamos um sistema linear de equações que pode ser descrito por

$$A \cdot C = B \quad (6)$$

onde A é a matriz dos termos de Zernike calculados nos pontos (ρ, θ) considerados, B é a matriz dos dados de elevação obtidos pela topografia da córnea e C é o vetor que contém os coeficientes de Zernike desejados. Aplicando-se um simples método de inversão de matrizes, como o método de Gauss [Press et al, 1989] por exemplo, chegamos aos valores destes coeficientes para cada córnea considerada. A partir deste ponto os dados da córnea estão prontos para alimentar os neurônios da camada de entrada de nossa RN. A seguir mostramos a estrutura de nossa RN e como os coeficientes de Zernike são utilizados para alimentar esta rede.

4.2 Construção de uma Rede Neural para análise de Videoceratografias

O diagrama da RN utilizada neste trabalho pode ser visto na Figura 7:

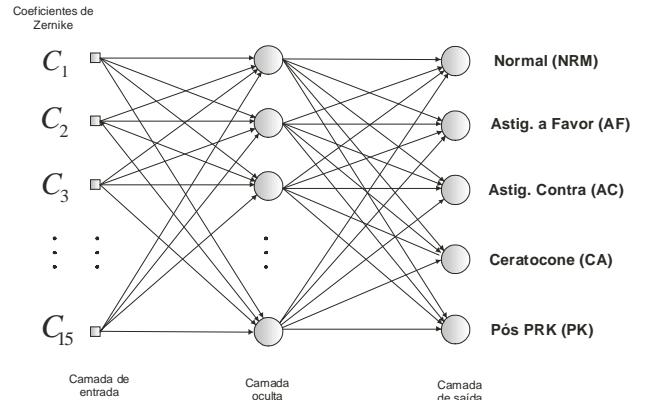


Figura 7. RN utilizada para reconhecimento e classificação de topografias de córnea.

Como podemos perceber pela Figura 7 e os tópicos abordados na seção (3), esta estrutura trata-se de uma RN do tipo alimentada adiante com uma única camada oculta. A camada de entrada é utilizada para inserir os dados relativos à topografia da córnea (que são 15 coeficientes $C_1, C_2, C_3, \dots, C_{15}$ de Zernike); para a camada intermediária (oculta), depois de várias testes para otimização de aprendizado, determinamos um número de 10 neurônios e a camada de saída contém 5 neurônios, cada um representando uma das dez classificações possíveis para o diagnóstico (o objetivo é, num futuro próximo, aumentar consideravelmente este número de saídas, para que a RN possa classificar o maior número possível de córneas). Obviamente que há muito mais possibilidades de classificação, mas como este número deve ser fixo para que possamos construir nossa estrutura de RN resolvemos escolher os 3 casos mais representativos em nossa base de dados (veja Tabela 2). A seguir mostramos como estes dados foram adquiridos e depois usados para treinar e testar a nossa RN.

4.3 Aquisição dos dados

Foi utilizado um total de 80 córneas de nossa base de dados (todos colhidos no Topógrafo Eyetec CT2000, software versão 3.1), sendo 50% destinados para treinar a rede e outros 50% para testar a eficiência da rede. Todas as 80 topografias foram classificadas pelos especialistas em 5 diferentes categorias (veja Tabela 2). A escolha destas 5 categorias foi baseada no fato de que elas respondem por 90% de todos os casos de deformações na córnea humana [Kanski, 1994].

Apenas para fins ilustrativos, na Figura 8 mostramos alguns exemplos de cada um dos casos mostrados na Tabela 2 e também um caso para ilustrar uma das dificuldades de

diagnóstico.

Tabela 2. Topografias usadas para treinar a RN. Para não privilegiar nenhuma das 5 classificações previamente definidas procuramos estruturar uma base de dados com números de casos parecidos para cada uma das classificações.

Número de casos	Classificação
16	Normal (NRM)
16	Astigmatismo a favor da regra (AF)
16	Astigmatismo contra a regra (AC)
16	Ceratocone avançado (CA)
16	Pós PRK (PK)

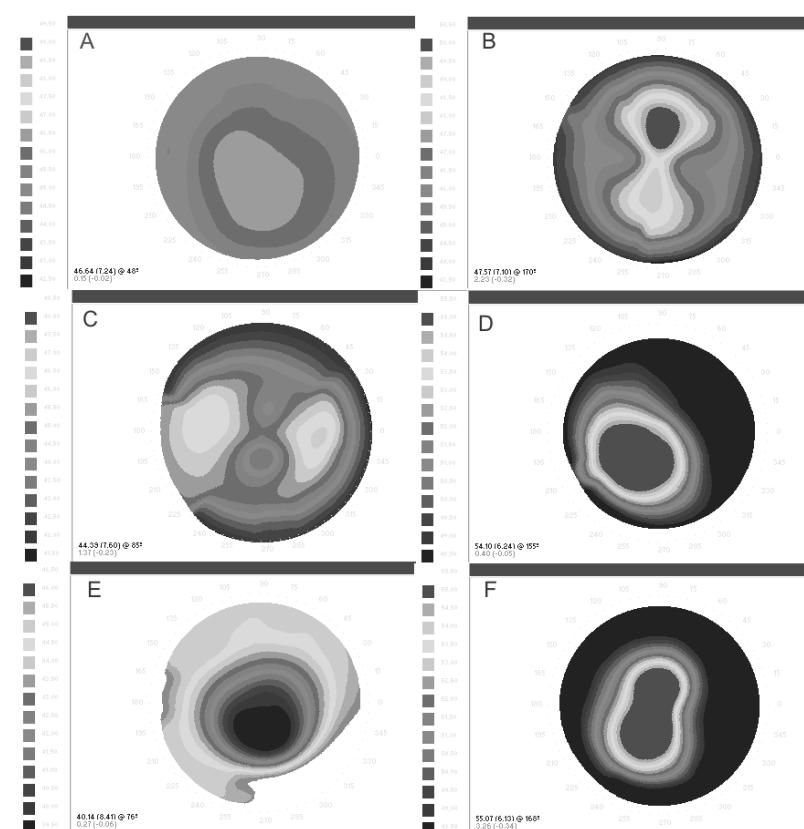


Figura 8. Exemplos de mapas topográficos para os 5 tipos de córneas usadas na classificação. (A) Córnea normal: poucos níveis de cor; (B) Astigmatismo a favor da regra: maior curvatura no eixo vertical e aparência típica de ampulheta “em pé”; (C) Astigmatismo contra a regra: mesmo que em (B) mas para eixo horizontal, ou seja, forma de ampulheta “deitada”; (D) Ceratocone avançado: caso típico geralmente manifesta-se como uma região ovulada com altos graus de curvatura cercado de uma região mais plana; (E) Córnea pós-PRK: a cirurgia refrativa denominada ‘Photorefractive Keratectomy’ (PRK) tem como objetivo a correção de ametropias como miopia, hipermetropia e astigmatismo. Para o caso de miopia há um aplaínamento na região central da córnea, deixando-a menos curva; (F) Ceratocone “disfarçado”: embora seja um ceratocone até mais intenso que o caso mostrado em (D), pode ser facilmente confundido com um intenso astigmatismo a favor da regra.

Como podemos perceber pela Figura 8, os padrões de cores (no instrumento original as imagens são coloridas) variam bastante de caso para caso, mas não é uma ciência exata determinar qual mapa se enquadra em qual classificação. Os mapas de (A) a (E) são casos clássicos e bastante simples de identificar, mas nem sempre aparecem

de maneira tão clara para o médico. No consultório podem ocorrer casos como aquele ilustrado no mapa (F). O médico inexperiente pode achar, a princípio, que se trata de uma córnea com alto astigmatismo a favor da regra. Mas se olhar os valores e as diferenças de curvatura sobre a região mais central e comparar com a região periférica, irá perce-

ber que, na realidade, trata-se de uma córnea com ceratocone avançado, apenas com aparência e forma de astigmatismo a favor da regra. São casos típicos como este que podem levar o cirurgião a decidir por intervenção em casos cujo melhor procedimento seria, por exemplo, o uso de lentes de contato rígidas.

Cada um dos dados topográficos das córneas mostradas na Tabela 2 foi transformado num vetor com 15 valores de coeficientes de Zernike, conforme o procedimento descrito na seção (4.1). Estes vetores foram então alimentados, um a um, em nossa RN e os diferentes pesos sinápticos W_k entre cada neurônio foram ajustados de maneira iterativa até que a resposta correta fosse encontrada. Aqui o termo *resposta correta* significa que um valor normalizado

(entre 0 e 1) deve aparecer no neurônio de saída que represente o correto diagnóstico fornecido pelos especialistas que classificaram previamente aquela córnea. Quando isso ocorre todos os outros neurônios da camada de saída têm que ter resposta negativa, o que significa um valor normalizado menor que 0.5. O mesmo procedimento foi realizado aleatoriamente para todos os outros olhos do conjunto de treinamento. Quando a RN atingisse este estado de saída desejado para todos as córneas de treinamento os valores dos pesos sinápticos (W_{kj}) eram armazenados numa matriz na memória do computador. Na Tabela 3 mostramos os resultados da RN para o conjunto de treinamento após 300 mil iterações para ajustes dos pesos sinápticos.

Tabela 3. Resultados de nossa RN para os 40 casos-teste. 100% de aproveitamento nos indicou que a arquitetura da RN utilizada poderia ser correta para o problema de classificação de mapas topográficos.

Classificação	Classificação da Rede Neural				
	NRM	AF	AC	AI	PK
NRM	8	0	0	0	0
AF	0	8	0	0	0
AC	0	0	8	0	0
AI	0	0	0	8	0
PK	0	0	0	0	8

Como podemos perceber nossa RN obteve 100% de aproveitamento na fase de treinamento. Isso nos mostrou que o número de camadas, número de neurônios da camada intermediária (oculta) e arquitetura de nossa RN poderiam ser eficazes para o tipo de classificação desejado. Após a etapa de treinamento passamos a utilizar os outros 50% das córneas para testar a eficiência da RN com a mesma matriz de pesos sinápticos determinados na etapa de treinamento. Desta vez a RN recebeu apenas o vetor de coeficientes de Zernike, sendo que a resposta dos neurônios de saída passou a ser a incógnita do algoritmo, ou seja, desta vez a RN deveria fornecer como resposta o diagnóstico para aquela córnea em questão. Este mesmo procedimento foi realizado para cada córnea e o diagnóstico da RN para as 40 córneas-teste foi obtido. Apresentamos estes resultados a seguir.

5 Resultados

Como observado na seção anterior, primeiramente utilizamos nossa amostragem de treinamento para ajustar os

pesos sinápticos da RN e depois disso utilizamos as outras córneas para testar nossa RN.

A eficiência da RN foi analisada para estas córneas sem incluir nenhum dos mapas usados para treinamento. Neste ponto do estudo um sinal de saída acima do valor limiar de 0.5 foi definido como uma resposta positiva para a categoria correspondente, e uma resposta menor que 0.5 foi definida como resposta negativa para aquela classificação. Se mais de um neurônio de resposta estivesse com valor acima de 0.5, aquele que contivesse o maior valor seria considerado como a resposta da RN. Quando nenhuma das saídas tivesse valor maior que 0.5 consideramos que a RN não tinha classificação definitiva para aquela córnea.

Analisamos os resultados da Tabela 3 para cada categoria de classificação em termos de *sensibilidade* (verdadeiro positivo/[verdadeiro positivo+falso negativo]), *especificidade* (verdadeiro negativo/[verdadeiro negativo+falso positivo]), e *precisão* ([verdadeiro positivo+verdadeiro negativo]/total de casos). Na Tabela 4 mostramos os resultados para estes três índices para todos os casos-teste para cada tipo de classificação.

Tabela 4. Resultados para 40 córneas-teste, ou seja, córneas que não foram apresentadas à RN durante o processo de treinamento (ajuste dos pesos sinápticos e dos valores de “bias”).

Classificação	Sensibilidade (%)	Especificidade (%)	Precisão (%)
NRM	56,25	95,31	87,50
AF	56,25	98,44	90,00
AC	87,50	96,88	95,00
CA	93,75	98,44	97,50
PK	100,00	100,00	100,00
Média	78,75	97,81	94,00

6 Discussão

Interpretação automatizada de padrões topográficos pode ser uma importante ferramenta para o oftalmologista, principalmente para aqueles que têm pouca ou nenhuma experiência no diagnóstico destes exames. Até onde sabemos, não há outros casos de utilização de Polinômios de Zernike em conjunto com técnicas de RN, ou técnicas que utilizam dados estatísticos, para auxílio ao diagnóstico de exames da córnea. Com o auxílio de um software como aquele sugerido aqui, o médico poderia, com o acúmulo de casos diferentes, adquirir maior experiência em menor tempo; e para aqueles usuários mais experientes, a interpretação da máquina seria útil como uma “segunda opinião”. Outros aspectos inevitáveis relacionados à interpretação humana, como fator emocional, concentração, memória, etc, não estão presentes no sistema artificial, tornando-se menos subjetivo.

Apesar do diagnóstico automatizado poder ser realizado utilizando-se outras metodologias, como análise variacional ou a filosofia *top-down* da inteligência artificial (expert system), o uso de RN oferece vantagens com relação a estes métodos mais convencionais. A RN oferece extrema habilidade na detecção de características “escondidas” nos dados de entrada e que não são explicitamente formuladas como entradas. Nenhum dos outros métodos citados são capazes de utilizar e relacionar informações “escondidas” nas entradas. Além disso, a RN se baseia apenas nas informações de entrada, sendo que nenhuma informação extra é necessária a respeito de regras, inter-relação das partes que compõem o problema ou outras estruturas lógicas. Por outro lado, um sistema “top-down” necessita de várias informações prévias contendo uma lista extensa de regras para tomada de decisões e uma estrutura de algoritmo sequencial (como um programa de computador).

Para projetar uma RN eficiente, um dos passos críticos é a escolha de como os dados de entrada serão fornecidos. Este aliás é um dos aspectos cruciais deste trabalho, pois ao tempo que outros autores escolhem sistemas complicados com índices muitas vezes confusos e mal documentados na literatura, aqui foi escolhido um método simples (apenas 15 termos) mas extremamente poderoso e elegante do ponto de vista matemático e computacional. Como pode ser visto nos trabalhos de [Guirao & Artal, 2000] e [Schwiegerling, 1995] descrevem a córnea com precisão média de $0.5\mu\text{m}$.

Como mostrado na seção (5.0), nossa RN foi treinada usando 40 córneas com 5 diferentes classificações clínicas. A mesma RN, depois de treinada (ou seja, depois de ter seus pesos sinápticos ajustados), foi testada no diagnóstico de outros 40 casos, tendo precisão média de 94% na interpretação para todos os casos. Este resultado é satisfatório neste ponto de nossas pesquisas, dado que outras estruturas de RN devem ser testadas e outras otimizações são provavelmente úteis nas próximas etapas. RN utilizadas em outros campos da medicina, como diagnóstico de câncer [Aston & Wilding, 1992] e interpretação de campos visuais [Lin et al, 2003] têm mostrado eficiência semelhante àquelas conseguidas neste trabalho. Erros inaceitáveis,

como interpretação como ceratcone avançado uma córnea normal, não ocorreram.

Algumas melhorias na atual RN são possíveis. A dependência dos pesos sinápticos com o número de iterações para treinamento da RN sugere que o aumento de nossa base de dados para treino deve aumentar a eficiência da RN. Apesar destes aspectos que ainda podem ser aprimorados os resultados preliminares obtidos neste trabalho indicam que a utilização de RN para interpretação de mapas topográficos da córnea, em conjunto com a representação destes mapas por Polinômios de Zernike, merece continuidade e avanço nas pesquisas. Este tipo de sistema oferece vantagens significativas e pode num futuro breve estar disponível como parte integrante dos softwares para topografias de córnea no sentido de se diagnosticar precisamente anomalias em sua forma e poderes refrativos.

Agradecimentos

Gostaríamos de agradecer aos Drs. Wallace Chamon e Paulo Schor da Escola Paulista de Medicina – UNIFESP pela análise dos mapas topográficos utilizados para treinar a rede neural. Gostaríamos também de agradecer a equipe de software da Eyetec Equipamentos Oftálmicos pelo auxílio no módulo de visualização e escolha das córneas para teste e treinamento.

Referências

- [1] Aston ML, Wilding P, Application of neural networks to the interpretation of laboratory data in cancer diagnosis, *Clin Chem*, 1992; 38:34-38.
- [2] Born M, Wolf E, *Principles of Optics*, Pergamon Press, 1975: 464-466.
- [3] Carvalho LA, Sidney Julho de Faria e Souza, Castro, J. C., Desenvolvimento de um Ceratômetro Intracirúrgico, XVIII Encontro Nacional de Física da Matéria Condensada, 1995, p. 140.
- [4] Carvalho LA, Souza SJF, Castro JC, Desenvolvimento de um sistema para medida da curvatura da córnea durante o ato cirúrgico, *RFAI*, 1996, 11:119-126.
- [5] Carvalho LA, Silva EP, Santos LER, Tonissi SA, Romão AC, Castro JC, Detecção de Bordas de Imagens Refletidas pela Superfície Anterior da Córnea, III Fórum Nacional de Ciência e Tecnologia em Saúde, Campos de Jordão-Outubro de 1996.
- [6] Carvalho LA, Souza SJF, Castro JC, Desenvolvimento de um Sistema para Medida da Esfericidade da Córnea Durante a Cirurgia, *Revista de Física & Instrumentação*, 1997; 12, n° 3: 81-90.
- [7] Carvalho LA & Tear Mixing Gruop da University of California at Berkeley, “A digital mage processing system for assessment of contact lens rotation and translation”, realizada no Hotel Hilton de São Francisco, Annual Meeting of Lens Manufacturers, 1998.
- [8] Carvalho LA, Tonissi AS, Romão AC, Santos LE, Yasuoka F, Oliveira AC, Schor P, Chamon W, Castro JC, Desenvolvimento de um Instrumento Computadorizado para Medida do

- Poder Refrativo da Córnea (Videoceratógrafo), Arq. Bras. Oftal. 61(3), Dezembro/1998.
- [9] Carvalho LA, 21º Simpósio Internacional Moacyr Álvaro (SIMASP), São Paulo, "Processamento Digital de Imagens do Videoceratoscópio", 12 a 14 de Fevereiro de 1998.
- [10] Carvalho LA; Tonissi SA, Castro JC, Preliminary tests and construction of a computerized quantitative surgical keratometer, J Cataract Refract Surg 1999; 25: 821-826.
- [11] Carvalho LA, Corzine JC, Miller KL, Carney T, Klein SA, Polse KA, A computer-based image processing system for assessment of contact lens translation and rotation, ARVO (The Association for Research in Vision and Ophthalmology), Annual Meeting, Fort Lauderdale, Florida -May 9-14, 1999.
- [12] Carvalho LA, Romão AC, Stefani M, Tonissi SA, Castro JC, Digital processing of images reflected from the lachrymal film of the anterior corneal surface, Revista Brasileira de Engenharia Biomédica, v. 17, n. 3, p. 113-123, set/dez 2001.
- [13] Carvalho LA, Romão AC, Tonissi S, Yasuoka F, Castro JC, Schor P, Chamon W, Videokeratograph (VKS) for monitoring corneal curvature during surgery, Arquivos Brasileiros de Oftalmologia (ABO), 65(1), Fevereiro/2002.
- [14] Carvalho LA, Stefani M, Romão AC, Carvalho LAV, Castro JC, Tonissi S, Schor P, Chamon W, Videokeratoscopes for dioptric power measurement during surgery, J Cataract Refract Surg 28:2006-2016, 2002.
- [15] Gonzales RC, Woods R. E., Digital Image Processing, Addison-Wesley, 1992.
- [16] Guirao A, Artal P, Corneal wave aberration from videokeratography: accuracy and limitations of the procedure, J Opt Soc Am A Opt Image Sci Vis. 2000 Jun;17(3):955-65.
- [17] Haykin S, Redes Neurais – Princípios e prática, 2ª edição, Bookman, Porto Alegre, 2001.
- [18] Hopfield JJ, Neural networks and physical systems with emergent collective computational abilities", Proceedings of the National Academy of Sciences, USA, vol. 79, 1982, pp. 2554-2558.
- [19] Kalin NS, Maeda N, Klyce SD, Hargrave S, Wilson SE, Automated topographic screening for keratoconus in refractive surgery candidates, CLAO J. 1996 Jul;22(3):164-7.
Kanski JJ, Clinical Ophthalmology, Third Edition, Butterworth-Heinemann International Editions, London, 1994.
- [20] Klyce SD, Smolek MK, Maeda N, Keratoconus detection with the KISA% method-another view, J Cataract Refract Surg 2000 Apr;26(4):472-4.
- [21] Lin A, Hoffman D, Gaasterland DE, Caprioli J, Neural networks to identify glaucomatous visual field progression, Am J Ophthalmol. 2003 Jan;135(1):49-54.
- [22] McCulloch WS, Pitts W, A logical calculus of the ideas eminent in nervous activity, Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133.
- [23] Maeda N, Klyce SD, Tano Y, Detection and classification of mild irregular astigmatism in patients with good visual acuity, Surv Ophthalmol. 1998 Jul-Aug;43(1):53-8.
- [24] Mandell RB, York MA, A new calibration system for photokeratoscopy, Am J Optom Arch Am Acad Optom 1969 Jun;46(3):410-7.
- [25] Mead CA, Analog VLSI and Neural Systems, Reading, MA: Addison-Wesley, 1989.
- [26] Philippe J. Chastang, MD, Vincent M. Borderie, MD, Santos Carvajal-Gonzalez, PhD, William Rostène, PhD, Laurent Laroche, MD, Automated keratoconus detection using the EyeSys videokeratoscope, J Cataract Refract Surg, v. 26, n. 05, May 2000, p. 675-683.
- [27] Placido, A., Novo Instrumento de Exploração da Cornea, Periódico d'Oftalmológica Practica, Lisboa, 1880;5:27-30.
- [28] Press WH, Flannery BP, Teukolsky SA, Vetterling WT, Numerical Receipes in Pascal – The Art of Scientific Computing, Cambridge University Press, New York, pp. 37, 1989.
- [29] Rabinowitz YS, Rasheed K., KISA% index: a quantitative videokeratography algorithm embodying minimal topographic criteria for diagnosing keratoconus. J Cataract Refract Surg. 1999 Oct;25(10):1327-35.
- [30] Rabinowitz YS, Rasheed K., KISA% index: a quantitative videokeratography algorithm embodying minimal topographic criteria for diagnosing keratoconus. J Cataract Refract Surg. 1999 Oct;25(10):1327-35.
- [31] Salmon, T.O., Horner, DG, Comparison of Elevation, Curvature, and Power Descriptors for Corneal Topographic Mapping, Optometry and Vision Science, 1995; 72: 800-808.
- [32] Schwiegerling J, Greivenkamp JE, Miller JM, Representation of videokeratoscopic height data with Zernike polynomials, J Opt Soc Am A, Vol. 12, No. 10, October 1995; 2105-2113.
- [33] Smolek MK, Klyce SD, Current keratoconus detection methods compared with a neural network approach. Invest Ophthalmol Vis Sci. 1997 Oct;38(11):2290-9.