

Universidade Federal de Minas Gerais - UFMG

Programa de Pós-Graduação em Engenharia Elétrica - PPGE

Dissertação de Mestrado

Diagnóstico de aberrações ópticas em um sistema óptico adaptativo

Mestrando: Antônio Isidório Ferreira Júnior
Co-orientadora: Carmen Déa Moraes Pataro
Orientador: Davies William de Lima Monteiro

1 de outubro de 2006

Agradecimentos

À Deus e aos meus pais, Maria e Antônio, pelo dom da vida e tudo que a ela se refere. E à minha irmã, Adriana, que muito me orgulha.

Ao professor Davies William pela confiança e todo apoio ao longo desta jornada.

Aos companheiros do OptMA^{lab} pela ajuda, em especial ao Fred e ao João Guilherme, que contribuíram diretamente na realização deste trabalho, e ao colega Henrique L. Santos pelo auxílio na montagem do primeiro *setup* óptico.

À FAPEMIG e à Dutch Technical Foundation (STW/Holanda) pelo apoio financeiro a esta pesquisa.

Ao Dr. Mikhail Loktev (OKO Technologies) pelo suporte ao software de reconhecimento de frentes de onda, e aos senhores Jaime Ono e Lauro T. Muramoto da Lynx Tecnologia Eletrônica pelo suporte ao código do driver da placa de aquisição de dados.

À Natália pelo carinho e amor dedicados.

Sumário

1	Introdução	9
2	Redes Neurais	12
2.1	Fundamentos	12
2.1.1	Aspectos Gerais	12
2.1.2	Neurônio Artificial	13
2.1.3	Topologia	13
2.1.4	Aprendizagem	14
2.2	Perceptron	16
2.3	Adaline	17
2.3.1	Descida do Gradiente	19
2.4	Multi-Layer-Perceptron	20
2.4.1	Adaptação dos pesos	21
3	Sistemas Ópticos Adaptativos	24
3.1	Introdução	24
3.1.1	Polinômios de Zernike	25
3.2	Sistema	28
3.2.1	Configuração do Sistema Óptico	29
3.2.2	Controle do Sistema	32
3.2.3	Processamento dos dados	34
3.3	Componentes	34
3.3.1	Espelho Adaptativo	34
3.3.2	Sensor de frentes de onda	38
4	Discussões e Resultados	45
4.1	Adaline versus MLP	45
4.2	Aquisição de dados	48
4.3	Adaline no Sistema Óptico	52
4.3.1	Algoritmo Adaline	53
4.4	Resultados	57

5	Conclusões e Trabalhos Futuros	69
A	Rotina em C	70
	Referências Bibliográficas	70

Lista de Figuras

2.1	Neurônio Artificial [1]	14
2.2	Topologia geral de uma rede	14
2.3	Exemplo de aprendizagem com Regressão Linear	15
2.4	Exemplo da separação do perceptron com Regressão Linear	16
2.5	Perceptron	17
2.6	Adaline	18
2.7	Função de erro mse para um peso w	19
3.1	Representação unidimensional da correção de uma frente de onda deformada. Ξ_{in} : frente de onda; Ξ_0 : frente de onda corrigida; S: perfil de um Espelho Adaptativo; Z: direção de propagação.	25
3.2	Sistema Óptico Adaptativo	28
3.3	Configuração das lentes	29
3.4	Diagrama de Funcionamento	33
3.5	Esquema de um Espelho Adaptativo	35
3.6	Espelho Adaptativo	36
3.7	<i>Lay-out</i> dos atuadores	37
3.8	Óculos eletrônico	38
3.9	Representação matricial do problema a ser resolvido pelo método de mínimos quadrados	40
3.10	Junções das Quadricélulas	42
3.11	Pixel passivo	42
3.12	Micro-fotografia de uma quadricélula	43
3.13	Esquema do chip	44
3.14	Fotografia do sensor	44
4.1	Esquemático da MLP	45
4.2	Topologia Adaline	47
4.3	Pinagem do sensor	49
4.4	Entradas analógicas (conector DB37 macho)	50

4.5	Saídas digitais (conector DB37 fêmea)	50
4.6	Diagrama da placa de interface	51
4.7	Adaline com modos na entrada	52
4.8	Fluxograma do algoritmo Adaline	53
4.9	Formação do <i>grid</i> de um polinômio de Zernike	54
4.10	Algoritmo Adaline com Zernike	55
4.11	Algoritmo Adaline com Modos do Espelho Adaptativo	56
4.12	Cáculo de D_{opt_rede}	58
4.13	$(rms = \sqrt{mse})$ em função do número de épocas	59
4.14	Forma da frente de onda da deformação analisada, que contém, principalmente, coma, astigmatismo, trefoil e deformação esférica. No canto superior à direita: interferograma da frente de onda.	60
4.15	Aberração residual	61
4.16	Aberração: coma; lente com distância focal=1000mm, descentralizada	62
4.17	Posição do feixe em relação a lente - primeira aberração	62
4.18	Pesos do Adaline após treinamento - primeira aberração	62
4.19	Aberração imposta pelo sistema	63
4.20	Aberração: coma; lente com distância focal=1000mm, centralizada	64
4.21	Posição do feixe em relação a lente - segunda aberração	64
4.22	Pesos do Adaline após treinamento - segunda aberração	65
4.23	Aberração: coma; lente com distância focal=750mm, centralizada	66
4.24	Pesos do Adaline após treinamento - terceira aberração	66
4.25	Sobreposição das tensões durante a multiplexação	68

Lista de Tabelas

3.1	Conversão do coeficiente i em n e m até $i = 8$	25
-----	---	----

Resumo

Este trabalho investiga o emprego do método neural Adaline para o diagnóstico de aberrações ópticas de baixa ordem, através de decomposição das mesmas em polinômios de Zernike e também o acoplamento de um sensor CMOS dedicado de frentes de onda a um espelho adaptativo micro-usinado em um sistema óptico adaptativo. O algoritmo não está vinculado a uma base matricial fixa, em contraste com métodos tradicionais, oferece excelente imunidade à propagação de erros de arredondamento e admite adaptabilidade na dimensão de sua entrada em tempo real para acelerar a base de cálculos.

Abstract

This work investigates the employment of the Adaline neural method for diagnosis of low-order optical aberrations decomposed over Zernike polynomials and also the coupling of a custom CMOS wavefront sensor to a micromachined adaptive mirror in an adaptive optical system. The algorithm does not rely on a fixed basis matrix -as opposed to traditional methods-, offers excellent immunity to the propagation of round-off errors and admits real-time input dimension adaptability to speed up computations.

Capítulo 1

Introdução

Um número crescente de sistemas ópticos requer detecção e correção de aberrações ópticas com precisão para que um ou mais parâmetros de qualidade sejam melhorados. Dependendo do sistema primário (telescópio, microscópio, transmissão de dados, compressão de pulsos, etc) o parâmetro desejado pode ser por exemplo nitidez, potência, largura de pulso, uniformidade do perfil de intensidade, etc, que pode ser conseguido através de um sistema secundário acoplado, denominado Sistema Óptico Adaptativo (SOA). Há um número crescente de aplicações na indústria, ciência e medicina carentes de um sistema adaptativo, como exemplificado a seguir:

- (i) controle de qualidade - deformações sutis em peças automotivas e componentes ópticos podem ser monitorados durante o processo de fabricação e validação;
- (ii) observação astronômica - distorções ópticas introduzidas pela atmosfera afetam a nitidez da observação de corpos celestes;
- (iii) microscopia confocal de varredura - incongruência entre os centros do feixe de amostragem e da lente de focalização comprometem a qualidade do foco em regiões periféricas da amostra investigada;
- (iv) visão humana - deformações na córnea e no cristalino do olho resultam em qualidade inferior de imagens formadas na retina e podem comprometer o exame do fundo do olho.

O estudo de sistemas ópticos adaptativos vem ao encontro dessas demandas. Para tanto este trabalho versa sobre a utilização de Redes Neurais Artificiais (RNA's) tanto como ferramenta de controle desses sistemas [2, 3], quanto como um método para diagnosticar aberrações ópticas quantitativamente a partir dos sinais de um sensor de frentes de onda. Em ambos os

Introdução

casos o método convencionalmente empregado é o de reconstrução de frentes de onda através de álgebra matricial para solução de mínimos quadrados, cujo desempenho é satisfatório em termos de precisão e velocidade de processamento, contanto que uma matriz base seja inversível, que a propagação de erros de arredondamento seja controlada e que os vetores de sinais do sensor e de coeficientes (incógnitas) sejam dimensionalmente compatíveis [4]. Propõe-se identificar um método neural que possa substituir o método de mínimos quadrados, e que apresente as seguintes características:

- (i) velocidade de processamento compatível com a frequência de operação esperada para sistemas ópticos capazes de lidar com alterações dinâmicas de distorções, a exemplo do olho humano que pode apresentar flutuações até próximo a 100Hz e turbulência atmosférica com variações na ordem de 1kHz;
- (ii) precisão na detecção e correção de aberrações entre $\lambda/4$ e $\lambda/50$, onde λ é o comprimento de onda do feixe de teste; componentes ópticos comuns (ex.: lentes para lupas, webcam) toleram um desvio padrão de até $\lambda/4$, com $\lambda \sim 550nm$ ao passo que lentes e espelhos para projeção litográficas podem requerer um precisão de $\lambda/1000$;
- (iii) adaptabilidade do número de entradas em tempo real para otimizar seja a velocidade de processamento, a precisão do sistema, ou a compatibilidade do sistema ao perfil da aberração; no caso de turbulência atmosférica, seja para observação astronômica ou para transmissão de dados sem fibra óptica, a complexidade da distorção varia de acordo com condições climáticas pontuais.
- (iv) maior imunidade à propagação de erros de arredondamento e independência de condicionamento matricial; o sistema de convergência do erro para um mínimo através de realimentação com o erro quadrático e permutação de dados pode favorecer o controle de uma sistema com uma base *quase* linearmente independente.

Foram abordados os métodos Multi-Layer Perceptron (MLP) e ADaptive LInear NEuron (Adaline), tendo o último método se mostrado mais adequado a suprir as características acima. O trabalho de avaliação do método neural dividiu-se em duas etapas: 1) diagnóstico de aberrações ópticas através da simulação numérica de aberrações conhecidas apresentadas à rede; 2) controle de um espelho deformável através dos sinais neuralmente processados de um sensor CMOS de frentes de onda customizado, constituindo um regime óptico em ciclo fechado, como se tornará evidente no capítulo correspondente.

Introdução

Essa pesquisa é multidisciplinar e requer excursões por domínios da óptica (física, geométrica e adaptativa), eletrônica (*drives* de controle, aquisição de dados, amplificação, sensor óptico integrado) e computação (algoritmos neurais, *drivers* de controle e comunicação). A adequação de cada um dos tópicos supra-citados para a aplicação em questão e sua interdependência representam uma interface única, cujos elementos serão apresentados nesta dissertação.

O trabalho envolve o estudo e a elaboração dos algoritmos neurais para diagnóstico e controle óptico, realização do sistema óptico adaptativo, construção de uma interface eletrônica entre o *chip* sensor e a placa de aquisição de dados e a elaboração de um *driver* para a aquisição de dados através de interface ethernet. Esses temas são apresentados do segundo ao quarto capítulo que abordam redes neurais, sistema óptico adaptativo e resultados, respectivamente. O quinto capítulo conclui a dissertação contrastando resultados obtidos com os desejados e indica possibilidades para trabalhos futuros.

Capítulo 2

Redes Neurais

"Uma rede neural é um processador distribuído de forma maciçamente paralela, sendo constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem;
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido". [1]

As Redes Neurais Artificiais (RNA's) têm se mostrado eficientes na resolução de problemas de difícil solução para a computação convencional. Ao contrário dos modelos computacionais comumente utilizados, em que um programa precisa ser escrito para resolver um dado problema, as RNA's aprendem a resolver problemas através da sua interação com o meio a que são expostas. Esta capacidade de aprendizado da dinâmica de um sistema apenas através do mapeamento de entrada e saída e a adaptabilidade em relação a mudanças do meio as tornam excelentes candidatas para utilização em Sistemas Ópticos Adaptativos (SOA's).

2.1 Fundamentos

2.1.1 Aspectos Gerais

As RNA's são sistemas paralelos distribuídos, compostos por unidades de processamento simples (nós) que calculam determinadas funções matemáticas (normalmente não-lineares). Essas unidades geralmente são conectadas por canais de comunicação que estão associados a determinado peso. As

unidades fazem operações apenas sobre seus dados locais, que são entradas recebidas por suas conexões. O comportamento "inteligente" de uma Rede Neural Artificial vem das interações entre as unidades de processamento da rede [5].

Uma RNA é dividida basicamente em arquitetura e algoritmo de aprendizagem. Ao contrário de um computador que é programado, a rede é treinada através de exemplos. O algoritmo de aprendizagem generaliza os dados presentes nos exemplos e memoriza o conhecimento dentro dos parâmetros adaptáveis da rede, os pesos. Desta forma, um sistema baseado em RNA tem dois graus de liberdade: a definição sobre o tipo de rede e o algoritmo para treinar a rede. Normalmente o tipo de processamento de um único neurônio é a combinação linear das entradas com os pesos, que posteriormente são submetidos a uma função de ativação. A natureza do problema a ser resolvido, em geral, define restrições em relação aos possíveis tipos de redes e algoritmos de aprendizagem.

2.1.2 Neurônio Artificial

A Figura 2.1 mostra o modelo de um neurônio artificial de McCulloch and Pitts [6]. O modelo procura simular o comportamento de um neurônio biológico. A informação fornecida por outros neurônios entra em M entradas x_m no neurônio processador, que realiza uma combinação linear entre elas (equação 2.1). A cada entrada está associado um peso w_{km} que reflete a sua importância. O resultado da combinação linear é v_k . Se esse valor ultrapassar um limiar θ , o neurônio dispara o valor 1 na saída, se não a saída fica passiva em $y_k = 0$. A comparação de v_k com o limiar θ é realizada pela função de Heaveside (função de escada) mostrada na equação 2.2. A saída y_k do neurônio artificial é definida na equação 2.3.

$$v_k = \sum_{m=1}^{M'} w_{km} x_m \quad (2.1)$$

$$\varphi(v_k) = \begin{cases} 1 & v_k \geq \theta \\ 0 & v_k < \theta \end{cases} \quad (2.2)$$

$$y_k = \varphi(v_k) \quad (2.3)$$

2.1.3 Topologia

O potencial e a flexibilidade do cálculo baseado em redes neurais vêm da criação de conjuntos de neurônios interligados entre si (Figura 2.2). Esse




Figura 2.1: Neurônio Artificial [1]

paralelismo de elementos com processamento local cria a inteligência global da rede. Neurônios que recebem a informação simultaneamente agrupam-se em camadas. Camadas que não estão ligadas às entradas e nem às saídas da rede chamam-se camadas escondidas. Exemplos para esse tipo de rede são o Multi-Layer-Perceptron (MLP) [7] e o MADALINE [8].




Figura 2.2: Topologia geral de uma rede

2.1.4 Aprendizagem

A tarefa de treinamento da rede é realizada por um método de aprendizagem. Para as configurações abordadas nas seções 2.2, 2.3 e 2.4 o método

utilizado é da aprendizagem supervisionada.

Na aprendizagem supervisionada cada exemplo de treinamento está acompanhado por um valor desejado. Isso significa que o conjunto de treinamento T é composto por M pares de exemplos (x_m, y_{dm}) .

Um exemplo de uma tarefa de aprendizagem supervisionada é a regressão linear (Figura 2.3). O conjunto de treinamento consiste em pares de números reais (x_m, y_m) . O objetivo da aprendizagem é a determinação dos coeficientes w_0 e w_1 da reta $\mathbf{y} = w_0 + w_1\mathbf{x}$. O algoritmo de aprendizagem procura minimizar, em média para cada par (x_m, y_m) , a diferença entre o valor desejado y_{dm} e o valor que é a resposta do sistema $y_m = w_0 + w_1x_m$.

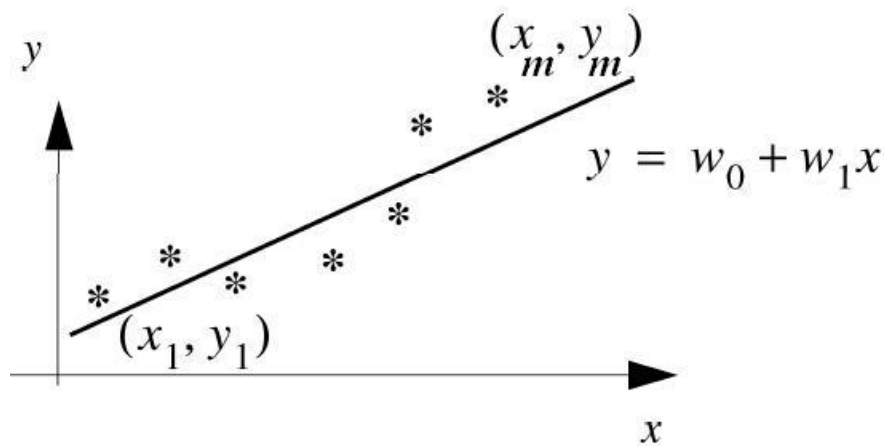


Figura 2.3: Exemplo de aprendizagem com Regressão Linear

Adaptação dos Pesos

Durante a aprendizagem os pesos são modificados de forma iterativa. Dado um peso inicial w_{ij}^I de uma primeira iteração I entre um neurônio i e um neurônio j , o algoritmo de aprendizagem julga a qualidade do peso e determina se ele deve sofrer ou não uma modificação no seu valor, de uma diferença Δw_{ij}^I na próxima iteração $I + 1$ conforme a equação 2.4:

$$w_{ij}^{I+1} = w_{ij}^I + \Delta w_{ij}^I \quad (2.4)$$

Os valores iniciais dos pesos podem ser escolhidos aleatoriamente, sendo geralmente usados valores unitários. O algoritmo de aprendizagem finaliza as modificações nos pesos após um número fixo de iterações e/ou até que seja atingida uma determinada condição de parada.

Regra Delta

Uma regra de adaptação dos pesos com um objetivo claro é a Regra Delta ou regra de Widrow-Hoff [8]. A rede entrega na saída do neurônio i uma função y_i . Como o valor desejado y_{di} que a rede deve calcular é conhecido, pode-se calcular o erro $e_i = y_{di} - y_i$ entre o desejado e o calculado. O peso do entre um neurônio i e um neurônio j , que é responsável por esse erro, deve, então, ser modificado proporcionalmente a ele (equação 2.5).

$$\Delta w_{ij} = \eta e_i y_i = \eta (y_{di} - y_i) y_i \quad (2.5)$$

Onde η é um fator de escala positivo que determina a velocidade da aprendizagem.

2.2 Perceptron

O perceptron [9] é capaz de classificar entre duas classes que são linearmente separáveis (Figura 2.4).




Figura 2.4: Exemplo da separação do perceptron com Regressão Linear

A função que o perceptron implementa é a do neurônio de McCulloch e Pitts, onde a função de Heaviside (equação 2.2) é modificada como mostrado na equação 2.6. Como a condição de disparo do neurônio é $v_k = \sum_{m=1}^M w_{km} x_m = \theta$, pode-se absorver o limiar θ em v_k resultando $v_k = \sum_{m=1}^M (w_{km} x_m) - \theta = 0$. O que equivale a adicionar um peso θ as entradas do perceptron, conectando-o a uma entrada de valor fixo $x_{m+1} = -1$. A esta entrada é dado o nome de bias b_k , cuja função é aumentar o número de graus de liberdade disponíveis no

modelo, permitindo que o perceptron tenha maior capacidade de se ajustar ao conhecimento a ele fornecido.

$$\varphi(v_k) = \begin{cases} 1 & v_k \geq 0 \\ 0 & v_k < 0 \end{cases} \quad (2.6)$$

Sendo o perceptron um neurônio com m entradas (Figura 2.5) o Δw de adaptação dos pesos é definido conforme mostrado na equação 2.7.

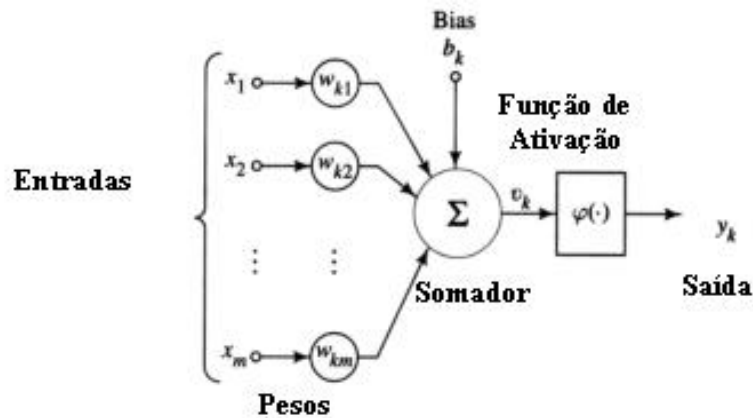


Figura 2.5: Perceptron

$$\begin{aligned} \Delta w_{km} &= \eta y_d x_m \quad \text{se } y_k \neq y_d \\ \Delta w_{km} &= 0 \quad \text{se } y_k = y_d \end{aligned} \quad (2.7)$$

O perceptron é uma rede neural simples, capaz de resolver problemas lineares de classificação. Está equipado com um algoritmo de adaptação de pesos que aprende baseado nos exemplos de treinamento. Porém a sua capacidade de cálculo é limitada pela separabilidade linear das classes. Para classificar problemas em que as classes se distribuem de tal forma que seja impossível criar um hiperplano para separá-las, técnicas mais sofisticadas têm que ser usadas, como a MLP (Multi-Layer-Perceptron).

2.3 Adaline

Um modelo muito parecido com o perceptron em termos de arquitetura é o Adaline [8]. A diferença está na saída, que está no domínio dos números

reais em virtude da retirada do bloco da função de ativação (Figura 2.6) e na adaptação dos pesos. Desta forma a função calculada y_k é simplesmente a combinação linear dos pesos e das entradas (equação 2.8):

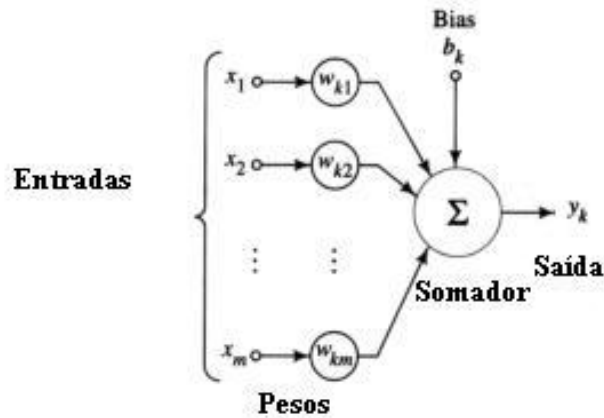


Figura 2.6: Adaline

$$y_k = \sum_{m=1}^M (w_{km} x_m) - b_k \quad (2.8)$$

Erro Médio Quadrático

Erro Médio Quadrático (Mean Square Error – *mse*) é o critério de avaliação utilizado para verificar se o Adaline alcançou o menor erro possível entre sua saída y_k e o valor desejado y_d . Assim, além do critério de parada do algoritmo baseado no número de iterações, o Adaline irá procurar alcançar um valor de erro igual ou inferior ao permitido, minimizando a função da equação 2.9.

$$mse = (y_d - y_k)^2 \quad (2.9)$$

Caso as entradas x_m sejam vetores de N elementos a equação do *mse* é dada em 2.10:

$$mse = \frac{1}{N} \sum_{n=1}^N (y_{dn} - y_{kn})^2 \quad (2.10)$$

2.3.1 Descida do Gradiente

A Figura 2.7 mostra a idéia principal da técnica de descida do gradiente. Das equações 2.8 e 2.9 conclui-se que o mse é uma função dos pesos da rede – para fins de ilustração usa-se um único peso w . O objetivo é encontrar o peso w_{min} que minimize o erro mse (2.9), isto é, que aproxima, da melhor maneira possível, o mapeamento entre todas as m entradas x_m para os valores desejados y_d . Tenta-se chegar iterativamente ao mínimo global w_{min} . A única informação que é conhecida na iteração I é o valor do erro $mse(w^I) = E(w^I)$ para o peso w^I atual. Supondo que a função do erro seja derivável em todo o domínio, o gradiente da função de erro $\nabla E = \partial E(w)/\partial w$ existe.




Figura 2.7: Função de erro mse para um peso w

O gradiente é um vetor. Ele aponta na direção do crescimento da função E . Conseqüentemente o gradiente negativo aponta na direção de decréscimo da função. A estratégia para chegar ao mínimo da função é, então, a modificação do peso da iteração I para o da iteração $I + 1$ na direção do gradiente negativo (da descida do gradiente). Para controlar a velocidade de modificação do peso w^I para w^{I+1} usa-se um fator de escala, a taxa de aprendizagem η . Tem-se, então, a técnica da adaptação dos pesos (equação 2.11):

$$w^{I+1} = w^I + \Delta w^I = w^I - \eta \nabla E^I \quad (2.11)$$

Os problemas com a técnica de descida do gradiente são a escolha da

taxa de aprendizagem η e a ocorrência de mínimos locais. Se η for muito pequena a aprendizagem pode ficar lenta. Caso seja grande demais podem surgir oscilações do erro com uma divergência dos pesos, isto é, os pesos não param de crescer. Mínimos locais são regiões na função de erro onde o gradiente desaparece, não havendo uma modificação dos pesos. Assim o algoritmo pode parar num conjunto de pesos que não corresponde ao mínimo global da função de erro.

A partir da técnica de descida do gradiente, e sabendo que o Adaline procura minimizar a média do erro quadrático (equação 2.9), ou seja, trabalha na superfície $(y_d - y_k)^2$, tem-se:

$$\begin{aligned} E^2 &= (y_d - y_k)^2 \\ \nabla E &= \frac{\partial E}{\partial w} = \\ 2E \frac{\partial(y_d - (\sum_{m=1}^m (w_{km}x_m) - b_k))}{\partial w_{km}} &= -2Ex_m \end{aligned} \quad (2.12)$$

substituindo 2.12 em 2.11 e incorporando o termo constante 2 ao η , tem-se:

$$w_m^{I+1} = w_m^I + \eta(y_d - y_k)x_m \quad (2.13)$$

Que é a regra de adaptação dos pesos para o método Adaline.

2.4 Multi-Layer-Perceptron

Multi-Layer-Perceptron (MLP) [7] são redes de perceptrons com pelo menos uma camada escondida (seção 2.1.3). Consideramos aqui, para efeito de demonstração destas redes, o caso de uma única camada escondida. A generalização para mais de uma camada escondida é direta e a teoria aplica-se sem alteração. Um neurônio recebe várias entradas da camada anterior e calcula uma combinação linear (equação 2.8) dessas variáveis. O resultado da combinação linear passa pela função de ativação, por exemplo a função sigmoideal:

$$g(v) = \frac{1}{1 + e^{-v}} \quad (2.14)$$

A escolha da equação 2.14 como função de ativação deve-se as suas propriedades, a citar:

- Contínua e diferenciável em todo domínio \Re ;

- Derivada tem forma simples e é expressa pela própria função $g'(v) = g(v)(1 - g(v))$;
- Estritamente monótona ($v_1 \leq v_2 \Leftrightarrow g(v_1) \leq g(v_2)$).

Uma MLP pode conter mais de uma saída, o que significa que a saída é um vetor $\mathbf{y} = (y_{k1}, \dots, y_{kN})$ de N funções individuais y_{kn} calculadas. Assim a rede realiza um mapeamento de um vetor multidimensional \mathbf{x} para outro vetor multidimensional \mathbf{y} . A camada escondida tem um número H de neurônios. Um peso entre a variável de entrada x_m e o neurônio com índice h na camada escondida chama-se w_{hm} . De forma análoga, existe um peso w_{nh} que liga o neurônio com índice h na camada da saída y_{kn} .

O mapeamento realizado para uma função de saída é:

$$y_{kn} = g \left(\sum_{h=0}^H w_{nh} \cdot g \left(\sum_{m=0}^M w_{hm} x_m \right) \right) \quad (2.15)$$

A função 2.15 constitui um instrumento poderoso de realizar cálculos não lineares em muitas áreas de aplicação. Pode-se usar 2.15 para classificação de classes não linearmente separáveis, como no caso do XOR (OU exclusivo). Também para problemas de regressão o MLP é muito útil, por exemplo, para realizar previsões. A área de controle automático e a identificação de plantas é outro exemplo.

Uma das grandes vantagens dessa técnica é que o MLP é um aproximador universal de funções, ou seja, desde que os pesos sejam bem adaptados e a rede possua um número suficiente de neurônios escondidos, o resultado desejado é atingido.

2.4.1 Adaptação dos pesos

Assim como no ADALINE, a rede MLP procura aprender os pesos da rede baseado numa função de erro entre a sua saída y_k e o valor esperado y_d . A técnica utilizada é da descida do gradiente. É necessário reformular o *mse*, porque o número de saídas y_k aumentou para N . A diferença entre os valores desejados para o exemplo e os valores calculados pela rede viraram a diferença entre dois vetores. Os valores desejados são o vetor alvo $\mathbf{y}_d = (y_{d1}, \dots, y_{dn})$. O valor calculado pela rede é o vetor $\mathbf{y}_k = (y_{k1}, \dots, y_{kn})$. A escolha comum para a diferença entre o desejado e o calculado pela rede é a distância Euclidiana quadrática entre os dois vetores:

$$E^2 = \|\mathbf{y}_d - \mathbf{y}_k\|^2 = \sum_{n=1}^N (y_{dn} - y_{kn})^2 \quad (2.16)$$

Finalmente o valor esperado mse pode ser estimado pela média dos erros quadráticos de todos os exemplos T do conjunto de treinamento.

$$mse = \frac{1}{T} \sum_{t=1}^T E^2 = \frac{1}{T} \sum_{t=1}^T \sum_{n=1}^N (y_{dn} - y_{kn})^2 \quad (2.17)$$

Utilizamos outra vez a filosofia da descida de gradiente (equação 2.11) para adaptar os pesos. Na adaptação dos pesos w_{nh} da camada escondida para a camada de saída utilizamos a regra de delta. Para a adaptação dos pesos w_{hm} da entrada para a camada escondida temos que usar a regra de delta generalizada.

Vamos considerar unicamente a aprendizagem orientada a cada exemplo x_m . Resta então calcular o gradiente em relação aos pesos da camada escondida para a camada de saída $\nabla E_{nh} = \partial E / \partial w_{nh}$ e o gradiente em relação aos pesos da entrada para a camada escondida $\nabla E_{hm} = \partial E / \partial w_{hm}$.

$$e_n = y_{dn} - y_{kn}$$

$$y_{kn} = g \left(\sum_{h=0}^H w_{nh} \cdot g \left(\sum_{m=0}^m w_{hm} x_m \right) \right)$$

Camada escondida para a camada de saída (Regra Delta):

$$\nabla E_{nh} = \partial E / \partial w_{nh} = -2\delta_n g_h$$

$$\delta_n = e_n g'_n = e_n (g_n (1 - g_n))$$

Entrada para a camada escondida (Regra Delta generalizada):

$$\nabla E_{hm} = \partial E / \partial w_{hm} = -2\delta_h g_m$$

$$\delta_h = g'_h \sum_{n=1}^n \delta_n x_m$$

A rede neural artificial do MLP é um instrumento poderoso de realizar aproximações universais de funções a partir de um conjunto de dados de treino. Existem muitos campos de aplicação que permitem mapear o problema para uma rede e adaptar os pesos pelos dados de treinamento.

Uma desvantagem do MLP é o tempo de treinamento extenso. Em um problema complexo pode-se levar várias semanas até se obter um conjunto de pesos adequados. A escolha da taxa de aprendizagem desempenha também

um papel fundamental. Como já foi dito existe a possibilidade de que a função de erro fique presa em um mínimo local. A paralisia do treinamento é um fenômeno que acontece quando a magnitude dos pesos é grande. Nesse caso a derivada da função sigmoïdal 2.14 fica muito pequena, o que faz a modificação dos pesos praticamente desaparecer.

Capítulo 3

Sistemas Ópticos Adaptativos

3.1 Introdução

Todo o processo de detecção e correção de aberrações está fundamentado no conceito de frente de onda¹, cujo perfil é afetado pelo meio de propagação (ex.: córnea, camadas atmosféricas, lentes, etc). A fim de corrigir seu perfil, deve-se primeiramente detectar a topografia da aberração impressa na frente de onda com um sensor óptico de fase. A restauração do perfil inicial ótimo de uma frente de onda deformada pelo meio pode ser realizada estaticamente, com lentes ou espelhos conjugados (ex.: lentes de contato personalizadas e espelhos esféricos), ou dinamicamente através de lentes e espelhos adaptativos [10]. Em ambos os casos a aberração é eliminada quando o elemento corretor apresenta um perfil proporcional à frente de onda Ξ_{in} , como mostrado na Figura 3.1 para o caso de espelhos.

Uma frente de onda deformada Ξ_W pode ser representada pela soma ponderada de um conjunto normalizado de aberrações ópticas conhecidas, descritas por polinômios de Zernike Z_i (3.1). [11, 12]

$$\Xi_W = \sum_{i=0}^{\infty} C_i Z_i \quad (3.1)$$

Onde o número adequado de polinômios Z_i depende da frequência espacial da frente de onda em questão.

¹A luz propaga-se como onda eletromagnética, cujas superfícies isofásicas são representadas por frentes de onda.




Figura 3.1: Representação unidimensional da correção de uma frente de onda deformada. Ξ_{in} : frente de onda; Ξ_0 : frente de onda corrigida; S: perfil de um Espelho Adaptativo; Z: direção de propagação.

3.1.1 Polinômios de Zernike

Os polinômios de Zernike são dados pela equação (3.2), sendo a componente R_n^m mostrada na equação (3.3). Os valores de ρ estão compreendidos no intervalo $[0 \ 1]$ e os de θ em $[0 \ 2\pi]$.

$$Z_i(\rho, \theta) = Z_{n,m}(\rho, \theta) = \begin{cases} R_n^m(\rho) \cos(m\theta) & m > 0 \\ R_n^m(\rho) \sin(m\theta) & m < 0 \\ R_n^m(\rho) & m = 0 \end{cases} \quad (3.2)$$

$$R_n^m(\rho) = \sum_{s=0}^{(n-|m|)/2} \frac{(-1)^s (n-s)!}{s! \left[\frac{(n+|m|)}{2} - s \right]! \left[\frac{(n-|m|)}{2} - s \right]!} \rho^{n-2s} \quad (3.3)$$

A relação adotada neste trabalho entre o índice i e os índices n e m é mostrada na tabela 3.1 para os nove primeiros polinômios Z_i ($i = \{0, \dots, 8\}$).

i	0	1	2	3	4	5	6	7	8
n	1	1	2	2	2	3	3	3	3
m	1	-1	0	2	-2	1	-1	3	-3

Tabela 3.1: Conversão do coeficiente i em n e m até $i = 8$

onde os valores de n e m devem obedecer as seguintes regras para garantir a ortonormalidade dos polinômios de Zernike:

- n e m são inteiros e $n > 0$;

- n e m tem a mesma paridade;
- para um dado n , m varia de $-n$ a n com um passo de dois.



No apêndice A é apresentada uma rotina em C para o cálculo automático da relação entre índice i e os índices n e m .

A seguir são mostradas, de forma gráfica, as aberrações típicas representadas pelos sete primeiros polinômios Z_i ($i = \{0, \dots, 6\}$), com amplitudes entre -1 e 1.

tilt x

$i = 0$

$n = 1, m = 1$



tilt y


$i = 1$


$n = 1, m = -1$

defocus

$i = 2$


$n = 2, m = 0$







45 degree
astigmatism
 $i = 3$
 $n = 2, m = 2$

0 degree
astigmatism
 $i = 4$
 $n = 2, m = -2$



coma x
 $i = 5$
 $n = 3, m = 1$



coma y
 $i = 6$
 $n = 3, m = -1$

3.2 Sistema

O sistema Óptico Adaptativo utilizado neste trabalho é mostrado na Figura 3.2. O laser (12-mm de diâmetro, He-Ne, $\lambda = 632,8\text{nm}$), passa pelo plano de aberração (AB), atinge o espelho e é refletido até o *beam-splitter*, onde é dividido em dois feixes, um para o sensor de frentes de onda em CMOS e o outro para o sensor CCD convencional. Esta arquitetura do sistema foi elaborada para o teste dos componentes do sistema e dos algoritmos de controle.




Figura 3.2: Sistema Óptico Adaptativo

3.2.1 Configuração do Sistema Óptico

O diagrama da Figura 3.3 ilustra a configuração típica das lentes em um sistema óptico. Esta configuração de lentes deve ser utilizada para garantir a conjugação óptica entre planos, ou seja, que a aberração no plano A seja idêntica à aberração no plano B. Esse sistema está na categoria de sistemas afocais, podendo incorporar magnificação ou demagnificação do feixe.




Figura 3.3: Configuração das lentes

A dedução da fórmula que relacione as distâncias L_1 e L_2 com as distâncias focais f_1 e f_2 , para a montagem do *setup* óptico é mostrada a seguir.

Sejam i as distâncias das imagens às lentes e o as distâncias dos objetos às lentes. Da óptica geométrica, tem-se:

$$\frac{1}{i_1} = \frac{1}{f_1} - \frac{1}{o_1} \Leftrightarrow i_1 = \frac{o_1 f_1}{o_1 - f_1} \quad (3.4)$$

$$o_2 = d - i_1 \quad (3.5)$$

onde o_2 é o objeto da lente 2.

$$i_2 = \frac{o_2 f_2}{o_2 - f_2} \quad (3.6)$$

Substituindo 3.5 em 3.6:

$$i_2 = \frac{(d - i_1) f_2}{d - i_1 - f_2} \quad (3.7)$$

Se $L_1 = o_1$, então, de 3.4

$$i_1 = \frac{L_1 f_1}{L_1 - f_1} \quad (3.8)$$

Seja $L_2 = i_2$, então, de 3.7

$$L_2 = \frac{(d - i_1)f_2}{d - i_1 - f_2} \quad (3.9)$$

Substituindo 3.8 em 3.9:

$$L_2 = \frac{(d - \frac{L_1 f_1}{L_1 - f_1})f_2}{d - \frac{L_1 f_1}{L_1 - f_1} - f_2}$$

$$L_2 = \frac{[(L_1 - f_1)d - L_1 f_1]f_2}{(L_1 - f_1)d - L_1 f_1 - f_2(L_1 - f_1)}$$

Como $d = f_1 + f_2$:

$$L_2 = \frac{f_2(f_1^2 + f_1 f_2 - L_1 f_2)}{f_1^2} \quad (3.10)$$

Cálculos

O objetivo dessa seção é mostrar como foram feitos os cálculos que levam à montagem e à atual configuração do sistema óptico (Figura 3.2).

As equações de 3.11 a 3.14 serão usadas para se obter as distâncias corretas entre os componentes:

$$L_2 = \frac{f_2(f_1^2 + f_1 f_2 - L_1 f_2)}{f_1^2} \quad (3.11)$$

$$L_4 = \frac{f_4(f_3^2 + f_3 f_4 - L_3 f_4)}{f_3^2} \quad (3.12)$$

$$d_3 = d_1 \frac{f_2}{f_1} \quad (3.13)$$

$$d_4 = d_1 \frac{f_4}{f_3} \quad (3.14)$$

As equações 3.13 e 3.14 mostram que é possível modificar o diâmetro do feixe de laser no sistema, basta utilizar lentes de distâncias focais diferentes com a relação do mesmo valor da relação entre os diâmetros do feixe. Há uma série de lentes com distâncias focais diferentes disponível comercialmente.

Na montagem realizada neste trabalho o diâmetro do Espelho Adaptativo é de $15mm$, sendo que o diâmetro d_1 do feixe que deve incidir centralizado sobre ele, deve ser de $12mm$. Na montagem existe um componente com um orifício de $12mm$ de diâmetro logo após a lente colimadora. Assim, o primeiro

sistema afocal não precisa ter lentes de distâncias focais diferentes, visto que não é necessário mudar o diâmetro do feixe. Assim, foi decidido que:

$$\begin{aligned}f_1 &= f_2 = 150mm \\L_1 &= 200mm \\L_2 &= 100mm\end{aligned}$$

Dos valores acima, apenas o de L_2 não é arbitrário, uma vez que ele vem da equação 3.11.

O diâmetro do feixe incidente sobre o sensor de frentes de onda deve ser de $8mm$, e portanto compatível com a área ativa do sensor. Assim:

$$\begin{aligned}\frac{d_1}{d_4} &= \frac{12}{8} = 1,5 \\ \frac{f_3}{f_4} &= 1,5\end{aligned}$$

Escolhe-se, portanto:

$$\begin{aligned}f_3 &= 150mm \\f_4 &= 100mm \\L_3 &= 200mm\end{aligned}$$

E se encontra $L_4 = 78$ pela equação 3.12. Isso quer dizer que a máscara de Hartmann do sensor de frentes de onda deve estar a $78mm$ da quarta lente. Um ajuste fino da posição é conseguido através de parafusos de precisão com ajuste micrométrico, presentes em alguns componentes mecânicos do sistema óptico.

Ao substituir o sensor de frentes de onda pela câmera CCD, o ajuste das lentes será diferente, pois o feixe que chega sobre ela deve ter apenas $5mm$ de diâmetro. Seja d_4 o valor desse diâmetro:

$$\begin{aligned}\frac{d_1}{d_4} &= \frac{12}{5} = 2,4 \\ \frac{f_3}{f_4} &= 2,4\end{aligned}$$

Escolhe-se, portanto:

$$\begin{aligned}f_3 &= 250mm \\f_4 &= 100mm \\L_3 &= 200mm\end{aligned}$$

Pela equação 3.12 verificou-se que o valor de $L_4 = 108mm$. Observe que a relação entre as distâncias focais das lentes escolhidas está um pouco maior do que a relação entre diâmetros, ou seja, indica uma ligeira redução no diâmetro de $0,2mm$ do feixe incidente na câmera. Mas essa redução não é problema, uma vez que a diagonal da área ativa do sensor é de $5mm$, o que configuraria este o diâmetro máximo do feixe de laser.

Se for necessário modificar o diâmetro do feixe que chega ao espelho são utilizadas as equações 3.11 e 3.14. Sempre que não for necessário fazer essa mudança é aconselhável manter as distâncias focais iguais para lentes de um mesmo sistema afocal.

3.2.2 Controle do Sistema

O controle de um Sistema Óptico Adaptativo é a metodologia usada para processar os dados de um sensor de frentes de onda, obtendo saídas que podem ser utilizadas em um Espelho Adaptativo para corrigir as aberrações da frente de onda. Esta metodologia é tipicamente transcrita dentro de algoritmos e software. Contudo, um sistema de controle completo inclui sensor de frentes de onda, Espelho Adaptativo, *drivers* associados (se necessário), unidades de processamento, caminho óptico, barramentos de dados digitais e circuitos de sinais analógicos (Figura 3.4).

O controle de um Sistema Óptico Adaptativo frequentemente inclui todos os elementos contidos dentro do quadro mostrado na Figura 3.4. É essencial prover uma transferência cíclica e processamento da informação obtida pela amostragem óptica da entrada.

O objetivo do controle do sistema é minimizar as aberrações da frente de onda detectadas pelo sensor na amostra da entrada, através da aplicação de deformações apropriadas no espelho, obtendo uma frente de onda corrigida na saída. As aberrações são usualmente determinadas em comparação com as medidas feitas em uma onda de entrada de referência. O sensor de frentes de onda do sistema de controle é muitas vezes referido como sensor de nulo, visto que as aberrações da frente de onda são nulas no sensor, quando o sistema de controle transmite os sinais de correção apropriados ao Espelho Adaptativo. Tal como um sistema, o sensor de frentes de onda e as unidades de processamento não reconstroem diretamente a fase da frente de onda, e sim as aberrações da frente de onda são sintetizadas no Espelho Adaptativo.

Quando consideramos a transferência de informação através do sistema, é conveniente iniciar onde as aberrações da frente de onda são controladas, em outras palavras, onde são as entradas do sistema. Na prática, o primeiro elemento de controle da frente de onda será um espelho *tip-tilt*, uma vez que para muitas aplicações de Óptica Adaptativa os erros de *tip-tilt* são corrigidos

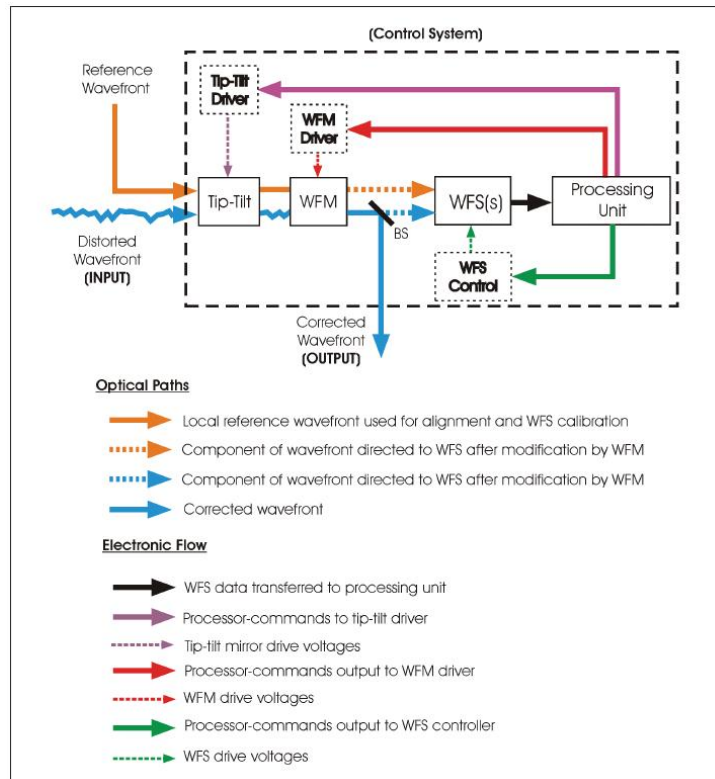


Figura 3.4: Diagrama de Funcionamento

separadamente para aberrações de alta ordem. Isto porque erros de *tip-tilt* podem ser muitos maiores que aberrações de alta ordem e necessitariam de um Espelho Adaptativo com um alto alcance dinâmico, que muitas vezes não é disponível.

O espelho de *tip-tilt* e o Espelho Adaptativo são usualmente localizados em planos conjugados do sistema óptico. A luz refletida ou transmitida pelo Espelho Adaptativo constitui a saída do sistema e uma parte desta luz é amostrada pelo sensor de frentes de onda através de um *beam-splitter* (BS).

O sensor de frentes de onda mostrado na Figura 3.4 também inclui um sensor de *tip-tilt*. Devido as altas variações de fase esperadas para erros de *tip-tilt*, outro *beam-splitter* é muitas vezes usado para possibilitar a detecção dos dados de *tip-tilt* separadamente dos modos de alta ordem. Em princípio, *tip-tilt* e dados dos modos de alta ordem podem ser extraídos em um mesmo sensor de frentes de onda, embora todos os modos possam ser separados espacialmente e detectados separadamente.

3.2.3 Processamento dos dados

As necessidades específicas do processo entre os dados de saída do sensor de frentes de onda e os sinais de erro aplicados ao Espelho Adaptativo dependem das características do sensor e do espelho. Contudo, mesmo determinado um par específico de sensor/espelho, há muitas metodologias de processo que podem ser adotadas, tão boas quanto diferentes escolhas de processos de hardware.

A questão do impacto do processamento dos dados dentro do sistema de controle agrupa a teoria de controle clássica com o problema de transformação das medidas do sensor em sinais de controle, que mudem a forma do Espelho Adaptativo e então corrijem as aberrações da frente de onda. Embora a aplicação da teoria de controle clássico seja indispensável ao projeto de um Sistema Óptico Adaptativo, ela já é bem estudada e discutida[[19],[20]]. O problema da transformação, contudo, pode ser discutido num contexto específico de Óptica Adaptativa, embora discussões gerais deste problema possam ser encontradas na literatura[[21],[22]].

Um dos parâmetros críticos de controle em um Sistema Óptico Adaptativo em loop fechado é o atraso temporal, ou defasagem, entre as medidas feitas pelo sensor e os sinais de controle a serem aplicados no espelho. Quando a correção adaptativa de aberrações de frente de onda é contínua, o tempo de integração dos detectores do sensor, o subsequente atraso no processamento dos dados do sensor e finalmente a aplicação da correção no espelho, tem que ser rápidos o suficiente para assegurar que a correção aplicada está ainda correlacionada com as aberrações da frente de onda. Em algumas aplicações, particularmente as que tratam do controle adaptativo em turbulência atmosférica, um número de estratégias tem que ser desenvolvida para alcançar este objetivo. Muitas destas estratégias acompanham as evoluções estatísticas das aberrações das frentes de onda e exploram "algoritmos de aprendizado" que podem ser treinados para criar previsões futuras inteligentes das aberrações da frente de onda. Exemplos destes algoritmos de aprendizado são: redes neurais, treinamento recursivo de previsores com mínimos quadrados e aprendizado adaptativo por gradiente.

3.3 Componentes

3.3.1 Espelho Adaptativo

O Espelho Adaptativo utilizado possui uma membrana reflexiva de 15mm de diâmetro suspensa acima de uma rede hexagonal de 37 atuadores eletrostáticos. A membrana é polarizada com uma tensão base de 125V aplicada

a todos os atuadores, para permitir correções tanto de aberrações côncavas como convexas. A diferença de potencial entre um dado eletrodo e a membrana (aterrada) pode chegar a 250V; a excursão máxima da membrana é de $8\mu\text{m}$ [7]. Espelhos adaptativos são fabricados com tecnologia de microfabricação em silício.

O dispositivo consiste de um *chip* de silício montado sobre uma placa PCB (Printed Circuit Board – Placa de Circuito impresso). O *chip* contém uma membrana de nitreto de silício revestida com uma camada de prata para formar o espelho. A PCB contém os eletrodos. A forma da membrana do espelho é controlada por um sistema de controle da tensão dos eletrodos. O dispositivo pode ser usado para correção dinâmica de aberrações de baixa ordem como: foco, astigmatismo, coma, etc. O esquema da montagem do espelho e os canais de controle são mostrados na Figura 3.5.

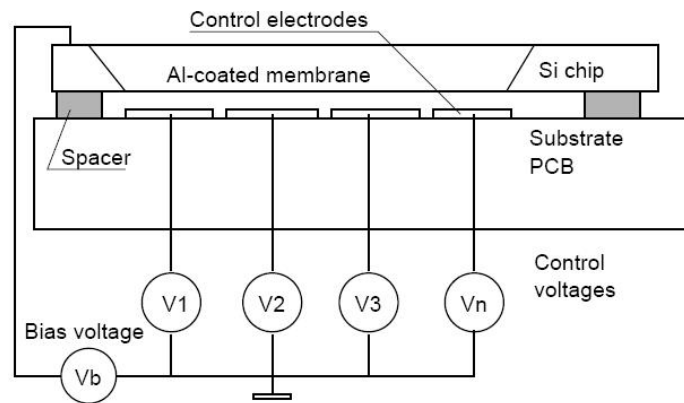


Figura 3.5: Esquema de um Espelho Adaptativo

A Figura 3.6 mostra a fotografia de um Espelho Adaptativo.

Características do Espelho

A membrana é montada em cima da estrutura de atuadores mostradas na Figura 3.7. A distância de centro a centro entre cada atuador é $1,8\text{mm}$. A estrutura total do atuador está circunscrita a um diâmetro de 12mm e fica posicionada abaixo da membrana do espelho.

A membrana condutora presa ao redor do seu perímetro e suspensa sobre uma matriz de eletrodos pode ser deformada através da aplicação de uma diferença de potencial entre ela e os eletrodos. O perfil da membrana pode ser controlado pela aplicação de tensões apropriadas a cada eletrodo [10]. Portanto, uma frente de onda deformada $W(x, y)$ pode ser corrigida ao ser refletida pela membrana com a forma $W(x, y)/2$.



Figura 3.6: Espelho Adaptativo

A membrana deve ser plana, resistente e tensionável, o que é conseguido com a deposição mecânica de uma fina camada ($\sim 300\text{nm}$ a 800nm) de material tensionável Si_nN_m num substrato de silício. O Si_nN_m tem boas propriedades mecânicas, não é frágil e é compatível com processos de microfabricação e deposição por LPCVD (Low-Pressure Chemical Vapor Deposition) garantindo a alta pureza e uniformidade da camada. A membrana é destacada do silício por corrosão anisotrópica. Se é usada a corrosão anisotrópica com alta seletividade (p.ex.: solução aquosa de KOH para cor-
roer $< 100 >$ wafer), a membrana de nitreto não é afetada pela corrosão do substrato de silício.

O número de eletrodos está na faixa de 1 a 119 e o tamanho da membrana de 5 a 50mm . A deformação da membrana é proporcional à raiz quadrada da tensão, onde a tensão de controle é no máximo 300V .

Para assegurar a reflexão e condução, a membrana é revestida com uma película de 200nm de alumínio ou ouro. Estes revestimentos são suficientes para um alcance espectral amplo na região do visível (Al) e do infravermelho (Au). Revestindo a membrana com um película de Cr/Ag, além de múltiplas camadas dielétricas apropriadamente dimensionadas pode-se obter uma reflexão de 99.8% na faixa de comprimento de onda. Espelhos revestidos com multicamadas são designados para trabalhar com laser de até 550W , feixe de 5mm de diâmetro e $\lambda=1.06\mu\text{m}$.

Membranas de até 50mm podem ser fabricadas pela inserção de uma camada relativamente espessa - até $10\mu\text{m}$ - de poli-Silício entre duas camadas de nitreto.




Figura 3.7: *Lay-out* dos atuadores

Inicialmente a membrana plana pode ser deformada somente na direção dos atuadores eletrostáticos porque a força eletrostática é somente atrativa. Isto limita as formas que o Espelho Adaptativo pode descrever a serem sempre côncavas. Visto que a maioria das aplicações requer ambas as formas, côncavas e convexas, o espelho é inicialmente polarizado para adquirir a forma côncava, na média entre a mínima e a máxima deflexão. Nesta posição, o espelho pode corrigir tanto aberrações côncavas como convexas. O tempo de resposta típico é de $\sim 1\text{ms}$, fazendo o espelho aplicável para controle em tempo real de aberrações presentes em turbulência.

Como a tecnologia do Espelho Adaptativo é baseada completamente em materiais inorgânicos, pode-se demonstrar que ele pode trabalhar no vácuo e em temperaturas criogênicas de $T = 78\text{K}$ [13], tornando-o potencialmente adequado para óptica adaptativa no espaço.

É relatada a utilização com sucesso de Espelho Adaptativo na correção, em tempo real, de aberrações de fase em laboratório e em um telescópio da Apache Point, Novo Mexico [14]. Em particular, a razão Strehl ² foi

²Razão entre intensidade no centro da distribuição de campo distante da imagem (feixe) de teste e a da imagem (feixe) de referência, isto é, a razão entre as amplitudes da trans-

melhorada na média de 0.08 para 0.48 para uma turbulência simulada em laboratório.

Pequeno tamanho, resposta rápida, alta densidade de atuadores, resposta modal linear e operação livre de histereses fazem do Espelho Adaptativo altamente adequado para correção *feed-forward* baseada numa combinação de otimização e programa de controle. No início o vetor de tensões aplicado aos eletrodos do espelho é otimizado para obter o máximo de parâmetros apropriados de qualidade – luminosidade para sistemas laser, nitidez e qualidade de imagem para sistemas de imagem, duração do pulso para lasers ultra-rápidos. O processo de otimização pode ser feito através de iterações sucessivas e o resultado usualmente significa melhoria na qualidade do sistema óptico. O vetor de controle é escrito na memória do computador e pode ser recalculado várias vezes para refazer a situação de controle.

Finalmente, o Espelho Adaptativo é adequado para correção em tempo real de aberrações do olho humano, tornando possível "óculos eletrônicos" para aperfeiçoamento em tempo real da acuidade visual (Figura 3.8) [18].




Figura 3.8: Óculos eletrônico

Portabilidade, simplicidade e alta qualidade óptica fazem do Espelho Adaptativo o dispositivo adequado para aplicações ópticas em óptica laser, imagem, testes ópticos e astronomia.

3.3.2 Sensor de frentes de onda

No método de Hartmann um feixe de laser incide sobre uma máscara opaca com um dado número de orifícios. O feixe é subdividido em M sub-feixes, que se propagam por uma pequena distância (geralmente de 1 a 10

formada de Fourier das imagens. Em geral, os valores são da ordem de 0.8 (o que equivale a uma *rms* de $\lambda/14$).

cm) até um anteparo de observação. Assumindo que a difração de Fresnel causa pouca divergência da máscara até o anteparo e que a frente de onda é plana, temos como resultado uma rede bidimensional de pontos luminosos, que reproduzem no anteparo a rede de orifícios presente na máscara, constituindo uma malha de referência. Distorções presentes na frente de onda resultam em um deslocamento dos pontos luminosos em relação à rede de referência. Registrando os valores x e y desses deslocamentos, podemos calcular geometricamente as inclinações locais da frente de onda, restaurando seu perfil original.

Uma frente de onda de teste Ξ_W pode ser representada por uma base infinita de funções nativas, como por exemplo os polinômios de Zernike Z_i (equação 3.1) [11]. O sinal do sensor, associado à frente de onda de teste, produz uma frente de onda reconstruída Ξ_R , que pode ser decomposta em uma base truncada com N funções e seus respectivos coeficientes c_i (equação 3.15).

$$\Xi_R = \sum_{i=0}^{N-1} c_i Z_i(\rho, \theta) \quad (3.15)$$

A ordem N de reconstrução é geralmente estabelecida pela geometria do sensor e o ruído presente no sistema.

Na reconstrução modal, através do método dos mínimos quadrados, os coeficientes \mathbf{c} que ponderam os polinômios de Zernike, para a reconstrução da frente de uma onda, são obtidos através da equação 3.16:

$$[\mathbf{B}^T \mathbf{B}]^{-1} \mathbf{B}^T \mathbf{s} = \mathbf{c} \quad (3.16)$$

Onde \mathbf{s} representa o vetor de inclinações locais, em x e y , das partes da frente de onda que atravessam os orifícios da máscara de Hartmann. As inclinações são dadas pelas equações 3.17 e 3.18.

$$S_i^x = \left. \frac{dW}{dx} \right|_{(x_i, y_i)} = \sum_{k=0}^{M-1} C_k \left. \frac{dZ_k}{dx} \right|_{(x_i, y_i)} \quad (3.17)$$

$$S_i^y = \left. \frac{dW}{dy} \right|_{(x_i, y_i)} = \sum_{k=0}^{M-1} C_k \left. \frac{dZ_k}{dy} \right|_{(x_i, y_i)} \quad (3.18)$$

De forma expandida, o problema a ser resolvido pelo método dos mínimos quadrados através da equação 3.16 é mostrado na Figura 3.9.

$$\begin{array}{c}
 \left[\begin{array}{c}
 S_0^x \\
 S_0^y \\
 S_1^x \\
 S_1^y \\
 \vdots \\
 S_i^x \\
 S_i^y \\
 \vdots \\
 S_{N-1}^x \\
 S_{N-1}^y
 \end{array} \right] = \begin{array}{c}
 \left[\begin{array}{ccccccc}
 \frac{dZ_0}{dx} \Big|_0 & \frac{dZ_1}{dx} \Big|_0 & \frac{dZ_2}{dx} \Big|_0 & \frac{dZ_3}{dx} \Big|_0 & \cdots & \frac{dZ_{M-2}}{dx} \Big|_0 & \frac{dZ_{M-1}}{dx} \Big|_0 \\
 \frac{dZ_0}{dy} \Big|_0 & \frac{dZ_1}{dy} \Big|_0 & \frac{dZ_2}{dy} \Big|_0 & \frac{dZ_3}{dy} \Big|_0 & \cdots & \frac{dZ_{M-2}}{dy} \Big|_0 & \frac{dZ_{M-1}}{dy} \Big|_0 \\
 \frac{dZ_0}{dx} \Big|_1 & \frac{dZ_1}{dx} \Big|_1 & \frac{dZ_2}{dx} \Big|_1 & \frac{dZ_3}{dx} \Big|_1 & \cdots & \frac{dZ_{M-2}}{dx} \Big|_1 & \frac{dZ_{M-1}}{dx} \Big|_1 \\
 \frac{dZ_0}{dy} \Big|_1 & \frac{dZ_1}{dy} \Big|_1 & \frac{dZ_2}{dy} \Big|_1 & \frac{dZ_3}{dy} \Big|_1 & \cdots & \frac{dZ_{M-2}}{dy} \Big|_1 & \frac{dZ_{M-1}}{dy} \Big|_1 \\
 \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\
 \frac{dZ_0}{dx} \Big|_i & \frac{dZ_1}{dx} \Big|_i & \frac{dZ_2}{dx} \Big|_i & \frac{dZ_3}{dx} \Big|_i & \cdots & \frac{dZ_{M-2}}{dx} \Big|_i & \frac{dZ_{M-1}}{dx} \Big|_i \\
 \frac{dZ_0}{dy} \Big|_i & \frac{dZ_1}{dy} \Big|_i & \frac{dZ_2}{dy} \Big|_i & \frac{dZ_3}{dy} \Big|_i & \cdots & \frac{dZ_{M-2}}{dy} \Big|_i & \frac{dZ_{M-1}}{dy} \Big|_i \\
 \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\
 \frac{dZ_0}{dx} \Big|_{N-1} & \frac{dZ_1}{dx} \Big|_{N-1} & \frac{dZ_2}{dx} \Big|_{N-1} & \frac{dZ_3}{dx} \Big|_{N-1} & \cdots & \frac{dZ_{M-2}}{dx} \Big|_{N-1} & \frac{dZ_{M-1}}{dx} \Big|_{N-1} \\
 \frac{dZ_0}{dy} \Big|_{N-1} & \frac{dZ_1}{dy} \Big|_{N-1} & \frac{dZ_2}{dy} \Big|_{N-1} & \frac{dZ_3}{dy} \Big|_{N-1} & \cdots & \frac{dZ_{M-2}}{dy} \Big|_{N-1} & \frac{dZ_{M-1}}{dy} \Big|_{N-1}
 \end{array} \right]
 \end{array}
 \begin{array}{c}
 \left[\begin{array}{c}
 C_0 \\
 C_1 \\
 \vdots \\
 C_k \\
 \vdots \\
 C_{M-2} \\
 C_{M-1}
 \end{array} \right]
 \end{array}
 \end{array}$$

s

2N x 1

B

2N x M

C

M x 1

Figura 3.9: Representação matricial do problema a ser resolvido pelo método de mínimos quadrados

O sensor de frentes de onda CMOS é composto de uma máscara de Hartmann com 64 orifícios de $450\mu\text{m}$ de diâmetro, uniformemente distribuídos em uma matriz ortogonal 8×8 . Neste trabalho utilizamos 16 orifícios, para adequação à velocidade da placa de aquisição de dados utilizada no capítulo 4. A máscara está posicionada a $8,3\text{cm}$ do *chip* CMOS, que corresponde a uma matriz de quadricélulas (QC's) com 600mm de lado [8]. Cada pixel da QC é passivo e é baseado em uma estrutura fotosensível de dupla junção (p+/nwell/p-epi). O desempenho desse *chip* é melhor que o de uma câmera comercial em termos de frequência de operação, em função dos seus sinais de saída serem diretamente proporcionais aos deslocamentos x e y dos pontos luminosos.

A resposta da QC não é linear e pode ser aproximada por uma curva sigmoïdal, que é utilizada no ajuste do posicionamento da máscara em relação ao *chip*.

O sensor de frentes de onda de Hartmann é fabricado em tecnologia CMOS $1.6\mu\text{m}$, onde uma matriz bidimensional de 64 detectores ópticos de posição produzem uma simples computação de deslocamentos. O *chip* acomoda tanto os circuitos digitais quanto analógicos. Os detectores de posição respondem aos deslocamentos dos pontos de luz dependendo do seu perfil e da relação entre o raio efetivo e o tamanho lateral do detector.

Este sensor requer pontos de luz na ordem de μW , operados a 3KHz e uma boa resolução de posição ($1\mu\text{m}$); portanto uma boa precisão da frente de onda ($\sim 13\text{nm}$ @ $10\mu\text{W}$ /ponto de luz).

Quadricélulas

Cada quadricélula consiste de quatro fotodiodos de junções duplas (Figura 3.10). Para minimizar o número de saídas do *chip*, foi implementado um multiplexador analógico integrado ao *chip*, tal que o sinal do fotodiodo selecionado seja disponibilizado sequencialmente em cada linha de saída. Para este propósito, cada pixel consiste de um fotodiodo provido de um circuito de chaveamento. Duas arquiteturas de pixel podem ser utilizadas: ativa ou passiva. A arquitetura ativa envolve o uso de um amplificador por píxel além de um mecanismo de *reset*, já o passivo baseia-se no acoplamento direto do sinal a linha de saída através de simples chaveamento.

O pixel passivo, empregado no sensor de frentes de onda, é mostrado na Figura 3.11, onde o chaveamento do sinal é realizado através de uma porta analógica complementar com chaves *dummy* laterais, constituída por transistores de efeito de campo NMOS e PMOS. Uma chave de descarga é também adicionada e acionada através de um inversor do sinal de controle, ocasionando o descarregamento contínuo do sinal do píxel enquanto não endereçado.




Figura 3.10: Junções das Quadricélulas

O circuito do pixel encontra-se protegido da incidência de luz por meio de uma camada de metal.

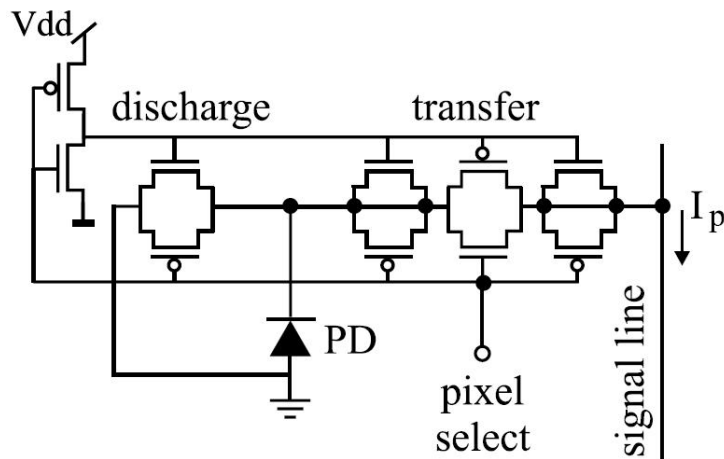


Figura 3.11: Pixel passivo

O layout do pixel passivo com descarga contínua permite o verdadeiro acesso aleatório espacial e temporal, porque os píxeis somente transferem suas fotocorrentes quando são endereçados. Contudo, o limite mínimo para o tempo de acesso do pixel é imposto a ambos pela capacitância do pixel ou pelo chaveamento, que tem um tempo fixo.

Foi escolhido o uso do pixel do tipo passivo para a quadricélula para este sensor de frentes de onda de Hartmann, porque ele é de fácil implementação e requer menos linhas de controle que o pixel ativo. A Figura 3.12 mostra a micro-fotografia de uma quadricélula de pixel passivo integrada no *chip* do sensor de frentes de onda.

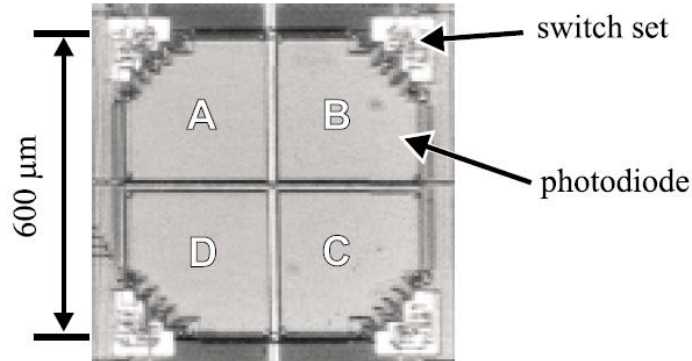


Figura 3.12: Micro-fotografia de uma quadricélula

Chip CMOS

O *chip* CMOS foi fabricado no DIMES/Holanda com processo padrão $1.6\text{-}\mu\text{m}$. Ele compreende 256 píxeis passivos agrupados e conjuntos de quatro-por-quatro, formando 64 quadricélulas espacialmente isoladas. A distância entre quadricélulas é de $380\mu\text{m}$, tal que a interferência elétrica entre quadricélulas vizinhas é minimizada. Os píxeis podem ser endereçados espacialmente e temporalmente de forma aleatória. A Figura 3.13 mostra os diferentes blocos de circuito integrado no *chip*. O *chip* foi projetado de forma que o caminho para os quatro píxeis de um quadricélula são endereçados simultaneamente. Isto minimiza o efeito temporal do *chip* na informação da posição do ponto de luz. Isto é, para uma dada quadricélula, caso o sinal do pixel B seja coletado ao mesmo tempo ou depois que o sinal do pixel A, e o ponto de luz se mover nesse intervalo, a precisão do registro de posição será afetada. As quadricélulas são divididas em dois grupos de acesso: interno e externo, em que ambos podem ser endereçados independentemente ou simultaneamente. Dependendo do nível digital dos pinos de controle, o controlador da taxa de amostragem determina se uma ou duas quadricélulas são endereçadas ao mesmo tempo. A distribuição do demultiplexador consiste de várias unidades digitais e analógicas. Os decodificadores controlam a seleção das chaves analógicas em cada pixel. Um conjunto de 8 saídas transmitem 4 ou 8 sinais ao mesmo tempo, dependendo da forma de controle. A fotografia de um sensor de frente de ondas implementado e o detalhe de seu canto superior direito é mostrada na Figura 3.14.




Figura 3.13: Esquema do chip




Figura 3.14: Fotografia do sensor

Capítulo 4

Discussões e Resultados

4.1 Adaline versus MLP

Inicialmente foram testados dois métodos de redes neurais candidatos a substituírem o algoritmo de mínimos quadrados no controle de Sistemas Ópticos Adaptativos.

Foi desenvolvido, primeiramente, um algoritmo MLP [1] com a configuração 3:3:1 (Figura 4.1), totalmente conectado. As entradas para o teste do algoritmo foram compostas pelos polinômios de Zernike mostrados nas equações (4.1) e a saída pela composição destes mesmos polinômios conforme equação(4.2).




Figura 4.1: Esquemático da MLP

$$\begin{aligned}
Entrada_1\{Z_0\} &= R_1^1(\rho)\cos\theta \\
Entrada_2\{Z_1\} &= R_{-1}^1(\rho)\sin(-\theta) \\
Entrada_3\{Z_2\} &= R_0^2(\rho)
\end{aligned} \tag{4.1}$$

$$Saída\{\Xi_{simulado}\} = C_0 * Z_0 + C_1 * Z_1 + C_2 * Z_2 \tag{4.2}$$

O teste foi realizado através dos seguintes passos:

1. Execução do algoritmo MLP;
2. Atribuição de um vetor de constantes C_i cujos valores são arbitrários;
3. Registro das épocas (após a convergência) ou mse (caso a rede exceda o valor pré-estabelecido de 1000 épocas).

Em virtude do maior número de épocas, comparado ao Adaline descrito a seguir, até a convergência e a necessidade de se descobrir a correlação entre os pesos da rede e os coeficientes iniciais C_i arbitrados, necessários a recuperação da frente de onda, o método foi considerado ineficiente. Testou-se, então, o método Adaline.

A exemplo do método MLP foi desenvolvido um algoritmo Adaline [23] com $\eta = 0.01$, $mse \leq 1e - 6$, número máximo de épocas igual a 1000, três entradas e a respectiva saída, geradas pelas mesmas equações (4.1) e (4.2). Foi aplicado o mesmo teste ao qual foi submetida a MLP. Além da convergência em uma época, a correlação entre os pesos do Adaline e os coeficientes C_i mostrou-se direta, com os pesos finais do treinamento iguais aos coeficientes arbitrados inicialmente a composição da saída.

Em virtude do bom resultado do Adaline um algoritmo ampliado com oito entradas foi elaborado (C_i com $i = \{0, \dots, 6\}$ e um $bias = -1$). A Figura 4.2 apresenta a topologia geral do Adaline desenvolvido.

Com o intuito de uma análise mais apurada foram realizados nove testes no segundo algoritmo com os vetores de saída descritos a seguir:

- 1º - $C_i=1$ para $i=0, \dots, 6$;
- 2º - $C_0=1$, $C_i=0$ para $i \neq 0$;
- 3º - $C_2=1$, $C_i=0$ para $i \neq 2$;
- 4º - $C_4=1$, $C_i=0$ para $i \neq 4$;
- 5º - $C_i=1$ para $i=0, 2, 4$ e $C_i=0$ para $i=1, 3, 5, 6$;

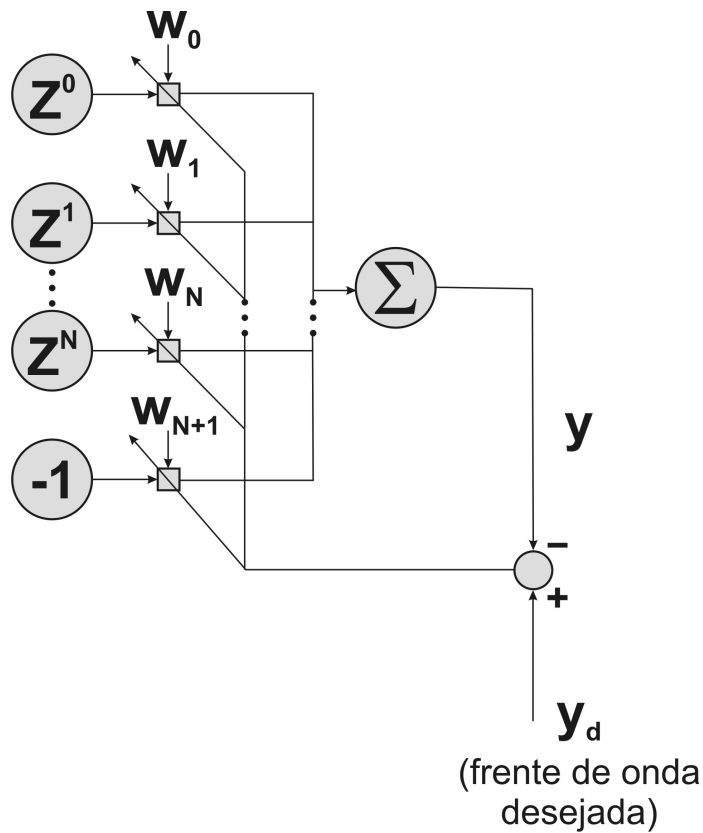


Figura 4.2: Topologia Adaline

6º - $C_i=1$ para $i=0,2,4$ e $C_i =0,1$ para $i=1,3,5,6$;

7º - primeiro teste acrescido de um $C_7 = 0,1$;

8º - primeiro teste acrescido de um $C_7 = 1$;

9º - primeiro teste acrescido de um $C_7 = 2$.

O algoritmo também pode ser utilizado para coeficientes não unitários, resultando em uma saída linearmente alterada.

A seguir é mostrado o objetivo de cada teste:

1º verificar a convergência geral, demonstrando a capacidade de recuperar os coeficientes da saída com todos eles diferentes de zero;

2º-4º verificar a capacidade de recuperar o único coeficiente diferente de zero da saída;

- 5°-6° verificar a capacidade de recuperar uma saída cujos coeficientes estão associados a aberrações com alto grau de assimetria (neste caso tilt x, defocus e astigmatismo)
- 7°-9° verificar a eficiência do algoritmo na recuperação de uma saída composta com mais coeficientes que a entrada.

O algoritmo convergiu do primeiro ao sexto teste em uma época e com *mse* final da rede inferior a $1e - 6$. Isso significa que para valores de coeficientes tomados em microns, o erro estará abaixo de $1e - 6 \mu\text{m}$.

O algoritmo não convergiu do sétimo ao nono, sendo interrompido após 1000 épocas, com um *mse* da rede no sétimo teste em torno de $1e - 3$ e no nono em 0,4. Visto que a complexidade da saída é maior do que a capacidade de combinação dos polinômios da entrada, era esperado que o erro de aproximação aumentasse.

O resultado dos testes mostram que o método Adaline pode ser adotado, tendo conseguido recuperar os coeficientes iniciais nos seis primeiros testes e do sétimo em diante foi capaz, através do aumento do erro quadrático médio, de inferir a presença de mais elementos na saída, o que serviria de sinal para que a próxima iteração alterasse o número de polinômios na entrada, possibilitando a adequação da método a sistemas ópticos de correção ou caracterização de aberrações.

4.2 Aquisição de dados

A aquisição dos dados de leitura do sensor de frentes de onda foi feita por intermédio de uma placa ETHERNET de 10Mbits/s, adaptada para fornecer sinais de sincronismo ao mux do sensor de frentes de onda e receber sinais de tensão. Além disto ela possui um sistema cliente/servidor baseado em protocolo UDP (User Datagram Protocol), que empacota os valores de tensão digitalizados e os envia a qualquer cliente conectado em uma rede.


Este sistema de coletas de dados é diferenciado por ser modular e portátil. Como não se trata de uma placa de aquisição ligada diretamente a um computador, os dados podem ser coletados remotamente e enviados via link de rede ao local onde serão analisados.

A adoção do protocolo UDP foi escolhida pela sua rapidez de processamento e envio dos dados em relação ao TCP (Transmission Control Protocol). Porém o aumento de velocidade é feito em detrimento da confiabilidade dos dados entregues. Em função disto o sistema possui rotinas de confirmação de envio e recebimento das informações, que estão implantadas no cliente/servidor da placa e no software cliente.

O UDP é um protocolo de datagramas de utilizador (ou usuário). O UDP faz a entrega de mensagens independentes, designadas por datagramas, entre aplicações ou processos, em sistemas host. A entrega é não confiável, porque os datagramas podem ser entregues fora de ordem ou até perdidos. A integridade dos dados pode ser gerenciada por um "checksum" (um campo no cabeçalho de checagem por soma).

Interface para placa ETHERNET

Segue na Figura 4.3 a pinagem do sensor de frentes de onda. A vista é da parte traseira da caixa que contém esse sensor.



Pino	Função
1	Analog 1 (saída)
3	Analog 2 (saída)
5	Analog 3 (saída)
7	Analog 4 (saída)
9	Analog 5 (saída)
11	Analog 6 (saída)
13	Analog 7 (saída)
15	Analog 8 (saída)
2	Digital 1 (entrada)
4	Digital 2 (entrada)
6	Digital 3 (entrada)
8	Digital 4 (entrada)
10	Digital 5 (entrada)
12	- 12 V
14	+ 12 V
18	+ 5 V
17	terra
19	terra
20	Terra
16	nc

Figura 4.3: Pinagem do sensor

O sensor de frentes de onda possui 8 saídas analógicas, correspondentes à tensão em cada região de um pixel do sensor. As entradas digitais são responsáveis pela seleção do pixel do qual serão feitas as medições.

Para a aplicação desejada, muitas das entradas e saídas dessa placa não foram utilizadas. Só foram usadas para ligar ao sensor de frentes de onda

Pinos	Função
3	-12 V
4	+12 V
8	Entrada 1
9	Entrada 2
11	Entrada 3
12	Entrada 4
14	Entrada 5
15	Entrada 6
17	Entrada 7
18	Entrada 8
7	Terra
10	Terra
13	Terra
16	Terra
19	Terra
27	Terra
30	Terra
33	Terra
36	Terra

Figura 4.4: Entradas analógicas (conector DB37 macho)

as entradas analógicas e as saídas digitais. As Figuras 4.4 e 4.5 mostram os pinos funcionais para a montagem.

Pinos	Função
6	Saída 0
7	Saída 2
8	Saída 4
25	Saída 1
26	Saída 3
19	Terra digital

Figura 4.5: Saídas digitais (conector DB37 fêmea)

Pelas figuras 4.4 e 4.5 percebe-se a necessidade de se conectar vários pinos ao mesmo ponto, como ao terra. Para facilitar a ligação da placa de aquisição ao sensor e ambas à fonte, foi montada uma placa de circuito impresso que une esses três equipamentos. O diagrama da placa é mostrado na Figura 4.6:

A Figura 4.6 mostra as entradas digitais do sensor ligadas às saídas digitais do conector DB37 fêmea e suas saídas analógicas ligadas às entradas analógicas do conector DB37 macho. As tensões de alimentação -12 e +12 V são fornecidas pela placa ethernet. Uma fonte externa precisa fornecer a tensão de 5 V para o sensor, 3,3 V para a placa que simulará os sinais




Figura 4.6: Diagrama da placa de interface

digitais e o terra. A conexão dessa fonte se dá na região inferior da placa. A placa que simula os sinais digitais serve para testar os pixels do sensor de frentes de onda. Ela fornece uma tensão de 3,3 V ao sensor para nível alto e 0 V para nível baixo. Ela será útil principalmente nessa fase inicial de testes, o objetivo final é fazer com que os sinais digitais partam da placa ethernet. Observe que todos os terras foram curto-circuitados e ligados ao terra da fonte, algo que só pode ser feito com tamanha organização devido a essa placa de circuito impresso.

4.3 Adaline no Sistema Óptico

Modos do espelho, ou funções de influência, são obtidos quando aplicamos a um eletrodo do espelho um incremento de tensão. Assim podemos construir 37 modos, cada qual resultando em um arranjo característico dos 16 pontos luminosos projetados pela máscara de Hartmann no *chip*, gerando um vetor com 16 valores de coordenada x e um número igual de valores de coordenada y . Esses vetores de modos podem ser utilizados como funções de base e servir como entrada do algoritmo Adaline mostrado na Figura 4.2. A topologia da rede modificada é mostrada na Figura 4.7. Cada vetor modo (M^i) é composto por 32 elementos e, como no método anterior, a saída Y do algoritmo é comparada com a saída desejada Y_d , representando o vetor de coordenadas associadas a frente de onda a ser corrigida. Através da minimização do *mse* de $Y - Y_d$ são encontrados os melhores valores dos pesos w_i . Neste método os pesos w_i ($N=1, \dots, 37$) referem-se aos valores de tensão que serão aplicados ao espelho.

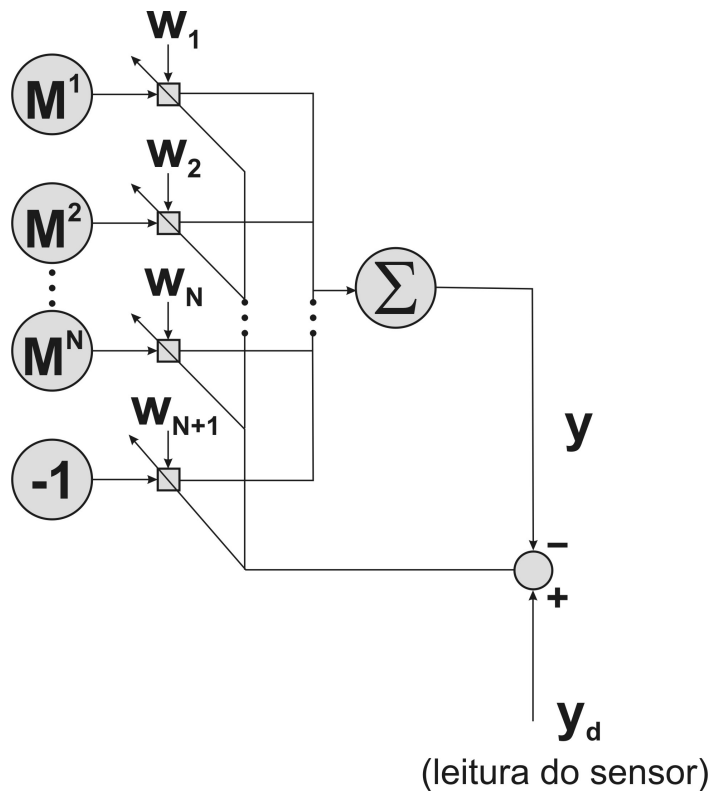


Figura 4.7: Adaline com modos na entrada

4.3.1 Algoritmo Adaline

O algoritmo Adaline implementado computacionalmente segue basicamente os seguintes passos mostrados no fluxograma da Figura 4.8:

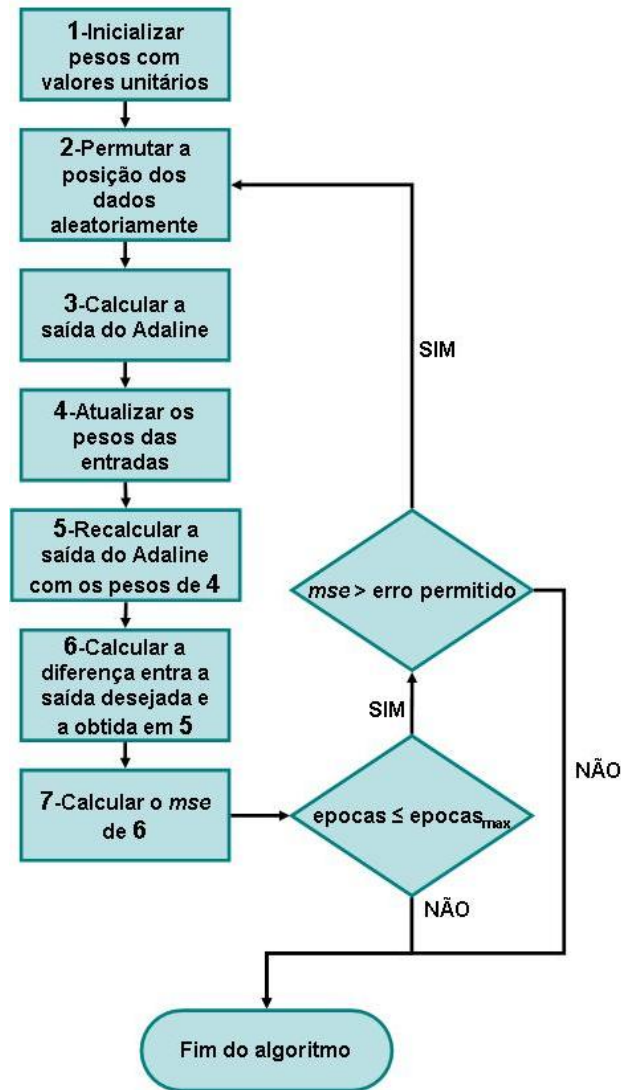


Figura 4.8: Fluxograma do algoritmo Adaline

Para ilustrar uma iteração do Adaline com as entradas baseadas nos polinômios de Zernike (cada qual representado por sua amplitude em um *grid* de quatro pontos distintos Figura 4.9) os itens 2, 3, 4 e 7 do fluxograma são mostrados de maneira esquemática, para N entradas, na Figura 4.10. No item 2 é mostrada a permutação termo a termo dos elementos constituintes

das matrizes de entrada Z^i e da saída desejada Y_d . Esta permutação é feita aleatoriamente a cada época do algoritmo, afim de evitar que o mesmo caia em um mínimo local. No item 3 é apresentado como se realiza o cálculo matricial da saída Y do algoritmo. No item 4 são mostrados todos os elementos que envolvem a atualização dos pesos w_i^l em cada época l . Finalmente no item 7 faz-se o cálculo do critério de convergência da rede (mse).

Vale ressaltar que para se detectar os polinômios de Zernike Z^i presentes em uma aberração, obtida através dos sensor de frentes de onda, é necessário construir uma base de i dados com leituras do sensor submetido a Z^i polinômios aplicados ao Espelho Adaptativo [24].

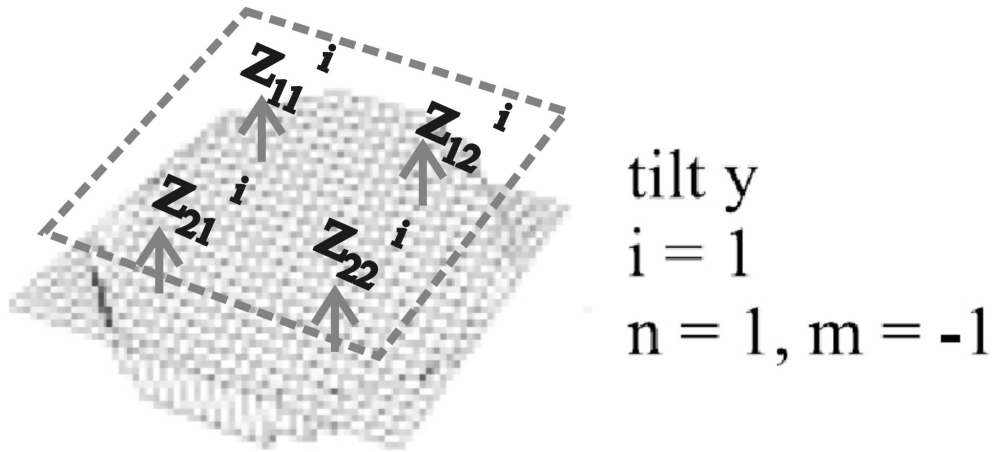


Figura 4.9: Formação do *grid* de um polinômio de Zernike

A Figura 4.11 mostra os mesmos itens da Figura 4.10 para entradas baseadas nas respostas de duas quadricélulas aos modos M^i do Espelho Adaptativo. A resposta de cada quadricélula consiste em um par de coordenadas (x, y) , portanto a permutação do item 2 é feita aos pares. Desta forma, para uma entrada M^i a saída de cada quadricélula é um par (m_{qx}^i, m_{qy}^i) , onde o sub-índice qx representa a resposta da coordenada x ao ponto de luz incidente na quadricélula q . De forma análoga o mesmo vale para qy . A saída desejada Y_d segue o mesmo padrão tendo como par coordenado (y_{qx}^d, y_{qy}^d) .




Figura 4.10: Algoritmo Adaline com Zernike




Figura 4.11: Algoritmo Adaline com Modos do Espelho Adaptativo

4.4 Resultados

Inicialmente analisamos uma frente de onda sujeita à aberração focal com amplitude de $36\mu\text{m}$ ($> 55 \lambda$). Esse valor é muito maior que a excursão mecânica do centro da membrana reflexiva e tem como propósito verificar a capacidade de convergência do algoritmo. A frente de onda desfocada explora o alcance espacial dinâmico das QC's, forçando o deslocamento dos pontos luminosos para suas bordas. A cada época do algoritmo, o S_{opt} mostra quão próximo está o vetor de saída do vetor desejado, referente a onda com aberração focal. Para todas as épocas o erro de deslocamento associado ao S_{opt} foi inferior a 1%. A resolução de posicionamento, normalizada para os deslocamentos de -1 a 1, é dada pelo desvio padrão D_{opt_rede} e está relacionada com S_{opt} de acordo com a equação 4.3.

$$D_{opt_rede} = \frac{\sqrt{S_{opt}}}{(N + 2)} \quad (4.3)$$

onde N é o número de modos do espelho e o S_{opt} é dado pela equação 4.4. O denominador $(N + 2)$ normaliza o valor do D_{opt_rede} retirando a influência do Adaline. Na Figura 4.12 é exemplificado como se chega a equação 4.3, considerando-se três modos e duas quadricélulas, através de uma análise dimensional.

$$S_{opt} = \frac{1}{K - 1} \sum_{i=1}^K \left((Y_d - Y) - \left(\sum_{i=1}^K \frac{(Y_d - Y)}{K} \right) \right)^2 \quad (4.4)$$

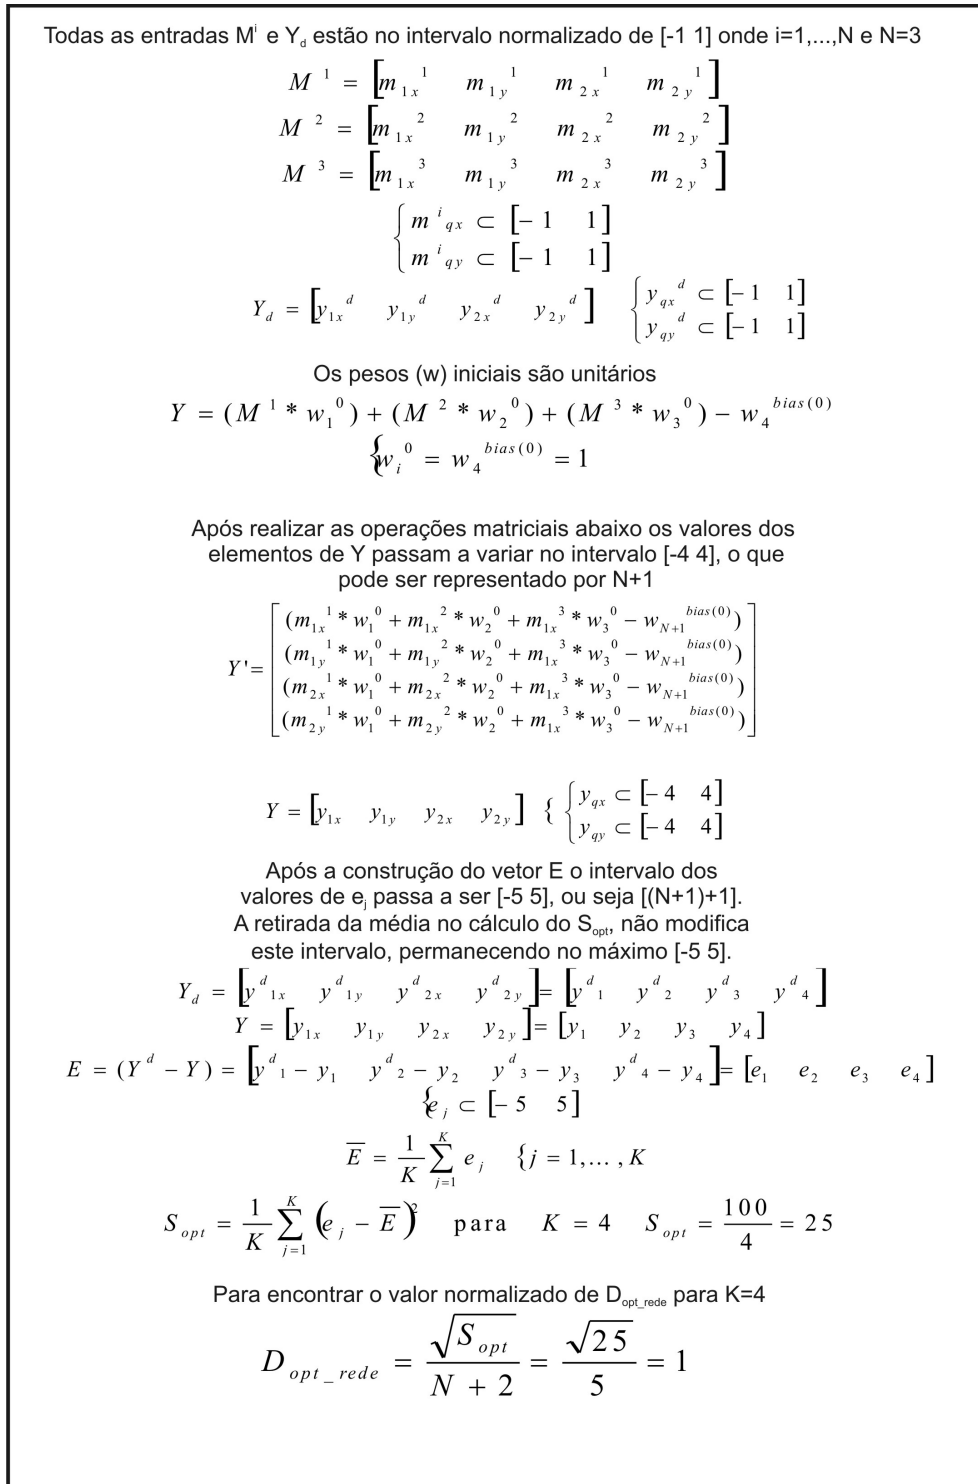


Figura 4.12: Cálculo de D_{opt_rede}

A Figura 4.13 apresenta erro de posição normalizado em relação ao número de épocas. O erro foi computado em função do número de épocas gastos pelo Adaline para encontrar a composição de modos que constituem a aberração da Figura 4.14. No início a descida é mais íngreme, em função da saída do Adaline estar muito distante do vetor desejado (Figura 4.14). Após alcançar uma saída próxima ao vetor desejado o Adaline progride mais lentamente, em função dos erros de arredondamento tornarem-se mais significativos e do passo η arbitrado. Para todas as épocas o erro é inferior a 1% do valor desejado.




Figura 4.13: ($rms = \sqrt{mse}$) em função do número de épocas

Depois foi introduzido uma aberração suave com amplitude $\lambda/2$ (Figura 4.14) para verificar a convergência do algoritmo.

Quando o algoritmo neural é iniciado com pesos unitários, ele alcança em uma única época um solução aceitável, isto é um frente de onda melhor que $\lambda/50$. Depois de $\sim 80s$ e 1.5M épocas o mse chega a 0.00017 ($D_{opt} < 3e^{-3}$), que corresponde a uma frente de onda melhor que $\lambda/5000$).

Na prática, distorções dinâmicas em uma determinada frente de onda ocorrem suavemente e os pesos da rede dentro de um certa faixa limitada. Através de uma ligeira modificação na frente de onda ($\sim \lambda/16$ rms) registrou-se a convergência do algoritmo em uma única época em 200 μs , com um $mse=0.0018$ (precisão de $\sim \lambda/1000$). A Figura 4.15 mostra a aberração residual introduzida.

Como o sensor tem sido lido a 1kHz (1ms) e as rotinas de software rodam a menos de 400 μs , o sistema tem potencial para operar a taxas de 600 Hz.




Figura 4.14: Forma da frente de onda da deformação analisada, que contém, principalmente, coma, astigmatismo, trefoil e deformação esférica. No canto superior à direita: interferograma da frente de onda.

Para testar o efeito de uma interação do Sistema Óptico Adaptativo, nós compensamos parcialmente a aberração da Figura 4.14 aplicando ao espelho uma tensão proporcional aos pesos encontrados para o $mse = 0.0018$. Os pontos de luz resultantes coincidiram com o *grid* de referência em uma margem de $\sim 10\%$, o que corresponde aproximadamente a $\lambda/5$. Isto indica que em uma única interação já alcançam uma frente de onda com precisão de $\lambda/4$ usualmente demandada por teste simples no olho, onde aberrações de baixa ordem são dominantes e tão altas quanto 5λ [25].

Para melhorar a precisão é necessário empregar uma frente de onda [26] de referência mais precisa e aumentar o número de quadricélulas, diminuindo a frequência de operação do sistema. No caso de uma aplicação oftalmológica, onde as micro-flutuações do olho podem chegar a 90Hz, o sistema ainda permitiria opere cerca de 3 iterações caso operasse a 300 Hz.

Para finalizar foram realizados testes de identificação dos termos de Zernike presentes em um feixe de laser de 6mm de diâmetro, com aberrações originadas por lentes de distância focal igual a 1000mm e 750mm. A entrada do Adaline foi formada por nove polinômios de Zernike, cada um constituído de um vetor de trinta e dois elementos, que como nos modos, representam




Figura 4.15: Aberração residual

dezesesseis pares de coordenadas x e y . Estas coordenadas foram geradas por meio de um algoritmo, que simula a leitura obtida por um sensor de frentes de onda submetido a um determinado polinômio de Zernike.

A primeira aberração analisada (Figura 4.16) foi um coma obtido pelo posicionamento da lente de 1000mm descentralizada em relação ao feixe do laser, como pode ser observado no esquema da Figura 4.17. Os pesos do Adaline obtidos após o treinamento são mostrados na Figura 4.18, onde pode ser observado que o maior peso está no termo w_5 correspondente a Z_5 que representa coma (vide seção 3.1.1).




Figura 4.16: Aberração: coma; lente com distância focal=1000mm, descentralizada




Figura 4.17: Posição do feixe em relação a lente - primeira aberração

w0	→	0.711073
w1	→	-0.823192
w2	→	0.414928
w3	→	-0.72324
w4	→	-0.552896
w5	→	1.132429
w6	→	-0.700573
w7	→	-0.547246
w8	→	-0.752855

Figura 4.18: Pesos do Adaline após treinamento - primeira aberração

Como a frente de onda de referência não é plana (Figura 4.19) os gráficos das aberrações desse teste e os valores dos pesos finais após o treinamento, foram obtidos após a retirada do componente de referência. As componentes de w_0 e w_1 que representam o *tiltx* e *tilty*, não são relevantes para a análise, visto que podem ser eliminadas por um espelho do tipo *tip-tilt*, descrito na seção 3.2.2.




Figura 4.19: Aberração imposta pelo sistema

A segunda aberração analisada (Figura 4.20) foi um coma obtido pelo posicionamento da lente de 1000mm com maior centralização em relação ao feixe do laser (Figura 4.21). Os pesos do Adaline obtidos após o treinamento são mostrados na Figura 4.22, onde pode ser observado que o maior peso está no termo w_5 correspondente a Z_5 que representa coma (vide seção 3.1.1). Com a maior centralização, é possível observar pelos valores dos pesos que o coma diminuiu e a componente w_2 que representa foco aumentou.




Figura 4.20: Aberração: coma; lente com distância focal=1000mm, centralizada


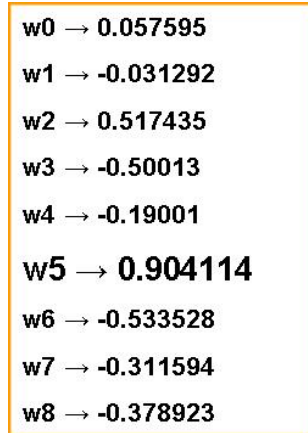


Figura 4.21: Posição do feixe em relação a lente - segunda aberração



w0	→	0.057595
w1	→	-0.031292
w2	→	0.517435
w3	→	-0.50013
w4	→	-0.19001
w5	→	0.904114
w6	→	-0.533528
w7	→	-0.311594
w8	→	-0.378923

Figura 4.22: Pesos do Adaline após treinamento - segunda aberração

O terceiro teste foi substituir a lente de 1000mm por uma de 750mm de foco, com feixe de laser descentralizado. A aberração obtida é mostrada na Figura 4.23. Através da observação dos pesos de treinamento da rede mostrados na Figura 4.24, vê-se que a componente focal $w2$ aumentou, o que era esperado pelo valor da distância focal da lente, com a continuidade do coma $w5$.




Figura 4.23: Aberração: coma; lente com distância focal=750mm, centralizada



Figura 4.24: Pesos do Adaline após treinamento - terceira aberração

O método foi bastante eficaz apesar das dificuldades técnicas que limitaram o experimento:

- Entrada do Adaline truncada em nove termos. Caso a aberração possua termos de Zernike de ordem superior (maior frequência espacial), estes afetarão no resultado (seção 4.1), devido a representação sub-ótima destes termos pelos presentes na entrada.
- Amostragem das aberrações feita com 16 quadricélulas (3.3.2), para adequação da frequência de funcionamento do sensor à frequência de aquisição de dados. Esta sub-amostragem da frente de onda incidente afeta no resultado, pois para termos uma boa precisão a nível oftálmico precisamos de no mínimo 25 quadricélulas.
- Problema de sobreposição entre as tensões lidas do sensor pela placa de aquisição de dados, durante a multiplexação. O resquício de tensão na linha de sinal afeta o cálculo das coordenadas x e y , diminuindo a precisão da leitura da frente de onda. A Figura 4.25 ilustra este fato.
- A resposta das quadricélulas foi considerada linear, porém ela é sigmoïdal. Esta aproximação também afeta a leitura de tensões do sensor e como no item anterior insere um erro no cálculo das coordenadas x e y , prejudicando a precisão da leitura da frente de onda. Seria necessário um modelamento do sensor para obter a resposta correta.

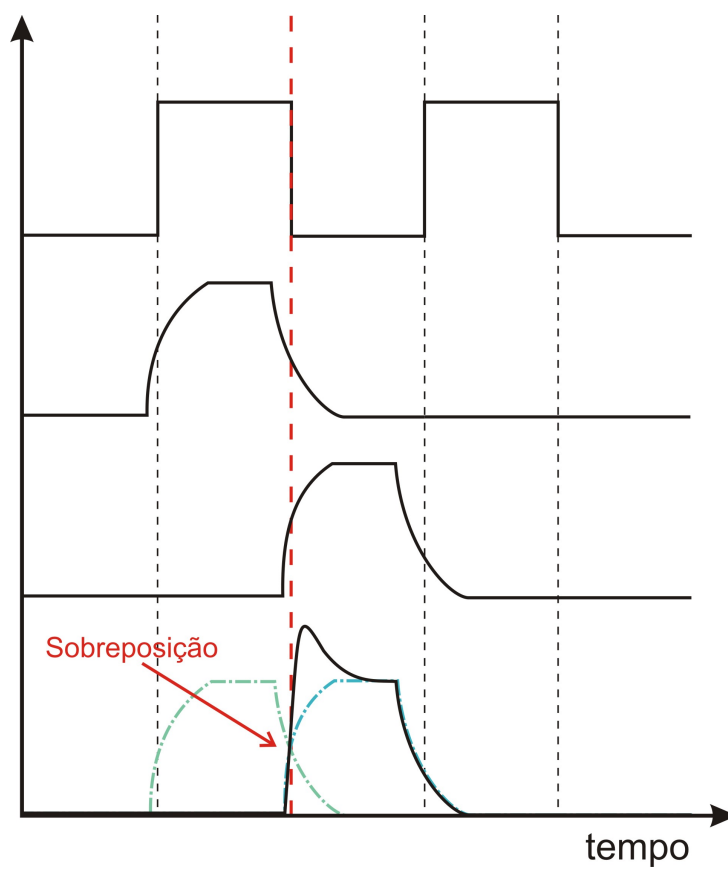


Figura 4.25: Sobreposição das tensões durante a multiplexação

Capítulo 5

Conclusões e Trabalhos Futuros

Neste trabalho foram estudadas alternativas para os métodos de diagnóstico de aberrações ópticas e de controle de um sistema óptico adaptativo. Essa alternativas se basearam em métodos neurais simples como substitutos para o método convencional de mínimos quadrados com inversão de matrizes e pivoteamento Gaussiano. Verificou-se que redes MLP apresentam falhas de convergência e que o método Adaline com topologia elementar foi capaz de atender os critérios de precisão e frequência de processamento desejados, além de oferecer a possibilidade de adaptabilidade do número de entradas em tempo real.

Os resultados foram promissores e demonstram a potencialidade de Sistemas Ópticos Adaptativos. Através da detecção precisa de frentes de onda e de sua correção dinâmica poder-se-á conceber perfis de lentes de contato personalizadas, melhorar a observação in vivo da retina ou mesmo monitorar dinamicamente a magnitude de aberrações durante cirurgias refrativas. A utilização de um método neural como algoritmo de controle trouxe maior adaptabilidade ao sistema sem prejuízo da qualidade do resultado. Melhorias no design do *chip*, podem aumentar sua frequência de operação, incrementando a velocidade de aquisição dos dados.

Há que se estudar ainda, qual a relação ótima dos pesos finais do algoritmo Adaline e as tensões aplicadas ao espelho, bem como a precisão que pode ser alcançada, em termos de λ , com um maior número de iterações. Além disso a adesão de outros métodos de otimização ao Adaline, podem melhorar seu tempo de convergência e diminuir o erro, associado ao algoritmo, de reconstrução da frente de onda.

Apêndice A

Rotina em C

```
int index_transform (M) int *n, *m; {
    int i, j, k;
    i = k = 0;
    while (i <= M)
    {
        for (j = k % 2; j <= k; j += 2)
        {
            n[i]=k; m[i]=j;
            i++;
            if (j != 0)
            {
                n[i]=k; m[i]=(-j);
                i++;
            }
        }
        k += 1;
    }
    j = i - 1;
    for (i=0; i < M; i++)
    {
        n[i] = n[i + 1]; m[i] =m[i + 1];
    }
    return j;
}
```

Referências Bibliográficas

- [1] Haykin S. *Redes Neurais - Princípios e prática*. Bookman, Porto Alegre, 2 edition, 2001.
- [2] G. Vdovin. Model of an adaptive optical system controlled by a neural network. *Opt. Engineering*, 34(11):3249–3253, novembro 1995.
- [3] Carvalho LA. Aplicação de redes neurais na implementação de um sistema de auxílio ao diagnóstico em um instrumento médico hospitalar. *Física Aplicada e Instrumentação*, 16(2), junho 2003.
- [4] D. W. de Lima Monteiro. *CMOS-based integrated wavefront sensor*. Delft University Press Science, Delft, 2002.
- [5] A.P.L.F. e Ludemir T.B. Braga, A.P.; Carvalho. *Fundamentos de Redes Neurais Artificiais*. XI Escola Brasileira de Computação, Rio de Janeiro, 11 edition, 1998.
- [6] W. S.; McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity,.
- [7] G. E. Rumelhart, D. E.; Hinton and R. J. Williams. Learning internal representations by error propagation. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition I*, pages 318–362, 1986.
- [8] B. Widrow; and M. E. Hoff. Adaptive switching circuits. *WESCON Convention Record*, 1960.
- [9] F. Rosenblatt. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65:386–408, 1958.
- [10] G. Vdovin; S. Middelhoek; P.M. Sarro. Technology and applications of micromachined silicon adaptive mirrors. *Optical Engineering*, 36:1382–1390, 1997.

- [11] M. Born and E. Wolf. *Principles of Optics*. Pergamon Press, Oxford, 6 edition, 1986.
- [12] D. W. de Lima Monteiro e G. Vdovin. Nos limites da visão - um desafio para a óptica adaptativa. *Ciência Hoje*, 32(188):32–37, novembro 2002.
- [13] H.M. Dyson; R.M. Sharples; N.A. Dipper; G.V. Vdovin. *Optics Express*, 8/1, 2001.
- [14] D. Dayton; S. Restaino; J. Gonglewski; J. Gallegos; S. McDermott; S. Browne; S. Rogers; M. Vaidyanathan; M. Shilko. *Optics Communications*, 176:339–345, 2000.
- [15] F. Druon; G. Cheraux; J. Faure; J. Nees; M. Nantel; A. Maksimchuk; G. Mourou; J.C. Chanteloup; G. Vdovin. *Optics Letters*, 23:1043, 1998.
- [16] G. Vdovin; V. Kiyko. *Optics Letters*, 26/11:798–800, 2001.
- [17] W. Lubeigt; G. Valentine; J. Girkin; E. Bente; D. Burns. *Optics Express*, 10/13:550–555, 2002.
- [18] E. Fernandez; I. Iglesias; P. Artal. *Optics Letters*, 26/10:746–748, 2001.
- [19] Chi-Tsong Chen. *Linear System Theory and Design*. OUP, 1998.
- [20] B C Kuo. *Automatic Control Systems*, volume 8th edn. John Wiley and Sons, 2002.
- [21] R K Tyson. *Principles of Adaptive Optics*. Academic Press, 1991.
- [22] F Roddier. *Adaptive Optics In Astronomy*. CUP, 1999.
- [23] A P L; Ludemir TB. Braga, A P; Carvalho. *Redes Neurais Artificiais: Teoria e Aplicações*. JC Editora.
- [24] L. Zhu; P. Sun; D. Bartsch; W. Freeman and Y. Fainman. Wave-front generation of zernike polynomial modes with a micromachined membrane deformable mirror. *Applied Optics*, 38(28):6019–6026, 1999.
- [25] J. Liang. *A new method to precisely measure the wave aberrations of the human eye with a Hartmann-Shack-Wavefront-Sensor*. Phd thesis, University of Heidelberg, 1991.
- [26] G Vdovin. Optimization-based operation of micromachined deformable mirrors. In *Proc. SPIE*, volume 3353, pages 902–909, 1998.