ROBSON BARCELLOS

Novo método de mapeamento de espaços de cor através de redes neurais artificiais especializadas.

Tese apresentada à Escola de Engenharia de São Carlos da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Doutor em Ciências, Programa de Engenharia Elétrica.

Área de Concentração: Telecomunicações

Orientador: Prof. Dr. Luiz Gonçalves Neto

Co-orientador: Prof. Dr. Giuseppe Antonio

Cirino

São Carlos 2011

Trata-se da versão corrigida da tese. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica preparada pela Seção de Tratamento da Informação do Serviço de Biblioteca – EESC/USP

Barcellos, Robson.

B242n

Novo método de mapeamento de espaços de cor através de redes artificiais especializadas / Robson Barcellos ; orientador Luiz Gonçalves Neto e co-orientador Giuseppe Antonio Cirino. São Carlos, 2011.

Tese (Doutorado - Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Telecomunicações) -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2011.

1. Redes neurais artificiais. 2. CIE. 3. Colorímetro. 4. Espaços de cor. 5. Mapeamento. 6. Matriz pseudo-inversa. 7. ColorChecker®. 8. Notação Munsell. 9. CIELAB. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro ROBSON BARCELLOS

Título da tese: Novo método de mapeamento de espaços de cor através de redes neurais artificiais especializadas.

Data da defesa: 24/08/2011:

Comissão Julgadora:

Prof. Dr. Giuseppe Antonio Cirino (Substituto) (Universidade Federal de São Carlos/UFSCar)

Prof. Associado Ivan Nunes da Silva (Escola de Engenharia de São Carlos/EESC)

Prof^a Associada Liliane Ventura Schiabel (Escola de Engenharia de São Carlos/EESC)

Prof. Dr. José Carlos Pizolato Junior (Universidade Federal de São Carlos/UFSCar)

Prof. Dr. João Eduardo Kögler Junior (Escola Politécnica/USP) Resultado:

APROVADO

ARBULARD

APROYADO

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica: Prof. Titular **Denis Vinicius Coury**

Presidente da Comissão de Pós-Graduação: Prof. Associado Paulo Cesar Lima Segantine

Este trabalho é dedicado a minha esposa Heleusa e ao meu filho William, prêmios que me foram concedidos por Deus ao colocá-los em minha vida.

AGRADECIMENTOS

Meus agradecimentos iniciais vão para o Prof. Dr. Luiz Gonçalves, pela atenção que me foi dispensada durante todas as fases de desenvolvimento desta pesquisa, e pelas suas orientações, de fundamental importância para que ela fosse concluída com êxito.

Não poderia deixar de agradecer ao Prof. Dr. Giuseppe Cirino, pelas contribuições e orientações. Freqüentes foram as ocasiões em que discutimos longamente sobre o direcionamento da pesquisa. Agradeço também pelo paciente trabalho de revisão dos "manuscritos" e pelas sugestões de melhoria. Não passou despercebido seu entusiasmo e vontade de cooperar.

Agradeço também minha esposa Heleusa e meu filho William, que suportaram longos períodos de minha ausência, enquanto estive dedicado a esta pesquisa.

RESUMO

Este trabalho apresenta uma nova metodologia para mapeamento no espaço de cor colorimétrico CIEXYZ, dos valores de triestímulo obtidos em um espaço de cor não colorimétrico definido pelas curvas de sensibilidade de um sensor eletrônico. A inovação do método proposto é realizar o mapeamento através de três redes neurais artificiais sendo que cada uma é especializada em mapear cores com um determinado triestímulo dominante. É feita a comparação dos resultados do mapeamento com vários trabalhos publicados sobre mapeamento de um espaço de cor em outro usando diversas técnicas. Os resultados mostram a eficiência do método proposto e permitem sua utilização em equipamentos para medir cores, incrementando sua precisão.

Palavras-chave: CIE, colorímetro, espaços de cor, mapeamento, redes neurais artificiais, matriz pseudo-inversa, ColorChecker®, notação Munsell, CIELAB.

ABSTRACT

This work presents a new method for mapping a non colorimetric color space defined by the sensitivity curves of an electronic color sensor to the colorimetric color space CIEXYZ. The novelty of the proposed method is to perform the mapping by a set of three artificial neural networks, each one specialized in mapping colors with a specific dominant tristimulus. The results are compared with the ones obtained in published works about the mapping of color spaces, using several methods. The results of the method proposed in this work show that it is efficient and it can be used in equipments for measuring colors, improving its precision.

Keywords: CIE, colorimeter, color spaces, mapping, artificial neural network, pseudo inverse matrix, Munsell notation, ColorChecker®, CIELAB.

LISTA DE ABREVIATURAS E SIGLAS

A.C. Antes de Cristo

ASD Advanced Systems Development

CCD Charge-coupled Device

CMC Color Measurement Committee

CMF Color Matching Function

D.C. Depois de Cristo

IR Infrared

ISO International Organization for Standardization

JND Just Noticeable Difference

LCD Liquid Cristal Display

LS Least Square

LUT Lookup Table

MDE Metamer Density Estimated Color Correction

MLP Multi Layer Perceptron

NCS Natural Color System

NIR Near Infrared

OL Optronic Laboratories

PS Pattern Search

RPM Regressão Polinomial Múltipla

SOCS Standard Object Color Spectra

SPD Spectral Power Distribution

TAOS Texas Advanced Optoelectronic Solutions Inc

TCDM Total Color Difference Minimization

TLS Total Least Squares

UV Ultraviolet

VIS Visible

YNSN Yule-Nielsen Spectral Neugebauer

SUMÁRIO

Capítu	ılo I - Introdução	. 1	
1.1.	Considerações iniciais		
Capítu	ılo II – Revisão bibliográfica	. 3	
2.1.	Introdução ao problema a ser resolvido		
2.2.	Métodos de solução encontrados na literatura		
Capítulo III - Um rápido histórico sobre a visão a cores humana 7			
3.1.	Os primeiros conceitos dos gregos	. 7	
3.2.	A idade média		
3.3.	A era moderna da luz e visão	-	
Capítulo IV – Percepção de cores e espaços de cor9			
4.1.	O processo de percepção de cores		
4.2.	A natureza psicofísica da visão humana de cores	10	
4.3.	Casamento de cores		
4.4.	A natureza tricromática da visão humana		
4.5.	O experimento de casamento de cores	13	
4.6.	Função de casamento de cores (Color-Matching Function - CMF)		
4.7.	A especificação do triestímulo	15	
4.8.	Diagrama de cromaticidade CIE 1931	16	
4.9.	O espaço de cor CIE - <i>L</i> * <i>a</i> * <i>b</i> * 1976 ⁽¹⁾	17	
4.10.	O sistema de ordenamento de cor Munsell	22	
Capítu	ılo V – Equipamentos usados para medir cor	25	
5.1.	Espectroradiômetros		
5.2.	Espectrofotômetros	26	
5.3.	Colorímetros	28	
Capítulo VI - O problema de mapeamento do triestímulo			
6.1.	Sensores e espaços de cor colorimétricos		
6.2.	O ColorChecker®	33	
6.3.	Diferenças na medida do triestímulo	35	
Capítu	ılo VII – Métodos de mapeamento do triestímulo	37	
7.1.	Mapeamento usando a matriz pseudo-inversa	37	
7.2.	O mapeamento usando regressão polinomial	39	
7.3.	O novo método de mapeamento de espaços de cor proposto	41	
7.3.1.	O mapeamento usando redes neurais artificiais	41	
7.3.2.	O mapeamento usando redes neurais artificiais especializadas	51	
7.3.3.	Principais inovações e contribuições do método	64	
	ılo VIII – Resultados obtidos		
Capítu	ılo IX – Desenvolvimentos futuros	79	
9.1.	Estudo de novas arquiteturas	79	
9.2.	Estudo para melhoria de desempenho da rede G	79	
9.3.	Aplicação da segmentação do espaço de cores em outros métodos	79	
Capítulo X – Conclusão			
Referências Bibliográficas 8			
APÊNDICE A			
Tabela de comparação de resultados 8			
ANEXO A9			

Dados Espectrais	91
ANEXO B	97
Especificação de Equipamentos	

Capítulo I - Introdução

1.1. Considerações iniciais

Todos os cinco sentidos do ser humano são importantes para orientá-lo no relacionamento com o meio em que está, porém o sentido da visão se destaca devido a sua complexidade e também pela sua abrangência em termos de percepção. Através da visão, pode-se perceber a forma, o tamanho, a distância, a posição e a cor dos objetos que nos cercam. Das características percebidas pela visão, certamente a cor é a que mais nos impressiona, não só pelo grande número de cores que são percebidas, mas também por nos proporcionar uma capacidade de discriminação entre objetos para os quais outras características percebidas sejam iguais. Assim, dois objetos podem ter a mesma forma, o mesmo tamanho, estar à mesma distância e na mesma posição, porém serem diferenciados unicamente pela sua cor.

Por ser um fenômeno psicofísico, a percepção das cores influencia psicologicamente na percepção de outras características. Por exemplo, cores mais avermelhadas são intuitivamente associadas a temperaturas mais elevadas, e por isto chamadas de cores "quentes". Evocam emoções fortes e até mesmo a raiva e a violência. As cores azuladas são relacionadas com temperaturas mais baixas e chamadas de cores "frias" e são calmantes e relaxantes. [1].

Por esta característica de influenciar psicologicamente as pessoas, as cores são exploradas para direcionar seu comportamento e, portanto passam a ser valorizadas comercialmente, dando origem a uma atividade, exercida principalmente dentro das empresas, que é o "gerenciamento de cores".

Para desempenhar a atividade de "gerenciamento de cores", é necessário realizar, entre outras tarefas, especificar, medir e comparar cores. Estas tarefas são realizadas através de equipamentos que medem a cor dos objetos e normalmente podem ser de 3 tipos: espectroradiômetros, espectrofotômetros e colorímetros [2].

Um aspecto relevante na quantificação de cores está relacionado com o problema de mapear os valores das cores medidas através de um sensor eletrônico em um espaço de cor colorimétrico, isto é, independente das características do dispositivo, e definido por entidade

normativa internacional. Este problema consiste em se encontrar um mapeamento do espaço de cor definido pelo sensor no espaço de cor padronizado. Diversos métodos têm sido usados para realizar este mapeamento: tabela de pesquisa multidimensional com interpolação, regressão polinomial múltipla, transformação linear, análise de componente principal (PCA) e redes neurais artificiais, entre outros [3].

Neste trabalho foi usado inicialmente um processo de mapeamento através de matrizes de transformação linear, mas surgiu a idéia de usar uma Rede Neural Artificial (RNA) para realizar o mapeamento. Os primeiros testes foram feitos, e uma melhora no desempenho da correção foi conseguida em relação ao método inicial. Assim, definiu-se o tema deste trabalho, que é a aplicação de RNAs no mapeamento do espaço de cor definido pelo sensor eletrônico [4], em um espaço colorimétrico definido por entidade normativa internacional.

Capítulo II - Revisão bibliográfica

2.1. Introdução ao problema a ser resolvido

Para se definir ou expressar as cores de uma forma objetiva, é necessário que se desenvolva um sistema de medir cores que transforme a percepção das cores em um código, normalmente numérico ou alfanumérico. Estes sistemas são denominados espaços de cor, onde as cores são expressas como a combinação, em diferentes intensidades, de cores básicas. Existem inúmeros espaços de cor definidos, cuja diferença entre eles é o conjunto de cores básicas utilizadas, que são escolhidas de acordo com a necessidade para cada aplicação.

Equipamentos que utilizam cor, como monitores de vídeo, impressoras, *scanners* e mostradores LCD, definem espaços de cor cujas cores básicas de cada espaço são aquelas determinadas pelas características específicas de seus sensores ou emissores/absorvedores de luz. Estes espaços são denominados "espaços de cor dependentes de dispositivos". Alguns outros espaços de cor foram definidos a partir de cores básicas que não estão associadas a nenhum dispositivo, e são denominados "espaços de cor independentes de dispositivos" [5]. O objetivo destes espaços é de se tornarem espaços padrão para medir ou expressar cores. Alguns deles são pouco conhecidos, mas vários se tornaram padrões consagrados, como L*a*b*, sRGB e CIEXYZ [2].

Quando se tem uma cor expressa em um "espaço de cor dependente de dispositivo", é desejável transformar sua expressão num "espaço de cor independente de dispositivo", e de forma inversa, tendo esta cor inicialmente expressa em um "espaço de cor independente de dispositivo", expressá-la em um "espaço de cor dependente de dispositivo". Como exemplo, tendo-se uma cor expressa no espaço RGB de um monitor de vídeo, é desejável transformá-la num espaço independente, pois a partir deste espaço pode-se transformar esta cor nos espaços dependentes de diversos dispositivos, como o CMYK usado em impressoras ou sRGB usado na Internet. Estas transformações, que podem ser interpretadas como um mapeamento de um espaço em outro, são em geral complexas devido às não linearidades das transformações e diferenças de abrangência das cores em cada espaço [6]. Assim, procura-se determinar funções f_{map1} e f_{map2} que façam o mapeamento de um espaço em outro, como mostrado esquematicamente na Fig. 2.1.

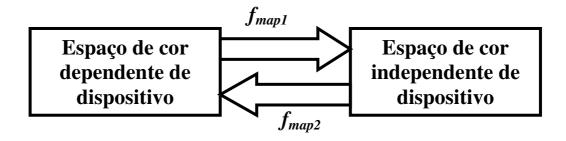


Fig. 2.1- O processo de mapeamento de cores entre espaços de cor.

Vários métodos têm sido usados para encontrar as funções f_{map1} e f_{map2} , para mapear os mais diversos pares de espaços de cor, e devido à complexidade desta tarefa, esta é ainda uma área ativa de pesquisa, como indica o número de trabalhos recentes publicados nesta área. No capítulo VII estão detalhadas as dificuldades inerentes à determinação destas funções.

2.2. Métodos de solução encontrados na literatura

Entre os diversos métodos encontrados na literatura que têm sido usados para encontrar as funções f_{map1} e f_{map2} , foram destacados os trabalhos mencionados a seguir, que mostram que de uma forma geral estas funções são determinadas de forma aproximada.

A matriz pseudo-inversa de Moore-Penrose foi usada por Poynton, C. [7] para mapear o espaço de cor definido por um sensor eletrônico no espaço CIEXYZ, a partir das cores de uma cartela de calibração fotográfica chamada ColorChecker®, que possui 24 cores, e o método usado será descrito em detalhes no capítulo VII deste trabalho. A regressão polinomial múltipla (RPM) foi usada por vários autores para fazer o mapeamento em diversas situações, e com diferentes objetivos. A RPM com polinômios de segunda e terceira ordem foi usada por Han, K. et. al. para caracterizar uma impressora, mapeando seu espaço CMY no espaço CIEXYZ, a partir de 729 amostras impressas pela impressora em teste [8]. A caracterização de uma câmera digital foi feita por Yoon, C e Cho, M., usando RPM para mapear o espaço RGB da câmera no espaço CIEXYZ, a partir de 168 cores de uma carta IT8, usada para calibração de scanners [9]. A caracterização de um mostrador LCD colorido foi feita por Tsai C., Liaw, M., e Shieh, H., usando RPM para gerar uma matriz de regressão 3 X 9, para mapear o espaço RGB do mostrador no espaço CIEXYZ, a partir de 793 cores geradas pelo mostrador [10]. Um estudo abrangente foi feito por Urban, P. e Grigat, R., do mapeamento do espaço RGB de um conjunto de 6 câmeras digitais e 3 diferentes iluminantes padrão, no espaço $L^*a^*b^*$ definido pela CIE, usando vários métodos, entre eles, RPM. As cores de teste foram obtidas a partir do banco de espectros Vrhel, com 354 espectros de refletância [11]. Também foi usada RPM, entre outros métodos, no trabalho de Bianco, S. et. al., para mapear o espaço RGB de uma câmera digital para o espaço CIEXYZ. Foram usadas 40.000 cores do banco de espectros SOCS [12], sendo 20.000 usadas para determinação dos coeficientes, e as outras 20.000 para testes [13]. A caracterização de um scanner, usando vários tipos de papel e mecanismos de impressão a laser e jato de tinta foi feita por Pan Z. et. al., através do mapeamento do espaço RGB estabelecido pelos sensores do scanner, para o espaço $L^*a^*b^*$. Neste mapeamento foi usada RPM com polinômios de terceira ordem com 19 termos. Foram usadas 1024 cores para treinamento e 420 cores para teste [14]. A caracterização de uma câmera fotográfica e de um scanner foi realizada por Tong-Sheng, M. e Hui-Linag, S. através do método de Minimização Total da Diferença de Cor (Total Color Difference Minimization - TCDM), através do mapeamento dos espaços de cor RGB definidos pela câmera e pelo scanner, diretamente no espaço L*a*b*. Além deste método foram usados os métodos de Mínimos Quadrados (Least Square – LS) e Total dos Mínimos Quadrados (Total Least Squares - TLS). Para o método TCDM foi usada RPM com polinômios de terceira ordem com 14 termos. Tanto para o treinamento quanto para a verificação foram usadas as cores do ColorChecker® na caracterização da câmera e as cores da carta IT8 na caracterização do scanner [3].

Recentemente, muitos trabalhos têm sido publicados sobre a utilização de redes neurais artificiais (RNAs) na obtenção de uma aproximação das funções de mapeamento de um espaço de cor em outro. Foi usada uma RNA na calibração de um scanner, no trabalho de Schettini, R., Barolo, B. e Boldrin, E., através do mapeamento do espaço RGB de um scanner Sharp® JP600, no espaço CIEXYZ. Para treinamento foram usadas as 264 cores de uma carta IT8 do padrão Agfa®, e para teste foram usadas as 24 cores do ColorChecker® [15]. Também foi usada uma RNA por Ye, L., Hongfei, Y. e Junsheng, S. para caracterizar uma câmera digital, através do mapeamento do espaço RGB da câmera no espaço CIEXYZ. Neste caso foram usadas 1267 cores do Munsell Book of Colors, sendo que 1.000 cores foram usadas para treinamento da RNA e 267 foram usadas para verificação [16]. Outro trabalho sobre caracterização de câmeras digitais, fazendo a comparação do desempenho do método usando RNA e RPM, foi publicado por Cheung, V. et. al. Neste trabalho é feito o mapeamento do espaço RGB definido pelos sensores da câmera, no espaço CIEXYZ. Foram usadas 166 cores da carta ColorChecker® DC para treinamento da RNA e 50 cores do Natural Color System (NCS) para a verificação [17]. A calibração de um scanner colorido foi publicada por Vrhel, M. J. e Trussell, H. J., em que são usados três métodos de interpolação em uma tabela de

pesquisa (Look-up Table - LUT) multidimensional e um quarto método usando uma RNA. Para isto, é feito um mapeamento do espaço RGB do scanner no espaço CIEXYZ. Para a construção da tabela e para o treinamento da RNA, foram usadas 264 cores lidas através do scanner [18]. Um trabalho foi publicado por Shams-Nateri, A., em que uma câmera digital foi usada para estimar a cor de tecidos tingidos. Foi usada a técnica neuro-fuzzy para mapear o espaço RGB de uma câmera digital no espaço CIEXYZ, em que o número de regras foi variado de 8 a 25 e o número de funções de pertinência, de 2 a 5. Pedaços de tecido tingidos com 141 cores foram usados para treinamento e 41 cores usadas para verificação [19]. Também foi publicado por Burian, A., Happonen, A e Cirlugea, M., um trabalho em que o espaço RGB definido por uma câmera de telefone é mapeado no espaço CIEXYZ através de 3 métodos; RPM com polinômios de segunda ordem e 12 termos, uma série de Fourier de senos com 12 termos e uma RNA com uma camada escondida de 21 neurônios. Foram usadas 160 amostras para treinamento e 80 para verificação, capturadas a partir da carta ColorChecker® [20]. O trabalho publicado por Hongxia, Z. e Tao, W. envolve um estudo da conversão de cores em um espaço RGB de uma câmera CCD no espaço CIE L*a*b*, usando uma RNA. Para treinamento foram usadas 1550 amostras, obtidas do sistema de cores Munsell, e 52 amostras foram usadas para verificação. O espaço CIEXYZ foi usado para uma conversão intermediária [21]. RNAs e algoritmos genéticos foram usados por Zuffi, S., Schettini, R. e Mauri, G. para caracterização de impressoras a jato de tinta, consideradas como dispositivos RGB. Este espaço é mapeado em um espaço espectral que é convertido no espaço CIE L*a*b*. Foi usado um total de 777 cores geradas a partir do modelo YNSN para impressão halftoning. Destas cores, 143 foram utilizadas para treinamento e as restantes para verificação [22].

O método a ser descrito neste trabalho, para mapear o espaço XYZ criado por um sensor eletrônico, no espaço CIEXYZ, resulta em um erro médio e máximo inferiores aos valores obtidos nos trabalhos citados acima. Um maior detalhamento de cada um destes métodos e a comparação dos resultados obtidos por eles com os resultados deste trabalho são feitos no Capítulo VIII.

Capítulo III - Um rápido histórico sobre a visão a cores humana

3.1. Os primeiros conceitos dos gregos

Os antigos filósofos gregos acreditavam que algum fenômeno ocorria entre nossos olhos e os objetos que são vistos. No século V A.C., Empédocles sugeriu que "o olho é como uma lanterna", talvez influenciado pelo fato dos olhos dos animais parecerem emitir luz sob certas condições [23].

Uma observação adicional, certamente influenciou os antigos gregos, que foi o fenômeno dos fosfenos visuais [23]. Fosfeno é um fenômeno caracterizado pela sensação de ver manchas luminosas, causadas pela estimulação mecânica, elétrica ou magnética da retina ou do córtex visual [24]. Os antigos gregos atribuíam esta sensação a haver fogo dentro dos olhos. Foi com base nos fosfenos que Platão desenvolveu a teoria da emanação da visão, segundo a qual o fogo interno cria raios visuais que são lançados na direção dos objetos que são percebidos [23]. Como a visão humana não ocorre na ausência de luz, Platão foi obrigado a admitir mais tarde, a existência de raios externos que interagiriam com os raios visuais. Por outro lado, Platão pensava, de forma correta que, o quanto a luz penetrava na superfície de um objeto era importante para a definição da cor que é recebida pelo olho.

Epicurus (341 A.C. – 370 A.C.) não aceitou a teoria da emanação e apresentou uma idéia extravagante de que pequenas réplicas dos objetos, que se moviam rapidamente e conservavam a característica de forma e cor, penetravam nas nossas vistas e nos nossos pensamentos.

Uma idéia que era aceita pela maioria dos antigos filósofos gregos era que o "preto" e o "branco" devem ser considerados como opostos e que os matizes são obtidos a partir de um número limitado de outros matizes fundamentais.

Theophrastus acreditava que os raios eram coloridos [25], idéia que foi rejeitada por Newton no século XVII D.C.

3.2. A idade média

Com o declínio da antiga civilização grega, registros do que havia sido aprendido foram utilizados pela cultura árabe. Durante a idade média, um renomado filósofo natural

chamado Abu Ali Mohammed Ibn Al Hazen, também conhecido como Alhazen (965-1039 D.C.), era partidário de que a luz que atingia o olho, era conseqüência da reflexão em um objeto, da luz emitida por uma fonte, e que a cor do objeto dependia da cor desta fonte.

Durante a Renascença Italiana, Leonardo da Vinci se contrapôs às idéias de Aristóteles (384 A.C. – 322 A.C.), afirmando que a cor era uma característica da luz e não dos objetos. Também afirmou que todas as cores poderiam ser obtidas a partir do vermelho, azul, verde e amarelo [26].

3.3. A era moderna da luz e visão

No século XVII, os pensamentos antigos sobre a luz a visão são substituídos por resultados de observação natural, experimentação e desejo de desafiar pensamentos estabelecidos [27]. No século XVI, ainda não estava claro se a cor estava contida na luz, no objeto, no olho ou na alma. Nesta época, a visão espacial não era melhor entendida do que pelos gregos ou árabes.

Em 1587, o professor de medicina Giulio Cesar Aranzi observou que ao fazer um corte na parte posterior de um olho de boi e colocando uma tela translúcida neste corte, ele pode observar uma imagem colorida [28].

Aparentemente por desconhecer o trabalho de Aranzi, em 1604 Johannes Kepler argumentou que o cristalino era necessário para formar uma imagem dentro do olho e, portanto, a imagem não poderia estar no próprio cristalino. Ele deduziu que a imagem seria formada na parte de trás do olho, na retina. Embora tendo alguns conceitos errados, Kepler estava certo em acreditar que a imagem na retina era pequena, invertida, relacionada de forma sistemática com os pontos no espaço, e acima de tudo, colorida [27].

Francesco Maria Grimaldi, além de considerar a teoria ondulatória da luz, também definiu três cores básicas como o verde, o vermelho e o azul. Por isto, pode-se atribuir a ele o início da teoria tricromática [27].

Em 1730, Newton publicou "Opticks" descrevendo seus experimentos de decomposição da luz branca nas suas componentes espectrais, com um prisma, fato que pode ser considerado a origem da ciência moderna da cor.

Capítulo IV - Percepção de cores e espaços de cor

4.1. O processo de percepção de cores

O processo de percepção de cores está relacionado com quatro mecanismos, mostrados esquematicamente na Fig. 4.1 [29].

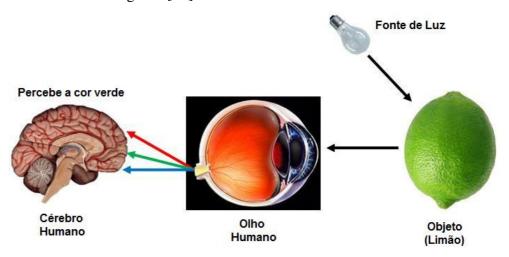


Fig. 4.1- O processo de percepção de cores [29].

O perfil de distribuição da energia luminosa nos diversos comprimentos de onda, chamado de Distribuição Espectral de Potência (*Spectral Power Distribution* - SPD) é uma característica da fonte de luz e é um dos fatores fundamentais na percepção de cores. A CIE define vários iluminantes padrão através de suas SPDs. É conveniente ressaltar que um iluminante é uma fonte de luz não necessariamente realizável, isto é, pode não existir fisicamente. Como exemplo, na Fig. 4.2 está mostrada a SPD do iluminante D65. Este iluminante padrão representa a luz do dia a 6.500 K e é o iluminante usado pela indústria de artes gráficas [30].

O segundo mecanismo é a interação da luz com o objeto iluminado. São conhecidos 15 tipos de interação que dão origem à cor dos objetos [31], nos quais a luz originada no iluminante é absorvida, refletida, refratada, espalhada ou difratada pela matéria. A luz resultante dessa interação é então direcionada ao olho do observador.

O terceiro mecanismo se dá dentro do olho humano, mais precisamente na retina, onde existem fotorreceptores responsáveis pela geração dos sinais neurais que produzem a

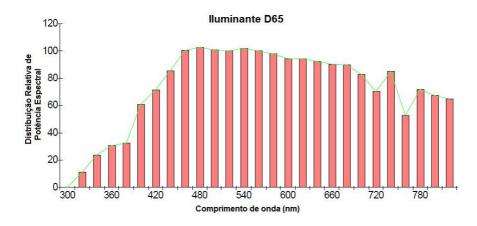


Fig. 4.2- Distribuição relativa de potência espectral do iluminante D65 [30].

percepção de cor. Estes receptores são chamados cones e podem ser de três tipos diferentes, que são L, M e S. Os cones S são sensíveis aos comprimentos de onda curtos (*short*), os cones M são sensíveis aos comprimentos de onda médios (*medium*) e os do tipo L são sensíveis aos comprimentos de onda longos (*long*). A estimulação destas células é transformada em sinais enviados ao cérebro [31].

O quarto mecanismo se dá dentro do cérebro, onde os sinais vindos da retina são decodificados, e onde realmente se realiza a percepção das cores [31].

4.2. A natureza psicofísica da visão humana de cores

As cores percebidas pela visão humana dependem, sem dúvida, das características físicas da radiação eletromagnética que atinge a retina. Aprende-se desde criança, o nome das cores que são percebidas quando a luz branca do sol é refratada por um prisma. Porém, a partir da retina, o processo de percepção de cores passa a ser um fenômeno mental e não um fenômeno físico.

Para ilustrar esta afirmação, considere-se a Fig. 4.3 [31]. A cor do círculo laranja é idêntica, na sua composição espectral, no primeiro círculo, onde aparece sozinha, e nos dois conjuntos de círculos à sua direita. No entanto parecem ter cores diferentes porque nossa percepção é afetada pela luz vinda das regiões adjacentes ao círculo laranja.



Fig. 4.3- O círculo de cor laranja tem exatamente a mesma cor nos 3 desenhos, no entanto parecem ter cores diferentes [31].

4.3. Casamento de cores

Quando os espectros da luz refletida em dois objetos produzem a mesma resposta dos cones e, portanto produzem a mesma sensação de cor, diz-se que houve o casamento das cores.

Representando a distribuição espectral da luz incidente na retina por $f(\lambda)$, sendo λ o comprimento de onda, e $s_i(\lambda)$, a sensibilidade do i-ésimo tipo de cone, a resposta de cada um dos tipos de cone pode ser escrita como [2]:

$$c_i = \int_{\lambda_{min}}^{\lambda_{max}} s_i(\lambda) f(\lambda) d\lambda \qquad i = 1, 2, 3$$
 (Eq. 4.1)

Onde $[\lambda_{min}, \lambda_{max}]$ é o intervalo dentro do qual s_i é diferente de zero.

É possível substituir a Eq. 4.1 pela sua versão amostrada (Eq.4.2), e obter somas que são aproximações da integral. Considerando que a curva de refletância de objetos reais é uma função relativamente suave em relação ao comprimento de onda, normalmente, intervalos $\Delta\lambda$ de 10nm produzem uma aproximação adequada [2]. Somente nos casos em que a iluminação apresenta picos no espectro, é necessária uma amostragem com intervalos menores. Considerando então que $\lambda_{max} = \lambda_{min} + (N-1) \Delta\lambda$, tem-se:

$$c_i = \sum_{j=0}^{N-1} s_i(\lambda_j) f(\lambda_j) \Delta \lambda \qquad i = 1, 2, 3$$
 (Eq.4.2)

onde $\lambda_j = \lambda_0 + j \Delta \lambda$

Esta equação pode ser escrita na forma vetorial como:

$$c = S^{\mathsf{T}} f \tag{Eq.4.3}$$

onde o "T" sobrescrito significa a matriz transposta, $\mathbf{c} = [c_1, c_2, c_3]^T$ e $\mathbf{S} = [s_1, s_2, s_3]$ é uma matriz $N \times 3$.

Sejam considerados agora dois espectros f e g, que produzem a mesma resposta dos cones e, portanto representam a mesma cor. Este casamento de cores pode ser expresso por:

$$\mathbf{S}^{\mathrm{T}} \mathbf{f} = \mathbf{S}^{\mathrm{T}} \mathbf{g} \tag{Eq.4.4}$$

4.4. A natureza tricromática da visão humana

A CIE (Commission Internationale de l'Eclairage), também conhecida como ICI (International Commission on Illumination) é uma organização independente, sem fins lucrativos, e que serve aos países membros de forma voluntária. Foi criada em 1913, e desde então se tornou uma organização profissional, sendo reconhecida como a melhor autoridade em todos os assuntos relacionados à ciência da luz e iluminação, cor e visão, fotobiologia e tecnologia de imagem. Também é reconhecida pela International Organization for Standadization (ISO) como um corpo de normalização internacional [32].

A natureza tricromática da visão humana foi expressa matematicamente pela CIE através dos valores de triestímulo, representados pelas grandezas X, Y e Z [33]. As especificações colorimétricas da CIE estão fundamentadas no casamento de cores através da mistura aditiva de cores, cujos princípios são conhecidos como as Leis de Grassmann das misturas de cores [34], expressas da seguinte forma:

- 1. Simetria: Se um estímulo A casa com o estímulo B, então B casa com A.
- 2. Transitividade: Se um estímulo A casa com o estímulo B e B casa com C, então A casa com C.
- 3. Proporcionalidade: Se um estímulo A casa com o estímulo B, então nA casa com nB (onde n é uma constante de proporcionalidade).
- 4. Aditividade: Se um estímulo *A* casa com o estímulo *B* e *C* casa com *D*, então a combinação de *A* e *C* casa com a combinação de *B* e *D* (e da mesma forma a combinação de *A* com *D* casa com a combinação de *B* com *C*).

Com base na primeira lei de Grassmann, considerem-se três cores primárias p_1 , p_2 e p_3 e, portanto linearmente independentes. Então S^Tp_1 , S^Tp_2 e S^Tp_3 são linearmente independentes. Sendo $P=[p_1, p_2, p_3]$, então S^TP é uma matriz 3 X 3 não singular [35].

Para qualquer espectro visível f, o vetor a(f) definido como:

$$a(f) = (S^{\mathrm{T}} P)^{-1} S^{\mathrm{T}} f \tag{Eq.4.5}$$

satisfaz a relação do casamento de cor:

$$\mathbf{S}^{\mathrm{T}} \mathbf{f} = \mathbf{S}^{\mathrm{T}} \mathbf{P} \mathbf{a}(\mathbf{f}) \tag{Eq.4.6}$$

Portanto, para qualquer espectro visível f, existe uma combinação de cores primárias P a(f) que casa com a cor f. O vetor a(f) representa a intensidade das cores primárias quando o casamento é obtido.

4.5. O experimento de casamento de cores

Com o objetivo de normatizar a sensibilidade de um observador padrão em relação à percepção de diferença de cores, a CIE realizou um experimento denominado "Experimento de casamento de cores" [36]. Um observador era solicitado a olhar através de uma pequena abertura circular, para um painel dividido em duas metades. O experimentador projetava em uma das metades uma cor com espectro f. Na outra metade, o observador tentava casar a cor a ele apresentada, variando a intensidade de três cores primárias, p_1 , p_2 e p_3 .

É importante observar que na expressão matemática da Eq. 4.6, é possível que o vetor das cores primárias a(f) tenha componentes negativas. Neste caso, a combinação de primárias não é fisicamente realizável. No entanto, uma implementação correspondente à equação ainda é possível; quando isto acontece, o observador pode mover uma ou duas primárias para o mesmo lado do painel onde é projetada a cor de espectro f. Este procedimento é equivalente a subtrair a(s) primária(s) da metade onde estas são projetadas inicialmente. A Fig. 4.4 mostra esquematicamente, a disposição usada neste experimento.

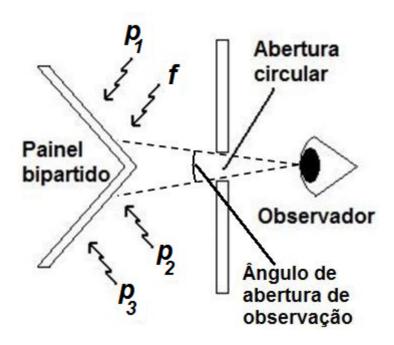


Fig. 4.4- Esquema da disposição usada no experimento de casamento de cores.

4.6. Função de casamento de cores (Color-Matching Function - CMF)

Sejam considerados espectros monocromáticos unitários $[e_i]_{i=1}^N$, em que e_i é um vetor de dimensão N com 1 na N-ésima posição e zero em todas as outras. Sejam as intensidades das três primárias para casar e_i expressas por $a_i = a(e_i)$. O casamento de todos os espectros monocromáticos pode ser expresso por:

$$\mathbf{S}^{\mathrm{T}} \mathbf{e}_{i} = \mathbf{S}^{\mathrm{T}} \mathbf{P} \mathbf{a}_{i} \tag{Eq.4.7}$$

Combinando o resultado dos *N* espectros monocromáticos, com base na terceira lei de Grassmann, obtém-se:

$$\mathbf{S}^{\mathsf{T}} \mathbf{I}_{N} = \mathbf{S}^{\mathsf{T}} \mathbf{P} \mathbf{A}^{\mathsf{T}}$$
 (Eq.4.8)

Onde I_N é a matriz identidade $N \times N$, e $A = [a_1, a_2, ..., a_N]^T$ é a matriz de casamento de cores correspondente às primárias P, e as colunas de A são chamadas funções de casamento de cor (*color-matching functions* – CMFs) que são usualmente representadas por $\bar{x}(\lambda)$, $\bar{y}(\lambda)$ e $\bar{z}(\lambda)$. Assim, pode-se escrever: $A(\lambda) = [\bar{x}(\lambda), \bar{y}(\lambda), \bar{z}(\lambda)]$.

O ângulo de abertura de observação tem uma influência importante na percepção de uma cor e assim, um casamento feito com uma determinada abertura não permanecerá para

aberturas maiores ou menores. Portanto, as CMFs são diferentes para diferentes ângulos de abertura de observação [2].

A CIE recomendou 2 observadores padrão [33]. O primeiro, de 1931, com ângulo de abertura de observação de 2⁰, e com cores primárias nos comprimentos de onda 700,0 nm, 546,1 nm e 435,8 nm. O segundo, de 1964, com ângulo de abertura de observação de 10⁰, e com cores primárias especificadas em termos de número de onda de 15.500, 19.000 e 22.500 cm⁻¹ [36]. Uma tabela com os valores das CMFs dos observadores padrão está mostrada no anexo A.1. A Fig. 4.5 mostra um gráfico com as funções de casamento de cor.

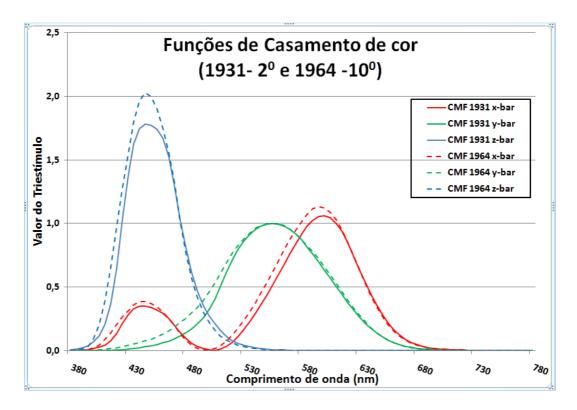


Fig. 4.5– Gráfico das funções de casamento de cor $1931 - 2^0$ e $1964 - 10^0$.

4.7. A especificação do triestímulo

Matematicamente, a especificação dos triestímulos X, Y e Z definidos pela CIE é a integração do produto de 3 espectros; as funções de casamento de cor $A(\lambda) = [\bar{x}(\lambda), \bar{y}(\lambda), \bar{z}(\lambda)]$, a SPD do iluminante $E(\lambda)$, e o espectro de refletância do objeto $R(\lambda)$.

Portanto tem-se:

$$X = k \int \bar{x}(\lambda)E(\lambda)R(\lambda) d\lambda$$
 (Eq. 4.9)

$$Y = k \int \bar{y}(\lambda)E(\lambda)R(\lambda) d\lambda$$
 (Eq. 4.10)

$$Z = k \int \bar{z}(\lambda)E(\lambda)R(\lambda) d\lambda$$
 (Eq. 4.11)

Onde *k* é uma constante de normalização, dada por:

$$k = \frac{100}{\left[\int \bar{y}(\lambda)E(\lambda) d\lambda\right]} \cong \frac{100}{\left[\sum_{i=1}^{N} \bar{y}(\lambda_{i})E(\lambda_{i}) \Delta\lambda\right]}$$
(Eq.4.12)

Pelos mesmos motivos que nos permitiram a aproximação da Eq.4.1, pode-se substituir as Eqs.4.9 a 4.12 pela suas versões amostradas (Eqs.4.13 a 4.16), e obter somas que são aproximações das integrais.

$$X = k \sum_{i=1}^{N} \bar{x} (\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq. 4.13)

$$Y = k \sum_{i=1}^{N} \bar{y} (\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq. 4.14)

$$Z = k \sum_{i=1}^{N} \bar{z} (\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq. 4.15)

$$k = 100 / \sum_{i=1}^{N} \bar{y} (\lambda_i) E(\lambda_i) \Delta \lambda$$
 (Eq. 4.16)

$$Y = k \sum_{i=1}^{N} \bar{y}(\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq. 4.14)

$$Z = k \sum_{i=1}^{N} \bar{z}(\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq. 4.15)

$$k = 100 / \sum_{i=1}^{N} \bar{y}(\lambda_i) E(\lambda_i) \Delta \lambda$$
 (Eq. 4.16)

Aqui também, pelos mesmos motivos, é usado $\Delta \lambda = 10nm$.

O espaço que se obtém ao usar cada componente do triestímulo em eixos ortogonais é chamado espaço de triestímulo ou espaço de cor CIEXYZ, e este espaço não é visualmente uniforme [2].

4.8. Diagrama de cromaticidade CIE 1931

O espaço de triestímulo pode ser projetado em um espaço bidimensional, normalizando-se cada componente em relação à soma dos valores componentes do triestímulo. Desta forma, denominam-se coordenadas de cromaticidade, os valores x, y e z assim definidos:

$$x = \frac{X}{X + Y + Z} \tag{Eq.4.17}$$

$$y = \frac{Y}{X + Y + Z} \tag{Eq.4.18}$$

$$z = \frac{Z}{X + Y + Z} \tag{Eq.4.19}$$

Portanto x + y + z = 1.

A fronteira da abrangência do espaço de cor CIEXYZ pode ser representada no diagrama de cromaticidade calculando-se os pontos do diagrama correspondentes às CMFs $\bar{x}(\lambda)$, $\bar{y}(\lambda)$, $\bar{z}(\lambda)$. A Fig. 4.6 mostra o diagrama de cromaticidade para as CMFs referentes ao observador padrão de 1931 [31]. Os números em verde representam o comprimento de onda usado para calcular os pontos indicados.

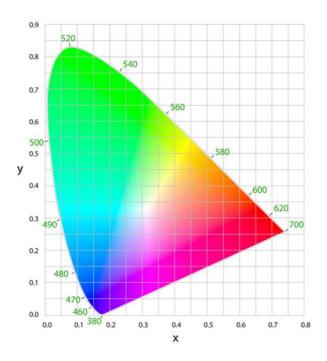


Fig. 4.6– Diagrama de cromaticidade $1931 - 2^0$ [31].

4.9. O espaço de cor CIE - L*a*b*1976 (1)

As principais funções de um espaço de cor são poder indicar a existência de diferença entre duas cores e quantificar esta diferença [2]. Várias pesquisas foram realizadas para analisar a distribuição da menor diferença percebível (*Just Noticeable Difference* – JND) entre duas cores, para diferentes cores no diagrama de cromaticidade e no espaço de triestímulo CIEXYZ. A conclusão é que a JND varia fortemente ao longo dos espaços de cor mencionados. Portanto, o espaço CIEXYZ não é perceptualmente uniforme, e diferenças aparentemente iguais não correspondem a distâncias iguais neste espaço [37].

Devido à limitação de espaços não uniformes na quantificação de diferenças de cor, a CIE recomendou, em 1976, o uso de dois espaços de cor aproximadamente uniformes: o espaço CIE $L^*u^*v^*$ e o espaço CIE L^* a* b*. Estes espaços são definidos em termos de transformações a partir do espaço de triestímulo CIEXYZ [38].

De particular interesse neste trabalho é o espaço $L^*a^*b^*$, ou CIELAB, devido a sua

⁽¹⁾ Usa-se "*" sobrescrito para o espaço L*a*b* CIE para diferenciar da escala de cor L a b do HunterLab [39].

consagração em aplicações práticas [2], e sua definição é expressa como a seguinte transformação sobre o espaço CIEXYZ [38]:

$$L *= 116 f\left(\frac{Y}{Y_n}\right) - 16$$
 (Eq.4.20)

$$a *= 500 \left(f\left(\frac{X}{X_n}\right) - f\left(\frac{Y}{Y_n}\right) \right)$$
 (Eq. 4.21)

$$b *= 200 \left(f\left(\frac{Y}{Y_n}\right) - f\left(\frac{Z}{Z_n}\right) \right)$$
 (Eq.4.22)

Onde

$$f(x) = \begin{cases} x^{1/3} & , x > 0.008856 \\ 7.787x + \frac{16}{116}, x \le 0.008856 \end{cases}$$
 (Eq.4.23)

e X_n , Y_n e Z_n são os triestímulos para a cor branca.

A distância euclidiana entre os estímulos de duas cores no espaço CIELAB é chamado ΔE^*_{ab} (delta E-ab). Assim, se tivermos duas cores expressas neste espaço como L_2^* , a_2^* , b_2^* e L_1^* , a_1^* , b_1^* , ΔE^*_{ab} é dado por [2,38]:

$$\Delta E_{ab}^* = \sqrt{(L_2^* - L_1^*)^2 + (a_2^* - a_1^*)^2 + (b_2^* - b_1^*)^2}$$
 (Eq.4.24)

No espaço de cores CIELAB, que é aproximadamente uniforme, pode-se atribuir um único valor à JND, que foi determinado corresponder a um valor de ΔE^*_{ab} de aproximadamente 2,3 [40].

As diferenças de cor expressas em ΔE^*_{ab} são mais concordantes com as diferenças de cor percebidas por um observador, do que diferença expressas no espaço CIEXYZ. Ainda assim, em certas regiões do espaço, o valor de ΔE^*_{ab} perde sua uniformidade com as diferenças percebidas.

O espaço de cor $L^*u^*v^*$, também recomendado pela CIE em 1976 [33], tem os valores das suas componentes u^* e v^* definidos nas equações Eq.4.25 a Eq. 4.30. O valor de L^* é o mesmo definido para o espaço $L^*a^*b^*$.

$$u^* = 13.L^*(u' - u'_n)$$
 (Eq.4.25)

$$v^* = 13.L^*(v' - v'_n)$$
 (Eq.4.26)

onde

$$u' = \frac{4X}{X + 15Y + 3Z}$$
 (Eq.4.27)

$$v' = \frac{9Y}{X + 15Y + 3Z}$$
 (Eq.4.28)

$$u_n' = \frac{4X_n}{X_n + 15Y_n + 3Z_n}$$
 (Eq.4.29)

$$v_n' = \frac{9Y_n}{X_n + 15Y_n + 3Z_n}$$
 (Eq.4.30)

 X_n , Y_n e Z_n são os triestímulos da cor branca, da mesma forma que definido para o espaço $L^*a^*b^*$. Assim, se tivermos duas cores expressas no espaço $L^*u^*v^*$ como L_2^* , u_2^* , v_2^* e L_1^* , u_1^* , v_1^* , ΔE^*_{uv} é dado por [2]:

$$\Delta E_{uv}^* = \sqrt{(L_2^* - L_1^*)^2 + (u_2^* - u_1^*)^2 + (v_2^* - v_1^*)^2}$$
 (Eq.4.31)

Para o espaço $L^*u^*v^*$, o valor de JND é de aproximadamente 2,9 [40]. Este espaço sofre das mesmas deficiências que o espaço $L^*a^*b^*$ em relação à uniformidade das diferenças percebidas.

Uma evolução das fórmulas de diferença de cor mencionadas, e que foi criada para reduzir as deficiências descritas é a fórmula $\Delta E_{CMC(l:c)}$. A expressão desta fórmula é dada pela Eq. 4.32 [41] e fornece a diferença entre a cor de uma amostra e de uma cor tomada como padrão.

$$\Delta E_{CMC(l:c)} = \sqrt{\left(\frac{\Delta L^*}{k_L S_L}\right)^2 + \left(\frac{\Delta C^*}{k_C S_C}\right)^2 + \left(\frac{\Delta H^*}{k_H S_H}\right)^2}$$
(Eq.4.32)

Os termos ΔL^* , ΔC^* e ΔH^* são denominados diferenças de luminosidade, croma e matiz, respectivamente e são definidos em termos dos valores CIELAB da amostra e do padrão. Assim, se uma amostra tiver os valores CIELAB dados por L_2^* , a_2^* e b_2^* , e o padrão, L_s^* , a_s^* e b_s^* , os valores de ΔL^* , ΔC^* e ΔH^* são definidos como:

$$\Delta L^* = L_2^* - L_S^* \tag{Eq.4.33}$$

$$C_{ab}^* = \sqrt{(a^*)^2 + (b^*)^2}$$
 (Eq.4.34)

$$\Delta C^* = C_{ab,2}^* - C_{ab,s}^*$$
 (Eq.4.35)

$$\Delta H^* = \frac{2(a_2^*.b_s^* - a_s^*.b_2^*)}{\sqrt{c_{ab,2}^*.c_{ab,s}^* + a_2^*.a_s^* + b_2^*.b_s^*}}$$
(Eq.4.36)

As funções de ponderação S_L , S_C e S_H são definidas a partir de valores de L*a*b* para a cor considerada como referência, conforme mostrado nas equações Eq. 4.37 a Eq. 4.42 [42].

$$S_L^{CMC} = \begin{cases} \frac{0.040975L_S^*}{1+0.01765L_S^*}, & L_S^* \ge 16\\ 0.511, & L_S^* < 16 \end{cases}$$
 (Eq.4.37)

$$S_C^{CMC} = \frac{0.0638C_{ab,s}^*}{1 + 0.0131C_{ab,s}^*} + 0.638$$
 (Eq.4.38)

$$S_H^{CMC} = S_C^{CMC} (T^{CMC}. F^{CMC} + 1 - F^{CMC})$$
 (Eq.4.39)

$$F^{CMC} = \sqrt{\frac{\left(C_{ab,s}^*\right)^4}{\left(C_{ab,s}^*\right)^4 + 1900}}$$
 (Eq.4.40)

$$h_{ab}^* = tan^{-1} \left(\frac{b^*}{a^*}\right) \tag{Eq.4.41}$$

$$T^{CMC} = \begin{cases} 0.56 + |0.2\cos(h_{ab,s}^* + 168^\circ)|, & 164^\circ \le h_{ab,s}^* \le 345^\circ \\ 0.36 + |0.4\cos(h_{ab,s}^* + 35^\circ)|, & h_{ab,s}^* < 164^\circ ou \ h_{ab,s}^* > 345^\circ \end{cases}$$
(Eq.4.42)

Os valores das constantes k_L , k_C e k_H são escolhidos com base na aplicação para a qual a fórmula é usada, e neste trabalho será atribuído o valor 1 a estas constantes, por ser o valor usado nos trabalhos citados no capítulo VIII.

É interessante observar que as diferenças de cor expressas em unidades CMC não são simétricas, isto é, dependem da cor escolhida como referência. Assim, consideradas 2 cores, se a primeira é escolhida como referência, a diferença de cor expressa em unidades CMC, para a segunda cor é de forma geral diferente do valor obtido se a segunda cor fosse tomada como referência [2]. Nas equações Eq. 4.33 a Eq. 4.42, os valores associados à cor escolhida como referência possuem um subscrito em "s" minúsculo.

Embora a fórmula CMC seja mais linear com a percepção do que a fórmula de ΔE^*_{ab} , ela é mais complexa e existe uma preocupação sobre sua validade para situações diferentes das que foram usadas para sua definição [43].

A Fig. 4.7 mostra uma simplificação de um modelo de visão de cor. Neste modelo, os triângulos representam as repostas dos cones do tipo L, M e S, conforme definido no item 3.2. Estas sofrem uma transformação não linear e são combinadas em três canais: dois de cores oponentes; VERMELHO-VERDE (R – G), AMARELO-AZUL (Y – B) e um canal acromático A. O canal (R – G) indica o quanto uma cor é vermelha (sinais positivos) ou verde (sinais negativos). Da mesma forma, a indicação de quanto uma cor é amarela ou azul é dada pelo outro canal cromático, sendo amarelo para sinais positivos [44].

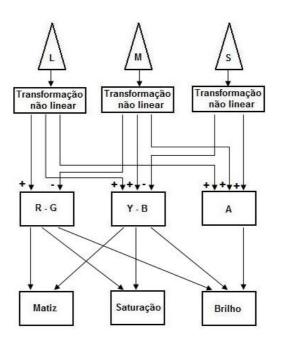


Fig. 4.7– Diagrama simplificado de um modelo de visão humana de cor. As repostas dos cones L, M e S sofrem uma transformação não linear e são combinadas em três canais: dois de cores oponentes; VERMELHO-VERDE (R –G), AMARELO-AZUL (Y – B) e um canal acromático A. [2,44].

O espaço CIELAB baseia-se no modelo de visão humana de cor que adota a teoria da codificação de cores oponentes [2, 45]. A Fig. 4.8 mostra esta relação. O eixo L^* representa o nível de brilho da cor, o eixo a^* indica o quanto a cor é vermelha ou verde e o eixo b^* mostra o quanto a cor é amarela ou azul.

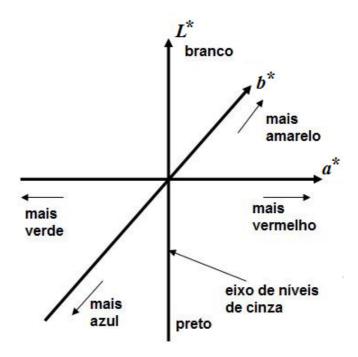


Fig. 4.8- Significado das grandezas a* e b* do espaço de cor CIELAB [2].

4.10. O sistema de ordenamento de cor Munsell

Um sistema de ordenamento de cor é um sistema que tem como objetivo identificar uma cor por sua aparência. As cores são selecionadas e dispostas em uma ordem tal que seja fácil encontrar uma cor desejada e também fazer uma interpolação visual entre as cores do sistema [31].

Em 1905, o Prof. Albert Henry Munsell idealizou um sistema de ordenamento de cores [46] que se tornou amplamente conhecido e aplicado em vários segmentos da ciência e da indústria, para fazer o gerenciamento de cores [47]. Este sistema de ordenamento de cores foi modificado várias vezes para melhorar a correspondência entre as amostras e a organização perceptual das cores. Em 1915 foi produzido o Atlas de Cor Munsell, que serviu de base para a publicação do Livro de Cores Munsell em 1929, que continha 421 cores [48]. Ao longo do tempo, novas cores foram sendo adicionadas tendo hoje, a versão para cores foscas aproximadamente 1300 cores [47].

Este sistema se baseia na premissa que a aparência de uma cor pode ser descrita em termos de 3 atributos: matiz, saturação ou pureza da cor e brilho. O sistema consiste em escalas para cada um destes atributos. O matiz é representado em uma escala circular de 10 matizes principais: vermelho (R), amarelo-vermelho (Y-R), amarelo (Y), verde-amarelo (G-

Y), verde (G), azul-verde (B-G), azul (B), púrpura-azul (P-B), púrpura (P) e vermelho-púrpura. Além dos 10 matizes principais, a escala é dividida em trechos que variam de 1 a 10, onde o valor 5 significa um matiz principal. Uma notação constituída de dígitos e letras é usada para especificar o matiz. Distâncias iguais na escala são projetadas para representar mudanças iguais no matiz percebido [46]. A Fig. 4.9 mostra o círculo de matizes da escala Munsell [47].

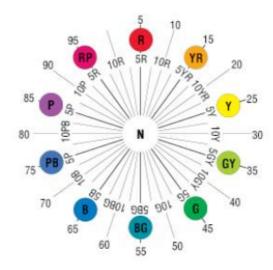


Fig. 4.9- O círculo de matizes da escala Munsell [47].

A saturação é especificada numa escala numérica que começa em zero e vai até a saturação máxima de cada matiz. Uma saturação zero representa uma cor neutra, isto é, um nível na escala de cinza, indo do preto até o branco. Da mesma forma que para o matiz, distâncias iguais na escala são projetadas para representar mudanças iguais na saturação percebida [46]. A Fig. 4.10 mostra uma seqüência de cores da escala variando a saturação, com matiz e brilho constantes [47].



Fig. 4.10- Seqüência de cores na escala Munsell, variando a saturação, com matiz e brilho constantes [47].

A escala de brilho é chamada "valor", que é especificado numericamente no intervalo de 0 a 10. Zero representa cores que possuem o brilho do preto, e 10 indica cores com brilho do branco. Entre 0 e 10, tem-se gradações do nível de cinza. Da mesma forma que para o

matiz e para a saturação, distâncias iguais na escala são projetadas para representar mudanças iguais no valor (brilho) percebido [46]. A Fig. 4.11 mostra uma sequência de cores da escala variando o valor, com matiz qualquer e saturação zero [47].



Fig. 4.11- Seqüência de cores na escala Munsell, variando o valor, com matiz qualquer e saturação zero [47].

A notação Munsell começa com o matiz, seguido pelo valor e por último a saturação. O valor e a saturação são separados por uma barra inclinada. Por exemplo, a notação 2,5R8/4 significa uma amostra com cor de matiz 2,5 vermelho, valor (brilho) 8 e saturação 4.

Para as cores neutras, isto é, saturação igual a zero, é usada a letra "N" no lugar do matiz, seguida do valor, e neste caso a saturação é omitida. Por exemplo, N8/ significa uma amostra com cor neutra, de valor 8 e saturação 0. A Fig. 4.12 mostra a organização cilíndrica do sistema Munsell [47], com a coordenada angular representando o matiz, a coordenada linear representando o valor, e a coordenada radial representando a saturação.

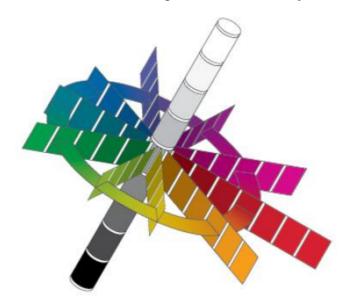


Fig. 4.12— Organização cilíndrica do sistema Munsell, com a coordenada angular representando o matiz, a coordenada linear representando o valor, e a coordenada radial representando a saturação [46].

Capítulo V – Equipamentos usados para medir cor

.

5.1. Espectroradiômetros

A maneira mais direta e completa de se medir uma cor é obter sua distribuição espectral. O espectroradiômetro mede a potência da radiação óptica como função do comprimento de onda [2]. A Fig. 5.1 mostra esquematicamente um espectroradiômetro. A luz que vem da amostra é colimada por uma lente sobre um elemento dispersivo que decompõe a luz no seu espectro. Uma rede de difração é o elemento dispersivo geralmente utilizado para esta aplicação, devido à linearidade entre comprimento de onda e deslocamento espacial do comprimento de onda sobre o detector.

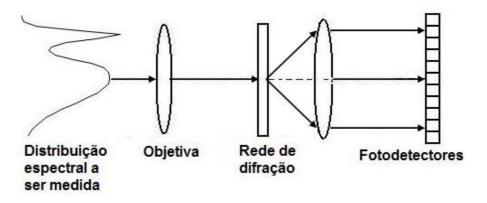


Fig 5.1- Diagrama esquemático de um espectroradiometro [2].

Se fosse usado um prisma para esta tarefa, a relação seria altamente não linear, o que tornaria mais difícil a calibração do instrumento.

Os espectroradiômetros usados para medida de cor usualmente abrangem a faixa de 380 a 780 nm e possuem uma resolução espectral de 1 a 10 nm. Podem medir tanto objetos que emitem luz como aqueles que refletem/espalham luz. Para a medida do espectro de refletância, uma amostra de referência é necessária. Esta amostra deve ter alta refletividade (branca) e espectro de refletância conhecido. Também é preciso uma fonte de luz com espectro uniformemente distribuído (branca). O valor de refletância da amostra em análise é obtido por comparação com o valor da refletância da amostra de referência

Os espectroradiômetros, embora tenham a vantagem de medir tanto objetos luminosos como não luminosos, são mais caros, complexos e menos portáteis que outros instrumentos, e

em geral, são mais difíceis de operar devido à quantidade de parâmetros a serem configurados para realizar uma medida. Alguns exemplos de espectroradiômetros comercialmente disponíveis são: FieldSpec3, fabricado pela ASD Inc. [49] e o OL 750 da Optronic Laboratories [50]. Nos anexos B.1 e B.2 estão mostradas as características técnicas destes equipamentos.

5.2. Espectrofotômetros

Espectrofotômetros são equipamentos destinados especificamente para medir a refletância e/ou transmitância espectral, e não medem objetos luminosos [2]. Os espectrofotômetros possuem sua própria fonte de iluminação para iluminar a amostra durante a medida. O sensor e a fonte de iluminação podem ser posicionados, um em relação ao outro, de muitas formas, dependendo da aplicação a ser feita do instrumento [2]. Para aplicações gráficas coloridas, o sensor e a fonte de luz são em geral, colocados na configuração denominada $45^{\circ}/0^{\circ}$, como mostrado na Fig. 5.2.

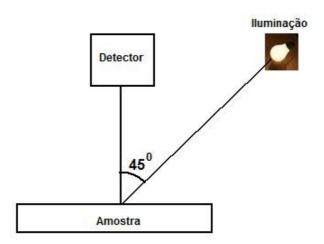


Fig 5.2– Configuração $45^{0}/0^{0}$ para o posicionamento relativo da iluminação e do sensor [2].

Alguns iluminam a mostra com luz difusa e posicionam o sensor fora do eixo, oferecendo a opção de medir ou não a componente especular. Outros usam um disco com filtros, que são posicionados de acordo com a faixa do espectro sendo medida em cada momento. Alguns usam fontes de luz com espectros diferentes para iluminar a amostra.

Para fazer medidas de refletância, o espectrofotômetro mede a refletância como a relação entre duas medidas espectroradiométricas não calibradas, como mostrado na Fig. 5.3 [2].

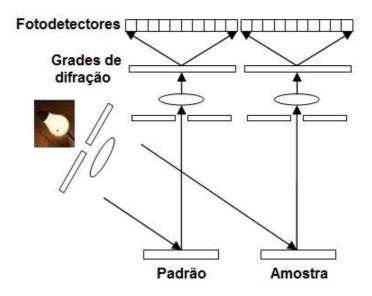


Fig 5.3- Diagrama esquemático de um espectrofotômetro [2].

A fonte de luz do equipamento ilumina simultaneamente uma superfície padrão, com uma refletância $r_s(\lambda)$ conhecida, e uma amostra que se deseja medir, com refletância $r_0(\lambda)$ desconhecida. Supõe-se que o espectro será medido usando um intervalo de amostragem $\Delta\lambda$ dentro da faixa $[\lambda_0, \lambda_{max}]$, e que $\lambda_{max} = \lambda_0 + [(N-1).\Delta\lambda]$, sendo N inteiro, indicando o número de comprimentos de onda considerados na amostragem. A fonte de luz possui uma SPD que será chamada de $l(\lambda)$. Pode-se escrever que a medida da intensidade dada pelo sensor para cada um nos N comprimentos de onda, quando o padrão é considerado, é:

$$M_s(n) = d_n l(\lambda_0 + n \Delta \lambda) r_s(\lambda_0 + n \Delta \lambda), \quad 0 \le n \le (N-1)$$
 (Eq.5.1)

onde d_n significa a sensibilidade do sensor. Da mesma forma, quando a amostra é considerada, pode-se escrever:

$$M_0(n) = d_n l(\lambda_0 + n \Delta \lambda) r_0(\lambda_0 + n \Delta \lambda), \quad 0 \le n \le (N-1)$$
 (Eq.5.2)

Assim, a refletância da amostra pode ser calculada como:

$$r_0(\lambda_0 + n \Delta \lambda) = (M_0(n)/M_s(n)) r_s(\lambda_0 + n \Delta \lambda), \quad 0 \le n \le (N-1)$$
 (Eq.5.3)

Na prática, o sistema óptico e os sensores não são duplicados, e na realidade são feitas duas medidas sequenciais, uma da amostra padrão e outra da amostra a ser medida.

A fonte luminosa destes dispositivos são normalmente lâmpadas incandescentes filtradas ou lâmpadas de arco de xenônio, cujo espectro é plano, e a faixa do espectro usada para trabalhos com cor vai de 380 a 780 nm.

A curva de refletância de objetos reais é uma função relativamente suave em relação ao comprimento de onda e por isto, os espectrofotômetros utilizam intervalos de amostragem maiores do que os usados em espectroradiômetros, sendo tipicamente usados intervalos de 5, 10 ou até mesmo 20nm.

Como consequência das menores exigências em relação à resolução e à calibração, os espectrofotômetros são significativamente mais baratos do que espectroradiômetros, e são também mais estáveis ao longo do tempo [2].

Alguns exemplos de espectrofotômetros comercialmente disponíveis são: MA68-II, fabricado pela X-Rite [51] e o T60 fabricado pela PG Instruments [52]. Nos anexos B.3 e B.4 estão mostradas as características técnicas destes equipamentos.

5.3. Colorímetros

Colorímetros são equipamentos que medem o triestímulo, mostrando ao usuário este valor medido, ou sua transformação para algum outro espaço de cor. Alguns colorímetros possuem uma fonte de luz interna e medem a refletância da amostra, enquanto outros medem a emissão luminosa da amostra, ou mesmo a refletância obtida através de uma fonte de luz externa.

Os colorímetros normalmente são pequenos, não possuem partes móveis, usam um único detector e são portáteis. São mais baratos do que espectrofotômetros e espectroradiômetros, mas não expressam a informação espectral detalhada da amostra, visto que o valor medido pelo sensor é uma integração da SPD sob a CMF de um observador padrão CIE.

Alguns exemplos de colorímetros comercialmente disponíveis são: CR400 fabricado pela Konica Minolta [53] e o ColorQA [54] fabricado pela PocketSpec. Nos anexos B.5 e B.6 estão mostradas as características técnicas destes equipamentos.

Capítulo VI – O problema de mapeamento do triestímulo

6.1. Sensores e espaços de cor colorimétricos

Sensores eletrônicos são, de forma geral, usados pelos dispositivos que medem cor, para determinar a intensidade da luz vinda da amostra sendo medida. Como as curvas de sensibilidade dos sensores são diferentes das curvas de sensibilidade dos observadores padrão CIE, o valor do triestímulo medido será também diferente do valor que este teria no espaço de cor CIEXYZ.

Um espaço de cor definido por um sensor é denominado "colorimétrico" se e somente se a sensibilidade dos canais de cor for uma combinação linear das funções de casamento de cor definidas por um observador colorimétrico CIE [15].

O sensor considerado neste trabalho é o TCS230, componente fabricado pela empresa TAOS[®] (Texas Advanced Optoelectronic Solutions Inc.), e é um conversor programável de intensidade luminosa para freqüência. Sua saída é uma onda quadrada com *duty cycle* de 50% e a freqüência é diretamente proporcional a irradiância. O conversor usa uma matriz de fotodiodos de 8 X 8, sendo que 16 fotodiodos possuem um filtro verde, outros 16 fotodiodos possuem filtro vermelho, 16 possuem filtro azul e os 16 restantes não possuem filtro. Os quatro tipos de fotodiodos são intercalados de forma a minimizar a não uniformidade da luz incidente. O tamanho dos fotodiodos é 120μm X 120μm, e estão separados por uma distância entre centros de 144 μm. Os fotodiodos de cada tipo são conectados em paralelo e o tipo que está sendo usado em um determinado instante é selecionado através de pinos de controle. O erro de linearidade típico é de 0,2% em 50 kHz e o coeficiente de temperatura é de 200 ppm/°C [4].

A Fig. 6.1 (a) mostra o diagrama de blocos do componente e a Fig 6.1 (b) mostra a disposição física dos sensores:

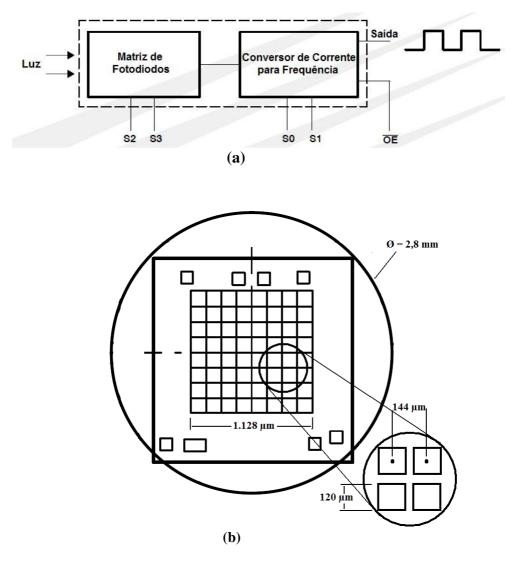


Fig. 6.1 – (a) Diagrama de blocos do sensor TCS230. (b) Disposição física dos Sensores.

O componente é encapsulado em material plástico transparente, com uma janela polida de 2,8 mm de diâmetro, centralizada sobre a matriz de fotodiodos. A resposta espectral (sensibilidade) das matrizes de fotodiodos R, G e B (com filtros vermelho, verde e azul), fornecida pelo fabricante, com intervalos de 5 nm e normalizada em relação à resposta do canal branco, constituído pelos fotodiodos sem filtro, está mostrada na Fig. 6.2.

Pode-se observar que a resposta espectral do sensor se estende acima do espectro visível, o que no caso considerado é indesejável. Para evitar que estes comprimentos de onda influenciem na medida da cor, onde somente o espectro visível deve ser considerado, é usado

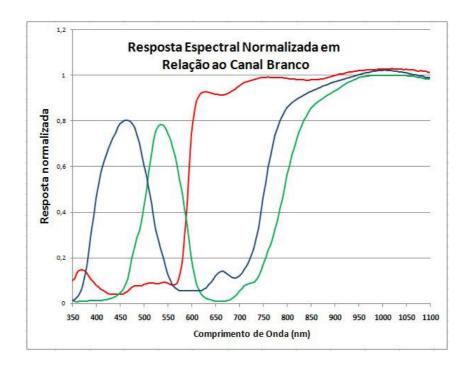


Fig. 6.2 – Resposta espectral do sensor TCS230, normalizada em relação à resposta do canal branco.

um filtro IR fabricado pela Hoya, código CM500 e que é recomendado pelo fabricante do sensor. O gráfico da transmitância espectral normalizada deste filtro está mostrado na Fig. 6.3.

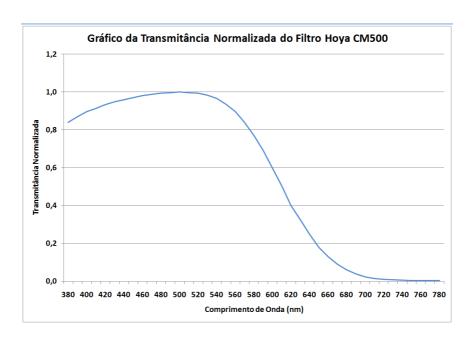


Fig. 6.3 – Gráfico da transmitância normalizada do Filtro IR Hoya CM500.

Este filtro fica posicionado sobre a superfície superior do sensor, impedindo assim que os comprimentos de onda fora do espectro visível sejam considerados. A Fig. 6.4 mostra uma foto deste filtro.

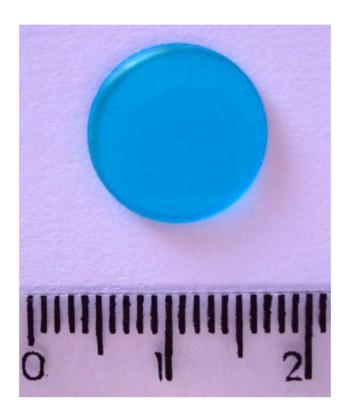


Fig. 6.4- Foto do Filtro IR.

Lembrando que os valores de triestímulo são calculados pelas equações Eq. 4.13 a Eq. 4.16, aqui repetidas por conveniência:

$$X = k \sum_{i=1}^{N} \bar{x} (\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq.6.1)

$$Y = k \sum_{i=1}^{N} \bar{y}(\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq. 6.2)

$$Z = k \sum_{i=1}^{N} \bar{z}(\lambda_i) E(\lambda_i) R(\lambda_i) \Delta \lambda$$
 (Eq.6.3)

$$k = 100 / \sum_{i=1}^{N} \bar{y}(\lambda_i) E(\lambda_i) \Delta \lambda$$
 (Eq.6.4)

onde $\bar{x}(\lambda)$, $\bar{y}(\lambda)$, $\bar{z}(\lambda)$ são as funções de casamento de cor (CMFs), $E(\lambda_i)$ é a SPD do iluminante, e $R(\lambda_i)$ é a refletância do objeto.

Quando é usado um sensor com um filtro para medir o triestímulo, a curva de resposta da combinação sensor mais filtro toma o lugar das CMFs, e o desejável é que o valor medido seja exatamente o mesmo que seria obtido com as CMFs, ou possa ser calculado através de uma relação linear entre os valores. Para isso, seria necessário que a curva de resposta do

sensor fosse colorimétrica, isto é, uma combinação linear das curvas das CMFs, o que por razões práticas de construção dos sensores, não é factível [7]. A Fig. 6.5 mostra em um mesmo gráfico, as curvas das CMFs e da resposta da combinação sensor mais filtro para comparação.

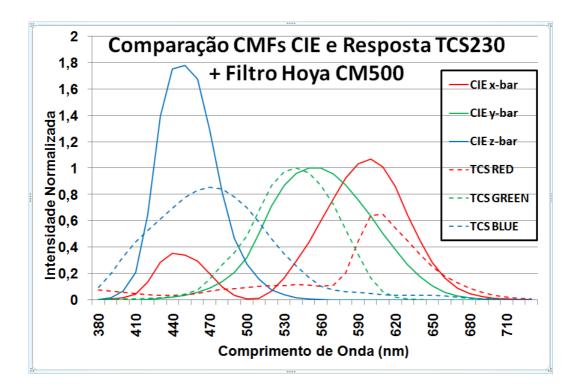


Fig. 6.5- Gráfico comparativo das CMFs CIE 1931 com a resposta combinada do sensor TCS230 e o Filtro Hoya CM500.

6.2. O ColorChecker®

O ColorChecker® é um cartão usado para calibração de cores por profissionais de fotografia. O cartão tem dimensões de 230 mm de altura por 330 mm de largura, e está dividido de forma quadriculada em 24 regiões, e organizada em 4 linhas de 6 regiões. A última linha é constituída de cores neutras (níveis de cinza) variando do branco até o preto. A Fig. 6.6 mostra a aparência de um ColorChecker®.

O ColorChecker® foi desenvolvido, fabricado e fornecido pela empresa GretagMacbeth, que foi adquirida pela empresa X-Rite em julho de 2006, que é a atual fornecedora do produto.

O ColorChecker® foi usado como uma das referências de cor neste trabalho porque a X-Rite fornece dados confiáveis sobre as especificações das cores contidas na cartela. Além

disto, este produto tem uso consagrado na calibração de cores em fotografia e é referenciado em vários trabalhos [7, 55].

No folheto de instruções que acompanha o produto, a cor de cada região está especificada em L*a*b*, usando o iluminante D50, e no espaço de cores sRGB, usando

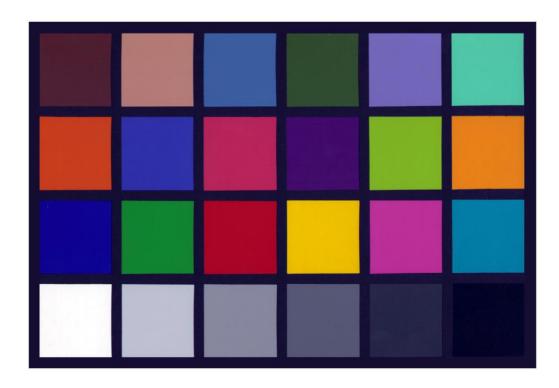


Fig 6.6- A aparência do ColorChecker®.

o iluminante D65, ambos para o observador CIE $1931 - 2^0$. Adicionalmente, as cores estão expressas em notação Munsell [56]. A Fig. 6.7 mostra a parte do folheto de instruções onde estes dados são exibidos.

A empresa The BabelColor Company publica em seu site [57] os espectros de refletância de todas as cores do ColorChecker®, com passos de 10nm, no intervalo de 380 a 730 nm. Estes espectros são usados neste trabalho para calcular o triestímulo e a cromaticidade destas cores para o observador padrão CIE 1931 e também usando a resposta do TCS230 em conjunto com o filtro Hoya CM500. Os espectros fornecidos pela The BabelColor Company estão mostrados no anexo A.2.

		sRGB		CIE L*a*b*		Munsell Notation				
No.	Number		R	G	В	L*	ä"	p.		e / Chroma
1.	dark skin		115	82	68	37.986	13.555	14.059	3 YR	3.7 / 3.2
2.	light skin		194	150	130	65.711	18.13	17.81	2.2 YR	6.47 / 4.1
3.	blue sky		98	122	157	49.927	-4.88	-21.925	4.3 PB	4.95 / 5.5
4.	foliage		87	108	67	43.139	-13.095	21.905	6.7 GY	4.2 / 4.1
5.	blue flower		133	128	177	55.112	8.844	-25.399	9.7 PB	5.47 / 6.7
6.	bluish green		103	189	170	70.719	-33.397	-0.199	2.5 BG	7/6
7.	orange		214	126	44	62.661	36.067	57.096	5 YR	6/11
8.	purplish blue		80	91	166	40.02	10.41	-45.964	7.5 PB	4/10.7
9.	moderate red		193	90	99	51.124	48.239	16.248	2.5 R	5/10
10.	purple		94	60	108	30.325	22.976	-21.587	5 P	3/7
11.	yellow green		157	188	64	72.532	-23.709	57.255	5 GY	7.1 / 9.1
12.	orange yellow		224	163	46	71.941	19.363	67.857	10 YR	7 / 10.5
13.	blue		56	61	150	28.778	14.179	-50.297	7.5 PB	2.9 / 12.7
14.	green		70	148	73	55.261	-38.342	31.37	0.25 G	5.4 / 8.65
15.	red		175	54	60	42.101	53.378	28.19	5 R	4/12
16.	yellow		231	199	31	81.733	4.039	79.819	5 Y	8/11.1
17.	magenta		187	86	149	51.935	49.986	-14.574	2.5 RP	5/12
18.	cyan		8	133	161	51.038	-28.631	-28.638	5 B	5/8
19.	white (.05*)		243	243	242	96.539	-0.425	1.186	N.	9.5 /
20.	neutral 8 (.23*)		200	200	200	81.257	-0.638	-0.335	N	8/
21.	neutral 6.5 (.44*)	WW.	160	160	160	66.766	-0.734	-0.504	N	6.5 /
22.	neutral 5 (.70*)		122	122	121	50.867	-0.153	-0.27	N	5/
23.	neutral 3.5 (.1.05*)		85	85	85	35.656	-0.421	-1.231	N	3.5 /
24.	black (1.50*)		52	52	52	20.461	-0.079	-0.973	N	2/

Cie L*a*b* values use Illuminant D50 2 degree observer sRGB values for Illuminate D65. © 2005, GretagMacbeth. All rights reserved.

Fig 6.7- Valores em sRGB (iluminante D65) e CIE L*a*b* (iluminante D50) publicados no folheto de instruções do ColorChecker®.

6.3. Diferenças na medida do triestímulo

Para avaliar as diferenças na medida dos triestímulos, decorrentes das diferenças das curvas de resposta CMFs – CIE 1931 e do conjunto TCS230 mais filtro CM500, são usadas as equações 6.1 a 6.4., a SPD do iluminante D50, publicado pela CIE e os espectros de refletância de todas as cores do ColorChecker®, fornecidos pela The BabelColor Company. No primeiro caso, são calculados os triestímulos XYZ usando as curvas CMFs publicadas pela CIE, e no segundo caso, são usadas as curvas de sensibilidade combinada do TCS230 e do filtro Hoya CM500. Os triestímulos calculados nos dois casos são projetados no diagrama de cromaticidade mostrado na Fig. 6.8, sendo que o local das cores do primeiro caso é

marcada com um "+" azul e no segundo caso, marcada com um "o" verde. O número da cor correspondente do ColorChecker® é indicado ao ladao da marcação. A linha contínua em azul representa os limites (*gamut*) do espaço de cor CIE.

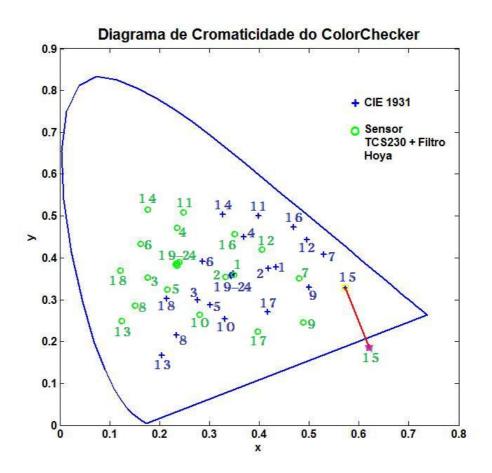


Fig 6.8- Diagrama de cromaticidade mostrando as diferenças de medida de triestímulo entre CMFs CIE 1931 com a resposta combinada do sensor TCS230 e o Filtro Hoya CM500. O maior erro é indicado pelo segmento vermelho.

A maior diferença (maior distância), indicado por uma linha vermelha, ocorre para a cor de número 15 do ColorChecker® (vermelho). Este erro corresponde a um ΔE^*ab de 98,00. Observa-se que neste caso a cromaticidade dada pelo sensor está fora dos limites do espaço de cor CIE.

As diferenças apontadas acima são devidas às diferenças entre as curvas de CMF CIE e das curvas de sensibilidade dos sensores do TCS230. Assim sendo, é desejável que se determine uma função que mapeie os valores dos triestímulo do espaço de cor definido pelo TCS230 nos valores correspondentes no espaço CIE.

No capítulo seguinte, são detalhados alguns métodos que podem ser usados para realizar tal mapeamento.

Capítulo VII - Métodos de mapeamento do triestímulo

7.1. Mapeamento usando a matriz pseudo-inversa

Seja $T_S = [X_S, Y_S, Z_S]^T$ o vetor dos valores de triestímulo obtido usando o sensor e $T_C = [X_C, Y_C, Z_C]^T$, o vetor dos valores de triestímulo obtidos com o observador padrão CIE, para uma determinada cor. Para fazer o mapeamento dos valores obtidos no espaço de cores definido pelo sensor para os valores CIE, é necessário encontrar uma matriz M de dimensão 3 X 3, tal que:

$$T_C = M \cdot T_S \tag{Eq.7.1}$$

Estendendo este conceito para a matriz de triestímulos T_{C24} , obtida com as 24 cores do ColorChecker® e calculada usando-se as CMFs CIE, e para a matriz T_{S24} , obtida com as mesmas 24 cores, desta vez usando as curvas de sensibilidade da combinação sensor mais filtro, pode-se escrever:

$$T_{C24} = M \cdot T_{S24}$$
 (Eq.7.2)

A matriz *M* poderia então obtida por:

$$M = T_{C24} \cdot T_{S24}^{-1} \tag{Eq.7.3}$$

Porém, como o número de colunas da matriz T_{S24} , de dimensão 3 X 24, é maior do que 3, a equação é sobredeterminada e sua inversa não existe. É possível, no entanto, calcular uma matriz M que minimizará o erro quadrático (somatório do quadrado dos erros), em que o erro é a diferença entre o valor de um triestímulo do sensor para o triestímulo correspondente para o observador CIE. Esta matriz é denominada matriz pseudo-inversa ou Inversa de Moore-Penrose, calculada a partir da decomposição da matriz T_{S24} em valores singulares [58]. Neste caso a matriz obtida é:

$$\mathbf{M} = \begin{bmatrix} 1,1727 & 0,2515 & 0,0234 \\ 0,4998 & 0,8286 & -0.1455 \\ -0,0004 & -0,3820 & 1,2249 \end{bmatrix}$$
 (Eq.7.4)

Os erros obtidos em cada uma das cores do ColorChecker®, expressos em termos de ΔE^*_{ab} são mostrados na Tabela 7.1. Este método foi usado por Poynton [7], porém, para o iluminante D65 e um filtro com características diferentes do usado aqui.

Tabela 7.1 - ΔE^*_{ab} para as cores do ColorChecker® usando a matriz de correção M.

No.	Nome da cor	ΔE*ab
1	dark skin	0,6556
2	light skin	4,2478
3	blue sky	0,8391
4	foliage	2,0044
5	blue flower	0,6992
6	bluish green	4,5368
7	orange	2,2197
8	purplish blue	4,6237
9	moderate red	3,2591
10	purple	1,5785
11	yellow green	2,0001
12	orange yellow	7,6355
13	blue	7,9566
14	green	7,6938
15	red	6,7232
16	yellow	1,9825
17	magenta	1,7630
18	cyan	6,5292
19	white 9.5 (.05 D)	1,3964
20	neutral 8 (.23 D)	1,2247
21	neutral 6.5 (.44 D)	1,0348
22	neutral 5 (.70 D)	0,8045
23	neutral 3.5 (1.05 D)	0,6072
24	black 2 (1.5 D)	0,3989

A partir dos valores da tabela 7.1, pode-se calcular o valor de $\Delta E^*_{ab(m\acute{e}dio)}$, que expressa o desempenho global do método e a porcentagem de mapeamentos cujos erros são menores que JND e, portanto não perceptíveis para a maioria das pessoas. Estes valores e o valor máximo do erro cometido, $\Delta E^*_{ab(m\acute{a}ximo)}$, estão mostrados na tabela 7.2

Tabela 7.2 - Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para as cores do ColorChecker®, usando a matriz de correção M.

Método da Matriz	ΔE*ab(médio)	ΔE*ab(máximo)	% < JND	
Pseudo-inversa	3,0173	7,9566	62,5000	

Pode ser observado que o valor de $\Delta E^*_{ab(m\acute{e}dio)}$ é grande, sendo maior que o valor de JND, e o $\Delta E^*_{ab(m\acute{a}ximo)}$ é aproximadamente 2 vezes e meia este valor. A porcentagem de mapeamentos cujo ΔE^*ab é inferior a JND é pequena, pois o desejável é um número perto de 100%. Além disto, a matriz pseudo-inversa minimiza o erro quadrático dos valores usados para calculá-la, não sendo possível fazer nenhuma afirmação quanto ao erro para valores diferentes daqueles usados.

7.2. O mapeamento usando regressão polinomial

Um dos métodos usados para aproximar a função de mapeamento de um espaço de cor em outro é a regressão polinomial [36]. Neste método, pressupõe-se que a relação entre os espaços de cor possa ser aproximada por um conjunto de equações simultâneas. Desta forma uma equação polinomial é escolhida para fazer o mapeamento, onde cada termo do polinômio é constituído pelo produto de um coeficiente por uma variável independente ou um produto destas variáveis. Alguns valores de mapeamento conhecidos são então usados para determinar o valor dos coeficientes do(s) polinômio(s). A Fig. 7.1 mostra um diagrama da aplicação do método.

Ao escolher o polinômio para fazer o mapeamento entre os espaços de cor, deve-se observar a restrição de que seu número de termos não pode ser maior do que o número de pontos para os quais o mapeamento é conhecido. De outra forma, haverá mais variáveis desconhecidas do que equações, e neste caso não existirá uma solução única para o sistema de equações. A tabela 7.3 mostra exemplos de polinômios que poderiam ser selecionados para fazer o mapeamento desejado [36].

Os coeficientes dos polinômios são determinados através da solução do sistema de equações simultâneas, usando-se os valores de *X*, *Y* e *Z* do espaço TCSXYZ, e os valores conhecidos *X*, *Y* e *Z* correspondentes, do espaço CIEXYZ. Uma vez determinados os coeficientes dos polinômios, estes podem ser usados para calcular o mapeamento de pontos

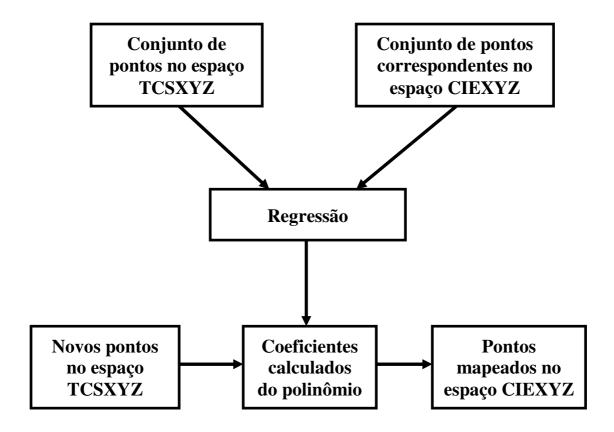


Fig 7.1- Diagrama da aplicação do método de regressão polinomial ao mapeamento do espaço TCSXYZ no espaço CIEXYZ.

do espaço TCSXYZ para os quais os correspondentes pontos no espaço CIEXYZ são desconhecidos.

Tabela 7.3 - Polinômios para mapeamento dos espaços de cor.

N° de Termos	Polinômio
3	$P(X,Y,Z) = c_1 X + c_2 Y + c_3 Z$
4	$P(X,Y,Z) = c_0 + c_1 X + c_2 Y + c_3 Z$
6	$P(X,Y,Z) = c_1X + c_2Y + c_3Z + c_4XY + c_5XZ + c_6YZ$
8	$P(X,Y,Z) = c_0 + c_1X + c_2Y + c_3Z + c_4XY + c_5XZ + c_6YZ + c_7XYZ$
	$P(X,Y,Z) = c_1X + c_2Y + c_3Z + c_4XY + c_5XZ + c_6YZ + c_7X^2 +$
9	$c_8 Y^2 + c_9 Z^2$
	$P(X,Y,Z) = c_0 + c_1X + c_2Y + c_3Z + c_4XY + c_5XZ + c_6YZ +$
11	$c_7 X^2 + c_8 Y^2 + c_9 Z^2 + c_{10} XYZ$
	$P(X,Y,Z) = c_0 + c_1X + c_2Y + c_3Z + c_4XY + c_5XZ + c_6YZ +$
	$c_7 X^2 + c_8 Y^2 + c_9 Z^2 + c_{10} XYZ + c_{11} X^3 + c_{12} Y^3 +$
14	$c_{13}Z^3$
	$P(X,Y,Z) = c_0 + c_1X + c_2Y + c_3Z + c_4XY + c_5XZ + c_6YZ +$
	$c_7 X^2 + c_8 Y^2 + c_9 Z^2 + c_{10} XYZ + c_{11} X^3 + c_{12} Y^3 +$
	$c_{13}Z^3 + c_{14}XY^2 + c_{15}XZ^2 + c_{16}YZ^2 + c_{17}YX^2 +$
20	$c_{18}ZX^2 + c_{19}ZY^2$

É importante observar que cada valor *X*, *Y* e *Z* do espaço CIEXYZ é calculado com um polinômio diferente e, portanto são necessários 3 polinômios para fazer o mapeamento.

7.3. O novo método de mapeamento de espaços de cor proposto

A proposta deste trabalho é uma nova metodologia, usando redes neurais artificiais (RNAs) especializadas, para mapear os valores de triestímulo obtidos no espaço de cor TCSXYZ, criado pelo sensor, nos valores que seriam obtidos no espaço colorimétrico CIEXYZ.

Nas seções 7.3.1 e 7.32, está descrito o método usado para determinação das RNAs especializadas. Inicialmente é investigada a arquitetura de uma única RNA fazendo o mapeamento desejado. Em seguida, tomando-se por base os resultados desta primeira investigação, são determinadas 3 RNAs, cada uma especializada em mapear cores com um determinado triestímulo dominante.

7.3.1. O mapeamento usando redes neurais artificiais

As redes neurais artificiais do tipo perceptron de múltiplas camadas (*Multi Layer Perceptron* – MLP) têm sido aplicadas com sucesso para resolver diversos problemas complexos. As principais características das redes MLP são [59]:

- 1- Popularidade: É o tipo mais utilizado de rede neural artificial.
- 2- Aproximador Universal: Aplicação em um grande número de finalidades.
- 3- Não linearidade: Capaz de modelar funções complexas.
- 4- Robustez: Capaz de ignorar entradas não relevantes e ruído.
- 5- Adaptabilidade: Pode adaptar seus pesos e/ou topologia a mudanças do ambiente.
- 6- Fácil de usar: Pode ser usada com pouco conhecimento sobre a função a ser modelada.

Considerando estas características, escolheu-se usar inicialmente uma rede neural do tipo MLP com uma única camada escondida. Para determinar o número de neurônios a ser usado nesta camada, tal que seja o menor possível e ainda assim produza resultados dentro das necessidades da aplicação, foi usado o Teorema de Kolmogorov, expresso pela (Eq.7.5) [60].

$$N_h = 2.N_i + 1$$
 (Eq.7.5)

Onde N_h é o número de neurônios na camada escondida e N_i é o número de entradas da rede. Assim, no caso considerado, onde a entrada é um vetor com 3 elementos, o número de neurônios a ser usado na camada escondida é de 7 neurônios. Esta regra deve ser usada somente como uma aproximação, visto que não considera características importantes como a quantidade de dados, sua qualidade, sua disposição no espaço de domínio da função e a complexidade do problema [60]. Para comprovar empiricamente este valor de N_h , foram experimentadas 3 arquiteturas, uma com $N_h = 5$, outra com $N_h = 10$, e uma terceira com $N_h = 20$. Para criação da rede, seu treinamento e avaliação, foi usada a *toolbox* de Redes Neurais Artificiais versão 6.0.1 da linguagem Matlab [62]. A arquitetura das 3 redes experimentadas é mostrada na Fig. 7.2. Nos neurônios da camada escondida foi usada a função de transferência *tansig* e nos neurônios da camada de saída foi usada a função de transferência *purelin*.

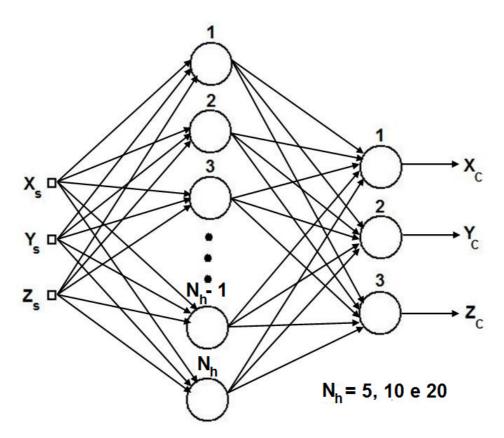


Fig 7.2- Arquitetura das redes neurais experimentadas com uma camada Escondida.

Para o treinamento da rede é aplicado inicialmente o método de retropropagação de erro (*error back-propagation*) [63], usando o algoritmo de Levenberg-Marquardt, em que o treinamento é feito de forma supervisionada. Os dados para o treinamento e para a verificação são obtidos a partir de um banco de espectros de refletância publicado na Internet pelo Departamento de Tecnologia da Informação da Universidade de Tecnologia de Lappeenranta, na Finlândia [64], onde são mostrados os espectros de 1.269 cores extraídas do Livro de Cores Munsell (*Munsell Book of Colors*) [65], na sua versão para cores foscas (*matt*). Os espectros foram obtidos usando um espectrofotômetro Perkin-Elmer lambda 9 UV/VIS/NIR, no intervalo do espectro de 380 a 800 nm, com resolução de 1nm.

Os espectros usados no treinamento e verificação, da mesma forma que os usados com o ColorChecker®, possuem resolução de 10nm, no intervalo de 380 a 730 nm. Assim, a resolução e o intervalo dos espectros do banco referenciado acima foram reduzidos e o conjunto de espectros obtido pode ser descrito como:

$$S_N = [s(\lambda_1) s(\lambda_1) s(\lambda_1) ... s(\lambda_n)]^T$$
 $n = 1, 2, ..., 36$ $N = 1, 2, ..., 1.269$ (Eq. 7.6)

Este conjunto de espectros S_N foi usado para gerar espectros adicionais, onde cada espectro S_M é a média de dois espectros de S_N . Estes espectros podem ser escritos como:

$$S_M = \frac{S_i + S_j}{2} \qquad i = [1 + (10.n)]; n = 1, 2, ..., 126$$

$$j = [(i+1) + (5.m)]; m = 1, 2, ..., m_{MAX}; j \le 1269$$
(Eq. 7.7)

Não foram considerados todos os valores possíveis de i e j para o cálculo de S_M porque neste caso o conjunto de espectros seria desnecessariamente grande. Também, os valores de i e j foram tomados de forma a distribuir o mais uniformemente possível, dentro do *espaço de cor Munsell*, os espectros considerados.

A união dos conjuntos de espectros $S_T = S_N \cup S_M$ representa um conjunto de 17.525 cores. Para cada uma das cores do conjunto de espectros S_T , foi calculado o triestímulo $T_S = [X_S, Y_S, Z_S]^T$ no espaço de cor TCSXYZ definido pelo sensor e $T_C = [X_C, Y_C, Z_C]^T$, no espaço de cor CIEXYZ. Em seguida estes conjuntos T_S e T_C foram divididos em duas partes cada um, sendo que a primeira contem 70% do total de cores, que depois de normalizadas, foram usadas para treinamento, e as cores da segunda parte, depois de normalizadas, usadas para verificação.

Inicialmente foi aplicado o treinamento de retropropagação de erro, empregando o algoritmo de Levenberg-Marquardt [66]. Foram feitos 4 treinamentos da RNA com cada uma das arquiteturas propostas, e para cada uma das redes treinadas, calculados os valores de ΔE^*_{ab} entre os valores calculados pela rede e os valores do espaço de cores padrão CIEXYZ.

A tabela 7.4 mostra, para cada um dos treinamentos realizados, os valores máximos e médios de ΔE^*_{ab} obtidos para o conjunto de valores de verificação e também a porcentagem dos valores de ΔE^*_{ab} inferiores ao valor de JND. O $\Delta E^*_{ab(m\acute{e}dio)}$ fornece uma indicação do erro médio cometido no mapeamento. O $\Delta E^*_{ab(m\acute{a}ximo)}$ indica o máximo erro cometido. Tendo em vista a aplicação do resultado deste estudo na medição de cores, quanto menor estes valores, menor será o erro médio e máximo cometidos em medições. A porcentagem dos valores de ΔE^*_{ab} inferiores ao valor de JND fornece uma indicação da quantidade de erros relevantes, visto que valores de ΔE^*_{ab} inferiores ao valor de JND não são percebidos pela grande maioria dos observadores.

Tabela 7.4 - Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para cada treinamento, para o conjunto de verificação, usando o *algoritmo de Levenberg-Marquardt*. São mostrados os resultados para 5, 10 e 20 neurônios na camada escondida (continua).

Número do	Rede	Única - 5 neurônios		
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	3,7374	17,6897	41,2403	
2	9,7241	32,7389	8,0654	
3	5,1063	15,9916	10,8998	
4	1,4107	8,4537	81,9859	
Número do	Rede	Única - 10 neurônios		
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	1,1356	7,7406	88,7388	
2	1,2455	8,9741	86,1328	
3	1,6011	9,4229	81,0158	
4	1,2141	8,5006	86,7795	
Número do	Rede Única - 20 neurônios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	1,0442	7,5744	89,3095	
2	1,0779	7,4613	85,4290	
3	1,2008	8,3591	92,5813	
4	0,9283	7,4867	92,9618	

Uma preocupação pertinente a estes dados estatísticos é com relação aos valores de $\Delta E^*_{ab(m\acute{a}ximo)}$. Estes valores podem não ser relevantes se estiverem muito afastado dos outros

valores obtidos e são denominados *outliers*. Para verificar que os valores de $\Delta E^*_{ab(m\acute{a}ximo)}$ considerados não são *outliers*, foram feitos gráficos com histogramas da distribuição de ΔE^*_{ab} para todos os valores usados na verificação. As figuras 7.3, 7.4 e 7.5 mostram os histogramas obtidos, onde os valores de ΔE^*_{ab} foram classificados em 1000 intervalos (*bins*). A Fig. 7.3 mostra o histograma obtido para o melhor treinamento (menor $\Delta E^*_{ab(m\acute{a}ximo)}$ - treinamento 4) da rede com 5 neurônios na camada escondida, a Fig. 7.4 para o melhor treinamento (treinamento 1) da rede com 10 neurônios nesta camada, e a Fig. 7.5, para o treinamento 2 da rede com 20 neurônios na camada escondida.

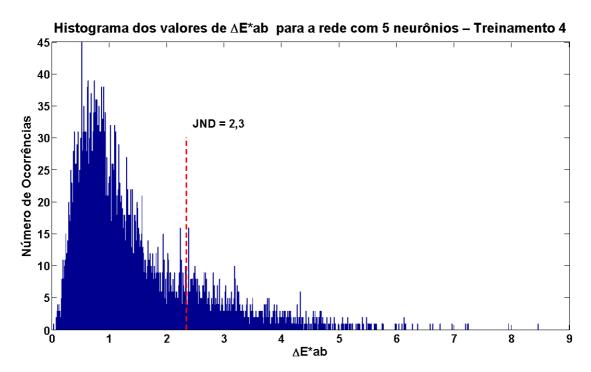


Fig 7.3- Histograma dos valores de ΔE^* ab - rede com 5 neurônios – Treinamento 4.

Na Fig. 7.3, pode-se observar que o valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ está aproximadamente 1 unidade de ΔE^*_{ab} afastado dos valores mais freqüentes que começam a aparecer em torno do valor 7. Desta forma pode-se considerar que o $\Delta E^*_{ab(m\acute{a}ximo)}$ neste caso não é um *outlier*.

Na Fig. 7.4, o valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ está afastado de menos de 1 unidade de ΔE^*_{ab} dos valores mais freqüentes, que começam a aparecer em torno do valor 7. Assim, também neste caso, pode-se considerar que o $\Delta E^*_{ab(m\acute{a}ximo)}$ não é um *outlier*.

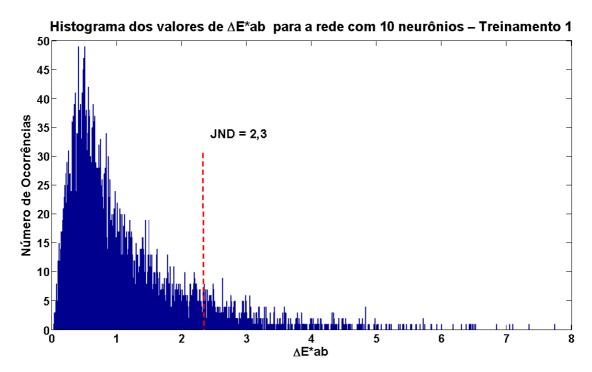


Fig 7.4- Histograma dos valores de ΔE^* ab - rede com 10 neurônios - Treinamento 1.

Na Fig. 7.5, pode-se observar que o valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ está aproximadamente 0,5 unidades de ΔE^*_{ab} afastado dos valores mais freqüentes que começam a aparecer em torno do valor 7. Assim, também neste caso, pode-se considerar que o $\Delta E^*_{ab(m\acute{a}ximo)}$ não é um *outlier*.

Os dados da tabela 7.4 indicam que a RNA com 5 neurônios na camada escondida possui desempenho inferior à RNA com 10 neurônios nesta camada. Considerando-se a rede

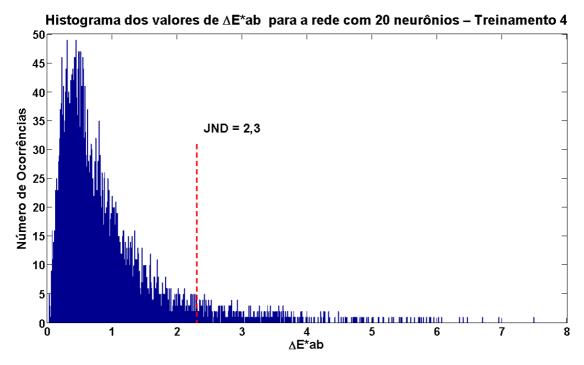


Fig 7.5- Histograma dos valores de ΔE^* ab - rede com 20 neurônios - Treinamento 4.

com 5 neurônios na camada escondida, obtida com o treinamento 4, que resultou no melhor desempenho, o $\Delta E^*_{ab(m\acute{e}dio)}$ obtido foi de aproximadamente 1,41, sendo que este valor para a rede com 10 neurônios foi de aproximadamente 1,13, que é 20% melhor que o valor obtido com 5 neurônios. Também o valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ na rede com 5 neurônios na camada escondida, obtido com o treinamento 4 foi de 8,45, valor superior ao obtido com o treinamento 1 da rede com 10 neurônios, que foi de 7,74, que é 8,5% melhor que o valor com 5 neurônios. Adicionalmente, a porcentagem das entradas com ΔE^*_{ab} menor que JND é aproximadamente 82% para a rede com 5 neurônios e quase 89% na rede com 10 neurônios, obtida com o treinamento 1, o que representa uma melhora de 7%.

A diferença de desempenho entre os melhores resultados é menor entre as redes com 10 e 20 neurônios na camada escondida. No caso do $\Delta E^*_{ab(m\acute{e}dio)}$, a diferença porcentual pouco mudou em relação à comparação anterior, tendo a rede com 20 neurônios obtido um resultado 18% melhor que a rede de 10 neurônios. Porém a diferença do $\Delta E^*_{ab(m\acute{a}ximo)}$ é igual a 0,2793, o que representa uma melhora de apenas 3% em relação à rede com 10 neurônios. A diferença entre as porcentagens das entradas com ΔE^*_{ab} menor que JND é de 4,22%, o que representa uma melhora de 4,8% no caso da rede de 20 neurônios.

Freqüentemente é encontrado um problema no treinamento de RNAs, denominado sobre-ajuste (*overfitting*). Com o conjunto de dados usados no treinamento, os pesos sinápticos são ajustados para se obter um erro pequeno no mapeamento. No entanto, quando são aplicados os valores de verificação, os erros podem ficar grandes. Isto indica que a rede "memorizou" os exemplos do treinamento, mas não é capaz de generalizar o cálculo do mapeamento com pequenos erros, quando são usados novos dados de entrada que não foram utilizados no treinamento.

Para melhorar a generalização, é usado um método de regularização chamado $Regularização\ Bayesiana$. Neste método, a função de validação de desempenho da RNA é alterada, de forma que esta tenha pesos e bias menores, o que resulta em uma resposta mais suave da rede e uma menor probabilidade de sobre-ajuste [61]. A função $f_{mse}(e)$ normalmente usada para avaliar o desempenho de uma RNA é a média da soma dos quadrados dos erros. Assim, chamando de e_i o erro de cada um dos N valores de saída em relação aos valores correspondente de treinamento, tem-se:

$$f_{mse}(e) = \frac{1}{N} \sum_{i=1}^{N} (e_i)^2$$
 (Eq.7.8)

Esta função é alterada, de forma a adicionar um termo que é a soma dos quadrados dos pesos sinápticos e *biases*, w_j , da RNA. Chamando esta nova função de $f_{msereg}(e)$ e considerando que a rede possua n pesos e biases, resulta:

$$f_{msereg}(e) = \gamma \left(\frac{1}{N} \sum_{i=1}^{N} (e_i)^2\right) + (1 - \gamma) \left(\frac{1}{n} \sum_{j=1}^{n} (w_j)^2\right)$$
 (Eq.7.9)

Onde y é chamada de razão de desempenho [67].

Na *toolbox* da linguagem Matlab, este tipo de treinamento é conseguido definido-se o parâmetro *trainFcn* como *trainbr*. Foram realizados 4 treinamentos da RNA usando este algoritmo, e os valores máximos e médios de ΔE^*_{ab} , assim como as porcentagens dos valores de ΔE^*_{ab} inferiores ao valor de JND são mostrados na tabela 7.5.

Tabela 7.5 - Valores de ΔE^*ab médio, máximo e porcentagem inferior a JND = 2,3, obtidos para cada treinamento, para o conjunto de verificação, usando o *algoritmo de Regularização Bayesiana*. São mostrados os resultados para 5, 10 e 20 neurônios na camada escondida.

Número do	Rede Única - 5 neurônios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	1,0259	7,8528	90,5650	
2	0,9514	7,4728	92,3721	
3	0,9955	7,5382	90,8883	
4	1,0268	7,3961	90,0133	
Número do	Rede	Única - 10 neurônios		
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,9519	7,2978	93,3993	
2	0.9262	7,3223	93,5705	
3	0,9439	7,3403	93,4754	
4	0,9256	7,3476	93,8748	
Número do	Rede Única - 20 neurônios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,8982	7,4617	94,6928	
2	0,8927	7,4509	93,9509	
3	0,8816	7,4089	93,9129	
4	0,8966	7,4380	94,5406	

Como pode ser observado, houve uma melhora significativa no desempenho das redes, em decorrência do aumento da sua capacidade de generalização, com o uso da *Regularização Bayesiana*. Assim como no caso das redes treinadas com o *algoritmo de Levenberg-Marquardt*, a rede com 5 neurônios na camada escondida apresenta desempenho sensívelmente inferior. As redes com 10 e 20 neurônios apresentam desempenho bastante próximos.

O tempo para treinamento das RNAs com 5, 10 e 20 neurônios é de aproximadamente 4 min, 8 min e 20 min respectivamente, usando-se um computador com processador da Intel T2080 operando a 1,73GHz, e com 2GB de memória RAM.

Pelo teorema da aproximação universal, qualquer função não linear contínua definida num domínio compacto (fechado), pode ser aproximada por uma RNA com uma única camada escondida [60]. No entanto, ainda não se conhece o número de neurônios necessários para aproximar a função, e a utilização de camadas escondidas adicionais pode melhorar o desempenho do processo, reduzindo a complexidade da topologia. Como o conhecimento a respeito das características da função de mapeamento procurada é quase inexistente, foi realizado um estudo sobre o desempenho de uma RNA com duas camadas escondidas, na aproximação desta função. A arquitetura da rede utilizada está na Fig 7.6.

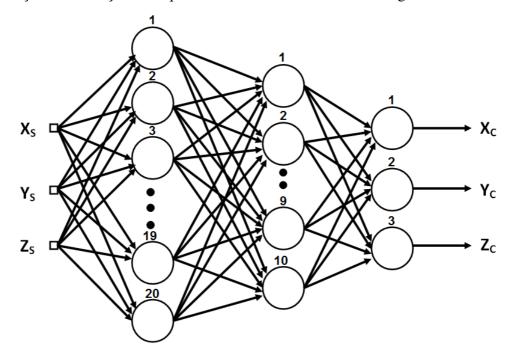


Fig 7.6- Arquitetura da rede neural experimentada com duas camadas escondidas.

Foram feitos 4 treinamentos com esta rede usando o *algoritmo de Regularização Bayesiana*, obtendo-se assim 4 redes diferentes. A cada uma delas foi aplicado o mesmo

conjunto de dados usados para verificação das redes com uma única camada escondida. Os valores de $\Delta E^*_{ab(m\acute{e}dio)}$, $\Delta E^*_{ab(m\acute{a}ximo)}$ e as porcentagens dos valores de ΔE^*_{ab} inferiores ao valor de JND, para cada rede, estão mostradas na tabela 7.6. Para uma melhor visualização das diferenças de desempenho, foram repetidos nesta tabela os valores obtidos para a rede com uma única camada escondida com 20 neurônios.

Os resultados obtidos mostram que não houve melhora significativa de desempenho, ao ser usada uma RNA com 2 camadas de neurônios escondidas. Considerando os treinamentos que produziram o melhor resultado em cada caso, e para cada uma das grandezas consideradas, a maior melhoria obtida foi para o valor de $\Delta E^*_{ab(m\acute{a}ximo)}$, que foi reduzido em 0,2083, que representa uma redução de apenas 2,8% em relação ao valor produzido com a rede com uma única camada escondida. Assim, a complexidade e aumento do custo computacional envolvidos no uso da RNA com 2 camadas escondidas, frente à pequena melhoria obtida, não justificam o seu uso.

Embora o valor de $\Delta E^*_{ab(m\acute{e}dio)}$ represente uma medida de desempenho das RNAs na aproximação da função de mapeamento, para a aplicação deste conceito em um equipamento

Tabela 7.6 - Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para cada treinamento, para o conjunto de verificação, usando o *algoritmo de Regularização Bayesiana*. São mostrados os resultados para rede com 2 camadas escondidas com 20 e 10 neurônios na camada escondida e 1 camada escondida com 20 neurônios.

Número do	Rede 2 Camad. Escond 20 - 10 neurônios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,8793	7,2006	94,4455	
2	0,8664	7,4040	94,5026	
3	0,8616	7,2134	94,4645	
4	0,8571	7,2968	94,3314	
Número do	Rede 1 Camad. Escond 20 neurônios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,8982	7,4617	94,6928	
2	0,8927	7,4509	93,9509	
3	0,8816	7,4089	93,9129	
4	0,8966	7,4380	94,5406	

de medida de cores, os valores mais importantes são os valores de $\Delta E^*_{ab(m\acute{a}ximo)}$, que representam o máximo erro que poderá ser cometido em uma medida, e a porcentagem das

medidas cujo valor de ΔE^*_{ab} é menor do que o valor de JND. Nestes casos, a diferença de medida para o valor real não será visualmente detectado pelo usuário.

Ao serem usadas RNAs para aproximar a função de mapeamento, o melhor (menor) valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ obtido foi de 7,2006, e a melhor (maior) porcentagem de ΔE^*_{ab} menor do que o valor de JND foi de 94,6928. Embora estes resultados sejam razoavelmente satisfatórios matematicamente, na prática seria desejável diminuir o $\Delta E^*_{ab(m\acute{a}ximo)}$ e aumentar a porcentagem das medidas cujo valor de ΔE^*_{ab} é menor do que o valor de JND.

7.3.2. O mapeamento usando redes neurais artificiais especializadas

Lembrando que os valores de os valores de X_S , Y_S e Z_S , X_C , Y_C e Z_C são calculados integrando-se os espectros refletidos na amostra sob as curvas mostradas na Fig 6.5, e que estas curvas possuem uma sobreposição entre elas mais acentuada na região central do espectro visível, é intuitivo pensar que a RNA terá uma dificuldade maior em aproximar a função de mapeamento nesta região. A solução proposta neste trabalho é, portanto, utilizar 3 RNAs distintas, cada uma especializada em um trecho do espectro visível, levando em consideração a predominância do triestímulo da amostra na parte baixa, média ou alta do espectro visível. Esta classificação pode ser feita através dos valores de X_S , Y_S e Z_S , que são os valores de entrada da RNA.

A arquitetura escolhida inicialmente para as 3 RNAs foi a que possui uma única camada escondida com 10 neurônios, como mostrado na Fig. 7.2. Esta escolha é fundamentada no desempenho anteriormente observado desta arquitetura, que é razoavelmente simples e cujos resultados não são muito diferentes dos obtidos com arquiteturas maiores ou mais complexas.

O primeiro passo é classificar os espectros do banco de espectros de refletância publicado na Internet pela Universidade de Tecnologia de Lappeenranta em 3 conjuntos. No primeiro conjunto estão os espectros cujo triestímulo com maior valor é X_S , no segundo, aqueles espectros cujo maior triestímulo é Y_S , e no terceiro conjunto os espectros restantes, cujo maior triestímulo é Z_S . Ao fazer esta classificação, foram obtidos conjuntos de espectros com 124, 612 e 533 espectros respectivamente. A seguir, para cada um destes conjuntos foram gerados espectros, usando o mesmo método anteriormente usado para geração de espectros simulados, e descrito nas Eq.7.6 e Eq. 7.7, sendo que os intervalos entre os valores de i e de j foram ajustados de forma que o tamanho de cada conjunto de espectros fosse aproximadamente igual ao tamanho do conjunto de espectros usados no treinamento e

verificação. Os conjuntos de espectros resultantes da aplicação deste método ficaram respectivamente com 17.121, 16.320 e 16.464 espectros. É claro que devido ao método utilizado, chamando-se de T_S o triestímulo dominante (X_S , Y_S ou Z_S), pode-se garantir que os espectros simulados obtidos a partir da média de dois espectros cujo triestímulo predominante é T_S , também terão o triestímulo predominante T_S . O mesmo procedimento usado no caso com uma única RNA foi aplicado neste caso, para dividir cada um dos conjuntos de espectros em 2 partes; a primeira, com 70% do número de espectros, é aplicada no treinamento da rede e a segunda, com os espectros restantes do conjunto, é utilizada no processo de verificação.

Chamando-se de RNA-R, RNA-G e RNA-B as 3 RNAs com a arquitetura selecionada, com 10 neurônios em uma única camada escondida, os dados de treinamento do primeiro, segundo e terceiro conjuntos de espectros foram usados para treinar respectivamente as redes RNA-R, RNA-G e RNA-B. Foram realizados 4 treinamentos de cada uma das RNAs usando o *algoritmo com Regularização Bayesiana*, e os valores máximos e médios de ΔE^*_{ab} , assim como as porcentagens dos valores de ΔE^*_{ab} inferiores ao valor de JND, obtidos ao aplicar os respectivos conjuntos de verificação são mostrados na tabela 7.7.

Um fato que chama a atenção nos resultados mostrados na tabela 7.7 é que o desempenho das redes RNA-R e RNA-B é bastante superior ao desempenho de todas as configurações apresentadas anteriormente. Tanto os valores de $\Delta E^*_{ab(m\acute{e}dio)}$ como os de $\Delta E^*_{ab(m\acute{a}ximo)}$ são inferiores aos obtidos com a rede de 20 neurônios na camada escondida. Praticamente todos os resultados do mapeamento feito por estas redes possuem erro menor do que o valor de JND.

Também pode ser observado que o desempenho da rede RNA-G é significativamente inferior ao resultado das redes RNA-R e RNA-B, sendo seu $\Delta E_{ab(médio)}^*$ de 1,1629, 25,6% pior (maior) do que os obtidos com uma única rede com 10 neurônios na camada escondida. Também a porcentagem dos valores de ΔE_{ab}^* inferiores ao valor de JND é pior (menor) do que os apresentados nos casos anteriores. Estes resultados concordam com a suposição feita inicialmente, e que motivou o uso de RNAs especializadas, de que a RNA teria uma dificuldade maior em aproximar a função de mapeamento na região central do espectro visível. Esta maior dificuldade é atribuída ao fato das curvas mostradas na Fig. 6.5 possuírem uma sobreposição entre elas mais acentuada na região central do espectro visível. Por outro lado, o valor de $\Delta E_{ab(máximo)}^*$ obtido pela rede RNA-G, para o treinamento 3, é melhor (menor) do que os valores obtidos nos casos anteriores, o que era um dos objetivos da utilização das redes especializadas.

Tabela 7.7 - Valores de ΔE*ab médio, máximo e porcentagem inferior a JND = 2,3, obtidos para cada treinamento, para o conjunto de verificação, usando o algoritmo de Regularização Bayesiana para 3 RNAs especializadas com 10 neurônios na camada escondida.

3 RNAs - 1 camada escondida - 10 Neuronios					
Número do	RNA-R				
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	0,4287	1,6946	100,0000		
2	0,4349	1,7552	100,0000		
3	0,4304	1,6696	100,0000		
4	0,4253	1,7340	100,0000		
Número do	RNA-G				
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	1,1645	5,6536	87,7451		
2	1,1648	5,7467	87,7247		
3	1,1629	5,3466	87,5000		
4	1,1835	7,5889	86,9077		
Número do	RNA-B				
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	0,7813	2,7091	99,4938		
2	0,7823	2,6188	99,6963		
3	0,7740	2,5302	99,8178		
4	0,7905	2,7723	99,3521		

Todas as 3 RNAs consideradas, RNA-R, RNA-G e RNA-B possuem 10 neurônios na camada escondida, porém pode acontecer que um desempenho otimizado para uma das redes possa ser obtido com um determinado número de neurônios, e para outra rede este número seja diferente. Para a determinação do número de neurônios a ser usado na camada escondida, de forma independente para cada uma das redes, foram estudadas redes com 5, 15, 25 e 50 neurônios nesta camada. Os conjuntos de dados usados para treinamento e verificação foram os mesmos aplicados nas redes com 10 neurônios do caso anterior, cujos resultados estão mostrados na tabela 7.7.

Na tabela 7.8 estão mostrados os resultados deste estudo para a rede RNA-R, onde as grandezas e o número de treinamentos realizados com cada rede são os mesmos usados nos casos anteriores, sendo que os resultados com 10 neurônios são repetidos aqui para permitir uma melhor visualização, para feito de comparação.

Tabela 7.8 - RNA-R: Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para o conjunto de verificação, com 5, 25, 25 e 50 neurônios na camada escondida. Para comparação, são mostrados aqui, novamente, os resultados para esta rede com 10 neurônios na camada escondida (continua).

	RNA-R	1			
Número do	5 MAS 1 Camada esconarda 5 Mediomos				
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	0,4506	1,7877	100,0000		
2	0,4456	1,8289	100,0000		
3	0,4512	1,7687	100,0000		
4	0,4561	1,7450	100,0000		
Número do	3 RNAs - 1 cam	ada escondida - 10 N	euronios		
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	0,4287	1,6946	100,0000		
2	0,4349	1,7552	100,0000		
3	0,4304	1,6696	100,0000		
4	0,4253	1,7340	100,0000		
Número do	3 RNAs - 1 camada escondida - 15 Neuronios				
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	0,4259	1,7337	100,0000		
2	0,4295	1,7114	100,0000		
3	0,4277	1,7831	100,0000		
4	0,4291	1,7253	100,0000		
Número do	3 RNAs - 1 camada escondida - 25 Neuronios				
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	0,4272	1,7744	100,0000		
2	0,4263	1,7598	100,0000		
3	0,4272	1,7744	100,0000		
4	0,4263	1,7598	100,0000		
Número do	3 RNAs - 1 camada escondida - 50 Neuronios				
Treinamento	ΔE*ab (médio)	ΔE*ab (máximo)	% < JND		
1	0,4276	1,8009	100,0000		
2	0,4232	1,7370	100,0000		
3	0,4263	1,7720	100,0000		
4	0,4291	1,7137	100,0000		

A tabela 7.8 mostra que em todos os casos o mapeamento foi realizado com valores de ΔE^*_{ab} inferiores ao valor de JND, porém o menor $\Delta E^*_{ab(m\acute{a}ximo)}$ é obtido no treinamento 3 da rede com 10 neurônios na camada escondida. Portanto, a RNA com 10 neurônios na camada escondida foi selecionada como a de melhor desempenho.

A Fig. 7.7 mostra um gráfico da variação dos valores de $\Delta E^*_{ab(m\acute{e}dio)}$ e $\Delta E^*_{ab(m\acute{a}ximo)}$, onde são considerados os resultados dos treinamentos com os menores valores de $\Delta E^*_{ab(m\acute{a}ximo)}$, das redes RNA-R com 5, 10, 15, 25 e 50 neurônios na camada escondida. Pode-

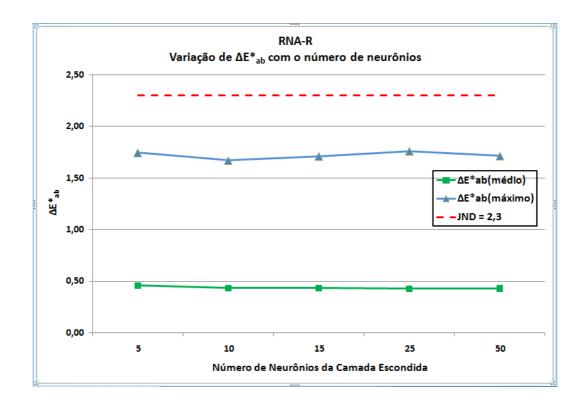


Fig 7.7- RNA-R: Gráfico da variação de ΔE^*_{ab} com o número de neurônios na camada escondida.

se observar que o valor de $\Delta E^*_{ab(m\acute{e}dio)}$ diminui lentamente com o aumento do número de neurônios. Também se observa que o valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ passa por um mínimo para 10 neurônios na camada escondida, o que reforça os argumentos para a escolha desta rede como a de melhor desempenho. Outro fato importante mostrado pela Fig. 7.7 é que todos os valores de $\Delta E^*_{ab(m\acute{e}dio)}$ e $\Delta E^*_{ab(m\acute{a}ximo)}$ estão abaixo do valor de JND, cujo valor é aproximadamente 2,3 para o espaço de cor $L^*a^*b^*$.

A Fig. 7.8 mostra o histograma da distribuição de ΔE^*_{ab} obtida com o treinamento 3 para a rede RNA-R com 10 neurônios na camada escondida. Observa-se que o valor de

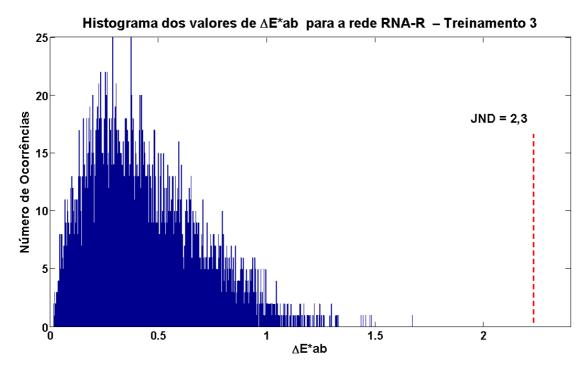


Fig 7.8- Histograma dos valores de ΔE^* ab para a rede RNA-R – Treinamento 3.

 $\Delta E^*_{ab(m\acute{a}ximo)}$ neste caso está afastado de aproximadamente uma unidade de ΔE^*_{ab} dos valores que aparecem em torno de 1,5. Assim, neste caso, pode-se considerar que o $\Delta E^*_{ab(m\acute{a}ximo)}$ não é um *outlier*.

Ao se repetir o estudo para a rede RNA-G, são obtidos os resultados mostrados na tabela 7.9.

Tabela 7.9 - RNA-G: Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para o conjunto de verificação, com 5, 25, 25 e 50 neurônios na camada escondida. Para comparação, são mostrados aqui, novamente, os resultados para esta rede com 10 neurônios na camada escondida (continua).

RNA-G					
Número do	3 RNAs - 1 camada escondida - 5 Neuronios				
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND		
1	1,2120	9,2747	86,3971		
2	1,2061	8,5625	85,5801		
3	1,1990	8,7510	87,2345		
4	1,2368	8,1828	86,4992		
Número do	3 RNAs - 1 cama	da escondida - 10 Ne	uronios		
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND		
1	1,1645	5,6536	87,7451		
2	1,1648	5,7467	87,7247		
3	1,1629	5,3466	87,5000		
4	1,1835	7,5889	86,9077		

Tabela 7.9 - RNA-G: Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para o conjunto de verificação, com 5, 25, 25 e 50 neurônios na camada escondida. Para comparação, são mostrados aqui, novamente, os resultados para esta rede com 10 neurônios na camada escondida (conclusão).

RNA-G			
Número do	3 RNAs - 1 camada escondida - 15 Neuror		
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND
1	1,1763	6,3556	86,9894
2	1,1692	5,5262	87,6021
3	1,1610	5,7644	87,6225
4	1,1681	5,7403	87,4592
Número do	3 RNAs - 1 cama	da escondida - 25 N	euronios
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND
1	1,1633	5,9622	87,7655
2	1,1682	5,8958	86,9281
3	1,1675	5,5407	87,5204
4	1,1616	5,7488	87,5000
Número do	3 RNAs - 1 cama	da escondida - 50 N	euronios
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND
1	1,1551	5,7394	87,8268
2	1,1651	5,7289	87,6021
3	1,1580	5,7688	87,7042
4	1,1662	5,6233	87,4796

A tabela 7.9 mostra que a queda de desempenho da rede RNA-G permanece elevada quando o número de neurônios da camada escondida é aumentado até 50 neurônios. O melhor (menor) valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ é conseguido com a rede de 10 neurônios e com o treinamento 3. O melhor valor da porcentagem de entradas com erro de mapeamento menor que JND resulta com a rede de 50 neurônios com o treinamento 1.

A tabela 7.10 mostra, para estes dois casos, os valores mencionados e as diferenças entre eles, para efeito de comparação. Observando a última linha desta tabela, nota-se que o valor de $\Delta E^*_{ab(m\acute{e}dio)}$ é maior, para a rede com 10 neurônios, na ordem de milésimos, valor este bastante pequeno quando comparado ao valor de JND. Pode-se considerar então que as duas redes, neste aspecto, possuem desempenhos semelhantes. Com relação aos valores de $\Delta E^*_{ab(m\acute{a}ximo)}$, a rede com 10 neurônios possui desempenho ligeiramente superior. Por outro lado para o valor de porcentagem de entradas com erro de mapeamento menor que JND, é a

Tabela 7.10 - RNA-G: Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para o conjunto de verificação, com 10 e 50 neurônios na camada escondida. A última linha mostra a diferença destes valores entre a rede de 10 neurônios e a rede de 50 neurônios.

RNA-G					
Neurônios	Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
10	3	1,1629	5,3466	87,5000	
50	1	1,1551	5,7394	87,8268	
Diferença (10-50) 0,0078 -0,3928 -0,3268					

rede com 50 neurônios que possui desempenho ligeiramente superior, porém esta diferença, por ser muito pequena, não justificaria a escolha desta rede, que tem custo computacional muito maior que a rede de 10 neurônios. Assim, a escolha da rede a ser usada recai sobre a rede com 10 neurônios com o treinamento 3.

A Fig. 7.9 mostra um gráfico da variação dos valores de $\Delta E^*_{ab(m\acute{e}dio)}$ e $\Delta E^*_{ab(m\acute{a}ximo)}$, onde são considerados os resultados dos treinamentos com os menores valores de $\Delta E^*_{ab(m\acute{a}ximo)}$, das redes RNA-G com 5, 10, 15, 25 e 50 neurônios na camada escondida.

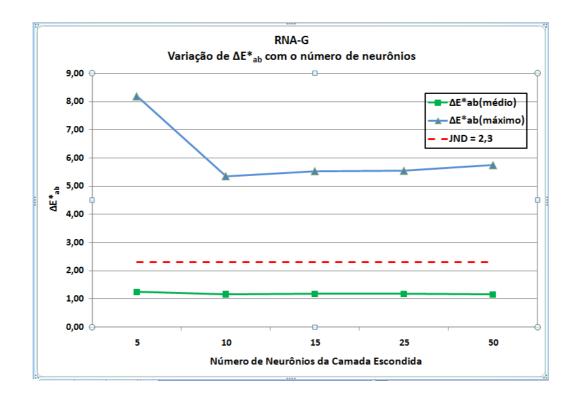


Fig 7.9- RNA-G: Gráfico da variação de ΔE^*_{ab} com o número de neurônios na camada escondida.

A Fig. 7.10 mostra o histograma da distribuição de ΔE^*_{ab} obtida com o treinamento 3 para a rede RNA-G com 10 neurônios na camada escondida. Observa-se que o valor de

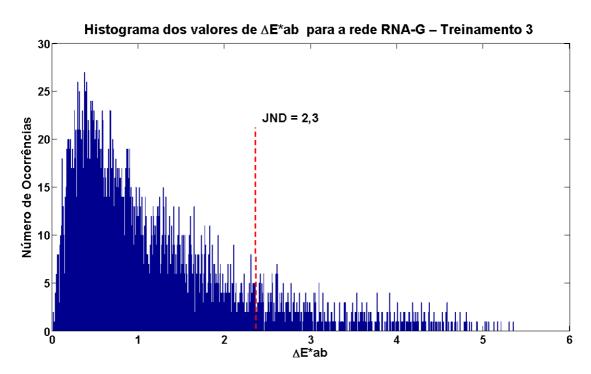


Fig 7.10- Histograma dos valores de ΔE *ab para a rede RNA-G – Treinamento 3.

 $\Delta E^*_{ab(m\acute{a}ximo)}$ neste caso está afastado de aproximadamente 0,1 unidades de ΔE^*_{ab} dos valores que aparecem em torno de 5,2. Assim, também neste caso pode-se considerar que o $\Delta E^*_{ab(m\acute{a}ximo)}$ não é um *outlier*.

Ao se repetir novamente o estudo, agora para a rede RNA-B, são obtidos os resultados mostrados na tabela 7.11

A tabela 7.11 mostra que existem pequenas diferenças de desempenho entre as redes de 10, 15, 25 e 50 neurônios. A única rede com desempenho sensivelmente inferior é a rede com 5 neurônios. Com o objetivo de facilitar a visualização, as linhas da tabela 7.11 correspondentes aos melhores desempenhos em cada uma das grandezas são mostradas na tabela 7.12

O melhor (menor) valor de $\Delta E^*_{ab(m\acute{e}dio)}$ foi obtido com o treinamento 2 da rede com 25 neurônios; o melhor (menor) valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ foi obtido com o treinamento 4 da rede com 15 neurônios e o melhor valor da porcentagem de entradas com erro de mapeamento

Tabela 7.11 - RNA-B: Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para o conjunto de verificação, com 5, 15, 25 e 50 neurônios na camada escondida. Para comparação, são mostrados aqui, novamente, os resultados para esta rede com 10 neurônios na camada escondida (continua).

RNA-B				
Número do	3 RNAs - 1 can	nada escondida - 5 Ne	euronios	
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,8508	3,6397	97,9551	
2	0,8132	4,8407	98,0360	
3	0,8823	3,6220	97,5096	
4	0,8847	3,9624	97,0642	
Número do	3 RNAs - 1 cam	ada escondida - 10 N	euronios	
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,7813	2,7091	99,4938	
2	0,7823	2,6188	99,6963	
3	0,7740	2,5302	99,8178	
4	0,7905	2,7723	99,3521	
Número do	3 RNAs - 1 camada escondida - 15 Neuronios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,7622	2,6521	99,7570	
2	0,7743	2,7514	99,7165	
3	0,7753	2,7690	99,4331	
4	0,7765	2,4846	99,7570	
Número do	3 RNAs - 1 cam	ada escondida - 25 N	euronios	
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,7784	2,7125	99,7368	
2	0,7680	2,6303	99,6356	
3	0,7711	2,6252	99,6558	
4	0,7989	2,9030	99,4533	
Número do	3 RNAs - 1 camada escondida - 50 Neuronios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,7710	2,7012	99,6760	
2	0,7774	2,7351	99,6356	
3	0,7711	2,5958	99,6963	
4	0,7731	2,6719	99,6558	

Tabela 7.12 - Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para o conjunto de verificação, para a rede RNA-B com 10, 15, 25 e 50 neurônios na camada escondida, correspondente aos melhores desempenhos de cada uma delas.

RNA-B					
Neurônios	Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
10	3	0,7740	2,5302	99,8178	
15	4	0,7765	2,4846	99,7570	
25	2	0,7680	2,6303	99,6356	
50	3	0,7711	2,5958	99,6963	

menor que JND resulta da rede de 10 neurônios com o treinamento 3. Uma vez que, para a aplicação desejada para esta metodologia de mapeamento, os valores mais relevantes são o $\Delta E^*_{ab(m\acute{a}ximo)}$ e a porcentagem de entradas com erro de mapeamento menor que JND, a escolha da rede a ser usada recai sobre a rede com 10 neurônios com o treinamento 3, pois é a rede com menor custo computacional e a diferença de $\Delta E^*_{ab(m\acute{a}ximo)}$ entre esta e a rede com 15 neurônios é igual a 0,0456, que corresponde a um aumento de apenas 1,8%.

A Fig. 7.11 mostra um gráfico da variação dos valores de $\Delta E^*_{ab(médio)}$ e $\Delta E^*_{ab(méximo)}$.

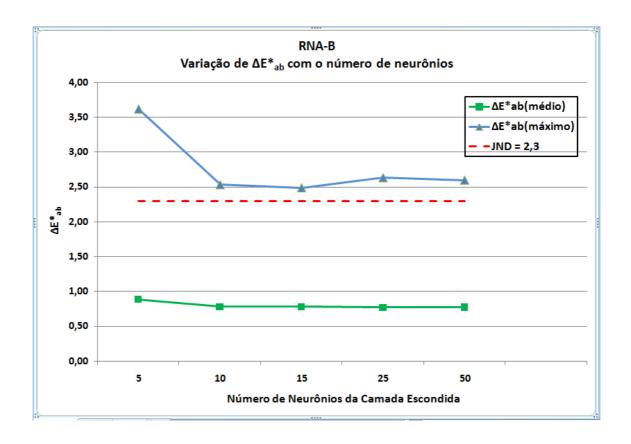


Fig 7.11- RNA-B: Gráfico da variação de ΔE^*_{ab} com o número de neurônios na camada escondida.

onde são considerados os resultados dos treinamentos com os menores valores de $\Delta E^*_{ab(m\acute{a}ximo)}$, das redes RNA-B com 5, 10, 15, 25 e 50 neurônios na camada escondida

A Fig. 7.12 mostra o histograma da distribuição de ΔE^*_{ab} obtida com o treinamento 3 para a rede RNA-B com 10 neurônios na camada escondida. Observa-se que o valor de

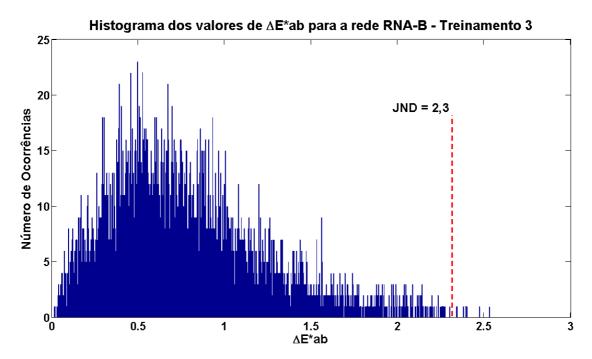


Fig 7.12- Histograma dos valores de ΔE *ab para a rede RNA-B – Treinamento 3.

 $\Delta E^*_{ab(m\acute{a}ximo)}$ neste caso está afastado de aproximadamente 0,2 unidades de ΔE^*_{ab} dos valores que aparecem em torno de 2,4. Assim, também neste caso pode-se considerar que o $\Delta E^*_{ab(m\acute{a}ximo)}$ não é um *outlier*.

O conjunto final de redes selecionadas e seus respectivos desempenhos são mostrados na tabela 7.13.

Tabela 7.13 - Redes se	lecionadas e seus	desempenhos.
------------------------	-------------------	--------------

Rede	Neurônios	Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND
RNA-R	10	3	0,4304	1,6696	100,0000
RNA-G	10	3	1,1629	5,3466	87,5000
RNA-B	10	3	0,7740	2,5302	99,8178

Para efeito de comparação do método usando redes especializadas com o método de utilização de uma única RNA com uma camada escondida, os resultados devem ser

apresentados sob uma perspectiva global, observando-se o desempenho do método quando considerada a totalidade dos dados de entrada e de saída, sem separá-los por tipo de rede.

O valor de $\Delta E^*_{ab(m\acute{e}dio)}$ global é a média ponderada dos valores de $\Delta E^*_{ab(m\acute{e}dio)}$ destas 3 RNAs, em relação ao número de dados de verificação de cada uma das redes. Desta forma tem-se:

k= número de entradas de verificação para a rede RNA-Rl= número de entradas de verificação para a rede RNA-G

m= número de entradas de verificação para a rede RNA-B

 $M_1 = \Delta E^*_{ab(m\acute{e}dio)}$ para a rede RNA-R

 $M_2 = \Delta E^*_{ab(m\acute{e}dio)}$ para a rede RNA-G

 $M_3 = \Delta E^*_{ab(m\acute{e}dio)}$ para a rede RNA-B

 $M = \Delta E^*_{ab(m\acute{e}dio)}$ global

$$M = \frac{k.M_1 + l.M_2 + m.M_3}{k + l + m}$$
 (Eq. 7.10)

O valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ global é o maior valor entre os três melhores (menores) valores de $\Delta E^*_{ab(m\acute{a}ximo)}$, para cada uma das redes. Este valor resulta da aplicação da RNA-G com o treinamento 3. Assim, tem-se

 E_R = mínimo dos valores de $\Delta E^*_{ab(m\acute{a}ximo)}$ para a rede RNA-R

 E_G = mínimo dos valores de $\Delta E^*_{ab(m\acute{a}ximo)}$ para a rede RNA-G

 E_B = mínimo dos valores de $\Delta E^*_{ab(m\acute{a}ximo)}$ para a rede RNA-B

 $E_{GLOBAL} = \Delta E^*_{ab(m\acute{a}ximo)}$ global

$$E_{GLOBAL} = \text{máximo}[E_{R}, E_{G}, E_{B}]$$
 (Eq. 7.11)

A porcentagem global dos valores de ΔE^*_{ab} inferiores ao valor de JND é determinada calculando-se, para cada uma das redes, o número de dados de entrada que resulta em um ΔE^*_{ab} inferior ao valor de JND. Estes valores são somados, divididos pelo número total de entradas e multiplicado por 100. Os resultados calculados desta forma são mostrados na tabela 7.14. Para efeito de comparação, estão também mostrados os resultados obtidos com a rede com 2 camadas escondidas, que foi a rede anteriormente experimentada com melhor desempenho.

Tabela 7.14 - Resultados globais considerando os melhores valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para o conjunto de verificação, para 3 RNAs especializadas com 10 neurônios na camada escondida. Para comparação, são mostrados os resultados para a rede com 2 camadas escondidas com 20-10 neurônios.

	Resultados Globais 3 RNAs - 1 camada escondida - 10 Neuronios			
	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
	0,7833 5,3466 95,8521			
Número do	Rede 2 Camad. Escond 20 - 10 neurônios			
Treinamento	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND	
1	0,8793	7,2006	94,4455	
2	0,8664	7,4040	94,5026	
3	0,8616	7,2134	94,4645	
4	0,8571	7,2968	94,3314	

Estes resultados mostram que, apesar da perda desempenho da rede RNA-G, em relação aos resultados obtidos com a utilização de uma única RNA, as redes RNA-R e RNA-B tiveram um incremento de desempenho tão acentuado, que de forma global o uso de redes especializadas superou o desempenho de uma única rede.

7.3.3. Principais inovações e contribuições do método

A principal inovação do método apresentado neste trabalho é a classificação dos dados de entrada de acordo com o triestímulo dominante, e a utilização de uma RNA específica, especializada no processamento de cada uma das classes de entrada. Não foi encontrado na literatura nenhum trabalho onde este critério fosse utilizado.

A principal contribuição é a disponibilização de um método de mapeamento de espaços de cor cujos valores de erro, expressos por $\Delta E^*_{ab(m\acute{e}dio)}$ e $\Delta E^*_{ab(m\acute{e}dio)}$ são menores do que os encontrados na literatura. Este método possui aplicação direta em equipamentos to tipo colorímetros, que realizam medidas de cor a partir do triestímulo medido por um sensor eletrônico.

Adicionalmente, o método utiliza RNAs com uma arquitetura simples, de apenas uma camada escondida e um número pequeno de neurônios, resultando em um custo computacional reduzido. Como conseqüência desta menor complexidade e tempo de processamento reduzido, o método encontra espaço em aplicações de tempo real.

Capítulo VIII - Resultados obtidos

Foram obtidos resultados significativos na realização do mapeamento do triestímulo medido no espaço de cores definido pelo sensor TCS230, no espaço de cores colorimétrico CIEXYZ, através de em conjunto de 3 RNAs, que passam a ser denominadas Redes Especializadas. Os valores de $\Delta E^*_{ab(médio)}$, $\Delta E^*_{ab(máximo)}$ e a porcentagem de entradas com erro de mapeamento menor que JND se sobressaem, quando comparados com os valores de outros trabalhos realizados na área. Neste capítulo, os resultados obtidos com as Redes Especializadas são comparados com os resultados de cada um dos métodos citados no Capítulo II e no Capítulo VII.

O método usado por Poynton, usando uma matriz de mapeamento calculada através do conceito da matriz pseudo-inversa de Moore-Penrose, foi repetido neste trabalho, no Capítulo VII, usando o iluminante D50, em vez do iluminante D65, e também usando um filtro modelo CM500 do fabricante Hoya, de características diferentes do usado por Poynton. O desempenho resultante da aplicação da matriz pseudo-inversa está mostrado na tabela 7.2 e é superado pelo desempenho do método desenvolvido neste trabalho, mostrado na tabela 7.14. Estão repetidos na tabela 8.1, para uma melhor visualização, os resultados obtidos nos dois métodos, facilitando a comparação entre eles.

Pode-se observar que as Redes Especializadas conseguem resultados melhores em todas as grandezas, com destaque para o $\Delta E^*_{ab(m\'edio)}$, que é aproximadamente 4 vezes menor e porcentagem de entradas com erro de mapeamento menor que JND que é aproximadamente 50% maior.

Um segundo método utilizado para aproximar as funções que fazem o mapeamento entre espaços de cor é a Regressão Polinomial Múltipla (RPM), que foi explicada no capítulo VII. Este método foi usado por Kang [36] para mapear o espaço Xerox/RGB no espaço CIELAB, usando 4 polinômios da tabela 7.3 com 4, 8, 14 e 20 termos. Foram usados 729 pontos do espaço RGB para o cálculo dos coeficientes, de um total de 3072 pontos selecionados. Está mostrado na tabela 8.2, o resultado obtido para os valores de $\Delta E^*_{ab(médio)}$, usando os dados de verificação, isto é, os dados não usados para o cálculo dos coeficientes.

Tabela 8.1 - Comparação de Resultados com Ref.[7]: Valores de ΔE^*_{ab} médio, máximo e porcentagem inferior a JND = 2,3, obtidos para os métodos da Matriz Pseudo-inversa das Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < JND
Matriz Pseudo-inversa	3,0173	7,9566	62,5000
Redes Especializadas	0,7833	5,3466	95,8521
Melhoria de Desempenho (%)	74,04	32,80	53,36

O valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ aproximado só foi mostrado para o polinômio com 14 termos e é maior do que 18. A porcentagem de pontos com erro menor que JND não está disponível.

Tabela 8.2 - Comparação de Resultados com Ref.[36]: Valores de ΔE^*ab (médio) obtidos por regressão polinomial, para polinômios com 4, 8, 14 e 20 termos, no mapeamento do espaço Xerox/RGB para o espaço CIELAB.

Método	N° de Termos	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
	4	10,60	-
Regressão Polinomial	8	8,00	-
Múltipla	14	4,04	> 18
	20	1,73	-
Redes Especializadas	-	0,7833	5,3466
Melhoria de Desempenho (%)	-	54,72	> 70,29

O $\Delta E^*_{ab(m\'edio)}$ obtido com o método de redes especializadas, de 0,7833 é menor que a metade do melhor (menor) $\Delta E^*_{ab(m\'edio)}$ resultado usando regressão polinomial, com um polinômio de 20 termos.

O método de RPM também foi usado por Han, K. et. al. [8] para caracterizar uma impressora, mapeando seu espaço CMY no espaço CIEXYZ, a partir de 729 amostras impressas pela impressora. Foram usados os polinômios de segunda ordem, mostrados nas (Eq. 8.1) a (Eq. 8.3), e terceira ordem, mostrados nas (Eq. 8.4) a (Eq. 8.6), para fazer o mapeamento.

$$D_X = a_1C + a_2M + a_3Y + a_4CM + a_5CY + a_6MY + a_7C^2 + a_8M^2 + a_9Y^2$$
 (Eq. 8.1)

$$D_Y = b_1 C + b_2 M + b_3 Y + b_4 C M + b_5 C Y + b_6 M Y + b_7 C^2 + b_8 M^2 + b_9 Y^2$$
 (Eq. 8.2)

$$D_Z = c_1 C + c_2 M + c_3 Y + c_4 C M + c_5 C Y + c_6 M Y + c_7 C^2 + c_8 M^2 + c_9 Y^2$$
 (Eq. 8.3)

$$\begin{split} D_X &= p_1C + p_2M + p_3Y + p_4CM + p_5CY + p_6MY + p_7C^2 + p_8M^2 + p_9Y^2 + \\ &\quad p_{10}C^3 + p_{11}M^3 + p_{12}Y^3 + p_{13}CM^2 + p_{14}CY^2 + p_{15}MC^2 + p_{16}MY^2 + \\ &\quad p_{17}YC^2 + p_{18}YM^2 \end{split} \tag{Eq. 8.4}$$

$$D_{Y} = r_{1}C + r_{2}M + r_{3}Y + r_{4}CM + r_{5}CY + r_{6}MY + r_{7}C^{2} + r_{8}M^{2} + r_{9}Y^{2} + r_{10}C^{3} + r_{11}M^{3} + r_{12}Y^{3} + r_{13}CM^{2} + r_{14}CY^{2} + r_{15}MC^{2} + r_{16}MY^{2} + r_{17}YC^{2} + r_{18}YM^{2}$$
(Eq. 8.5)

$$D_Z = r_1C + r_2M + r_3Y + r_4CM + r_5CY + r_6MY + r_7C^2 + r_8M^2 + r_9Y^2 + r_{10}C^3 + r_{11}M^3 + r_{12}Y^3 + r_{13}CM^2 + r_{14}CY^2 + r_{15}MC^2 + r_{16}MY^2 + r_{17}YC^2 + r_{18}YM^2$$
(Eq. 8.6)

Sendo que:

$$D_X = log_{10}(X_0/X)$$
 (Eq. 8.7)

$$D_{\rm Y} = log_{10}(Y_0/Y)$$
 (Eq. 8.8)

$$D_Z = log_{10}(Z_0/Z)$$
 (Eq. 8.9)

Os resultados obtidos com os polinômios de segunda e terceira ordem e variando-se o número de amostras, é mostrado na tabela 8.3

O melhor (menor) $\Delta E^*_{ab(m\acute{e}dio)}$ obtido neste caso, com o maior número de amostras e com o polinômio de 3ª ordem é 3 vezes e meia maior do que o obtido pelo método aqui proposto com redes especializadas. Os valores de $\Delta E^*_{ab(m\acute{a}ximo)}$ e da porcentagem de pontos com erro menor que JND não estão disponíveis

A caracterização de uma câmera digital foi feita por Yoon, C e Cho, M., usando RPM para mapear o espaço RGB da câmera no espaço CIEXYZ. Foram usadas as cores da carta *IT8*, aplicadas para treinamento e validação de vários tipos de polinômios de segunda ordem. Neste caso, os resultados da diferença de cor foram apresentados em unidades *CMC(1:1)*. Para efeito de comparação, estes resultados são apresentados na tabela 8.4, com os resultados globais obtidos pelas redes especializadas, também expressos em unidades *CMC(1:1)*.

Tabela 8.3 - Comparação de Resultados com Ref.[8]: Valores de ΔE^*ab (médio) obtidos por regressão polinomial, para polinômios de 2^a e 3^a ordem, no mapeamento do espaço CMY para o espaço CIEXYZ.

Método	N° de Amostras	Polinômio	ΔE* _{ab(médio)}
	27	2ª ordem	6,74
	27	3ª ordem	8,06
Regressão Polinomial	125	2 ^a ordem	5,29
Múltipla	125	3 ^a ordem	2,87
	729	2ª ordem	5,47
		3ª ordem	2,82
Redes Especializadas	-	-	0,7833
	1		1
Melhoria de Desempenho (%)	-	-	72,22

Pode-se observar que os resultados obtidos através das redes especializadas usadas neste trabalho superam os melhores resultados de um conjunto de 12 tipos de polinômio, usados na regressão polinomial do trabalho citado.

A caracterização de um mostrador LCD colorido foi feita por Tsai C., Liaw, M., e Shieh, H., usando RPM para gerar uma matriz de regressão 3 X 9, para mapear o espaço RGB do mostrador no espaço CIEXYZ, a partir de 793 cores geradas pelo mostrador. Neste caso, os resultados da diferença de cor foram apresentados em unidades de ΔE^*_{uv} .

Tabela 8.4 - Comparação de Resultados com Ref.[9]: Valores de ΔΕCMC(1:1) médio, máximo e percentil 95% obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através regressão polinomial de segunda ordem e no mapeamento realizado pelas Redes Especializadas.

Método	ΔE _{CMC(1:1)}		
Wictodo	ΔE _(médio)	ΔE _(máximo)	Percentil 95%
Regressão Polinomial	1,68	12,32	4,11
Redes Especializadas	1,07	8,56	2,30
Melhoria de Desempenho (%)	36,58	30,53	44,04

Para efeito de comparação, estes resultados são apresentados na tabela 8.5, com os resultados globais obtidos pelas redes especializadas, também expressos em unidades ΔE^*_{uv} .

Tabela 8.5 - Comparação de Resultados com Ref.[10]: Valores de ΔE^* uv médio, máximo e porcentagem inferior a JND = 2,9, obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através de regressão polinomial e de Redes Especializadas.

Mátada	ΔΕ* _{uν}		
Método	ΔE _(médio)	ΔE _(máximo)	% < JND
Regressão Polinomial	2,55		86,0
Redes Especializadas	0,97	5,88	97,56
Melhoria de Desempenho (%)	62,15	-	13,44

É importante ressaltar que para o espaço de cores $L^*u^*v^*$, o valor de JND é de aproximadamente 2.9 [2], sendo que o valor usado no trabalho citado foi de 3.0 e o valor de $\Delta E^*_{uv(m\acute{a}ximo)}$ não é citado. Os valores mostrados na tabela 11.5 indicam o desempenho superior do método das redes especializadas.

Um estudo abrangente foi feito por Urban, P. e Grigat, R., do mapeamento do espaço RGB de um conjunto de 6 câmeras digitais e 3 diferentes iluminantes padrão, no espaço L*a*b* definido pela CIE, usando vários métodos, entre eles, RPM e MDE ("Metamer Density Estimated Color Correction"), proposto pelos autores . As cores de teste foram obtidas a partir do banco de espectros Vrhel, com 354 espectros de refletância abrangendo a intervalo de 400nm a 700nm, com intervalos de 5nm [68]. O melhor resultado foi obtido pelo método MDE, considerando-se ausência de ruído, e é mostrado na tabela 8.6, junto com os resultados globais obtidos pelas redes especializadas, para efeito de comparação.

Os dados da tabela 8.6 mostram que o método das Redes Especializadas superam os resultados apresentados para o método MDE.

Tabela 8.6 - Comparação de Resultados com Ref.[11]: Valores de ΔE^* ab médio, máximo e percentil 95% obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através do método MDE e no mapeamento realizado pelas Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	Percentil 95%
MDE	3,85	16,65	9,7
Redes Especializadas	0,78	5,35	2,30
Melhoria de Desempenho (%)	79,65	67,89	76,24

No trabalho de Bianco, S. et. al., foi proposto, o método "Pattern Search Optimization" (PS), uma alteração do método de RPM, para mapear o espaço RGB de uma câmera digital para o espaço CIEXYZ. Foram usadas 40.000 cores do banco de espectros *Standard Object Color Spectra* (SOCS) [69], sendo 20.000 usados para determinação dos coeficientes, e os outros 20.000 para testes. Os resultados do método proposto foram comparados com os resultados obtidos por outros quatro métodos e outros 2 bancos de espectro, obtendo o melhor desempenho. O resultado obtido pelo método PS é mostrado na tabela 8.7, junto com os resultados globais obtidos pelas redes especializadas, para efeito de comparação.

Tabela 8.7 - Comparação de Resultados com Ref.[13]: Valores de ΔE^* ab médio, máximo e porcentagem inferior a 3, obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através do método PS e no mapeamento realizado pelas Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}	% < 3
Pattern Search	2,20	65,72	78,09
Redes Especializadas	0,78	5,35	> 95,85
Melhoria de Desempenho (%)	64,40	91,86	>22,74

Os resultados da tabela 8.7 mostram um desempenho significativamente superior do método das redes especializadas, em todos os parâmetros de comparação.

A caracterização de um scanner foi feita por Pan Z. et. al usando imagens de referência impressas por uma impressora jato de tinta em três tipos de papel: comum, revestido e papel brilhante. Também foram usadas imagens de referência impressas em uma impressora a laser em papel normal e revestido. A caracterização foi feita através do mapeamento do espaço RGB estabelecido pelos sensores do scanner, para o espaço $L^*a^*b^*$. Neste mapeamento foi usada RPM com polinômios de terceira ordem com 19 termos. Foram usadas 1024 cores para treinamento e 420 cores para teste. Nos resultados apresentados, somente os valores de $\Delta E^*_{ab(médio)}$ foram citados. Não há referência aos valores de $\Delta E^*_{ab(médio)}$ e porcentagem dos dados de validação usados que resultaram em um ΔE^*_{ab} menor do que JND. Na tabela 8.8 estão mostrados os melhores valores de $\Delta E^*_{ab(médio)}$ obtidos em cada caso, junto com os resultados globais obtidos pelas redes especializadas, para efeito de comparação.

O papel brilhante foi usado somente com a impressora jato de tinta e por isto os resultados com seu uso não são apresentados na tabela 8.8, e também porque foi o pior dos

resultados para este tipo de impressora. Pode-se observar que os valores de $\Delta E^*_{ab~(m\'edio)}$ são muito bons para o papel comum, mas ainda assim, são inferiores ao resultado obtido com as redes especializadas.

A caracterização de uma câmera fotográfica e de um scanner foi realizada por Tong-Sheng, M. e Hui-Linag, S. através do método proposto de Minimização Total da Diferença de Cor (*Total Color Difference Minimization* – TCDM), através do mapeamento dos espaços de cor RGB definidos pela câmera e pelo scanner, diretamente no espaço L*a*b*. O método proposto foi comparado com os métodos de Mínimos Quadrados (*Least Square* – LS) e Total dos Mínimos Quadrados (*Total Least Squares* – TLS), e mostrou melhor desempenho do que estes. Para o método TCDM foi usada RPM com polinômios de terceira ordem com 14

Tabela 8.8 - Comparação de Resultados com Ref.[14]: Valores de ΔE^* ab médio obtidos no mapeamento do espaço RGB para o espaço L*a*b*, através do uso de diferentes papéis métodos de impressão e no mapeamento realizado pelas Redes Especializadas.

Método	Impressora	Papel	ΔE* _{ab(médio)}
	Jato de Tinta	Comum	0,89
Regressão Polinomial	Jato de Tilita	Revestido	0,94
Múltipla	. Comum	Comum	1,44
	Laser	Revestido	1,41
Redes Especializadas	-	-	0,7833
Melhoria de Desempenho (%)	-	-	11,99

termos. Tanto para o treinamento quanto para a verificação foram usadas as cores do ColorChecker® na caracterização da câmera e as cores da carta IT8.7/2 da Kodak na caracterização do scanner. A câmera usada foi uma Canon modelo EOS D30 com 3.25 megapixels, as imagens foram capturadas com a geometria 45/0, e o scanner foi da marca Epson, modelo GT-10000+. Os valores resultantes de $\Delta E^*_{ab(médio)}$ e $\Delta E^*_{ab(máximo)}$ para os dois dispositivos estão mostrados na tabela 8.9, junto com os resultados globais obtidos pelas redes especializadas, para efeito de comparação.

Pode-se observar que quanto ao valor de $\Delta E^*_{ab(m\acute{e}dio)}$, o método das redes especializadas possui um desempenho melhor que o método TCDM, porém, quanto ao valor de $\Delta E^*_{ab(m\acute{a}ximo)}$, este último método supera o método aqui proposto, no caso da câmera digital. Deve-se ressaltar, no entanto que todas as cores do ColorChecker® foram usados como treinamento.

Tabela 8.9 - Comparação de Resultados com Ref.[3]: Valores de ΔE*ab médio e máximo obtidos no mapeamento do espaço RGB para o espaço L*a*b*, através do método TCDM, para uma câmera fotográfica digital e um scanner, e no mapeamento realizado pelas Redes Especializadas.

Método	Dispositivo	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
TCDM	Câmera	1,10	3,97
TCDM	Scanner	1,09	5,58
Redes Especializadas	-	0,78	5,35
		•	
Melhoria de Desempenho (%)	-	28,14	4,18

No trabalho de Schettini, R., Barolo, B. e Boldrin, E., foi usada uma RNA na calibração de um *scanner*, através do mapeamento do espaço RGB definido pelos sensores do *scanner* Sharp® JP600, no espaço CIEXYZ. Para treinamento foram usadas as 264 cores de uma carta IT8 do padrão Agfa®, e para teste foram usadas as 24 cores do ColorChecker®, sendo adotado o iluminante D50. O melhor resultado foi obtido com uma RNA com 2 camadas escondidas com 10 neurônios cada, sendo o valor de $\Delta E^*_{ab(médio)}$ obtido de 5,29. Não estão disponíveis os valores de $\Delta E^*_{ab(máximo)}$ e da porcentagem de entradas com erro de mapeamento menor que JND. Este valor é superior ao valor obtido com o método de redes especializadas de 0,78.

Também foi usada uma RNA por Ye, L., Hongfei, Y. e Junsheng, S. para caracterizar uma câmera digital, através do mapeamento do espaço RGB da câmera no espaço CIEXYZ. Neste caso foram usadas 1267 cores do *Munsell Book of Colors*, sendo que 1.000 cores foram usadas para treinamento da RNA e 267 foram usadas para verificação. Para a captura das imagens foi usada a geometria 0/45 com iluminante D65. Não é declarada a marca da câmera usada, mas somente o modelo MVC 1000. Também não é declarado como foram obtidos os espectros de refletância das cores Munsell. A RNA usada contém 3 camadas escondidas com 10 neurônios cada. Só é declarado o valor de $\Delta E*_{ab(máximo)}$, obtido de 0,50 que é melhor do que o resultado obtido no método de redes especializadas.

Outro trabalho sobre caracterização de câmeras digitais, fazendo a comparação do desempenho entre os métodos usando RNA e RPM foi publicado por Cheung, T.L.V. et. al. Neste trabalho é feito o mapeamento do espaço RGB definido pelos sensores da câmera, no espaço CIEXYZ. Foram usadas 166 cores da carta ColorChecker® DC para a fase de treinamento da RNA e geração dos coeficientes dos polinômios, e 50 cores do *Natural Color*

System (NCS) para o verificação dos dois métodos. A câmera digital avaliada foi da marca Agfa modelo StudioCam, com 4500 X 3648 pixels por canal, e as imagens obtidas com a geometria 0/45. Vários tipos de polinômios foram usados, desde primeira ordem com 3 termos até quarta ordem, com 35 termos. A RNA testada possui 1 camada escondida, onde o número de neurônios foi alterado, assumindo 6 valores diferentes entre 3 e 40 neurônios. O melhor resultado para o método da RPM foi conseguido com um polinômio de terceira ordem com 20 termos, e para o método com a RNA, quando usada uma camada escondida com 18 neurônios

São mostrados na tabela 8.10, os valores dos melhores resultados obtidos para o valor de $\Delta E^*_{ab(m\acute{e}dio)}$ e respectivos valores aproximados de $\Delta E^*_{ab(m\acute{a}ximo)}$, tanto para o caso das RNAs como para o da RPM. Também são mostrados os resultados globais obtidos pelas redes especializadas, para efeito de comparação. Não está disponível o valor da porcentagem de entradas com erro de mapeamento menor que JND.

Pode-se observar na tabela 8.10 que o método das redes especializadas supera o desempenho tanto do método de RPM como o de RNAs apresentado no trabalho referenciado.

A calibração de um scanner colorido foi publicada por Vrhel, M. J. e Trussell, H. J., em que são usados três métodos de interpolação em uma tabela de pesquisa (*Look-up*

Tabela 8.10 - Comparação de Resultados com Ref.[17]: Valores de ΔE*ab médio e máximo aproximado obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através do uso de RNAs e RPM, e no mapeamento realizado pelas Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
RPM - 20 termos	2,57	15 (aprox.)
RNA - 18 neurônios	2,89	17 (aprox.)
Redes Especializadas	0,78	5,35
Melhoria de Desempenho (%)	69,52	64,36 (aprox.)

Table - LUT) multidimensional, de tamanho 32 X 32 X 32. Para isto, é feito um mapeamento do espaço RGB do *scanner* no espaço CIEXYZ e no primeiro método, os valores intermediários são calculados através de um ajuste linear global, no segundo, por um ajuste polinomial global e no terceiro, através de um ajuste linear local. Foi também pesquisado um quarto método usando uma RNA com uma única camada escondida, onde o número de neurônios desta camada foi variado de 5 a 25 com passos de 5 neurônios. O melhor resultado

foi obtido com 20 neurônios. Para a construção da tabela e para o treinamento da RNA, foram usadas 264 cores lidas através do scanner. Os valores do espaço CIEXYZ foram convertidos para o espaço CIELAB, onde foi feito cálculo das diferenças de cor usando o iluminante D50. Os valores dos resultados de $\Delta E^*_{ab(m\acute{e}dio)}$ e $\Delta E^*_{ab(m\acute{e}dio)}$, assim como o melhor resultado de $\Delta E^*_{ab(m\acute{e}dio)}$ para o caso da RNAs e o respectivo valor de $\Delta E^*_{ab(m\acute{e}dio)}$ são mostrados na tabela 8.11. Também são mostrados os resultados globais obtidos pelas redes especializadas, para efeito de comparação. Não está disponível o valor da porcentagem de entradas com erro de mapeamento menor que JND.

Os resultados apresentados na tabela 8.11 mostram que dos quatro métodos estudados no trabalho publicado, o melhor desempenho é da RNA considerada. Ainda assim, este resultado é superado pelos resultados das redes especializadas.

Shams-Nateri publicou um trabalho em que uma câmera digital Nikon modelo Coolpix 4500 foi usada para estimar a cor de tecidos tingidos. As imagens foram colhidas usando uma geometria 45/0. Foi usada a técnica neuro-fuzzy para mapear o espaço

Tabela 8.11 - Comparação de Resultados com Ref.[18]: Valores de ΔΕ*ab médio e máximo obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através de três métodos de interpolação numa LUT e através de uma RNA. Também são mostrados estes valores para o mapeamento realizado pelas Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
Linear Global	4,89	20,70
Polinomial Global	4,08	17,40
Linear local	2,80	23,00
RNA - 20 neurônios	2,20	12,09
Redes Especializadas	0,78	5,35
	•	
Melhoria de Desempenho (%)	64,40	55,78

RGB de uma câmera digital no espaço CIEXYZ, em que o número de regras foi variado de 8 a 25 e o número de funções de pertinência, de 2 a 5. Os valores do espaço CIEXYZ foram convertidos para o espaço CIELAB, onde foi feito cálculo das diferenças de cor usando o iluminante D65. Pedaços de tecido tingidos com 141 cores foram usados para treinamento e 41 cores usadas para verificação. Os valores de referência CIELAB foram obtidos com um espectrofotômetro Datacolor Corporation. Os melhores valores dos resultados de $\Delta E^*_{ab(médio)}$ e $\Delta E^*_{ab(méximo)}$ para o conjunto de verificação estão mostrados na tabela 8.12. Também são

mostrados os resultados globais obtidos pelas redes especializadas, para efeito de comparação. Não está disponível o valor da porcentagem de entradas com erro de mapeamento menor que JND.

Pelos resultados apresentados na tabela 8.12, observa-se um desempenho consideravelmente inferior da técnica neuro-fuzzy em relação aos resultados das redes especializadas.

Burian, A., Happonen, A e Cirlugea, M. publicaram um trabalho em que o espaço RGB definido por uma câmera de telefone da marca Nokia modelo N93 é mapeado no

Tabela 8.12 - Comparação de Resultados com Ref.[19]: Valores de ΔE*ab médio e máximo obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através de técnica neuro-fuzzy. Também são mostrados estes valores para o mapeamento realizado pelas Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
Neuro-fuzzy	5,80	36,59
Redes Especializadas	0,78	5,35
Melhoria de Desempenho (%)	86,49	85,39

espaço CIEXYZ através de 3 métodos; RPM com polinômios de segunda ordem e 12 termos, uma série de Fourier de senos também com 12 termos e uma RNA com uma camada escondida de 21 neurônios. Foram usadas 160 amostras para treinamento e 80 para verificação, capturadas a partir da carta ColorChecker®. Os valores dos resultados de $\Delta E^*_{ab(médio)}$ e $\Delta E^*_{ab(máximo)}$ para o conjunto de verificação estão mostrados na tabela 8.13. Também são mostrados os resultados globais obtidos pelas redes especializadas, para efeito de comparação. Não está disponível o valor da porcentagem de entradas com erro de mapeamento menor que JND.

Pode-se observar da tabela 8.13 que o melhor resultado é obtido pela série de Fourier de senos que não obstante é superado pelos resultados das redes especializadas.

Hongxia, Z. e Tao, W. publicaram um estudo da conversão de cores em um espaço RGB de uma câmera CCD no espaço CIE $L^*a^*b^*$, usando uma RNA. Sua arquitetura é composta de duas camadas escondidas, sendo que a primeira possui 59 neurônios, com função de transferência "logsig" e a segunda, possui 10 neurônios com função de transferência "tansig". Para treinamento foram usadas 1550 amostras, obtidas do sistema de cores Munsell, e 52 amostras foram usadas para verificação. O espaço CIEXYZ foi usado para uma

conversão intermediária. Os valores dos resultados de $\Delta E^*_{ab(m\'edio)}$ e $\Delta E^*_{ab(m\'edio)}$ para o conjunto de verificação estão mostrados na tabela 8.14.

Tabela 8.13 - Comparação de Resultados com Ref.[20]: Valores de ΔE*ab médio e máximo obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através de RPM, Serie de Fourier de senos e RNA . Também são mostrados estes valores para o mapeamento realizado pelas Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
RPM	1,98	30,40
Série de Fourier	1,12	25,90
RNA - 21 neurônios	1,24	34,10
Redes Especializadas	0,78	5,35
	T	
Melhoria de Desempenho (%)	30,06	84,32

Também são mostrados os resultados globais obtidos pelas redes especializadas, para efeito de comparação. Não está disponível o valor da porcentagem de entradas com erro de mapeamento menor que JND.

Pode-se observar que o número de amostras usadas para teste é muito menor do que as usadas para treinamento, o que pode prejudicar o significado estatístico do resultado, visto que é recomendado usar entre 10% a 40% dos dados disponíveis para verificação [60]. O valor de $\Delta E^*_{ab(m\acute{a}ximo)}$ obtido é pouco superior ao conseguido com as redes especializadas, porém o valor de $\Delta E^*_{ab(m\acute{e}dio)}$ é consideravelmente maior do que o resultante com este último método.

RNAs e algoritmos genéticos foram usados por Zuffi, S., Schettini, R. e Mauri, G. para caracterização de impressoras a jato de tinta, consideradas como dispositivos RGB. Este espaço é mapeado em um espaço espectral que é convertido no espaço CIE L*a*b*. Quatro modelos de impressoras foram considerados: Epson Stylus Color, HP2000C, Epson Stylus C80 e Epson 890. Foi usado um total de 777 cores geradas a partir do modelo Yule-Nielsen Spectral Neugebauer (YNSN) para impressão "halftoning". Os espectros considerados estavam no intervalo de 400nm a 680nm com intervalos de 40nm. Destas cores, 143 foram utilizadas para treinamento as restantes para verificação. Os valores dos melhores resultados de $\Delta E*_{ab(médio)}$ e $\Delta E*_{ab(méximo)}$ para o conjunto de verificação estão mostrados na tabela 8.15.

Tabela 8.14 - Comparação de Resultados com Ref.[21]: Valores de ΔE*ab médio e máximo obtidos no mapeamento do espaço RGB para o espaço CIEXYZ, através de uma RNA com 2 camadas escondidas. Também são mostrados estes valores para o mapeamento realizado pelas Redes Especializadas.

Método	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
RNA - 2 camadas escondidas	3,1744	5,6357
Redes Especializadas	0,7833	5,3466
Melhoria de Desempenho (%)	75,32	5,13

Também são mostrados os resultados globais obtidos pelas redes especializadas, para efeito de comparação. Não está disponível o valor da porcentagem de entradas com erro de mapeamento menor que JND.

Tabela 8.15 - Comparação de Resultados com Ref.[22]: Valores de ΔE*ab médio e máximo obtidos no mapeamento do espaço RGB para o espaço L*a*b*, através de algoritmo genético e RNA, para impressoras jato de tinta, e no mapeamento realizado pelas Redes Especializadas.

Método	Impressora	ΔE* _{ab(médio)}	ΔE* _{ab(máximo)}
Algorit. Genético	Epson Stylus Color	1,92	7,99
RNA	Epson 890	3,26	12,20
Redes Especializadas	•	0,78	5,35
Melhoria de Desempenho (%)	-	59,20	33,08

Pode-se perceber um desempenho melhor do algoritmo genético no caso da impressora Epson Stylus Color, quando comparado com o melhor desempenho conseguido com a RNA, porém o desempenho foi superior somente neste caso. Quando considerada a impressora HP 2000C, o desempenho usando algoritmo genético é o segundo pior de todos os casos (algoritmo genético e RNA). Aqui também, as redes especializadas obtiveram um resultado melhor do que as duas técnicas apresentadas no trabalho publicado.

É importante ressaltar que os trabalhos usados para comparação de desempenho podem incluir em seus resultados erros de medição e ruído, o que no caso das redes especializadas se restringe ao levantamento da curva de resposta do sensor TCS230 fornecida pelo fabricante. No apêndice A está mostrada uma tabela contendo um resumo das

comparações do método apresentado neste trabalho, com os métodos encontrados na literatura e citados neste capítulo.

Capítulo IX – Desenvolvimentos futuros

9.1. Estudo de novas arquiteturas

Embora tenha sido feito neste trabalho, um estudo do comportamento de uma rede com 2 camadas escondidas, é necessário fazer de forma mais sistemática, um estudo para verificar a alteração no desempenho de uma única rede com um maior número de camadas escondidas. Não há como determinar analiticamente a arquitetura da RNA ótima. Ela deve ser determinada através de experimentação, devendo ser escolhida a menor arquitetura que mantenha os erros dentro de valores aceitáveis [63].

9.2. Estudo para melhoria de desempenho da rede G

A segmentação do espaço de cores de entrada levou a uma melhoria do desempenho global, no mapeamento do espaço de cores do sensor TCS230 no espaço colorimétrico CIEXYZ. No entanto, foi verificado que a rede G possui desempenho nitidamente inferior às redes R e B. Este fato pode ser objeto de investigação em trabalhos futuros.

9.3. Aplicação da segmentação do espaço de cores em outros métodos

Ao segmentar o espaço de cores de entrada, o problema inicialmente proposto de achar uma única função de mapeamento, transforma-se na pesquisa de 3 ou mais funções. A complexidade pode variar, dependendo do segmento específico do espaço considerado, permitindo que os métodos não analíticos de procura destas funções tenham um resultado global melhorado em relação aos resultados apresentados no Capítulo VIII.

Capítulo X - Conclusão

O problema do mapeamento de espaços de cor não colorimétricos em espaços de cor colorimétricos é complexo e ainda é objeto de estudo da comunidade científica. Esta complexidade tem direcionado as pesquisas a buscar soluções não analíticas, com aplicação de métodos que usam redes neurais artificiais, algoritmos neuro-fuzzy e algoritmos genéticos, entre outras técnicas avançadas. Os resultados obtidos até o momento reduzem o valor médio dos erros de mapeamento a valores pequenos, porém com valores máximos do erro ainda superiores aos valores de JND, o que torna estes erros perceptualmente observáveis.

A aplicação de redes neurais artificiais especializadas para fazer o mapeamento de um espaço de cor não colorimétrico em um espaço colorimétrico permitiu uma considerável redução dos erros médios dos valores mapeados. No entanto, os valores de erro máximo resultantes da aplicação do método proposto ainda são superiores aos valores de JND, embora bem próximos deste valor.

A complexidade do desenvolvimento de um equipamento para medir cores é relativamente alta, exigindo conhecimento em várias especialidades da ciência e da tecnologia. O método aqui desenvolvido aparece como uma alternativa viável para aplicação do mapeamento necessário nestes equipamentos, resultando em medidas com erros pequenos.

Investigações adicionais são necessárias para obtenção de melhorias ainda maiores no método de mapeamento proposto, mas o desempenho atingido indica que o caminho na direção de segmentar o espaço não colorimétrico de entrada é promissor e deve ser analisado com maior cuidado.

Referências Bibliográficas

- [1] O'Connor, Z., Colour Psychology and Colour Therapy: Caveat Emptor. *Color Research & Application*, Hoboken, NJ, v. 36, n. 3, p. 229-234, 2010.
- [2] SHARMA, G.(Ed.) Digital Color Imaging: Handbook. Webster, New York: CRC Press, 2003.
- [3] TONG-SHENG, M.; HUI-LIANG S. Colorimetric characterization of imaging device by total color difference minimization. *Journal of Zhejiang University SCIENCE A*, Zhejiang, China, v. 7, n. 6, p. 1041-1045, 2006.
- [4] TEXAS ADVANCED OPTOELETRONIC SOLUTIONS. TCS230 programmable color light-to-frequency converter. Plano, Texas, 2007.
- [5] VRHEL, M. J.; TRUSSEL, H.J. Color scanner calibration via a neural network.: *ICASSP* '99. *Proceedings, IEEE International Conference on Acoustics, Speech, and Signal Processing*, Phoenix, AZ, v. 6, p. 3465-3468, 1999.
- [6] SHASTRI,V. et. al. Device-independent color correction for multimedia applications using neural networks and abductive modeling approaches. *IEEE International Conference on Neural Networks*, Washington, DC, USA, v. 4, p. 2176-2181, 1996.
- [7] TEXAS ADVANCED OPTOELETRONIC SOLUTIONS. Sensing Color with the TAOS TCS230. Plano, Texas, 2005.
- [8] HAN,K. et. al. Characterizing the desktop color printer with polynomial regression. *IEEE International Conference on Systems, Man, and Cybernetics*, San Diego, CA, USA, v. 5, p. 4369-4372, 1999.
- [9] YOON, C; CHO, M. Colorimetric characterization for digital camera by using multiple regression. *TENCON 99. Proceedings of the IEEE Region 10 Conference*, Cheju Island, South Korea, v. 1, p. 585-588, 1999
- [10] TSAI,C.; LIAW,M.; SHIEH, H. Color reproduction of twist nematic LCD by polynomial regression applied in primary-invariance model: *ASID '99. Proceedings of the 5th Asian Symposium on Information Display*, Hsinchu, Taiwan, p. 115-118, 1999.
- [11] URBAN,P.; GRIGAT, R. Metamer density estimated color correction. *Signal, Image and Video Processing*, v. 3, n. 2, p. 171-182, 2009.
- [12] ISO/TR 16066, Graphic technology Standard object colour spectra database for color reproduction evaluation (SOCS), Technical Report:2003(E).
- [13] BIANCO, S. et. al. A New Method for RGB to XYZ Transformation Based on Pattern Search Optimization: *IEEE Transactions on Consumer Electronics*, v. 53, n. 3, p. 1020-1028, 2007.
- [14] PAN Z. et. al. Color Scanner Characterization with Scan Targets of Different Media

- Types and Printing Mechanisms: *Proc. SPIE Color Imaging: Device-Independent Color, Color Hardcopy, and Graphic Arts VI*, San Jose, CA, USA, v. 4300, p. 58-63, 2001.
- [15] SCHETTINI, R.; BAROLO, B.; BOLDRIN, E., Colorimetric calibration of color scanners by back-propagation. *Pattern Recognition Letters*, Elsevier Science Inc. New York, NY, USA, v. 16, n. 10, p. 1051-1056, 1995.
- [16] YE, L.; HONGFEI, Y.; JUNSHENG, S. Camera Characterization Using Back-Propagation Artificial Neutral Network Based on Munsell System. *Proc. SPIE International Symposium on Photoelectronic Detection and Imaging 2007: Photoelectronic Imaging and Detection*, Beijing, China, v. 6621, 2007. doi:10.1117/12.790592.
- [17] CHEUNG, V. et. al. A comparative study of the characterisation of colour cameras by means of neural networks and polynomial transforms. *Coloration Technology*, v.120, p. 19–25, 2004.
- [18] VRHEL, M. J.; TRUSSELL, H. J., Color Scanner Calibration via a Neural Network. *ICASSP '99. Proceedings. IEEE International Conference on Acoustics, Speech, and Signal Processing*, Phoenix, AZ, USA, v. 6, p. 3465-3468, 1999.
- [19] SHAMS-NATERI, A., Estimation of fabric color by camera based neuro-fuzzy technique: *Indian Journal of Fibre & Textile Research (IJFTR)*, New Delhi. India, v. 36, p. 74-80, 2011.
- [20] BURIAN, A.; HAPPONEN, A.; CIRLUGEA, M. Characterization of Imaging Phone Cameras Using Minimum Description Length Principle. *WSEAS Transactions on Information Science and Applications*, World Scientific and Engineering Academy and Society (WSEAS) Stevens Point, Wisconsin, USA, v. 5, n. 4, p. 512-521, 2008.
- [21] HONGXIA, Z.; TAO, W., Study on Conversion Method of Color Space under a Big Color Gamut. 2007 International Conference on Computational Intelligence and Security (CIS 2007), Harbin, Heilongjiang, China, p. 386-390, 2007.
- [22] ZUFFI, S.; SCHETTINI, R.; MAURI, G. Spectral-Based Characterization of Inkjet Printers by Neural and Genetic Algorithms. *PICS 2003: Image Processing, Image Quality, Image Capture Systems Conference, including MCS/05 Fifth International Symposium on Multispectral Color Science*, Rochester, NY, USA, p. 479-484, 2003.
- [23] BEARE, J. I. *Greek Theories of Elementary Cognition from Alcmaeon to Aristotle*. Oxford: The Clarendon Press, 1906.
- [24] MEDICOPEDIA *El Diccionario Médico Interactivo*. Diponível em: < http://www.portalesmedicos.com/diccionario_medico/index.php/Fosfeno>. Acesso em 12/07/2008.
- [25] STRATTON, G. M. Theophrastus and the Greek Physiological Pscycology before Aristotle. London: G. Allen & Unwin; New York: Macmillan, 1917.
- [26] DA VINCI, L. Trattato della pittura, Roma, Newton Compton, 1996.

- [27] KEISER, P.K.; BOYNTON, R.M. *Human Color Vision*. Washington, DC: Optical Society of America, p. 1-16, 1996.
- [28] CROMBIE, A. C. Science, optics, and music in medieval and early modern thought Continuum International Publishing Group, Londres, 1990, p221
- [29] TEXAS ADVANCED OPTOELETRONIC SOLUTIONS. Basics of Light and Color. Plano, Texas, 2003.
- [30] X-RITE INCORPORATED. *Understanding Illuminants*. Grand Rapids, Michigan, 2005. Disponível em: http://www.xrite.com/documents/apps/public/whitepapers/Ca00002a.pdf >. Acesso em 12/07/2010.
- [31] SHEVELL, S.K. (Ed.) The Science of Color. Oxford: Elsevier, 2003.
- [32] COMISSION INTERNATIONALE DE L'ECLAIRAGE CIE. *Home Page*. Vienna, Austria, 2010. Disponível em http://www.cie.co.at/index.php/?service=restart. Acesso em 15/07/2010.
- [33] COMISSION INTERNATIONALE DE L'ECLAIRAGE. CIE. Recommendation on uniform color spaces, color-difference equations and psychometric color terms, Supplement No 2 to Colorimetry, Publication No 15, Paris, 1978.
- [34] WYSZECKI G.; STILES, W.S. Color Science—Concepts and Methods, Quantitative Data and Formulae, 2nd ed. New York: John Wiley & Sons, 1982.
- [35] BARTLESOM, C.J., Colorimetry, Optical RadiationMeasurements: Color measurement. Grum, F.; Bartlesom, C.J. (Eds.), New York: Academic Press, 1980, v.2., p.33-148.
- [36] KANG, H. R. *Computational Color Technology*. Bellingham, Washington: The International Society for Optical Engineering, 2006.
- [37] MACADAM, D.L., Visual sensitivities to color differences in daylight, *Journal of the Optical Society of America*, v. 32, p. 247-274, 1942.
- [38] COMISSION INTERNATIONALE DE L'ECLAIRAGE. CIE. Colorimetry Part 4: 1976 L*a*b* Colour Space. Vienna, Austria, 1976.
- [39] HUNTER ASSOCIATES LABORATORY, INC. Hunter L,a,b Color Scale, Applications Note, Vol.8, No 9, Reston, VA, 2008.
- [40] MAHY, M.; VAN EYCKDEN, L.; OOSTERLINCK, A. Evaluation of uniform color spaces after de adoption of CIELAB and CIELUV. *Color Research & Application*. Hoboken, NJ: John Willey & Sons, Inc., v.19, n. 2, p. 105-121, 1994.
- [41] CLARKE, F.J.J.; McDONALD, R.; RIGG, B., Modification to the JPC79 colour-difference formula. *Journal of Society of Dyers and Colourists*, v. 100, p. 128-132, 1984.
- [42] McDONALD, R. Acceptability and perceptibility decisions using CMC color difference formula. *Textile Chemist and Colorist (TCC)*, v. 20, n. 6, p. 31-37, 1988.

- [43] BERNS, R. S. Billmeyer and Saltzman's Principles of Color Technology, 3rd ed., New York: Wiley-Intercience, 2000.
- [44] ROBERTSON A.R. The future of Color Science. *Color Research & Application*. Hoboken, NJ: John Willey & Sons, Inc., v.7, n. 1 p. 16-18, 1982.
- [45] ADAMS E. Q. A theory of color vision, *Psychology Review*, v.36, p.56-76, 1923.
- [46] MUNSELL, A. H. A color notation, Macbeth, Newburgh, NY, 1992.
- [47] X-RITE INCORPORATED. Defining color systems for precise color validation. Grand Rapids, Michigan, 2007.
- [48] GRANVILLE, W. C.; NICKERSON, D.; FOSS, C. E., Trichromatic Specifications for Intermediate and Special Colors of the Munsell System. *Journal of the Optical Society of America*, v. 33, n. 7, p. 376-385, 1943.
- [49] ASD, INC. Disponível em http://www.asdi.com/products/fieldspec-3. Acesso em 15/07/2010.
- [50] OPTRONIC LABORATORIES. Disponível em http://www.olinet.com/products.php?_act=manageProduct&DO=viewProduct&intProdID=10. Acesso em 15/07/2010.
- [51] X-RITE INCORPORATED. Disponível em http://www.xrite.com/product_overview.aspx?ID=63. Acesso em 15/07/2010.
- [52] PG INSTRUMENTS LIMITED. Disponível em http://www.pginstruments.com/uv.html#T60 UV>. Acesso em 15/07/2010.
- [53] KONICA MINOLTA SENSING, INC Croma Meter CR400/410. Osaka, Japan, 2007.
- [54] POCKETSPEC TECHNOLIGIES, INC Operation Manual ColorQA: Series 3, Series 4, PC Series. Denver, Colorado, 2006.
- [55] THE BABEL COLOR COMPANY. *RGB Coordinates of the Macbeth ColorChecker*. Quebec:, 2006. Disponível em: http://www.babelcolor.com/main_level/ColorChecker.htm#ColorChecker_data. Acesso em 12/07/2008.
- [56] X-RITE INCORPORATED. *Using ColorChecker Image Reproduction Target*. Grand Rapids, Michigan, 2007.
- [57] THE BABEL COLOR COMPANY, *ColorChecker_RGB_and_spectra*, 2006. Disponível em: http://www.babelcolor.com/download/ColorChecker_RGB_and_spectra.xls. Acesso em 12/07/2008.
- [58] STRANG,G., *Introduction to Linear Algebra*, 4th ed. Boston, MA: Wellesley-Cambridge, 2009.

- [59] UNIVERSITY OF MINHO. *Multilayer Perceptron (MLP) Application Guidelines*, Guimarães, Portugal, 2004. Disponível em:http://www3.dsi.uminho.pt/pcortez/mg.pdf. Acesso em 15/07/2010.
- [60] SILVA, I. N.; SPATTI, D. N.; FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas curso prático. São Paulo: Artliber, 2010.
- [61] F. D. FORESEE, M. T. HAGAN, Gauss-Newton approximation to Bayesian regularization, *Proceedings of the 1997 International Joint Conference on Neural Networks*, 1997.
- [62] THE MATHWORKS, INC. *Version 6.0.1 (R2008b) Neural Network Toolbox*TM *Software.* Natick, MA, 2008. Disponível em: < http://www.mathworks.com/access/helpdesk/help/toolbox/ nnet/rn/rn5.html>. Acesso em 12/07/2008.
- [63] HAYKIN, S. *Neural Networks*: A comprehensive Foundation. Upper Saddle River, New Jersey: Prentice Hall, 1999.
- [64] LAPPEENRANTA UNIVERSITY OF TECHNOLOGY *munsell380_800_1.mat.gz*, Finland, 1995. Disponível em: < ftp://ftp.cs.joensuu.fi/pub/color/spectra/mspec/>. Acesso em 11/11/2010.
- [65] Munsell Book of Colors, Matte Finish Collection. Munsell Color, Baltimore, MD, USA, 1976.
- [66] M. FUN, M. HAGAN, Levenberg-Marquardt training for modular networks, *Proceedings of the 1996 International Conference on Neural Networks*, pp. 468-473, 1996.
- [67] MacKAY, D.J.C. Bayesian interpolation, *Neural Computation*, MIT Press Cambridge, MA, USA, v. 4, n. 3, p. 415-447, 1992.
- [68] A. KIMBALL ROMNEY, A. K.; INDOW, T. Munsell Reflectance Spectra Represented in Three-Dimensional Euclidean Space. *Color research and application*, 2003, v. 28, n. 3, p. 182-196.
- [69] ISO, Graphic Technology Standard object colour spectra database for color reproduction evaluation (SOCS), Technical Report ISO/TR 16066, 2003(E).

APÊNDICE A

Tabela de comparação de resultados

Autor	Método	Melhoria ΔE*ab (médio) %	Melhoria ΔE*ab (máximo) %	% < JND
Poynton, C.	Matriz Pseudo-inversa	74,04	32,8	53,36
· ·	RPM	·	·	33,30
Kang, H. R.	KPIVI	54,72	> 70,29	-
Han, K. et. al.	RPM	72,22	-	-
Yoon, C. et. al.	RPM	36,58	30,53	44,04
Tsai, C. et. al.	RPM	62,15	-	13,44
Urban, P. et. al.	MDE	79,65	67,89	76,24
Bianco, S. et. al.	RPM	64,4	91,86	>22,74
Pan, Z. et. al.	RPM	11,99	-	-
Sheng, M. et. al.	RPM	28,14	4,18	-
Schettini, R. et. al.	RNA	85,26	-	-
Ye, L. et. al.	RNA	-	-969,32	-
Cheung, T. L. V. et.				
al.	RNA e RPM	69,52	64,36 (aprox.)	-
Vrhel, M. J. et. al.	RNA	64,4	55,78	-
Shams, N.	Neuro-fuzzy	86,49	85,39	-
Burian, A. et. al.	Série de Fourier	30,06	84,32	-
Hongxia, Z. et. Ala	RNA	75,32	5,13	_
Zuffi, S. et. al.	RNA e Algoritmo Genético	59,2	33,08	_

Tabela resumo das comparações do método deste trabalho com os métodos encontrados na literatura, mostrados no capítulo 8.

ANEXO A

Dados Espectrais

CI	CIE 1931 standard colorimetric observer			
λ, nm	x-bar	y-bar	z-bar	
380	0,001368	0,000039	0,006450	
385	0,002236	0,000064	0,010550	
390	0,004243	0,000120	0,020050	
395	0,007650	0,000217	0,036210	
400	0,014310	0,000396	0,067850	
405	0,023190	0,000640	0,110200	
410	0,043510	0,001210	0,207400	
415	0,077630	0,002180	0,371300	
420	0,134380	0,004000	0,645600	
425	0,214770	0,007300	1,039050	
430	0,283900	0,011600	1,385600	
435	0,328500	0,016840	1,622960	
440	0,348280	0,023000	1,747060	
445	0,348060	0,029800	1,782600	
450	0,336200	0,038000	1,772110	
455	0,318700	0,048000	1,744100	
460	0,290800	0,060000	1,669200	
465	0,251100	0,073900	1,528100	
470	0,195360	0,090980	1,287640	
475	0,142100	0,112600	1,041900	
480	0,095640	0,139020	0,812950	
485	0,057950	0,169300	0,616200	
490	0,032010	0,208020	0,465180	
495	0,014700	0,258600	0,353300	
500	0,004900	0,323000	0,272000	
505	0,002400	0,407300	0,212300	
510	0,009300	0,503000	0,158200	

CIE 1964 supplementary standard colorimetric observer			
λ,nm	x-bar10	y-bar10	z-bar10
380	0,000160	0,000017	0,000705
385	0,000662	0,000072	0,002928
390	0,002362	0,000253	0,010482
395	0,007242	0,000769	0,032344
400	0,019110	0,002004	0,086011
405	0,043400	0,004509	0,197120
410	0,084736	0,008756	0,389366
415	0,140638	0,014456	0,656760
420	0,204492	0,021391	0,972542
425	0,264737	0,029497	1,282500
430	0,314679	0,038676	1,553480
435	0,357719	0,049602	1,798500
440	0,383734	0,062077	1,967280
445	0,386726	0,074704	2,027300
450	0,370702	0,089456	1,994800
455	0,342957	0,106256	1,900700
460	0,302273	0,128201	1,745370
465	0,254085	0,152761	1,554900
470	0,195618	0,185190	1,317560
475	0,132349	0,219940	1,030200
480	0,080507	0,253589	0,772125
485	0,041072	0,297665	0,570060
490	0,016172	0,339133	0,415254
495	0,005132	0,395379	0,302356
500	0,003816	0,460777	0,218502
505	0,015444	0,531360	0,159249
510	0,037465	0,606741	0,112044

A1. Tabela das CMFs publicadas pela CIE para os observadores padrão (continua)

CI	CIE 1931 standard colorimetric observer							
λ,	v bor	v bor	- bor					
nm	x-bar	y-bar	z-bar					
515	0,029100	0,608200	0,111700					
520	0,063270	0,710000	0,078250					
525	0,109600	0,793200	0,057250					
530	0,165500	0,862000	0,042160					
535	0,225750	0,914850	0,029840					
540	0,290400	0,954000	0,020300					
545	0,359700	0,980300	0,013400					
550	0,433450	0,994950	0,008750					
555	0,512050	1,000000	0,005750					
560	0,594500	0,995000	0,003900					
565	0,678400	0,978600	0,002750					
570	0,762100	0,952000	0,002100					
575	0,842500	0,915400	0,001800					
580	0,916300	0,870000	0,001650					
585	0,978600	0,816300	0,001400					
590	1,026300	0,757000	0,001100					
595	1,056700	0,694900	0,001000					
600	1,062200	0,631000	0,000800					
605	1,045600	0,566800	0,000600					
610	1,002600	0,503000	0,000340					
615	0,938400	0,441200	0,000240					
620	0,854450	0,381000	0,000190					
625	0,751400	0,321000	0,000100					
630	0,642400	0,265000	0,000050					
635	0,541900	0,217000	0,000030					
640	0,447900	0,175000	0,000020					
645	0,360800	0,138200	0,000010					

CIE	1964 suppl colorime	lementary s tric observe	tandard er
λ,nm	x-bar10	y-bar10	z-bar10
515	0,071358	0,685660	0,082248
520	0,117749	0,761757	0,060709
525	0,172953	0,823330	0,043050
530	0,236491	0,875211	0,030451
535	0,304213	0,923810	0,020584
540	0,376772	0,961988	0,013676
545	0,451584	0,982200	0,007918
550	0,529826	0,991761	0,003988
555	0,616053	0,999110	0,001091
560	0,705224	0,997340	0,000000
565	0,793832	0,982380	0,000000
570	0,878655	0,955552	0,000000
575	0,951162	0,915175	0,000000
580	1,014160	0,868934	0,000000
585	1,074300	0,825623	0,000000
590	1,118520	0,777405	0,000000
595	1,134300	0,720353	0,000000
600	1,123990	0,658341	0,000000
605	1,089100	0,593878	0,000000
610	1,030480	0,527963	0,000000
615	0,950740	0,461834	0,000000
620	0,856297	0,398057	0,000000
625	0,754930	0,339554	0,000000
630	0,647467	0,283493	0,000000
635	0,535110	0,228254	0,000000
640	0,431567	0,179828	0,000000
645	0,343690	0,140211	0,000000

A1. Tabela das CMFs publicadas pela CIE para os observadores padrão (continuação)

CI	CIE 1931 standard colorimetric observer							
λ,								
nm	x-bar	y-bar	z-bar					
650	0,283500	0,107000	0,000000					
655	0,218700	0,081600	0,000000					
660	0,164900	0,061000	0,000000					
665	0,121200	0,044580	0,000000					
670	0,087400	0,032000	0,000000					
675	0,063600	0,023200	0,000000					
680	0,046770	0,017000	0,000000					
685	0,032900	0,011920	0,000000					
690	0,022700	0,008210	0,000000					
695	0,015840	0,005723	0,000000					
700	0,011359	0,004102	0,000000					
705	0,008111	0,002929	0,000000					
710	0,005790	0,002091	0,000000					
715	0,004109	0,001484	0,000000					
720	0,002899	0,001047	0,000000					
725	0,002049	0,000740	0,000000					
730	0,001440	0,000520	0,000000					
735	0,001000	0,000361	0,000000					
740	0,000690	0,000249	0,000000					
745	0,000476	0,000172	0,000000					
750	0,000332	0,000120	0,000000					
755	0,000235	0,000085	0,000000					
760	0,000166	0,000060	0,000000					
765	0,000117	0,000042	0,000000					
770	0,000083	0,000030	0,000000					
775	0,000059	0,000021	0,000000					
780	0,000042	0,000015	0,000000					

CIE		lementary s	
λ,nm	x-bar10	y-bar10	z-bar10
650	0,268329	0,107633	0,000000
655	0,204300	0,081187	0,000000
660	0,152568	0,060281	0,000000
665	0,112210	0,044096	0,000000
670	0,081261	0,031800	0,000000
675	0,057930	0,022602	0,000000
680	0,040851	0,015905	0,000000
685	0,028623	0,011130	0,000000
690	0,019941	0,007749	0,000000
695	0,013842	0,005375	0,000000
700	0,009577	0,003718	0,000000
705	0,006605	0,002565	0,000000
710	0,004553	0,001768	0,000000
715	0,003145	0,001222	0,000000
720	0,002175	0,000846	0,000000
725	0,001506	0,000586	0,000000
730	0,001045	0,000407	0,000000
735	0,000727	0,000284	0,000000
740	0,000508	0,000199	0,000000
745	0,000356	0,000140	0,000000
750	0,000251	0,000098	0,000000
755	0,000178	0,000070	0,000000
760	0,000126	0,000050	0,000000
765	0,000090	0,000036	0,000000
770	0,000065	0,000025	0,000000
775	0,000046	0,000018	0,000000
780	0,000033	0,000013	0,000000

A1. Tabela das CMFs publicadas pela CIE para os observadores padrão (conclusão)

В	abelColor Avg.								W	avelen	gth (nı	m)							
No.	Color name	380	390	400	410	420	430	440	450	460	470	480	490	500	510	520	530	540	550
1	dark skin	0,055	0,058	0,061	0,062	0,062	0,062	0,061	0,061	0,061	0,061	0,061	0,062	0,065	0,070	0,076	0,079	0,080	0,084
2	light skin	0,121	0,148	0,180	0,197	0,201	0,204	0,208	0,216	0,229	0,250	0,277	0,304	0,325	0,330	0,314	0,289	0,277	0,279
3	blue sky	0,141	0,184	0,254	0,307	0,325	0,331	0,334	0,333	0,327	0,314	0,300	0,287	0,271	0,251	0,231	0,215	0,200	0,184
4	foliage	0,051	0,054	0,055	0,056	0,057	0,059	0,060	0,062	0,062	0,063	0,065	0,068	0,076	0,103	0,146	0,177	0,183	0,170
5	blue flower	0,158	0,209	0,300	0,380	0,412	0,425	0,429	0,429	0,422	0,405	0,381	0,348	0,313	0,282	0,254	0,229	0,214	0,208
6	bluish green	0,145	0,185	0,250	0,299	0,323	0,340	0,358	0,383	0,420	0,466	0,509	0,545	0,567	0,575	0,571	0,553	0,524	0,488
7	orange	0,053	0,053	0,053	0,053	0,053	0,054	0,054	0,054	0,055	0,056	0,058	0,060	0,067	0,088	0,123	0,151	0,172	0,200
8	purplish blue	0,132	0,171	0,233	0,290	0,329	0,362	0,387	0,399	0,390	0,359	0,313	0,257	0,207	0,167	0,137	0,117	0,105	0,097
9	moderate red	0,098	0,116	0,131	0,136	0,134	0,132	0,131	0,129	0,126	0,121	0,116	0,111	0,106	0,101	0,096	0,093	0,093	0,094
10	purple	0,095	0,119	0,148	0,172	0,182	0,176	0,160	0,139	0,118	0,100	0,085	0,074	0,065	0,059	0,056	0,053	0,051	0,051
11	yellow green	0,060	0,061	0,062	0,063	0,064	0,066	0,070	0,075	0,086	0,104	0,137	0,190	0,269	0,377	0,478	0,533	0,551	0,547
12	orange yellow	0,062	0,062	0,063	0,064	0,064	0,065	0,066	0,066	0,067	0,069	0,072	0,077	0,090	0,129	0,208	0,303	0,378	0,426
13	blue	0,064	0,074	0,094	0,138	0,192	0,239	0,280	0,311	0,312	0,281	0,231	0,175	0,126	0,090	0,066	0,052	0,045	0,041
14	green	0,051	0,053	0,054	0,055	0,057	0,059	0,062	0,066	0,074	0,092	0,123	0,176	0,244	0,306	0,338	0,334	0,316	0,293
15	red	0,049	0,048	0,047	0,047	0,047	0,047	0,047	0,046	0,045	0,045	0,044	0,044	0,044	0,045	0,045	0,046	0,047	0,049
16	yellow	0,056	0,053	0,052	0,052	0,052	0,054	0,056	0,059	0,066	0,081	0,108	0,154	0,228	0,339	0,464	0,557	0,613	0,647
17	magenta	0,155	0,202	0,284	0,346	0,362	0,355	0,334	0,305	0,275	0,246	0,217	0,189	0,167	0,148	0,126	0,107	0,099	0,101
18	cyan	0,114	0,145	0,192	0,235	0,259	0,284	0,316	0,352	0,390	0,426	0,446	0,444	0,423	0,384	0,335	0,280	0,229	0,183
19	white 9.5 (.05 D)	0,199	0,259	0,421	0,660	0,811	0,863	0,877	0,884	0,890	0,894	0,897	0,901	0,905	0,906	0,908	0,907	0,907	0,910
20	neutral 8 (.23 D)	0,182	0,240	0,367	0,506	0,566	0,581	0,586	0,587	0,588	0,587	0,585	0,585	0,586	0,586	0,587	0,586	0,586	0,586
21	neutral 6.5 (.44 D)	0,152	0,197	0,272	0,330	0,349	0,356	0,360	0,361	0,361	0,359	0,357	0,356	0,356	0,357	0,358	0,358	0,358	0,358
22	neutral 5 (.70 D)	0,109	0,133	0,163	0,181	0,187	0,191	0,194	0,195	0,194	0,193	0,192	0,192	0,192	0,192	0,192	0,192	0,192	0,192
23	neutral 3.5 (1.05 D)	0,068	0,076	0,083	0,086	0,088	0,090	0,091	0,091	0,090	0,090	0,089	0,089	0,089	0,089	0,089	0,089	0,089	0,089
24	black 2 (1.5 D)	0,031	0,032	0,032	0,032	0,033	0,033	0,033	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032

A2. Espectro de Refletância das cores do ColorChecker® (continua)

В	SabelColor Avg.								W	avelen	gth (nı	m)							
No.	Color name	560	570	580	590	600	610	620	630	640	650	660	670	680	690	700	710	720	730
1	dark skin	0,090	0,102	0,119	0,134	0,143	0,147	0,151	0,158	0,168	0,179	0,188	0,190	0,188	0,185	0,186	0,192	0,200	0,214
2	light skin	0,280	0,294	0,344	0,424	0,489	0,523	0,542	0,558	0,576	0,594	0,611	0,623	0,634	0,651	0,672	0,693	0,710	0,728
3	blue sky	0,167	0,156	0,150	0,147	0,144	0,141	0,140	0,140	0,141	0,145	0,150	0,151	0,147	0,141	0,134	0,131	0,133	0,144
4	foliage	0,149	0,132	0,121	0,114	0,109	0,104	0,103	0,104	0,107	0,109	0,111	0,111	0,111	0,112	0,117	0,123	0,129	0,135
5	blue flower	0,202	0,195	0,194	0,202	0,216	0,231	0,241	0,253	0,276	0,310	0,345	0,365	0,367	0,363	0,362	0,368	0,377	0,394
6	bluish green	0,443	0,398	0,349	0,299	0,253	0,223	0,206	0,198	0,192	0,190	0,192	0,200	0,212	0,223	0,231	0,233	0,229	0,229
7	orange	0,250	0,338	0,445	0,536	0,583	0,590	0,586	0,582	0,579	0,579	0,584	0,595	0,611	0,628	0,644	0,653	0,654	0,659
8	purplish blue	0,090	0,086	0,084	0,084	0,084	0,084	0,083	0,084	0,088	0,095	0,105	0,117	0,133	0,155	0,186	0,218	0,255	0,296
9	moderate red	0,097	0,109	0,157	0,268	0,401	0,501	0,557	0,579	0,587	0,589	0,592	0,595	0,601	0,607	0,614	0,617	0,617	0,618
10	purple	0,052	0,052	0,051	0,053	0,059	0,073	0,095	0,117	0,139	0,162	0,189	0,221	0,256	0,295	0,336	0,370	0,404	0,445
11	yellow green	0,529	0,505	0,471	0,427	0,381	0,346	0,327	0,317	0,312	0,309	0,314	0,327	0,345	0,362	0,376	0,380	0,378	0,380
12	orange yellow	0,468	0,521	0,575	0,613	0,631	0,637	0,637	0,638	0,641	0,644	0,646	0,648	0,653	0,661	0,671	0,679	0,684	0,689
13	blue	0,039	0,038	0,038	0,038	0,038	0,039	0,040	0,040	0,040	0,041	0,042	0,043	0,043	0,043	0,044	0,047	0,050	0,055
14	green	0,261	0,228	0,196	0,164	0,134	0,114	0,102	0,096	0,092	0,090	0,090	0,093	0,099	0,104	0,109	0,111	0,110	0,110
15	red	0,052	0,058	0,071	0,103	0,177	0,313	0,471	0,586	0,651	0,682	0,698	0,707	0,715	0,725	0,734	0,740	0,744	0,748
16	yellow	0,670	0,692	0,709	0,722	0,731	0,739	0,747	0,753	0,759	0,764	0,769	0,772	0,777	0,784	0,792	0,798	0,801	0,805
17	magenta	0,103	0,109	0,136	0,199	0,290	0,400	0,514	0,611	0,682	0,726	0,754	0,769	0,779	0,789	0,800	0,807	0,813	0,821
18	cyan	0,144	0,117	0,100	0,089	0,081	0,076	0,074	0,073	0,073	0,073	0,075	0,076	0,076	0,075	0,072	0,072	0,073	0,079
19	white 9.5 (.05 D)	0,910	0,912	0,912	0,912	0,910	0,912	0,915	0,916	0,918	0,920	0,921	0,920	0,921	0,923	0,926	0,928	0,929	0,932
20	neutral 8 (.23 D)	0,585	0,587	0,587	0,586	0,584	0,582	0,580	0,577	0,575	0,573	0,572	0,570	0,569	0,568	0,567	0,567	0,565	0,565
21	neutral 6.5 (.44 D)	0,358	0,359	0,359	0,359	0,357	0,356	0,354	0,351	0,348	0,346	0,344	0,341	0,339	0,337	0,334	0,333	0,331	0,330
22	neutral 5 (.70 D)	0,192	0,192	0,192	0,191	0,190	0,189	0,188	0,186	0,184	0,182	0,181	0,179	0,178	0,177	0,175	0,174	0,173	0,172
23	neutral 3.5 (1.05 D)	0,089	0,089	0,089	0,088	0,088	0,087	0,087	0,086	0,085	0,084	0,084	0,083	0,083	0,082	0,081	0,081	0,081	0,080
24	black 2 (1.5 D)	0,032	0,032	0,031	0,031	0,031	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032	0,032

A2. Espectro de Refletância das cores do ColorChecker® (conclusão)

ANEXO B

Especificação de Equipamentos

FieldSpec® 3 Portable Spectroradiometer

The truly field-portable spectroradiometer designed by researchers, for researchers to perform solar spectral reflectance, radiance, and irradiance measurements.

The FieldSpec® 3
portable
spectroradiometer
offers the modular Goetz
spectrometer engine
with a spectral range
from 350 nm to 2500
nm and is ideal for
numerous remote
sensing and research
applications including:



- · Airborne Measurement
- · Atmospheric Research
- Climate Effects
- · Crops and Soils Research
- . Forestry, Ecology, and Plant Physiology Research
- · General Field Spectrometry
- Geology and Mineral Analysis
- Ground Truthing
- Hyperspectral and Multispectral Imagery and Analysis
- · Snow and Ice Research
- · Light Energy Measurements
- · Oceanography and Inland Water Bodies Research
- · Plant Breeding Research
- · Spectroradiometry and Radiometric Calibration

Specifications

Spectral Range	350-2500 nm
Spectral Resolution	3 nm @ 700 nm 10 nm @ 1400/2100 nm
Sampling Interval	1.4 nm @ 350-1050 nm 2 nm @ 1000-2500 nm
Scanning Time	100 milliseconds
Detectors	One 512 element Si photodiode array 350- 1000 nm Two separate, TE cooled, graded index InGaAs photodiodes 1000-2500 nm
Input	1.5 m fiber optic (25° field of view) Optional foreoptics available
Noise Equivalent Radiance (NEdL)	UV/VNIR 1.1 x 10 ⁻⁹ W/cm ² /nm/sr @700 nm NIR 2.4 x 10 ⁻⁹ W/cm ² /nm/sr @ 1400 nm NIR 4.7 x 10 ⁻⁹ W/cm ² /nm/sr @ 2100 nm
Weight	12 lbs (5.2 kg)
Calibrations	Wavelength, reflectance, radiance*, irradiance* All calibrations are NIST traceable (*radiometric calibrations are optional)

B.1. Características do Espectroradiômetro FieldSpec3 fabricado pela empresa ASD



- ¹ 6-Inch diameter sphere
- ² Source overfills FOV of monochromator
- 3 1° FOV aperture
- 4 1-Inch diameter, 1:1 objective lens



OL Series 750 Automated Spectroradiometric Measurement System Spectral Sensitivity Performance Specifications

nput Optics	HBW	Detector	@ 300nm	@ 550nm	@ 750nm	@ 1000nm	@ 1500nm	@ 2500nm
iiput Optics	HDAA	Detector	@ Soonin	@ 330tilli	@ roomin	@ rooulin	@ 1300mm	@ 2300mm
	5 nm	Si	1.5 x 10 ⁻¹³	3 x 10 ⁻¹⁴	3.5 x 10 ⁻¹⁴	2.5 x 10 ⁻¹⁴	820	_
None	5 nm	PMT	7.5 x 10 ⁻¹⁵	2 x 10 ⁻¹⁵	2 x 10 ⁻¹⁵	120	722	9223
	10 nm	PbS)==	()		1 x 10 ⁻¹¹	9 x 10 ⁻¹²	1 x 10 ⁻¹¹
	5 nm	Si	4 x 10 ⁻¹¹	5 x 10 ⁻¹²	8 x 10 ⁻¹²	9 x 10 ⁻¹²	-	
Sphere ¹	5 nm	PMT	2 x 10 ⁻¹²	3 x 10 ⁻¹³	4 x 10 ⁻¹³		122	-
	10 nm	PbS	5 1-		_	5 x 10 ⁻⁹	2 x 10 ⁻⁹	1 x 10 ⁻⁸
		6:	2 40-12	0 40-13	4 40-12	0 40:13		50
nput Optics	HBW	Detector	@ 300nm	@ 550nm	@ 750nm	@ 1000nm	@ 1500nm	@ 2500nm
	5 nm	Si	3 x 10 ⁻¹²	9 x 10 ⁻¹³	1 x 10 ⁻¹²	9 x 10 ⁻¹³	822	1990
	9	The second second	TO COURT OF THE PARTY OF	The second second	COMPANIE DE COM	1		
None ²	5 nm	PMT	1.5 x 10 ⁻¹³	7 x 10 ⁻¹⁴	3 x 10 ⁻¹³		-	-
None ²	5 nm 20 nm	PMT PbS	1.5 x 10 ⁻¹³	7 x 10 ⁻¹⁴	3 x 10 ⁻¹³	1.5 x 10 ⁻¹⁰	5 x 10 ⁻¹¹	8 x 10 ⁻¹¹
						1.5 x 10 ⁻¹⁰		
None ² Reflex Telescope ³	20 nm	PbS				0000	5 x 10 ⁻¹¹	8 x 10 ⁻¹¹
Reflex	20 nm	PbS	2 x 10 ⁻¹¹	8 x 10 ⁻¹²	1 x 10 ¹¹	0000	5 x 10 ⁻¹¹	8 x 10 ⁻¹¹
Reflex	20 nm 5 nm 5 nm	PbS Si PMT	2 x 10 ⁻¹¹ 1 x 10 ⁻¹²	8 x 10 ⁻¹² 5 x 10 ⁻¹³	1 x 10 ⁻¹¹ 2 x 10 ⁻¹²	8 x 10 ⁻¹² 4 x 10 ⁻¹⁰	5 x 10 ⁻¹¹	8 x 10 ⁻¹¹
Reflex	5 nm 5 nm 20 nm	PbS Si PMT PbS	2 x 10 ⁻¹¹ 1 x 10 ⁻¹²	8 x 10 ⁻¹² 5 x 10 ⁻¹³	1 x 10 ⁻¹¹ 2 x 10 ⁻¹²	8 x 10 ⁻¹²	5 x 10 ⁻¹¹	8 x 10 ⁻¹¹

B.2. Características do Espectroradiômetro OL 750 fabricado pela empresa Optronics Laboratories



Portable Multi-Angle Spectrophotometer

A rugged, compact design for fast, precise color measurement information on metallic, pearlescent, and special effect finishes. Its full range of angular viewing ensures complete, accurate readings that reduce downtime and wasted material. Color values are obtained for the following colorimetric systems: L"a"b", AL"Aa"Ab", L"C"h", AL"AC"AH", Flop Index, AFlop Index, AE₁₇₈₈, and AE



MA68II Advantages

- Easy to Use. Portable, lightweight, with LCD display
- Efficient. Measuring time per sample within 2 seconds
- Dynamic Rotation Sampling (DRS). Exclusive optical technology that provides for simultaneous measurement of all angles
- Rechargeable Battery. Allows for remote use
- Accessible Long-Term Data. Remote operation permits storage of measurement data for retrieval and printing to aid in maintaining color standards
- Durable. Supported by unprecedented two-year warranty

X-Rite Your source for accurate color. On time, Every time.

Grand Rapids, Michigan USA + (800) 748-9748 + +1 616-803 2100 © 2007, X-Rib, Incorporated. All rights reserved.

color measurement capabilities.

X-RITE WORLD HEADQUARTERS

£10-000 (0000)

X-Site is a world leader in providing global color control solutions for manufacturing and quality management

We lead the industry in offering sentce options to ensure uninterrupted performance of all X-Rite products. Tailoing and oducational resources are available globally and online for both new and opportunoid users to optimize their

Visit artis.com for more information about X-file products, X-file customers worldwide may also call the Applications Support from at CASupport Swifes com or Customer Service at 800-248-9748.

Quality Assurance software included. The graphical capabilities of the Metallix-QA program allow for application-specific bitmapping for advanced comparison



Specifications

- Measuring Geometrics

 45° Europaton
- 45" BUFBIGUEDS
 15", 75", 45", 75", 110" aspecular viewing Angular accuracy ±0.15°.
- Fiber optic pick-up, coupled with DFS technology

Measuring Area 0.5 in. diameter (12mm)

Light Source Gas-filed tungsten lamp, color corrected to approx. 4000°K

Huminant Types C, D_{In}, D_{In}, A, F2, F7, F11 8-F12

Standard Observers 2° 8 10°

Receiver Blue-enhanced silicon photododes

Spectral Range 400nm - 700nm

- Spectral Interval
 28 band spectral measurement:
 10cm interval from
 400cm 640cm
 20cm interval from
 640cm 700cm

- . 15nm bandwidths

Spectral Data Output Spectral reflectance values are available for output from the RS-232 port for 5 angles at 10nm intervals from 400nm - 700nm

Measurement Range 0 to 400% reflectance

Measuring Time Approx. 2.0 seconds

- Inter-Instrument Agreement 0.18 AE* avg. on refere BCBA tile set
 0.35 AE* max. on any
- chromatic tile

 0,15 AE* max. on any grey tile
- Short-Term Repeatability 0.10 AE*, on white coranic

Lamp Life Approx. 500,000 measurements

Power Supply
Six rechargoshie AA Ni-metal
hydride batteries included
- Removable battery pack; 7.2 VDC
rated © 1400 mAh

- ACAdapter Requirements

 MASE: 90-130VAC, 50-60Hz, 15W max

 MASEX: 180-260VAC, 50-60Hz,
- 15W max 12 VDC ⊕ 700 mA

Charge Time In instrument – 4 hts (50%)

16 hrs (100%)

Measurements Por Charge 1,000 5-angle measurements

(continuous measurements @ 10 sec. intervals)

Data Storage (five angles) 200 Standards 850 Samples

Data Interface Potented bi-directional RS-232, 300-19,200 baud

Display 4-row by 20-character supertwist dot matrix LCD

Operating Temperature Range 50° to 104°F (10° to 40°C) 85% Relative humidity max (non-condensing)

Storage Temperature Range -4" to 122"F (-20" to 50"C)

Weight 3 lbs. 2 oz. (1.4 kg)

Accessories Provided

Calibration standards, operation manual, AC adaptor & carrying case



B.3. Características do Espectrofotômetro MA68II fabricado pela empresa X-Rite



Title	Model	Part No.	Description	Specifications
T60 Series	T60NC	T60-1651F	5 cell holder (5-100mm) and 220V 50-60Hz power supply	Dual beam UV-Vis spectrophotometer
		T60-1651E	8 cell holder (10mm) and 220V 50-60Hz power supply	Wavelength Range: 190-1100nm, Spectral bandwidth: 2nm
		T60-1652F	5 cell holder (5-100mm) and 110V 50-60Hz power supply	Wavelength accuracy: ±1nm, Wavelength repeatability: ≤0.2nm
		T60-1652E	8 cell holder (10mm) and 110V 50-60Hz power supply	Photometric accuracy: ±0.3%T, Photometric repeatability: ≤0.15%T
				Stray light: ≤0.05%T at 220nm(Nal) and at 340nm(NaNO2)
	T60 Aurora	T60-1611F	5 cell holder (5-100mm) and 220V 50-60Hz power supply	Dual beam Vis spectrophotometer
		T60-1611E	8 cell holder (10mm) and 220V 50-60Hz power supply	Wavelength Range: 320-1100nm, Spectral bandwidth: 2nm
		T60-1612F	5 cell holder (5-100mm) and 110V 50-60Hz power supply	Wavelength accuracy: ±2nm, Wavelength repeatability: ≤0.4nm
I		T60-1612E	8 cell holder (10mm) and 110V 50-60Hz power supply	Photometric accuracy: ±0.3%T, Photometric repeatability: ≤0.15%T
Î				Stray light: ≤0.1%T at 340nm(NaNO2)

B.4. Características do Espectrofotômetro T60 fabricado pela empresa PG Instruments





Name	Chroma Meter Measuring Head				
Model	CR-400 Head	CR-410Head			
Illuminating/viewing system	d/0 (Diffuse illumination/0° viewing angle)	Wide-area illumination/0° viewing angle			
	(Specular component included)	(Specular component included)			
Detector	Silicone photo cells (6)	187400 02 187			
Display range	Y: 0.01 to 160.00% (reflectance)				
Light source	Pulsed xenon lamp				
Measurement time	1 seconds.				
Minimum measurement interval	3 seconds.				
Battery performance	Approx. 800 measurements				
and the same of	(when using batteries under company	testing Konica Minolta's conditions)			
Measurement/illumination area	é8/é11	650/653			
Repeatability	Within ∆E*ab0.07 standard deviation (when the white calibration plate			
	is measured 30 times at intervals of 10				
Inter instrument	ΔE*ab: within 0.6	ΔE*ab: within 0.8			
agreement	Average of 12 BCRA series II colors				
Observer	2 degrees Closely matches CIE 1931	Standard Observers: (x2\lambda, \varphi\lambda, \varphi\lambda)			
Illuminant *1	C, Des				
Display +1	Chroma values, color difference value	s. PASS/WARN/FAIL display			
Tolerance judgment +1	Color difference tolerance (box toleran				
Color space/	XYZ, Y x y, L*a*b*, Hunter Lab, L*C*h, Munsell (
colorimetric data	LCh99, CIE2000, CIE WI-Tw (only illuminant YI ASTM D1925 (only illuminant C), YI	Des), WI ASTM E313 (only illuminant C), I ASTM E313 (only illuminant C),			
	User index (up to six can be registered	from computer)			
Languages	Operating keys : English LCD : English (default)				
	(LCD: German, French, Italian, Spani				
Storable data sets	1000 (measuring head and data proce	essor save different data)			
Color difference target colors	100				
Calibration channels *1	20 channels (ch00 : white calibration,				
Display	Dot-matrix LCD with back light (15 chars x				
Interface	RS-232C compliant (for data processor				
The second second	* Baud rate : 4800, 9600, 19200 (bps), set a	at 9600 bps when shipped from factory			
Power source	4 AAA size alkaline or Ni-MH batteries	C			
	AC adapter (AC-A17) AC120V ~ 50-60H AC230V ~ 50-60H	z 0.4A (for N.America and Japan) z 0.4A (for worldwide except N.America			
Size	102(W) x 217(H) x 63(D)mm	102(W) x 244(H) x 63(D)mm			
Weight	Approx. 550g	Approx. 570g			
	(including 4 AAA size batteries and no	t including RS-232C cable)			
Operating temperature/	0 to 40°C, relative humidity 85% or less (at	t 35°C) with no condensation			
humidity range	* Operating temperature/humidity range of groducts for North America:	5 to 40°C, relative humidity 80% or less (at 31°C) with no condensatio			
Storage temperature/humidity range					
Other	-20 to 40°C, relative humidity 85% or less (at 35°C) with no condensation LCD back light ON/OFF function (when ON, back light stays ON for 3 seconds after last key or measurement operation)				

^{*1} indicates when connected to the Data Processor or when not set using the Data Processor or the optional software that some of the function are not available when the measuring head is not connected.

B.5. Características do Colorímetro CR400/410 fabricado pela empresa Konica Minolta



i ecnnicai Sp	ecincations
Display	4 Lines x 12 Characters LCD
Spectral Width	400 nm - 700 nm
Design Color Sensitivity	> 16.5 Million Colors
Length	168.7 mm / 6.7 ln.
Wigth	48 mm / 1.9 in.
Height	61 mm / 2.4 in.
Controls	2 Buttons
Measurement Time	Approx. 1 sec.
Weight:	15 grams 4 oz. w/ Battery
Reading Diameter	6 mm
Sensor Tip Surface Diameter	10 mm
Power	6 Volt, J-Cell Battery



PocketSpec Technologies Inc.
3225 East 2nd Avenue
Denver, Colorado 80206
Technical support - support@pocketspec.com
Sales and customer service - info@pocketspec.com
WWW.pocketspec.com

B.6. Características do Colorímetro QA Series 3 fabricado pela empresa PocketSpec Technologies Inc.