



**UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA / INSTITUTO DE MATEMÁTICA
PROGRAMA DE PÓS-GRADUAÇÃO EM MECATRÔNICA**

DANIEL DOS ANJOS COSTA

**CLASSIFICAÇÃO DE RUGAS CUTÂNEAS PERIORBITAIS
EM IMAGENS DIGITAIS**

Salvador

2016

DANIEL DOS ANJOS COSTA

**CLASSIFICAÇÃO DE RUGAS CUTÂNEAS PERIORBITAIS
EM IMAGENS DIGITAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Mecatrônica da Escola Politécnica e do Instituto de Matemática, Universidade Federal da Bahia, como requisito para a obtenção do grau de Mestre em Mecatrônica.

Orientador: Prof. Dr. Leizer Schnitman

Co-orientador: Prof. Dr. Ângelo Amâncio Duarte

Salvador

2016

Modelo de ficha catalográfica fornecido pelo Sistema Universitário de
Bibliotecas da UFBA para ser confeccionada pelo autor

Costa, Daniel

CLASSIFICAÇÃO DE RUGAS CUTÂNEAS PERIORBITAIS EM
IMAGENS DIGITAIS / Daniel Costa. -- Salvador, 2016.
122 f. : il

Orientador: LEIZER SCHNITMAN.

Co-orientador: ANGELO DUARTE.

Dissertação (MESTRADO - PROGRAMA DE PÓS-
GRADUAÇÃO EM MECATRÔNICA) -- Universidade Federal
da Bahia, ESCOLA POLITÉCNICA / INSTITUTO DE
MATEMÁTICA, 2016.

1. Rugas periorbitais. 2. Classificação. 3.
Dermatologia. I. SCHNITMAN, LEIZER. II. DUARTE,
ANGELO. III. Título.

DANIEL DOS ANJOS COSTA

**CLASSIFICAÇÃO DE RUGAS CUTÂNEAS PERIORBITAIS
EM IMAGENS DIGITAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Mecatrônica da
Escola Politécnica e do Instituto de Matemática, Universidade Federal da Bahia,
como requisito parcial da obtenção do grau de Mestre.

Aprovada em 03 de junho de 2016

Banca Examinadora



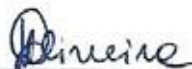
Prof. Dr. LEIZER SCHNITMAN – Orientador – UFBA
Doutor em Engenharia Eletrônica e Computação pelo Instituto Tecnológico de
Aeronáutica (ITA)



Prof. Dr. ANGELO AMÂNCIO DUARTE – Co-orientador
Doutor em Ciência da Computação pela Universidad Autónoma de Barcelona
(Espanha)
Universidade Estadual de Feira de Santana



Prof. Dr. MICHELE FÚLVIA ANGELO
Doutora em Engenharia Elétrica pela Universidade de São Paulo em 2007
Universidade Estadual de Feira de Santana



Prof. Dr. LUCIANO REBOUÇAS DE OLIVEIRA
Doutor em Engenharia Elétrica pela Universidade de Coimbra (Portugal)
Universidade Federal da Bahia

AGRADECIMENTOS

A DEUS, que todos os dias da minha vida me deu forças para nunca desistir e sabedoria para entender tudo que foi estudado.

Gostaria de agradecer especialmente ao professor Dr. Ângelo Amâncio Duarte, que considero um excelente professor e orientador e, acima de tudo, um grande amigo, sempre auxiliando de uma forma bastante criativa nas incontáveis dúvidas que surgiram durante a realização deste trabalho.

Agradeço também ao professor Dr. Leizer Schnitman, que sempre se mostrou disposto a me auxiliar.

À doutora Deborah Duarte, que atuou como consultora para esse trabalho.

Ao professor Dr. Luciano Rebouças de Oliveira pelas revisões, correções e sugestões ao trabalho final.

A todos os professores do mestrado que, de alguma forma, contribuíram para a minha formação.

Aos familiares e amigos (novos e antigos), que sempre me incentivaram e apoiaram nessa jornada. Em especial os meus pais, que sempre me apoiaram e me ajudaram nos momentos difíceis da minha formação.

COSTA, Daniel dos Anjos. Classificação de rugas cutâneas periorbitais em imagens digitais. 122 f. il. 2016. Dissertação (Mestrado) - Escola Politécnica / Instituto de Matemática, Universidade Federal da Bahia, Salvador, 2016.

RESUMO

Esse trabalho surgiu da dificuldade apresentada por médicos dermatologistas em estabelecer um critério objetivo para o acompanhamento da evolução dos tratamentos dermatológicos antienvhecimento, em especial o de redução de rugas periorbitais, pois elas são um dos principais indicadores visíveis de envelhecimento. Esses tratamentos requerem que o dermatologista faça um bom diagnóstico da avaliação da intensidade das rugas, de forma a estabelecer qual o melhor conjunto de medidas para cada caso clínico. Diversos trabalhos na literatura apresentam métodos para essa finalidade, alguns são precisos e trabalhosos como o da construção de moldes negativos de silicone do relevo das rugas, outros são simples e subjetivos como a comparação do caso clínico do paciente com fotografias de escalas de enrugamento validadas clinicamente. A falta de ferramentas simples e objetivas não apenas dificulta o tratamento, como também dificulta a comunicação médico-paciente, quando é necessário que o médico informe objetivamente os efeitos do tratamento ao paciente. Diante dos problemas apontados, estabeleceu-se como objetivo desse trabalho desenvolver uma ferramenta que reduza a subjetividade na avaliação de imagens de rugas periorbitais, sem, no entanto, aumentar os custos e dificultar o procedimento de diagnóstico. Para isso, foi desenvolvido um sistema computacional baseado num classificador de rugas periorbitais, capaz de categorizar o estado atual das rugas a partir de uma imagem digital obtida por uma câmera sem requisitos especiais. O sistema localiza as rugas nas imagens da região do canto do olho e classifica o grau de enrugamento do paciente na fotografia, segundo a escala de rugas de Fitzpatrick e Goldman. Os resultados apontam que o método desenvolvido obteve um desempenho de 89.6%, introduz pouca ou nenhuma interferência na rotina de consultórios dermatológicos, e auxilia na diminuição da subjetividade da classificação de rugas periorbitais.

Palavras-chave: Rugas periorbitais, Classificação e Dermatologia.

COSTA, Daniel dos Anjos. Classification of periorbital wrinkles in digital images. 122 pp. ill. 2016. Dissertation (Master) - Escola Politécnica / Instituto de Matemática, Universidade Federal da Bahia, Salvador, 2016.

ABSTRACT

This work arose from the difficulty by dermatologists to establish objective criteria for monitoring the evolution of anti-aging skin treatments, particularly the reduction of periorbital wrinkles because they are one of the main visible indicators of aging. These treatments require the dermatologist make a good diagnosis of the evaluation of the intensity of wrinkles in order to establish what the best set of measures for each clinical case. Several studies in the literature describing methods for this purpose, some are precise and laborious as the construction of negative molds silicone relief of wrinkles, others are simple and subjective as compared the patient's clinical case with wrinkle scale photographs validated clinically. The lack of objective tools for classification of wrinkles not only complicates treatment, but also hampers the physician-patient communication when it is necessary that the doctor objectively report the effects of a treatment to his/her patient. To face these problems, this work developed a computational tool that reduces subjectivity in the evaluation of periorbital wrinkles images, without increasing costs neither hampering the diagnostic procedure. To do this, we developed a computer system based on a classifier of periorbital wrinkles, that is able to categorize the current state of wrinkles from a digital image obtained by a digital camera without special requirements or procedures. The system categorizes the wrinkles detected on the images of the eye corner of the region and ranks the degree of patient wrinkle in photography, according to wrinkle scale Fitzpatrick and Goldman. The results indicate that the developed method achieved a performance of 89.6%, introduces little or none interference in the routine of dermatological practice, and helps to reduce the subjectivity in rating the periorbital wrinkles.

Keywords: Periorbital Wrinkles, Classification and Dermatology.

LISTA DE ILUSTRAÇÕES

Figura 1 - (a) transformação linear; (b) transformação univariada e monotonicamente crescente; (c) função de limiarização.	23
Figura 2 - (a) função de transformação logarítmica.....	24
Figura 3 - Exemplos de alterações no resultado da transformada exponencial com mudanças no γ	25
Figura 4 - Exemplos de histogramas.....	26
Figura 5 - Exemplo da aplicação da equalização do histograma em uma imagem de baixo contraste.....	27
Figura 6 - Esquema de funcionamento da difusão anisotrópica discreta.....	29
Figura 7 - Ilustração de relações espaciais entre os <i>pixels</i>	30
Figura 8 - Processo usado para criar a GLCM.....	31
Figura 9 - Modelo de Neurônio artificial.....	34
Figura 10 - (a) função limiar; (b) função limiar por partes; (c) função sigmóide; (d) função tangente hiperbólica.	34
Figura 11 - Arquitetura das RNAs.....	35
Figura 12 - Ilustração mostrando um conjunto de dados linearmente separáveis, com um possível hiperplano separando-os.....	37
Figura 13 - Ilustração com o hiperplano de separação e os dois hiperplanos limites H_1 e H_2	38
Figura 14 - Ilustração da aplicação de uma função <i>kernel</i> . (a) espaço de características antigo; (b) novo espaço de características.....	41
Figura 15 - Seções de pele fotografadas com luz natural (a e b) e as mesmas seções fotografadas com luz polarizada paralelamente (c e d).....	50
Figura 16 - Máscara seletora do trabalho de Cula et al. (2009, 2012).....	52
Figura 17 - Ilustração do cálculo da frequência das rugas.....	52
Figura 18 - Exemplo de fotografias no momento da aquisição.	54
Figura 19 - Ilustração das restrições geométricas da conectividade dos componentes; (a) Mostra a conexão do componente 'A' ao 'B' pelo segmento 'D'; (b) mostra a não conexão do 'A' ao 'C'; (c) exemplo de componente penalizado por sobreposição e congestionamento. .	59
Figura 20 – Pipeline do método proposto por esse trabalho.....	61
Figura 21 - Resultados das etapas do método proposto. (a) imagem original; (b) separação do canal azul; (c) difusão anisotrópica; (d) transformada exponencial; (e) limiarização pela	

média; (f) aplicação do operador <i>Sobel</i> Horizontal; (g) normalização; (h) método de Otsu; (i) aplicação da máscara seletora; (j) seleção das rugas.....	62
Figura 22 - Imagem ilustrando o ponto superior, inferior e o canto do olho (em vermelho). .	67
Figura 23 - (a) imagem original; (b) imagem com destaque da região que será recortada; (c) resultado do recorte da figura (b); (d) imagem resultante do processo de redimensionamento da imagem; (e) imagem com destaque para a região a ser recortada; (f) resultado final do recorte da região periorbital na imagem ajustada.	68
Figura 24 – (a) imagem original contendo todos os 3 canais do RGB; (b) canal R; (c) canal G; (d) canal B; (e) resultado da soma ponderada pela função <i>rgb2gray</i> do <i>Matlab</i>	70
Figura 25 - (a) antes; (b) resultado da aplicação da Transformada Exponencial; (c) resultado da Equalização do Histograma.....	72
Figura 26 - Imagem mostrando a coleta de pontos em regiões lisas da pele.	73
Figura 27 - (a) resultado da aplicação do operador <i>Sobel</i> vertical; (b) resultado da aplicação do operador <i>Sobel</i> horizontal.....	78
Figura 28 - (a) antes; (b) depois da aplicação da normalização.....	79
Figura 29 - (a) antes; (b) depois da seleção feita com ajuda da Imagem de Confiança.	81
Figura 30 - (a) Ilustração do conceito de agrupamento de <i>pixels</i> brancos; (b) ilustração da ordem sequencial de execução do algoritmo.	82
Figura 31 - Em I exemplos de agrupamentos com baixa probabilidade de serem rugas e em II com alta probabilidade.....	84
Figura 32 - (a) antes; (b) depois do processo de remoção dos pequenos agrupamentos. ...	85
Figura 33 - Gráfico com a distribuição das amostras de densidade organizadas por classe.	86
Figura 34 - Gráfico com a distribuição das amostras de variância média da pele organizadas por classe.	87
Figura 35 - Gráfico com a distribuição das amostras de comprimento da maior ruga organizada por classe.....	88
Figura 36 - Gráfico com a distribuição das amostras de contraste organizadas por classe.	89
Figura 37 - Gráfico com a distribuição das amostras de energia organizadas por classe. ...	90
Figura 38 - Exemplos de imagens classificadas. Linha (a) Suave; Linha (b) Moderado; Linha (c) Severo.	93
Figura 39 - Resultado da detecção das rugas. Linha (a) Suave; Linha (b) Moderado; Linha (c) Severo.	94
Figura 40 - Modelo da Matriz de Confusão.	97
Figura 41 - Ilustração da organização lógica das matrizes de confusão para múltiplas classes.....	98

Figura 42 - Mostra a área sobre a curva de um classificador discreto (A) e um classificador probabilístico (B).....	99
Figura 43 - Gráficos das taxas de acerto por topologia.....	102
Figura 44 - Gráfico de TOPOLOGIA x AUC das RNAs; (a) e (b) gráficos da classe SUAVE; (c) e (d) gráficos da classe MODERADO; (e) e (f) gráficos da classe SEVERO.....	104
Figura 45 - Gráfico de Função <i>Kernel</i> x AUC das SVMs; (a) e (b) gráficos da classe SUAVE; (c) e (d) gráficos da classe MODERADO; (e) e (f) gráficos da classe SEVERO.....	107
Figura 46 – Matrizes de Confusão.....	109
Figura 47 - Curva ROC dos classificadores	113

LISTA DE TABELAS

Tabela 1 - Sumário das principais escalas de rugas faciais.....	21
Tabela 2 - Descritores de textura de <i>Haralick</i>	31
Tabela 3 - Funções <i>Kernel</i>	41
Tabela 4 - Taxas de porcentagem das imagens com maior espalhamento dos níveis de cinza para cada técnica de conversão.	71
Tabela 5 - Operadores 3x3 <i>Sobel</i> , <i>Roberts</i> e <i>Prewitt</i>	76
Tabela 6 - Distribuição quantitativa das amostras nos métodos reamostragem.	101
Tabela 7 - Resultados de desempenho do classificador RNA quando submetido a topologias de redes diferentes.	102
Tabela 8 - Tabela com os resultados do desempenho do classificador SVM mediante o tipo de função <i>kernel</i> utilizado.	106
Tabela 9 - Resultados da Sensibilidade dos classificadores.....	110
Tabela 10 - Resultado da Precisão dos classificadores.	111
Tabela 11 - Resultado da Especificidade dos classificadores.....	112
Tabela 12 - Taxas de acerto na classificação mediante a troca de alguns parâmetros de projeto.....	115

SUMÁRIO

1	INTRODUÇÃO	14
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	CLASSIFICAÇÃO DE RUGAS DA PELE	19
2.1.1	Classificação das rugas quanto ao grau de enrugamento.....	19
2.2	PROCESSAMENTO DE IMAGENS	22
2.2.1	Melhoramento de Contraste	22
2.2.2	Equalização do Histograma	25
2.2.3	Suavização de Imagens	28
2.3	TÉCNICAS DE ANÁLISE DE TEXTURA ESPACIAL	29
2.3.1	Matriz de Co-ocorrência de Níveis de Cinza.....	29
2.4	APRENDIZAGEM DE MÁQUINA.....	32
2.4.1	Aprendizagem com Redes Neurais Artificiais.....	33
2.4.2	Aprendizagem com Máquinas de Vetores de Suporte	36
2.4.2.1	Função Kernel.....	40
3	DETECÇÃO E CLASSIFICAÇÃO DE RUGAS	42
3.1	DETECÇÃO E CLASSIFICAÇÃO DE RUGAS NO CONTEXTO GERAL EM IMAGENS	43
3.1.1	Sistemas de detecção de rugas para predição da idade por imagem.....	43
3.1.2	Sistemas de detecção de rugas em tecidos.....	47
3.2	SISTEMAS DE DETECÇÃO E CLASSIFICAÇÃO DE RUGAS DA PELE POR IMAGEM	49
3.2.1	Sistemas de detecção e classificação de rugas (CULA et al., 2009, 2012).....	50
3.2.2	Sistema de detecção e classificação de rugas (BRAND, 2007)	53
3.2.3	Sistemas de detecção de rugas em imagens coletadas da internet (BATOOL; CHELLAPPA, 2012 e 2015).....	57

4	DESENVOLVIMENTO DO SISTEMA	60
4.1	MÉTODO PROPOSTO PARA CLASSIFICAÇÃO DE RUGAS PERIORBITAIS	60
4.2	METODOLOGIA	65
4.2.1	Aquisição de Imagens	65
4.2.1.1	Redimensionamento da Imagem e Recorte da Região Periorbital	66
4.2.2	Pré-Processamento das Imagens	69
4.2.2.1	Conversão da imagem	69
4.2.2.2	Melhoramento do Contraste	71
4.2.3	Segmentação	74
4.2.3.1	Operadores a Gradiente	76
4.2.3.2	Normalização da imagem	78
4.2.3.3	Máscara Seletora	79
4.2.3.4	Seleção das Rugas	82
4.2.3.4.1	Restrições Geométricas	83
4.2.4	Extração de Características	85
4.2.5	Reconhecimento e Interpretação	91
4.3	DESCRIÇÃO DO <i>DATASET</i>	92
4.4	MÉTODOS DE AVALIAÇÃO DOS RESULTADOS	94
5	EXPERIMENTOS E RESULTADOS	100
5.1	TESTES COM O CLASSIFICADOR RNA	101
5.2	TESTES COM O CLASSIFICADOR SVM	105
5.3	ANÁLISE DE SENSIBILIDADE, ESPECIFICIDADE, PRECISÃO E CURVA ROC	108
5.4	TESTES PARA AJUSTE DOS PARÂMETROS DO MÉTODO	114
5.5	CONSIDERAÇÕES SOBRE OS RESULTADOS	115
6	CONCLUSÃO	117
	REFERÊNCIAS	119

1 INTRODUÇÃO

Diariamente, publicam-se nos mais diversos veículos midiáticos – como revistas impressas, programas de rádio e TV – anúncios publicitários de cosméticos utilizados em tratamentos antienvelhecimento, principalmente no combate às rugas. Um artigo publicado no *site* da Associação Brasileira da Indústria de Higiene Pessoal, Perfumaria e Cosméticos – ABIHPEC (2014) indica que o Brasil é o 3º mercado consumidor de itens dessa categoria, e os produtos para pele subiram do 7º lugar (em 2008) para o 5º lugar (em 2013) em termos de volume comercializado.

Em se tratando de estética facial, é senso comum que as rugas, particularmente as periorbitais – aquelas que aparecem ao redor dos olhos, mais conhecidas como “pé de galinha” – sejam indicadores de envelhecimento e, por causa disso, são de grande interesse nos tratamentos dermatológicos antienvelhecimento (BEILIN, 2011).

Os tratamentos dermatológicos antienvelhecimento que visam à melhoria estética, como em qualquer outro tratamento médico, requerem que o dermatologista faça um bom diagnóstico, a partir da coleta de parâmetros específicos da pele (como rugosidade, oleosidade, tipo de hidratação da pele) e da avaliação da intensidade das rugas, de forma a estabelecer qual o melhor conjunto de medidas para cada caso.

Intuitivamente, relaciona-se a intensidade das rugas à sua amplitude e profundidade, e essa intensidade está associada a percepção da idade de um indivíduo. Portanto, esses dois parâmetros são marcadores naturais para a classificação de rugas.

Diversos trabalhos na literatura apresentam métodos para coleta desses marcadores, para auxiliar na definição e acompanhamento dos tratamentos antirrugas. Entre estes, está o método da construção de moldes negativos de silicone da região da pele sob análise (BAZIN e LÉVÊQUE, 2011; GROVE e LEYDEN, 1989; HATZIS, 2004). Essa prática se mostrou bastante trabalhosa, pois requer cuidados especiais na construção dos moldes, incluindo a utilização de produtos que não agriçam a pele do paciente, que estejam em estado líquido em temperatura ambiente e que se solidifiquem rápido.

Existem também métodos baseados em equipamentos de fotografia especializados, que podem coletar detalhes da pele de forma padronizada (iluminação e distância entre a câmera e o rosto do paciente) e com alta definição, como o *Visia Complexion Analysis* da *RBX Canfield* (CANFIELD SCIENTIFIC, 2011). Outros métodos usam ultrassonografia de alta frequência ou tecnologias como *multiphoton fluorescence* e *harmonic generation microscopy* (SHOSHANI et al., 2008). Estes sistemas, embora apresentem grande precisão e reduzam a subjetividade, requerem um protocolo médico complexo para a captura das informações.

A complexidade destes protocolos dificulta e encarece o acompanhamento do paciente, o que fez com que durante muito tempo apenas a percepção visual fosse o indicador usado pelos médicos nos tratamentos antirrugas. Entretanto, nas últimas décadas, a popularização e melhoria da qualidade das câmeras fotográficas digitais permitiu a adoção destes equipamentos para registro das imagens das rugas, o que se tornou uma prática comum na rotina dermatológica, pois dá tanto ao médico quanto ao paciente uma valiosa informação sobre o estado das rugas (PINHEIRO, 2013). A utilização de imagens digitais viabilizou também a criação de bases de dados de imagens, que passaram a servir de subsídio para a pesquisa de métodos quantitativos para a classificação das rugas.

Se por um lado a adoção das câmeras digitais comuns simplificou a coleta das imagens, por outro, a necessidade de redução do tempo entre os atendimentos e a infraestrutura das clínicas de dermatologia acaba por fazer com que as fotografias sejam tiradas, em sua grande maioria, sem um padrão de iluminação e posicionamento do paciente em relação à câmera. Essa falta de padronização das imagens é compensada pelo olhar treinado do especialista, que consegue fazer as ponderações e correções necessárias para analisá-las. Infelizmente, quando existe a necessidade de comparar imagens digitais para confrontar a evolução de um tratamento, ou para que se obtenham opiniões de especialistas diferentes, a falta de padronização facilita discrepâncias entre análises, principalmente porque entra em cena a subjetividade e experiência do observador.

Visando reduzir a subjetividade, os dermatologistas comparam as fotografias da região enrugada dos pacientes com fotografias de referência de escalas de rugas previamente classificadas e validadas, como as escalas descritas nos trabalhos de

Shoshani (SHOSHANI et al., 2008), Fitzpatrick (FITZPATRICK et al., 1996), Day (DAY et al., 2004), Fabi (FABI et al., 2012), Glogau (GLOGAU, 1996) e Lemperle (LEMPERLE; HOLMES; LEMPERLE, 2001). Entretanto, mesmo com o uso das escalas de rugas como referência na análise, o processo segue sendo subjetivo, podendo um mesmo paciente receber avaliações distintas de especialistas diferentes. Além do mais, do ponto de vista do paciente, é importante que o médico utilize métodos de avaliação menos subjetivos, para que possa ganhar melhor consciência da evolução do seu tratamento (PINHEIRO; CONCEIÇÃO, 2013). Embora o “padrão ouro” nos tratamentos estéticos seja sempre a percepção final do paciente, um sistema que possa reduzir o grau de subjetividade nas análises das rugas apresenta benefícios tanto para a prática médica quanto para o melhor esclarecimento do tratamento ao paciente.

Sobre esse tema encontram-se na literatura algumas abordagens que detectam e classificam rugas faciais de forma automática a partir de imagens digitais, porém, segundo Cula (CULA et al., 2012), os métodos têm confiabilidade limitada. Os trabalhos de Cula (CULA et al., 2009) e Brand (BRAND, 2007) apresentam algoritmos de detecção e classificação de rugas da região periorbital, enquanto, no trabalho de Cula et al., (2012), os autores detectam e classificam rugas na testa. Nos três trabalhos listados, os autores descrevem seus procedimentos para a criação dos *datasets*, e alguns procedimentos para a coleta das fotografias como a utilização de uma infraestrutura mecânica para posicionar corretamente a face do paciente em relação à câmera, iluminação controlada e luz do *flash* polarizada paralelamente com a pele. Apesar desses trabalhos declararem haver obtido resultados satisfatórios, a necessidade de controlar o processo de aquisição de imagens torna o procedimento caro e trabalhoso, além de dificultar seu uso em clínicas dermatológicas, por causa dos requisitos de tempo entre os atendimentos dos pacientes. Por causa disso, a utilização desses métodos que, via de regra, implicam no aumento do tempo de atendimento ou requerem equipamento especializado, não foram amplamente aceitos pelos dermatologistas em sua prática diária.

Visando a simplificar os procedimentos de aquisição das fotografias, trabalhos recentes apresentam métodos que localizam as rugas na pele sem se preocupar com a maneira como as fotografias são tiradas (BATOOL; CHALLAPPA, 2012 e 2015). Os métodos descritos foram testados com um *dataset* criado a partir de fotografias de

peessoas famosas coletadas na *Internet*. Entretanto, não há registros de que estes estudos tenham sido aplicados à rotina de um consultório dermatológico.

Baseado nesse contexto, o objetivo deste trabalho se concentra no desenvolvimento de um método computacional para auxiliar a classificação das rugas periorbitais, a partir de imagens de pacientes coletadas de forma não padronizada por médicos dermatologistas. O método proposto utiliza uma junção de técnicas de pré-processamento de imagens digitais para detectar as rugas, e em seguida retira informações e características para alimentar um classificador que indica a qual classe de enrugamento pertence o paciente analisado. O desenvolvimento desse método traz uma contribuição significativa, pois fornece uma arquitetura com grande potencial de expansão, além de contribuir com o estudo de métodos para detecção e classificação de rugas em imagens. Todos os procedimentos e testes do método serão apresentados no decorrer do trabalho, que foi organizado em mais seis capítulos.

No Capítulo 2 é apresentada uma Fundamentação Teórica sobre rugas na pele, métodos computacionais para Processamento de Imagens Digitais, técnicas de Análise e Extração de Textura e Algoritmos de Aprendizagem de Máquina.

O Capítulo 3 apresenta uma revisão bibliográfica dos principais trabalhos disponíveis na literatura, que envolvem detecção e classificação de rugas em imagens. Trabalhos dessa natureza ainda são poucos e recentes. Entretanto, na tentativa de buscar conhecimento teórico para embasar nossa pesquisa, buscamos trabalhos que tratam de detecção de rugas na pele e em tecidos para os mais variados propósitos. Dessa maneira dividimos esse capítulo em duas seções, a primeira apresenta um breve resumo dos principais trabalhos que envolvem detecção e classificação de rugas em imagens para estimar idade das pessoas, a idade da pele e o grau de enrugamento de tecidos de roupa. Na segunda seção, daremos atenção especial aos cinco trabalhos diretamente relacionados com a nossa pesquisa. Esses trabalhos foram organizados e explicados nessa seção quanto à maneira como seus respectivos sistemas requisitam a coleta das imagens para seu perfeito funcionamento, para destacar suas principais diferenças para com o nosso trabalho.

O Capítulo 4 detalha todas as partes do método de classificação de rugas periorbitais proposto, que foi subdividido nas seguintes atividades: processo de aquisição das imagens da região periorbital; pré-processamento; segmentação;

extração de características; reconhecimento e interpretação dos dados coletados para classificação das rugas do paciente. Em seguida, é apresentada a Metodologia contendo a explicação detalhada do funcionamento do método e os principais passos e escolhas de projeto para alcançar os resultados. Ainda nesse capítulo, descrevemos a criação do *Dataset* de imagens usadas para avaliar o projeto e, ao final, os Métodos de Avaliação dos Resultados.

O Capítulo 5 apresenta os Experimentos e Resultados com uma discussão sobre os testes de avaliação e as taxas de desempenho obtidas do método final. No Capítulo 6 são apresentadas as considerações finais sobre o trabalho e acerca dos resultados obtidos, assim como algumas propostas para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este Capítulo foi dividido em quatro seções que descrevem temas centrais para o desenvolvimento do trabalho, os quais vão do domínio da aplicação até temas tecnológicos específicos para o desenvolvimento da solução. Ele engloba quatro tópicos: Classificação de rugas na pele; Processamento de Imagens Digitais; Análise e Extração de Texturas; e Aprendizagem de Máquina.

2.1 CLASSIFICAÇÃO DE RUGAS DA PELE

As rugas são vincos ou dobras que aparecem com mais frequência na face e no pescoço, e são um dos principais indicadores do envelhecimento. Elas são ocasionadas principalmente pela flacidez da pele e dos músculos, ou por movimentos naturais em locais do corpo, como por exemplo as dobras nasolabiais, que são resultados do movimento natural da boca falando ou dando sorriso (HATZIS, 2004).

O que desencadeia a formação das rugas é o fato das fibras elásticas irem se tornando frágeis com o passar dos anos. Juntamente com a exposição ao sol, a consequência é a perda de firmeza da pele. Finalmente, a perda de elasticidade chega a um ponto em que a contração dos músculos envolvidos nas expressões faciais forma na pele os desenhos dos seus movimentos (MENDONÇA, 2004).

2.1.1 Classificação das rugas quanto ao grau de enrugamento

Esse tipo de classificação vem da necessidade de mensurar os níveis de severidade do enrugamento da pele dos pacientes que estão passando por tratamento. Algumas escalas numéricas de rugas foram criadas a partir de ensaios clínicos projetados para diminuir a subjetividade e as discrepâncias durante o

processo de avaliação. Na Tabela 1 exibem-se as principais escalas de rugas na face, utilizadas pelos dermatologistas.

A Escala de Rao-Goldman, a Escala de Lemperle e a Escala de Glogau avaliam a maioria das rugas na região da face, e as três se baseiam na avaliação por fotografias. Entretanto, a Escala de Glogau utiliza outros critérios técnicos para aprimorar sua avaliação, como a observação do foto-envelhecimento, os níveis de queratose, a pigmentação da pele e a idade do paciente.

A Escala de Fitzpatrick-Goldman propõe um escore de intensidade das rugas para avaliar a gravidade das rugas periorais (ao redor da boca) e periorbitais (no canto dos olhos), para ser usado em estudos de tratamento a *laser* de recapeamento da pele. Sua classificação utiliza como parâmetro a observação das rugas em imagens, medidas de elastose solar na pele (degeneração do tecido), discromia (alteração da cor) e profundidade das rugas. O critério de profundidade das rugas se baseia na opinião dos avaliadores pela observação, e não em medidas coletadas fisicamente.

A Escala de Fitzpatrick Modificada e a Escala de Day tratam de rugas da região nasolabial. Cada uma delas apresenta suas classes, especificações técnicas, descrições de características e fotografias de referência.

A escala de Fitzpatrick Modificada (SHOSHANI et al., 2008) foi validada pelo *Medical Department of ColBar LifeScience*, no sentido de verificar o quanto essa escala facilita e aumenta a taxa de acertos nos diagnósticos dos pacientes. A eficácia da escala foi avaliada observando o processo de treinamento dos avaliadores e o processo de classificação com imagens de treinamento. Essa avaliação mediu o sincronismo dos resultados das avaliações, buscando a concordância inter e intra-avaliadores.

Tabela 1 - Sumário das principais escalas de rugas faciais.

Nome da Escala	Lugar de avaliação	Sistema de Classificação
Escala de rugas na face de Rao-Goldman (RAO; EHRlich; GOLDMAN, 2004)	Face	Classe 1 - Sem rugas Classe 2 - Rasa, mas visível Classe 3 - Rugas de profundidade moderada Classe 4 - Rugas profundas, com boas definições de bordas Classe 5 - Rugas muito profundas, com dobras redundantes.
Escala de rugas de 9 pontos de Fitzpatrick-Goldman (FITZPATRICK et al., 1996)	Perioral e Periorbital	Escore Descrição Grau de Elastose ¹
		1-3 Rugas leves Suave
		4-6 Rugas com profundidade moderada e quantidade moderada Moderado
7-9 Rugas profundas, em grande quantidade, com ou sem redundância de dobras Severo		
Escala de rugas de Fitzpatrick modificada (SHOSHANI et al., 2008)	Nasolabial	Classe 0 - Sem visíveis rugas Classe 0.5 - Rugas muito rasas, mas visíveis Classe 1.0 - Rugas finas, visíveis e com suave reentrância Classe 1.5 - Rugas visíveis, com reentrâncias claras e com 1 mm de profundidade Classe 2.0 - Rugas moderadas, reentrâncias muito claras e com profundidade de 1 a 2 mm Classe 2.5 - Rugas visíveis, salientes e com profundidade de 2 a 3 mm Classe 3.0 - Rugas bastante profundas, com profundidade acima de 3 mm
Escala de 6 pontos de Lemperle (LEMPERLE; HOLMES e LEMPERLE, 2001)	Entre as sobrancelhas, periorbitais, periauricular, nasolabiais, lábios superiores e inferiores, canto da boca, lateral do queixo, testa, acima do queixo e pescoço	Classe 1 - Sem rugas Classe 2 - Apenas perceptível Classe 3 - Rugas rasas Classe 4 - Rugas moderadas Classe 5 - Rugas profundas com bordas bem definidas Classe 6 - Rugas muito profundas com dobras redundantes
Escala de 5 pontos de Day (DAY et al., 2004)	Nasolabial	Classe 1 (ausente) - sulco nasolabial não visível Classe 2 (suave) - sulco nasolabial raso, mas visível Classe 3 (moderado) - sulco com profundidade moderada, claramente visível normalmente, mas não quando esticado Classe 4 (severo) - sulco nasolabial longo e profundo com 2 mm de profundidade Classe 5 (extremo) - sulcos extremamente profundos e longos, com 2 a 4 mm de profundidade.
Escala de 4 pontos de Glogau (GLOGAU, 1996)	Face	Tipo I - Sem rugas e <i>queratose</i> ² ; foto envelhecimento precoce; suaves mudanças na pigmentação; pacientes de 20 e 30 anos. Tipo II - Rugas em movimento; foto envelhecimento moderado; lentigos precoces visíveis, queratose palpável, mas não visível, linhas periorais começam a aparecer; pacientes de 30 a 40 anos. Tipos III - Rugas em repouso; foto envelhecimento avançado; <i>discromias</i> ³ aparentes, <i>telangiectasia</i> ⁴ aparente, queratoses visíveis; paciente com mais de 50 anos. Tipo IV - Somente rugas; foto envelhecimento crítico; cor da pele amarela acinzentada; pacientes acima de 60 anos.

Fonte: Adaptado de Fabi et al. (2012).

¹ Degeneração do tecido elástico subdérmica por exposição prolongada ao sol.

² Lesão vermelha e escamosa que indica dano solar que pode evoluir para câncer da pele.

³ Anomalia ou alteração na pigmentação da pele.

⁴ Trata-se de dilatações capilares.

2.2 PROCESSAMENTO DE IMAGENS

O Processamento de Imagens consiste na aplicação de técnicas que trabalham diretamente na intensidade dos *pixels*, para melhorar o aspecto visual de uma imagem ou convertê-la a um formato mais adequado, que facilite a análise de uma pessoa ou de uma máquina (FILHO; NETO, 1999, p.10). Na prática, não existe uma teoria unificada de melhoria de imagens, porque não há um padrão geral de qualidade de imagem que sirva como critério de comparação. Porém, a literatura apresenta uma variedade de técnicas que são úteis para essa atividade.


Nesta seção falaremos das técnicas utilizadas neste trabalho: Melhoramento do Contraste, Equalização do Histograma e suavização de imagens com a Difusão Anisotrópica.

2.2.1 Melhoramento de Contraste

As técnicas de melhoramento de contraste são usadas para aprimorar a qualidade visual da imagem, objetivando facilitar a interpretação, melhorar a visualização de cenas e aumentar a quantidade de informações que podem ser extraídas visualmente. Segundo Gonzalez e Woods (2008, p. 142), o contraste é diretamente proporcional ao espalhamento dos níveis de cinza, que é dado pela largura da base do histograma (conceito que será visto com mais detalhes na próxima seção). Logo o melhoramento do contraste busca uma ampliação do intervalo original de níveis de cinza.

Segundo Gonzalez e Woods (2008, p. 137), imagens de baixo contraste podem ser resultantes de iluminação insuficiente, limitações da escala dinâmica no sensor que capta a luminosidade das imagens que são projetadas sobre ele, ou incorreta abertura da lente durante a fotografia. Uma maneira de corrigir o problema de contraste é aplicar transformações para o alongamento da escala de níveis de cinza. Na Figura 1 ilustramos três exemplos de alterações dos níveis de cinza dinâmicos pela função de transformação $T(f(i, j))$.

Figura 1 - (a) transformação linear; (b) transformação univariada e monotonicamente crescente; (c) função de limiarização.

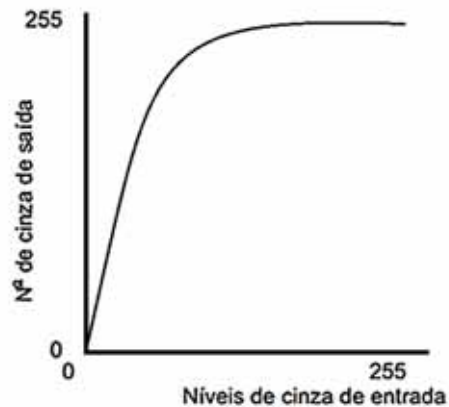


Fonte: Adaptada de Gonzalez e Woods (2008, p. 137).

No exemplo da Figura 1a é apresentado um caso em que $r_1 = s_1$ e $r_2 = s_2$, o que provoca na função de transformação uma distribuição dos níveis de cinza linear que não produzirá mudanças. Na Figura 1b ilustra-se um caso em que $r_1 \leq r_2$ e $s_1 \leq s_2$ e a nova função de transformação será univariada e monotonicamente crescente (GONZALEZ; WOODS, 2008, p. 137). A posição dos pontos (r_1, s_1) e (r_2, s_2) molda a função de transformação, e altera diretamente os níveis de cinza, implicando a alteração do contraste. A Figura 1c apresenta um caso em que a função de transformação é de limiarização. Ela cria uma imagem binária em que $r_1 = r_2$, $s_1 = 0$ e $s_2 = L - 1$.

Dentre as funções de transformação não linear, podemos destacar a transformação logarítmica e exponencial. A curva de transferência de uma função logarítmica tem por característica realçar as partes escuras de uma imagem em detrimento das partes mais claras. Na Figura 2 pode-se acompanhar a evolução progressiva da curva de uma função logarítmica pelo espelhamento da função no eixo Y (eixo com os níveis de cinza de saída da transformação), que amplia a faixa de níveis de cinza escuro em detrimento das faixas de *pixels* claros, ou seja, tornando visíveis partes escuras da imagem (GONZALEZ; WOODS, 2008, p. 131).

Figura 2 - (a) função de transformação logarítmica.



Fonte: Elaborado pelo autor.

Esse realce utiliza uma função de transformação logarítmica, que, em geral, é dada pela seguinte equação:

$$g(i, j) = c \cdot \log_a(1 + |f(i, j)|) \quad (2.1)$$


O termo c é uma constante de escala que serve para ampliar a curva, $f(i, j)$ é a intensidade dos *pixels* da imagem que sofrerá a compressão e a é a base, que deve ser maior que 1.

A transformação exponencial ou de potência tem uma abrangência maior que a transformação logarítmica. A função de transformação exponencial é mapeada pela Equação 2.2:

$$g(i, j) = c \cdot f(i, j)^\gamma \quad (2.2)$$

O termo c é uma constante de escala e γ é a potência à qual se deseja elevar o brilho da imagem original $f(i, j)$. Se $\gamma > 1$ a transformação exponencial tem o efeito inverso do logarítmico, ou seja, realça as porções mais claras da imagem às custas da porção mais escura. Caso $\gamma < 1$, seu efeito é semelhante ao da função logarítmica, e se $\gamma = 1$, não tem efeito a transformação. A Figura 3 exhibe gráficos da transformada exponencial para vários valores de γ ($c = 1$ para todos os casos).

Figura 3 - Exemplos de alterações no resultado da transformada exponencial com mudanças no γ .



Fonte: Adaptada de Gonzalez e Woods (2008, p. 133).

É importante, ao aplicar essa técnica, manter a amplitude da imagem final dentro de uma faixa aceitável pelo padrão de cores que está sendo usado.

2.2.2 Equalização do Histograma

Segundo Filho e Neto (1999, p. 55), o conceito de histograma de uma imagem pode ser expresso como um conjunto de números indicando o percentual de *pixels* naquela imagem que apresentam um determinado nível de cinza. Na prática, um histograma nada mais é que uma função de distribuição de probabilidades e, como tal, deve obedecer aos axiomas e teoremas da teoria de probabilidade. O cálculo das probabilidades das intensidades dos níveis de cinza de uma imagem com $M \times N$ *pixels* é dado pela seguinte equação:


$$P_r(r_k) = \frac{n_k}{M.N} \quad (2.3)$$

em que:

- $k = \{0, 1, \dots, L - 1\}$, e L é o número de níveis de cinza diferentes da imagem digitalizada;
- $M.N$ é o número total de *pixels* na imagem;
- $P_r(r_k)$ é a proporção de *pixels* com intensidade r_k na imagem;
- n_k é o número de *pixels* cujo nível de cinza corresponde a intensidade r_k .

A Figura 4a apresenta o histograma de uma imagem predominantemente escura, pelo fato de os *pixels* encontrarem-se agrupados, em sua maioria, nos valores mais baixos de cinza. O oposto verifica-se na Figura 4b, em que é ilustrado um histograma de uma imagem predominantemente clara. Na Figura 4c os *pixels* estão agrupados em torno de valores intermediários de cinza, correspondendo a uma imagem de brilho médio de baixo contraste. A Figura 4d apresenta uma imagem com *pixels* distribuídos ao longo de toda a escala de cinza, a qual consideramos uma imagem de bom contraste.

Figura 4 - Exemplos de histogramas.



Fonte: Adaptada de Gonzalez e Woods (2008, p. 143)


A técnica de equalização do histograma procura redistribuir os valores de tons de cinza dos *pixels* em uma imagem, de maneira que se obtenha um histograma uniforme, no qual o percentual de *pixels* de qualquer nível de cinza seja praticamente o mesmo (FILHO; NETO, 1999, p. 61). Uma técnica muito utilizada para equalizar um histograma é a da função de distribuição acumulada da distribuição de probabilidades original, que é expressa pela Equação 2.4:

$$s_k = T(r_k) = \sum_{j=0}^k \frac{n_j}{n} = \sum_{j=0}^k p_r(r_j) \quad (2.4)$$

O termo S_k é o resultado das somas de todas as distribuições $P_r(r_k)$ até o intervalo k , que vai de 0 até $L - 1$. Como a imagem foi quantizada com apenas k níveis de cinza, cada valor s_k deverá ser arredondado para o valor válido (múltiplo de $1/k$) mais próximo, e os níveis de intensidade de cinza r_k serão mapeados para o novo nível s_k . Esse arredondamento direciona para uma melhor distribuição de *pixels* ao longo da escala de cinza em relação a original.

Na Figura 5a é apresentada uma imagem com pouco contraste e na Figura 5b o histograma da mesma. No histograma pode-se observar a concentração dos *pixels* da imagem dentro de um pequeno intervalo de níveis de cinza, deixando a imagem com pouco contraste e brilho médio.

Figura 5 - Exemplo da aplicação da equalização do histograma em uma imagem de baixo contraste.



Fonte: Adaptada de Filho e Neto (1999, p. 64)

A Figura 5c apresenta o resultado da equalização do histograma da Figura 5a, e pode-se facilmente perceber o aumento do contraste na definição da imagem. Na Figura 5d nota-se como os *pixels* se apresentam mais distribuídos pelos níveis de cinza da imagem.

2.2.3 Suavização de Imagens

Filtros de suavização são usados para borramento e redução de ruídos (GONZALEZ; WOODS, 2008, p. 174). A grande maioria das técnicas de suavização não localizam as bordas das imagens, e acabam suavizando a imagem como um todo, o que, dependendo da aplicação, acaba dificultando ainda mais o trabalho do detector de bordas. Por essa razão, a difusão anisotrópica (PERONA; MALIK, 1990) é umas das técnicas mais utilizadas na literatura para suavizar a imagem sem perder as características das bordas.

O processo de difusão anisotrópica calcula coeficientes de condução que têm a função de encorajar a suavização intrarregião (regiões que não são bordas) e evitar a suavização interregião (regiões de fronteiras ou bordas), ou seja, para regiões homogêneas temos difusão máxima e para regiões heterogêneas temos difusão mínima. Nesse cálculo os autores usaram uma função chamada de Função de Parada na Aresta (*Edge Stopping Function*). A função de parada controla a intensidade da difusão anisotrópica na região da imagem que deve sofrer a difusão, de acordo com o específico gradiente do ponto.

A difusão anisotrópica é descrita pela Equação 2.5:

$$I_t = \text{div}(c(x, y, t)\nabla I) = c(x, y, t)\Delta I + \nabla c \cdot \nabla I \quad (2.5)$$


em que:

- div é o operador divergente;
- ∇ é o operador gradiente;
- Δ é o operador Laplaciano;
- c é o coeficiente de condução;
- I é a imagem;
- t são as iterações.

A Equação 2.5 pode ser discretizada em uma rede quadrada, com o valor de intensidade $I_{i,j}$ associado aos vértices, e os coeficientes de condução c associados

aos arcos (PERONA; MALIK, 1990). A estrutura do esquema computacional para a simulação da difusão anisotrópica é exibida na Figura 6.

Figura 6 - Esquema de funcionamento da difusão anisotrópica discreta.



Fonte: Adaptada de Perona e Malik (1990).


2.3 TÉCNICAS DE ANÁLISE DE TEXTURA ESPACIAL

Nessa seção abordaremos os métodos de análise de textura espacial, que usam a matriz GLCM (*Gray-Level Co-Occurrence Matrix*, em português Matriz de Co-ocorrência de Níveis de Cinza) e os descritores de textura de *Haralick* (HARALICK et al., 1973), que foram úteis nas etapas de Extração de Características das imagens e Reconhecimento e Interpretação do sistema.

2.3.1 Matriz de Co-ocorrência de Níveis de Cinza

Também conhecida como matriz de dependência espacial de níveis de cinza, é um método de análise de textura espacial, em que a matriz contém a probabilidade conjunta de todas as relações angulares e de distância entre pares de *pixels* vizinhos na imagem em nível de cinza (HARALICK et al., 1973). A Figura 7 ilustra algumas relações espaciais de distância ' d ' e ângulo ' θ ' entre o *pixel* de interesse e seus vizinhos na imagem. Os ângulos ilustrados na figura são de 0° , 45° , 90° e 135° .


Figura 7 - Ilustração de relações espaciais entre os *pixels*.



Fonte: Adaptada de *Mathworks Documentation* (2016).

A matriz GLCM contém as informações de co-ocorrência de pares de *pixels* relacionados seguindo uma relação espacial específica. A partir da matriz podem-se derivar várias medidas estatísticas sobre a imagem e algumas propriedades relativas à distribuição espacial dos *pixels*. Por exemplo, pode-se concluir que a textura é grosseira quanto aos deslocamentos específicos de *pixels*, caso a maior parte dos elementos na GLCM esteja distribuída na diagonal principal. Isso ocorre porque as relações que estão distribuídas na diagonal da GLCM são entre os *pixels* com intensidades iguais.

O tamanho da GLCM é determinado pela quantidade de níveis de cinza diferentes que existem na imagem analisada. Para ilustrar, a Figura 8 mostra como calcular três valores de uma GLCM para $d=1$ e ângulo $\theta=0^\circ$. Na posição (1,1) da matriz GLCM, encontramos o valor 1, porque só existe um único caso na imagem de entrada A que tem dois *pixels* adjacentes com valores 1 e 1. A célula (0,2) contém o valor 2, porque existem dois casos em que dois *pixels* adjacentes na horizontal têm os valores 0 e 2, respectivamente. Elemento (0,3) tem o valor 0, porque não existem exemplos de dois *pixels* adjacentes na horizontal com os valores 0 e 3. Esse mesmo procedimento pode ser feito com outras variações de distância e ângulo.

Figura 8 - Processo usado para criar a GLCM.

Fonte: Adaptada de *Mathworks Documentation* (2016).

Segundo Haralick (HARALICK, 1973), a partir da matriz de Co-ocorrência, podemos gerar 14 descritores de textura, também conhecidos como descritores de textura de *Haralick*, que são valores numéricos que podem ser usados para diferenciar ou até classificar texturas. Na Tabela 2 são apresentados os dois descritores usados no presente trabalho, os quais integram o conjunto dos 14 descritores de textura de Haralick. Os detalhes em relação à escolha dos descritores da Tabela 2 serão apresentados na seção 4.2.4, juntamente com as outras características extraídas das imagens pelo sistema.

Tabela 2 - Descritores de textura de *Haralick*.

Nome	Descrição	Equação
Contraste	Mede as variações locais na GLCM em todos os <i>pixels</i> da imagem. Essa variação é a medida do contraste entre as intensidades do <i>pixel</i> analisado e do <i>pixel</i> vizinho.	$\sum_{i,j} i - j ^2 p(i, j)$
Segundo momento angular (energia)	Faixa de valores possíveis: 0 a 1. Fornece a soma de elementos quadrados da GLCM. É uma medida que expressa a uniformidade da imagem. A energia possui valor 1 para uma imagem constante (mesmo tom de cinza em toda a sua extensão).	$\sum_{i,j} p(i, j)^2$

Fonte: Haralick et al. (1973)

O termo $p(i, j)$ é o registro na posição i e j na matriz GLCM. Os termos μ_i, μ_j são as médias e os termos σ_i, σ_j são os desvios padrões da probabilidade marginal que são obtidos pela soma da coluna i ou j na matriz GLCM.

2.4 APRENDIZAGEM DE MÁQUINA

De acordo com Mitchell (1997, p. 20), a aprendizagem de máquina é a capacidade de uma máquina adquirir a definição de uma categoria geral, a partir de amostras de exemplos de formação positiva e negativa desta categoria. Em outras palavras, pode-se dizer que o processo de aprendizagem está ligado à capacidade de qualquer máquina ou programa melhorar seu desempenho em uma tarefa por meio da experiência.

O conceito de aprendizagem de máquina se adapta de acordo com o ambiente e as técnicas utilizadas. No caso das Redes Neurais Artificiais (RNA), Haykin (2001, p. 75) define a aprendizagem como um processo pelo qual os parâmetros livres de uma RNA são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida.

Uma questão importante é a maneira como se realiza o aprendizado de máquina. A escolha do paradigma determina como o algoritmo se relaciona com o meio para, de fato, evoluir seu aprendizado (HAYKIN, 2001, p.75). Dentre diversos paradigmas desse ramo, discutiremos o processo de aprendizagem supervisionada, porque foi o utilizado neste trabalho.

No paradigma de aprendizagem supervisionada (também chamado de aprendizagem com professor) é introduzido no sistema um “professor” que possui conhecimento do ambiente apresentado. Esse professor é representado por um conjunto de exemplos na forma de entrada/saída, que ajudará o sistema – até o momento sem conhecimento prévio do ambiente – a manipular seus parâmetros internos para que, a cada iteração, evolua aprendendo com seus “erros”. A evolução dos parâmetros do sistema é regida por um sinal de erro, que é definido como a

diferença entre a resposta desejada e a resposta real do sistema (HAYKIN, 2001, p. 88).

Nas próximas seções trataremos das duas abordagens de aprendizagem de máquina que foram usadas neste trabalho: aprendizagem com RNA (Redes Neurais Artificiais) e com Máquinas de Vetores de Suporte (em inglês *Support Vector Machine* – SVM).

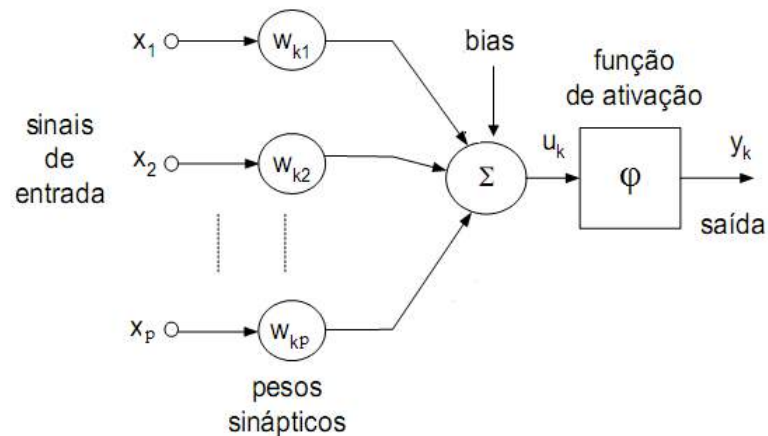
2.4.1 Aprendizagem com Redes Neurais Artificiais

Haykin (2001, p. 28) propõe que uma RNA é um processador maciçamente distribuído constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível ao uso. Sua estrutura física se assemelha a do cérebro humano, por adquirir conhecimento a partir de seu ambiente, através de um processo de aprendizagem, e por usar pesos sinápticos para armazenar o conhecimento adquirido.

Os neurônios artificiais são os elementos básicos de uma RNA e devem estar conectados entre si, dispostos em camadas. Normalmente se comportam de maneira semelhante, caso pertençam a uma mesma camada. A disposição dos neurônios nas camadas, e o padrão de conexão entre estas, definem a arquitetura da RNA. O modelo de um neurônio artificial pode ser visto na Figura 9.

Os termos $\{x_1, x_2, \dots, x_p\}$ simbolizam terminais externos de entrada de sinal, geralmente podem ser usados como porta de entrada na rede ou conectados a saídas de outros neurônios. Os símbolos $\{w_{k1}, w_{k2}, \dots, w_{kp}\}$ correspondem aos pesos sinápticos das entradas do neurônio k . Os sinais de entrada são ponderados pela multiplicação com os pesos sinápticos, e são somados com o *bias* para gerar a saída do combinador linear u_k . O *bias* é um parâmetro externo do neurônio k e serve para deslocar a curva da função gerada pelo somatório dos sinais de entrada.

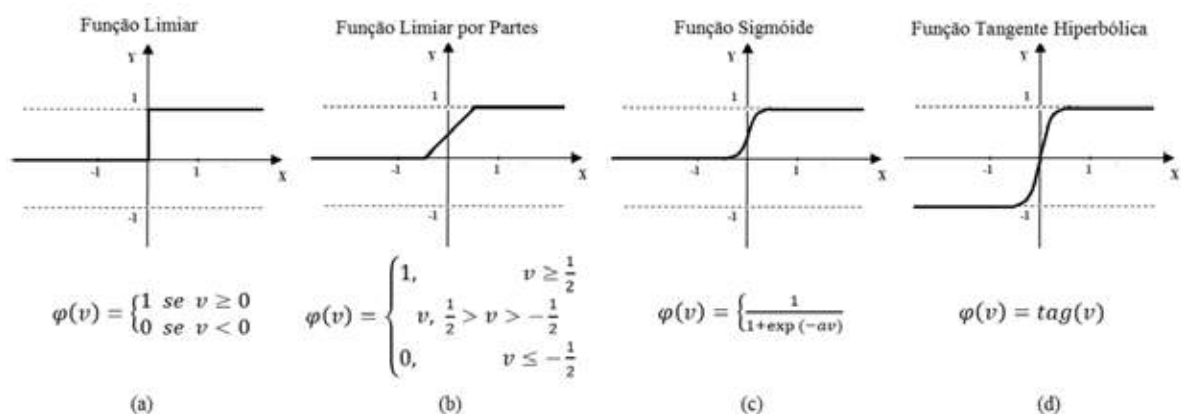
Figura 9 - Modelo de Neurônio artificial.



Fonte: Adaptada de Haykin (2001)

O último elemento do neurônio é a função de ativação, representada por $\varphi(v)$, que por definição, segundo Haykin (2001, p. 38), é a saída do neurônio em termo do campo local induzido v . As funções de ativação mais conhecidas e usadas são: função limiar, limiar por partes, sigmóide e tangente hiperbólica. A Figura 10 exibe as equações de quatro funções de ativação descritas e seus respectivos gráficos.

Figura 10 - (a) função limiar; (b) função limiar por partes; (c) função sigmóide; (d) função tangente hiperbólica.



Fonte: Adaptada de Haykin (2001)

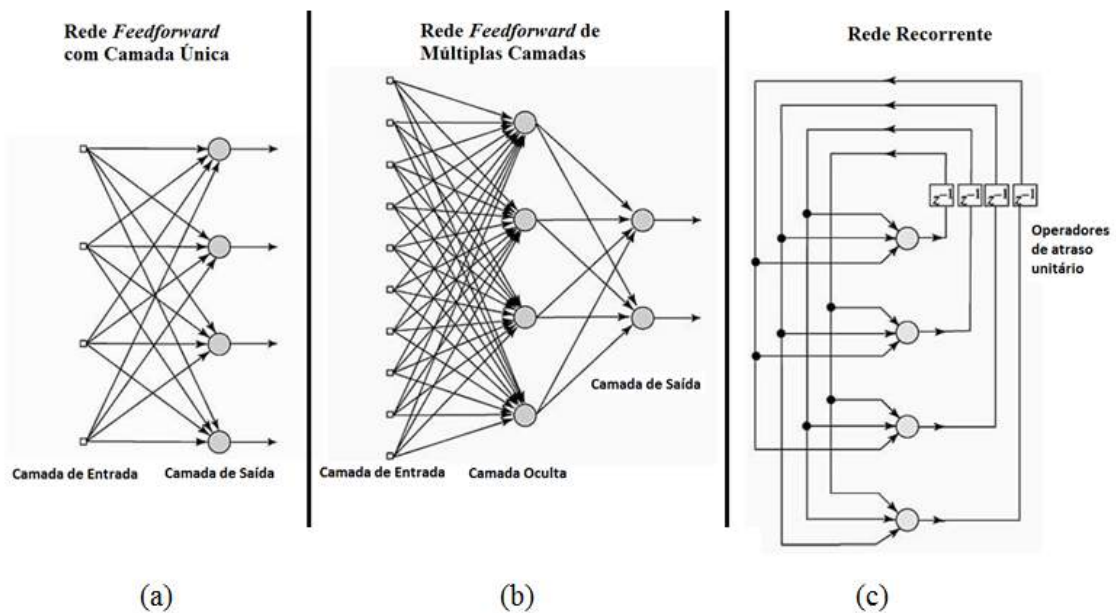
Outra maneira de se classificar uma rede RNA é quanto à sua organização estrutural (topologia). Esse tipo de critério influencia diretamente no desempenho da

rede. Entretanto, a escolha da topologia da rede, na maioria das vezes, é puramente empírica. Geralmente, as RNAs são organizadas em estrutura de camadas, na qual a saída de uma camada se liga à entrada de outra camada posterior, como ilustrado na Figura 11b.

A arquitetura de uma RNA pode ser classificada em três classes diferentes, ilustradas na Figura 11. A primeira classificação é conhecida como rede *Feedforward* com Camada Única (Figura 11a). Ela apresenta uma camada de entrada e uma camada de saída, e é denominada *feedforward* porque o sinal é propagado apenas da entrada para a saída, em um único sentido positivo.

Outra derivação é a rede *Feedforward* de Múltiplas Camadas (Figura 11b), que, como o próprio nome já diz, pode possuir n camadas intermediárias, o que implica um maior poder de processamento. A última estrutura arquitetural é a da rede Recorrente (Figura 11c). Esse tipo de rede possui pelo menos um laço de realimentação, e pode ser formada por uma única camada de neurônios, com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios (HAYKIN, 2001, p.47). A presença desses laços de realimentação proporciona à rede um impacto profundo na capacidade de aprendizagem e desempenho.

Figura 11 - Arquitetura das RNAs.



Fonte: Adaptada de Haykin (2001)

Os operadores de atraso unitário (representados por z^{-1}), ilustrados na Figura 11c nas redes recorrentes, conferem à rede um comportamento dinâmico e não linear (HAYKIN, 2001, p. 49).

2.4.2 Aprendizagem com Máquinas de Vetores de Suporte

A técnica conhecida como Máquinas de Vetores de Suporte (em inglês *Support Vector Machines* – SVM), foi idealizada na década de 60, com a teoria de Lagrange, porém começou a ter destaque nos anos 90, com o artigo de Vapnik, Boser e Guyon (1992). A principal tarefa de uma SVM é dividir um conjunto de amostras em duas classes, utilizando um hiperplano que é induzido a partir das amostras de treinamento, baseando-se na teoria do aprendizado estatístico e na teoria da otimização.

Seja f um classificador e F o conjunto de todos os classificadores que um determinado algoritmo de aprendizado de máquina pode gerar. A teoria de aprendizado estatístico fornece condições matemáticas que auxiliam, durante o processo de aprendizado e usando um conjunto de treinamento dado pelo par de matrizes (X, Y) , a escolha de um classificador particular $\hat{f} \in F$ (LORENA; CARVALHO, 2007).

A matriz X tem dimensão $N \times n$, enquanto a matriz Y é de dimensão $N \times 1$, com N representando o número de amostras e n indicando a dimensão do espaço de entrada. O par (x_i, y_i) é uma amostra dos dados, e é considerado a i -ésima linha da matriz (X, Y) , com o vetor $x_i \in \mathfrak{R}^n$ e o escalar $y_i \in \mathfrak{R}$.


O classificador SVM busca encontrar o melhor hiperplano H_i entre todos os hiperplanos $\{H_1, H_2, \dots, H_n\}$ no espaço r -dimensional que separa as amostras positivas das amostras negativas de treinamento. O hiperplano ótimo deve fornecer o menor erro de classificação e a maior margem, distância entre as superfícies limítrofes (limites definidos pelas posições das últimas amostras positivas e negativas em relação ao hiperplano) (VAPNIK; BOSER; GUYON, 1992). A Figura 12 ilustra um conjunto de dados com apenas duas categorias de amostras (positivas e negativas) e um hiperplano de separação. As amostras mais próximas do hiperplano estão

circuladas e delimitam à distância de margem, e é chamada de vetor-suporte. A função que delimita o hiperplano é dada na forma de:

$$(\mathbf{x} \cdot \mathbf{w}) + b = 0 \quad \text{com } \mathbf{w} \text{ e } \mathbf{x} \in \mathfrak{R}^n \text{ e } b \in \mathfrak{R} \quad (2.6)$$

O termo \mathbf{w} é o vetor normal ao hiperplano H , o parâmetro b é chamado de *bias* e permite a movimentação do hiperplano na direção normal. O \mathbf{x} é o vetor de amostras de treinamento. No momento do treinamento, os parâmetros \mathbf{w}^* e b^* são calculados na tentativa de encontrar o hiperplano ótimo. A notação $(\mathbf{x} \cdot \mathbf{w})$ indica a operação de produto interno entre os vetores.

Figura 12 - Ilustração mostrando um conjunto de dados linearmente separáveis, com um possível hiperplano separando-os.



Fonte: Adaptada de Vapnik e Cortes (1995).

O hiperplano de separação na forma canônica deve satisfazer as seguintes condições na Equação 2.7:

$$\begin{cases} (\mathbf{w} \cdot \mathbf{x}_i) + b \geq +1, & \text{para } y_i = +1, i = 1, \dots, N \\ (\mathbf{w} \cdot \mathbf{x}_i) + b \leq -1, & \text{para } y_i = -1, i = 1, \dots, N \end{cases} \quad (2.7)$$

Caso peguemos um ponto $P(x_1, y_1)$ qualquer e uma reta definida por $ax + by + c = 0$, a distância do ponto P à reta é dada pela Equação 2.8. De maneira semelhante

podemos deduzir a equação da distância entre o hiperplano H com o vetor de amostra x_i (Equação 2.9).


$$d(a, b; P) = \frac{|ax_1 + by_1 + c|}{\sqrt{a^2 + b^2}} \quad (2.8)$$

$$d(\mathbf{w}, b; \mathbf{x}) = \frac{|(\mathbf{w} \cdot \mathbf{x}) + b|}{\|\mathbf{w}\|} \quad (2.9)$$

A margem de separação $\rho(\mathbf{w}, b)$, que é a distância entre os hiperplanos limites H_1 e H_2 (ilustrados na Figura 13), é definida por Vapnik e Cortes (1995):

$$\begin{aligned} \rho(\mathbf{w}, b) &= \min_{\{x_i, y_i=1\}} d(\mathbf{w}, b; x_i) + \min_{\{x_j, y_j=-1\}} d(\mathbf{w}, b; x_j) \\ \rho(\mathbf{w}, b) &= \frac{1}{\|\mathbf{w}\|} \left(\min_{\{x_i, y_i=1\}} |\mathbf{w} \cdot x_i + b| + \min_{\{x_j, y_j=-1\}} |\mathbf{w} \cdot x_j + b| \right) \\ \rho(\mathbf{w}, b) &= \frac{2}{\|\mathbf{w}\|} \end{aligned} \quad (2.10)$$

Figura 13 - Ilustração com o hiperplano de separação e os dois hiperplanos limites H_1 e H_2 .



Fonte: Adaptada de Lorena e Carvalho (2007).

Portanto, o hiperplano ótimo é definido para os valores de \mathbf{w} e b que satisfaçam as restrições da equação 2.7 e tenham $\min \|\mathbf{w}\|$. As restrições da equação 2.7 são impostas para garantir que não existam amostras x_i entre as margens limites (H_1 e H_2) das classes. Dessa forma, recorre-se ao seguinte problema de otimização:

$$\min_{\mathbf{w}, b} \frac{1}{2} \|\mathbf{w}\|^2 \quad (2.11)$$

A Equação 2.11 apresenta um problema clássico em otimização denominado programação quadrática. Como solução, usou-se uma função Lagrangeana definida em termos de \mathbf{w} e b :

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i (\mathbf{w} \cdot \mathbf{x}_i + b) - 1) \quad (2.12)$$

O termo α_i ($i = 1, \dots, N$) é o multiplicador de Lagrange. A função Lagrangeana L tem que ser minimizada em função de \mathbf{w} e b e maximizada com respeito a α_i (LIMA, 2004). Disto resulta o seguinte problema dual:

$$\max_{\alpha} W(\alpha) = \max_{\alpha} \left\{ \min_{\mathbf{w}, b} L(\mathbf{w}, b, \alpha) \right\} \quad (2.13)$$

$$\max_{\alpha} W(\alpha) = \max_{\alpha} \left[-\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) + \sum_{i=1}^N \alpha_i \right] \quad (2.14)$$

A solução para o problema é dada pela equação 2.15:

$$\alpha^* = \arg \min_{\alpha} \left[\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) - \sum_{i=1}^N \alpha_i \right] \quad (2.15)$$

Considerem-se as seguintes restrições:

$$\begin{cases} \alpha_i \geq 0, i = 1, \dots, N \\ \sum_{i=1}^N \alpha_i y_i = 0 \end{cases} \quad (2.16)$$

Logo, com o valor de α^* , podemos encontrar os valores de \mathbf{w}^* e b^* :

$$\mathbf{w}^* = \sum_{i=1}^N \alpha_i^* x_i y_i \quad (2.17)$$

$$b^* = -\frac{1}{2} [(\mathbf{w}^* \cdot \mathbf{x}_r) + (\mathbf{w}^* \cdot \mathbf{x}_s)] \quad (2.18)$$

Os termos \mathbf{x}_r e \mathbf{x}_s são os vetores-suporte de cada classe (LIMA, 2004), e satisfazem:

$$\alpha_r, \alpha_s > 0, y_r = 1, y_s = -1 \quad (2.19)$$

Portanto, de acordo com a Equação 2.17 os vetores-suporte \mathbf{x}_r e \mathbf{x}_s são aquelas amostras em que os multiplicadores α são maiores que zero. A função de classificação SVM é dada pela Equação 2.19. A função *sign* retorna +1 para $\mathbf{w}^* \cdot \mathbf{x} + b^* > 0$ e retorna -1 para $\mathbf{w}^* \cdot \mathbf{x} + b^* < 0$:

$$f(\mathbf{x}) = \text{sign}(\mathbf{w}^* \cdot \mathbf{x} + b^*) \quad (2.20)$$

2.4.2.1 Função Kernel

Em alguns casos uma SVM linear não é capaz de separar amostra de um determinado domínio usando hiperplanos, devido à distribuição e à complexidade das amostras. Nestes casos, pode-se alterar o domínio matemático das amostras, permitindo assim que um classificador linear possa separá-las. Esse novo domínio é chamado de espaço das características e é obtido submetendo as amostras a uma função *kernel*. Segundo Hsu et al. (2003), os vetores de treinamento x_i são mapeados em um espaço dimensional maior (talvez infinito) pela φ função *kernel*, na tentativa de ajudar a SVM a encontrar um hiperplano separador.

Na Figura 14(a) ilustramos um domínio onde as amostras não poderiam ser separadas por um classificador linear. Por outro lado, na Figura 14(b), apresentamos as mesmas amostras mapeadas em um domínio diferente, que possibilitou a


separação das duas classes por um hiperplano. As funções *kernel* mais usadas estão apresentadas na Tabela 3.

Tabela 3 - Funções Kernel.

Funções Kernel	Equações
Linear	$K(x_i, x_j) = x_i^T x_j$
Polinomial	$K(x_i, x_j) = (\gamma x_i^T x_j + r)^d, \gamma > 0$
<i>Radial Basis Function</i> (RBF)	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2), \gamma > 0$

Fonte: adaptado de HSU et al (2003).

Figura 14 - Ilustração da aplicação de uma função *kernel*. (a) espaço de características antigo; (b) novo espaço de características.



Fonte: Adaptado de Muller et al. (2001).

3 DETECÇÃO E CLASSIFICAÇÃO DE RUGAS

Esse capítulo apresenta um resumo dos principais trabalhos, disponíveis na literatura, que envolvem detecção e classificação de rugas. Em virtude da detecção de rugas não ser o tema principal dos referidos trabalhos, mas sim um tema secundário, apresentamos alguns trabalhos que localizam as rugas em imagens como uma solução, dentre um conjunto de soluções, para resolver um determinado problema de uma aplicação.

Para manter o capítulo organizado ele foi dividido em duas seções. A primeira seção apresenta um breve resumo dos principais trabalhos que envolvem detecção e classificação de rugas para estimar a idade de pessoas, a idade da pele, o sexo e rugas em tecidos de roupa. As rugas em tecidos de roupas podem se assemelhar em formato e aparência às rugas da pele. Boa parte das rugas nos tecidos são originadas de maneira similar às rugas na pele, como as rugas criadas nas mangas das camisas pelo movimento do cotovelo. Esses trabalhos não são diretamente relacionados com o tema de detecção de rugas na pele para mensurar seu grau de enrugamento (tema central de nosso estudo), no entanto, estudá-los nos proporcionou uma visão ampla das técnicas mais utilizadas de detecção de rugas disponíveis.

Na segunda seção, daremos atenção especial aos cinco trabalhos que tratam apenas de detecção e classificação de rugas na pele. Três dos trabalhos tratados nessa seção utilizam meios próprios para coleta de imagens, visando aumentar as taxas de reprodutibilidade e repetibilidade dos seus resultados. Os últimos dois trabalhos tentam desvincular o processo de localização das rugas do de coleta padronizada de imagens, trazendo assim uma nova perspectiva de análise mais próxima de um especialista humano.

3.1 DETECÇÃO E CLASSIFICAÇÃO DE RUGAS NO CONTEXTO GERAL EM IMAGENS

Conforme apresentado no texto introdutório do capítulo, nessa seção serão apresentados os principais trabalhos de detecção e classificação de rugas com os mais variados propósitos. Começaremos pelos trabalhos que envolvem detecção de rugas para extrair características para estimar a idade das pessoas e da pele, seguido dos trabalhos de detecção de rugas em tecidos.

3.1.1 Sistemas de detecção de rugas para predição da idade por imagem

A tarefa de estimar a idade de pessoas por imagem tem um campo extenso de usabilidade em muitas aplicações do mundo real. Dentre elas podem-se destacar as aplicações de interação humano-computador (no intuito de adequar a comunicação ao tipo de usuário), de segurança na Internet (para bloquear o acesso a *sites* proibido para menores), de máquinas de vendas (não permitir a venda de alguns produtos para menores), etc. (UBAID; DAS; IMTHIYAS, 2013).

Um dos primeiros trabalhos nessa área é o de Kwon e Lobo (1999), que trata da estimação da idade de pessoas através de fotografias faciais. Os autores classificam as pessoas em três grupos de idade: bebês, adultos jovens e adultos idosos. Eles utilizam informações geométricas da face (como distância entre os olhos, distância entre a ponta do nariz e olhos, e distância entre os olhos e boca) e características do enrugamento da pele para estimar a qual grupo etário o avaliado pertence. Para localizar as rugas na face das pessoas, os autores utilizaram uma técnica chamada *snakelets*. Essa técnica espalha segmentos de curvas (chamados de *snakes* ou cobras) aleatoriamente sobre uma determinada região. Os segmentos são deformados de maneira que se ajustem aos contornos das rugas. Ele utiliza a derivada direcional para poder calcular o erro de posicionamento do *snake* para com a ruga, e assim corrigir seu posicionamento.

Kwon e Lobo (1999) utilizam as características geométricas da face para fazer separação entre os grupos etários: bebês e adultos. Posteriormente, utiliza as informações sobre as rugas para separar os grupos etários: adultos jovens de adultos idosos. Os autores testaram seus métodos em um conjunto de 15 imagens, 5 de cada grupo, e obtiveram 100% de acerto na classificação.

Apoiado no trabalho de Kwon e Lobo (1999), os autores Horng, Lee e Chen (2001) utilizaram características geométricas de toda a face e características das rugas de três regiões da face (testa, canto dos olhos e ao redor da boca) para estimar a idade das pessoas em 4 grupos etários: bebês, adultos jovens, adultos médios e adultos idosos. Os autores utilizaram filtro *Sobel* para localizar as rugas e posteriormente um *threshold* para separar a região enrugada das outras na imagem. São extraídas as seguintes características das rugas detectadas: densidade de enrugamento, profundidade das rugas (baseado na magnitude do gradiente das regiões consideradas como rugas) e a variância média do enrugamento.

Os autores utilizam dois classificadores neurais para classificar 230 imagens de pessoas com dimensão 480×380 *pixels*. O primeiro classificador tem a função de separar as pessoas que pertencem ao grupo etário bebê das pessoas que pertencem ao grupo etário adulto, e, segundo os autores, teve um desempenho de acerto de 100%. O segundo classificador tem a função de separar os outros três grupos de indivíduos, e obteve uma taxa de desempenho de 85,52%.

O trabalho de Takimoto et al. (2008) coleta informações de fotografias da face de pessoas em diferentes ângulos para estimar a idade dos indivíduos e estimar seu sexo. Os autores utilizaram o filtro *Sobel* para detectar as rugas profundas da pele, e o filtro *Gabor* para encontrar rugas finas e irregulares, bem como microestruturas de relevo da pele. Eles consideraram como rugas profundas as rugas presentes na região da testa, canto dos olhos (periorbitais), ao redor da boca e queixo. As características extraídas das rugas foram: média e variância da intensidade das bordas de cada região. Usando o filtro *Gabor* com várias resoluções e orientações, os autores extraem a periodicidade e direção da textura da pele das regiões em análise. Além das características citadas acima, são adicionadas informações de coloração da pele ao conjunto de características extraídas das imagens, pois os autores acreditam que existe escurecimento da pele com o envelhecimento.

Os autores utilizaram a técnica Análise de Componentes Principais Simples (em inglês, *simple principal component analysis – SPCA*), que é uma variante de processamento mais acelerado da técnica PCA (*principal component analysis*), para reduzir o espaço vetorial do conjunto de características coletado. Nesse sistema foram utilizados dois classificadores neurais com três camadas cada. O primeiro classificador RNA tem apenas um neurônio de saída. O resultado dessa saída é combinado com uma equação (fornecida pelos autores) para estimar a idade das pessoas. Esse método foi testado usando 15 fotografias frontais de pessoas e o erro médio encontrado na estimativa da idade foi de apenas 5 anos.

O segundo classificador possui dois neurônios na camada de saída e foi utilizado para estimar o sexo dos voluntários nas imagens. Nos testes do segundo classificador usaram-se as imagens do *dataset* HOIP, que somam 113 imagens de homens e 139 imagens de mulheres. Segundo os autores, a maior precisão do método proposto foi constatada nas faces viradas horizontalmente em 45° , em que se obteve 96.4% de acerto.

No trabalho de Ubaid, Das e Imthiyas (2013), os autores fazem uma análise das variações texturais de pontos da face de pessoas para associá-las à idade. Nesse trabalho foi utilizada a transformada Hough para localizar, de forma automática, a íris dos olhos dos indivíduos na imagem. Em seguida foi feito um redimensionamento da imagem para um tamanho uniforme, baseando-se na distância entre os olhos. O próximo passo foi retirar as informações de contraste das bochechas dos indivíduos nas imagens. Com esses dados foi gerado um polinômio, usando a técnica de regressão polinomial, que prediz a idade das pessoas. Os autores utilizaram o *dataset* de imagens do FG-NET e obtiveram 90% de precisão nas estimativas da idade em 100% das imagens do *dataset*.

O próximo trabalho relatado nessa seção é o dos autores Izadpanahi e Toygar (2014), que desenvolveram um método de classificação etária usando parâmetros coletados das rugas da face dos voluntários em fotografias. O método proposto conta com o uso de três classificadores SVM montados em níveis hierárquicos, para classificar as pessoas em 7 grupos etários. O primeiro classificador recebe, como parâmetro de entrada, dados de características geométricas da face, para separar os indivíduos com mais de 20 anos dos que têm menos de 20 anos. Os outros dois

classificadores utilizam características de densidade de enrugamento, extraídas pelo detector de bordas *Canny* da região da testa, canto dos olhos e bochecha. O primeiro deles subdivide a classificação das pessoas com menos de 20 em três grupos etários (0-2, 3-7 e 8-19 anos), e o segundo subdivide as pessoas com mais de 20 em quatro grupos etários (20-29, 30-45, 46-60 e mais de 60 anos).

Para medir o desempenho do método proposto, os autores utilizaram um *dataset* com 1104 imagens de pessoas sem óculos e barba, disponíveis nos bancos de dados FGNET e IFDB. O sistema proposto apresentou taxa mínima de acerto de 88,46% para os grupos etários de meia idade; a taxa máxima de acerto foi de 97,95% para a faixa etária de 0-2 anos. A taxa de acerto geral do sistema foi de 92,62%.

O último trabalho dessa seção foi o de Choi et al. (2013), que propõe um sistema computacional para medir a idade da pele do paciente, extraindo informações de imagens microscópicas. As imagens utilizadas no desenvolvimento desse trabalho foram coletadas das regiões do pescoço, face e mãos. Essas imagens foram submetidas às técnicas de equalização do histograma (para aumentar o contraste) e normalização. Um mascaramento foi utilizado para selecionar a região de interesse (ROI), pois a fonte luminosa de um microscópio digital é concentrada em torno de sua área central. Por fim, a imagem binária é criada aplicando o método de Otsu (OTSU, 1979).

Os autores extraíram o comprimento, a largura e a profundidade das rugas (considerando que as rugas mais profundas têm cores escuras). Além dos parâmetros citados anteriormente, os autores propõem um algoritmo de detecção de malha poligonal, que percorre toda a imagem binária, montando um esqueleto poligonal de rugas, pois foi observado que a estrutura poligonal do esqueleto das rugas tem relação com a idade da pele.

Na validação do sistema proposto por Choi et al. (2013) utilizou-se um classificador SVM multiclases que classifica a idade da pele em 5 grupos: adolescentes, 20-29, 30-39, 40-49 e mais de 50. O *dataset* usado na validação do sistema consiste em 834 imagens da região do pescoço, face e mãos, de 238 indivíduos do sexo masculino e feminino com idades entre 10 e 50 anos. O desempenho máximo que o sistema atingiu foi de 90%.

3.1.2 Sistemas de detecção de rugas em tecidos

Recentemente, muitos métodos instrumentais têm sido desenvolvidos e introduzidos na indústria, com o propósito de avaliar de forma objetiva a aparência do enrugamento dos tecidos fabricados. Em alguns casos, esses métodos são utilizados para verificar erros de fabricação, quando ocorre uma sobreposição dos fios durante o processo de fabricação do tecido, provocando rugas indesejadas. Em outros casos, os métodos são usados para medir a qualidade do tecido, mensurando o quanto um determinado tecido se enruga quando é manuseado ou vestido.

O trabalho de Sun et al. (2011) apresenta um método de avaliação de rugas que usa coeficientes *Wavelets* modificados e classificadores SVM para caracterizar e classificar a aparência das rugas nos tecidos. Convencionalmente, o enrugamento dos tecidos é avaliado por verificação visual de amostras de tecido realizada por especialistas treinados de acordo com os padrões de enrugamento. Dentre esses padrões, um dos mais utilizados é o *American Association of Textile Chemists and Colorists* (AATCC), que classifica as rugas em 5 graus: do SA-1 (rugos severas) até o SA-5 (rugos suaves).

O sistema projetado pelos autores consiste em uma câmera digital infravermelha, quatro luminárias LED infravermelho, cada uma contendo 40 luzes LED, uma *copy-stand* (uma estrutura para segurar tudo), um computador e o *software* que controla a câmera, processa as imagens e as medidas de rugas do padrão estabelecido. Para intensificar o contraste das rugas na imagem, as luzes infravermelhas são colocadas em posições oblíquas estrategicamente, para criar uma iluminação direcional que aumenta o gradiente de intensidade em frente ao campo de imagem. As quatro luzes também são ativadas em sequência para destacar as rugas em diferentes ângulos.

As imagens de tecidos foram decompostas pela transformada *Wavelet*, e alguns parâmetros foram coletados, dentre eles os parâmetros de orientação, dureza, densidade e contraste. Nos testes de classificação, os autores usaram dois classificadores SVM com variações de núcleo, um com núcleo linear e outro com núcleo RFB (*radial-basis-function*). Os autores verificaram a eficácia do método

desenvolvido com 300 imagens de cinco tipos de tecidos selecionados que tiveram teor de fibras, estruturas de tecelagem, cores e ciclos de lavagem semelhantes. Durante os testes, percebeu-se que 75% das amostras poderiam ser corretamente reconhecidas.

O trabalho de Yu, Yao e Xu (2009) apresenta sistema de visão computacional estéreo que reconstrói uma superfície 3D de tecidos para detectar e classificar a severidade do enrugamento. O sistema é formado por duas câmeras digitais que capturam um par de imagens de uma superfície. Para cada amostra de tecido, o sistema pode gerar uma superfície 3D com uma resolução de profundidade de até 0,1 milímetro.

Os autores geram uma imagem 2D, fazendo uma correspondência entre os dados de profundidade da imagem 3D com a escala convencional de valores de *pixel* (0-255). O próximo passo é encontrar os cumes e vales (que são locais com valores de intensidade alto e baixo) na imagem 2D gerada. A nova imagem passa por um processo de remoção de ruídos com a aplicação da técnica Difusão Anisotrópica, que tem por característica suavizar a imagem sem perder detalhes geométricos. Em seguida aplica-se o filtro *Sobel*, que calcula o gradiente da imagem para, assim, encontrar as rugas do tecido; por fim, é gerado um mapa das rugas através da técnica de limiarização chamada histerese. A partir do mapa de rugas extrai-se a densidade do enrugamento, a profundidade e a nitidez.

Para validar o sistema proposto, os autores o testaram com 10 amostras de tecido de algodão que foram submetidas a diferentes níveis de carga e estiramento, o que provocou diferentes níveis de rugosidade nos tecidos. As amostras foram classificadas segundo o padrão AATCC. Os parâmetros coletados pelo sistema apresentam uma relação consistente com a classificação do enrugamento do padrão AATCC. Logo os autores concluíram que o método proposto de reconstrução 3D do tecido é mais rentável do que os métodos a *laser* disponíveis.

3.2 SISTEMAS DE DETECÇÃO E CLASSIFICAÇÃO DE RUGAS DA PELE POR IMAGEM

A detecção de rugas na pele em fotografias da face é uma tarefa complexa, porque as rugas não têm formato fixo: as imagens podem sofrer distorções por ruídos, sombras, diferentes intensidades de brilho, pelos, cicatrizes, verrugas e manchas ou pigmentação da pele. Todos estes elementos criam figuras que poderão ser facilmente confundidas com rugas.

Boa parte desses problemas pode ser resolvida no momento da fotografia, com um fotógrafo experiente e com bons equipamentos que assegurem a tomada da foto com a melhor qualidade e homogeneidade possível. Como parte da solução dessas dificuldades, alguns trabalhos que desenvolveram soluções computacionais para detecção de rugas da pele utilizaram procedimentos preparatórios, para que as fotografias fossem tiradas com um padrão de iluminação e distância entre câmera e paciente desejados. Nas próximas três seções são analisados cinco trabalhos que envolvem o tema de detecção e classificação de rugas da pele em fotografias.

Na seção 3.2.1 serão mencionados dois trabalhos de Cula et al. (2009, 2012) que tratam de detecção e classificação (com escala própria) de rugas na testa e periorbitais, com o uso de técnicas de coleta padronizada de fotografias, processamento de imagem e aplicação do filtro *Gabor* para localizar as regiões enrugadas.

A seção 3.2.2 apresenta o trabalho de Brand (2007), que trata de detecção e classificação de rugas periorbitais, usando como referência a escala Glogau (1996). O autor utilizou técnicas de coleta padronizada de fotografias, processamento de imagem e filtros de primeira ordem para segmentar as rugas.


A seção 3.2.3 apresenta dois trabalhos dos autores Batool e Chellappa (2012 e 2015), que tratam de detecção de rugas usando filtro *Gabor*, morfologia de imagens e restrições geométricas. Nesses dois trabalhos, os autores utilizam imagens de pessoas famosas coletadas da *internet*.

3.2.1 Sistemas de detecção e classificação de rugas (CULA et al., 2009, 2012)

Nos trabalhos de Cula et al. (2009, 2012) são apresentados sistemas de detecção e classificação (com uma escala própria) de rugas periorbitais e rugas de testa, respectivamente. Em sua metodologia de trabalho, o autor compara a pele enrugada com as cristas, e a pele sem rugas, com os vales de imagens de impressão digital.

Cula utiliza um sistema que mantém a câmera e a fonte luminosa agrupada paralelamente. Quando a pele é iluminada com luz linearmente polarizada, a interface ar/pele resulta em uma melhor reflexão especular, que preserva a polarização da luz incidente. Segundo Cula et al. (2012), essa técnica permite uma boa separação das características da superfície da pele, como as rugas, as bordas elevadas de lesões e a estrutura de poros. Na Figura 15, pode-se observar e comparar a aparência da pele fotografada com luz visível comum (Figura 15a e Figura 15b), e com luz polarizada paralelamente (Figura 15c, Figura 15d). Pela figura pode-se notar que nas fotografias com luz polarizada paralelamente a pigmentação e vermelhidão da pele são minimizadas, além de permitir ver com mais clareza os traços contínuos das rugas destacadas pela iluminação.

Figura 15 - Seções de pele fotografadas com luz natural (a e b) e as mesmas seções fotografadas com luz polarizada paralelamente (c e d).



Fonte: Cula et. al. (2012).

Após o processo de aquisição o autor descreve mais oito passos para chegar à imagem binária final, que estão descritos abaixo (CULA, et al., 2009):

1. Separação do canal vermelho do RGB – esse canal foi escolhido porque possui mais informações sobre a estrutura da superfície da pele que interessa, e menos informações de manchas e pigmentos.
2. Aumento do contraste – esse aumento é realizado via equalização do histograma (apresentada na seção 2.2.2).
3. Normalização – a imagem do passo anterior é normalizada para que tenha média e variância pré-definidas. A estrutura da imagem não sofre variação, porém os níveis dinâmicos de cinza são padronizados, o que facilitará os passos posteriores.
4. Definição da região de interesse – nesse passo utiliza-se uma máscara binária feita manualmente, que limita a região periorbital na imagem em análise. Ou seja, para os cálculos posteriores só serão considerados os *pixels* que possuem um outro *pixel* correspondente na máscara binária com valor “1” (branco), como ilustrado na Figura 16.
5. Estimação da orientação local – esse é um processo de extração de informações da orientação local das rugas das imagens. Calcula-se a imagem de orientação com base na estimação dos mínimos quadrados (método que pode ser encontrado em Hong, Wan e Jain (1998)). Ao final desse passo é gerada uma imagem chamada de imagem de confiança, que apresenta valores de estimativa altos para os *pixels* que estão em área de orientação contínua (regiões de linhas ou rugas) e valores de estimativa baixos para áreas sem características de orientação contínua.
6. Estimação da frequência – nesse passo encontra-se a frequência das estruturas das rugas, procedimento usado em técnicas de melhoramento de imagens de impressão digital. Segundo Hong, Wan e Jain (1998), em uma vizinhança local, onde não aparecem minúcias e pontos singulares, os níveis de cinza ao longo de cumes e vales podem ser modelados como uma onda em forma sinusoidal ao longo da direção normal da orientação local do cume, como mostra a Figura 17. Na figura pode-se ver um exemplo

de uma imagem de impressão digital, que foi subdividida em pequenos blocos para encontrar a frequência local. Cada bloco possui um *pixel* central com as coordenadas (x, y) e a partir dele encontra-se uma janela de orientação (de tamanho $w \times l$) que se encontra rotacionada na direção da orientação local do cume.


7. Melhoramento da imagem com o filtro *Gabor* – nesse passo é feita uma filtragem com o filtro *Gabor* e depois essa imagem é multiplicada pela imagem de confiança e pela máscara binária do passo 4.
8. Detecção das rugas – nesse passo é aplicado um *thresholding* global para gerar a imagem binária final.

Figura 16 - Máscara seletora do trabalho de Cula et al. (2009, 2012)



Fonte: Cula et al. (2009, 2012)

Figura 17 - Ilustração do cálculo da frequência das rugas.



Fonte: Adaptada de Hong, Wan e Jain (1998).

Depois que as rugas são localizadas, mede-se o grau de enrugamento pela densidade de rugas dentro da imagem, calculando-se a proporção de *pixels* que foram titulados como *pixels* de rugas pela quantidade total de *pixels* da imagem.

No trabalho de 2009 os autores detectam e classificam rugas periorbitais (utilizando uma escala de 8 níveis de enrugamento). Os resultados clínicos obtidos com a classificação pelos especialistas foram comparados com os resultados obtidos pelo sistema de detecção de rugas desenvolvido, e apresentaram 81% de correlação; entretanto, não mencionam o tamanho do *dataset* utilizado na validação do sistema.

No trabalho realizado em 2012, os autores criam um *dataset* com 100 imagens de rugas na testa, que foram classificadas com uma escala própria em 11 níveis de enrugamento. Os índices de rugas computados pelo sistema proposto e os escores clínicos classificados por especialista tiveram uma correlação de 91%.


3.2.2 Sistema de detecção e classificação de rugas (BRAND, 2007)

O trabalho de Brand (2007) propõe um sistema de detecção e avaliação de rugas cutâneas da região periorbital com imagens. O autor descreve em seu trabalho toda a metodologia operacional, que vai da aquisição da imagem até o resultado final de detecção e classificação. O trabalho é dividido em 6 passos, a saber: Aquisição, Calibração, Recorte, Segmentação, Mensuração e Análise dos resultados.

A etapa de Aquisição das imagens tem o propósito coletar imagens e assegurar sua padronização. Descreve-se a utilização de um ambiente fechado, com iluminação controlada e plano de fundo completamente preto. Para uniformizar a distância entre rosto do paciente e câmera, o autor utiliza uma estrutura metálica que mantém essa distância fixa em 50 centímetros com um ângulo de 45° entre o eixo frontal da face e a câmera.

Na Figura 18 podem-se observar exemplos de imagem coletadas no trabalho de Brand (2007). O autor também utiliza etiquetas circulares sempre com a mesma tonalidade e tamanho, como objeto de referência de cor para calibração.

Figura 18 - Exemplo de fotografias no momento da aquisição.



Fonte: Brand (2007)

A etapa de Calibração é feita para garantir que as pequenas diferenças de iluminação não afetem o resultado do método proposto. Para isso, é realizado um processo de calibração linear com base no tamanho e na cor do objeto de referência. A fotografia é convertida para o formato HSI (*hue, saturation and intensity* – matiz, saturação e intensidade) e a intensidade da iluminação é padronizada com base na referência.

Na etapa de Recorte, extrai-se a região periorbital. Isso é feito selecionando uma janela de 150x81 *pixels* de forma manual, porém, em alguns casos, o autor relata que não foi possível o recorte do tamanho padrão pelo fato de haver a presença de pelos, manchas, maquiagens e outros elementos contaminantes.

A etapa de Segmentação tem a função de separar as regiões com rugas das regiões sem rugas. Para isso o autor experimentou quatro métodos automáticos de segmentação, que são:

- Método baseado em *Poster Edges* – método desenvolvido pelo Núcleo de Pesquisas em Imunodermatologia da UFPR, baseado em ferramentas existentes no *software* comercial Adobe Photoshop;
- Método baseado no operador *Canny* – método que utiliza o operador *Canny* como localizador das rugas. Em seguida as rugas são separadas usando os seguintes limiares: $T_1=0,1$ e $T_2=0,9$. Segundo Brand, esses limiares

foram resultados de observações empíricas;

- Método baseado em Morfologia Matemática – método implementado de duas formas. A primeira consiste na localização de borda pela erosão da imagem subtraída da imagem original. A segunda foi feita localizando a borda pela erosão subtraída da dilatação. A imagem resultante final foi segmentada usando o método de Otsu (OTSU, 1979);
- Método baseado no Gradiente – utiliza a reconstrução morfológica para atenuar os ruídos das imagens e em seguida aplica o operador *Sobel* na imagem resultante.

Na etapa de Mensuração foi realizada uma contagem dos *pixels* considerados como *pixels* de rugas, nos resultados encontrados pelos métodos de Segmentação. Por fim, a análise dos resultados foi baseada no valor de contagem da etapa de mensuração. Segundo Brand, a análise dos resultados avalia os métodos de segmentação nos seguintes requisitos:

- Efetividade dos resultados – mede a eficiência do método em distinguir corretamente as regiões com rugas das sem rugas;
- Correspondência com o conhecimento médico – mede a proximidade dos resultados encontrados com os resultados esperados (resultados classificados por especialistas segundo a escala de 4 pontos de Glogau);
- Repetibilidade e Reprodutibilidade – mede o quanto o método tende a variar, considerando recortes por um mesmo observador e por observadores diferentes, em fotografias semelhantes;

Para medir os resultados, utilizou-se o coeficiente de variação, que é uma grandeza definida pela divisão do desvio padrão pela média. O coeficiente de variação pode ser interpretado como a variabilidade dos dados em relação à média, e pode-se concluir que quanto menor é o coeficiente de variação, mais homogêneo é o conjunto de dados. O autor teve disponível para a validação do sistema um *dataset* com 762 fotografias de 109 voluntários diferentes. Entretanto, para cada teste realizado, ele utilizou um conjunto menor de fotografias.

O autor considerou como excelentes os resultados do coeficiente de variação menor que 10%, adequados os resultados entre 11% e 20%, aceitáveis os resultados entre 21% e 30%, e inaceitáveis os resultados maiores que 30%. O trabalho apresentou quatro categorias de testes, que estão apresentadas abaixo:

- Correlação dos métodos com a idade – observou-se que apenas com o método *Canny* (com $\sigma=5$) e Gradiente (com uma e duas filtragens de ruídos) houve o aumento das rugas com a idade;
- Correlação dos métodos com Glogau – esse teste teve o objetivo de verificar se os métodos automáticos conseguiriam resultado semelhante à classificação de Glogau, efetuada por especialistas. Apenas o método *Canny* (com $\sigma=3$ e $\sigma=5$) conseguiu apresentar esse resultado;
- Correlação entre os métodos – o coeficiente de correlação de Pearson foi calculado para todos os métodos e, em geral, houve baixa correlação entre os métodos. Segundo o autor, uma explicação para a baixa correlação é que cada método mede uma característica diferente da imagem;
- Reprodutibilidade e repetibilidade dos métodos – nesse teste, com o método *Canny* (com σ variando de 1 até 5), predominou a classificação aceitável. Com o método baseado em *poster edges* predominou a classificação excelente. No método baseado no operador gradiente (somente naqueles em que houve filtragem), obteve-se classificação excelente. Já o método de morfologia matemática apresentou alguns resultados inaceitáveis.

Por fim, dentre os quatro métodos analisados pelo autor, apenas os métodos *Canny* (com $\sigma = 5$) e os métodos baseados no Gradiente, principalmente aqueles nos quais houve filtragem de ruído, obtiveram resultado esperado na maior parte dos testes.

3.2.3 Sistemas de detecção de rugas em imagens coletadas da internet (BATOOL; CHELLAPPA, 2012 e 2015).

Visando reduzir custos e desvincular a capacidade de detecção das rugas em imagens pelos algoritmos do processo de coleta padronizada, alguns trabalhos mais recentes estão sendo publicados usando imagens comuns coletadas da *internet* (BATOOL; CHALLAPPA, 2012 e 2015). O trabalho de 2015 é continuação do trabalho de 2012, com pequenas diferenças.

No trabalho de Batool e Chellappa (2015) é apresentado um algoritmo determinístico de detecção de rugas na testa, usando filtro *Gabor* e morfologia de imagem, para incorporar restrições geométricas que ajudam a localizar os contornos curvilíneos das rugas.

O autor propôs um método baseado no Processo de Ponto Marcado (em inglês MPP – *Marked Point Process*) para localizar as rugas como segmentos de linha ou curvas. Uma rede Bayesiana foi utilizada para modelar o conhecimento das características espaciais das rugas e serviu de base para a classificação. A rede penaliza situações nas quais existe uma sobreposição ou uma aglomeração de segmentos de linha, porque as rugas na testa não se aglomeram ou se cruzam, pelo fato de se organizarem horizontalmente por consequência do movimento dos músculos da testa.

O trabalho se baseia nas seguintes suposições geométricas e características das imagens de ruga:

1. Rugas causam variações de gradiente que são destacadas pelo filtro *Gabor*;
2. Rugas aparecem com características curvilíneas ao contrário de borrões;
3. Rugas são contínuas e não uma série de segmentos descontínuos;
4. Rugas têm baixa probabilidade de se cruzar entre si e congestionar em pequenas áreas.

O algoritmo apresentado no trabalho de Batool e Chellappa (2015) tem basicamente dois passos. O primeiro é baseado nas regras 1 e 2 (mencionadas

acima) e detecta lugares com alto valor de gradiente (chamado de lugares-chave). Esse procedimento é feito com a aplicação de um *threshold* (limiar) gradual. Ainda nessa etapa as regiões com formato de gotas ou borrão são descartadas.

O segundo passo é baseado nas regras 3 e 4. Depois de encontrar as zonas de interesse, o algoritmo traça segmentos curvilíneos nessas zonas. O algoritmo permite unir segmentos que têm alta probabilidade de pertencer à mesma ruga (por terem a mesma orientação e estarem próximos) e penaliza congestionamento e intercessão de segmentos.


Para unir os segmentos, o algoritmo faz uma pesquisa ao redor dos dois pontos terminais do segmento (a área de pesquisa é baseada na orientação do segmento) e, caso exista um outro ponto terminal de outro segmento dentro dessa área de pesquisa, os dois segmentos são unidos.

As Figura 19a e Figura 19b mostram dois exemplos de pesquisa para interligação de componentes. Na Figura 19a, pode-se observar que o algoritmo fez uma pesquisa ao redor dos pontos terminais do componente 'A' (varrendo uma área no formato de um semicírculo de raio r_N) e o algoritmo encontrou o ponto terminal do componente 'B', o que possibilitou a interligação dos componentes pelo segmento 'D'. Na Figura 19b, a mesma pesquisa foi feita varrendo a mesma área, porém não houve ligação entre os componentes, pelo fato de o componente 'C' não ter pontos dentro da área de pesquisa de 'A'.

A Figura 19c ilustra um exemplo de sobreposição em que o componente 'C' invade a área de dilatação do componente 'A' (área que é usada para garantir a distância mínima entre os componentes). Isso implica uma penalização do componente 'C'.

No trabalho de Batool e Chellappa (2012), os gradientes de intensidade gerados nas imagens devido às rugas são melhorados com filtros e são usados para detectar os locais e as direções mais prováveis dos segmentos de linha. Rugas são localizadas por amostragem do processo de ponto de Markov (em inglês *Markov point process*), usando o algoritmo Monte Carlo via cadeias de Markov com saltos reversíveis (em inglês *Reversible Jump Markov Chain Monte Carlo*).

Figura 19 - Ilustração das restrições geométricas da conectividade dos componentes; (a) Mostra a conexão do componente 'A' ao 'B' pelo segmento 'D'; (b) mostra a não conexão do 'A' ao 'C'; (c) exemplo de componente penalizado por sobreposição e congestionamento.



Fonte: Adaptada de Batool e Chellappa (2015)

Os autores compararam os resultados dos dois trabalhos, e a sua metodologia de comparação analisa os contornos curvilíneos das rugas encontrados pelos algoritmos, em relação aos contornos manualmente localizados por usuários.

Nos dois trabalhos, os autores montaram um *dataset* a partir de fotos coletadas da *Internet* de pessoas famosas mundialmente e de imagens coletadas no banco de imagens do FG-NET. Entretanto os autores não mencionam a quantidade de imagens utilizadas. A grande maioria das imagens é de homens, pelo fato de as imagens de mulheres tipicamente sofrerem alterações por *softwares* de edição, e também porque as mulheres se preocupam mais em esconder suas rugas com maquiagem ou posições mais favoráveis no momento da fotografia.

É importante informar que os autores aplicam seu algoritmo em imagens de rugas periorbitais, porém não obtiveram resultados satisfatórios, pelo fato de que esse tipo de ruga apresenta características geométricas diferentes das rugas na testa, que são mais lineares e com menos ramificações que as periorbitais.

4 DESENVOLVIMENTO DO SISTEMA

Esse capítulo apresenta toda a descrição da construção do método proposto de classificação de rugas em imagens. Por se tratar de uma abordagem nova, a montagem da arquitetura de todo o método foi um processo que evoluiu com o tempo, e o modelo final foi o resultado de diversos experimentos e combinações entre métodos.

A descrição completa do método desenvolvido é apresentada na seção 4.1; logo em seguida, na seção 4.2, descreve-se toda a metodologia utilizada para chegar a um sistema definitivo de detecção e classificação de rugas. Na seção 4.3 explica-se a coleta e a criação do *dataset* de imagens de rugas periorbitais, e a seção 4.4 apresenta os métodos de avaliação dos resultados.

4.1 MÉTODO PROPOSTO PARA CLASSIFICAÇÃO DE RUGAS PERIORBITAIS

De maneira semelhante à maioria dos projetos de sistemas de visão computacional, o nosso projeto foi construído seguindo as cinco etapas propostas por Filho e Neto (1999): Aquisição, Pré-Processamento, Segmentação, Extração de Características e Reconhecimento e Interpretação. A arquitetura do sistema é apresentada na Figura 20 com suas respectivas divisões.


O método foi implementado usando o *software Matlab* r2012a versão 7.14 no sistema operacional Windows 8. Ele recebe como entrada uma fotografia da lateral da face do paciente, com foco na região periorbital, e entrega como saída a classe de enrugamento que o paciente pertence e uma imagem destacando a localização das rugas.

A primeira etapa do método (Aquisição) trata da maneira como as imagens foram coletadas e repassadas para as próximas fases, respeitando o requisito inicial do projeto de trabalhar com imagens coletadas sem critérios de padronização. Essa

etapa tem a função de compensar a falta de padrão no processo de coleta das fotografias.

Para isso, a etapa de Aquisição é composta de duas partes. Na primeira é feito um redimensionamento da imagem, que foi a abordagem usada para compensar possíveis diferenças na distância entre a câmera e a face do paciente no momento da tomada da fotografia. A segunda recorta a região periorbital da imagem e a envia para as outras etapas do sistema. O resultado dessa etapa é visto na Figura 21a.

Figura 20 – Pipeline do método proposto por esse trabalho.




Fonte: Elaborado pelo autor.

Logo após a etapa de Aquisição vem a etapa de Pré-Processamento, que tem a função de aplicar técnicas de processamento de imagens digitais para melhorar e

destacar partes da imagem para facilitar as etapas posteriores. O primeiro procedimento executado na etapa de Pré-Processamento é a separação do canal azul da imagem em RGB (resultado exibido na Figura 21b). O segundo procedimento é a aplicação da Difusão Anisotrópica (técnica explicada na seção 2.2.3), com o objetivo de remover ruídos e imperfeições da imagem, suavizando as regiões homogêneas da imagem (regiões de pele lisa), sem comprometer o detalhamento das rugas (resultado exibido na Figura 21c).

Figura 21 - Resultados das etapas do método proposto. (a) imagem original; (b) separação do canal azul; (c) difusão anisotrópica; (d) transformada exponencial; (e) limiarização pela média; (f) aplicação do operador *Sobel* Horizontal; (g) normalização; (h) método de Otsu; (i) aplicação da máscara seletora; (j) seleção das rugas.



Fonte: Elaborado pelo autor.

O terceiro procedimento consiste na aplicação da Transformada Exponencial

(técnica explicada na seção 2.2.1) para aumentar o contraste da imagem de maneira que se destaquem as rugas e se facilite o processo de Segmentação (resultado apresentado na Figura 21d).

O último procedimento da etapa de Pré-Processamento é chamado de limiarização pela média, e consiste na substituição dos *pixels* com valores de intensidade acima da média da imagem pelo valor de intensidade médio. A maioria das imagens de rugas tem predominância de *pixels* mais claros que correspondem a *pixels* da pele lisa, mesmo nas imagens em que o paciente tem um grau de enrugamento severo, o que eleva o valor da média das intensidades. Por outro lado, temos as regiões com rugas, que são regiões de menor predominância na imagem e são formadas por *pixels* escuros, com valores de intensidade baixos. Diante disso, ao substituímos todos os *pixels* com valores acima da média da imagem, estaremos alterando os *pixels* da pele, sem interferir com os *pixels* das rugas. Esse procedimento se mostrou eficiente em equalizar o excesso de iluminação na pele e reduzir a interferência dos poros, pelos e pigmentos sobre a detecção das rugas (resultado pode ser visto na Figura 21e).

Ao final da etapa de Pré-Processamento, inicia-se a etapa de Segmentação, que visa a separar as rugas da pele lisa, subdividida em quatro passos. O primeiro procedimento da segmentação corresponde à aplicação do Operador *Sobel* Horizontal, que identifica e destaca os *pixels* que fazem parte da região de fronteira entre pele lisa e rugas (resultado exibido na Figura 21f). O segundo passo dessa etapa, como mostra a Figura 20, é o processo de Normalização, que tem a função de uniformizar os níveis de cinza da imagem e assim destacar as regiões de fronteira que foram encontradas com a aplicação do Operador *Sobel* (o resultado desse procedimento está na Figura 21g).

O terceiro passo da Segmentação é a binarização da imagem com o método de Otsu, que é um procedimento automático para fazer a separação entre as regiões com rugas das regiões de pele lisa, levando em consideração que as regiões enrugadas são as regiões de fronteira mencionadas anteriormente. O ponto de corte encontrado é o valor que proporciona a menor variância entre as duas classes (OTSU, 1979). Ao final do terceiro passo, o resultado é uma imagem binária em que os *pixels* com valor “1” são rugas e com “0” pele lisa. O resultado dessa técnica pode ser

acompanhado na Figura 21h.

No quarto e no quinto passo da Segmentação são aplicados procedimentos para reduzir os *pixels* considerados falsos positivos (*pixels* que indicam a presença de ruga na imagem original do paciente sem, no entanto, existirem realmente). O quarto passo calcula uma máscara seletora para filtrar e reduzir os *pixels* falsos positivos, buscando regiões da imagem binária onde existem agrupamentos de *pixels* brancos que possuem orientação contínua, que é uma característica das rugas periorbitais. O resultado da filtragem da imagem binária pode ser visto na Figura 21i.

O quinto e último passo da Segmentação é chamado de Seleção das Rugas. Esse procedimento varre toda a imagem binária resultante do passo anterior para localizar e rotular os agrupamentos de rugas da imagem. Após a identificação dos agrupamentos, são excluídos os que têm formatos arredondados e os que não estão distribuídos de forma contínua na horizontal. Ao fim de todos esses procedimentos citados anteriormente para melhorar os resultados da detecção, a etapa de Segmentação retorna a imagem binária, destacando as regiões com rugas da imagem original, ilustrada pela Figura 21j.

A quarta etapa da arquitetura é a Extração de Características, como mostra a Figura 20. Ela coleta informações da imagem binária e da imagem normalizada. As informações coletadas nessa etapa são: densidade, variância média, comprimento das rugas, e dois descritores de textura de Haralick (mencionados na seção 2.3) contaste e energia.

Esses cinco valores coletados são repassados para a etapa de Reconhecimento e Interpretação. Nessa etapa um classificador RNA (Rede Neural Artificial) é utilizado para informar a qual classe de enrugamento o paciente pertence, segundo a escala de rugas Fitzpatrick e Goldman com três níveis de enrugamento (apresentada na seção 2.1.1). O classificador utilizado recebe como parâmetro os cinco valores coletados da última etapa para classificar se a imagem pertence à classe de enrugamento suave, moderado ou severo.

4.2 METODOLOGIA

Ao longo do desenvolvimento do projeto, foi necessário testar diversas abordagens, sempre com o objetivo de aumentar o desempenho da classificação das rugas. Tendo em vista a premissa de que o sistema final deveria ser robusto o suficiente para trabalhar com imagens que fossem tomadas sem um critério rigoroso de padronização, essa seção apresenta os passos metodológicos, as decisões de projeto e as justificativas que levaram à escolha dos procedimentos mencionados na seção anterior.

4.2.1 Aquisição de Imagens

O processo de Aquisição tem a função de coletar as imagens. Em alguns trabalhos na literatura (como os citados no capítulo 3), o processo de aquisição padronizado é de extrema importância para o sucesso do método. A padronização facilita o trabalho do detector de rugas, pois homogeneiza as fotos e facilita a calibração dos parâmetros do sistema, levando a melhores resultados de detecção e classificação.

Como mencionado na seção 3.2.3, em alguns trabalhos mais recentes já aparece uma tendência de estudo de métodos que não sejam totalmente dependentes de um processo de aquisição padronizado. Seguindo a tendência de construir métodos baratos, ágeis e ao mesmo tempo eficiente, a etapa de Aquisição para o nosso método foi desafiadora, pelo fato de usarmos imagens de rugas periorbitais tomadas de forma irregular e sem critérios de padronização.

É comum os médicos fotografarem as rugas dos pacientes para acompanhar a evolução dos tratamentos, porém, a grande maioria não se preocupa com padrões fotográficos, como distância fixa entre a câmera e o rosto do paciente, a iluminação do ambiente controlada, ou o posicionamento do *flash*, pelo fato de que um especialista humano pode analisar imagens mesmo com essas pequenas diferenças. Quando se trabalha com imagens sem padronização, é comum haver imagens nos

mais diversos tamanhos. Por exemplo, o *dataset* usado no trabalho contém imagens com dimensão de 3456x2304, 1162x1744 e 1253x1880 *pixels*.

A diferença na distância entre o rosto do paciente e a câmera no momento da fotografia, em imagens de tamanhos diferentes, prejudica o isolamento e a retirada da região periorbital, pois isso implica o recorte de áreas de tamanhos diferentes. Por exemplo, a região periorbital do paciente na fotografia com dimensão de 3456x2304 será bem maior que a da fotografia com 1162x1744. Essa falta de uniformidade gera problemas, principalmente quando se precisa classificar o enrugamento do paciente a partir de critérios como densidade de enrugamento por região ou comprimento das rugas.

Com vistas a corrigir o problema da falta de padronização da distância entre o rosto do paciente e a câmera, a primeira tarefa do método foi ajustar as imagens para compensar as diferenças descritas acima, e em seguida recortar a região periorbital da nova imagem ajustada, para depois repassar as imagens para as próximas etapas.


4.2.1.1 *Redimensionamento da Imagem e Recorte da Região Periorbital*

O processo de redimensionamento da imagem apoia-se no aumento ou na diminuição da dimensão da imagem, tomando como referência a distância entre as pálpebras superior e inferior do olho do paciente. Denomina-se essa distância de altura da fenda palpebral vertical. Um processo semelhante é realizado no trabalho de Ubaid, Das e Imthiyas (2013), no qual é feito o redimensionamento da imagem para um tamanho uniforme, baseando-se na distância entre os olhos.

O procedimento para encontrar a altura da fenda requer que o usuário informe manualmente a localização das duas pálpebras do olho na imagem em análise (procedimento ilustrado na Figura 22). O valor da distância (em *pixels*) entre a pálpebra superior e inferior do paciente serve como métrica, quando comparada a um valor de referência, para decidir o quanto a imagem deve ser ampliada ou reduzida. Nessa etapa definimos como valor de referência padrão 170 *pixels* de distância entre as pálpebras do paciente na fotografia, valor baseado na média dos valores de altura

da fenda palpebral vertical das 433 imagens do *dataset* utilizadas para avaliar nosso método.

Figura 22 - Imagem ilustrando o ponto superior, inferior e o canto do olho (em vermelho).



Fonte: Adaptada de Tamura e Odo (2011).

O segundo passo é o recorte da região periorbital na imagem em análise. Por definição, esse procedimento recorta uma janela de tamanho fixo, com dimensão de 350x300 *pixels*, tomando como referência o ponto de canto do olho também marcado pelo usuário, como pode ser visto na Figura 22.

A Figura 23 ilustra (na parte superior) o procedimento de recorte da região periorbital sem aplicar os passos de redimensionamento da imagem, e na parte inferior ilustra o mesmo procedimento, porém aplicando o redimensionamento.


A Figura 23a apresenta a imagem original do paciente com uma dimensão de 2173x1418 *pixels* e um valor de 296 *pixels* de altura da fenda palpebral vertical. A fotografia da paciente utilizada na Figura 23 foi retirada do artigo de Cula et al. (2012) somente para fins ilustrativos do procedimento de redimensionamento da imagem e recorte da região periorbital. A Figura 23b apresenta em destaque, com um retângulo preto, a janela de recorte da região periorbital da Figura 23a, e a Figura 23c o resultado do recorte.

Em razão da altura da fenda palpebral vertical da Figura 23a ser maior que o valor padrão adotado de 170 *pixels*, essa imagem sofreu uma redução de dimensionamento, para se enquadrar nos padrões estabelecidos. A imagem gerada pela redução da Figura 23a está ilustrada na Figura 23d, que agora possui uma dimensão de 1209x814 *pixels* e altura da fenda palpebral de 170 *pixels*. Ao lado, na

Figura 23e, é apresentada em destaque, com um retângulo preto, a janela de recorte. Na última imagem (Figura 23f) é exibido o resultado final do recorte.

Observando e comparando as Figura 23c e Figura 23f, podem-se compreender os resultados do redimensionamento da imagem. A primeira impressão, ao observar as imagens finais, é que elas são fotografias diferentes do mesmo objeto, com distâncias entre câmera e objeto diferentes.

Figura 23 - (a) imagem original; (b) imagem com destaque da região que será recortada; (c) resultado do recorte da figura (b); (d) imagem resultante do processo de redimensionamento da imagem; (e) imagem com destaque para a região a ser recortada; (f) resultado final do recorte da região periorbital na imagem ajustada.



Fonte: Imagem da paciente retirada de Cula et al. (2012).

Realizando esse procedimento, pode-se aproximar e padronizar de forma indireta a distância entre câmera e face, mesmo que no momento da fotografia não se tenha observado esse critério, o que contribuiu diretamente para que os resultados da classificação das rugas se tornassem mais confiáveis.

4.2.2 Pré-Processamento das Imagens

A etapa de Pré-Processamento de Imagem consiste na aplicação de técnicas para aprimorar a qualidade (corrigindo imperfeições, presença de *pixels* ruidosos, contraste e/ou brilho inadequado) e destacar partes de interesse para as etapas posteriores. Diante desse conceito, nessa etapa aplicou-se uma sequência de técnicas para homogeneizar a iluminação e a qualidade das imagens, destacar as rugas e reduzir a presença dos ruídos.

Todas as quatro operações efetuadas nessa etapa (ilustrada na Figura 20) são referidas como de baixo nível, porque trabalham diretamente com os valores de intensidade dos *pixels*, sem nenhum conhecimento prévio sobre sua função na imagem.

4.2.2.1 Conversão da imagem

A imagem de entrada está no modelo RGB, que é formado por três canais, como a própria sigla denuncia: o canal *Red* (vermelho), *Green* (verde) e *Blue* (azul). Uma cor no modelo de cores RGB pode ser descrita pela indicação da quantidade de vermelho, verde e azul que contém cada *pixel* (FILHO; NETO, 1999, p.21).


Para converter imagens do modelo RGB em imagens em escala de cinza simples, podem-se separar os três canais do RGB e utilizá-los separadamente, ou então utilizar uma função que realiza uma soma ponderada das intensidades dos *pixels* de cada um dos canais.

Nas Figura 24b, 24c e 24d são apresentados os resultados da separação dos três canais do RGB, respectivamente, e na Figura 24e é exibido o resultado da soma ponderada, obedecendo a Equação 5.1 sugerida pela função `rgb2gray` do *Matlab*:

$$Img = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (5.1)$$

Diante das quatro possibilidades ilustradas na Figura 24, foi escolhida a imagem em tons de cinza correspondentes às intensidades dos *pixels* do canal azul (B), Figura 24d. A escolha desse canal proporcionou melhores resultados de classificação ao sistema proposto quando comparado com as outras opções. Substituindo o canal B pelo canal R, o desempenho sistema reduz entre 10.5% e 14.6%; pelo canal G, reduz entre 2.7% e 5.3%, e pela função de soma ponderada (`rgb2gray`) reduz entre 4.3% e 6.3% (esses resultados serão apresentados com mais detalhes na seção 5.4). Nossa hipótese para o melhor desempenho do canal B é de que esse canal traz maior contraste das rugas porque existem poucos componentes dessa tonalidade na pele humana.

Figura 24 – (a) imagem original contendo todos os 3 canais do RGB; (b) canal R; (c) canal G; (d) canal B; (e) resultado da soma ponderada pela função `rgb2gray` do *Matlab*.



Fonte: Elaborado pelo autor.

Para comprovar essa hipótese, desenvolvemos uma função que contabiliza a quantidade de níveis de cinza diferentes que existem no histograma de cada canal das imagens analisadas. Diante desses resultados, observamos que as imagens do canal B de nosso *dataset* (433 imagens) apresentavam mais níveis de cinza diferentes do que as dos outros canais, aproximadamente 78%, como pode ser visto na Tabela 4. Portanto, como o contraste é diretamente proporcional ao espalhamento dos níveis de cinza (GONZALEZ; WOODS, 2008, p. 142), o canal B é o que apresenta o maior contraste.

Por falta de informações precisas sobre as câmeras que foram usadas no momento da coleta das fotografias, não se pôde fazer um estudo mais categórico para comprovar se existe alguma associação entre a marca e o modelo da máquina fotográfica com a escolha do melhor canal do RGB para o sistema.

Tabela 4 - Taxas de porcentagem das imagens com maior espalhamento dos níveis de cinza para cada técnica de conversão.

Técnicas de Conversão	Porcentagem de imagens com maior espalhamento dos níveis de cinza
Canal R	5.3%
Canal G	16.9%
Canal B	77.8%
Função <code>rgb2gray</code>	0%

Fonte: Elaborado pelo autor.


4.2.2.2 *Melhoramento do Contraste*

As técnicas de melhoramento do contraste buscam aprimorar o contraste entre os elementos apresentados na imagem. Em nosso caso, o objetivo foi destacar as rugas e diferenciá-las cada vez mais das regiões da pele lisa. Nessa etapa foram aplicadas duas técnicas de melhoramento do contraste: Equalização do Histograma e Transformada Exponencial (explicadas nas seções 2.2.2 e 2.2.1, respectivamente).

A Equalização do Histograma é um método automático que redistribui os valores de tons de cinza dos *pixels* em uma imagem, de maneira que se obtenha um

histograma uniforme, no qual o percentual de *pixels* de qualquer nível de cinza seja praticamente o mesmo (FILHO; NETO, 1999, p. 61). A Transformada Exponencial mapeia uma faixa de baixos valores de intensidade luminosa para faixas maiores, tornando visíveis partes da imagem que se encontram muito claras. Os resultados da aplicação das duas técnicas podem ser vistos nas Figura 25b (Transformada Exponencial) e Figura 25c (Equalização do Histograma).

Figura 25 - (a) antes; (b) resultado da aplicação da Transformada Exponencial; (c) resultado da Equalização do Histograma.



Fonte: Elaborado pelo autor.


Foram feitos os mesmos testes da seção anterior, tendo como entrada os resultados obtidos com a Equalização do Histograma e a Transformada Exponencial. Esse teste foi aplicado em todas as imagens do nosso *dataset* (433 imagens) e comprovou que em todas, a Equalização do Histograma retornou imagens com mais contraste do que a Transformada Exponencial. Porém, foi escolhida a Transformada Exponencial pelo fato dela realçar as porções mais claras da imagem onde se encontram ruídos (pigmentos, poros, etc.) que podem ser facilmente confundidos com rugas. Essa conclusão foi confirmada com os testes de desempenho comparando o uso das duas técnicas. Substituindo a Transformada Exponencial pela Equalização do Histograma, o desempenho do sistema reduz entre 10.0% e 11.3% (esses resultados serão apresentados com mais detalhes na seção 5.4).

Pode-se observar que a Equalização do Histograma diferencia bem os intervalos de intensidades dos *pixels* entre as regiões com rugas em relação às sem

rugas. Porém, observou-se em algumas imagens que essa diferenciação também aconteceu entre os *pixels* das regiões sem rugas, que antes do processo tinham valores próximos e depois acabaram tendo valores distantes entre si.

Em nosso entendimento, isso aconteceu pelo fato da Equalização do Histograma levar em conta a frequência dos níveis de cinza, e por consequência o espalhamento será maior para os níveis de cinza mais frequentes, ou seja, regiões de pele lisa. Essa hipótese pode ser observada na Figura 26, na qual foram selecionados dois *pixels* nas imagens analisadas (de regiões lisas da pele) com as coordenadas (352, 288) e (81, 474). Na imagem gerada pela Transformada Exponencial (Figura 26a), o intervalo entre os dois pontos coletados é de 0,244, e na imagem gerada pela Equalização do Histograma (Figura 26b), o intervalo é de 0,8357.

Figura 26 - Imagem mostrando a coleta de pontos em regiões lisas da pele.



Fonte: Elaborado pelo autor.

4.2.3 Segmentação

A Segmentação se refere ao processo de dividir uma imagem digital em múltiplas regiões ou objetos, com o propósito de simplificar e/ou mudar a representação de uma imagem para facilitar a sua análise. A segmentação é tipicamente usada para localizar objetos, formas, linhas, curvas e bordas (*edge*). Usam-se as técnicas de segmentação para localizar rugas, pois seu formato e sua distribuição de *pixels* dentro da imagem as faz assemelhar-se a uma borda.

Define-se borda como a fronteira entre duas regiões cujos níveis de cinza predominantes são razoavelmente diferentes, ou seja, uma borda pode ser vista como um segmento de aresta em que a intensidade do fundo de cada lado do segmento tem menos intensidade ou mais intensidade do que a intensidade dos *pixels* do segmento (GONZALEZ; WOODS, 2008, p. 714). A definição das bordas é influenciada pelo contraste da imagem. Por essa razão, nas etapas anteriores à segmentação, sempre se buscou aumentar o intervalo entre os *pixels* de pele com rugas em relação aos *pixels* de pele sem rugas.

No Capítulo 3 foi feito um resumo dos principais trabalhos que utilizam informações de rugas detectadas em imagens de pele e de tecidos para resolver problemas de sistemas computacionais nas mais variadas áreas. Dentre esses trabalhos, podemos destacar quatro técnicas de detecção de rugas: *Snakelets*; Filtro *Gabor*; Filtro *Sobel*; e o algoritmo de detecção de bordas *Canny*.

A técnica conhecida como *Snakelets* foi usada no trabalho de Kwon e Lobo (1999). Essa técnica espalha segmentos de *snakes* (cobras) aleatoriamente sobre a região da pele com rugas, e os segmentos são deformados de maneira que se ajustem aos contornos das rugas, utilizando derivada direcional para poder corrigir seu posicionamento. No entanto, apesar dela ser umas das primeiras técnicas a serem utilizadas para detecção de rugas, os trabalhos desenvolvidos em seguida, que inclusive utilizaram o trabalho de Kwon e Lobo (1999) como base, não deram seguimento à detecção de rugas com *Snakelets*.

O algoritmo de detecção de bordas *Canny* foi utilizado no trabalho de Brand (2007) e Izadpanahi e Toygar (2014). O detector *Canny* suaviza o ruído e localiza as

bordas, combinando um operador diferencial com um filtro Gaussiano (GONZALEZ; WOODS, 2008, p. 745). Apesar de ser um detector de bordas muito famoso na literatura, para o ramo de detecção de rugas não foi bem aceito. Os dois trabalhos que o utilizaram não retornaram bons resultados.

Os filtros *Gabor* e *Sobel* são as técnicas mais utilizadas para detecção de rugas. Dentre os trabalhos analisados, o filtro *Gabor* foi utilizado nos estudos de Takimoto et al. (2008) e Cula et al. (2009, 2012). Ele tem a característica de destacar as bordas na imagem de acordo com os parâmetros de resolução e orientação que lhes são passados. Por esse motivo, nos trabalhos citados os autores precisaram utilizar diferentes parâmetros de orientação de acordo com as características das rugas. Por exemplo, quando se utiliza o filtro *Gabor* para localizar as rugas na testa, é necessário passar parâmetros de orientação horizontal; entretanto, quando se está tentando localizar rugas ao redor dos olhos, é necessário passar como parâmetro diversas orientações, pelo fato desse tipo de ruga não ter um padrão de direcionamento.

Por outro lado, o Filtro *Sobel*, que é um filtro a gradiente de primeira ordem, é subdividido em duas orientações (horizontal e vertical). Para rugas periorbitais, esse filtro se apresenta como uma boa opção porque, apesar desse tipo de ruga não ter uma orientação bem definida, a sua grande maioria é na horizontal ou levemente inclinada. Dentre os trabalhos analisados, esse filtro foi utilizado nos estudos de Horng, Lee e Chen (2001), Brand et al. (2007), Takimoto et al. (2008) e Yu, Yao e Xu (2009).

Takimoto et al. (2008) utilizam em seu trabalho os filtros *Gabor* e *Sobel*. Os autores perceberam que o filtro *Gabor* apresenta uma melhor *performance* quando utilizado na detecção de microrugas, enquanto o filtro *Sobel* apresenta uma melhor *performance* quando utilizado na detecção de rugas profundas, como as rugas da testa, canto dos olhos e ao redor da boca.

Com base nos motivos citados, nessa etapa do trabalho decidimos utilizar o filtro a gradiente *Sobel* para detectar as rugas. Para incrementar o estudo, também fizemos testes com outros filtros (*Roberts* e *Prewitt*) com o propósito de verificar se seu uso melhora o desempenho do sistema.

A etapa de Segmentação foi dividida em cinco partes, como exibido na Figura 20 e apresentado na seção 4.1. Nas próximas seções serão descritos

metodologicamente os processos envolvidos na parametrização da Segmentação, com exceção da Binarização com o Método de Otsu (OTSU, 1979), que é um procedimento automático sem escolhas de parâmetros associados a seu uso.

4.2.3.1 Operadores a Gradiente

Essa etapa tem a função destacar as rugas nas imagens com o uso de filtros, que identificam variações de intensidade entre *pixels* próximos. O uso desses operadores implica na geração de gradientes em duas direções ortogonais, um na direção vertical e outro na horizontal. Em geral, para realizar essa tarefa, basta convoluir as matrizes dos operadores gradiente (apresentados na Tabela 5) com a imagem de entrada. Segundo Filho e Neto (1999, p. 36), no processo de convolução é realizado um espelhamento tanto na horizontal quanto na vertical da máscara, para depois percorrer todos os pontos da imagem deslocando-se ao longo de cada linha e entre as várias linhas, da direita para a esquerda, de cima para baixo, até ter processado o último elemento da matriz imagem.

Tabela 5 - Operadores 3x3 *Sobel*, *Roberts* e *Prewitt*.

OPERADOR	Vertical	Horizontal
<i>Roberts</i>	$\begin{bmatrix} 0 & 0 & -1 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$	$\begin{bmatrix} -1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix}$
<i>Sobel</i>	$\frac{1}{4} \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & -1 \end{bmatrix}$	$\frac{1}{4} \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$
<i>Prewitt</i>	$\frac{1}{3} \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix}$	$\frac{1}{3} \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$

Fonte: Elaborado pelo autor.

Testamos três operadores gradiente com duas direções ortogonais cada, e o que proporcionou os melhores resultados de desempenho na classificação foi o operador *Sobel* Horizontal. Utilizamos apenas os resultados de desempenho da classificação do método proposto como critério objetivo de escolha entre os

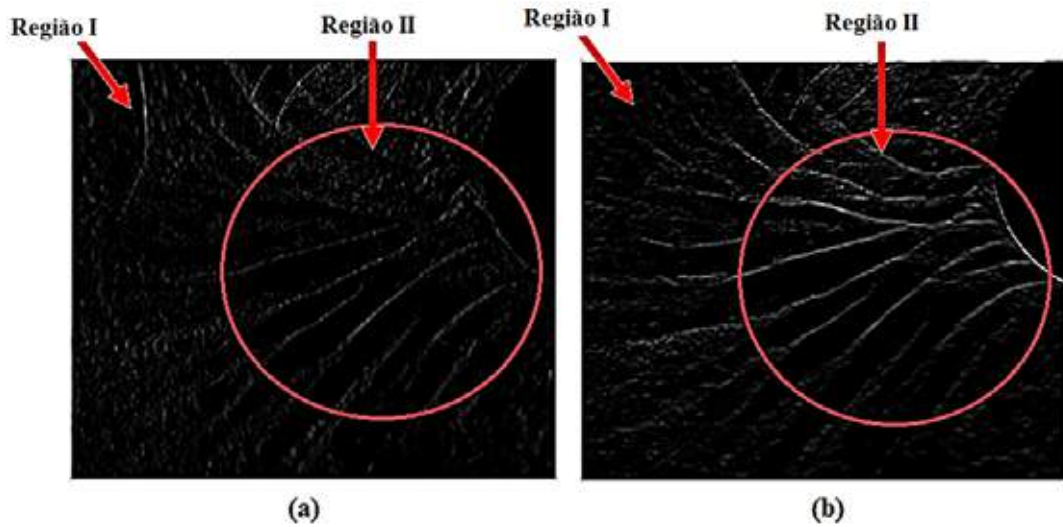
operadores, pelo fato de que um teste mais preciso necessitaria de uma segunda ferramenta já validada e com ampla aceitação pela literatura (que ainda não existe) para localizar as rugas e, com base em seus resultados, comparar com nossos resultados.

O operador *Sobel*/ Horizontal apresentou os melhores resultados devido ao fato de a grande maioria das rugas periorbitais apresentarem uma configuração horizontal, o que mostra uma resposta forte ao longo das bordas horizontais (GONZALEZ; WOODS, 2008, p. 732). Simultaneamente, o gradiente na horizontal reduz o efeito dos fios de cabelo, que tipicamente aparecem de forma ortogonal às rugas. Os resultados da aplicação dos operadores *Sobel*/ Vertical e Horizontal estão na Figura 27a e Figura 27b, respectivamente. Nessas figuras estão em destaque duas regiões com setas e circunferências em vermelho.

Na Região I na Figura 27a, na qual foi usado o operador *Sobel*/ Vertical, a seta aponta para a localização de um suposto fio de cabelo que se encontra posicionado na vertical na imagem, entretanto, na mesma região na Figura 27b, em que foi usado o operador *Sobel*/ Horizontal, esse mesmo fio de cabelo não ficou em destaque. Na Região II o destaque está em uma área com forte presença de rugas na horizontal e levemente inclinadas. Pode-se observar que a Figura 27b destaca mais essas rugas em comparação ao resultado apresentado pela Figura 27a. Observando-se as imagens, determinou-se que a aplicação do operador *Sobel*/ Horizontal conseguiu destacar a maioria das rugas periorbitais do paciente com mais nitidez e continuidade do que o operador *Sobel*/ vertical. Esses dois fatores apontados nas imagens evidenciam as maneiras distintas de extração de bordas dos operadores, e reforça a escolha do operador *Sobel*/ Horizontal.

Em relação aos outros operadores, o filtro *Sobel* também proporcionou vantagens de desempenho ao sistema, e isso ocorreu pelo fato da máscara *Sobel* apresentar maiores pesos de diferenciação em relação aos outros operadores. Substituindo o operador *Sobel* pelo operador *Prewitt*, o desempenho do sistema reduz entre 6.9% e 10.4%; e se substituirmos pelo operador *Roberts*, o desempenho reduz entre 18.7% e 25.5%. Esses resultados que validam a escolha do filtro *Sobel* serão apresentados na seção 5.4 com mais detalhes.

Figura 27 - (a) resultado da aplicação do operador *Sobel* vertical; (b) resultado da aplicação do operador *Sobel* horizontal.



Fonte: Elaborado pelo autor.

4.2.3.2 Normalização da imagem


O procedimento de Normalização não muda a estrutura da imagem, o seu propósito é padronizar os níveis dinâmicos de cinza de modo que o conjunto de *pixels* da imagem tenha uma média e uma variância pré-definida. Essa técnica também foi utilizada nos trabalhos de Cula et al. (2009, 2012) e no trabalho de melhoramento de imagens de impressão digital de Hong, Wan e Jain (1998). A imagem normalizada é obtida da imagem original a partir da Equação 5.2.

$$G(i, j) = M_0 + \sqrt{\frac{VAR_0(I(i, j) - M)^2}{VAR}} \quad (5.2)$$

Em que $G(i, j)$ é a imagem normalizada, M e VAR são média e variância da imagem de entrada. Os termos M_0 e VAR_0 são os valores desejados para a média e a variância da imagem normalizada, que terão valores 1 e 0, respectivamente (valores sugeridos por Cula et al., 2009). Os resultados da aplicação desse procedimento estão na Figura 28.

O processo de Normalização possibilitou maior destaque e uniformidade dos níveis de cinza em relação à imagem gerada pela aplicação do operador a gradiente no passo anterior.

Figura 28 - (a) antes; (b) depois da aplicação da normalização.



Fonte: Elaborado pelo autor.

4.2.3.3 Máscara Seletora

Apesar de nossa abordagem utilizar diversas técnicas para destacar as regiões enrugadas das sem rugas, e reduzir a interferência da iluminação e de ruídos em geral, os resultados dos primeiros testes de detecção apresentaram uma quantidade considerável de *pixels* falsos positivos, ou seja, *pixels* que indicam a presença de rugas, sem que estas existissem na imagem real, o que interferiu bastante no desempenho do classificador.

Na tentativa de reduzir os *pixels* falsos positivos na imagem binária, foram adicionados mais dois procedimentos ao sistema, com base em técnicas de melhoramento de imagens de impressão digital. A estrutura e o formato de uma impressão digital são muito semelhantes a uma região de pele enrugada, em que as cristas da impressão digital se assemelham às rugas e os vales à região da pele lisa.

O primeiro procedimento calcula e utiliza a Imagem de Confiança como máscara seletiva de rugas, e o segundo (será explicado na próxima seção) consiste na varredura da imagem binária para localizar e rotular as rugas e, a partir daí, remover as que não se enquadram nos padrões geométricos estabelecidos.

Antes do cálculo da Imagem de Confiança é necessário o cálculo da Imagem de Orientação, que também é utilizada em trabalhos de melhoria de imagens de impressões digitais, como pode ser visto no trabalho Hong, Wan e Jain (1998), e é definida como a orientação local de cumes e vales em estruturas de uma impressão digital.

Os procedimentos do cálculo da Imagem de Orientação estão descritos nos seguintes passos calculados com a imagem Normalizada (apresentada na seção 4.2.3.2):

1. Dividir a imagem Normalizada em blocos de $w \times w$.
2. Calcular o gradiente de cada *pixel* $\partial_x(i, j)$ e $\partial_y(i, j)$ com o auxílio do operador *Sobel*.
3. Estimar a orientação local de cada *pixel* central dos blocos, usando as seguintes equações:

$$V_x(i, j) = \sum_{u=i-\frac{w}{2}}^{i+\frac{w}{2}} \cdot \sum_{v=j-\frac{w}{2}}^{j+\frac{w}{2}} 2 \cdot \partial_x(u, v) \cdot \partial_y(u, v) \quad (5.3)$$

$$V_y(i, j) = \sum_{u=i-\frac{w}{2}}^{i+\frac{w}{2}} \cdot \sum_{v=j-\frac{w}{2}}^{j+\frac{w}{2}} \partial_x^2(u, v) \cdot \partial_y^2(u, v) \quad (5.4)$$

$$\theta(i, j) = \frac{1}{2} \tan^{-1} \left(\frac{V_x(i, j)}{V_y(i, j)} \right) \quad (5.5)$$

onde $\theta(i, j)$ é a estimativa dos mínimos quadrados da orientação do *pixel* central do bloco. Segundo Hong, Wan e Jain (1998), $\theta(i, j)$ representa a direção ortogonal a direção dominante do *Espectro de Fourier* da janela $w \times w$.


4. Passar um filtro passa-baixa na imagem para diminuir a influência de

possíveis ruídos e imperfeições, e tornar a estimativa da orientação dos blocos mais confiáveis.

Depois de calcular a Imagem de Orientação, que contém a estimativa de direção do *pixel* central no bloco, o próximo passo é o cálculo da Imagem de Confiança, que fornece informações sobre a precisão da estimativa da orientação local. A estimativa da confiança da orientação local é definida como a covariância do bloco em relação aos seus blocos vizinhos. Portanto, nos casos em que o valor da confiança é baixo, o bloco em questão não apresenta característica de orientação contínua, logo pode ser considerada uma área sem rugas. Nos casos em que o valor de confiança é alto, existem elementos de orientação contínua, ligados ao bloco e, possivelmente, ele pertence a uma área onde há rugas.

Na Figura 29b, podemos ver o resultado do uso da Imagem de Confiança como uma máscara seletora de *pixels*. Pode-se observar que boa parte dos *pixels* que são considerados como ruído ou falsos positivos na imagem binária foi removida, permanecendo somente os agrupamentos de *pixels* com características contínuas.

Figura 29 - (a) antes; (b) depois da seleção feita com ajuda da Imagem de Confiança.




Fonte: Elaborado pelo autor.

4.2.3.4 Seleção das Rugas

A última parte da Segmentação consiste em localizar e rotular todos os agrupamentos de *pixels* que foram considerados rugas e, em seguida, eliminar os que não se enquadram nas restrições geométricas impostas. Para tanto, foi definido que uma ruga isolada na imagem binária é um agrupamento de *pixels* brancos cercados por *pixels* pretos (como uma ilha). A Figura 30a apresenta uma ilustração com cinco agrupamentos de *pixels* brancos, incluindo também o que tem apenas um *pixel*.

O algoritmo de localização dos agrupamentos percorre toda a imagem binária, *pixel a pixel*, de cima para baixo e depois da esquerda para a direita (como ilustrado pelas setas na Figura 30a). Ele verifica primeiramente se o *pixel* corrente é branco, ou seja, se tem valor lógico '1'; caso não tenha, o algoritmo passa para o próximo *pixel*, seguindo a ordem de execução; caso contrário, ele inicia uma verificação para saber se já existe algum agrupamento ou *pixel* rotulado próximo ao *pixel* corrente. Nessa etapa da execução, o algoritmo verifica quatro *pixels* a partir do *pixel* corrente: NORTE, NOROESTE, OESTE e SUDOESTE, nessa respectiva ordem, como mostra a Figura 30b.

Figura 30 - (a) Ilustração do conceito de agrupamento de *pixels* brancos; (b) ilustração da ordem sequencial de execução do algoritmo.



Fonte: Elaborado pelo autor.

Esses quatro *pixels* vizinhos ao *pixel* corrente, que estão sendo verificados pela ordem normal de execução do algoritmo, já passaram por essa verificação em momentos anteriores; logo, ou eles são *pixels* pretos, que não interferem, ou são *pixels* brancos, que fazem parte de algum agrupamento e já foram rotulados. Caso alguns dos quatro *pixels* já estejam rotulados, o *pixel* corrente também receberá o mesmo rótulo, sendo incluído no mesmo agrupamento de seus vizinhos. Porém, se nenhum dos quatro *pixels* for branco, o *pixel* corrente receberá um novo rótulo, que indica se ele é o início de um novo agrupamento. Ao final da execução do algoritmo, cada ruga terá seu rótulo próprio.

4.2.3.4.1 Restrições Geométricas

Pensando em reduzir os ruídos e os falsos positivos na imagem binária, incorporaram-se ao método algumas restrições geométricas simples, que ajudam a separar os agrupamentos de *pixels* brancos, que realmente são rugas, dos que não são rugas. Para isso, foram criadas três restrições baseadas em observações de imagens de rugas periorbitais:


1. Agrupamentos com *pixels* distribuídos na horizontal e com leve inclinação para a diagonal têm alta probabilidade de serem realmente rugas periorbitais;
2. Agrupamentos com *pixels* distribuídos de forma alongada e contínua semelhante a segmentos curvilíneos têm alta probabilidade de serem realmente rugas;
3. Agrupamentos arredondados com poucos *pixels* e que estão distribuídos de uma maneira semelhante a gotas ou borrões têm baixa probabilidade de serem realmente rugas.

Na Figura 31 são exibidos em destaque duas regiões com agrupamentos de *pixels* brancos que têm probabilidades distintas de serem consideradas rugas. Dentro da região em destaque I, podemos ver pequenos agrupamentos semelhantes a gotas ou a borrões que se encaixam na terceira regra. Esse tipo de formação com poucos

pixels e com formato levemente arredondado tem baixa probabilidade de ser ruga e geralmente é oriunda de pigmentos da pele ou excesso de iluminação, logo devem ser removidos.

Na região em destaque II são apresentados casos de agrupamentos que se enquadram nas regras 1 e 2, com alta probabilidade de serem rugas. A distribuição de seus *pixels* é alongada e contínua (semelhante a segmentos de reta); estando eles na horizontal, logo devem permanecer na imagem binária.


Figura 31 - Em I exemplos de agrupamentos com baixa probabilidade de serem rugas e em II com alta probabilidade.



Fonte: Elaborado pelo autor.

O resultado final da quinta etapa do algoritmo pode ser visto na Figura 32b. Nela pode-se observar que as principais rugas do paciente foram localizadas e destacadas, e a grande maioria dos agrupamentos que torna a imagem binária poluída foi removida.

Figura 32 - (a) antes; (b) depois do processo de remoção dos pequenos agrupamentos.



Fonte: Elaborado pelo autor.

4.2.4 Extração de Características

A etapa de Extração de Características visa obter informações úteis para serem utilizadas na etapa de Reconhecimento e Interpretação. A partir do que os dermatologistas usam para identificar rugas, buscou-se entender como e quais são as características que os médicos observam nas imagens para estabelecer seus diagnósticos, e daí partiu-se para a escolha dos melhores parâmetros de classificação.

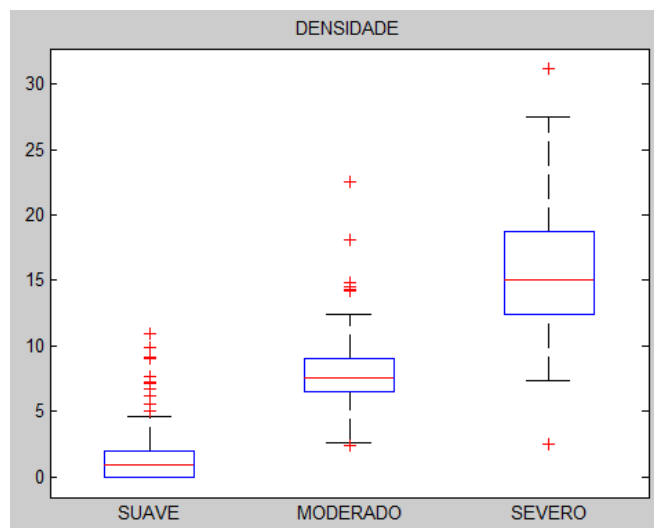
Na seção 2.1 da Fundamentação Teórica, foram apresentadas seis escalas que mensuram a severidade das rugas com imagens fotográficas de diferentes regiões do corpo. Os autores comprovam, através de cálculos estatísticos que medem o grau de semelhança nos resultados obtidos com o uso das escalas, que as escalas funcionam como boas ferramentas para auxiliar dermatologistas em diagnósticos (FITZPATRICK et al., 1996; GOLDMAN et al., 2004; SHOSHANI et al., 2008).

Analisando criteriosamente as seis escalas (seção 2.1.1), pôde-se observar que os autores diferenciam as classes de enrugamento dos pacientes com as seguintes métricas: quantidade (ou densidade) de rugas na imagem, comprimento, largura e profundidade das rugas. De forma semelhante, e tomando como referência o conceito de cada uma dessas métricas, extraíram-se das imagens os seguintes parâmetros:

1. Densidade das rugas – é a proporção de *pixels* brancos (rugas) dentro da imagem. Ela é encontrada dividindo-se o número de *pixels* brancos pela quantidade total de *pixels* da imagem, o que o torna diretamente proporcional à quantidade de rugas na imagem. Esse parâmetro foi utilizado de maneira semelhante aos trabalhos Brand (2007), Cula et al. (2009, 2012), Yu, Yao e Xu (2009) e Horng, Lee e Chen (2011).

Na Figura 33 é apresentado o gráfico em caixa com a distribuição de amostras de densidade organizadas por classes. Em cada caixa, a marca central (em vermelho) indica a mediana, e as bordas inferior e superior da caixa indicam os percentis 25% e 75% das amostras, respectivamente. A linha vertical pontilhada que se estende às amostras mais extremas que não são considerados valores discrepantes e os valores atípicos são traçados individualmente usando o símbolo '+'.

Figura 33 - Gráfico com a distribuição das amostras de densidade organizadas por classe.



Fonte: Elaborado pelo autor.


Para analisar esse tipo de gráfico, devemos observar quatro pontos: a distância entre as medianas das três classes, o intervalo entre os percentis 25% e 75% das amostras em cada classe, o intervalo entre as amostras externas e a quantidade de amostras atípicas. Portanto, a distribuição ótima de amostras deve possuir intervalo máximo entre as medianas das três classes de maneira que as amostras de uma classe não se sobreponham às amostras das outras; os percentis 25% e 75% e as

amostras externas devem possuir um intervalo mínimo (tendendo a zero), ou seja, as amostras desses grupos devem estar muito próximas umas das outras, e por fim não deve haver amostra atípica.

Analisando o gráfico apresentado na Figura 33, podemos observar que os intervalos entre as medianas das três classes e os seus respectivos percentis de 25% e 75% (ou seja, as caixas) não se sobrepõem, o que indica que esse parâmetro consegue discriminar a separação entre as classes, apesar de algumas amostras externas e atípicas se sobrepondo.

2. Variância média da pele – esse valor é encontrado dividindo-se a soma das magnitudes dos gradientes obtidos com o operador *Sobel* das regiões enrugadas, pelo número de *pixels* da imagem, multiplicado por 255. Esse parâmetro também foi coletado no trabalho de Horng, Lee e Chen (2011) e Lazarus, Srilakshmi e Sandeep (2013). Na Figura 34 é apresentada o gráfico da distribuição das amostras coletadas de variância média. Analisando o gráfico podemos observar que os intervalos que separam as caixas e as medianas dos três grupos não se sobrepõem, e os gráficos apresentam poucas amostras atípicas. De maneira semelhante ao resultado da densidade, esse parâmetro permite distinguir a separação entre as classes.

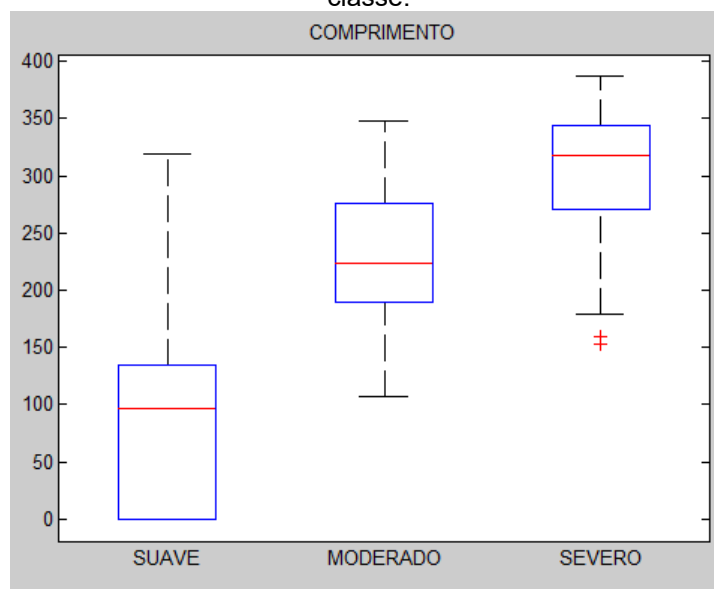
Figura 34 - Gráfico com a distribuição das amostras de variância média da pele organizadas por classe.



Fonte: Elaborado pelo autor.

3. Comprimento da maior ruga – esse valor é encontrado estabelecendo-se a maior distância entre os *pixels* das extremidades na horizontal de cada um dos agrupamentos de branco. Ele é dado em quantidade de *pixels*, e não em unidades métricas convencionais. A Figura 35 exibe a distribuição das amostras coletadas do comprimento da maior ruga na imagem. Seus resultados de assemelham aos resultados de densidade e variância média. Existe uma pequena sobreposição da caixa da classe MODERADO com a caixa da classe SEVERO, porém não invalida a capacidade do parâmetro coletado de discriminar as classes.

Figura 35 - Gráfico com a distribuição das amostras de comprimento da maior ruga organizada por classe.



Fonte: Elaborado pelo autor.

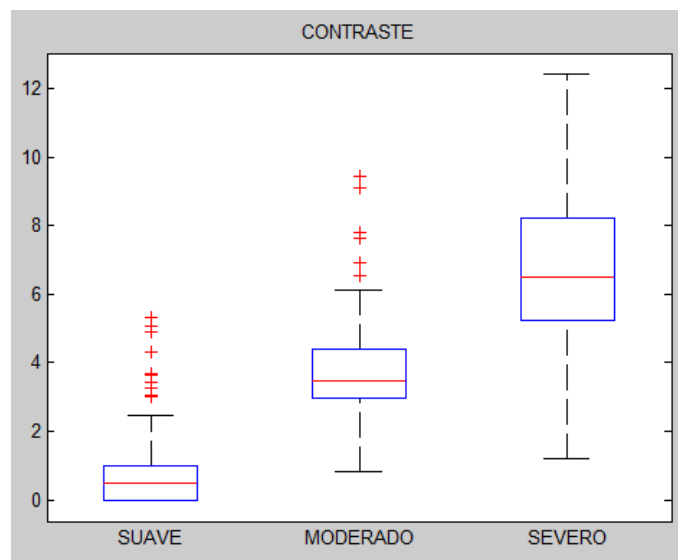
Com base nos estudos sobre descritores de textura (seção 2.3), também coletamos os parâmetros de contraste e de energia, que são conhecidos como descritores de textura *Haralick* (HARALICK et al., 1973) e calculados a partir da matriz GLCM. Esses dois descritores foram escolhidos por retornarem valores que permitem distinguir as três classes, pelo fato de suas equações retornarem valores antagônicos para imagens com poucas rugas e muitas rugas, devido às variações de intensidade de *pixels* que as rugas introduzem na imagem. Abaixo segue a descrição dos dois últimos parâmetros coletados e suas respectivas equações:

4. Contraste – mede as variações locais na matriz de co-ocorrência dos níveis de cinza (descrita na seção 2.3.1 da fundamentação teórica). Este descritor mede a intensidade de contraste entre um *pixel* e o seu vizinho ao longo de toda a imagem, e é descrito pela equação 5.6:

$$\text{Contraste} = \sum_{i,j} |i - j|^2 \cdot p(i, j) \quad (5.6)$$

o termo $p(i, j)$ é o valor normalizado da célula com índice i, j da matriz GLCM. Para uma imagem constante (mesmo tom de cinza em toda a extensão), o contraste é 0 (zero). Portanto, o contraste será menor para imagens com poucas rugas e será maior para imagens com muitas rugas. A Figura 36 exibe a distribuição o das amostras coletadas de contraste organizadas por classe, onde podemos ver que não existe sobreposição entre as caixas.

Figura 36 - Gráfico com a distribuição das amostras de contraste organizadas por classe.



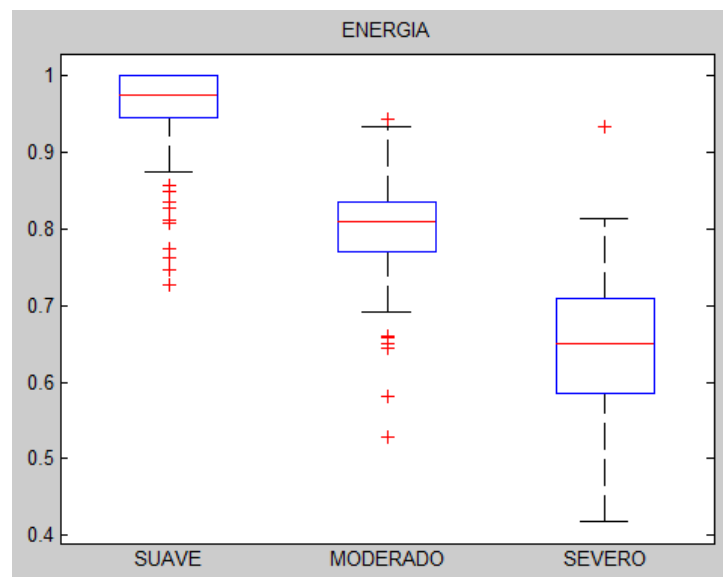
Fonte: Elaborado pelo autor.

5. Energia – Fornece a soma dos quadrados dos elementos no GLCM. Também conhecida como a uniformidade ou o segundo momento angular. Seu cálculo é regido pela equação 5.7:

$$Energia = \sum_{i,j} p(i,j)^2 \quad (5.7)$$

A energia possui valor 1 para uma imagem constante (mesmo tom de cinza em toda a sua extensão), logo quanto menos rugas houver na imagem analisada, mais próximo de 1 será o resultado da energia, e quanto mais rugas houver o valor da energia tenderá a 0. Na Figura 37, pode-se ver o gráfico da distribuição das amostras coletadas de energia organizadas por classes. De maneira semelhante aos outros parâmetros coletados, as caixas não se sobrepõem, o que permite concluir que as amostras de energia coletadas discriminam a separação entre as classes.

Figura 37 - Gráfico com a distribuição das amostras de energia organizadas por classe.



Fonte: Elaborado pelo autor.

4.2.5 Reconhecimento e Interpretação

A última etapa consiste em atribuir significado ao conjunto de dados coletados das imagens da etapa anterior. Para isso utilizaram-se mecanismos de aprendizagem de máquina para extrair conhecimento de um conjunto de dados, de maneira automática, usando métodos computacionais e estatísticos para, a partir daí, aprender como classificar outras amostras de dados semelhantes.

Nessa etapa do projeto, foram treinados dois classificadores com comportamentos distintos (um classificador RNA e um SVM), para escolher dentre eles qual apresenta as melhores taxas de desempenho, para exercer a função de Reconhecimento e Interpretação no sistema proposto no presente trabalho. Foram usadas as mesmas distribuições de dados de treinamento e teste para os dois classificadores, com o propósito de uniformizar os critérios de comparação.

Testamos os desempenhos de diversas configurações de RNA *Feedforward* de múltiplas camadas, porém todas foram treinadas com o algoritmo de retropropagação de erro (*error back-propagation*). O erro é a subtração da resposta desejada (alvo) pela resposta real emitida pela RNA. Esse sinal de erro é então propagado para trás, através da rede (contra a direção das conexões sinápticas), o que proporciona um ajustamento dos pesos sinápticos, de maneira a fazer com que a resposta real da rede se movimente para mais perto da resposta desejada (HAYKIN, 2001, p. 183 e 184).

Nas camadas intermediárias, usaram-se neurônios com a função de ativação do tipo Sigmóide (seção 2.4.1). Essa escolha foi feita pelo fato desses neurônios proporcionarem que os pesos sinápticos sejam modificados mais intensamente para aqueles neurônios da rede em que os sinais funcionais estão no meio do seu intervalo, o que contribui para a estabilidade quando se usa o algoritmo de retropropagação de erros (HAYKIN, 2001, p. 195). Na camada de saída usaram-se neurônios do tipo Limiar (seção 2.4.1) que aprimoram a definição da resposta da rede.

O classificador SVM foi testado mudando o espaço das características das amostras com a aplicação das funções *kernel* linear, quadrática, polinomial e RBF (apresentadas na seção 2.4.2.1). Esse teste foi feito com o objetivo de verificar se o

uso de alguma dessas funções, alterando o espaço de características das amostras, resultaria no aumento de desempenho do classificador.

Dentre os dois classificadores analisados, o que apresentou o melhor desempenho de classificação das rugas foi o classificador RNA. Logo, este classificador foi selecionado para exercer a função de Reconhecimento e Interpretação no método proposto. Os resultados que apoiam essas escolhas serão apresentados na seção 5.

4.3 DESCRIÇÃO DO DATASET

O *dataset* usado nos experimentos foi composto por 433 fotografias da região periorbital da face de pacientes não identificados. Todas as imagens foram coletadas sem critérios rigorosos de padronização (citados na seção 4), e cedidas por clínicas parceiras de nossa pesquisa. As fotografias foram tiradas por pessoas diferentes (tanto por médicos quanto por auxiliares), em ambientes diferentes e sem uso de equipamentos que controlassem iluminação e distância entre o rosto do paciente e a câmera. O único critério observado nas imagens foi o foco, para permitir uma clara visualização das rugas.

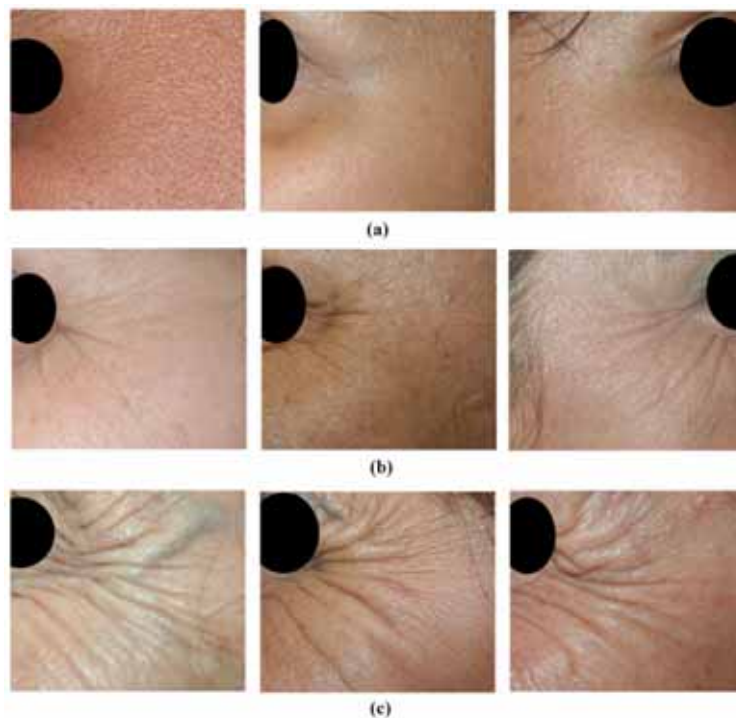
Sabemos que algumas das imagens foram tomadas por uma câmera *Canon EOS Rebel XT* com lente *Canon EFS 18-55mm*, porém não obtivemos informações precisas sobre as outras máquinas fotográficas utilizadas. Isso entretanto, não é significativo para o nosso trabalho, já que seu foco é justamente poder classificar rugas a partir de imagens tomadas sem padronização.

As imagens foram classificadas por um dermatologista seguindo a Escala de Rugas Periorbitais de Fitzpatrick e Goldman em três níveis de severidade: rugas Suaves, Moderadas e Severas. Essa escala foi escolhida para o projeto, por ser uma das escalas mais aceitas disponíveis na literatura, e por ainda permitir uma expansão da classificação em até 9 níveis de enrugamento, o que será muito útil na continuidade do projeto. Segundo a classificação feita pelos especialistas, foram contabilizadas 178 imagens classificadas como suaves, 84 como moderadas e 171 como severas.

Na Figura 38 são apresentados nove exemplos de imagens classificadas segundo os três graus de enrugamento da escala Fitzpatrick e Goldman. Na Figura 38a (primeira linha), temos exemplos de pacientes com enrugamento Suave, na Figura 38b (segunda linha) pacientes com grau de enrugamento Moderado, e na Figura 38c (última linha) pacientes com grau Severo.

As imagens disponibilizadas na Figura 38 foram recortadas da imagem original, depois que elas passaram pelo processo de redimensionamento explicado na seção 4.2.1.1. Recortou-se uma área maior do que a região periorbital somente por motivos ilustrativos.

Figura 38 - Exemplos de imagens classificadas. Linha (a) Suave; Linha (b) Moderado; Linha (c) Severo.



Fonte: Elaborado pelo autor.

A Figura 39 apresenta os resultados da detecção das rugas realizadas nas imagens da Figura 38. Os resultados apresentados na Figura 39 focam somente na região periorbital, ao contrário das imagens que estão na Figura 38, que ilustram uma região além da região periorbital.

Figura 39 - Resultado da detecção das rugas. Linha (a) Suave; Linha (b) Moderado; Linha (c) Severo.



Fonte: Elaborado pelo autor.

4.4 MÉTODOS DE AVALIAÇÃO DOS RESULTADOS

Diante de um número limitado de imagens no *dataset* (433 fotografias de rugas periorbitais), que gerou uma matriz de 433x5 amostras de dados coletados das imagens (seção 4.2.4), os testes foram conduzidos utilizando duas metodologias de reamostragem diferentes: a *Holdout Repetida* e o *K-Folds Cross-Validation*.

Essas técnicas são usadas com o propósito de trazer um resultado mais imparcial na estimativa de erro dos classificadores (que é uma de nossas métricas de desempenho), e tão perto quanto possível do valor de medida verdadeiro. Geralmente, quanto maior a quantidade de amostras, melhores e mais verdadeiros os resultados da estimativa de erros. Porém, na maioria dos trabalhos, os dados são limitados e, para se obter as taxas de erro do classificador de forma confiável, os dados têm de ser usados e reutilizados, a fim de se obter um número suficientemente grande de amostras (JAPKOWICZ; SHAH, 2011). Esse procedimento é conhecido como reamostragem.

Na técnica *Holdout* as amostras são divididas em dois conjuntos, um de treinamento e outro de teste. Na maioria das vezes, $2/3$ das amostras são separadas para o treinamento e $1/3$ para os testes, e são escolhidas aleatoriamente. As amostras de treinamento são usadas para preparar o classificador, e as de teste servem para avaliar o desempenho do mesmo. A grande vantagem desse método é que as amostras de teste não são usadas na etapa de treinamento e, por isso, ele consegue medir a capacidade de generalização do classificador. A estimativa de erro é basicamente a proporção de acertos do classificador diante de todas as amostras que foram submetidas.

A abordagem conhecida como *Holdout Repetido* é uma variação do método *Holdout* que se repete k vezes, e a estimativa de erro geral é a média das estimativas das k rodadas. Com a repetição do processo com diferentes subamostragens aleatórias, a estimação do erro pode ser considerada mais confiável do que com a técnica sendo utilizada em uma única iteração. Apesar dessa vantagem, essa técnica não garante que os diferentes conjuntos de testes encontrados aleatoriamente em cada iteração sejam mutuamente excludentes.

A técnica *K-Fold Cross-Validation*, segundo Japkowicz e Shah (2011), é uma das mais populares para estimar o erro em aprendizagem de máquina. Ela divide o conjunto de amostras em k subconjuntos de tamanhos aproximadamente iguais. A cada iteração do método, um dos k subconjuntos é separado para ser usado nos testes, e os outros $k-1$ conjuntos são usados para treinar o classificador. Assim, todo k subconjunto, em alguma iteração, é utilizado somente como amostras de teste e, nas outras, como amostra de treinamento. Segundo Japkowicz e Shah, (2011) o valor mais utilizado do k nos casos dos algoritmos de aprendizagem automática é $k=10$.

Consideramos nesse trabalho como métrica de desempenho as taxas de acertos dos classificadores (que são o inverso da taxa de erro), área sobre a curva ROC (em inglês *Area under an ROC Curve* - AUC), os valores de sensibilidade (ou *recall*), especificidade, precisão (ou Valores Preditivos Positivos) e as respectivas curvas ROC (*Receiver Operating Characteristic*) de cada classificador.

A sensibilidade (ou taxa de verdadeiro positivo) é a porcentagem de instâncias classificadas corretamente como verdadeiros positivos dentre todas as que realmente são positivas (verdadeiros positivos ou VP + falsos negativos ou FN), ou seja, taxa

com que classifica como positivos todos os exemplos que são de fato positivos (JAPKOWICZ; SHAH, 2011, p. 95, 96 e 101), como pode ser visto na Equação 5.8:

$$\text{Sensibilidade} = \frac{VP}{VP + FN} \quad (5.8)$$

A especificidade (ou taxa de verdadeiro negativo) é a porcentagem de instâncias classificadas corretamente como verdadeiros negativos dentre todas as que realmente são negativas (verdadeiros negativos ou VN + falsos positivos ou FP), em outras palavras, é a taxa com que classifica como negativos todos os exemplos que são de fato negativos (JAPKOWICZ; SHAH, 2011, p. 95 e 96), como pode ser visto na Equação 5.9:

$$\text{Especificidade} = \frac{VN}{VN + FP} \quad (5.9)$$

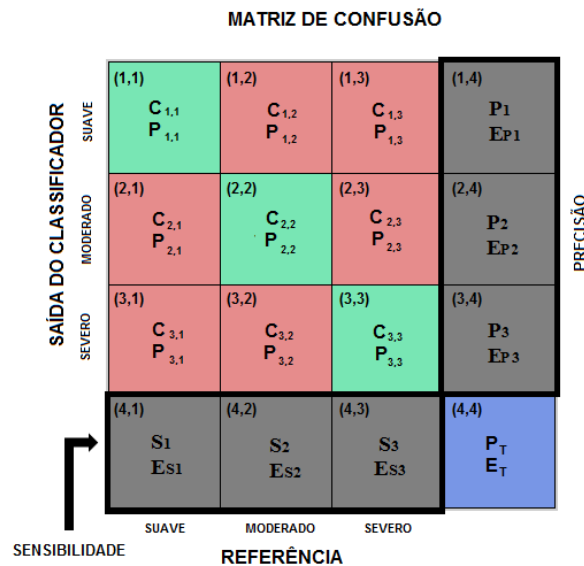
A precisão é outra métrica de avaliação de um classificador e, por definição, é a porcentagem de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas (JAPKOWICZ; SHAH, 2011, p. 99). Observe que o conceito é parecido com o de sensibilidade, entretanto a diferença está no denominador da equação da sensibilidade, que aponta para todas as amostras que são realmente positivas, independentemente de qualquer resultado de classificação, e o denominador da precisão aponta para as amostras que o classificador afirma que são positivas, ou seja, afirma que pertence a uma determinada classe, como pode ser visto na Equação (5.10):

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (5.10)$$

A outra técnica que foi utilizada é conhecida como matriz de confusão. Ela é uma ferramenta importante para avaliar os resultados de previsão do classificador, pois sua maneira de expor os dados facilita o entendimento e ajuda a entender em quais categorias o classificador apresenta respostas certas e erradas. O modelo da

matriz de confusão que será apresentado no Capítulo 5 desse trabalho é apresentado na Figura 40.

Figura 40 - Modelo da Matriz de Confusão.



Fonte: Elaborado pelo autor.

Analisando a Figura 40, podemos fazer as seguintes observações, com base nos conceitos propostos por Japkowicz e Shah (2011, p. 78 e 79):

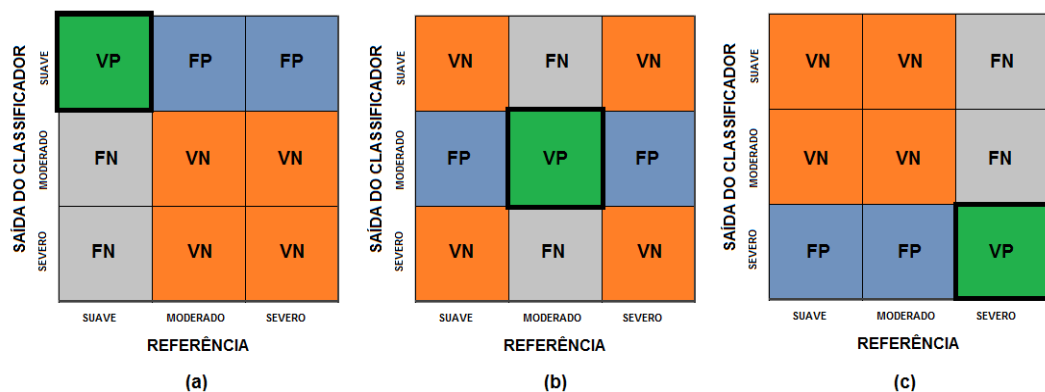
- A combinação dos termos i e j das coordenadas (i, j) representam as combinações das três classes analisadas: SUAVE, MODERADO e SEVERO;
- Todos os elementos da diagonal principal $C_{i,i}$ denotam as amostras classificadas corretamente para a classe i . Assim, $\sum_{i=1}^3 C_{i,i}$ denota o número total de amostras classificadas corretamente pelo classificador;
- Todos os elementos que não estão na diagonal principal denotam erro de classificação. Assim, $\sum_{i,j:i \neq j} C_{i,j}$ denota o número total de amostras atribuídas erroneamente às classes pelo classificador;
- O termo $P_{i,j}$ denota a probabilidade de $C_{i,j}$ dentre o conjunto total de amostras;
- Os termos S_1 , S_2 e S_3 denotam a sensibilidade das classes que é igual a $C_{i,i}/\text{soma marginal da coluna } i$;
- Os termos ES_1 , ES_2 e ES_3 denotam 100% menos o valor de sensibilidade da classe;
- Os termos P_1 , P_2 e P_3 denotam a precisão das classes que é igual a $C_{i,i}/\text{soma marginal da linha } i$;
- Os termos EP_1 , EP_2 e EP_3 denotam 100% menos o valor de precisão da classe;
- O termo P_T denota a probabilidade de acerto de todas as amostras

classificadas;

- O termo E_T denota a probabilidade de erro de todas as amostras classificadas erroneamente;

No eixo vertical da matriz de confusão estão os resultados da classificação, e no eixo horizontal as classificações de referência. Quando trabalhamos com uma matriz de confusão de múltiplas classes, devemos deixar claro como fica a organização lógica da matriz quando se analisam as classes separadamente. Essa organização pode ser vista na Figura 41. A Figura 41a foca a organização da matriz quando a classe analisada é a SUAVE; a Figura 41b foca a classe MODERADO e na Figura 41c a classe analisada é a SEVERO.

Figura 41 - Ilustração da organização lógica das matrizes de confusão para múltiplas classes.



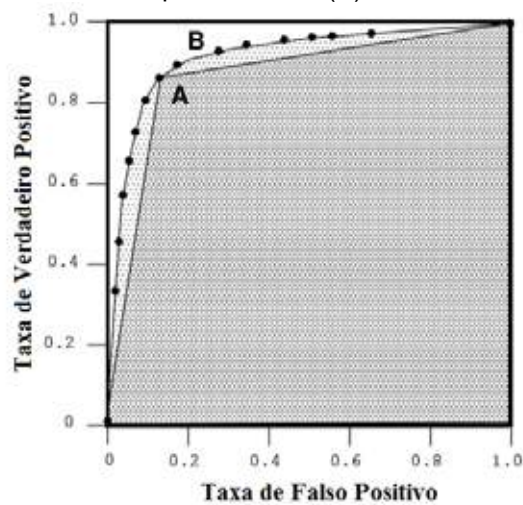
Fonte: Elaborado pelo autor.

Outra maneira de enxergar as medidas de sensibilidade e especificidade de um classificador é através das curvas ROC (*Receiver Operating Characteristic*). Uma curva ROC é um gráfico bidimensional em que a taxa de VP (taxa de verdadeiro positivo ou sensibilidade) é traçada no eixo Y e a taxa de FP (taxa de falso positivo ou 1 menos especificidade) é traçada no eixo X (JAPKOWICZ; SHAH, 2011, p. 95, 96, 113). Um gráfico ROC retrata compensações relativas entre benefícios (verdadeiros positivos) e custos (falsos positivos) (FAWCETT, 2004).

Segundo Fawcett (2004), um classificador discreto é aquele que transmite apenas se uma amostra pertence ou não a uma determinada classe, enquanto um

classificador probabilístico retorna o quanto uma amostra pertence a uma determinada classe. Cada classificador discreto produz um par (taxa FP, taxa VP) que corresponde a um único ponto no espaço ROC, enquanto um classificador probabilístico pode produzir vários pontos no espaço ROC, como pode ser visto na Figura 42, que exhibe um gráfico ROC para o classificador discreto A e um outro gráfico ROC para um classificador probabilístico B.

Figura 42 - Mostra a área sobre a curva de um classificador discreto (A) e um classificador probabilístico (B).



Fonte: Adaptada de Fawcett (2004).

Um método comum usado para medir o desempenho de um classificador é comparar a área sobre a curva ROC ou AUC. Quanto mais próximo estiver o gráfico do ponto (0, 1), que é o ponto ideal de desempenho do classificador, melhor será o seu desempenho e maior será a AUC do classificador. Quando se trabalha com classificadores discretos, o ponto máximo do gráfico ROC é exatamente o ponto (taxa FP, taxa de VP).

5 EXPERIMENTOS E RESULTADOS

Nesse capítulo serão apresentados os desempenhos dos classificadores por meio das métricas de taxa de acerto, área da curva ROC (AUC), sensibilidade, precisão e especificidade.

Nas seções 5.1 e 5.2 são analisados os dois classificadores RNA e SVM quanto ao seu desempenho, mediante as variações de parâmetros internos dos mesmos, com o objetivo de escolher qual configuração retorna melhores resultados. Para tal, usaram-se as taxas de acerto dos classificadores e a área sobre a curva ROC. É importante destacar que os dois classificadores receberam a mesma distribuição de dados, tanto para o treinamento quanto para os testes.

Na seção 5.3 os dois classificadores, já configurados segundo os melhores parâmetros internos, são avaliados de acordo com as métricas de sensibilidade, especificidade, precisão e curva ROC, com o objetivo de definir qual deles é a melhor opção para ocupar o setor de reconhecimento e interpretação do sistema. As análises nessa seção se expandem também para avaliar qual algoritmo de reamostragem proporciona melhores resultados de desempenho.

A seção 5.4 realizou os testes de desempenho de classificação mencionados em seções anteriores do trabalho (4.2.2.1, 4.2.2.2 e 4.2.3.1). Esses testes focaram na averiguação do desempenho de classificação do sistema quando se substituem os seguintes parâmetros: o canal B pelos canais R, G ou pela soma ponderada sugerida pela função *rgb2gray*; a transformada exponencial pela equalização do histograma; ou o filtro *Sobel* pelos filtros *Prewitt* e *Roberts*.

A Tabela 6 exhibe a distribuição quantitativa das amostras separadas pelos dois métodos de reamostragem, e as respectivas quantidades de amostras para cada classe de enrugamento. No método *Holdout*, aproximadamente 2/3 das amostras foram separadas para o treinamento e apenas 1/3 para os testes. Por outro lado, no método *Cross-Validation* foram contabilizadas 10 partições – sete partições com 43 amostras e três partições com 44 amostras. Portanto, em três iterações, 389 amostras foram separadas para o treinamento e 44 para testes, e, nas outras sete iterações 390 amostras foram separadas para o treinamento e 43 amostras para testes.

Tabela 6 - Distribuição quantitativa das amostras nos métodos reamostragem.

		Suave	Moderado	Severo	Total
<i>Holdout Repetido</i>	Treinamento	125	58	119	302
	Teste	54	26	52	131
<i>K-Folds C. Validation</i>	Treinamento	160	76	154	390
	Teste	18	8	17	43

Fonte: Elaborado pelo autor.

5.1 TESTES COM O CLASSIFICADOR RNA

O classificador RNA tem a capacidade de resolver problemas não lineares e complexos, e por ter grande capacidade de adaptação às mudanças nas características das informações de entrada, o que é muito adequado ao nosso problema, já que as rugas podem sofrer variações e novos casos clínicos podem aparecer. Nossa hipótese foi buscar um classificador que aumentassem a flexibilidade do sistema como um todo.

Nessa seção analisamos o desempenho das diferentes topologias de rede, observando dois critérios: taxa de acerto do classificador e área sobre a curva ROC das classes de cada classificador. A taxa de acerto é a porcentagem de amostras classificadas corretamente dentre todas as amostras disponibilizadas para o teste. A área sobre a curva ROC é uma métrica de desempenho bastante usada para comparar classificadores, como foi apresentado na seção 4.4.

Testamos onze topologias diferentes de rede RNA, três redes com cinco camadas, quatro redes com quatro camadas e quatro redes com três camadas. As topologias testadas foram: 5-5-5-5-3; 5-5-3-3-3; 5-3-3-3-3; 5-5-5-3; 5-5-3-3; 5-5-2-3; 5-2-2-3; 5-5-3; 5-3-3 e 5-2-3.


Analisando os classificadores RNA quanto às taxas de acerto, a topologia que obteve melhor desempenho com o algoritmo de reamostragem *Holdout* e com o *Cross-Validation* foi a 5-2-3 (cinco neurônios na entrada, dois na camada intermediária e três na saída), com as seguintes porcentagens de acerto: 88.7% e 89.6%, respectivamente (valores disponíveis na Tabela 7). Para ajudar na comparação dos resultados, disponibilizamos os dados da Tabela 7 nos gráficos da Figura 43.

Tabela 7 - Resultados de desempenho do classificador RNA quando submetido a topologias de redes diferentes.

Topologia	<i>Holdout Repetido</i>	<i>K-Folds Cross-Validation</i>
5-5-5-5-3	83.8%	82.9%
5-5-3-3-3	83.9%	86.4%
5-3-3-3-3	86.1%	86.8%
5-5-5-3	84.1%	86.1%
5-5-3-3	85.5%	85.9%
5-5-2-3	86.1%	85.5%
5-2-2-3	87.6%	87.5%
5-5-3	87.9%	88.0%
5-3-3	88.2%	88.7%
5-2-3	88.7%	89.6%
5-1-3	78.6%	78.8%

Fonte: Elaborado pelo autor.

Figura 43 - Gráficos das taxas de acerto por topologia.



Fonte: Elaborado pelo autor.


Diante dos resultados da Tabela 7 e dos gráficos da Figura 43, pode-se observar, comparando os resultados da técnica *Holdout* com a *Cross-Validation*, que a diferença nos percentuais de acerto do classificador RNA quando montado com métodos de reamostragem diferentes é de menos de 1% para nove das 11 topologias. As únicas exceções são as topologias 5-5-3-3-3 e 5-5-5-3, que apresentaram uma diferença de mais de 2%.

Na Figura 44 apresentamos seis gráficos que exibem a AUC dos classificadores. Esses gráficos possibilitam a análise dos resultados quando comparamos as diferentes topologias por classe e por algoritmo de reamostragem. Em todos os gráficos podemos observar que a maior AUC foi fornecido pela topologia 5-2-3, para todas as classes.


Comparando exclusivamente a topologia 5-2-3, podemos observar na Figura 44a e na Figura 44b que o algoritmo *Cross-Validation* retornou uma maior AUC (com um valor superior a 0.95) do que o algoritmo *Holdout* (com 0.94) para a classe SUAVE. Fazendo a mesma comparação para a classe MODERADO, observando os resultados na Figura 44c e na Figura 44d, podemos concluir que a técnica *Cross-Validation* (com 0.85) supera novamente a *Holdout* (com 0.82). Para a classe SEVERO (Figura 44e e Figura 44f), a técnica *Holdout* (com 0.931) supera a *Cross-Validation* (com 0.929), com uma margem muito pequena.

Diante dos resultados apresentados de taxa de acerto e AUC, podemos afirmar que o classificador RNA, com topologia 5-2-3, treinado com a técnica *Cross-Validation*, apresenta melhor desempenho do que os outros analisados. Apesar de terem sido usados métodos diferentes de reamostragem, ou seja, os classificadores foram montados com distribuições diferentes de dados para treinamento e teste, todos os testes retornaram resultados semelhantes, o que reforça a ideia de que os algoritmos de reamostragem usados ajudam a encontrar a estimativa de desempenho verdadeira do classificador.


Figura 44 - Gráfico de TOPOLOGIA x AUC das RNAs; (a) e (b) gráficos da classe SUAVE; (c) e (d) gráficos da classe MODERADO; (e) e (f) gráficos da classe SEVERO.




(a)




(b)




(c)



(d)



(e)



(f)

Fonte: Elaborado pelo autor.

5.2 TESTES COM O CLASSIFICADOR SVM

Uma SVM (Máquina de Vetores de Suporte) é por natureza um classificador binário, porém pode ser adaptada para classificar múltiplas classes. Existem diversas técnicas que podem ser empregadas na generalização das SVMs para a solução de problemas de múltiplas classes.

A técnica que foi usada nesse projeto é chamada de “um-contra-resto” ou “um-contra-todos”. Ela recorre à decomposição do problema multiclasse em vários subproblemas binários, assim criando um classificador SVM para distinguir cada classe de todas as outras classes (WESTON; WATKINS, 1999). O primeiro classificador SVM criado foi treinado para distinguir a classe SUAVE das classes MODERADO e SEVERO juntas; o segundo classificador foi treinado para distinguir a classe MODERADO da junção das classes SUAVE e SEVERO, e o terceiro treinado para distinguir a classe SEVERO da junção das classes SUAVE e MODERADO. Ao fim, usam-se os três classificadores para julgar os dados de teste, observando aquele que aponta para a classe isolada. Entretanto, apesar de haver ao final três classificadores SVM (um para cada classe), no decorrer do texto o termo SVM será mencionado no singular, como uma visão de alto nível do classificador.

De maneira semelhante à seção anterior, medimos o desempenho dos classificadores SVM pela taxa de acerto e pela área da curva ROC dos mesmos. Na Tabela 8 são apresentadas as taxas de acerto do classificador SVM mediante a troca da função *kernel* (explicadas na seção 2.4.2.1 da Fundamentação Teórica).

Diante dos resultados apresentados na Tabela 8, o classificador SVM com melhor desempenho foi o que usou a função *kernel* RBF. Podemos observar entre os resultados nas colunas 2 e 3 da Tabela 8, que a diferença percentual é de menos de 1% entre as taxas de acerto obtidas com os diferentes métodos de reamostragem.

Tabela 8 - Tabela com os resultados do desempenho do classificador SVM mediante o tipo de função *kernel* utilizado.

Kernel	Holdout Repetido	K-Folds Cross-Validation
Linear	72,3%	72,5%
Quadrática	83,4%	83,1%
Polinomial	85,3%	---
RBF	86,4%	87,8%

Fonte: Elaborado pelo autor.


Na Tabela 8 a taxa de acerto do classificador SVM usando *kernel* polinomial de grau 3, e recebendo os dados de treinamento selecionados pelo método *Cross-Validation*, encontra-se sem resultado, pelo fato do classificador SVM não haver convergido nesta situação.

A Figura 45 apresenta seis gráficos que exibem a AUC dos classificadores. Esses gráficos possibilitam a análise dos resultados quando comparamos o uso das diferentes funções *kernel* por classe e por algoritmo de reamostragem. Observando a Figura 45, podemos ver que, para a classe SUAVE, a melhor função *Kernel* foi a Linear enquanto para as outras classes foi a função RBF.

A Figura 45a e a Figura 45b apresentam os resultados da classe SUAVE, que *a priori*, contrariam os resultados de taxa de acerto apresentado anteriormente. Entretanto, quando observamos com mais atenção os gráficos, podemos ver que a diferença da AUC entre as funções *Kernel* Linear e RBF (Figura 45a) é de apenas 0.001, ou seja, os dois resultados estão bastante próximos, com uma diferença quase insignificante. Comparando de maneira semelhante os resultados da Figura 45b, podemos ver que a diferença nesse caso é de apenas 0.003. Portanto, pode-se concluir que os resultados de AUC dos classificadores SVM utilizando as funções *Kernel* Linear e RBF são praticamente os mesmos para a classe SUAVE. E quando comparamos o desempenho quanto à técnica de reamostragem, conclui-se que o algoritmo *Holdout* supera o *Cross-Validation* em aproximadamente 0.0006. Porém, para todas as outras duas classes, como pode ser visto na Figura 45c, na Figura 45d, na Figura 45e e na Figura 45f, o treinamento com a técnica *Cross-Validation* supera a *Holdout*.

Diante dos resultados de taxa de acerto apresentados na Tabela 8 e dos gráficos da Figura 45, pode-se concluir que o classificador SVM utilizando a função *Kernel* RBF e sendo treinado com a técnica *Cross-Validation* é a melhor opção para a classificação conjunta das três classes de enrugamento.

Figura 45 - Gráfico de Função *Kernel* x AUC das SVMs; (a) e (b) gráficos da classe SUAVE; (c) e (d) gráficos da classe MODERADO; (e) e (f) gráficos da classe SEVERO.



Fonte: Elaborado pelo autor.

5.3 ANÁLISE DE SENSIBILIDADE, ESPECIFICIDADE, PRECISÃO E CURVA ROC

Nessa seção é feita uma análise do desempenho dos dois classificadores testados no sistema mediante as métricas de Sensibilidade, Especificidade, Precisão e Curva ROC. Iniciaremos essa seção apresentando as matrizes de confusão dos classificadores em análise, que são apresentadas na Figura 46, pelo fato de todas as métricas de desempenho precisarem dos dados disponíveis nelas. Na seção 4.4 é apresentado o modelo da matriz de confusão utilizada nesse trabalho, juntamente com as respectivas explicações de suas partes.

A Figura 46a e a Figura 46c exibem as matrizes de confusão dos classificadores RNA e SVM, respectivamente, quando submetidos à técnica de reamostragem *Holdout* Repetido, respectivamente. Essa técnica proporcionou 1310 amostras de teste, obtidas com as 10 iterações de sua execução. As Figura 46b e Figura 46d apresentam, respectivamente, as matrizes de confusão dos classificadores RNA e SVM, quando submetidos à técnica de reamostragem *K-folds Cross-Validation*, respectivamente. Essa técnica proporcionou 433 amostras de teste durante suas 10 iterações.

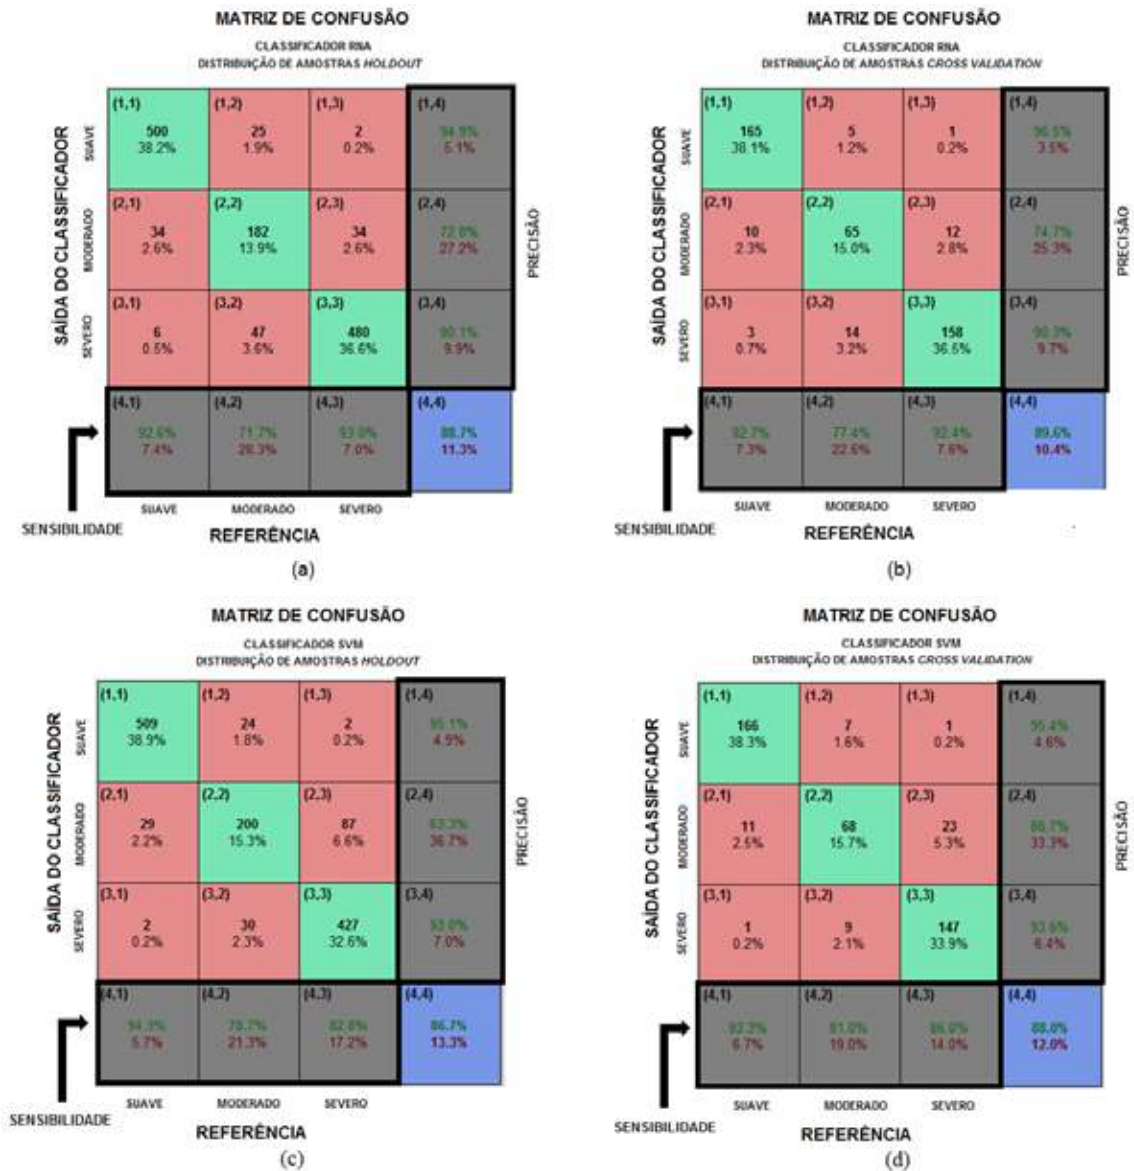
Na diagonal principal das quatro matrizes de confusão (células (1,1), (2,2) e (3,3)), podemos observar a quantidade de amostras que foram classificadas acertadamente (na parte superior da célula) e, logo abaixo, a porcentagem que essa quantidade representa dentro do conjunto total de amostras.

As células (1,2), (1,3), (2,1), (2,3), (3,1) e (3,2) exibem a quantidade de amostras classificadas erroneamente (na parte superior), e na parte inferior a porcentagem que essa quantidade representa dentro do conjunto total de amostras. Observando essas células, podemos concluir que a classe MODERADO apresentou mais erros do que as outras, pelo fato de ser uma classe intermediária.

As células (4,1), (4,2) e (4,3) apresentam os valores de sensibilidade (na parte superior) e na parte inferior seu inverso, ou seja, 100% menos o valor sensibilidade. Nas células (1,4), (2,4) e (3,4) são apresentados os valores de precisão para cada classe (na parte superior), e na parte inferior o inverso (100% menos o valor de

precisão). Por fim, a última célula (4,4) exibe a taxa de acerto total do classificador (na parte superior) e, na parte inferior, a taxa de erros do mesmo.

Figura 46 – Matrizes de Confusão.



Fonte: Elaborado pelo autor.

Disponibilizamos na Tabela 9 as taxas de sensibilidade (também conhecidas como *recall*) dos classificadores mediante o uso das técnicas de reamostragem, com o objetivo de facilitar a leitura e a compreensão do leitor. Essa taxa tem a função de informar a porcentagem de amostras positivas classificadas corretamente (amostras

que um classificador atribuiu corretamente a uma determinada classe) sobre o total de amostras positivas (todas as amostras que realmente pertencem àquela classe).

Na própria tabela disponibilizamos (entre parênteses em itálico e em verde) as diferenças entre as taxas de sensibilidade dos classificadores. Observando a tabela, podemos concluir que as diferenças entre as taxas de sensibilidade utilizando o método *Holdout* foram superiores às mesmas diferenças utilizando a técnica *Cross-Validation*, o que induz a uma maior confiança aos classificadores treinados com a *Cross-Validation*, por sua menor variabilidade. Entretanto, quando analisamos apenas as taxas de sensibilidade dos classificadores montados com a técnica *Cross-Validation*, percebemos que o classificador SVM superou o RNA nos resultados das classes SUAVE (em 0.6%) e MODERADO (em 3.5%); porém, na classe SEVERO, o classificador RNA superou o SVM em 6.5%, que é uma taxa elevada quando tomamos como critério comparativo as taxas anteriormente citadas (de 0.6% e 3.5%). Por essa pequena diferença, consideramos o classificador RNA montado com a técnica *Cross-Validation* superior ao outro, quanto à análise das taxas de sensibilidade.

Tabela 9 - Resultados da Sensibilidade dos classificadores.

		SUAVE	MODERADO	SEVERO
<i>Holdout</i>	RNA	92.6%	71.7%	93.0% (+10.2%)
	SVM	94.3% (+1.7%)	78.7% (+7.0%)	82.8%
<i>Cross-Validation</i>	RNA	92.7%	77.4%	92.4% (+6.5%)
	SVM	93.3% (+0.6%)	80.9% (+3.5%)	85.9%

Fonte: Elaborado pelo autor.

Na Tabela 10 apresentamos os resultados de Precisão dos classificadores RNA e SVM. Essa taxa tem a função de informar a porcentagem de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas (todas as amostras certas ou erradas que o classificador atribuiu a uma determinada classe).

Foi realizada uma análise dessa tabela de maneira semelhante à análise feita com as taxas de sensibilidade, pelo fato dos resultados terem valores muito próximos. A partir da observação das diferenças entre as taxas de precisão dos classificadores,

conclui-se que os classificadores montados com a técnica *Cross-Validation* são mais confiáveis que os montados com a *Holdout*.

Focando apenas os classificadores montados com a técnica *Cross-Validation*, percebemos que o classificador RNA supera o SVM nas classes SUAVE (com 1.1%) e MODERADO (com 8.0%), mas perde na classe SEVERO (com 3.3%). Para essa análise, mais uma vez iremos atribuir o melhor desempenho ao classificador RNA, porque a sua taxa de precisão da classe MODERADO está muito acima da taxa do SVM.

Tabela 10 - Resultado da Precisão dos classificadores.

		SUAVE	MODERADO	SEVERO
<i>Holdout</i>	RNA	94.9% (+9.8%)	72.8% (+9.5%)	90.1%
	SVM	85.1%	63.3%	93.0% (+2.9%)
<i>Cross-Validation</i>	RNA	96.5% (+1.1%)	74.7% (+8.0%)	90.3%
	SVM	95.4%	66.7%	93.6% (+3.3%)

Fonte: Elaborado pelo autor.

A Tabela 11 apresenta as taxa de especificidade dos classificadores. A especificidade é a porcentagem de amostras negativas identificadas corretamente (amostras que o classificador afirma que não pertencem a uma determinada classe) sobre o total de amostras negativas (amostras que realmente não pertencem à classe). As taxas de especificidade foram acima de 89%, o que amplia a confiabilidade dos classificadores quando eles afirmam que uma amostra não pertence a uma determinada classe.

Todas as taxas de especificidade dos classificadores montados com a técnica *Cross-Validation* superam as taxas de especificidade dos classificadores montados com o método *Holdout*. Diante disso, focando os resultados da técnica *Cross-Validation*, podemos perceber que, nas categorias SUAVE e MODERADO, o classificador RNA supera o SVM, sendo inferior na categoria SEVERO. Seguindo os mesmos critérios de comparação feitos com as taxas de sensibilidade e precisão, apresentadas anteriormente, podemos concluir que o classificador RNA (montado com a técnica *Cross-Validation*) é o que apresenta as melhores taxas de especificidade.

Tabela 11 - Resultado da Especificidade dos classificadores.

		SUAVE	MODERADO	SEVERO
Holdout	RNA	96.5%	93.6% (+4.6%)	93.3%
	SVM	96.6% (+0.1%)	89.0%	96.0% (+2.7%)
Cross-Validation	RNA	97.6% (+0.7%)	93.7% (+3.4%)	93.5%
	SVM	96.9%	90.3%	96.2% (+2.7%)


Fonte: Elaborado pelo autor.

Na Figura 47 são apresentadas as curvas ROC dos classificadores testados geradas com a função *plotroc* do *software* MATLAB. De acordo com Japkowicz e Shah (2011), quanto mais próxima a curva estiver do canto superior esquerdo do gráfico, melhor é o desempenho do classificador. Na mesma figura também são apresentadas as áreas abaixo das curvas para cada uma das classes. O valor da AUC pode variar entre o intervalo [0, 1], e quanto mais próximo estiver esse valor de 1, melhor será o desempenho do classificador.

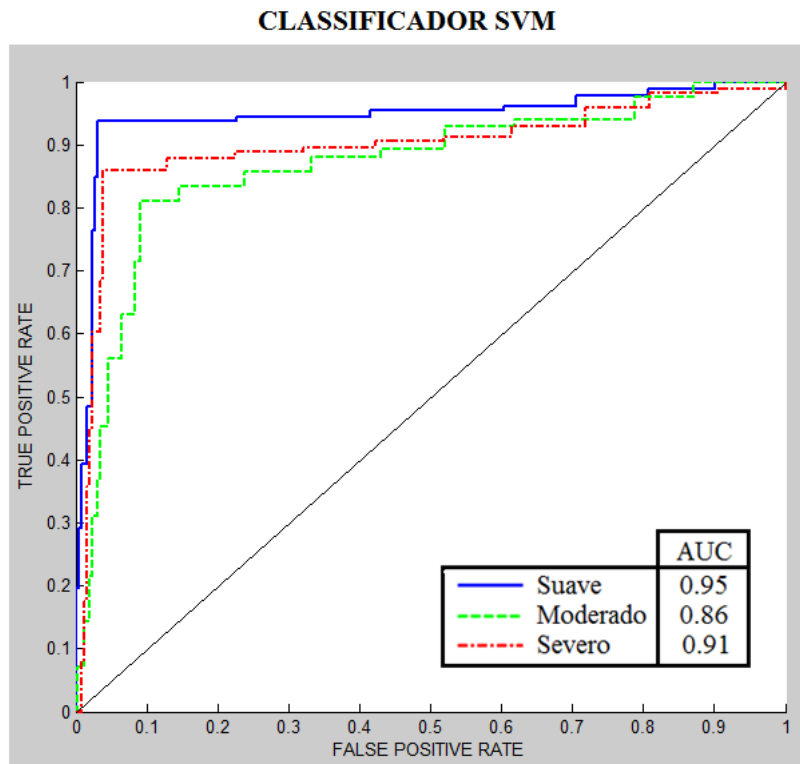
Ao se comparar as curvas dos classificadores RNA e SVM, pode-se concluir que as da classe SUAVE (em azul) e MODERADO (em verde) estão praticamente na mesma posição e apresentam aproximadamente a mesma AUC. Porém, a curva da classe SEVERO (em vermelho) do RNA apresenta um posicionamento mais próximo do canto superior esquerdo do que a curva da mesma classe do classificador SVM, o que também pode ser confirmado pelos valores de AUC dessa classe.

Portanto, diante dos resultados apresentados nessa seção, o classificador RNA treinado com o algoritmo de reamostragem *K-Folds Cross Validation* apresenta melhores métricas de desempenho que o classificador SVM, no entanto com uma pequena margem de diferença.

Figura 47 - Curva ROC dos classificadores



(a)



(b)

Fonte: Elaborado pelo autor.

5.4 TESTES PARA AJUSTE DOS PARÂMETROS DO MÉTODO

Essa seção apresenta uma visão geral dos percentuais de desempenho do método de classificação de rugas quando substituímos as técnicas escolhidas e validadas por outras mencionadas nas seções anteriores. Achamos interessante disponibilizar essas informações pelo fato dessas taxas terem ajudado a definir as escolhas de projeto.

A Tabela 12 compara as taxas de acerto dos classificadores RNA e SVM diante do uso das novas técnicas. Na linha 1 da Tabela 12, destacam-se em negrito as taxas de acerto do método final de classificação de rugas, ou seja, o sistema construído com todas as escolhas de projeto anteriormente apresentadas e justificadas nas seções anteriores, com a finalidade de facilitar ao leitor a comparação com os outros resultados.

Na seção 4.2.2.1, foi mencionada a escolha do canal azul (B) em relação aos outros dois canais do RGB, e da soma ponderada dos três canais (obtida com a função *rgb2gray* do *Matlab*). Essa escolha pode ser justificada observando as taxas de acerto dos classificadores (que estão exibidos na Tabela 12 linhas 2, 3 e 4) e mostra que todas as taxas de acerto foram inferiores às apresentadas na primeira linha. Substituindo o canal B pelo canal R, o desempenho do sistema reduz entre 10.5% e 14.6%; pelo canal G, reduz entre 2.7% e 5.3%; e pela soma ponderada (função *rgb2gray*), o desempenho reduz entre 4.3% e 6.3%.

Na seção 4.2.2.2 explicamos a escolha da Transformada Exponencial em relação ao uso da Equalização do Histograma, e na seção 4.2.3.1 tratou-se da escolha do operador *Sobel* em relação aos outros dois operadores gradiente (*Prewitt* e *Roberts*). Substituindo-se a Transformada Exponencial pela Equalização do Histograma o desempenho do sistema reduz entre 10.0% e 11.3%; substituindo-se o operador *Sobel* pelo operador *Prewitt*, a queda do desempenho do sistema fica entre 6.9% e 10.4%; e substituindo-se pelo operador *Roberts*, o desempenho reduz entre 18.7% e 25.5%.

Tabela 12 - Taxas de acerto na classificação mediante a troca de alguns parâmetros de projeto.

Linha	Alteração	Classificador	<i>Holdout Repetido</i>	<i>K-Folds Cross-Validation</i>
1	Método Final	RNA	88.7%	89.6%
		SVM	86.7%	88.0%
2	Alteração usando o Canal Vermelho (R)	RNA	78.2% (-10.5%)	77.3% (-12.3%)
		SVM	74.9% (-11.8%)	73.4% (-14.6%)
3	Alteração usando o Canal Verde (G)	RNA	85.0% (-3.7%)	84.3% (-5.3%)
		SVM	84.0% (-2.7%)	83.8% (-4.2%)
4	Alteração usando a Função rgb2gray	RNA	84.4% (-4.3%)	83.8% (-5.8%)
		SVM	81.5% (-5.2%)	81.7% (-6.3%)
5	Alteração usando a Eq. do Histograma	RNA	77.4% (-11.3%)	79.4% (-10.2%)
		SVM	76.7% (-10.0%)	77.3% (-10.7%)
6	Alteração usando o Operador <i>Prewitt</i>	RNA	81.8% (-6.9%)	81.7% (-7.9%)
		SVM	78.6% (-8.1%)	77.6% (-10.4%)
7	Alteração usando o Operador <i>Roberts</i>	RNA	70.0% (-18.7%)	69.2% (-20.4%)
		SVM	64.7% (-22.0%)	62.5% (-25.5%)

Fonte: Elaborado pelo autor.

É importante destacar que os resultados de classificação obtidos nessa seção foram alcançados usando os classificadores com as configurações que proporcionaram os melhores resultados de desempenho classificatórios mencionados nas duas seções anteriores.

5.5 CONSIDERAÇÕES SOBRE OS RESULTADOS

Este capítulo apresentou os testes de desempenho para comparação de classificadores baseados em RNA e SVM, que foram usados para a função de reconhecimento e interpretação do método de classificação de rugas proposto nesse trabalho. Também foram apresentados testes que justificaram a escolha de alguns parâmetros de projeto mencionados na seção de Metodologia.

O desempenho dos classificadores experimentados foi medido usando dois métodos distintos de reamostragem (*Holdout Repetido* e *K-Folds Cross-Validation*)

com o objetivo de encontrar as métricas de desempenho mais próximas dos valores reais, o que pode ser comprovado nos resultados apresentados pelos dois classificadores analisados.

Diante dos resultados encontrados, pôde-se concluir que o classificador RNA, sendo treinado pelo método de reamostragem *K-Folds Cross-Validation*, evidenciou as melhores taxas de desempenho, porém é importante ressaltar que suas taxas de desempenho foram bastante próximas das taxas do classificador SVM.

Limitações do Sistema

Quanto às limitações do sistema desenvolvido, podemos listar cinco situações que podem gerar problemas na detecção das rugas e conseqüentemente erros de classificação:

1. Imagens sem foco: o sistema, ao receber uma imagem sem foco como entrada, localiza as rugas. Entretanto, como esse tipo de imagem não possui bordas bem definidas (por consequência da falta de foco), o resultado da detecção fica comprometido, e as rugas detectadas excedem a real dimensão, o que prejudica o julgamento do classificador;
2. Imagens de paciente com verrugas ou cicatrizes: o sistema pode confundir as verrugas e cicatrizes com rugas e prejudicar a classificação;
3. Imagens com excesso de iluminação: parte da imagem fica prejudica pelo excesso de iluminação capturada e outras partes podem gerar excesso de sombra, o que pode prejudicar a classificação;
4. Ângulo entre a câmera e o rosto do paciente: o melhor posicionamento para a captura das imagens é a um ângulo de 45°, focalizando exatamente a região periorbital. Quando a fotografia é capturada frontalmente, a região periorbital fica reduzida, e parâmetros como densidade de enrugamento e comprimento da maior ruga ficam comprometidos;
5. Excesso de pelos e cabelo na imagem: pelos e fios de cabelo na imagem podem ser confundidos com rugas pelo sistema, principalmente se estiverem posicionados horizontalmente ou levemente inclinados;

6 CONCLUSÃO

O presente trabalho surgiu da dificuldade apresentada por médicos dermatologistas em reduzir a subjetividade no acompanhamento da evolução dos tratamentos dermatológicos de redução das rugas periorbitais em seus pacientes. Essa dificuldade é inerente ao procedimento básico usado pelos médicos em seu diagnóstico, que é a análise visual das imagens fotográficas do paciente ao longo do tratamento, e em alguns casos a comparação com fotografias de referência de escalas disponíveis na literatura. Entretanto, é frequente que as fotografias sejam tomadas sem padronização de iluminação, distância e ângulo entre a câmera e o rosto do paciente. Essa falta de padronização é consequência de uma pressão por um aumento na velocidade do atendimento, pela falta de aparelhagem adequada que facilite a padronização (equipamentos para fixar posicionamento e outros para controlar a iluminação do ambiente) e também por inabilidade do operador da câmera. A falta de padronização na tomada das fotos não só dificulta o acompanhamento do tratamento em si, como também a troca de informações entre médico e paciente.

Este trabalho se concentrou no desenvolvimento de um método computacional para auxiliar a detecção e classificação das rugas periorbitais, a partir de imagens de pacientes coletadas de forma não padronizada por médicos dermatologistas, para criar um sistema confiável de classificação de rugas que seja pouco suscetível à maneira como as fotografias são coletadas. O método classifica as rugas periorbitais em três níveis de classificação (segundo a escala de rugas de Fitzpatrick e Goldman) com o uso de um classificador RNA.

O sistema não impõe qualquer alteração na rotina de tomada das fotos, nem requer o uso de equipamento especializado, compensando a falta de padronização das fotografias com técnicas de redimensionamento e processamento digital de imagens, antes de extrair as informações referentes às rugas.

O método desenvolvido conseguiu classificar as rugas com uma precisão de 89.6% em cima do *dataset* criado, e teve como principal vantagem a capacidade de trabalhar com imagens que foram tomadas com diferentes distâncias câmera/paciente, em diferentes ângulos e com diversos graus de iluminação.

Apesar de ter sido alcançado o objetivo inicial desse trabalho, é importante destacar que ainda há um longo caminho para melhoria do método, para que o sistema possa interpretar e classificar qualquer imagem de rugas periorbitais fazendo ponderações aproximadas e semelhantes à de um especialista humano. Nesse sentido, esse trabalho dá uma contribuição significativa, pois já fornece uma arquitetura base e estabelece alguns parâmetros para a construção de uma importante ferramenta para auxiliar os médicos em suas avaliações.

Como atividades futuras, pretende-se aumentar o número de imagens do *dataset* e submetê-lo a análise de mais dermatologistas, para aumentar seu grau de representatividade e validar melhor o funcionamento do sistema. Além do mais, será dado prosseguimento à investigação de outras características para, se possível, desenvolver uma métrica que possa quantificar de forma confiável a intensidade das rugas em lugar de apenas classificá-las, e ampliar os experimentos incluindo testes de iluminação. Também será adaptado o sistema para que seja possível trabalhar com imagens de outros tipos de rugas, como rugas na testa e rugas no canto da boca.

Finalmente, a partir dos comentários ouvidos dos dermatologistas, está se avaliando a possibilidade de desenvolver uma versão do sistema para dispositivos móveis, o que poderia dar aos pacientes uma ferramenta de acompanhamento de seus tratamentos de maneira simples e informal.

REFERÊNCIAS

- ABIHPEC, Consumo de produtos para pele [2014]. Disponível em: <<https://www.abihpec.org.br/2014/05/abihpec-aumenta-procura-por-produtos-para-pele/>>. Acessado em 29-01-2016.
- BATOOL, Nazre; CHELLAPPA, Rama. Modeling and detection of wrinkles in aging human faces using marked point processes. In: **Computer Vision–ECCV 2012. Workshops and Demonstrations**. Springer Berlin Heidelberg, 2012. p. 178-188.
- BATOOL, Nazre; CHELLAPPA, Rama. Fast detection of facial wrinkles based on Gabor features using image morphology and geometric constraints. **Pattern Recognition**, v. 48, n. 3, p. 642-658, março de 2015.
- BAZIN, Roland; LÉVÊQUE, Jean Luc. Longitudinal study of skin aging: from microrelief to wrinkles. **Skin Research and Technology**, v. 17, n. 2, p. 135-140, 2011.
- BEILIN, Ghislaine. Home-use TriPollar RF device for facial skin tightening: Clinical study results. **Journal of Cosmetic and Laser Therapy**, v. 13, n. 2, p. 69-76, 2011.
- BRAND, Vínicius C. *Avaliação de rugas cutâneas da região periorbital baseada em processamento digital de imagens*. 2007. 76 f. Dissertação (mestrado em computação) - Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, Universidade Federal do Paraná, Curitiba. 2007.
- CHOI, Young-Hwan et al. Skin feature extraction and processing model for statistical skin age estimation. **Multimedia tools and applications**, v. 64, n. 2, p. 227-247, 2013.
- CULA, Gabriela O. et al. Assessing facial wrinkles: Automatic detection and quantification. **Photonic Therapeutics and Diagnostics**, v. 7161, 2009.
- CULA, Gabriela O. et al. Assessing facial wrinkles: automatic detection and quantification. **Skin Research and Technology**, v. 19, n. 1, p. e243-e251, 2013.
- DAY, Doris J. et al. The wrinkle severity rating scale. **American journal of clinical dermatology**, v. 5, n. 1, p. 49-52, 2004.
- FAWCETT, Tom. ROC graphs: Notes and practical considerations for researchers. **Machine learning**, v. 31, n. 1, p. 1-38, 2004.
- FABI, Sabrina et al. The Fabi–Bolton chest wrinkle scale: a pilot validation study. **Journal of cosmetic dermatology**, v. 11, n. 3, p. 229-234, 2012.

FILHO, Ogê Marques; NETO, Hugo Vieira. **Processamento digital de imagens**. Brasport, 1999.

FITZPATRICK, Richard E. et al. Pulsed carbon dioxide laser resurfacing of photoaged facial skin. **Archives of Dermatology**, v. 132, n. 4, p. 395-402, 1996.

GLOGAU, Richard G. A esthetic and anatomic analysis of the aging skin. In: **Seminars in cutaneous medicine and surgery**. No longer published by Elsevier, 1996. p. 134-138.

GONZALEZ, Rafael C.; WOODS, Richard E. Digital image processing. **Pearson Education, Inc.**, 2008.

GROVE, Gary L.; GROVE, Mary J.; LEYDEN, James J. Optical profilometry: an objective method for quantification of facial wrinkles. **Journal of the American Academy of Dermatology**, v. 21, n. 3, p. 631-637, 1989.

HARALICK, Robert M.; SHANMUGAM, Karthikeyan; DINSTEN, Its' Hak. Textural features for image classification. **Systems, Man and Cybernetics, IEEE Transactions on**, n. 6, p. 610-621, 1973.

HATZIS, John. The wrinkle and its measurement—: A skin surface Profilometric method. **Micron**, v. 35, n. 3, p. 201-219, 2004.

HAYKIN, Simon S. **Redes neurais: Principios e prática**. Bookman, 2001.

HONG, Lin; WAN, Yifei; JAIN, Anil. Fingerprint image enhancement: algorithm and performance evaluation. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 20, n. 8, p. 777-789, 1998.

HORNG, Wen-Bing; LEE, Cheng-Ping; CHEN, Chun-Wen. Classification of age groups based on facial features. *Tamkang Journal of Science and Engineering*, v. 4, n. 3, p. 183-192, 2001.

HSU, C. W. et al. A practical guide to support vector classification. 2003.

IZADPANAHI, Shima; TOYGAR, Önsen. Human age classification with optimal geometric ratios and wrinkle analysis. **International Journal of Pattern Recognition and Artificial Intelligence**, v. 28, n. 02, p. 1456003, 2014.

JAPKOWICZ, Nathalie; SHAH, Mohak. **Evaluating learning algorithms: a classification perspective**. Cambridge University Press, 2011.

KWON, Young H.; DA VITORIA LOBO, Niels. Age classification from facial images. **Computer Vision and Image Understanding**, v. 74, n. 1, p. 1-21, 1999.

LAZARUS, M. Z.; SRILAKSHMI, K.; SANDEEP, V. M. Age classification: Based on wrinkles analysis. **Int. J. Recent Innov. Trends Comput. Commun**, v. 1, p. 119-124, 2013.

LEMPERLE, Gottfried; HOLMES, Ralph E.; LEMPERLE, Steven Stefan M. A Classification of Facial Wri. **Plastic and reconstructive surgery**, v. 108, n. 6, p. 1735-1750, 2001.

LIMA, C. A. M., Comitê de Máquinas: *Uma Abordagem Unificada Empregando Máquinas de Vetores-Suporte*. 2004. 378f. Tese (Doutorado em Engenharia Elétrica) - Faculdade de Engenharia Elétrica e de Computação, Universidade Estadual De Campinas, Campinas, 2004.

LORENA, Ana Carolina; DE CARVALHO, André CPLF. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43-67, 2007.

MENDONÇA, Cosmética científica avançada. <<http://adeliamendonca.com.br/dicas/dica3.html>>. Acessado em 29-01-2016.

MITCHELL, Tom. M. **Machine Learning**. New York: McGraw Hill Science, 1997.

OTSU, N. Thresholds selection method form grey-level histograms. **IEEE Trans. On Systems, Man and Cybernetics**, v. 9, n. 1, p. 1979, 1979.

PERONA, Pietro; MALIK, Jitendra. Scale-space and edge detection using anisotropic diffusion. **Pattern Analysis and Machine Intelligence, IEEE Transactions on**, v. 12, n. 7, p. 629-639, 1990.

PINHEIRO, Maria Valéria Bussamara. A fotografia na cirurgia dermatológica e na cosmiatria–Parte II. **Surgical & Cosmetic Dermatology**, v. 5, n. 3, p. 189-198, 2013.

PINHEIRO, Maria Valéria Bussamara; CONCEIÇÃO, Vila Nova. A fotografia na cirurgia dermatológica e na cosmiatria: parte I. **Surg Cosmet Dermatol**, v. 5, n. 2, p. 101-8, 2013.

RAO, J.; EHRLICH, M.; GOLDMAN, M. P. Facial Skin Rejuvenation With a Novel Topical Compound Containing Transforming Growth Factor beta1 and Vitamin C. **COSMETIC DERMATOLOGY-CEDAR KNOLLS-**, v. 17, n. 11, p. 705-713, 2004.

MATHWORKS DOCUMENTATION, graycomatrix. Disponível em: <<http://www.mathworks.com/help/images/ref/graycomatrix.html?searchHighlight=glcm>>. Acessado em 27-07-2016.

MULLER, Klaus-Robert et al. An introduction to kernel-based learning algorithms. **Neural Networks, IEEE Transactions on**, v. 12, n. 2, p. 181-201, 2001.

SHOSHANI, David et al. The modified Fitzpatrick Wrinkle Scale: a clinical validated measurement tool for nasolabial wrinkle severity assessment. **Dermatologic Surgery**, v. 34, n. s1, p. S85-S91, 2008.

SUN, Jingjing et al. Fabric wrinkle characterization and classification using modified wavelet coefficients and support-vector-machine classifiers. **Textile Research Journal**, p. 0040517510391702, 2011.

TAMURA, Bhertha M.; ODO, Marina Y. Classificação das rugas periorbitárias e tratamento com a toxina botulínica tipo A. **Surg. cosmet. dermatol**, v. 3, n. 2, 2011.

TAKIMOTO, Hironori et al. Robust gender and age estimation under varying facial pose. **Electronics and Communications in Japan**, v. 91, n. 7, p. 32-40, 2008.

UBAID, Sithu; DAS, Shyama; IMTHIYAS, M. P. Human Age Prediction and Classification Using Facial Image. **International Journal on Computer Science and Engineering**, v. 5, n. 5, p. 357, 2013.

VAPNIK, Vladimir; CORTES, Corinna. Support-vector networks. **Machine learning**, v. 20, n. 3, p. 273-297, 1995.

VAPNIK, Vladimir N.; BOSER, Bernhard E.; GUYON, Isabelle M. A training algorithm for optimal margin classifiers. In: **Proceedings of the fifth annual workshop on Computational learning theory**. ACM, 1992. p. 144-152.

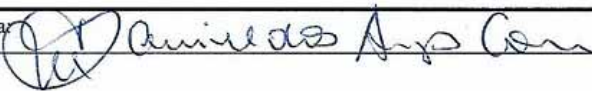
VISIA-COMPLEXION-ANALYSIS. In: Canfield Scientific, Inc. 2015. Disponível em: <<http://www.canfieldsci.com/imaging-systems/visia-complexion-analysis/>>. Acessado em 04-05-2015.

WESTON, J. e WATKINS, C. Support vector machines for multi-class pattern recognition. In: **ESANN**. 1999. p. 219-224.

YU, Wurong; YAO, Ming; XU, Bugao. 3-D surface reconstruction and evaluation of wrinkled fabrics by stereo vision. **Textile Research Journal**, v. 79, n. 1, p. 36-46, 2009.



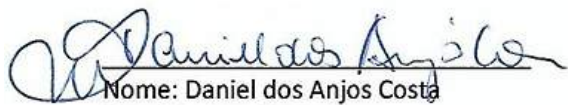
CADASTRO DE INFORMAÇÕES PARA PUBLICAÇÃO DIGITAL
NA BIBLIOTECA DIGITAL DA UFBA

1. Identificação do tipo de material	
Tese () Dissertação (X) Monografia () Trabalho de Conclusão de Curso ()	
2. Colegiado do Curso de Pós-Graduação: MECATRÔNICA	
Título: CLASSIFICAÇÃO DE RUGAS CUTÂNEAS PERIORBITAIS EM IMAGENS DIGITAIS	
Autor(a): DANIEL DOS ANJOS COSTA	
CPF: 021.011.675-73	E-mail: daniel.dosanjos@gmail.com
Orientador(a): Prof. Dr. LEIZER SCHNITMAN	
Nome: LEIZER SCHNITMAN	
CPF: 386.828.695-00	E-mail leizer@ufba.br
Co-Orientadores Prof. Dr. ANGELO AMÂNCIO DUARTE	
Nome: ANGELO AMÂNCIO DUARTE	
CPF: 365.265.415-34	E-mail angeloduarte@uefs.br
Membros da Banca	
Nome: Prof. Dr. ANGELO AMÂNCIO DUARTE	
CPF: 365.265.415-34	E-mail angeloduarte@uefs.br
Nome: Prof. Dr. MICHELE FÚLVIA ANGELO	
CPF: 265.540.938-85	E-mail mfangelo@ecomp.uefs.br
Nome: Prof. Dr. LUCIANO REBOUÇAS DE OLIVEIRA	
CPF: 673.235.295-49	E-mail luciano.reboucas@gmail.com
Nome:	
CPF:	E-mail
Data de Homologação Pós Graduação:	
Financiadores: CAPES	
Data: 05/09/2016	
Assinatura: 	

Salvador, 05/09/2016

DECLARAÇÃO

Declaro para os devidos fins que o texto final apresentado para a conclusão do meu curso de Mestrado em Mecatrônica da Universidade Federal da Bahia é de minha autoria. Declaro também que quaisquer informações utilizadas neste texto, mas que sejam provenientes de outros trabalhos tem fonte claramente expressa e, quando for o caso, foram devidamente autorizadas pelo(s) respectivo(s) autor(es).



Nome: Daniel dos Anjos Costa

CPF: 021.011.675-73