

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO CEARÁ
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E INOVAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Solon Alves Peixoto

**Classificação automática histologicamente próxima de lesões de pele
utilizando matriz de coocorrência estrutural**

Fortaleza – CE

25 de setembro de 2023

Solon Alves Peixoto

Classificação automática histologicamente próxima de lesões de pele utilizando matriz de coocorrência estrutural

Dissertação submetida ao Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará, como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Linha de Pesquisa: Inteligência Artificial

Orientador: Prof. Dr. Pedro Pedrosa Rebouças Filho

Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)

Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)

Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Fortaleza – CE

25 de setembro de 2023

Dados Internacionais de Catalogação na Publicação
Instituto Federal do Ceará - IFCE
Sistema de Bibliotecas - SIBI
Ficha catalográfica elaborada pelo SIBI/IFCE, com os dados fornecidos pelo(a) autor(a)

PEIXOTO, SOLON.

Classificação automática histologicamente próxima de lesões de pele utilizando matriz de coocorrência estrutural / SOLON PEIXOTO. - 2018.
62 f. : il. color.

Dissertação (Mestrado) - Instituto Federal do Ceará, Mestrado em Ciência da Computação, Campus Fortaleza, 2018.

Orientação: Prof. Dr. Pedro Pedrosa Rebouças Filho.

1. Structural Co-Occurrence Matrix. 2. Image Classification. 3. Machine Learning. 4. Melanoma. I.
Titulo.

CDD 004



Instituto Federal de Educação, Ciência e Tecnologia do Ceará (IFCE)
Pró-Reitoria de Pesquisa, Pós-Graduação e Inovação (PRPI)
Programa de Pós-Graduação em Ciência da Computação (PPGCC)

Solon Alves Peixoto

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Ciência da Computação, sendo aprovada pela Coordenação do Programa de Pós-Graduação em Ciência da Computação do Instituto Federal de Educação, Ciência e Tecnologia do Ceará e pela banca examinadora:

**Orientador: Prof. Dr. Pedro Pedrosa Rebouças
Filho**

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Prof. Dr. Geraldo Luis Bezerra Ramalho

Instituto Federal de Educação, Ciência e Tecnologia do
Ceará (IFCE)

Prof. Dr. Antonio Carlos da Silva Barros

Universidade da Integração Internacional da Lusofonia
Afro-Brasileira (UNILAB)

Fortaleza – CE
25 de setembro de 2023

Agradecimentos

Aos meus pais Márcia Cristina e Alexandre Domingues, pela constante dedicação em fornecer amor, incentivo e ensinamentos para a vida;

À minha adorável esposa Geísa Peixoto, que enquanto uma só carne me ama, apoia, orienta e luta diariamente ao meu lado em todos os momentos de nossas vidas;

Ao meu Orientador Prof. Dr. Pedro Pedrosa Rebouças Filho, pela gigante atenção, paciência, confiança e orientação, mostrando sempre vários lados de uma visão singular.

Ao Laboratório de Processamento de imagens , sinais e computação aplicada (LAPISCO) e todos os seus membros, pelas calorosas discussões científico-filosóficas durante o curso de mestrado;

“Haja Luz!”
Deus

Resumo

Segundo a American Cancer Society, o melanoma é um dos tipos mais comuns de câncer no mundo. Em 2017, aproximadamente 87.110 novos casos de câncer de pele foram diagnosticados apenas nos Estados Unidos. Um dermatoscópio é uma ferramenta que captura imagens de lesões com alta resolução e é uma das principais ferramentas clínicas para diagnosticar, avaliar e monitorar esta doença. Este artigo apresenta uma nova abordagem para classificar automaticamente a lesão usando Matriz Estrutural de Co-ocorrência (SCM) sobre imagens dermatoscópicas após um filtro passa-faixa utilizando a transformada de Fourier. A principal vantagem dessa abordagem consiste em transformar o SCM em um extrator de características adaptativo, melhorando seu poder de discriminação usando apenas a imagem como parâmetro. As imagens foram coletadas das bases de imagem International Skin Imaging Collaboration (ISIC) 2016, 2017 e do Hospital Pedro Hispano (PH²). Especificidade (Spe), sensibilidade (Sen), valor preditivo positivo, F Score, média harmônica, acurácia (Acc) e área sob a curva (AUC) foram utilizados para verificar a eficiência do SCM. Os resultados mostram que o SCM no domínio da frequência trabalha automaticamente, onde obteve melhores resultados em comparação com os extratores *local binary pattern*, *gray-level co-occurrence matrix* e momentos invariantes de Hu, bem como em comparação com trabalhos recentes com os mesmos conjuntos de dados.

Palavras-chave: Structural Co-Occurrence Matrix, Image Classification, Melanoma, Machine Learning.

Abstract

According to the American Cancer Society, melanoma is one of the most common types of cancer in the world. In 2017, approximately 87,110 new cases of skin cancer were diagnosed in the United States alone. A dermatoscope is a tool that captures lesion images with high resolution and is one of the main clinical tools to diagnose, evaluate and monitor this disease. This paper presents a new approach to classify lesion automatically using Structural Co-occurrence Matrix (SCM) of main frequencies extracted from dermoscopy images. The main advantage of this approach consists in transform the SCM in an adaptive feature extractor improving his power of discrimination using only the image as parameter. The images was collected from the International Skin Imaging Collaboration (ISIC) 2016, 2017 and Pedro Hispano Hospital (PH²) datasets. Specificity (Spe), sensitivity (Sen), positive predictive value, F Score, Harmonic Mean, accuracy (Acc) and area under the curve (AUC) were used to verify the efficiency of the SCM. The results show that the SCM in the frequency domain work automatically, where it obtained better results in comparison with local binary patterns, gray-level co-occurrence matrix and invariant moments of Hu as well as compared with recent works with the same datasets. The results of the proposed approach were: Spe 95.23%, 92.15% and 99.4%, Sen 94.57%, 89.9% and 99.2%, Acc 94.5%, 89.93% and 99%, and AUC 92%, 90% and 99% in ISIC 2016, 2017 and PH² datasets, respectively.

Keywords: latex. abntex. text editoration.

Lista de ilustrações

Figura 1 –	Imagens de Dermatoscopia de diferentes lesões. Algumas imagens têm uma régua e também a presença de cabelos. A régua ajuda no cálculo do tamanho da lesão.	25
Figura 2 –	Contorno da região brilhante sobre a lesão	31
Figura 3 –	O método proposto para normalização da pele. Do fundo, o primeiro passo se concentra na remoção dos principais ruídos apresentados na imagem como pêlos e gel. Em segundo lugar, as sombras dos pêlos são removidas, assim como a pele é normalizada para uma única tonalidade. A imagem superior é o resultado desse pré-processamento.	32
Figura 4 –	Etapas para a normalização da pele. Da esquerda para a direita, o cabelo foi removido e a máscara de segmentação foi aplicada. A imagem final mostra a imagem com o contraste ajustado.	33
Figura 5 –	<i>Multi-Layer Perceptron</i>	34
Figura 6 –	Modelo genérico de SCM para dois sinais de entrada. Este sinal será filtrado pela aplicação de uma função K. Em seguida, o SCM (histograma bidimensional) é criado usando o sinal original e o modificado k (g). . .	39
Figura 7 –	Processo de criação de SCM. A primeira imagem (a) está relacionada à segunda imagem (b). Neste caso, o processo imita o GLCM usando uma distância entre a posição do pixel p e a posição do pixel q usando um critério de vizinhança. (c) SCM criado.	39
Figura 8 –	Exemplo da abordagem proposta. O passo 1 indica a lesão como imagem de entrada seguindo usando as frequências principais extraídas da transformada de Fourier como função K, no passo 2. Então o SCM é criado no passo 3 usando o original e a imagem modificada. O passo 4 mostra o scm gerado.	40
Figura 9 –	Metodologia proposta. A etapa 1 armazenou inicialmente os bancos de dados seguidos pelo pré-processamento como indicado na etapa 2. Na sequência, a etapa 3 mostra a criação da matriz SCM para diferentes filtros e, finalmente, na etapa 4, a extração dos atributos	43
Figura 10 –	Aplicação do SCM com diferentes filtros. À esquerda, dermoscopia de uma lesão classificada como Não Melanoma e, à direita, Melanoma. Seguindo os passos descritos na Figura 8, 1: Imagem de Entrada (g), 2: Filtro Aplicado (k), 3: Imagem de Saída k (g).	44

Lista de tabelas

Tabela 1	– Resumo dos principais métodos utilizados para classificação de lesões de pele.	27
Tabela 2	– Resultado da classificação de imagens dermatoscópicas da base PH2 usando LBP, GLCM e HU considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F Score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação	45
Tabela 3	– Resultado da classificação de imagens dermatoscópicas da base Ph2 usando SCM considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação	46
Tabela 4	– Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2016 usando LBP, GLCM e HU considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F-score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação	47
Tabela 5	– Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2016 usando SCM considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação	48
Tabela 6	– Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2017 usando LBP, GLCM e HU considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F Score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação	49
Tabela 7	– Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2017 usando SCM considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação	52
Tabela 8	– Comparação do SCM com métodos recentes usando os mesmos conjuntos de dados e sensibilidade (Sen), especificidade (Spe), acurácia (Acc) e área sob a curva (AUC) como métricas de avaliação.	53

Lista de abreviaturas e siglas

CAD	diagnóstico auxiliado por computador
ISIC	International Skin Imaging Collaboration
Ppv	valor preditivo positivo
PH2	Hospital Pedro Hispano
SCM	Matriz Estrutural de Co-ocorrência
CNN	rede neural convolucional
Spe	Especificidade
Sen	Sensibilidade
SVM	Máquina de vetores de suporte
LS SVM	Least Square SVM
LBP	Local Binary Patterns
GLCM	Matriz de co-ocorrência entre tons de cinza
MLP	<i>Multi-Layer Perceptron</i>
MLM	<i>Minimal Learning Machine</i>
MLM-NN	<i>MLM-Nearest Neighbors</i>

Lista de símbolos

Γ	Letra grega Gama
Λ	Lambda
ζ	Letra grega minúscula zeta
$\in$	Pertence

Sumário

1	INTRODUÇÃO	25
1.1	Motivação para a Dissertação	27
1.2	Descrição do problema	28
1.3	Objetivos Geral e Específicos	28
1.4	Produção científica	28
1.5	Estrutura da Dissertação	29
2	METODOLOGIA	31
2.1	Aquisição das Imagens	31
2.2	Pré-Processamento	31
2.3	Técnicas de <i>Machine Learning</i>	33
2.3.1	Extração de Características	35
2.4	Matrix de Co-ocorrência Estrutural	38
2.4.1	Métricas	41
3	RESULTADOS	43
4	CONCLUSÃO	55
	REFERÊNCIAS	57


1 Introdução

Anualmente, milhões de pacientes são diagnosticados com câncer de pele, onde aproximadamente 132.000 destes são diagnosticados com melanoma. Isso faz com que esta doença esteja entre as patologias com as maiores taxas de mortalidade global (SONG et al., 2018). Um terço de todos os pacientes com câncer tem câncer de pele e, de acordo com as estatísticas da Skin Cancer Foundation, um em cada cinco americanos desenvolverá câncer de pele durante sua vida (LOPES; CHAMMAS; IYEYASU, 2013).

Existem vários fatores de risco que potencializam a aparência desta doença, tais como: envelhecimento, exposição aos raios ultravioletas, exposição a elementos químicos nocivos, baixa imunidade, entre outros. Em muitos casos, quando um paciente apresenta patologias que podem estar associadas a esses fatores de risco, essa patologia aparece como uma lesão cutânea.

Um dos desafios mais significativos relacionados à engenharia biomédica é identificar e classificar de maneira eficiente uma lesão de pele usando imagens dermatoscópicas. Alguns exemplos desse tipo de imagem são mostrados na Figura 1.

Figura 1 – Imagens de Dermatoscopia de diferentes lesões. Algumas imagens têm uma régua e também a presença de cabelos. A régua ajuda no cálculo do tamanho da lesão.



Fonte: Elaborada pelo autor.

Visão computacional é uma das principais ferramentas utilizadas no desenvolvimento de novas abordagens aplicadas a imagens biomédicas onde este sistema de computação

usa padrões específicos em uma imagem biomédica, muitos dos quais já são usados pelo especialista (FILHO et al., 2017b; FILHO et al., 2017a; RAMALHO et al., 2014). Como todos os fatores não relacionados ao prognóstico da doença são ignorados pelos sistemas computacionais, a possibilidade de erro é reduzida e um melhor diagnóstico clínico é oferecido com maior precisão e agilidade (RODRIGUES et al., 2016; NEW..., 2017; SOUZA et al., 2018; RODRIGUES et al., 2018).

Atualmente, os pixels das imagens dermatoscópicas fornecem informações suficientes para trabalhar em ambientes computacionais. Algumas informações são adquiridas usando métodos de extração de características baseados em cor e textura, e elas têm sido amplamente aplicadas para avaliar lesões como no caso de melanomas (RAHMAN; ALPASLAN; BHATTACHARYA, 2016).

No artigo apresentado por Kavitha e Suruliandi (KAVITHA; SURULIANDI, 2016), histogramas de cor e características de haralick foram usados com a máquina de vetores de suporte (SVM) para classificar imagens de dermoscopia em melanoma e não-melanoma. O trabalho de Gu *et al.* (GU; ZHOU; QIAN, 2017) apresentou uma abordagem baseada na distância de Mahalanobis e na fatoração de matriz não-negativa com grafismo restrito regularizado para aumentar a discriminabilidade da classificação usando informações da forma e variação de cor local.

Outras abordagens para detectar e classificar as lesões são baseadas na técnica atual usada por especialistas para o diagnóstico clínico. O objetivo é buscar os dados mais característicos nas imagens que possam ser utilizados para facilitar sua classificação utilizando a técnica conhecida como ABCD (KAVYA; SARANYA, 2016), onde 'A' significa assimetria da região, 'B' a irregularidade de sua fronteira (ou borda), 'C' a variação de cores ou intensidades de distintas áreas e 'D' sua estrutura diferencial.

Mete *et al.* (METE et al., 2016) usou o classificador SVM como uma ferramenta para comparar os tipos de lesões com base nas características extraídas pelo padrão ABCD. Uma abordagem semelhante é apresentada por Almaraz *et al.* (ALMARAZ-DAMIAN; PONOMARYOV; RENDON-GONZALEZ, 2016), mas com o foco em um sistema de diagnóstico auxiliado por computador (CAD) para classificação de lesões.

Um trabalho importante apresentado por Waheed *et al.* (WAHEED et al., 2017) mostrou que uma das características centrais usadas para classificar uma lesão são as diferenças de tons de pele na imagem. Neste caso, o espaço HSV para extração de cores pode ser mais apropriado devido à sua semelhança com a percepção humana. Kasmi *et al.* (KASMI; MOKRANI, 2016) apresentou uma técnica de remoção de pelos utilizando o filtro Gabor e a detecção da borda da lesão aplicando o contorno geodésico ativo.

Por outro lado, atualmente as técnicas da rede neural convolucional (CNN) buscam extrair as informações mais relevantes de uma imagem e generalizar a classificação da

Tabela 1 – Resumo dos principais métodos utilizados para classificação de lesões de pele.

Autor	Técnica Utilizada
(KAVITHA; SURULIANDI, 2016) (GU; ZHOU; QIAN, 2017)	Baseados em Cor e Textura
	Histograma de cor e Haralick com SVM
	Variação de cor e Distância de Mahalanobis
(YU et al., 2017a) (YU et al., 2017b) (MATSUNAGA et al., 2017) (LI; SHEN, 2017)	Baseados em CNN
	Segmentação e Classificação
	<i>Fisher Vectors</i>
	Luminância
	<i>Clustering Superpixels</i>
(METE et al., 2016) (KASMI; MOKRANI, 2016) (WAHEED et al., 2017)	Baseados em ABCD
	SVM e agrupamento de Características
	Filtro Gabor e Contorno ativo Geodésico
	Experimentos no espaço HSV

lesão (GE et al., 2017; DEMYANOV et al., 2016).

Yu *et al* (YU et al., 2017a) propôs uma abordagem CNN e criou uma estrutura de dois estágios (segmentação e classificação) para classificar a lesão automaticamente usando dados limitados de treinamento. Uma abordagem híbrida foi proposta por Yu *et al*. (YU et al., 2017b) usando o vetor CNN e Fisher para a extração das características mais representativas. Sabbaghi *et al*. (SABBAGHI; ALDEEN; GARNAVI, 2016) usava um conjunto de redes convolucionais de recursos que aprendiam com padrões de alta qualidade em imagens dermatoscópicas.

Sobre outra perspectiva, a normalização de luminância e cor é uma característica importante a ser analisada. Matsunaga *et. al* (MATSUNAGA et al., 2017) e Li *et. al* (LI; SHEN, 2017) propõe uma abordagem CNN, mas com dados de pré-processamento usando normalização de luminância de imagem e *clustering* de superpixels.

1.1 Motivação para a Dissertação

Pode-se ver que diferentes perspectivas de imagens dermatoscópicas mostram que existem padrões que permitem a classificação correta de uma lesão quando são identificados através da aplicação de filtros que destacam tais padrões. Ainda assim, estas abordagens apresentadas utilizam extratores de características que tendem a realçar um padrão específico, fazendo com que algumas características importantes não sejam utilizadas.

1.2 Descrição do problema

No artigo apresentado por Ramalho *et. al* (RAMALHO et al., 2016), a matriz estrutural de co-ocorrência (SCM) foi introduzida como um poderoso extrator de recursos que pode usar diferentes filtros para destacar um padrão específico. Este trabalho propõe uma inovação na configuração do SCM para classificação de lesões de pele. Como a lesão pode ser classificada usando diferentes padrões (como indicado pela técnica ABCD), o método proposto usa a transformada de Fourier para extrair as principais frequências da imagem e usar essa informação como entrada de filtro no SCM.

A vantagem deste modelo reside na sua capacidade de avaliar a imagem automaticamente e destacar múltiplos padrões na lesão usando apenas a informação da própria imagem.

1.3 Objetivos Geral e Específicos

Como a abordagem proposta envolve reconhecimento simultâneo de múltiplos padrões, este método pode ser uma ferramenta poderosa para o uso em sistemas que auxiliam diagnósticos clínicos. Assim, este trabalho aplica diferentes estratégias para destacar as principais características das imagens dermatoscópicas, a fim de obter diagnósticos clínicos mais precisos.

Este trabalho se concentra em:

- Os principais ruídos presentes nas imagens dermatoscópicas
- Filtros diferentes para remover os artefatos detectados
- A estrutura da lesão
- Uma nova abordagem para classificar a lesão
- Comparação com outros métodos de extração
- Comparação com resultados recentes na literatura

1.4 Produção científica

Durante este projeto de mestrado, os seguintes trabalhos científicos foram aceitos e publicados, a saber:

- **PEIXOTO, SOLON A.** ; REBOUÇAS FILHO, PEDRO P. ; SANGAIAH, A. K. ; ALBUQUERQUE, V. H. C. . Automatic classification of pulmonary disease using a Structural Co-Occurrence Matrix. NEURAL COMPUTING & APPLICATIONS, 2018.
- **PEIXOTO, SOLON A.** ; REBOUÇAS FILHO, Neurologist-level classification of stroke using a Structural Co-Occurrence Matrix based on the frequency domain.

COMPUTERS & Electrical Engineering. Volume 71, October 2018.

- **PEIXOTO, SOLON A**; MEDEIROS, ALDISIO G. ; BARROS, ANTONIO CARLOS. S. ; DE ALBUQUERQUE, VICTOR HUGO C. ; REBOUÇAS FILHO, PEDRO PEDROSA . A New Approach to Segment Hemorrhagic Stroke in Computed Tomography via Optimum Path Snakes. In: 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), 2017, Cancun.
- Rebouças Filho, Pedro Pedrosa; **PEIXOTO, S. A.** ; Nóbrega, Raul Victor M. ; HEMANTH, D. J. ; MEDEIROS, A. G. ; SANGAIAH, A. K. ; ALBUQUERQUE, V. H. C. . Automatic histologically-closer classification of skin lesions. *COMPUTERIZED MEDICAL IMAGING AND GRAPHICS*, v. 68, p. 40-54, 2018.
- MEDEIROS, A. G. ; **PEIXOTO, S. A.** ; BARROS, A. C. S. ; ALBUQUERQUE, V. H. C. ; Rebouças Filho, Pedro Pedrosa . Uma nova abordagem para a segmentação de pulmões utilizando o método de contorno ativo não paramétrico Optimum Path Snakes em imagens de tomografia computadorizada. In: 17 Workshop de Informática Médica (WIM), 2017, São Paulo. Workshop de Informática Médica (WIM), 2017. v. 17.
- NOBREGA, RAUL VICTOR MEDEIROS DA ; **PEIXOTO, SOLON ALVES** ; SILVA, SUANE PIRES P. DA ; FILHO, PEDRO PEDROSA REBOUCAS; **Lung Nodule Classification via Deep Transfer Learning in CT Lung Images**. IEEE 31st International Symposium on ComputerBased Medical Systems (CBMS), 2018, Karlstad.

1.5 Estrutura da Dissertação

Este trabalho apresenta no Capítulo 2 a metodologia utilizada para obter os resultados incluindo a aquisição de imagens, pré-processamento, métodos de extração de características e técnicas de classificação, bem como a apresentação da inovação no Configuração do SCM. Os resultados são apresentados e discutidos no Capítulo 3 comparando com outras configurações e com abordagens recentes.

2 Metodologia

2.1 Aquisição das Imagens

As imagens utilizadas neste trabalho foram retiradas das bases de imagens PH2 (MENDONÇA et al., 2013), ISIC 2016 (GUTMAN et al., 2016) e ISIC 2017 (CODELLA et al., 2017), totalizando 3.100 imagens dermatoscópicas. Com exceção da base de imagens PH2, as imagens contidas nas outras bases de imagens têm tamanhos diferentes bem como disposição não padronizada da lesão na imagem e outros ruídos, como adesivos e régua. Neste estudo, as imagens das lesões de melanoma e não-melanoma foram classificadas histologicamente.

2.2 Pré-Processamento

Algumas das imagens dermatoscópicas possuem uma região brilhante como indicado na Figura 2. Esta região brilha devido à presença de um gel aplicado no momento do exame por um especialista. Como a única região de interesse é a lesão, o gel e os pêlos, neste caso, são ruídos e, portanto, foram removidos da imagem.

Figura 2 – Contorno da região brilhante sobre a lesão




Fonte: Elaborada pelo autor.

Depois de aplicar a máscara de segmentação, o pré-processamento da imagem é

finalizado ajustando o contraste entre as imagens. Como também percebido por Kawahara et al. (KAWAHARA; BENTAIEB; HAMARNEH, 2016), a diferença no tom da pele de cada pessoa também tem uma influência negativa nos resultados e, portanto, também é caracterizada como um ruído. Nesse caso, uma normalização média foi aplicada a cada imagem. O pré-processamento foi realizado para a normalização da imagem, como mostrado na Figura 3.

Figura 3 – O método proposto para normalização da pele. Do fundo, o primeiro passo se concentra na remoção dos principais ruídos apresentados na imagem como pêlos e gel. Em segundo lugar, as sombras dos pêlos são removidas, assim como a pele é normalizada para uma única tonalidade. A imagem superior é o resultado desse pré-processamento.




Fonte: Elaborada pelo autor.

Houve uma grande variação nos tamanhos das imagens dermatoscópicas nos conjuntos de dados ISIC 2016 e ISIC 2017; portanto, o tamanho dessas imagens foi alterado para aproximadamente 760x570 pixels. Os valores foram baseados no tamanho médio das imagens no conjunto de dados PH2. O processamento de cada imagem foi o seguinte:

1. Redimensionamento de imagem
2. Transformação para tom de cinza
3. Remoção de ruído
4. Máscara de segmentação
5. Ajuste de contraste

Para adaptar as imagens aos extratores de características utilizados neste trabalho, as imagens redimensionadas foram transformadas em tons de cinza e posteriormente processadas de acordo com a sequência de 1 a 5, conforme ilustrado na Figura 4.

Figura 4 – Etapas para a normalização da pele. Da esquerda para a direita, o cabelo foi removido e a máscara de segmentação foi aplicada. A imagem final mostra a imagem com o contraste ajustado.



Fonte: Elaborada pelo autor.


2.3 Técnicas de Machine Learning

Neste trabalho, diferentes técnicas de Aprendizado de Máquina foram utilizadas para avaliar a eficiência dos extratores de características.

Multi-Layer Perceptron (MLP) é um modelo de classificação baseado em redes neurais, supervisionado, que fornece um novo filtro na sua saída após o processo de

treinamento. Inicialmente, ao modelo é apresentado algumas amostras de uma variável aleatória, normalmente em forma de vetor. Um processo de ajuste de pesos é iniciado utilizando o valor de saída da função e um valor esperado que compara a divergência entre os sinais. É fácil perceber que o objetivo principal é minimizar esse erro ou que a divergência apresentada pela comparação seja mínima. Esse processo ocorre ao longo de toda rede formada por várias camadas de neurônios, como ilustrado na Figura 5 com o objetivo de minimizar o erro entre uma função estimada e a função real.

Figura 5 – *Multi-Layer Perceptron*.



Fonte: (MARINHO, 2016)

Esta rede é dividida em três camadas principais: Entrada, Oculto e Saída. A camada de entrada é o ponto de partida para a análise de conteúdo. Em seguida, na camada oculta, ocorre a ativação de neurônios subsequentes, onde cada ligação entre os neurônios tem um peso associado. Quando o impulso finalmente chega à camada de saída através das funções de ativação, a camada de saída retorna o resultado da operação (S; HAYKIN, 2009).

Um hiperplano é usado para separar duas classes usando o SVM da regressão análise onde ele pode traçar um "eixo" entre as classes de tal maneira que o A análise é o mais eficiente possível. Uma das vantagens deste classificador é a robustez na presença de ruído nos dados [32]. Uma função de otimização J foi exigido para reduzir o risco entre os limites da classificação e sua apresentado por:

$$J(w, \xi) = \frac{1}{2} w^T w + c \sum_{i=1}^N \xi_i \quad (2.1)$$

aplicado em :

$$y_i[w^T \phi(x_i) + b] \geq 1 - \xi_i, i = 1, \dots, N, \xi_i \geq 0, i = 1, \dots, N \quad (2.2)$$

onde ω estende para multiplicadores de Lagrange, ξ_i como variável slack e c como parâmetro hyper.

Uma variação do SVM é o SVM do Least Square (LS SVM). Este classificador modifica a equação original proposta pelo Vapnik (VAPNIK; VAPNIK, 1998; SOUZA; ALMEIDA; FILHO, 2017). Neste caso, uma substituição é feita na equação de mínimos quadrados, mantendo a eficiência do classificador como apresentado na Equação 2.3.

$$J(w, b, e) = \frac{1}{2}w^T w + \gamma \frac{1}{2} \sum_{i=1}^N e_i^2 \quad (2.3)$$

aplicado em :

$$y_i[w^T \phi(x_i) + b] = 1 - e_i, i = 1, \dots, N \quad (2.4)$$

Nesse caso, e é a unidade de erro e γ indica o parâmetro de regularização (SAMUI; KOTHARI, 2011).

O algoritmo de classificação do Minimal Learning Machine (MLM) é um método recente de Aprendizado de Máquina baseado no mapeamento entre pontos nos espaços de entrada e saída. Este mapeamento representa a distância de cada ponto para k pontos escolhidos aleatoriamente. No processo de treinamento, a matriz de distância é multiplicada por um componente de distância estimado y .

Essa operação gera o modelo de distância para cada ponto. Essa distância representa um valor para a classe na qual o ponto pertence. Finalmente, a operação de teste é reduzida para escolher a distância mais curta para os outros pontos. A distância mais curta corresponderá à classe que será atribuída (SOUZA et al., 2015; A..., 2017).

Mesquita *et. al* (MESQUITA; GOMES; JUNIOR, 2015) propôs uma variação do MLM onde varia o cálculo do componente e e usa o *K Nearest Neighbors*. O processo de testar um novo evento ocorre escolhendo a classe com base no voto majoritário do vizinho K . Neste trabalho, essa variação é chamada MLM-*Nearest Neighbors* (MLM-NN).

2.3.1 Extração de Características

Técnicas de extração foram desenvolvidas, a partir de diferentes perspectivas, para detectar atributos e características específicas em uma imagem. Esses atributos estão relacionados à percepção do especialista e tendem a mimetizar a abordagem ABCD. Os extratores usados neste trabalho são baseados principalmente em dois tipos: Moments and Texture, conforme discutido abaixo.

HU (HU, 1962) propôs um modelo para utilizar momentos centrais na mudança de escala e rotação de uma imagem a partir da normalização de cada um deles. Essa técnica, conhecida como HU Moments, pode descrever sete momentos invariáveis de similaridade, tamanho, rotação e translação após os momentos centrais normalizados da ordem p e q , η_{pq} , apresentados pela Equação 2.5

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}} \quad (2.5)$$

onde

$$\gamma = \frac{p+q}{2}; \forall p+q \geq 2 \quad (2.6)$$

Então, os sete momentos são calculados seguindo usando seu resultado como atributo de imagem. Esses sete momentos são descritos como

- $I_1 = \eta_{20} + \eta_{02}$
- $I_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$
- $I_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$
- $I_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$
- $I_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$
- $I_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03})$
- $I_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] - (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]$

Haralick *et al.* (HARALICK; SHANMUGAM et al., 1973) mostra que o uso de métodos estatísticos na matriz de co-ocorrência de nível de cinza (GLCM) fornece uma associação dependente entre os pixels. A partir desta matriz de co-ocorrência, é possível extrair 14 descritores originais descritos abaixo. Para cada item nas seguintes equações:

- $p(i, j)$: (i, j) -th entrada em uma matriz de nível de cinza padronizada $g(i, j)/N$;
- $p_x(i)$: i -th entrada numa matriz de probabilidade marginal obtida pela soma das linhas de $p(i, j)$, $\sum_{j=1}^L p(i, j)$;
- L : Número de níveis de cinza na imagem quantizada;
- $\sum_i$ e $\sum_j$: forma simplificada de $\sum_{i=1}^L$ e $\sum_{j=1}^L$, respectivamente;
- $p_{x+y}(k) = \sum_{i=1}^L \sum_{\substack{j=1, \\ i+j=k}}^L p(i, j)$ para $k = 2, 3, \dots, 2L$;
- $p_{x-y}(k) = \sum_{i=1}^L \sum_{\substack{j=1, \\ |i-j=k|}}^L p(i, j)$ para $k = 0, 1, \dots, 2L - 1$.
- Segundo Momento Angular:

$$f_1 = \sum_i \sum_j [p(i, j)]^2. \quad (2.7)$$

- Contraste:

$$f_2 = \sum_{k=0}^{L-1} k^2 [p_{x-y}(k)]. \quad (2.8)$$

- Correlação:

$$f_3 = \frac{\sum_i \sum_j (i, j) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}, \quad (2.9)$$

onde μ_x, μ_y, σ_x e σ_y significam média, e desvio padrão de p_x e p_y .

- Soma dos quadrados: Variância

$$f_4 = \sum_i \sum_j (i - \mu)^2 p(i, j). \quad (2.10)$$

- Momento de Diferença Inversa:

$$f_5 = \sum_i \sum_j \frac{1}{1 + (i + j)^2} p(i, j) \quad (2.11)$$

- Média da soma:

$$f_6 = \sum_{i=2}^{2L} i p_{x+y}(i). \quad (2.12)$$

- Soma da Variância:

$$f_7 = \sum_{i=2}^{2L} (i - f_6)^2 p_{x+y}(i). \quad (2.13)$$

- Soma da Entropia

$$f_8 = - \sum_{i=2}^{2L} p_{x+y}(i) \log [p_{x+y}(i)]. \quad (2.14)$$

- Entropia:

$$f_9 = - \sum_i \sum_j p(i, j) \log [p(i, j)]. \quad (2.15)$$

- Diferença da Variância:

$$f_{10} = \text{variância } dep_{x+y}. \quad (2.16)$$

- Diferença da Entropia:

$$f_{11} = - \sum_{i=0}^{L-1} p_{x-y} \log [p_{x-y}(i)]. \quad (2.17)$$

- Info. Medida de Correlação (1 e 2):

$$f_{12} = \frac{HXY - HXY1}{\max [HX, HY]}, \quad (2.18)$$

$$f_{13} = 1 - \exp [-2.0(HXY2 - HXY)]^{1/2}, \quad (2.19)$$

onde:

- $HXY = - \sum_i \sum_j p(i, j) \log [p(i, j)];$
- HX e HY são entropia de p_x e p_y ;

- $HXY1 = - \sum_i \sum_j p(i, j) \log [p_x(i)p_y(j)];$
- $HXY2 = - \sum_i \sum_j p_x(i)p_y(j) \log [p_x(i)p_y(j)].$
- Max. Coeficiente de correlação

$$f_{14} = (\text{Raiz quadrada do maior autovalor } \mathbf{Q})^{1/2}, \quad (2.20)$$

onde:

$$\mathbf{Q} = \sum_k \frac{p(i, k)p(j, k)}{p_x(i)p_y(k)}. \quad (2.21)$$


Usando a análise de textura de uma imagem, Ojala *et. al* (OJALA; PIETIKAINEN; HARWOOD, 1994) formulou um extrator de recursos chamado Local Binary Patterns (LBP). Esse extrator analisa a vizinhança de um pixel classificando cada pixel em uma forma binária. A marcação de cada vizinho é feita a partir do valor do pixel central, onde é visto como um limite. Assim, pixels acima desse valor serão representados por 1 ou 0. Em seguida, um código é gerado pela representação de 8 bits que é o valor da textura. O presente trabalho aplicou um padrão uniforme deste extrator (LBP) para apresentar 59 atributos únicos (BRAZILIAN..., 2015; FILHO et al., 2017c; DEVELOPMENT..., 2018).

2.4 Matrix de Co-ocorrência Estrutural

Este trabalho propõe uma nova e eficiente abordagem para extração de características em imagens dermatoscópicas. Esta abordagem é baseada no SCM projetado por Ramalho *et. al* (RAMALHO et al., 2016).

O SCM ajuda a melhorar a identificação de estruturas de um objeto aplicando uma função de realce k a ele, como mostrado na Figura 6. Esta função é definida de acordo com a necessidade de cada problema e quando associada a imagens, k é um filtro onde serão destacadas as características mais importantes dessa imagem (RAMALHO et al., 2016).


Figura 6 – Modelo genérico de SCM para dois sinais de entrada. Este sinal será filtrado pela aplicação de uma função K . Em seguida, o SCM (histograma bidimensional) é criado usando o sinal original e o modificado $k(g)$.



Fonte: (RAMALHO et al., 2016).

O SCM usa a imagem original e a imagem filtrada em que cada pixel da imagem original será relacionado a um pixel da imagem filtrada de acordo com algum critério de vizinhança. A Figura 7 ilustra o comportamento e a criação da matriz de co-ocorrência estrutural.

Figura 7 – Processo de criação de SCM. A primeira imagem (a) está relacionada à segunda imagem (b). Neste caso, o processo imita o GLCM usando uma distância entre a posição do pixel p e a posição do pixel q usando um critério de vizinhança. (c) SCM criado.




Fonte: (RAMALHO et al., 2016).

Este trabalho propõe uma inovação na configuração do SCM modificando a imagem de entrada em função de k no domínio da frequência usando a transformada de Fourier. A imagem resultante $K(g)$ mostra as principais características estruturais da imagem, impli-

cando, assim, um aprimoramento mais efetivo pelo SCM. Um exemplo dessa abordagem está presente na Figura 8.

Figura 8 – Exemplo da abordagem proposta. O passo 1 indica a lesão como imagem de entrada seguindo usando as frequências principais extraídas da transformada de Fourier como função K, no passo 2. Então o SCM é criado no passo 3 usando o original e a imagem modificada. O passo 4 mostra o scm gerado.



Fonte: Elaborada pelo autor.

Essa técnica consiste em extrair, do espectro de magnitude, apenas as frequências que possuem uma intensidade de pelo menos 1 % do componente DC principal e, portanto, apenas as estruturas mais importantes da imagem permanecerão no espectro (FISHER et al., 1994). Nesse caso, a função k se comporta, para cada magnitude, de acordo com a seguinte equação:

$$k(x, y) = \begin{cases} m(x, y), m(x, y) \geq DC/100 \\ 0, \text{ caso contrário,} \end{cases} \quad (2.22)$$

Onde $m(x, y)$ é a magnitude do componente analisado no ponto (x, y) do espectro. A função k no domínio da frequência obtém um comportamento dinâmico que se ajusta às principais estruturas presentes na imagem e é, portanto, uma poderosa função capaz de atuar em diferentes bandas simultaneamente.

O SCM finalmente recebe $K(g)$, gerado a partir da transformada inversa do domínio da frequência, no domínio espacial e continua o processo de criação da matriz. O extrato de SCM de sua matriz 9 atributos divididos em 3 grupos: estatístico, divergente e informação. No grupo estatístico estão incluídas a correlação (COR), momento de diferença inversa (IDM), entropia (ENT). O grupo divergente apresenta a divergência de Kullback & Leibler (DKL) e a diferença absoluta complementar (CAD). O grupo de informação apresenta

a distância qui-quadrado (CSD), razão de distância qui-quadrado (CSR) e relação de diferença absoluta média (MDR) (RAMALHO et al., 2016).

2.4.1 Métricas

A comparação entre os resultados do SCM com outros métodos utilizou as métricas de avaliação com base nos resultados da classificação da matriz de confusão. Os resultados da matriz de confusão incluem Verdadeiro Positivo (VP), Verdadeiro Negativo (VN), Falso Positivo (FP) e Falso Negativo (FN), alguns dos quais foram usados para as métricas de avaliação.

Especificidade (Spe) é a métrica que mede a proporção dos resultados classificados como negativos entre todos os resultados que são realmente negativos e é apresentada pela Equação 2.23. No caso da classificação da lesão de pele, essa métrica corresponde à porcentagem correta do paciente que realmente não tem câncer.

$$Spe = \frac{VN}{VN + FP} \quad (2.23)$$

A sensibilidade (Sen) representa a proporção dos resultados classificados como positivos entre todos os resultados que são realmente positivos e apresentados pela Equação 2.24. Em problemas diagnósticos, essa é uma das métricas mais importantes, indicando se o paciente tem a doença. Pode-se ver que, se a classificação não é correta, o paciente não é mais tratado, pois é informado de que não tem doença.

$$Sen = \frac{VP}{VP + FN} \quad (2.24)$$

O valor preditivo positivo (Ppv) é a probabilidade de positivos verdadeiros em relação a todos os resultados classificados como positivos e é apresentado pela Equação 2.25. Mesmo que o diagnóstico do teste seja positivo, essa métrica calcula a probabilidade de o teste ser coerente com a probabilidade anterior.

$$Ppv = \frac{VP}{VP + FP} \quad (2.25)$$

Como contraponto ao Ppv, considerando seu risco de desequilíbrio, o F Score calcula o valor harmônico médio ponderado entre Ppv e Sen e é apresentado pela Equação 2.26. Isso representa o desempenho do método, pois, embora um diagnóstico seja classificado com precisão, ele não indica que terá o mesmo desempenho para os outros dados.

$$FScore = \frac{2 * Sen * Ppv}{Sen + Ppv} \quad (2.26)$$

Neste trabalho a média harmônica (Hm) da especificidade e da sensibilidade também foram calculadas e apresentadas pela Equação 2.27. Essa métrica representa se toda a classificação é balanceada.

$$Hm = \frac{2 * Sen * Esp}{Sen + Esp} \quad (2.27)$$

A Precisão (Acc) revela a proximidade do resultado ao padrão-ouro pela relação entre os acertos e o conjunto de possibilidades de erros e exatidão e é apresentada pela Equação 2.28.

$$Acc = \frac{VP + VN}{VP + VN + VP + VN} \quad (2.28)$$


A área sobre a curva (AUC), de uma forma geral, busca a validação do método através do seu desempenho associando a sensibilidade com a sensibilidade. O desempenho do algoritmo nesse caso é apresentado pelas Equações definido em 2.29

$$AUC = \frac{Spe + Sen}{2} \quad (2.29)$$

3 Resultados

Considerando as métricas Spe, Sen, Ppv, F Score, Hm e Acc e as imagens dermatoscópicas, esta seção é dividida em 2 etapas, a primeira etapa é a avaliação do SCM em comparação com os métodos de extração descritos na seção 2.3.1 e o segundo passo a avaliação do SCM com trabalhos recentes relacionados. Todo o processo relacionado ao SCM é apresentado na Figura 9.

Figura 9 – Metodologia proposta. A etapa 1 armazenou inicialmente os bancos de dados seguidos pelo pré-processamento como indicado na etapa 2. Na sequência, a etapa 3 mostra a criação da matriz SCM para diferentes filtros e, finalmente, na etapa 4, a extração dos atributos




Fonte: Elaborada pelo autor.

Os hiperparâmetros para o MLP, SVM e LSSVM foram selecionados a partir da validação cruzada com 10-folds. Tanto o SVM quanto o LSSVM foram treinados pela caixa de ferramentas SVM Matlab 2015a. Para cada hiper-parâmetro, uma busca de log gulosa foi usada entre 2^2 and 2^{11} . Para essas configurações, tanto o kernel Linear quanto o kernel da função Radial Basis foram usados. O MLP foi treinado usando a otimização Levenberg-Marquardt e a camada Oculto variou de 1 a 50. Para todos os conjuntos de dados, o SCM foi testado com os filtros Gaussian, Laplacian e Sobel com diferentes tamanhos de kernel (3x3 até 15x15). O filtro gaussiano variou de 0,5 a 5 como seu desvio padrão. Este trabalho apresenta apenas os melhores resultados de cada configuração.

O processo para cada um dos filtros usados neste trabalho é ilustrado na Figura 10. Cada um dos filtros usados modifica a estrutura da imagem, onde o SCM posteriormente destaca os recursos mais relevantes em cada combinação de imagem original e imagem filtrada.

Figura 10 – Aplicação do SCM com diferentes filtros. À esquerda, dermoscopia de uma lesão classificada como Não Melanoma e, à direita, Melanoma. Seguindo os passos descritos na Figura 8, 1: Imagem de Entrada (g), 2: Filtro Aplicado (k), 3: Imagem de Saída k (g).



Fonte: Elaborada pelo autor.

Tabela 2 mostra os resultados da classificação usando o conjunto de dados PH2 com os métodos de extração clássicos LBP (OJALA; PIETIKAINEN; HARWOOD, 1994), HU (HU, 1962) e GLCM (HARALICK; SHANMUGAM et al., 1973). Os atributos extraídos do LBP foram superiores aos demais métodos, onde os valores máximos das características foram do classificador MLM, utilizando as distâncias Cityblock e Euclidean em todas as métricas de avaliação.

O resultado de acurácia de 98,33 % pode indicar que a textura avaliada pluri-lateralmente apresenta maior grau de discriminação do que com GLCM, mas também reforça a técnica utilizada pelos especialistas desde que a normalização do tom da pele tenha ajudado a LBP a alcançar um resultado mais próximo o método ABCD. Quanto à especificidade e sensibilidade, a lombalgia também teve um resultado equilibrado, não favorecendo a classe maligna ou benigna da lesão com 98,8 % e 98,33 % respectivamente, o que também reforça sua capacidade de discriminar os dados. O resultado do aplicativo GLCM no conjunto de dados PH2 ilustra que, apesar da eficiência do método, ele apresenta resultados gerais inferiores aos da LBP. Por hipótese, analisando o comportamento do extrator, esses dados indicam que em algum momento pode estar perdendo informações devido a sua relação unilateral entre os pixels para a criação da matriz de coocorrência.

Com exceção do Linear SVM e Linear LSSVM, Moments of HU não mostraram

Tabela 2 – Resultado da classificação de imagens dermatoscópicas da base PH2 usando LBP, GLCM e HU considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F Score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação

Feature	Classifier	Setup	Spe(%)	Sen(%)	Ppv(%)	F score(%)	Hm(%)	Acc(%)
LBP	mlm	cityblock	98.8 ± 0.02	98.33 ± 0.03	98.61 ± 0.02	98.34 ± 0.03	98.46 ± 0.03	98.33 ± 0.03
		euclidean	98.7 ± 0.02	98.23 ± 0.01	98.31 ± 0.04	98.44 ± 0.05	98.56 ± 0.01	98.13 ± 0.07
		mahalanobis	9.62 ± 0.3	50.83 ± 0.02	99.3 ± 0.02	66.7 ± 0	7.05 ± 0.22	50.83 ± 0.02
		mahalanobis	9.65 ± 0.1	51.83 ± 0.01	99.1 ± 0.02	62.7 ± 0.02	7.02 ± 0.62	53.83 ± 0.01
	mlmNN	cityblock	98.8 ± 0.02	98.33 ± 0.03	98.61 ± 0.02	98.34 ± 0.03	98.46 ± 0.03	98.33 ± 0.03
		euclidean	98.8 ± 0.02	98.33 ± 0.03	98.61 ± 0.02	98.34 ± 0.03	98.46 ± 0.03	98.33 ± 0.03
	svm	Linear	97.97 ± 0.01	96.66 ± 0.02	97.5 ± 0.02	96.72 ± 0.02	97.03 ± 0.02	96.66 ± 0.02
		RBF	97.97 ± 0.01	96.66 ± 0.02	97.5 ± 0.02	96.72 ± 0.02	97.03 ± 0.02	96.66 ± 0.02
	mlp		97.73 ± 0.03	95.83 ± 0.07	97.08 ± 0.04	95.93 ± 0.06	96.37 ± 0.06	95.83 ± 0.07
		RBF	95.83 ± 0.02	94.16 ± 0.04	95.13 ± 0.03	94.2 ± 0.03	94.61 ± 0.03	94.16 ± 0.04
	lssvm		94.28 ± 0.03	90 ± 0.06	92.77 ± 0.04	90.21 ± 0.06	91.2 ± 0.05	90 ± 0.06
		linear						
	bayes		0 ± 0	50 ± 0	100 ± 0	66.66 ± 0	0 ± 0	50 ± 0
GLCM	MLM-NN	mahalanobis	95.71 ± 0.03	90.83 ± 0.09	94.3 ± 0.05	91.23 ± 0.09	92.26 ± 0.08	90.83 ± 0.09
		cityblock	91.07 ± 0.07	89.16 ± 0.07	90.41 ± 0.07	89.26 ± 0.07	89.7 ± 0.07	89.16 ± 0.07
		euclidean	92.16 ± 0.06	87.5 ± 0.08	90.69 ± 0.06	87.8 ± 0.07	88.84 ± 0.07	87.5 ± 0.08
		Euclidean	92.16 ± 0.06	87.5 ± 0.08	90.69 ± 0.06	87.8 ± 0.07	88.84 ± 0.07	87.5 ± 0.08
	MLM	mahalanobis	95.71 ± 0.03	90.83 ± 0.09	94.3 ± 0.05	91.23 ± 0.09	92.26 ± 0.08	90.83 ± 0.09
		Cityblock	91.07 ± 0.07	89.16 ± 0.07	90.41 ± 0.07	89.26 ± 0.07	89.7 ± 0.07	89.16 ± 0.07
	mlp		90.95 ± 0.05	78.33 ± 0.08	88.05 ± 0.04	79.79 ± 0.07	82.15 ± 0.06	78.33 ± 0.08
		rbf	91.69 ± 0.07	88.33 ± 0.08	90.55 ± 0.07	88.51 ± 0.07	89.28 ± 0.07	88.33 ± 0.08
	svm	linear	89.96 ± 0.09	84.16 ± 0.1	88.47 ± 0.08	84.64 ± 0.1	85.88 ± 0.09	84.16 ± 0.1
		rbf	94.04 ± 0.03	88.33 ± 0.08	92.22 ± 0.04	88.7 ± 0.07	89.97 ± 0.06	88.33 ± 0.08
	lssvm		91.45 ± 0.07	85 ± 0.1	89.72 ± 0.07	85.57 ± 0.09	86.91 ± 0.08	85 ± 0.1
		linear						
	bayes		90.47 ± 0.06	87.5 ± 0.08	89.58 ± 0.06	87.72 ± 0.07	88.36 ± 0.07	87.5 ± 0.08
HU	svm	linear	91.9 ± 0.03	83.33 ± 0.07	89.44 ± 0.04	84.02 ± 0.07	85.84 ± 0.06	83.33 ± 0.07
		rbf	66.1 ± 0.45	62.5 ± 0.13	93.75 ± 0.04	71.13 ± 0.07	53.4 ± 0.37	62.5 ± 0.13
	lssvm	linear	92.14 ± 0.06	79.16 ± 0.11	89.3 ± 0.06	80.73 ± 0.1	83.3 ± 0.08	80.83 ± 0.09
		RBF	89.02 ± 0.07	80.83 ± 0.09	87.08 ± 0.07	81.71 ± 0.08	83.11 ± 0.09	79.16 ± 0.11
	mlp		77.74 ± 0.3	72.5 ± 0.16	86.25 ± 0.13	75.95 ± 0.13	70.71 ± 0.27	72.5 ± 0.16
		euclidean	67.97 ± 0.13	66.66 ± 0.11	68.61 ± 0.11	67 ± 0.11	67.08 ± 0.12	66.66 ± 0.11
	mlm	mahalanobis	67.97 ± 0.13	66.66 ± 0.11	68.61 ± 0.11	67 ± 0.11	67.08 ± 0.12	66.66 ± 0.11
		cityblock	70.15 ± 0.11	68.33 ± 0.1	70.83 ± 0.1	68.78 ± 0.09	68.95 ± 0.1	68.33 ± 0.1
	mlmNN	cityblock	70.15 ± 0.11	68.33 ± 0.1	70.83 ± 0.1	68.78 ± 0.09	68.95 ± 0.1	68.33 ± 0.1
		euclidean	67.97 ± 0.13	66.66 ± 0.11	68.61 ± 0.11	67 ± 0.11	67.08 ± 0.12	66.66 ± 0.11
	lssvm	mahalanobis	67.97 ± 0.13	66.66 ± 0.11	68.61 ± 0.11	67 ± 0.11	67.08 ± 0.12	66.66 ± 0.11
	bayes		48.1 ± 0.5	54.16 ± 0.04	96.52 ± 0.03	66.87 ± 0	35.29 ± 0.37	54.16 ± 0.04

resultados significativos para LBP e GLCM. Observando a especificidade, os resultados dos classificadores mostram uma tendência maior a classificar a lesão como não-melanoma.

O SCM apresentou os melhores resultados para os resultados da classificação da lesão apresentados na Tabela 2. A tabela 3 ilustra os resultados das métricas de melanoma do SCM aplicado ao conjunto de dados PH2.

Os valores mais altos do SCM com a função k no domínio da frequência usando SVM Linear e RBF respectivamente tiveram uma especificidade e sensibilidade de 99,4 % e 99,16 %, além de PPV e F-score de 99,3 % e 99.17 % indicando resultados consistentes. Esta técnica também mostrou uma alta acurácia de 99,16 % indicando a eficiência deste extrator. Curiosamente, uma vez que o espectro de magnitude tem frequências mais próximas do componente DC e, portanto, baixas frequências, os filtros de alta frequência de Laplace e Sobel também mostraram altas taxas de acerto. Esse resultado mostra que o melanoma

Tabela 3 – Resultado da classificação de imagens dermatoscópicas da base Ph2 usando SCM considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação

Filter	Classifier	Setup	Spe(%)	Sen(%)	Ppv(%)	F score(%)	Hm(%)	Acc(%)
Fourier	SVM	Linear	99.3 ± 0.01	99.15 ± 0.02	99.2 ± 0.07	99.37 ± 0.01	99.13 ± 0.03	99.46 ± 0.01
		RBF	99.4 ± 0.03	99.16 ± 0.05	99.3 ± 0.04	99.17 ± 0.05	99.23 ± 0.05	99.16 ± 0.05
	LSSVM	Linear	95.71 ± 0.03	91.66 ± 0.08	94.44 ± 0.05	91.94 ± 0.08	92.83 ± 0.07	91.66 ± 0.08
		RBF	96.78 ± 0.03	95 ± 0.05	96.11 ± 0.04	95.07 ± 0.05	95.49 ± 0.05	95 ± 0.05
	MLM	Cityblock	96.19 ± 0.03	94.16 ± 0.05	95.41 ± 0.04	94.24 ± 0.05	94.72 ± 0.04	94.16 ± 0.05
		Euclidean	96.19 ± 0.03	94.16 ± 0.05	95.41 ± 0.04	94.24 ± 0.05	94.72 ± 0.04	94.16 ± 0.05
		Mahalanobis	96.19 ± 0.03	94.16 ± 0.05	95.41 ± 0.04	94.24 ± 0.05	94.72 ± 0.04	94.16 ± 0.05
	MLM-NN	Cityblock	96.19 ± 0.03	94.16 ± 0.05	95.41 ± 0.04	94.24 ± 0.05	94.72 ± 0.04	94.16 ± 0.05
		Euclidean	96.19 ± 0.03	94.16 ± 0.05	95.41 ± 0.04	94.24 ± 0.05	94.72 ± 0.04	94.16 ± 0.05
	MLP	Euclidean	96.19 ± 0.03	94.16 ± 0.05	95.41 ± 0.04	94.24 ± 0.05	94.72 ± 0.04	94.16 ± 0.05
		Mahalanobis	96.19 ± 0.03	94.16 ± 0.05	95.41 ± 0.04	94.24 ± 0.05	94.72 ± 0.04	94.16 ± 0.05
	Bayes		97.38 ± 0.03	95.83 ± 0.05	96.8 ± 0.04	95.89 ± 0.05	96.26 ± 0.05	95.83 ± 0.05
Gaussian	Bayes		97.97 ± 0.03	95.83 ± 0.08	97.36 ± 0.04	96.01 ± 0.07	96.46 ± 0.06	95.83 ± 0.08
	LSSVM	Linear	78.36 ± 0.12	70.83 ± 0.09	77.91 ± 0.1	71.97 ± 0.09	73.24 ± 0.1	70.83 ± 0.09
		RBF	83.77 ± 0.1	75 ± 0.08	82.22 ± 0.08	76.18 ± 0.07	77.71 ± 0.07	75 ± 0.08
		Cityblock	75.78 ± 0.14	69.16 ± 0.08	76.8 ± 0.09	70.64 ± 0.07	71.2 ± 0.09	69.16 ± 0.08
	MLM	Euclidean	79.53 ± 0.13	72.5 ± 0.1	78.47 ± 0.11	73.44 ± 0.1	74.68 ± 0.1	72.5 ± 0.1
		Mahalanobis	77.69 ± 0.11	71.66 ± 0.08	77.22 ± 0.09	72.47 ± 0.07	73.57 ± 0.08	71.66 ± 0.08
	MLM-NN	Cityblock	79.7 ± 0.09	75.83 ± 0.07	79.02 ± 0.08	76.23 ± 0.07	77.02 ± 0.07	75.83 ± 0.07
		Euclidean	79.53 ± 0.13	72.5 ± 0.1	78.47 ± 0.11	73.44 ± 0.1	74.68 ± 0.1	72.5 ± 0.1
	MLP	Mahalanobis	77.69 ± 0.11	71.66 ± 0.08	77.22 ± 0.09	72.47 ± 0.07	73.57 ± 0.08	71.66 ± 0.08
			66.97 ± 0.29	64.16 ± 0.11	79.02 ± 0.13	67.77 ± 0.09	61.61 ± 0.24	64.16 ± 0.11
	SVM	Linear	78.09 ± 0.11	71.66 ± 0.08	77.77 ± 0.08	72.7 ± 0.07	73.71 ± 0.08	71.66 ± 0.08
		RBF	80.35 ± 0.11	69.16 ± 0.06	79.58 ± 0.08	71.21 ± 0.05	72.74 ± 0.06	69.16 ± 0.06
Laplace	Bayes		90.5 ± 0.08	79.16 ± 0.11	88.19 ± 0.07	80.78 ± 0.09	82.63 ± 0.09	79.16 ± 0.11
	LSSVM	Linear	93.11 ± 0.06	87.5 ± 0.1	91.52 ± 0.07	87.95 ± 0.1	89.15 ± 0.09	87.5 ± 0.1
		RBF	83.9 ± 0.1	80 ± 0.08	82.77 ± 0.09	80.26 ± 0.08	81.13 ± 0.09	80 ± 0.08
		Cityblock	86.07 ± 0.03	84.71 ± 0.03	85.68 ± 0.03	84.79 ± 0.03	85.11 ± 0.03	85.11 ± 0.03
	MLM	Euclidean	75.7 ± 0.05	75.14 ± 0.05	75.7 ± 0.05	75.21 ± 0.05	75.32 ± 0.05	75.32 ± 0.05
		Mahalanobis	83.26 ± 0.03	81.85 ± 0.03	82.93 ± 0.03	81.95 ± 0.03	82.28 ± 0.03	82.28 ± 0.03
	MLM-NN	Cityblock	86.07 ± 0.03	84.71 ± 0.03	85.68 ± 0.03	84.79 ± 0.03	85.11 ± 0.03	85.11 ± 0.03
		Euclidean	75.7 ± 0.05	75.14 ± 0.05	75.7 ± 0.05	75.21 ± 0.05	75.32 ± 0.05	75.32 ± 0.05
	MLP	Mahalanobis	83.26 ± 0.03	81.85 ± 0.03	82.93 ± 0.03	81.95 ± 0.03	82.28 ± 0.03	82.28 ± 0.03
			77.92 ± 0.27	71.66 ± 0.12	83.33 ± 0.06	74.36 ± 0.08	70.6 ± 0.25	71.66 ± 0.12
	SVM	Linear	92.23 ± 0.02	77.5 ± 0.07	88.75 ± 0.01	79.14 ± 0.06	81.94 ± 0.05	77.5 ± 0.07
		RBF	93.53 ± 0.01	68.33 ± 0.08	89.72 ± 0.02	72.75 ± 0.05	76.24 ± 0.05	68.33 ± 0.08
Sobel	Bayes		93.11 ± 0.07	90.83 ± 0.09	92.36 ± 0.08	90.95 ± 0.09	91.48 ± 0.08	90.83 ± 0.09
	LSSVM	Linear	97.61 ± 0.03	96.66 ± 0.04	97.22 ± 0.03	96.68 ± 0.04	96.92 ± 0.03	96.66 ± 0.04
		RBF	95.38 ± 0.07	93.33 ± 0.09	94.72 ± 0.07	93.45 ± 0.09	93.92 ± 0.08	93.33 ± 0.09
		Cityblock	97.73 ± 0.03	95.83 ± 0.07	97.08 ± 0.04	95.93 ± 0.06	96.37 ± 0.06	95.83 ± 0.07
	MLM	Euclidean	90.61 ± 0.11	89.16 ± 0.11	90.13 ± 0.11	89.24 ± 0.11	89.58 ± 0.11	89.16 ± 0.11
		Mahalanobis	93.5 ± 0.09	92.5 ± 0.09	93.19 ± 0.09	92.55 ± 0.09	92.78 ± 0.09	92.5 ± 0.09
	MLM-NN	Cityblock	97.73 ± 0.03	95.83 ± 0.07	97.08 ± 0.04	95.93 ± 0.06	96.37 ± 0.06	95.83 ± 0.07
		Euclidean	90.61 ± 0.11	89.16 ± 0.11	90.13 ± 0.11	89.24 ± 0.11	89.58 ± 0.11	89.16 ± 0.11
	MLP	Mahalanobis	93.5 ± 0.09	92.5 ± 0.09	93.19 ± 0.09	92.55 ± 0.09	92.78 ± 0.09	92.5 ± 0.09
			92.66 ± 0.09	90.83 ± 0.09	92.08 ± 0.09	90.93 ± 0.09	91.35 ± 0.09	90.83 ± 0.09
	SVM	Linear	98.33 ± 0.03	96.66 ± 0.07	97.77 ± 0.04	96.76 ± 0.06	97.14 ± 0.06	96.66 ± 0.07
		RBF	95.47 ± 0.06	95 ± 0.07	95.27 ± 0.06	95.01 ± 0.07	95.12 ± 0.06	95 ± 0.07

pode ser identificado tanto pela região da lesão quanto pela sua borda (altas frequências) ou variação de cor (médias e baixas frequências). Essa ideia é reforçada quando os resultados do filtro gaussiano mostram valores ligeiramente inferiores nos classificadores MLM e MLM-NN quando comparados ao filtro laplaciano. Como a técnica do ABCD analisa com precisão essas características da lesão, a análise do SCM baseada nos componentes

Tabela 4 – Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2016 usando LBP, GLCM e HU considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F-score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação

Feature	Classifier	Setup	Spe(%)	Sen(%)	Ppv(%)	F score(%)	Hm(%)	Acc(%)
LBP	SVM	Linear	92.93 $\pm$ 0.01	89.57 $\pm$ 0.04	91.73 $\pm$ 0.02	89.73 $\pm$ 0.04	90.51 $\pm$ 0.03	90.51 $\pm$ 0.03
		RBF	89.04 $\pm$ 0.03	72.85 $\pm$ 0.02	85.95 $\pm$ 0.02	74.8 $\pm$ 0.02	77.85 $\pm$ 0.02	72.85 $\pm$ 0.02
	MLP		93.77 $\pm$ 0.02	92.42 $\pm$ 0.03	93.24 $\pm$ 0.02	92.46 $\pm$ 0.03	92.79 $\pm$ 0.02	92.42 $\pm$ 0.03
		Mahalanobis	88.75 $\pm$ 0.04	88 $\pm$ 0.04	88.49 $\pm$ 0.04	88.03 $\pm$ 0.04	88.21 $\pm$ 0.04	88 $\pm$ 0.04
	MLM-NN	Euclidean	89.14 $\pm$ 0.02	88.42 $\pm$ 0.02	88.91 $\pm$ 0.02	88.46 $\pm$ 0.02	88.63 $\pm$ 0.02	88.42 $\pm$ 0.02
		Cityblock	91.49 $\pm$ 0.03	90.28 $\pm$ 0.03	91.02 $\pm$ 0.02	90.32 $\pm$ 0.03	90.61 $\pm$ 0.03	90.28 $\pm$ 0.03
		Mahalanobis	88.75 $\pm$ 0.04	88 $\pm$ 0.04	88.49 $\pm$ 0.04	88.03 $\pm$ 0.04	88.21 $\pm$ 0.04	88 $\pm$ 0.04
	MLM	Euclidean	89.14 $\pm$ 0.02	88.42 $\pm$ 0.02	88.91 $\pm$ 0.02	88.46 $\pm$ 0.02	88.63 $\pm$ 0.02	88.42 $\pm$ 0.02
		Cityblock	91.49 $\pm$ 0.03	90.28 $\pm$ 0.03	91.02 $\pm$ 0.02	90.32 $\pm$ 0.03	90.61 $\pm$ 0.03	90.28 $\pm$ 0.03
	LSSVM	Linear	88.78 $\pm$ 0.02	85.57 $\pm$ 0.03	87.79 $\pm$ 0.02	85.75 $\pm$ 0.03	86.5 $\pm$ 0.03	85.57 $\pm$ 0.03
		RBF	89.06 $\pm$ 0.03	72.71 $\pm$ 0.02	85.96 $\pm$ 0.02	74.69 $\pm$ 0.02	77.76 $\pm$ 0.02	72.71 $\pm$ 0.02
	Bayes		85.56 $\pm$ 0.02	84.57 $\pm$ 0.03	85.32 $\pm$ 0.03	84.64 $\pm$ 0.03	84.86 $\pm$ 0.03	84.57 $\pm$ 0.03
HU	SVM	Linear	94.24 $\pm$ 0.02	93.71 $\pm$ 0.02	94.01 $\pm$ 0.02	93.72 $\pm$ 0.02	93.85 $\pm$ 0.02	93.71 $\pm$ 0.02
		RBF	97.08 $\pm$ 0	56.28 $\pm$ 0.01	94.56 $\pm$ 0.01	66.69 $\pm$ 0	69.59 $\pm$ 0	56.28 $\pm$ 0.01
	MLP		92.71 $\pm$ 0.01	90.14 $\pm$ 0.03	91.77 $\pm$ 0.02	90.25 $\pm$ 0.03	90.86 $\pm$ 0.03	90.14 $\pm$ 0.03
		Mahalanobis	92.48 $\pm$ 0.02	92 $\pm$ 0.01	92.27 $\pm$ 0.01	92 $\pm$ 0.01	92.12 $\pm$ 0.01	92 $\pm$ 0.01
	MLM-NN	Euclidean	92.48 $\pm$ 0.02	92 $\pm$ 0.01	92.27 $\pm$ 0.01	92 $\pm$ 0.01	92.12 $\pm$ 0.01	92 $\pm$ 0.01
		Cityblock	91.01 $\pm$ 0.02	90.28 $\pm$ 0.02	90.75 $\pm$ 0.02	90.31 $\pm$ 0.02	90.49 $\pm$ 0.02	90.28 $\pm$ 0.02
		Mahalanobis	92.48 $\pm$ 0.02	92 $\pm$ 0.01	92.27 $\pm$ 0.01	92 $\pm$ 0.01	92.12 $\pm$ 0.01	92 $\pm$ 0.01
	MLM	Euclidean	92.48 $\pm$ 0.02	92 $\pm$ 0.01	92.27 $\pm$ 0.01	92 $\pm$ 0.01	92.12 $\pm$ 0.01	92 $\pm$ 0.01
		Cityblock	91.01 $\pm$ 0.02	90.28 $\pm$ 0.02	90.75 $\pm$ 0.02	90.31 $\pm$ 0.02	90.49 $\pm$ 0.02	90.28 $\pm$ 0.02
	LSSVM	Linear	90.24 $\pm$ 0.02	80.85 $\pm$ 0.03	87.56 $\pm$ 0.01	81.56 $\pm$ 0.03	83.61 $\pm$ 0.02	80.85 $\pm$ 0.03
		RBF	91.29 $\pm$ 0.01	79.71 $\pm$ 0.04	88.04 $\pm$ 0.01	80.66 $\pm$ 0.03	83.12 $\pm$ 0.03	79.71 $\pm$ 0.04
	Bayes		92.04 $\pm$ 0	72.85 $\pm$ 0.02	87.74 $\pm$ 0	75.09 $\pm$ 0.02	78.68 $\pm$ 0.01	72.85 $\pm$ 0.02
GLCM	SVM	Linear	93.36 $\pm$ 0.03	90.85 $\pm$ 0.04	92.41 $\pm$ 0.03	90.94 $\pm$ 0.04	91.55 $\pm$ 0.03	90.85 $\pm$ 0.04
		RBF	85.03 $\pm$ 0.04	79.85 $\pm$ 0.04	83.93 $\pm$ 0.03	80.32 $\pm$ 0.04	81.43 $\pm$ 0.04	79.85 $\pm$ 0.04
	MLP		93.62 $\pm$ 0.03	92.42 $\pm$ 0.04	93.14 $\pm$ 0.03	92.46 $\pm$ 0.04	92.75 $\pm$ 0.04	92.42 $\pm$ 0.04
		Mahalanobis	89.08 $\pm$ 0.04	88.28 $\pm$ 0.03	88.8 $\pm$ 0.03	88.31 $\pm$ 0.03	88.51 $\pm$ 0.03	88.28 $\pm$ 0.03
	MLM-NN	Euclidean	85.94 $\pm$ 0.03	85.28 $\pm$ 0.03	85.74 $\pm$ 0.03	85.32 $\pm$ 0.03	85.47 $\pm$ 0.03	85.28 $\pm$ 0.03
		Cityblock	87.43 $\pm$ 0.04	87 $\pm$ 0.04	87.27 $\pm$ 0.04	87.01 $\pm$ 0.04	87.12 $\pm$ 0.04	87 $\pm$ 0.04
		Mahalanobis	89.08 $\pm$ 0.04	88.28 $\pm$ 0.03	88.8 $\pm$ 0.03	88.31 $\pm$ 0.03	88.51 $\pm$ 0.03	88.28 $\pm$ 0.03
	MLM	Euclidean	85.94 $\pm$ 0.03	85.28 $\pm$ 0.03	85.74 $\pm$ 0.03	85.32 $\pm$ 0.03	85.47 $\pm$ 0.03	85.28 $\pm$ 0.03
		Cityblock	87.43 $\pm$ 0.04	87 $\pm$ 0.04	87.27 $\pm$ 0.04	87.01 $\pm$ 0.04	87.12 $\pm$ 0.04	87 $\pm$ 0.04
	LSSVM	Linear	92.63 $\pm$ 0.03	89.71 $\pm$ 0.04	91.56 $\pm$ 0.03	89.83 $\pm$ 0.04	90.52 $\pm$ 0.04	89.71 $\pm$ 0.04
		RBF	84.84 $\pm$ 0.04	78.14 $\pm$ 0.04	83.54 $\pm$ 0.03	78.79 $\pm$ 0.03	80.2 $\pm$ 0.03	78.14 $\pm$ 0.04
	Bayes		90.05 $\pm$ 0.03	83.57 $\pm$ 0.05	88.13 $\pm$ 0.03	84.02 $\pm$ 0.04	85.46 $\pm$ 0.04	83.57 $\pm$ 0.05

mais relevantes no domínio da frequência apresenta resultados muito próximos aos do (s) especialista (s).

Os Momentos HU usando o conjunto de dados ISIC 2016 obtiveram o melhor resultado de acurácia com uma taxa de acerto de 93.71 % e 94.01 % e 93.72 % para Ppv e F-score usando o SVM Linear como mostrado na Tabela 4 . Além disso, o extrator Hu foi um pouco melhor com o ISIC 2016 do que com o banco de dados PH2 em todas as métricas e seu resultado de acurácia foi ligeiramente superior aos outros extratores. Como justificado na seção ref sub: aquisição, alguns fatores como a localização da lesão e seu tamanho não são tão bons quanto os do conjunto de dados PH2 e, dada a invariância do extrator HU, esse resultado pode estar relacionado à capacidade discriminativa em relação à área da lesão, ou que o conjunto de dados ISIC 2016 tenha mais imagens onde o melanoma também possa ser identificado em momentos. Os extratores LBP e GLCM

Tabela 5 – Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2016 usando SCM considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação

Filter	Classifier	Setup	Spe(%)	Sen(%)	Ppv(%)	F score(%)	Hm(%)	Acc(%)
Fourier	Bayes		92.71 ± 0.02	91.28 ± 0.04	92.22 ± 0.03	91.35 ± 0.04	91.69 ± 0.03	91.28 ± 0.04
	LSSVM	Linear	94.62 ± 0.02	93.85 ± 0.02	94.29 ± 0.02	93.87 ± 0.02	94.06 ± 0.02	93.85 ± 0.02
		RBF	89.81 ± 0.02	88.71 ± 0.03	89.46 ± 0.02	88.77 ± 0.03	89.03 ± 0.03	88.71 ± 0.03
	MLM	Cityblock	85.79 ± 0.04	84.85 ± 0.04	85.53 ± 0.04	84.91 ± 0.04	85.13 ± 0.04	84.85 ± 0.04
		Euclidean	86.08 ± 0.04	85.28 ± 0.04	85.86 ± 0.04	85.33 ± 0.04	85.52 ± 0.04	85.28 ± 0.04
		Mahalanobis	85.86 ± 0.03	85 ± 0.04	85.63 ± 0.03	85.05 ± 0.04	85.25 ± 0.03	85 ± 0.04
	MLM-NN	Cityblock	85.79 ± 0.04	84.85 ± 0.04	85.53 ± 0.04	84.91 ± 0.04	85.13 ± 0.04	84.85 ± 0.04
		Euclidean	86.08 ± 0.04	85.28 ± 0.04	85.86 ± 0.04	85.33 ± 0.04	85.52 ± 0.04	85.28 ± 0.04
	MLP	Mahalanobis	85.86 ± 0.03	85 ± 0.04	85.63 ± 0.03	85.05 ± 0.04	85.25 ± 0.03	85 ± 0.04
			92.65 ± 0.02	90.42 ± 0.04	91.85 ± 0.03	90.52 ± 0.04	91.05 ± 0.03	90.42 ± 0.04
Gaussian	SVM	Linear	95.23 ± 0.01	94.57 ± 0.02	94.94 ± 0.01	94.58 ± 0.02	94.74 ± 0.02	94.57 ± 0.02
		RBF	92.99 ± 0.02	91.14 ± 0.04	92.32 ± 0.03	91.21 ± 0.04	91.66 ± 0.03	91.14 ± 0.04
	Bayes		79.81 ± 0.03	77.28 ± 0.02	79.45 ± 0.03	77.53 ± 0.02	78.08 ± 0.02	77.28 ± 0.02
	LSSVM	Linear	80.92 ± 0.04	76.71 ± 0.04	80.37 ± 0.04	77.16 ± 0.04	78.04 ± 0.04	76.71 ± 0.04
		RBF	78.43 ± 0.03	77 ± 0.04	78.44 ± 0.03	77.19 ± 0.04	77.47 ± 0.04	77 ± 0.04
	MLM	Cityblock	82.48 ± 0.04	81.85 ± 0.04	82.35 ± 0.04	81.9 ± 0.04	82.04 ± 0.04	81.85 ± 0.04
		Euclidean	79.29 ± 0.03	78.42 ± 0.03	79.17 ± 0.03	78.51 ± 0.03	78.7 ± 0.03	78.42 ± 0.03
		Mahalanobis	82.53 ± 0.02	82 ± 0.02	82.41 ± 0.02	82.03 ± 0.02	82.16 ± 0.02	82 ± 0.02
	MLM-NN	Cityblock	82.48 ± 0.04	81.85 ± 0.04	82.35 ± 0.04	81.9 ± 0.04	82.04 ± 0.04	81.85 ± 0.04
		Euclidean	79.29 ± 0.03	78.42 ± 0.03	79.17 ± 0.03	78.51 ± 0.03	78.7 ± 0.03	78.42 ± 0.03
Laplace	MLP	Mahalanobis	82.53 ± 0.02	82 ± 0.02	82.41 ± 0.02	82.03 ± 0.02	82.16 ± 0.02	82 ± 0.02
			87.01 ± 0.03	85.14 ± 0.02	86.41 ± 0.02	85.25 ± 0.02	85.68 ± 0.02	85.14 ± 0.02
	SVM	Linear	85.28 ± 0.02	84.42 ± 0.02	85.05 ± 0.02	84.48 ± 0.02	84.68 ± 0.02	84.42 ± 0.02
		RBF	84.17 ± 0.07	65.14 ± 0.04	84.71 ± 0.03	69.07 ± 0.02	71.47 ± 0.04	65.14 ± 0.04
	Bayes		75.59 ± 0.07	72.71 ± 0.09	76.88 ± 0.05	73.48 ± 0.08	73.75 ± 0.08	72.71 ± 0.09
	LSSVM	Linear	79.4 ± 0.03	78.57 ± 0.04	79.35 ± 0.03	78.66 ± 0.03	78.84 ± 0.03	78.57 ± 0.04
		RBF	79.2 ± 0.03	76.57 ± 0.04	79.12 ± 0.03	76.93 ± 0.04	77.43 ± 0.04	76.57 ± 0.04
	MLM	Cityblock	86.07 ± 0.03	84.71 ± 0.03	85.68 ± 0.03	84.79 ± 0.03	85.11 ± 0.03	84.71 ± 0.03
		Euclidean	75.7 ± 0.05	75.14 ± 0.05	75.7 ± 0.05	75.21 ± 0.05	75.32 ± 0.05	75.14 ± 0.05
		Mahalanobis	83.26 ± 0.03	81.85 ± 0.03	82.93 ± 0.03	81.95 ± 0.03	82.28 ± 0.03	81.85 ± 0.03
Sobel	MLM-NN	Cityblock	86.07 ± 0.03	84.71 ± 0.03	85.68 ± 0.03	84.79 ± 0.03	85.11 ± 0.03	84.71 ± 0.03
		Euclidean	75.7 ± 0.05	75.14 ± 0.05	75.7 ± 0.05	75.21 ± 0.05	75.32 ± 0.05	75.14 ± 0.05
	MLP	Mahalanobis	83.26 ± 0.03	81.85 ± 0.03	82.93 ± 0.03	81.95 ± 0.03	82.28 ± 0.03	81.85 ± 0.03
			84.84 ± 0.05	83.57 ± 0.04	84.49 ± 0.04	83.64 ± 0.04	83.94 ± 0.04	83.57 ± 0.04
	SVM	Linear	84.9 ± 0.04	83.57 ± 0.04	84.52 ± 0.04	83.64 ± 0.04	83.96 ± 0.04	83.57 ± 0.04
		RBF	79.38 ± 0.03	76.85 ± 0.04	79.27 ± 0.03	77.19 ± 0.04	77.68 ± 0.03	76.85 ± 0.04
	Bayes		74.07 ± 0.05	72.71 ± 0.05	74.29 ± 0.05	72.95 ± 0.05	73.18 ± 0.05	72.71 ± 0.05
	LSSVM	Linear	85.56 ± 0.02	84.57 ± 0.03	85.28 ± 0.02	84.63 ± 0.03	84.86 ± 0.02	84.57 ± 0.03
		RBF	78.8 ± 0.05	71.71 ± 0.03	78.49 ± 0.04	72.72 ± 0.02	74.03 ± 0.03	71.71 ± 0.03
	MLM	Cityblock	80.36 ± 0.05	79.57 ± 0.05	80.18 ± 0.05	79.63 ± 0.05	79.81 ± 0.05	79.57 ± 0.05
		Euclidean	77.42 ± 0.04	76.85 ± 0.04	77.37 ± 0.04	76.91 ± 0.04	77.03 ± 0.04	76.85 ± 0.04
		Mahalanobis	80.33 ± 0.04	79.28 ± 0.03	80.16 ± 0.03	79.37 ± 0.03	79.61 ± 0.03	79.28 ± 0.03
	MLM-NN	Cityblock	80.36 ± 0.05	79.57 ± 0.05	80.18 ± 0.05	79.63 ± 0.05	79.81 ± 0.05	79.57 ± 0.05
		Euclidean	77.42 ± 0.04	76.85 ± 0.04	77.37 ± 0.04	76.91 ± 0.04	77.03 ± 0.04	76.85 ± 0.04
	MLP	Mahalanobis	80.33 ± 0.04	79.28 ± 0.03	80.16 ± 0.03	79.37 ± 0.03	79.61 ± 0.03	79.28 ± 0.03
			82.03 ± 0.04	81.57 ± 0.04	81.91 ± 0.04	81.6 ± 0.04	81.7 ± 0.04	81.57 ± 0.04
	SVM	Linear	85.11 ± 0.02	83.57 ± 0.03	84.71 ± 0.02	83.67 ± 0.02	84.03 ± 0.02	83.57 ± 0.03
		RBF	77.65 ± 0.04	71.57 ± 0.03	77.77 ± 0.03	72.54 ± 0.03	73.6 ± 0.03	71.57 ± 0.03

com o classificador MLP obtiveram uma acurácia muito próxima à do HU, com ambos alcançando 92,42 %. O extrator LBP com Especificidade de 93,77 % e Sensibilidade de 92,42 % resalta um comportamento equilibrado entre a discriminação para cada classe. Este resultado também é significativo devido ao comportamento estatístico do GLCM com especificidade e sensibilidade de 93,62 % e 92,42 %, respectivamente.

Tabela 6 – Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2017 usando LBP, GLCM e HU considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F Score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação

Feature	Classifier	Setup	Spe(%)	Sen(%)	Ppv(%)	F score(%)	Hm(%)	Acc(%)
LBP	SVM	Linear	89.32 ± 0	78.24 ± 0.03	86.62 ± 0	79.26 ± 0.03	81.57 ± 0.02	78.24 ± 0.03
		RBF	78.94 ± 0.02	72.6 ± 0.04	79.01 ± 0.01	73.56 ± 0.03	74.71 ± 0.03	72.6 ± 0.04
	MLP		90.16 ± 0.01	88 ± 0.01	89.37 ± 0.01	88.08 ± 0.01	88.06 ± 0.01	88 ± 0.01
		Mahalanobis	86.4 ± 0.01	84.6 ± 0.01	85.86 ± 0.01	84.69 ± 0.01	85.12 ± 0	84.6 ± 0.01
	MLM-NN	Euclidean	84.44 ± 0.02	83.93 ± 0.01	84.29 ± 0.01	83.96 ± 0.01	84.08 ± 0.01	83.93 ± 0.01
		Cityblock	84.68 ± 0.02	84.53 ± 0.01	84.64 ± 0.01	84.54 ± 0.01	84.57 ± 0.01	84.53 ± 0.01
		Mahalanobis	86.4 ± 0.01	84.6 ± 0.01	85.86 ± 0.01	84.69 ± 0.01	85.12 ± 0	84.6 ± 0.01
	MLM	Euclidean	84.44 ± 0.02	83.93 ± 0.01	84.29 ± 0.01	83.96 ± 0.01	84.08 ± 0.01	83.93 ± 0.01
		Cityblock	84.68 ± 0.02	84.53 ± 0.01	84.64 ± 0.01	84.54 ± 0.01	84.57 ± 0.01	84.53 ± 0.01
	LSSVM	Linear	86.09 ± 0.02	79.66 ± 0.02	84.59 ± 0.01	80.21 ± 0.02	81.61 ± 0.02	79.66 ± 0.02
		RBF	79.22 ± 0.02	72.46 ± 0.03	79.24 ± 0.01	73.48 ± 0.03	74.71 ± 0.03	72.46 ± 0.03
	Bayes		85.18 ± 0.02	84.2 ± 0.02	84.9 ± 0.02	84.25 ± 0.02	84.49 ± 0.02	84.2 ± 0.02
HU	SVM	Linear	91.08 ± 0.01	86 ± 0.02	89.33 ± 0.01	86.25 ± 0.02	87.44 ± 0.02	86 ± 0.02
		RBF	89.22 ± 0.31	51.6 ± 0.01	98.47 ± 0.01	66.45 ± 0	60.72 ± 0.21	51.6 ± 0.01
	MLP		91.69 ± 0.01	87.4 ± 0.02	90.14 ± 0.01	87.58 ± 0.02	88.06 ± 0.01	87.4 ± 0.02
		Mahalanobis	80.34 ± 0.02	80.2 ± 0.03	80.32 ± 0.02	80.21 ± 0.03	80.24 ± 0.03	80.2 ± 0.03
	MLM-NN	Euclidean	80.34 ± 0.02	80.2 ± 0.03	80.32 ± 0.02	80.21 ± 0.03	80.24 ± 0.03	80.2 ± 0.03
		Cityblock	80.1 ± 0.03	79.93 ± 0.03	80.07 ± 0.03	79.94 ± 0.03	79.98 ± 0.03	79.93 ± 0.03
		Mahalanobis	80.34 ± 0.02	80.2 ± 0.03	80.32 ± 0.02	80.21 ± 0.03	80.24 ± 0.03	80.2 ± 0.03
	MLM	Euclidean	80.34 ± 0.02	80.2 ± 0.03	80.32 ± 0.02	80.21 ± 0.03	80.24 ± 0.03	80.2 ± 0.03
		Cityblock	80.1 ± 0.03	79.93 ± 0.03	80.07 ± 0.03	79.94 ± 0.03	79.98 ± 0.03	79.93 ± 0.03
	LSSVM	Linear	91.75 ± 0	75.06 ± 0.02	87.65 ± 0	76.79 ± 0.02	80.08 ± 0.01	75.06 ± 0.02
		RBF	90.69 ± 0.01	72.73 ± 0.03	87.02 ± 0	74.88 ± 0.02	78.24 ± 0.02	72.73 ± 0.03
	Bayes		94.32 ± 0	63.53 ± 0.02	90.21 ± 0.01	69.2 ± 0.01	73.29 ± 0.01	63.53 ± 0.02
GLCM	SVM	Linear	89.19 ± 0.01	85.94 ± 0.01	88.11 ± 0.01	86.1 ± 0.01	86.87 ± 0.01	85.94 ± 0.01
		RBF	78.93 ± 0.41	52.22 ± 0.02	97.96 ± 0.01	66.49 ± 0	54.35 ± 0.28	52.22 ± 0.02
	MLP		77.76 ± 0.27	80.74 ± 0.11	87.1 ± 0.06	82.51 ± 0.06	76.32 ± 0.27	80.74 ± 0.11
		Mahalanobis	86.33 ± 0.02	85.33 ± 0.02	86.02 ± 0.02	85.38 ± 0.02	85.62 ± 0.02	85.33 ± 0.02
	MLM-NN	Euclidean	85.06 ± 0.02	84.32 ± 0.02	84.85 ± 0.02	84.36 ± 0.02	84.54 ± 0.02	84.32 ± 0.02
		Cityblock	80.9 ± 0.02	80.27 ± 0.02	80.77 ± 0.02	80.32 ± 0.02	80.46 ± 0.02	80.27 ± 0.02
		Mahalanobis	86.33 ± 0.02	85.33 ± 0.02	86.02 ± 0.02	85.38 ± 0.02	85.62 ± 0.02	85.33 ± 0.02
	MLM	Euclidean	85.06 ± 0.02	84.32 ± 0.02	84.85 ± 0.02	84.36 ± 0.02	84.54 ± 0.02	84.32 ± 0.02
		Cityblock	80.9 ± 0.02	80.27 ± 0.02	80.77 ± 0.02	80.32 ± 0.02	80.46 ± 0.02	80.27 ± 0.02
	LSSVM	Linear	88.79 ± 0.01	84.86 ± 0.01	87.53 ± 0	85.07 ± 0.01	85.99 ± 0	84.86 ± 0.01
		RBF	82.25 ± 0.02	81.62 ± 0.02	82.14 ± 0.02	81.67 ± 0.02	81.81 ± 0.02	81.62 ± 0.02
	Bayes		86.74 ± 0.02	72.56 ± 0.03	84.64 ± 0.01	74.38 ± 0.02	77.02 ± 0.02	72.56 ± 0.03

Aplicando diferentes filtros com SCM no conjunto de dados ISIC 2016, conforme ilustrado na Tabela 5, o SCM combinado com a função de filtro k no domínio da frequência apresenta o melhor resultado em relação aos outros filtros com Spe 95.23 %, Sen 94,57 %, Ppv 94,94 %, F-score 94,58 %, Hm 94,74 % e Acc 94,57 % usando o classificador Linear SVM.

Um comportamento semelhante foi observado nos outros filtros. Os filtros de Gauss, Laplace e Sobel alcançaram uma estatística geral de 85 % em todas as métricas, sugerindo

que as imagens dermatoscópicas que contêm melanoma têm um comportamento homogêneo em suas características.

A mudança de domínio da função k e o método proposto é mais robusto à presença de artefatos, pois destaca as frequências mais importantes da imagem.

Para o conjunto de dados ISIC 2017, o extrator LBP obteve os melhores resultados gerais com Spe 90.16 %, Sen 88 %, Ppv 89.37 %, F-score 88.08 %, Hm 88.06 % e Acc 88 % com o classificador MLP como mostrado na Tabela 6.

Os Momentos HU também obtiveram um resultado relevante muito próximo ao LBP com 91,69 %, 87,04 %, 90,14 %, 87,58 %, 88,06 % e 87,4 %, respectivamente. Esses dados apontam que as lesões presentes no conjunto de dados do ISIC 2017 possuem características mais relacionadas ao seu tamanho e cor em toda a sua região.

O SCM aplicado ao conjunto de dados do ISIC 2017 tem resultados geralmente mais baixos do que a análise anterior. No entanto, a aplicação do SCM no domínio da frequência com o classificador LSSVM linear, mostrado na Tabela 7, atinge um valor melhor que os outros com métricas gerais de Spe 92.15 %, Sen 89.93 %, Ppv 91,29 %, F-score 90 %, Hm 90,54 % e Acc 89,93 %.

Novamente, os resultados com os filtros Gaussian e Laplace têm valores muito próximos, indicando que o melanoma neste conjunto de dados é igualmente identificado pelas frequências baixas e altas, reforçando assim a importância da aplicação de filtros band-pass.

Entre as análises das Tabelas 2, 3, 4, 5, 6, 7, pode-se ver que o SCM com domínio de frequência contempla todas as principais características que caracterizam a lesão da pele mas, diferentemente do LBP, GLCM e HU, o SCM funciona em todos os conjuntos de dados com o mesmo poder discriminante quando configurado com o domínio da frequência abordagem.

Ao analisar as outras configurações de SCM usando os filtros Gaussian, Sobel e Laplace, a abordagem proposta está funcionando como um filtro passa-banda, fazendo com que considere vários padrões na imagem.

Este trabalho também comparou o método proposto com diferentes métodos atualizados aplicados aos mesmos conjuntos de dados. Tabela 8 mostra o Sen, Spe, Acc e AUC de cada método. Os resultados propostos foram retirados das Tabelas 3, 5 e 7. A métrica AUC foi calculada pela média dos resultados obtidos em cada um dos conjuntos de dados após a validação cruzada.

Para o conjunto de dados PH2, a metodologia proposta neste trabalho teve os melhores resultados com Sen 99.4 %, Spe 99.2 %, Acc 99 % e AUC 99 %. Os altos valores apresentados são justificados, pois, além da robustez do SCM, o conjunto de dados PH2

possui imagens mais uniformes, não conseguindo identificar padrões distintos.

Usando o mesmo conjunto de dados, Satheesha *et. al* (SATHEESHA *et al.*, 2017) propõe um método de reconstrução de lesão cutânea 3d para classificar as imagens dermatoscópicas usando a profundidade e a forma 3-D como principais características. Bi *et. al* (BI *et al.*, 2016) propõe um método baseado na representação tendenciosa contra lesões em escala múltipla e na classificação inversa comum.

Um ponto importante de divergência entre o Satheesha *et. al* (SATHEESHA *et al.*, 2017), Bi *et. al* (BI *et al.*, 2016), e a abordagem proposta está em pré-processamento principalmente no ajuste de contraste da lesão. No artigo apresentado por Waheed *et. al* (WAHEED *et al.*, 2017) mesmo com ajuste de contraste, o uso de características de cor e textura parece não ser suficiente para discriminar a lesão normal de melanoma.

A aplicação do SCM no conjunto de dados ISIC 2016 também obteve, exceto Spe, os melhores valores entre os métodos apresentados com Sen 95.23 %, Spe 94.57 %, Acc 94.5 % e AUC 92 %. Spe obteve um valor similar ao apresentado por Yu *et al.* (YU *et al.*, 2017a). Além da normalização do contraste, o método proposto também possui uma característica discriminativa importante, mas diferente de Yu *et. al* (YU *et al.*, 2017a), Yu *et. al* (YU *et al.*, 2017b) e Lopez *et. al* (LOPEZ *et al.*, 2017) que utiliza a análise do domínio espacial com a CNN, o método proposto extrai as principais propriedades estruturais do domínio da frequência e do domínio espacial. Apesar do impacto gerado pela variação de ruído presente no conjunto de dados do ISIC 2016, o método proposto conseguiu obter uma taxa equilibrada em sua classificação.

No conjunto de dados ISIC 2017, o método proposto obteve Sen 92.15 %, Spe 89.9 %, Acc 89.9 % e AUC 89 %. O SCM apresentou valores melhores que os outros métodos para Sen e Acc. Nota: no entanto, o SCM, em geral, obteve um melhor equilíbrio de classificação quando associado a Sen e Spe juntos. Assim como os métodos comparados do ISIC 2016, Matsunaga *et. al* (MATSUNAGA *et al.*, 2017), Sousa *et. al* (SOUSA; MORAES, 2017) e Li *et. al* (LI; SHEN, 2017) usa a CNN como a ferramenta principal. Isso pode indicar que a informação estrutural existente é melhor mostrada com a análise de frequência.

Tabela 7 – Resultado da classificação de imagens dermatoscópicas do conjunto de dados ISIC 2017 usando SCM considerando a especificidade (Spe), sensibilidade (Sen), valor preditivo positivo (Ppv), F score, média harmônica (Hm) e acurácia (Acc) como métricas de avaliação

Filter	Classifier	Setup	Spe(%)	Sen(%)	Ppv(%)	F score(%)	Hm(%)	Acc(%)
Fourier	Bayes		88.84 ± 0.01	80.06 ± 0.03	86.59 ± 0.01	80.78 ± 0.03	82.68 ± 0.03	80.06 ± 0.03
	LSSVM	Linear	92.15 ± 0.01	89.93 ± 0.01	91.29 ± 0.01	90 ± 0.01	90.54 ± 0.01	89.93 ± 0.01
		RBF	87.37 ± 0.02	83.17 ± 0.03	86.21 ± 0.02	83.44 ± 0.03	84.41 ± 0.02	83.17 ± 0.03
	MLM	Cityblock	77.05 ± 0.03	76.68 ± 0.03	77.03 ± 0.03	76.73 ± 0.03	76.8 ± 0.03	76.68 ± 0.03
		Euclidean	80.6 ± 0.03	80.33 ± 0.03	80.57 ± 0.03	80.36 ± 0.03	80.42 ± 0.03	80.33 ± 0.03
		Mahalanobis	78.93 ± 0.03	78.58 ± 0.03	78.88 ± 0.03	78.61 ± 0.03	78.69 ± 0.03	78.58 ± 0.03
	MLM-NN	Cityblock	77.05 ± 0.03	76.68 ± 0.03	77.03 ± 0.03	76.73 ± 0.03	76.8 ± 0.03	76.68 ± 0.03
		Euclidean	80.6 ± 0.03	80.33 ± 0.03	80.57 ± 0.03	80.36 ± 0.03	80.42 ± 0.03	80.33 ± 0.03
	MLP	Mahalanobis	78.93 ± 0.03	78.58 ± 0.03	78.88 ± 0.03	78.61 ± 0.03	78.69 ± 0.03	78.58 ± 0.03
			80.34 ± 0.28	79.05 ± 0.1	88.5 ± 0.04	81.14 ± 0.05	75.89 ± 0.26	79.05 ± 0.1
			89.74 ± 0.01	79.79 ± 0.04	87.14 ± 0.01	80.62 ± 0.03	82.75 ± 0.03	79.79 ± 0.04
	SVM	RBF	91.72 ± 0.01	71.14 ± 0.03	87.63 ± 0	73.79 ± 0.02	77.48 ± 0.02	71.14 ± 0.03
Gaussian	Bayes		92.8 ± 0.03	62.97 ± 0.03	89.66 ± 0.03	68.7 ± 0.02	72.53 ± 0.03	62.97 ± 0.03
	LSSVM	Linear	86.74 ± 0.03	75.67 ± 0.03	84.68 ± 0.02	76.9 ± 0.03	79.09 ± 0.03	75.67 ± 0.03
		RBF	82.96 ± 0.05	80.4 ± 0.04	82.41 ± 0.04	80.61 ± 0.04	81.18 ± 0.04	80.4 ± 0.04
	MLM	Cityblock	75.99 ± 0.03	75.2 ± 0.03	75.97 ± 0.03	75.29 ± 0.03	75.46 ± 0.03	75.2 ± 0.03
		Euclidean	75.18 ± 0.03	74.79 ± 0.03	75.21 ± 0.03	74.85 ± 0.03	74.92 ± 0.03	74.79 ± 0.03
		Mahalanobis	74.22 ± 0.02	73.91 ± 0.02	74.21 ± 0.02	73.95 ± 0.02	74.01 ± 0.02	73.91 ± 0.02
	MLM-NN	Cityblock	75.99 ± 0.03	75.2 ± 0.03	75.97 ± 0.03	75.29 ± 0.03	75.46 ± 0.03	75.2 ± 0.03
		Euclidean	75.18 ± 0.03	74.79 ± 0.03	75.21 ± 0.03	74.85 ± 0.03	74.92 ± 0.03	74.79 ± 0.03
	MLP	Mahalanobis	74.22 ± 0.02	73.91 ± 0.02	74.21 ± 0.02	73.95 ± 0.02	74.01 ± 0.02	73.91 ± 0.02
			84.58 ± 0.03	76.08 ± 0.03	83.27 ± 0.02	77.02 ± 0.03	78.74 ± 0.03	76.08 ± 0.03
			85.77 ± 0.03	76.08 ± 0.06	84.12 ± 0.02	77.14 ± 0.04	79.09 ± 0.03	76.08 ± 0.06
	SVM	RBF	80 ± 0	73.04 ± 0.02	79.72 ± 0.01	74 ± 0	75.31 ± 0.01	73.04 ± 0.02
Laplace	Bayes		74.38 ± 0.03	64.53 ± 0.03	77.4 ± 0.02	67.03 ± 0.02	68.07 ± 0.02	64.53 ± 0.03
	LSSVM	Linear	76.16 ± 0.02	75.93 ± 0.02	76.17 ± 0.02	75.96 ± 0.02	76.01 ± 0.02	75.93 ± 0.02
		RBF	68.77 ± 0.04	67 ± 0.04	69.48 ± 0.04	67.41 ± 0.04	67.64 ± 0.04	67 ± 0.04
	MLM	Cityblock	73.61 ± 0.03	73.13 ± 0.03	73.64 ± 0.03	73.2 ± 0.03	73.29 ± 0.03	73.13 ± 0.03
		Euclidean	74.92 ± 0.03	74.46 ± 0.03	74.92 ± 0.03	74.52 ± 0.03	74.61 ± 0.03	74.46 ± 0.03
		Mahalanobis	75.02 ± 0.04	74.73 ± 0.04	75.02 ± 0.04	74.77 ± 0.04	74.83 ± 0.04	74.73 ± 0.04
	MLM-NN	Cityblock	73.61 ± 0.03	73.13 ± 0.03	73.64 ± 0.03	73.2 ± 0.03	73.29 ± 0.03	73.13 ± 0.03
		Euclidean	74.92 ± 0.03	74.46 ± 0.03	74.92 ± 0.03	74.52 ± 0.03	74.61 ± 0.03	74.46 ± 0.03
	MLP	Mahalanobis	75.02 ± 0.04	74.73 ± 0.04	75.02 ± 0.04	74.77 ± 0.04	74.83 ± 0.04	74.73 ± 0.04
			83.02 ± 0.03	80.26 ± 0.03	82.42 ± 0.03	80.48 ± 0.03	81.1 ± 0.03	80.26 ± 0.03
			78.53 ± 0.05	74.4 ± 0.09	80.12 ± 0.04	75.58 ± 0.07	75.89 ± 0.07	74.4 ± 0.09
	SVM	RBF	71.56 ± 0.02	69.2 ± 0.01	72.03 ± 0.02	69.65 ± 0.01	70.03 ± 0.01	69.2 ± 0.01
Sobel	Bayes		83.1 ± 0.02	80.33 ± 0.03	82.58 ± 0.02	80.57 ± 0.03	81.19 ± 0.02	80.33 ± 0.03
	LSSVM	Linear	84.84 ± 0.01	83.06 ± 0.02	84.39 ± 0.01	83.18 ± 0.02	83.59 ± 0.01	83.06 ± 0.02
		RBF	73.73 ± 0.03	71.46 ± 0.02	73.91 ± 0.02	71.81 ± 0.02	72.23 ± 0.02	71.46 ± 0.02
	MLM	Cityblock	76.4 ± 0.04	76.13 ± 0.04	76.39 ± 0.04	76.16 ± 0.04	76.22 ± 0.04	76.13 ± 0.04
		Euclidean	77.88 ± 0.03	77.4 ± 0.03	77.83 ± 0.03	77.45 ± 0.03	77.55 ± 0.03	77.4 ± 0.03
		Mahalanobis	80.16 ± 0.03	79.53 ± 0.03	80.07 ± 0.03	79.59 ± 0.03	79.73 ± 0.03	79.53 ± 0.03
	MLM-NN	Cityblock	76.4 ± 0.04	76.13 ± 0.04	76.39 ± 0.04	76.16 ± 0.04	76.22 ± 0.04	76.13 ± 0.04
		Euclidean	77.88 ± 0.03	77.4 ± 0.03	77.83 ± 0.03	77.45 ± 0.03	77.55 ± 0.03	77.4 ± 0.03
	MLP	Mahalanobis	80.16 ± 0.03	79.53 ± 0.03	80.07 ± 0.03	79.59 ± 0.03	79.73 ± 0.03	79.53 ± 0.03
			83.75 ± 0.03	81.53 ± 0.03	83.21 ± 0.03	81.69 ± 0.03	82.2 ± 0.03	81.53 ± 0.03
			88.3 ± 0.02	84.06 ± 0.02	86.99 ± 0.02	84.31 ± 0.02	85.29 ± 0.02	84.06 ± 0.02
	SVM	RBF	84.2 ± 0.01	80.13 ± 0.01	83.3 ± 0.01	80.46 ± 0.01	81.37 ± 0.01	80.13 ± 0.01

Tabela 8 – Comparação do SCM com métodos recentes usando os mesmos conjuntos de dados e sensibilidade (Sen), especificidade (Spe), acurácia (Acc) e área sob a curva (AUC) como métricas de avaliação.

Dataset	Método	Sen(%)	Spe(%)	Acc(%)	Auc(%)
PH2	Satheesha <i>et al.</i> (SATHEESHA et al., 2017)	96	97	95.75	-
	Bi <i>et al.</i> (BI et al., 2016)	87.5	93.13	92	-
	Waheed <i>et al.</i> (WAHEED et al., 2017)	97	84	96	90
	SCM Fourier	99.4	99.2	99	99
ISIC 2016	Gutman <i>et al.</i> (GUTMAN et al., 2016)	50	92	91.6	67
	Yu <i>et al.</i> (YU et al., 2017b)	-	-	83.09	79.57
	Yu <i>et al.</i> (YU et al., 2017a)	50	94	85	80.4
	Lopez <i>et al.</i> (LOPEZ et al., 2017)	78.6	79.7	81.33	-
	SCM Fourier	95.23		94.5	92
ISIC 2017	Codella <i>et al.</i> (CODELLA et al., 2017)	71.8	90.1	-	92.6
	Matsunaga <i>et al.</i> (MATSUNAGA et al., 2017)	-	-	-	95.8
	Sousa <i>et al.</i> (SOUSA; MORAES, 2017)	63.3	90	84.7	84.6
	Li <i>et al.</i> (LI; SHEN, 2017)	50.4	93.3	85.2	82.3
	SCM Fourier	92.15		89.93	89

4 Conclusão

Este trabalho propõe uma inovação na configuração do SCM para classificação automática de lesões cutâneas utilizando a análise do domínio da frequência.

A vantagem da combinação entre SCM e domínio de frequência reside na capacidade de melhorar dinamicamente as características estruturais da imagem, refletindo na melhor discriminação dos dados. Os resultados mostram que o SCM alcançou valores mais expressivos em todas as bases de dados, mesmo quando comparado aos recentes métodos existentes na literatura.

Além de reforçar a eficiência da técnica ABCD atual utilizada por especialistas, este trabalho também mostrou a possibilidade de um modelo computacional muito relevante em que seu comportamento é fortemente assimilado a essa técnica e, portanto, uma ferramenta importante a ser incluída em sistemas para auxiliarem diagnósticos clínicos levando em conta as mesmas características. Como trabalho futuro, a intenção é validar este método em outras bases de dados, bem como a inclusão de novos modelos para aplicação e análise em imagens dermatoscópicas.

Referências

A novel mobile robot localization approach based on topological maps using classification with reject option in omnidirectional images. *Expert Systems with Applications*, v. 72, p. 1 – 17, 2017. ISSN 0957-4174. Citado na página 35.

ALMARAZ-DAMIAN, J.; PONOMARYOV, V.; RENDON-GONZALEZ, E. Melanoma cade based on abcd rule and haralick texture features. In: IEEE. *Physics and Engineering of Microwaves, Millimeter and Submillimeter Waves (MSMW), 2016 9th International Kharkiv Symposium on*. [S.l.], 2016. p. 1–4. Citado na página 26.

BI, L. et al. Automatic melanoma detection via multi-scale lesion-biased representation and joint reverse classification. In: *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*. [S.l.: s.n.], 2016. p. 1055–1058. Citado 2 vezes nas páginas 51 e 53.

BRAZILIAN vehicle identification using a new embedded plate recognition system. *Measurement*, v. 70, p. 36 – 46, 2015. ISSN 0263-2241. Citado na página 38.

CODELLA, N. C. et al. Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (isbi), hosted by the international skin imaging collaboration (isic). *arXiv preprint arXiv:1710.05006*, 2017. Citado 2 vezes nas páginas 31 e 53.

DEMYANOV, S. et al. Classification of dermoscopy patterns using deep convolutional neural networks. In: IEEE. *Biomedical Imaging (ISBI), 2016 IEEE 13th International Symposium on*. [S.l.], 2016. p. 364–368. Citado na página 27.

DEVELOPMENT of OCR system on android platforms to aid reading with a refreshable braille display in real time. *Measurement*, v. 120, p. 150 – 168, 2018. ISSN 0263-2241. Citado na página 38.

FILHO, P. P. R. et al. Automated recognition of lung diseases in ct images based on the optimum-path forest classifier. *Neural Computing and Applications*, p. 1–14, 2017. Citado na página 26.

FILHO, P. P. R. et al. Novel and powerful 3d adaptive crisp active contour method applied in the segmentation of ct lung images. *Medical image analysis*, Elsevier, v. 35, p. 503–516, 2017. Citado na página 26.

FILHO, P. P. R. et al. Analysis of human tissue densities: A new approach to extract features from medical images. *Pattern Recognition Letters*, Elsevier, v. 94, p. 211–218, 2017. Citado na página 38.

FISHER, R. et al. Hypermedia image processing reference. *Department of Artificial Intelligence, University of Edinburgh*, 1994. Citado na página 40.

GE, Z. et al. Exploiting local and generic features for accurate skin lesions classification using clinical and dermoscopy imaging. In: IEEE. *Biomedical Imaging (ISBI 2017), 2017 IEEE 14th International Symposium on*. [S.l.], 2017. p. 986–990. Citado na página 27.

GU, Y.; ZHOU, J.; QIAN, B. Melanoma detection based on mahalanobis distance learning and constrained graph regularized nonnegative matrix factorization. In: IEEE. *Applications of Computer Vision (WACV), 2017 IEEE Winter Conference on*. [S.l.], 2017. p. 797–805. Citado 2 vezes nas páginas 26 e 27.

GUTMAN, D. et al. Skin lesion analysis toward melanoma detection: A challenge at the international symposium on biomedical imaging (isbi) 2016, hosted by the international skin imaging collaboration (isic). *arXiv preprint arXiv:1605.01397*, 2016. Citado 2 vezes nas páginas 31 e 53.

HARALICK, R. M.; SHANMUGAM, K. et al. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, Ieee, v. 3, n. 6, p. 610–621, 1973. Citado 2 vezes nas páginas 36 e 44.

HU, M.-K. Visual pattern recognition by moment invariants. *IRE transactions on information theory*, IEEE, v. 8, n. 2, p. 179–187, 1962. Citado 2 vezes nas páginas 36 e 44.

KASMI, R.; MOKRANI, K. Classification of malignant melanoma and benign skin lesions: implementation of automatic abcd rule. *IET Image Processing*, IET, v. 10, n. 6, p. 448–455, 2016. Citado 2 vezes nas páginas 26 e 27.

KAVITHA, J.; SURULIANDI, A. Texture and color feature extraction for classification of melanoma using svm. In: IEEE. *Computing Technologies and Intelligent Data Engineering (ICCTIDE), International Conference on*. [S.l.], 2016. p. 1–6. Citado 2 vezes nas páginas 26 e 27.

KAVYA, S.; SARANYA, S. Routine identification of melanoma disease using global and local features. In: IEEE. *Computer Communication and Informatics (ICCCI), 2016 International Conference on*. [S.l.], 2016. p. 1–4. Citado na página 26.

KAWAHARA, J.; BENTAIEB, A.; HAMARNEH, G. Deep features to classify skin lesions. In: IEEE. *Biomedical Imaging (ISBI), 2016 IEEE 13th International Symposium on*. [S.l.], 2016. p. 1397–1400. Citado na página 32.

LI, Y.; SHEN, L. Skin lesion analysis towards melanoma detection using deep learning network. *arXiv preprint arXiv:1703.00577*, 2017. Citado 3 vezes nas páginas 27, 51 e 53.

LOPES, A.; CHAMMAS, R.; IYEYASU, H. Oncologia para a graduação. In: *Oncologia para a graduação*. [S.l.: s.n.], 2013. Citado na página 25.

LOPEZ, A. R. et al. Skin lesion classification from dermoscopic images using deep learning techniques. In: IEEE. *Biomedical Engineering (BioMed), 2017 13th IASTED International Conference on*. [S.l.], 2017. p. 49–54. Citado 2 vezes nas páginas 51 e 53.

MARINHO, L. B. Estudo comparativo de métodos de visão computacional no reconhecimento de locais internos. In: . [S.l.: s.n.], 2016. Citado na página 34.

MATSUNAGA, K. et al. Image classification of melanoma, nevus and seborrheic keratosis by deep neural network ensemble. *arXiv preprint arXiv:1703.03108*, 2017. Citado 3 vezes nas páginas 27, 51 e 53.

MENDONÇA, T. et al. Ph 2-a dermoscopic image database for research and benchmarking. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*. [S.l.], 2013. p. 5437–5440. Citado na página 31.

- MESQUITA, D. P. P.; GOMES, J. P. P.; JUNIOR, A. H. S. Ensemble of minimal learning machines for pattern classification. In: SPRINGER. *International Work-Conference on Artificial Neural Networks*. [S.l.], 2015. p. 142–152. Citado na página 35.
- METE, M. et al. A novel classification system for dysplastic nevus and malignant melanoma. In: IEEE. *Image Processing (ICIP), 2016 IEEE International Conference on*. [S.l.], 2016. p. 3414–3418. Citado 2 vezes nas páginas 26 e 27.
- NEW approach to detect and classify stroke in skull CT images via analysis of brain tissue densities. *Computer Methods and Programs in Biomedicine*, v. 148, p. 27 – 43, 2017. ISSN 0169-2607. Citado na página 26.
- OJALA, T.; PIETIKAINEN, M.; HARWOOD, D. Performance evaluation of texture measures with classification based on kullback discrimination of distributions. In: IEEE. *Pattern Recognition, 1994. Vol. 1-Conference A: Computer Vision & Image Processing., Proceedings of the 12th IAPR International Conference on*. [S.l.], 1994. v. 1, p. 582–585. Citado 2 vezes nas páginas 38 e 44.
- RAHMAN, M.; ALPASLAN, N.; BHATTACHARYA, P. Developing a retrieval based diagnostic aid for automated melanoma recognition of dermoscopic images. In: IEEE. *Applied Imagery Pattern Recognition Workshop (AIPR), 2016 IEEE*. [S.l.], 2016. p. 1–7. Citado na página 26.
- RAMALHO, G. L. B. et al. Rotation-invariant feature extraction using a structural co-occurrence matrix. *Measurement*, Elsevier, v. 94, p. 406–415, 2016. Citado 4 vezes nas páginas 28, 38, 39 e 41.
- RAMALHO, G. L. B. et al. Lung disease detection using feature extraction and extreme learning machine. *Revista Brasileira de Engenharia Biomédica*, SciELO Brasil, v. 30, n. 3, p. 207–214, 2014. Citado na página 26.
- RODRIGUES, M. B. et al. Lung segmentation in chest computerized tomography images using the border following algorithm. In: SPRINGER. *International Conference on Intelligent Systems Design and Applications*. [S.l.], 2016. p. 539–548. Citado na página 26.
- RODRIGUES, M. B. et al. Health of things algorithms for malignancy level classification of lung nodules. *IEEE Access*, IEEE, v. 6, p. 18592–18601, 2018. Citado na página 26.
- S, S.; HAYKIN. *Neural networks and learning machines*. [S.l.]: Pearson Upper Saddle River, NJ, USA:, 2009. v. 3. Citado na página 34.
- SABBAGHI, S.; ALDEEN, M.; GARNAVI, R. A deep bag-of-features model for the classification of melanomas in dermoscopy images. In: IEEE. *Engineering in Medicine and Biology Society (EMBC), 2016 IEEE 38th Annual International Conference of the*. [S.l.], 2016. p. 1369–1372. Citado na página 27.
- SAMUI, P.; KOTHARI, D. Utilization of a least square support vector machine (lssvm) for slope stability analysis. *Scientia Iranica*, Elsevier, v. 18, n. 1, p. 53–58, 2011. Citado na página 35.
- SATHEESHA, T. et al. Melanoma is skin deep: A 3d reconstruction technique for computerized dermoscopic skin lesion classification. *IEEE Journal of Translational Engineering in Health and Medicine*, IEEE, v. 5, p. 1–17, 2017. Citado 2 vezes nas páginas 51 e 53.

- SONG, F. et al. Personal history of keratinocyte carcinoma is associated with reduced risk of death from invasive melanoma in men. *Journal of the American Academy of Dermatology*, Elsevier, 2018. Citado na página 25.
- SOUSA, R. T.; MORAES, L. V. de. Araguaia medical vision lab at isic 2017 skin lesion classification challenge. *arXiv preprint arXiv:1703.00856*, 2017. Citado 2 vezes nas páginas 51 e 53.
- SOUZA, A. H. de et al. Minimal learning machine: a novel supervised distance-based approach for regression and classification. *Neurocomputing*, Elsevier, v. 164, p. 34–44, 2015. Citado na página 35.
- SOUZA, J. W. de; ALMEIDA, J. S.; FILHO, P. P. R. A new approach for the diagnosis of parkinson’s disease using a similarity feature extractor. In: SPRINGER. *International Conference on Intelligent Systems Design and Applications*. [S.l.], 2017. p. 21–31. Citado na página 35.
- SOUZA, J. W. de et al. A new approach to diagnose parkinson’s disease using a structural cooccurrence matrix for a similarity analysis. *Computational Intelligence and Neuroscience*, Hindawi, v. 2018, 2018. Citado na página 26.
- VAPNIK, V. N.; VAPNIK, V. *Statistical learning theory*. [S.l.]: Wiley New York, 1998. v. 1. Citado na página 35.
- WAHEED, Z. et al. An efficient machine learning approach for the detection of melanoma using dermoscopic images. In: IEEE. *Communication, Computing and Digital Systems (C-CODE), International Conference on*. [S.l.], 2017. p. 316–319. Citado 4 vezes nas páginas 26, 27, 51 e 53.
- YU, L. et al. Automated melanoma recognition in dermoscopy images via very deep residual networks. *IEEE transactions on medical imaging*, IEEE, v. 36, n. 4, p. 994–1004, 2017. Citado 3 vezes nas páginas 27, 51 e 53.
- YU, Z. et al. Hybrid dermoscopy image classification framework based on deep convolutional neural network and fisher vector. In: IEEE. *Biomedical Imaging (ISBI 2017), 2017 IEEE 14th International Symposium on*. [S.l.], 2017. p. 301–304. Citado 3 vezes nas páginas 27, 51 e 53.