

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Murilo Villas Bôas da Costa

**Reconhecimento Facial com LBP sobre
Transformação de Imagem Baseada em Graus de
Redes Complexas**

Monte Carmelo, Brasil

2026

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Murilo Villas Bôas da Costa

**Reconhecimento Facial com LBP sobre Transformação de
Imagem Baseada em Graus de Redes Complexas**

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido parcial à obtenção do grau de Bacharel em Sistemas de Informação.

Orientador: Leandro Nogueira Couto

Universidade Federal de Uberlândia – UFU

Faculdade de Computação

Bacharelado em Sistemas de Informação

Monte Carmelo, Brasil

2026

Murilo Villas Bôas da Costa

Reconhecimento Facial com LBP sobre Transformação de Imagem Baseada em Graus de Redes Complexas

Trabalho de conclusão de curso apresentado à Faculdade de Computação da Universidade Federal de Uberlândia, Minas Gerais, como requisito exigido parcial à obtenção do grau de Bacharel em Sistemas de Informação.

Trabalho aprovado. Monte Carmelo, Brasil, 28 de Agosto de 2026:

Prof. Dr. Leandro Nogueira Couto
Orientador

Monte Carmelo, Brasil
2026

Dedico este trabalho aos meus familiares, e ao meu orientador Leandro Nogueira Couto, e a todos meus amigos que com muito apoio, mesmo nos momentos mais difíceis, não mediram esforços para que eu chegasse até esta etapa de minha vida.

Agradecimentos

Agradeço a Deus, primeiramente, que permitiu que tudo isso acontecesse, ao longo da minha vida, e não somente nestes anos como universitário, mas em todos os momentos. A esta universidade, à direção, administração e seu corpo docente por me proporcionar o conhecimento não apenas racional, mas a manifestação do caráter e afetividade da educação no processo de formação profissional, por tanto que se dedicaram a mim, não somente por terem me ensinado, mas por terem me feito aprender.

À minha família e amigos tenho um agradecimento muito especial porque acreditaram em mim desde o primeiro instante. Sou quem sou porque vocês estiveram e estão sempre ao meu lado.

A todos os colegas, companheiros que estiveram ao meu lado diretamente ou indiretamente durante esta conquista, o meu muito obrigado.

"Não importa aonde você parou... Em que momento da vida você cansou... O que importa é que sempre é possível e necessário "Recomeçar". Recomeçar é dar uma chance a si mesmo... É renovar as esperanças na vida e o mais importante... Acreditar em você de novo. " -
Carlos Drummond de Andrade

Resumo

Este trabalho apresenta um estudo abrangente sobre a caracterização e análise de texturas e rostos através de uma metodologia híbrida que combina redes complexas, Local Binary Patterns (LBP) e estatísticas discriminativas. A abordagem proposta utiliza uma transformação baseada no grau da rede complexa como operação de pré-processamento antes da aplicação do LBP, permitindo a descrição de padrões em escalas maiores sem aumentar indevidamente a dimensionalidade do vetor de características.

Os experimentos abrangeram múltiplas bases de dados: uma base de texturas (Brodatz) e três bases de reconhecimento facial (JAFFE, Yale Faces, Faces Data). Os resultados revelam um padrão dicotômico: o método proposto é altamente eficaz em reconhecimento facial, atingindo taxas de acerto de até 97.65% na base JAFFE e 99.88% na base Faces Data, com melhorias de até 7.88% em relação ao LBP tradicional em cenários desafiadores (Yale Faces). Contrastivamente, em classificação de texturas (Brodatz), o método não demonstrou melhoria significativa, sugerindo que é mais apropriado para aplicações com estruturas hierárquicas multi-escala. Esta análise abrangente, incluindo resultados bem-sucedidos e as limitações do método, fornece uma compreensão crítica sobre quando e por que a abordagem proposta é eficaz, estabelecendo direções claras para trabalhos futuros.

Lista de ilustrações

Figura 1 – Exemplo do processo de codificação LBP: (a) vizinhança de um pixel com seus valores de intensidade; (b) geração do padrão binário pela comparação com o pixel central; (c) pesos para conversão binária; (d) conversão para valor decimal final.	17
Figura 2 – Resumo do descritor proposto. A imagem original I é convertida em uma rede complexa G (a), então os graus dos vértices da rede são usados como os valores dos pixels para uma imagem transformada I_{CN} (b). Em seguida, o operador LBP é aplicado a cada pixel em I_{CN} para gerar I_{LBP} . Um histograma de níveis de cinza de I_{LBP} é o vetor de características φ , que será utilizado para classificação. Opcionalmente, estatísticas discriminativas são extraídas e concatenadas ao vetor.	25
Figura 3 – Exemplos de imagens da base Brodatz, apresentando quatro classes (texturas) distintas.	26
Figura 4 – Exemplos de imagens da base JAFFE, ilustrando variações de expressão emocional.	27
Figura 5 – Resultados visuais para a base JAFFE: (a) matriz de confusão do classificador; (b) exemplo do par de classes mais confundidas.	28
Figura 6 – Exemplos de imagens da base Yale Faces, ilustrando variações entre classes como expressão e condições de captura.	29
Figura 7 – Resultados visuais para a base : (a) matriz de confusão do classificador; (b) exemplo do par de classes mais confundidas.	30
Figura 8 – Exemplos de imagens da base Faces Data, ilustrando variações controladas de pose e iluminação.	31
Figura 9 – Resultados visuais para a base : (a) matriz de confusão do classificador; (b) exemplo de classes mais confundidas.	32

Lista de tabelas

- Tabela 1 – A tabela apresenta as acurácias obtidas na base Brodatz para o LBP tradicional e para as variações RedeLBP e RedeLBPstats em diferentes valores de r_G . Observa-se que o LBP tradicional atinge 92.57% e serve como baseline. Para o método RedeLBP, a melhor classificação ocorre em $r_G = 6$ com 92.40%, enquanto para o RedeLBPstats o melhor resultado ocorre também em $r_G = 6$, alcançando 93.13%. Em contrapartida, para raios maiores (por exemplo $r_G \geq 7$), nota-se uma queda relevante de desempenho em ambos os métodos baseados em rede, sugerindo que o aumento excessivo do raio pode reduzir a capacidade discriminativa em texturas com padrões finos. 27
- Tabela 2 – A tabela apresenta as acurácias obtidas na base JAFFE. O LBP tradicional atinge 91.55%. Já o método RedeLBP melhora substancialmente com o aumento de r_G , atingindo seu melhor valor em $r_G = 13$ com 96.24%. Quando adicionadas estatísticas discriminativas (RedeLBPstats), observa-se o melhor desempenho global em $r_G = 13$ com 97.65%, evidenciando que, para expressões faciais, o uso de raios maiores no grafo contribui para capturar padrões faciais em múltiplas escalas e que as estatísticas adicionam poder discriminativo adicional. 28
- Tabela 3 – A tabela apresenta as acurácias obtidas na base Yale Faces. O LBP tradicional alcança 68.48%, enquanto o LBPstats melhora para 72.12%, indicando que estatísticas adicionais no histograma podem trazer ganhos mesmo sem a transformação por rede. Para o método proposto, observa-se que o RedeLBP tende a melhorar com o aumento de r_G , atingindo acurácia máxima de 76.36% (observada em $r_G = 9$, $r_G = 12$ e $r_G = 15$). Já o RedeLBPstats não supera o melhor resultado do RedeLBP nesta base, sugerindo que, para Yale Faces, o principal ganho está associado ao uso de vizinhança em maior escala via transformação por graus da rede, enquanto as estatísticas adicionais não trazem benefício consistente. . . . 29

Tabela 4 – A tabela apresenta as acurácias obtidas na base Faces Data. Observa-se que o baseline LBP já atinge 99.64%, indicando que a base é altamente separável pelo descritor tradicional. Ainda assim, o método RedeLBP apresenta desempenho superior em diversos valores de r_G , atingindo 99.88% (por exemplo em $r_G = 9$ e $r_G = 10$), o que sugere que a transformação baseada nos graus da rede pode refinar a representação sem aumentar a dimensionalidade do vetor de características do LBP. Além disso, as variações de desempenho ao longo de r_G são pequenas, indicando robustez do método para essa base.	31
Tabela 5 – A tabela consolida os melhores resultados obtidos em cada base, indicando o método vencedor, a acurácia correspondente e o(s) valor(es) de r_G em que o melhor desempenho foi observado, além da melhoria em relação ao baseline LBP. Observa-se que os maiores ganhos ocorrem nas bases faciais JAFFE (+6.10%) e Yale Faces (+7.88%), reforçando que a metodologia proposta é particularmente eficaz para reconhecimento facial sob variações de expressão e condições de captura. Em contrapartida, na base de textura Brodatz o ganho é marginal (+0.56%), sugerindo limitação do método para texturas finas e altamente regulares.	33
Tabela 6 – A tabela quantifica a sensibilidade do desempenho em função do raio r_G por meio dos valores mínimo e máximo, da amplitude (em pontos percentuais) e do desvio padrão. Nota-se que a maior variação ocorre em JAFFE com RedeLBPstats (79.81pp), evidenciando alta dependência da escolha de r_G nessa configuração. Em contraste, Faces Data apresenta baixa variação (3.24pp), indicando maior estabilidade do desempenho ao longo dos raios testados. Esses resultados reforçam que a seleção de r_G é um fator crítico para a aplicabilidade prática, sobretudo em cenários com variações faciais mais desafiadoras.	33

Lista de abreviaturas e siglas

CNN	Convolutional Neural Network (Rede Neural Convolucional)
G	Rede Complexa (Grafo)
GLCM	Gray Level Co-occurrence Matrix (Matriz de Coocorrência de Níveis de Cinza)
GLDM	Gray Level Difference Matrix (Matriz de Diferença de Níveis de Cinza)
I	Imagem Original
I_{CN}	Imagem Transformada por Rede Complexa
I_{LBP}	Imagem Transformada por LBP
JAFFE	Japanese Female Facial Expression Database
k-fold	Validação Cruzada com k Grupos
LBP	Padrão Binário Local (Local Binary Patterns)
LBP-TOP	Local Binary Patterns - Three Orthogonal Planes
LBPROT	Local Binary Patterns Rotation Invariant
LDA	Linear Discriminant Analysis (Análise Linear Discriminante)
MATLAB	Matrix Laboratory
MRELBP	Median Robust Extended Local Binary Pattern
RedeLBP	Rede Complexa Combinada com LBP
RedeLBPstats	Rede Complexa Combinada com LBP e Estatísticas Discriminativas
r_G	Raio da Rede Complexa
φ	Vetor de Características (Histograma LBP)
φ_{ext}	Vetor de Características Estendido (com Estatísticas)
VLBP	Volumetric Local Binary Patterns
V, E	Vértices e Arestas de um Grafo

Sumário

1	INTRODUÇÃO	13
1.1	Processamento De Imagem	13
1.1.1	Análise De Textura	13
1.1.2	Motivação	14
1.2	Objetivos	15
1.2.1	Objetivo Geral	15
1.2.2	Objetivos específicos	15
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Local Binary Pattern	16
2.1.1	Princípios Fundamentais do LBP	16
2.1.2	Variantes e Adaptações do LBP	17
2.2	Redes Complexas	19
2.2.1	Conceitos Fundamentais	19
2.2.2	Representação de Imagens como Redes Complexas	19
2.2.3	Grau de Rede e Análise de Características	20
2.2.4	Propriedades de Redes Geográficas	21
3	METODOLOGIA	22
3.1	Redes Complexas Combinadas com Local Binary Pattern	22
3.1.1	Motivação da Combinação	22
3.1.2	Pipeline do Método Proposto	22
3.1.3	Tratamento de Ambiguidades nos Graus	23
3.1.4	Atributos de Histograma e Estatísticas Discriminativas	24
4	EXPERIMENTOS E RESULTADOS	26
4.1	Base Brodatz	26
4.2	Base JAFFE	27
4.3	Base Yale Faces	29
4.4	Base Faces Data	30
4.5	Síntese Comparativa dos Resultados	33
4.6	Análise dos Resultados	33
4.6.1	Análise de Sucessos	33
4.6.2	Análise de Limitações e Fracassos	34

5	CONCLUSÕES E TRABALHOS FUTUROS	35
5.1	Produção bibliográfica	35
5.2	Trabalhos futuros	35
	REFERÊNCIAS	36

1 Introdução

1.1 Processamento De Imagem

As técnicas voltadas para a análise de dados bidimensionais, adquiridos por diversos tipos de sensores recebem o nome de processamento digital de imagens, ou seja, é a manipulação de uma imagem por computador de modo onde a entrada e a saída do processo são imagens.

A área de Processamento de Imagens incorpora fundamentos de várias ciências, como Física, Computação, Matemática. Conceitos como Óptica, Física do Estado Sólido, Projeto de Circuitos, Teoria dos Grafos, Álgebra, Estatística, dentre outros, são comumente requeridos no projeto de um sistema de processamento de imagens. Existe também uma intersecção forte entre processamento digital de imagens e outras disciplinas como Redes Neurais, Inteligência Artificial, Percepção Visual, Ciência Cognitiva (QUEIROZ; GOMES, 2001). Em particular, problemas de análise e reconhecimento facial continuam sendo fortemente estudados e aplicados em cenários reais (WANG et al., 2022).

O processamento de imagens pode-se dividir em pré-processamento, realce e classificação. Pré-processamento refere-se ao processamento inicial de dados brutos para calibração radiométrica da imagem, correção de distorções geométricas e remoção de ruído. Realce visa melhorar a qualidade da imagem, permitindo uma melhor discriminação dos objetos. A visão computacional é o processo de modelagem e replicação da visão humana usando software e hardware. O reconhecimento de imagens, análise de pixel e padrão de imagens é uma parte integrante do processo de visão computacional que envolve tudo, desde reconhecimento de objetos e caracteres até análise de texto e sentimento. Na classificação são atribuídas classes aos objetos.

1.1.1 Análise De Textura

Textura é um termo complexo para se definir, mas a nível geral a textura está relacionada com a superfície externa de um objeto. Trata-se de uma propriedade que é captada através do tato ou visão. Segundo Hájek (HÁJEK, 2006) texturas são padrões visuais complexos compostos de elementos espacialmente organizados, com características particulares como brilho, cor, forma e tamanho, entre outras.

1.1.2 Motivação

Com a evolução dos computadores, obter uma descrição que contenha informação suficiente para distinguir entre diferentes objetos na análise de texturas em processamento de imagens vem se tornando uma área de pesquisa muito promissora, devido à sua velocidade de processamento e ao alto potencial de precisão.

Existem diversas áreas de aplicação em que técnicas de classificação para reconhecimento de texturas são essenciais. A seguir listamos alguns exemplos:

- Medicina: auxiliar no diagnóstico médico por meio de imagens obtidas em exames como tomografia computadorizada e ultrassonografia, permitindo identificar anomalias e células com câncer (CHEN; CHANG; HUANG, 2002).
- Agricultura: a partir de imagens capturadas por drones, realizar análise para identificação de doenças e pragas (AL-HIARY et al., 2011).
- Identificação de Faces: utilizar imagens capturadas por câmeras para análise de expressões e reconhecimento facial (SAMAL; IYENGAR, 1992; WANG et al., 2022; ZENG et al., 2023).

A textura é uma propriedade altamente discriminativa da imagem, porém, muitos métodos estatísticos para descrição de texturas são computacionalmente caros e apresentam baixa escalabilidade (ZHAO; PIETIKÄINEN, 2007). Por isso, há oportunidades de explorar métodos que descrevam regiões em maior escala, como abordagens baseadas em redes complexas, mantendo uma complexidade computacional viável.

Além disso, problemas faciais mais desafiadores, como reconhecimento de expressões e micro-expressões, continuam motivando o uso e a comparação de descritores locais (como LBP/LBPH) com métodos recentes baseados em redes neurais (WANG et al., 2022; ZENG et al., 2023; KUMAR; SAGAR; PUNETHA, 2023).

Embora métodos recentes baseados em deep learning tenham se tornado predominantes em tarefas de reconhecimento facial devido ao seu alto desempenho, esses modelos tendem a ser intrinsecamente menos transparentes, o que pode dificultar a interpretação das decisões do classificador. Em contraste, descritores manuais como LBP/LBPH possuem um mecanismo de extração de características mais direto e interpretável, permitindo relacionar decisões do modelo a padrões locais da imagem. A literatura de Inteligência Artificial Explicável (XAI) destaca a relevância de interpretabilidade e transparência, especialmente quando modelos são aplicados em cenários reais e sensíveis (ARRIETA et al., 2020; MOLNAR, 2022). Assim, mesmo em um contexto de predominância de redes profundas, descritores clássicos

e explicáveis continuam tendo valor como baselines e como alternativas em pipelines com maior transparência.

Neste contexto, este trabalho investiga uma abordagem híbrida que combina redes complexas e LBP, explorando vantagens de escalabilidade e interpretabilidade, e avaliando seu desempenho em bases de texturas e, principalmente, em bases faciais.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral deste trabalho é caracterizar texturas e rostos utilizando a combinação de diversos métodos eficientes. Será apresentado os métodos de Redes Complexas, Local Binary Pattern (LBP), Caminhadas Determinísticas, Mediana e Estatísticas Discriminativas.

1.2.2 Objetivos específicos

- Avaliar o desempenho de redes complexas nas imagens combinado com histograma LBP.
- Avaliar a influência do cálculo das estatísticas discriminativas do histograma LBP aplicado na rede complexa.
- Analisar a viabilidade do cálculo da mediana nas imagens antes de gerar o histograma LBP.

2 Fundamentação Teórica

2.1 Local Binary Pattern

O Padrão Binário Local (LBP) é um operador de textura simples, mas altamente eficiente, amplamente utilizado na classificação de texturas. Ele identifica os pixels de uma imagem, considerando a vizinhança de cada pixel e representando o resultado como um número binário. O LBP é uma abordagem unificadora que combina modelos estatísticos e estruturais na análise de texturas, tornando-se popular em várias aplicações (PIETIKÄINEN, 2010).

2.1.1 Princípios Fundamentais do LBP

Uma das propriedades mais importantes do operador LBP é sua robustez às alterações de escala de cinza causadas por variações de iluminação, o que o torna adequado para aplicações do mundo real. Além disso, sua simplicidade computacional permite a análise de imagens em tempo real, mesmo em configurações desafiadoras (PIETIKÄINEN, 2010; PAUL; ASLAN, 2021). O LBP avalia a vizinhança de cada pixel, gerando um padrão local baseado na diferença entre os valores dos pixels. Seja um pixel $i = (x, y)$ da imagem I , onde $I(i)$ é a intensidade do pixel. Tomando-se uma vizinhança de raio $r = \sqrt{2}$, o pixel i possui 8 vizinhos, denotados por $N_i = \{n_{i,1}, n_{i,2}, \dots, n_{i,8}\}$ (COUTO, 2018). O método LBP propõe a comparação do pixel i com cada um de seus vizinhos em determinada ordem, criando um vetor T de 8 dígitos binários, de acordo com a Equação 2.1:

$$T = \{s([I(i) - I(n_{i,1})]), s([I(i) - I(n_{i,2})]), \dots, s([I(i) - I(n_{i,8})])\} \quad (2.1)$$

Em T , cada dígito recebe valor 0 se o valor de intensidade do pixel vizinho de índice correspondente é maior que $I(i)$, e recebe valor 1 caso contrário, de acordo com a função de sinal $s(d)$ apresentada na Equação 2.2:

$$s(d) = \begin{cases} 0, & d < 0 \\ 1, & d \geq 0 \end{cases} \quad (2.2)$$

Considerando 8 vizinhos, o vetor de 8 dígitos binários, quando analisado como um byte, pode ser convertido da base binária para um valor decimal correspondente. Este valor decimal descreve a configuração de intensidade relativa da vizinhança do pixel. Há um total de 256 valores distintos possíveis (desde 2^8 combinações), no intervalo $[0, 255]$, e chamamos esse valor

de valor ou codificação LBP do pixel (COUTO, 2018). O processo de geração do valor LBP para um pixel é exemplificado na Figura 1.




Figura 1 – Exemplo do processo de codificação LBP: (a) vizinhança de um pixel com seus valores de intensidade; (b) geração do padrão binário pela comparação com o pixel central; (c) pesos para conversão binária; (d) conversão para valor decimal final.

2.1.2 Variantes e Adaptações do LBP

O LBP tem sido amplamente utilizado no reconhecimento de texturas, apresentando altas taxas de acerto em tarefas de classificação e segmentação de texturas (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002). Uma das primeiras adaptações do método LBP é o LBP_{ROT} , que busca alcançar invariância a rotação. O LBP_{ROT} considera rotações de um mesmo padrão binário como padrões idênticos; por exemplo, os valores “00001010” e “00000101” são considerados o mesmo padrão, apenas rotacionado. Porém, essa adaptação apresenta limitações significativas em termos de poder de discriminação (PIETIKÄINEN; OJALA; XU, 2000).

Uma adaptação mais bem-sucedida para a invariância a rotação é o uso de padrões uniformes no LBP (OJALA; PIETIKÄINEN; MÄENPÄÄ, 2002). Esses padrões possuem alta uniformidade e podem ser agrupados em um único bin do histograma, melhorando as taxas de classificação mesmo em texturas rotacionadas. A ideia baseia-se na observação de que um conjunto pequeno de padrões ocorre na maioria das texturas com muito mais frequência que todos os outros. Padrões uniformes são aqueles que possuem alta uniformidade U , uma medida que corresponde ao número de transições entre 0 e 1 no padrão LBP. Por exemplo, o padrão “11111111” é perfeitamente uniforme pois não há transições ($U = 0$), enquanto o padrão “00111000” tem duas transições e portanto $U = 2$ (COUTO, 2018). Ao longo dos anos,

várias variantes do LBP foram desenvolvidas para diferentes aplicações, como o MRELBP (Median Robust Extended LBP), que incorpora melhorias adicionais ao método e aplica o LBP a valores de medianas locais da imagem em vez de aos valores originais de intensidade (LIU et al., 2016; HUANG et al., 2011).

Além disso, o sucesso do LBP na descrição de texturas estáticas motivou sua aplicação a dados espaço-temporais, como no caso do VLBP (Volumetric LBP) e do LBP-TOP (LBP - Three Orthogonal Planes), utilizados na classificação de texturas dinâmicas (ZHAO; PIETIKÄINEN, 2007). O VLBP é baseado em uma análise volumétrica que considera a vizinhança de cada pixel nas três dimensões $[X, Y, T]$ do vídeo para compor sua codificação LBP, enquanto o LBP-TOP calcula o histograma com base em múltiplas combinações de planos ortogonais (COUTO, 2018).

Em resumo, o Padrão Binário Local é um operador de textura eficiente e robusto que combina modelos estatísticos e estruturais na análise de texturas. Suas adaptações, como o uso de padrões uniformes e variantes como o MRELBP, têm demonstrado altas taxas de classificação em diversas aplicações. O LBP também tem sido aplicado com sucesso em texturas dinâmicas, mostrando sua versatilidade e potencial para diferentes contextos.

No contexto de análise facial, o LBP e suas variantes também permanecem relevantes, tanto em tarefas de reconhecimento de identidade quanto de expressões. Além disso, o reconhecimento facial continua sendo um tema com intensa produção recente, abrangendo desde pipelines clássicos até abordagens modernas baseadas em deep learning (WANG et al., 2022).

Além dos trabalhos clássicos baseados em LBP para descrição facial, estudos recentes têm revisitado e sistematizado o uso de LBP em problemas mais desafiadores, como o reconhecimento de micro-expressões. Zeng et al. (ZENG et al., 2023) revisam métodos de reconhecimento de micro-expressões baseados em LBP, fluxo óptico e deep learning, discutindo bases de dados, pré-processamento, métricas de avaliação e resultados reportados nos últimos 5 anos, além de limitações e direções futuras. Essa literatura recente ajuda a contextualizar a retomada do tema e reforça a relevância de descritores locais (como LBP e variantes) em cenários faciais com variações sutis e rápidas de expressão.

Além disso, Kumar et al. (KUMAR; SAGAR; PUNETHA, 2023) realizam um estudo comparativo recente em reconhecimento de expressões faciais, contrastando descritores baseados em LBP com abordagens baseadas em redes neurais, o que reforça a permanência do LBP como baseline relevante em tarefas de análise facial modernas. Em cenários mais práticos de reconhecimento facial, Paul e Aslan (PAUL; ASLAN, 2021) investigam um pipeline baseado em LBPH com pré-processamento (incluindo CLAHE e alinhamento facial),

reportando desempenho competitivo mesmo em condições adversas como baixa resolução, o que evidencia a continuidade do uso do LBP/LBPH em aplicações reais.

Em conjunto, esses trabalhos reforçam que o LBP/LBPH permanece relevante como baseline e componente de pipelines em tarefas faciais, mesmo com a predominância atual de métodos baseados em redes profundas (WANG et al., 2022).

2.2 Redes Complexas

2.2.1 Conceitos Fundamentais

Redes complexas podem ser conceituadas como estando na interseção entre a teoria dos grafos e a mecânica estatística, o que lhe confere uma natureza verdadeiramente multidisciplinar. Cada rede complexa (ou classe de redes) apresenta características topológicas específicas que caracterizam sua conectividade e influenciam fortemente a dinâmica dos processos executados na rede (COSTA et al., 2007).

Em sua definição mais geral, uma rede é uma abstração que permite codificar algum tipo de relacionamento entre pares de objetos. Por exemplo, em redes sociais objetos são geralmente indivíduos e relacionamentos representam algum tipo de relação social, como amizade ou trabalho em conjunto. Redes estão por todos os lados e durante a última década muitos estudos empíricos vêm identificando propriedades peculiares em redes muito distintas, da Internet e Redes Sociais Online (ex. Facebook) até redes de citação e redes de neurônios (COSTA et al., 2007).

A flexibilidade e generalidade na representação tornaram as redes complexas populares, pois praticamente qualquer estrutura natural, incluindo aquelas que sofrem mudanças dinâmicas de topologia, pode ser adequadamente representada. Na verdade, toda estrutura discreta, como listas, árvores, redes e imagens, podem ser adequadamente representadas como um grafo (COSTA et al., 2007).

2.2.2 Representação de Imagens como Redes Complexas

Levando em conta os princípios acima, vários estudos incluem investigações sobre como representar um problema como uma rede complexa, seguida por uma análise de suas características topológicas e extração de características. Algumas aplicações usam esses descritores para distinguir diferentes classes e, portanto, criar técnicas para reconhecimento de padrões (BACKES; CASANOVA; BRUNO, 2013).

Em imagens, os pixels são representados como nós (vértices) da rede, e as semelhanças

entre tais pixels são mapeadas como links (arestas) entre os nós da rede. (BACKES; CASANOVA; BRUNO, 2013) propõem uma abordagem inovadora para análise de texturas usando redes complexas: cada pixel da imagem é representado como um nó, e as conexões entre os nós são baseadas na distância euclidiana e na diferença de intensidade entre pixels.

Formalmente, seja I uma imagem e $G = (V, E)$ uma rede complexa que a representa, onde cada pixel $p = I(x, y)$ corresponde a um vértice $v_{x,y} \in V$. Um conjunto inicial de arestas E' é determinado por uma restrição de raio máximo r_G , como mostrado na Equação 2.3:

$$E' = \{(v_{x,y}, v_{x',y'}) \in I \times I \mid d((x, y), (x', y')) \leq r_G\} \quad (2.3)$$

onde $d((x, y), (x', y'))$ é a distância euclidiana entre as coordenadas. Para priorizar conexões entre pixels similares, cada aresta potencial recebe um peso baseado em dissimilaridade, como mostrado na Equação 2.4:

$$w(v_{x,y}, v_{x',y'}) = ((x - x')^2 + (y - y')^2) + \left(r_G^2 \frac{|I(x, y) - I(x', y')|}{255} \right) \quad (2.4)$$

As arestas finais E são selecionadas através da aplicação de um limiar t , conforme a Equação 2.5:

$$E^* = \{e \in E \mid w(e) \leq t\} \quad (2.5)$$

Embora abordagens modernas de reconhecimento facial sejam majoritariamente baseadas em deep learning, descritores e transformações baseadas em características locais continuam sendo relevantes como baselines e como componentes de comparação em análise facial (WANG et al., 2022; KUMAR; SAGAR; PUNETHA, 2023).

2.2.3 Grau de Rede e Análise de Características

Um dos atributos mais importantes de um nó em uma rede é seu grau, definido como o número de vértices conectados diretamente a ele por arestas. Seja $\partial(v_{x,y})$ o conjunto de vértices vizinhos de $v_{x,y}$ para um limiar escolhido t , o grau é dado por (Backes et al., 2013):

$$\deg(v_{x,y}) = |\partial(v_{x,y})| = |\{v' \in V \mid (v_{x,y}, v') \in E \text{ e } w(v_{x,y}, v') \leq t\}| \quad (2.6)$$

O grau de cada vértice carrega informação sobre quão semelhante o pixel correspondente é aos seus vizinhos. Em uma rede gerada a partir de uma imagem, regiões homogêneas terão graus elevados, enquanto pixels com valores distintos em relação à vizinhança (como em certas texturas ou pixels de ruído) terão graus baixos (BACKES; CASANOVA; BRUNO, 2013).

A partir da rede complexa G , é possível gerar uma imagem transformada I_{CN} onde a intensidade de cada pixel $I_{CN}(x, y)$ é dada pelo grau $\deg(v_{x,y})$ do vértice correspondente.

Esta transformação preserva informação discriminativa da textura original e oferece uma representação mais robusta das características estruturais da imagem (BACKES; CASANOVA; BRUNO, 2013).

Segundo Backes (2013), diferentes tipos de texturas apresentam distribuições de graus de nós que são muito distintas daquelas observadas em redes aleatórias, sugerindo uma organização complexa e estruturada dessas texturas. Medições tradicionais de conectividade de rede são então aplicadas para obter vetores de características, que podem ser usados para caracterização e classificação de texturas com altas taxas de acerto (BACKES; CASANOVA; BRUNO, 2013).

2.2.4 Propriedades de Redes Geográficas

Na teoria de redes complexas, a representação proposta configura-se como uma rede geográfica ou espacial, onde a posição dos vértices é relevante e pares de vértices próximos têm maior chance de apresentarem arestas (COSTA et al., 2007). Além disso, a restrição de que a ligação entre vértices apenas possa ocorrer dentro de uma região de raio r_G aumenta a probabilidade de formação de hubs (vértices altamente conectados) e comunidades bem distintas (BACKES; CASANOVA; BRUNO, 2013).

Esta propriedade é particularmente importante para análise de texturas, pois permite capturar tanto características locais quanto estruturas de maior escala, oferecendo um poder discriminativo superior ao de métodos que consideram apenas vizinhanças imediatas.

Em resumo, redes complexas oferecem um framework poderoso e flexível para análise de imagens e texturas. A representação de imagens como grafos permite explorar propriedades topológicas que capturam características estruturais e discriminativas das texturas, complementando e aprimorando métodos clássicos como o LBP.

3 Metodologia

3.1 Redes Complexas Combinadas com Local Binary Pattern

3.1.1 Motivação da Combinação

Este trabalho propõe a aquisição da transformação baseada no grau da rede complexa como uma operação de pré-processamento antes de aplicar o LBP (Local Binary Patterns). O LBP é então aplicado aos valores de grau da rede na imagem transformada I_{CN} . O objetivo dessa abordagem é aproveitar a capacidade da transformação baseada no grau da rede complexa em destacar, por meio de um único valor (o grau da rede), a similaridade entre um pixel e seus vizinhos em um determinado raio na imagem original. Com isso, o LBP pode ser aplicado a dados que já descrevem intrinsecamente uma região de pixels (COSTA; COUTO; COUTO, 2019).

Uma das principais diferenças entre a transformação baseada no grau da rede complexa e o LBP é que, no caso da primeira, raios consideravelmente maiores podem ser utilizados em comparação aos raios do LBP. Por exemplo, um raio de 15 resulta em 706 vizinhos, o que é viável para o cálculo do grau da rede complexa e não altera o tamanho do vetor de características resultante. No entanto, se fosse aplicado o LBP, o vetor de características resultante teria um tamanho de 2^{706} , o que é computacionalmente inviável (COSTA; COUTO; COUTO, 2019). Esta vantagem permite que o método capture características de texturas em múltiplas escalas sem o aumento exponencial do espaço de características (BACKES; CASANOVA; BRUNO, 2013).

3.1.2 Pipeline do Método Proposto

O LBP pode ser aplicado diretamente à imagem transformada baseada na rede complexa I_{CN} , sem a necessidade de modificações, e o vetor de características resultante possui o mesmo tamanho que teria se fosse aplicado a uma imagem regular. O raio da rede complexa afeta o número máximo de níveis de escala de cinza que a imagem transformada pode ter, pois o raio determina o grau máximo possível para cada nó da rede.

O pipeline completo do método proposto pode ser resumido nos seguintes passos:

1. **Geração da Rede Complexa:** A partir da imagem original I , gera-se uma rede complexa $G = (V, E)$ com raio máximo r_G , onde cada pixel corresponde a um vértice

e as arestas são determinadas pela dissimilaridade (Equação 2.4).

2. **Múltiplas Transformações por Limiar:** Cria-se um conjunto de múltiplas redes G_t para diferentes limiares t dentro do intervalo $T = \{t_1, t_2, \dots, t_n\}$, conforme estabelecido por Backes et al. (2013) no intervalo $t \in [0.005, 0.530]$ com incrementos de 0.015.
3. **Cálculo da Transformação Média:** Para cada pixel, calcula-se a média dos graus obtidos em cada rede G_t , gerando uma imagem transformada I_{CN} onde (Couto, 2018):

$$I_{CN}(x, y) = \frac{1}{|T|} \sum_{t \in T} \deg_{G_t}(v_{x,y}) \quad (3.1)$$

Este passo reduz significativamente a probabilidade de empates nos valores de grau, especialmente para raios menores. Por exemplo, para um raio de 2, o número limitado de graus possíveis (apenas 12) seria reduzido através dessa média ponderada.

4. **Aplicação do LBP:** Aplica-se o operador LBP à imagem transformada I_{CN} para gerar I_{LBP} , obtendo o vetor de características inicial φ através do histograma de I_{LBP} com dimensão 256 (Couto, 2018).
5. **Extração de Estatísticas Discriminativas (opcional):** Calculam-se medidas estatísticas adicionais sobre o histograma para formar o vetor final de características φ_{ext} .

3.1.3 Tratamento de Ambiguidades nos Graus

É importante ressaltar que, especialmente para raios menores, o número de graus possíveis pode ser bastante limitado (por exemplo, apenas 12 para um raio de 2). Isso inevitavelmente resulta em um alto número de empates nos valores entre os vizinhos. Essa situação é indesejável, pois quando os valores dos pixels são iguais no LBP, a decisão de atribuir o valor 0 ou 1 à posição correspondente no descritor LBP é arbitrária, comprometendo a estabilidade do método.

Para contornar essa questão, optou-se por realizar a transformação da rede complexa para o mesmo intervalo de valores de limiar utilizados por Backes et al. (2013). Em seguida, é calculada a média dos valores de grau para cada limiar (Equação 3.1), o que reduz significativamente a probabilidade de empates e torna o método mais robusto a variações de raio. A aplicação do LBP à imagem transformada I_{CN} resulta no vetor de características φ da imagem I .

3.1.4 Atributos de Histograma e Estatísticas Discriminativas

Além disso, foram realizados experimentos adicionando medidas de histograma ao vetor de características resultante, a fim de caracterizar ainda mais as propriedades discriminativas da textura. Esses atributos de histograma, também denominados estatísticas discriminativas, são calculados para o vetor de características φ (histograma de LBP) e adicionados a ele, formando o vetor estendido φ_{ext} .

Dentre as propriedades estatísticas mais populares na literatura por sua capacidade discriminativa comprovada, destacam-se 7 propriedades: energia, entropia, skewness, contraste, média, variância e kurtosis (COUTO, 2018). As seguintes medições são então aplicadas sobre o histograma gerado, denotando a topologia dos histogramas e podendo ser usadas para caracterizar descritores gerados pelo método proposto.

A Média é a medida do valor médio dos bins do histograma, e representa onde se concentram os valores na distribuição. Variância, Skewness e Kurtosis são chamados de momentos de segunda, terceira e quarta ordem, respectivamente. A Variância mede o grau de desvio do histograma em torno do eixo da Média. Skewness mede a assimetria do histograma em torno da Média (um histograma simétrico no eixo da Média tem Skewness igual a zero). Kurtosis mede o quão suave é a curva do histograma, ou seja, quão bruscas são as transições entre os bins (COUTO, 2018).

O Contraste mede a amplitude do desvio do histograma ao longo do eixo dos bins, e portanto, o quão concentrados ou espalhados são os valores. A medida de Energia mostra a uniformidade do histograma (um histograma com variações grandes de valores nos bins terá energia menor, um histograma em que todos os bins têm o mesmo valor tem energia alta). A Entropia é o contrário da Energia e mede o quão aleatória é a distribuição dos valores do histograma (COUTO, 2018).

Essas sete medidas são concatenadas ao vetor de características inicial φ , resultando em um vetor estendido φ_{ext} que contém tanto a informação de distribuição de padrões (histograma, 256 dimensões) quanto a informação sobre propriedades estatísticas da textura (7 dimensões adicionais), totalizando 263 dimensões quando utilizadas todas as estatísticas.




Figura 2 – Resumo do descritor proposto. A imagem original I é convertida em uma rede complexa G (a), então os graus dos vértices da rede são usados como os valores dos pixels para uma imagem transformada I_{CN} (b). Em seguida, o operador LBP é aplicado a cada pixel em I_{CN} para gerar I_{LBP} . Um histograma de níveis de cinza de I_{LBP} é o vetor de características φ , que será utilizado para classificação. Opcionalmente, estatísticas discriminativas são extraídas e concatenadas ao vetor.

A Figura 2 resume o método proposto, exemplificando-o com um exemplo real gerado a partir de uma das imagens do banco de dados JAFFE. Vale ressaltar que, no caso específico da rede complexa G , o exemplo é ilustrativo e a transformação ocorre em cada pixel da imagem original.

4 Experimentos e Resultados

Esse capítulo apresentará todos os resultados obtidos: valores obtidos da metodologia proposta neste trabalho aplicado em bases de texturas e de rostos e uma análise dos resultados.

4.1 Base Brodatz

A base Brodatz é uma coleção clássica de texturas em escala de cinza, amplamente utilizada em estudos de caracterização e classificação de texturas (BRODATZ, 1966). No presente trabalho, a base utilizada contém 1777 imagens, organizadas em classes onde cada textura corresponde a uma classe. Cada classe possui 16 imagens, representando variações/amstras da mesma textura.

A Figura 3 apresenta exemplos de imagens de quatro classes distintas da base, ilustrando a diversidade de padrões presentes (granularidade, contraste, regularidade e estruturas locais).




Figura 3 – Exemplos de imagens da base Brodatz, apresentando quatro classes (texturas) distintas.

Tabela 1 – A tabela apresenta as acurácias obtidas na base Brodatz para o LBP tradicional e para as variações RedeLBP e RedeLBPstats em diferentes valores de r_G . Observa-se que o LBP tradicional atinge 92.57% e serve como baseline. Para o método RedeLBP, a melhor classificação ocorre em $r_G = 6$ com 92.40%, enquanto para o RedeLBPstats o melhor resultado ocorre também em $r_G = 6$, alcançando 93.13%. Em contrapartida, para raios maiores (por exemplo $r_G \geq 7$), nota-se uma queda relevante de desempenho em ambos os métodos baseados em rede, sugerindo que o aumento excessivo do raio pode reduzir a capacidade discriminativa em texturas com padrões finos.

Método	Taxa de sucesso por r_G (%)										
	1	2	3	4	5	6	7	8	9	10	15
LBP						92.57					
RedeLBP	90.26	87.56	86.54	85.87	84.85	92.40	81.93	82.77	80.57	80.29	80.86
RedeLBPstats	91.22	88.63	88.23	88.18	87.33	93.13	84.07	83.28	82.71	80.74	82.32

4.2 Base JAFFE

A base JAFFE contém 213 imagens de faces, distribuídas em 10 classes, onde cada classe corresponde a uma pessoa distinta. Cada classe possui entre 21 e 23 imagens, contemplando diferentes expressões emocionais. Essa base é utilizada para avaliação de métodos de reconhecimento facial e, em particular, reconhecimento de expressões, devido às variações sistemáticas de expressão dentro de cada indivíduo.


A Figura 4 apresenta exemplos de imagens da base JAFFE (quatro amostras), ilustrando as variações de expressão presentes na base.



Figura 4 – Exemplos de imagens da base JAFFE, ilustrando variações de expressão emocional.

Tabela 2 – A tabela apresenta as acurácias obtidas na base JAFFE. O LBP tradicional atinge 91.55%. Já o método RedeLBP melhora substancialmente com o aumento de r_G , atingindo seu melhor valor em $r_G = 13$ com 96.24%. Quando adicionadas estatísticas discriminativas (RedeLBPstats), observa-se o melhor desempenho global em $r_G = 13$ com 97.65%, evidenciando que, para expressões faciais, o uso de raios maiores no grafo contribui para capturar padrões faciais em múltiplas escalas e que as estatísticas adicionam poder discriminativo adicional.

Método	Taxa de sucesso por r_G (%)														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
LBP	91.55														
RedeLBP	71.36	77.00	79.81	81.69	91.55	91.55	92.96	92.02	91.55	92.02	92.02	95.31	96.24	94.37	94.37
RedeLBPstats	77.00	17.84	62.44	86.85	92.02	88.73	92.02	90.14	93.43	92.49	91.08	96.24	97.65	94.84	96.71



(a) Matriz de confusão na base JAFFE.



(b) Exemplos das classes com maior confusão.

Figura 5 – Resultados visuais para a base JAFFE: (a) matriz de confusão do classificador; (b) exemplo do par de classes mais confundidas.

Erros de classificação em bases faciais são esperados, pois variações sutis de expressão podem gerar padrões locais muito semelhantes entre classes. Revisões e estudos comparativos recentes discutem esse desafio e mostram que descritores baseados em LBP frequentemente permanecem como baseline em tarefas de análise facial, inclusive em cenários desafiadores (ZENG et al., 2023; KUMAR; SAGAR; PUNETHA, 2023).

4.3 Base Yale Faces

A base Yale Faces contém 165 imagens faciais no formato GIF, com resolução original de 320×243 pixels, distribuídas em 15 classes, onde cada classe corresponde a uma pessoa distinta. Cada classe possui 11 amostras/imagens. A base apresenta variações relevantes entre as amostras, incluindo mudanças de expressão e condições de captura, o que a torna adequada para avaliar a robustez de descritores faciais frente a variações entre classes.


A Figura 6 apresenta exemplos de imagens da base Yale Faces (quatro amostras), ilustrando parte dessa variabilidade.



Figura 6 – Exemplos de imagens da base Yale Faces, ilustrando variações entre classes como expressão e condições de captura.

Tabela 3 – A tabela apresenta as acurácias obtidas na base Yale Faces. O LBP tradicional alcança 68.48%, enquanto o LBPstats melhora para 72.12%, indicando que estatísticas adicionais no histograma podem trazer ganhos mesmo sem a transformação por rede. Para o método proposto, observa-se que o RedeLBP tende a melhorar com o aumento de r_G , atingindo acurácia máxima de 76.36% (observada em $r_G = 9$, $r_G = 12$ e $r_G = 15$). Já o RedeLBPstats não supera o melhor resultado do RedeLBP nesta base, sugerindo que, para Yale Faces, o principal ganho está associado ao uso de vizinhança em maior escala via transformação por graus da rede, enquanto as estatísticas adicionais não trazem benefício consistente.

Método	Taxa de sucesso por r_G (%)														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
LBP								68.48							
LBPstats								72.12							
RedeLBP	64.85	61.21	60.61	63.03	65.45	67.88	66.06	70.30	76.36	73.94	73.33	76.36	71.52	73.94	76.36
RedeLBPstats	61.82	63.64	64.24	63.64	65.45	65.45	66.06	70.30	73.94	72.73	73.33	71.52	71.52	73.94	74.55



(a) Matriz de confusão na base Yale Faces.



(b) Exemplos das classes com maior confusão.

Figura 7 – Resultados visuais para a base : (a) matriz de confusão do classificador; (b) exemplo do par de classes mais confundidas.

Na base Yale Faces, observa-se que parte das confusões está associada às variações de iluminação, que alteram significativamente o padrão local capturado pelo descritor (WANG et al., 2022).

4.4 Base Faces Data

A base Faces Data contém 2500 imagens faciais no formato JPG, com resolução original de 180×200 pixels, distribuídas em 125 classes, onde cada classe corresponde a uma pessoa distinta. Cada classe possui 20 amostras/imagens, contemplando variações controladas

de pose e iluminação.


A Figura 8 apresenta exemplos de imagens da base Faces Data (quatro amostras), ilustrando essas variações.



Figura 8 – Exemplos de imagens da base Faces Data, ilustrando variações controladas de pose e iluminação.

Tabela 4 – A tabela apresenta as acurácias obtidas na base Faces Data. Observa-se que o baseline LBP já atinge 99.64%, indicando que a base é altamente separável pelo descritor tradicional. Ainda assim, o método RedeLBP apresenta desempenho superior em diversos valores de r_G , atingindo 99.88% (por exemplo em $r_G = 9$ e $r_G = 10$), o que sugere que a transformação baseada nos graus da rede pode refinar a representação sem aumentar a dimensionalidade do vetor de características do LBP. Além disso, as variações de desempenho ao longo de r_G são pequenas, indicando robustez do método para essa base.

Método	Taxa de sucesso por r_G (%)														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
LBP								99.64							
RedeLBP	96.64	97.68	99.20	99.68	99.56	99.72	99.84	99.84	99.88	99.88	99.72	99.84	99.84	99.74	99.84



(a) Matriz de confusão na base Yale Faces.



(b) Exemplos das classes com maior confusão.

Figura 9 – Resultados visuais para a base : (a) matriz de confusão do classificador; (b) exemplo de classes mais confundidas.

Na base Faces Data, a matriz de confusão é predominantemente diagonal, indicando poucas confusões entre classes e colaborando com o alto desempenho reportado na tabela(WANG et al., 2022).

4.5 Síntese Comparativa dos Resultados

Tabela 5 – A tabela consolida os melhores resultados obtidos em cada base, indicando o método vencedor, a acurácia correspondente e o(s) valor(es) de r_G em que o melhor desempenho foi observado, além da melhoria em relação ao baseline LBP. Observa-se que os maiores ganhos ocorrem nas bases faciais JAFFE (+6.10%) e Yale Faces (+7.88%), reforçando que a metodologia proposta é particularmente eficaz para reconhecimento facial sob variações de expressão e condições de captura. Em contrapartida, na base de textura Brodatz o ganho é marginal (+0.56%), sugerindo limitação do método para texturas finas e altamente regulares.

Base de Dados	Melhor Método	Acurácia (%)	r_G	Melhoria
Brodatz	RedeLBPstats	93.13	6	+0.56%
JAFFE	RedeLBPstats	97.65	13	+6.10%
Yale Faces	RedeLBP	76.36	9,12,15	+7.88%
Faces Data	RedeLBP	99.88	9,10	+0.24%

Tabela 6 – A tabela quantifica a sensibilidade do desempenho em função do raio r_G por meio dos valores mínimo e máximo, da amplitude (em pontos percentuais) e do desvio padrão. Nota-se que a maior variação ocorre em JAFFE com RedeLBPstats (79.81pp), evidenciando alta dependência da escolha de r_G nessa configuração. Em contraste, Faces Data apresenta baixa variação (3.24pp), indicando maior estabilidade do desempenho ao longo dos raios testados. Esses resultados reforçam que a seleção de r_G é um fator crítico para a aplicabilidade prática, sobretudo em cenários com variações faciais mais desafiadoras.

Base de Dados	Método	Min	Max	Distância	Des. Padrão
Brodatz	RedeLBP	80.29%	92.40%	12.11pp	3.82%
Brodatz	RedeLBPstats	80.74%	93.13%	12.39pp	3.91%
JAFFE	RedeLBP	71.36%	96.24%	24.88pp	6.45%
JAFFE	RedeLBPstats	17.84%	97.65%	79.81pp	22.14%
Yale	RedeLBP	60.61%	76.36%	15.75pp	4.89%
Yale	RedeLBPstats	61.82%	74.55%	12.73pp	3.92%
Faces Data	RedeLBP	96.64%	99.88%	3.24pp	1.01%

4.6 Análise dos Resultados

4.6.1 Análise de Sucessos

O método proposto alcançou seu maior sucesso em aplicações de reconhecimento facial, particularmente em bases com desafios de iluminação e variações de expressão. A melhoria de 7.88% em Yale Faces (68.48% $\rightarrow$ 76.36%) e 6.10% em JAFFE (91.55% $\rightarrow$ 97.65%) demonstram a eficácia da abordagem em cenários realistas. Esse comportamento é coerente com o uso recorrente de descritores locais e seus derivados como baseline em tarefas faciais,

incluindo reconhecimento de expressões, mesmo em trabalhos recentes que comparam abordagens clássicas e redes neurais (KUMAR; SAGAR; PUNETHA, 2023; WANG et al., 2022). Três fatores principais contribuem para este sucesso:

- **Captura de Padrões de Larga Escala** — A transformação de rede complexa com raios maiores consegue capturar estruturas faciais importantes que não seriam detectadas pelo LBP tradicional.
- **Robustez à Iluminação** — A medida de grau da rede complexa é mais robusta a variações de iluminação que o LBP tradicional.
- **Combinação com Estatísticas Discriminativas** — A adição de sete medidas estatísticas aumenta o poder discriminativo, especialmente na base JAFFE.

4.6.2 Análise de Limitações e Fracassos

Na base Brodatz, o LBP tradicional (92.57%) superou todas as configurações testadas. O melhor resultado (RedeLBPstats com raio 6) alcançou apenas 93.13%, uma melhoria de apenas 0.56%. Esta descoberta contra-intuitiva revela limitações importantes do método:

- **Características de Padrão Fino** — Texturas Brodatz dependem fortemente de padrões finos e de pequena escala. Aumentar o raio pode suavizar características importantes, resultando em perda de informação discriminativa.
- **Regularidade Excessiva** — As texturas Brodatz são altamente regulares e estruturadas. Em tais padrões, a transformação de rede complexa não adiciona informação discriminativa além do que o LBP já consegue capturar.
- **Otimização do Método** — O método foi desenvolvido principalmente para reconhecimento facial. Os parâmetros podem não ser ideais para classificação de texturas.

Adicionalmente, o desempenho foi altamente sensível à escolha do raio. Na base JAFFE, o desempenho variou de 71.36% (raio 1) a 96.24% (raio 13), uma variação de 24.88 pontos percentuais. Esta sensibilidade reduz a aplicabilidade prática do método, exigindo seleção cuidadosa de parâmetros para cada aplicação.

5 Conclusões e Trabalhos Futuros

Este trabalho demonstrou que a combinação de redes complexas, LBP e estatísticas discriminativas é eficaz especificamente para reconhecimento facial em cenários desafiadores, mas não é uma solução universal. O método alcançou taxas de acerto de 97.65% em JAFFE e 76.36% em Yale Faces, superando significativamente o LBP tradicional. Contudo, em classificação de texturas (Brodatz), o método não demonstrou melhoria, sugerindo forte dependência da natureza do problema.

5.1 Produção bibliográfica

A seguir listamos a produção bibliográfica gerada a partir das pesquisas relacionadas a este trabalho:

- Costa, M. V. B.; Villar Couto, C. M.; Couto, L. N. *Face Recognition Using LBP on an Image Transformation Based on Complex Network Degrees*. In: *SIBGRAPI — Conference on Graphics, Patterns and Images*, 2019.

5.2 Trabalhos futuros

- Aplicação em Raios Maiores — Testar em raios maiores para verificar se há aumento significativo nos resultados.
- Aplicação em Novas Bases — Aplicar em outras bases de rostos para avaliar eficácia da metodologia apresentada neste trabalho em outros cenários desafiadores.
- Aplicação em Texturas Dinâmicas — Estender para vídeos combinando com técnicas espaço-temporais.

Referências

- QUEIROZ, J.; GOMES, H. *Introdução ao Processamento Digital de Imagens*. [S.l.: s.n.], 2001. Citado na página 13.
- WANG, X. et al. A survey of face recognition. *arXiv*, 2022. Citado 8 vezes nas páginas 13, 14, 18, 19, 20, 30, 32 e 34.
- HÁJEK, M. *Texture analysis for magnetic resonance imaging*. [S.l.: s.n.], 2006. Citado na página 13.
- CHEN, D.-R.; CHANG, R.-F.; HUANG, Y.-L. Diagnosis of breast tumors with ultrasonic texture analysis using support vector machines. *Ultrasound in medicine & biology*, Elsevier, v. 29, n. 10, p. 1571–1578, 2002. Citado na página 14.
- AL-HIARY, H. et al. Fast and accurate detection and classification of plant diseases. *International Journal of Computer Vision*, v. 4, n. 3, p. 31–38, 2011. Citado na página 14.
- SAMAL, A.; IYENGAR, P. A. Automatic recognition and analysis of human faces and facial expressions: A survey. *Pattern recognition*, Elsevier, v. 25, n. 1, p. 65–77, 1992. Citado na página 14.
- ZENG, X. et al. A survey of micro-expression recognition methods based on lbp, optical flow and deep learning. *Neural Processing Letters*, v. 55, n. 5, p. 5995–6026, out. 2023. ISSN 1573-773X. Citado 3 vezes nas páginas 14, 18 e 29.
- ZHAO, G.; PIETIKÄINEN, M. Dynamic texture recognition using volume local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 29, n. 3, p. 500–509, 2007. Citado 2 vezes nas páginas 14 e 18.
- KUMAR, S.; SAGAR, V.; PUNETHA, D. A comparative study on facial expression recognition using local binary patterns, convolutional neural network and frequency neural network. *Multimedia Tools and Applications*, v. 82, p. 1–17, fev. 2023. Citado 5 vezes nas páginas 14, 18, 20, 29 e 34.
- ARRIETA, A. B. et al. Explainable artificial intelligence (xai): Concepts, taxonomies, opportunities and challenges toward responsible ai. *Information Fusion*, v. 58, p. 82–115, 2020. Citado na página 14.
- MOLNAR, C. *Interpretable Machine Learning*. [s.n.], 2022. Disponível em: <<https://christophm.github.io/interpretable-ml-book/>>. Citado na página 14.
- PIETIKÄINEN, M. Local binary patterns. *Scholarpedia*, v. 5, n. 3, p. 9775, 2010. Citado na página 16.
- PAUL, K. C.; ASLAN, S. An improved real-time face recognition system at low resolution based on local binary pattern histogram algorithm and clahe. *Optics and Photonics Journal*, v. 11, p. 63–78, 2021. ArXiv:2104.07234. Citado 2 vezes nas páginas 16 e 18.

COUTO, L. N. *Caracterização e Análise de Texturas Estáticas e Dinâmicas Utilizando Redes Complexas e Campos Vetoriais*. Tese (Doutorado) — Universidade Federal de Uberlândia, Faculdade de Computação, 2018. Citado 4 vezes nas páginas 16, 17, 18 e 24.

OJALA, T.; PIETIKÄINEN, M.; MÄENPÄÄ, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 24, n. 7, p. 971–987, 2002. Citado na página 17.

PIETIKÄINEN, M.; OJALA, T.; XU, Z. A comparative study of texture measures with classification based on featured distributions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 22, n. 3, p. 301–307, 2000. Citado na página 17.

LIU, L. et al. Median robust extended local binary pattern for texture classification. *IEEE Transactions on Image Processing*, IEEE, v. 25, n. 3, p. 1368–1381, 2016. Citado na página 18.

HUANG, D. et al. Local binary patterns and its application to facial image analysis: A survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, IEEE, v. 41, n. 6, p. 765–781, 2011. Citado na página 18.

COSTA, L. d. F. et al. Characterization of complex networks: A survey of measurements. *Advances in Physics*, Taylor & Francis, v. 56, n. 1, p. 167–242, 2007. Citado 2 vezes nas páginas 19 e 21.

BACKES, A. R.; CASANOVA, D.; BRUNO, O. M. Texture analysis and classification: A complex network-based approach. *Information Sciences*, Elsevier, v. 219, p. 168–180, 2013. Citado 4 vezes nas páginas 19, 20, 21 e 22.

COSTA, M. V. B. d.; COUTO, C. M. V.; COUTO, L. N. Face recognition using lbp on an image transformation based on complex network degrees. In: IEEE. *Proceedings of the 2019 SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI)*. [S.l.], 2019. p. 1–8. Citado na página 22.

BRODATZ, P. *Textures: A photographic album for artists and designers*. Dover Publications, 1966. Citado na página 26.