



**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS FLORIANO
CURSO TECNÓLOGO EM ANÁLISE E DESENVOLVIMENTO DE
SISTEMAS**

SAMUEL OLIVEIRA E SILVA

**ALGORITMO PARA RECONHECIMENTO DE IMAGEM VIA PCA: Análise de
Desempenho**

**FLORIANO
2025**

SAMUEL OLIVEIRA E SILVA

ALGORITMO PARA RECONHECIMENTO DE IMAGEM VIA PCA: Análise de
Desempenho

Trabalho de Conclusão de Curso (artigo científico) apresentado como exigência parcial para obtenção do diploma do Curso de Tecnólogo em Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Floriano.

Orientadora: Prof^ª. Me. André Francisco Coêlho Castro.

Floriano
2025

ALGORITMO PARA RECONHECIMENTO DE ANÁLISE VIA PCA: Análise de Desempenho

Samuel Oliveira e Silva¹
André Francisco Coêlho Castro²

RESUMO

O trabalho apresenta a implementação e avaliação de desempenho de um algoritmo de reconhecimento de imagens faciais baseado na técnica de Análise de Componentes Principais (PCA) — conhecida como EigenFaces — combinada com o classificador Support Vector Machine (SVM). Utilizou-se o Cropped Yale Face Database B, composto por imagens em escala de cinza sob diferentes condições de iluminação. A metodologia foi dividida em etapas: pré-processamento e padronização das imagens, extração de características com PCA, classificação utilizando SVM (com kernel RBF e estratégia one-vs-one para multiclases) e validação do modelo por meio de validação cruzada estratificada. Os testes definiram o número ideal de componentes principais (75) e os parâmetros do classificador. Os resultados demonstraram alto desempenho: acurácia média de 93,11% na validação, baixo desvio padrão (0,0195) entre subconjuntos e F1-Score elevado para a maioria das classes, mesmo em condições adversas de iluminação. A matriz de confusão mostrou erros pontuais, sem padrão sistemático. Concluiu-se que a combinação de EigenFaces e SVM é eficaz e robusta para reconhecimento facial em ambientes controlados, mesmo com variações de iluminação. Recomenda-se, para trabalhos futuros, aplicar o modelo em bases de dados mais complexas e compará-lo a outras técnicas, como Redes Neurais Convolucionais.

Palavras-chave: visão computacional; PCA; reconhecimento de faces; EigenFaces; SVM.

ABSTRACT

This work presents the implementation and performance evaluation of a facial image recognition algorithm based on the Principal Component Analysis (PCA) technique — known as EigenFaces — combined with the Support Vector Machine (SVM) classifier. The Cropped Yale Face Database B, composed of grayscale images under different lighting conditions, was used. The methodology was divided into steps: preprocessing and standardization of images, feature extraction with PCA, classification using SVM (with RBF kernel and one-vs-one strategy for multiclass classification), and model validation through stratified cross-validation. Tests defined the optimal number of principal components (75) and classifier parameters. The results demonstrated high performance: average validation accuracy of 93.11%, low standard deviation (0.0195) among folds, and high F1-Scores for most classes, even under adverse lighting. The confusion matrix showed occasional errors, without systematic patterns. It was concluded that combining EigenFaces and SVM is

¹ Graduando do curso de Tecnólogo em Análise e Desenvolvimento de Sistemas. Instituto Federal do Piauí Campus Floriano. samueloliveiraads1@gmail.com.

² Mestre em Modelagem Matemática e Computacional pela UFPB. Instituto Federal do Piauí Campus Floriano. andrecaastro@ifpi.edu.br.

effective and robust for facial recognition in controlled environments, even with lighting variations. For future work, it is recommended to apply the model to more complex datasets and compare it to other techniques, such as Convolutional Neural Networks.

Keywords: computer vision; PCA; face recognition; EigenFaces; SVM.

Data de aprovação: 15/08/2025

1 INTRODUÇÃO

A Visão Computacional é a ciência responsável por fornecer para uma máquina a possibilidade de enxergar o meio externo através de imagens e vídeos capturados por sensores. O computador capta informações significativas através dessas imagens e vídeos, possibilitando a execução de tarefas inteligentes, se aproximando da inteligência humana (Milano; Honorato, 2010).

Reconhecimento de Imagens é uma área de estudo e investigação de grande importância que pertence a Visão Computacional. A tecnologia de reconhecimento de imagens permite a análise e compreensão automática de objetos e informações por parte do computador em cenas, imagens e vídeos, possibilitando uma vasta área de aplicações, como medicina, segurança e condução automática de veículos (Luo, 2024, tradução nossa).

A Análise de Componentes Principais é um método de análise multivariada que é capaz de expressar um conjunto de dados original em um conjunto menor, comprimindo o conjunto de modo a conservar a maior parte da informação e identificar padrões em um conjunto de dados. Em um conjunto de dados que representa uma imagem, além da compressão, o PCA é capaz de fornecer os aspectos da imagem que são realmente importantes para o reconhecimento (Ribeiro; Chiachia; Marana, 2010).

Visto isso, este trabalho tem como objetivo a implementação e análise de desempenho de um algoritmo de reconhecimento de imagens utilizando a técnica de Análise de Componentes Principais. Este trabalho visa contribuir para o meio acadêmico com a implementação de um algoritmo de reconhecimento de imagens usando a técnica de Análise de Componentes Principais.

2 REFERENCIAL TEÓRICO

2.1 IMAGENS DIGITAIS

Uma imagem pode ser compreendida como um conjunto de valores organizados em linhas e colunas. A representação mais simples de uma imagem é a representação binária. Nela, um pixel pode assumir apenas um valor: 0 para a cor preta e 1 para a cor branca. (Barelli, 2018).

Em uma imagem representada em tons de cinza um pixel pode assumir 256 tonalidades de cinzas diferentes, variando de 0 (preto) a 255 (branco). Para o armazenamento do valor do pixel, são necessários 8 bits (1 byte). Logo, em uma imagem em tons de cinza, cada pixel é armazenado em 1 byte com um valor que varia de 0 a 255 (Barelli, 2018).

Imagens coloridas têm a intensidade de luz de cada canal de cor. No canal RGB (vermelho, verde e azul) existem três valores representados no mesmo pixel. Logo, são necessários 24 bits (3 bytes) para representar o valor numérico de cada cor. Portanto, uma imagem RGB pode ser vista como a união de 3 matrizes bidimensionais, onde cada matriz armazena um canal de cor (Barelli, 2018).

2.2 ALGORITMO

Um algoritmo consiste em um procedimento computacional com uma sequência de etapas bem definidas. Um algoritmo também pode ser usado como uma ferramenta para resolver um problema computacional. Para cada problema, existe um enunciado que relaciona uma entrada, sendo ela um valor ou conjunto de valores, e uma saída, sendo ela também um valor ou conjunto de valores. Basicamente o que o algoritmo faz é descrever o procedimento computacional necessário para alcançar essa relação entre entrada e saída (Cormen et al., 2002).

Um algoritmo é considerado correto se para cada instância de entrada, ele para com uma saída correta, resolvendo o problema computacional. Um algoritmo é considerado incorreto quando ele não para sua execução ou quando para com a resposta errada. Em certas situações, um algoritmo errado pode ser benéfico quando sua taxa de erro é controlada (Cormen et al., 2002).

Um algoritmo pode ser especificado em linguagem comum, como um programa de computador, ou mesmo como projeto de hardware. O único requisito é que a especificação deve fornecer uma descrição precisa do procedimento computacional a ser seguido (Cormen et al., 2002).

No contexto de reconhecimento de imagens, a escolha de algoritmo de reconhecimento deve levar em consideração fatores cruciais, como a complexidade do problema e a natureza das tarefas no processo de reconhecimento e no tamanho do conjunto de dados que serão utilizados (Chang, 2024, tradução nossa).

2.3 DECOMPOSIÇÃO EM VALORES SINGULARES

A Decomposição de Valores Singulares (SVD) é um método numérico da Álgebra Linear que tem como objetivo decompor uma matriz retangular em um produto entre matrizes ortonormais e uma matriz diagonal (Bressan, Santos, Martinez, 2022). Eugênio Beltrami em 1873 contribuiu notavelmente para o aparecimento da SVD, mostrando sua existência em matrizes quadradas reais e mais tarde, em 1936, Carl Eckart e Gale Young realizaram o mesmo feito para matrizes retangulares reais e complexas (Nobre, 2007).

Seja $X_{m \times n}$, com $m \geq n$. Então existem matrizes ortogonais $U_{m \times m}$ e $V_{n \times n}$ tais que $X = UDV^T$, onde as matrizes U e V são matrizes ortogonais e D é uma matriz diagonal que contém os autovalores de X . As colunas das matrizes U e V , são chamados autovetores à esquerda e à direita de X , respectivamente (Bressan; Santos; Martinez, 2022).

O Teorema de Eckart-Young afirma que a aproximação mais fiel da matriz original é construída através da soma dos k componentes mais significativos e descartando o resto, obtendo a melhor compressão possível nos dados (Bressan; Santos; Martinez, 2022).


2.4 ANÁLISE DE COMPONENTES PRINCIPAIS

A técnica estatística de Análise de Componentes Principais, inicialmente descrita por Person em 1901, tem como objetivo principal a transformação linear das variáveis originais de um conjunto em um novo conjunto de variáveis de mesma

dimensão que é substancialmente menor, mas que mantém a maior parte da informação do conjunto original. As variáveis deste novo conjunto, denominadas componentes principais, são combinações lineares das variáveis originais, independentes entre si e são estimadas em ordem para reter o máximo da variação dos dados (Hongyu; Sandanielo; Oliveira Junior, 2010).

Para obter essas componentes, primeiramente, é calculado a matriz de covariância em uma matriz de dimensão $n \times p$, onde n são as observações e p são as variáveis. Essa matriz quantifica como as variáveis se relacionam entre si. Depois, é calculado os autovetores e autovalores correspondentes desta matriz de covariância onde os autovalores, ordenados de forma decrescente, representam a magnitude da variância de cada componente principal. Por fim, o i -ésimo componente principal é definido como a combinação linear das variáveis originais. Desta forma, o primeiro componente principal explica a maior parte da variância, o segundo explica a variância restante, e assim por diante, reduzindo a informação em um conjunto menor de variáveis relevantes (Araujo; Coelho, 2009).

Figura 1 – Aplicação da PCA



Fonte: Scaler Topics (2023).

Como explicado anteriormente, a técnica SVD, quando aplicada em uma matriz, fornece os vetores singulares e os valores singulares. No contexto de aplicação do SVD para obtenção do resultado da PCA, os autovetores extraídos da matriz de covariância são os componentes principais, enquanto os valores

singulares são os autovalores, ou seja, a magnitude de variância de cada componente principal.).

2.5 EIGENFACES

A técnica de EigenFaces, consiste na aplicação da técnica PCA em imagens faciais. Neste contexto, ela tem como objetivo extrair os eigenfaces, que são os aspectos da face que mais representam a variação entre as faces do conjunto de dados (Ribeiro; Chiachia; Marana; 2010). Segundo Ribeiro, Chiachia e Marana (2010) o processo para a obtenção das eigenfaces conta com os seguintes passos:

1. As imagens das faces do conjunto de treinamento são convertidas em vetores, onde é calculado o valor médio das faces, que é subtraído dos demais vetores, obtendo dessa maneira, o desvio que cada face tem em relação à média. Em seguida, é calculada a matriz de covariância dos vetores resultantes. Nessa matriz, os elementos da diagonal principal representam a variância da mesma característica e os demais representam a covariância entre duas diferentes características;
2. Agora, é possível calcular os autovetores e autovalores desta matriz. Na aplicação de imagens, o autovetor é uma Eigenface. Cada EigenFace representa uma direção de variação dos dados, e são organizadas de forma decrescente. Sendo assim, enquanto as primeiras EigenFaces correspondem às características mais importantes e gerais da face, cruciais para o processo de identificação, as últimas eigenfaces capturam características mais irrelevantes e específicas das faces.
3. Para a redução da dimensionalidade, é selecionado apenas um subconjunto das eigenfaces, de modo que exista um balanço entre a preservação de informação e a compactação. Para a seleção das eigenfaces, pode ser escolhido um valor fixo de componentes ou pode ser definido uma porcentagem de modo que o número de componentes retenha essa porcentagem da variância de dados.
4. Por fim, cada imagem de face é projetada no espaço de faces definido pela eigenfaces selecionadas, tendo como resultado um vetor de K coeficientes. Esse vetor é a representação de uma face com as informações mais


discriminativas, que é utilizado por um algoritmo de classificação para a identificação do indivíduo. É como se o espaço de faces contivesse a fórmula necessária para a formação de todos os rostos do conjunto fornecido. O ato de projetar se refere a encontrar as eigenfaces necessárias para a construção da imagem fornecida no momento de projeção.

2.6 SUPPORT VECTOR MACHINE (SVM)

O SVM (Support Vector Machines) é um modelo de classificação proposto pela primeira vez por Cortes e Vapnik em 1995. Em suma, o algoritmo separa duas classes por meio de um hiperplano, que pode ser uma linha (em 2D) ou um plano em espaços de maior dimensionalidade. Os vetores de suporte são os pontos mais próximos ao hiperplano e o melhor hiperplano é aquele que possui a maior margem entre as classes (Zhuang, 2023, tradução nossa).

As SVMs lineares realizam a separação dos dados em duas classes através de hiperplanos, utilizando-se de margens rígidas ou margens suaves. As margens rígidas são utilizadas quando os dados são linearmente separáveis, ou seja, quando é possível traçar um hiperplano que separa perfeitamente as duas classes com exemplos localizados fora da região da margem, delimitada por hiperplanos paralelos ao hiperplano de separação. Já quando os dados não são perfeitamente separáveis, por conta de ruídos ou outliers, são utilizadas as margens suaves, que permite que alguns pontos invadam a margem, através de variáveis de folga, permitindo erros propositais e preservando a capacidade de generalização do modelo (Lorena; Carvalho, 2007).

Figura 2 – SVM de margens rígidas (à esquerda) e SVM de margens suaves (à direita)




Fonte: Survey Praticce (2018).

Muitas vezes, os dados são organizados de uma forma que um hiperplano não consegue separar as classes de maneira satisfatória, por exemplo, um cenário onde uma das classes formam um círculo e a outra classe forma um anel em volta. Uma linha reta não conseguiria separar esses dados de forma eficiente (Lorena; Carvalho, 2007).

Para isso, a estratégia principal é a transformação dos dados para um novo espaço de maior dimensão, com o intuito de tornar os dados linearmente separáveis neste novo espaço. Uma função Kernel realiza os cálculos desse novo espaço usando os dados no espaço original, sem precisar fazer o mapeamento de maneira explícita, tornando o processo computacionalmente viável e eficiente, pois sem o kernel seria feito o mapeamento e depois seria calculado os produtos escalares necessários para treinar a SVM, tornando o processo muito caro e em alguns casos impossível, em termos computacionais (Lorena; Carvalho, 2007). O Kernel Gaussiano RBF (Radial Basis Function) é padrão em bibliotecas que fornecem o

SVM, além de ser muito utilizado para resolução de problemas de aprendizagem. Existem dois parâmetros que podem ser modificados para atingir o melhor resultado: o gamma e o custo (Oliveira Junior, 2010).

Figura 3 – Uso do Kernel



Fonte: Zhuang (2023).

As SVMs foram concebidas para realizar classificações binárias. Diversas técnicas têm sido pesquisadas com o objetivo de tornar a SVM capaz de realizar classificações em problemas que envolvam mais de duas classes, sendo uma delas a One-vs-One (Chagas, 2009).

A técnica one-vs-one utiliza a estratégia de votação, onde um classificador é treinado para cada par de classes e, no momento de predição, o classificador irá rotular a instância como uma das classes e essa classe receberá um voto. No fim do processo a classe que receber mais votos será a vencedora e a instância será rotulada como pertencente a esta classe (Chagas, 2009).

3 METODOLOGIA

As pesquisas exploratórias são desenvolvidas com o objetivo de proporcionar visão geral, de tipo aproximativo, acerca de determinado fenômeno (Moreira; Calfe, p. 69, 2006). A pesquisa quantitativa, por outro lado, explora as

características e situações de que dados numéricos podem ser obtidos e faz uso da mensuração e estatísticas (Moreira; Callefe, p. 69, 2006).


Posto isto, este trabalho possui caráter exploratório pois visa explicar e descrever o funcionamento da técnica matemática Análise de Componentes Principais e tem uma abordagem quantitativa, pois envolve a manipulação matemática de um conjunto de dados e manipulação estatística dos resultados numéricos gerados após os testes realizados no algoritmo.

3.1 FUNCIONAMENTO DO ALGORITMO, TECNOLOGIAS UTILIZADAS E BASE DE DADOS

O sistema de reconhecimento de imagens proposto neste trabalho utiliza em sua implementação a linguagem de programação de Python e bibliotecas auxiliares, como: OpenCV, para a carregamento e redimensionamento de imagens; NumPy, para as operações matemáticas sobre vetores e matrizes; Scikit-Learn, para a implementação do algoritmo classificador e o algoritmo PCA; e por fim, Seaborn e Matplotlib para exibição dos dados e da matriz de confusão. O banco de imagens escolhido para treinamento e validação foi o Cropped Yale Face Database B, que possui 65 imagens de 39 faces em escala de cinza e sob diferentes condições de iluminação.

O processo de funcionamento do algoritmo segue o fluxograma da Figura 4 e conta com as seguinte etapas: (1) Pré-Processamento e Carregamento das imagens; (2) Extração de Características e Redução de Dimensionalidade com EigenFaces; (3) classificação das imagens utilizando SVM; (4) Validação do algoritmo com Cross-Validation.

Figura 4 – Fluxograma de funcionamento do algoritmo



Fonte: Autoria Própria (2025).

1. Pré-Processamento e Carregamento das imagens: Nesta etapa, cada imagem do dataset é padronizada para o tamanho de 150x150 pixels. Por fim, as imagens são vetorizadas, num processo chamado "flattening", de 22500 elementos para servirem como entrada para o EigenFaces.
2. Extração de Características e Redução de Dimensionalidade com EigenFaces: Para extração das características e redução de dimensionalidade, foi usado a técnica EigenFaces. A partir das imagens de face do conjunto de treinamento, foram calculados a face média e os

autovetores e os autovalores da matriz de covariância,. Com base em teste, foi definido que o número de componentes principais ideal era 75. Por fim, cada imagem foi projetada nesse novo espaço de 75 dimensões, gerando o vetor de características utilizado na etapa de classificação.

3. Classificação das Imagens Utilizando SVM: Para a etapa de classificação, foi utilizado o algoritmo classificador Support Vector Machine com o kernel RBF e com a estratégia de one-vs-one para classificações multiclases. Os parâmetros do Kernel foram definidos, através de testes, com “gamma” igual à “scale” e o “custo” igual à 5.
4. Validação com Cross-Validation: A avaliação da performance do modelo foi realizada com o método de Validação Cruzada Estratificada K-fold, com $K = 5$. Basicamente, o dataset foi dividido em 5 subconjuntos (folds), onde o modelo é treinado 5 vezes, usando 4 folds para treinamento e 1 para teste, rotacionando o fold de teste a cada vez. Assim, é oferecida uma estimativa mais robusta e confiável do desempenho do modelo.

4 RESULTADOS

Neste tópico será apresentado os resultados quantitativos e qualitativos obtidos pelo algoritmo de reconhecimento de imagens proposto. A avaliação do modelo, implementado com base na combinação entre as técnicas de EigenFaces e Support Vector Machines, foi realizada seguindo a metodologia descrita no capítulo anterior. A análise é dividida em 3 seções: Avaliação geral do desempenho do modelo, desempenho por classe e padrões de erro do modelo.

4.1 AVALIAÇÃO GERAL DO DESEMPENHO DO MODELO

A acurácia, métrica utilizada para avaliar a eficácia geral do modelo, mede a proporção de classificações corretas sobre o total de amostras. A validação cruzada com 5 subconjuntos fornece uma estimativa do desempenho do modelo para dados não vistos. Para uma análise mais profunda, foi avaliado a performance tanto na etapa de treinamento quanto na de validação de cada subconjunto. Os resultados obtidos são apresentados no Quadro 1.

Quadro 1 – Resultados Gerais do Desempenho do Modelo

Subconjunto	Acurácia (Treinamento)	Acurácia (Validação)
1	0.9832	0.9511
2	0.9852	0.9491
3	0.9867	0.9224
4	0.9867	0.9347
5	0.9883	0.8980
Média	0.9860	0.9311
Desvio Padrão	0.0017	0.0195

Fonte: Autoria Própria (2025).

A acurácia média de validação foi de 93,11%, indicando um alto grau de assertividade do modelo em dados não vistos. O desvio padrão de apenas 0.0195 demonstra que o modelo possui um desempenho consistente e estável através dos diferentes subconjuntos de dados.


O modelo atingiu uma acurácia média de treino de 98.60%, o que demonstra uma aprendizagem quase perfeita para os conjuntos de treinamento. A diferença entre a acurácia de validação e de treino foi de 5.49%. Este valor indica que o modelo não fica preso aos dados de treino e que possui poder de generalização alta o suficiente para desempenhar em novos dados.

4.2 AVALIAÇÃO DE DESEMPENHO POR CLASSE

Para realizar a análise individual de cada classe, foram utilizadas 3 métricas: a precisão, que mede a proporção de classificações positivas que estavam corretas; o recall, que avalia a proporção de amostras de uma classe que foram corretamente identificadas; e o F1-Score, que combina as duas métricas anteriores em uma única

pontuação para uma análise balanceada. Os dados obtidos estão expressos em um gráfico de barras apresentado na Figura 5.

Figura 5 - Precisão, Recall, e F1-score por Classe




Fonte: Autoria Própria (2025).

É percebido um desempenho consistentemente alto na maioria das classes. Destacam-se as classes yaleB12 que atingiu o F1-Score de 0.99 e as classes yaleB04, yaleB06 e yaleB18, com F1-Scores de 0.96 e 0.98. Por outro lado, a classe yaleB32 apresentou o menor F1-Score do conjunto (0.79), seguida por yaleB05 (0.84) e yaleB16 (0.89). Apesar de apresentarem um bom desempenho, indicam uma dificuldade do modelo em distinguir as amostras destas classes. Provavelmente, variações na iluminação ou características faciais tornam as amostras dessa classe menos distintas no espaço de características, levando a um número maior de erros.

4.2 PADRÕES DE ERROS

Para poder compreender onde o modelo cometeu erros, foi gerada uma matriz de confusão, apresentada na Figura 6. Essa matriz cruza as classificações do modelo com as classes reais para o conjunto de 2452 amostras de teste da validação cruzada.

Figura 6 - Matriz de Confusão



Fonte: Autoria Própria (2025).

A matriz de confusão confirma o alto desempenho do modelo. A diagonal principal, responsável por representar as classificações corretas, concentra a maioria das predições feitas pelo modelo. Os valores fora da diagonal principal, são esparsos e muito baixos. Além disso, não foi possível constatar um padrão de erro entre um par de classes. Os erros ocorreram de forma pontual e distribuída entre diferentes pares de classes. Em raros casos, houve três confusões entre um mesmo par de classes e o número máximo de erros de uma classe não excedeu sete. Os erros dispersos e em baixíssimos valores demonstram a alta capacidade de generalização e a robustez do modelo.

4.3 TRABALHOS RELACIONADOS

Neste tópico são apresentados 4 trabalhos, incluindo este: “Reconhecimento de Faces Utilizando Análise de Componentes Principais e Transformada de Censu”, de Ribeiro, Chiachia e Marana (2010); "Implementation of PCA for Recognition of Hand Gesture Representing Alphabets" de Pradhan A., Kumar, Dhakal e Pradhan B. (2016); e "Implementation of PCA and KNN Algorithms in the Classification of Indonesian Medicinal Plants" (Borman et al, 2021). Os pontos principais de cada trabalho foram apresentados no Quadro 1.

Quadro 1 – Trabalhos Relacionados

Trabalho	Reconhecimento de Faces Utilizando Análise de Componentes Principais e Transformada de Censu	Implementation of PCA for Recognition of Hand Gesture Representing Alphabets	Implementation of PCA and KNN Algorithms in the Classification of Indonesian Medicinal Plants	ALGORITMO PARA RECONHECIMENTO DE IMAGEM VIA PCA: Análise de Desempenho
Objetivo	Reconhecimento de faces com variação de iluminação.	Reconhecimento de gestos de mãos (alfabeto).	Classificação de plantas medicinais.	Classificação de imagens de faces com variação de iluminação.
Algoritmos utilizados	PCA e Transformada Censu.	PCA.	PCA (extração de características) e KNN (classificação).	PCA (EigenFaces) e SVM (Classificador).
Métricas de desempenho	Taxa de Erro Igual (EER), onde menor é melhor.	Taxa de eficiência.	Acurácia.	Acurácia, Precisão, Recall e F1-Score.
Resultados principais	A Transformada Censu reduziu a EER	Taxa de eficiência de 65,38%.	Precisão média de 88,67% (com mínima de	Acurácia média de XX% e F1-Score alto para

	de 0.03 para 0.01 (Exp. 1) e de 0.02 para 0.01 (Exp. 2).		82,22% e máxima de 97,78%).	maior parte das classes.
--	--	--	-----------------------------	--------------------------

Fonte: Autoria Própria (2025).

5 CONCLUSÃO

O trabalho proposto teve como objetivo geral a implementação e validação de um algoritmo de reconhecimento de imagens, utilizando a Análise de Componentes Principais (PCA), conhecida como EigenFaces quando usada no contexto de visão computacional, e como classificador o Support Vector Machine (SVM). Para a etapa de treinamento e de validação, foi utilizado o dataset Cropped Yale Face Database B, que conta com imagens com diferentes ângulos de iluminação.

A metodologia deste projeto inicia com o pré-processamento das imagens, seguido da aplicação do EigenFaces e finalizando na classificação multiclasse com o classificador SVM. A avaliação do algoritmo utilizou o método de validação cruzada estratificada com 5 subconjuntos. Os resultados obtidos se mostraram extremamente positivos, alcançando uma acurácia média de 93,11% e apresentando uma notável consistência, evidenciada pelo baixo desvio padrão de 0.0195 entre os subconjuntos de validação. Além disso, a análise detalhada e a matriz de confusão demonstram que o modelo manteve um alto f1-Score para a maioria das classes e que os poucos erros cometidos não seguiram um padrão sistemático.

Portanto, conclui-se que o objetivo de realizar a implementação e validação de um algoritmo de reconhecimento de imagens foi plenamente alcançado. É possível constatar que a combinação da técnica EigenFaces com o classificador Support Vector Machine é uma solução eficaz e confiável para reconhecimento de faces em ambientes controlados apesar da alta variação de iluminação. Embora o modelo tenha sido pleno e eficaz, é de suma importância salientar que sua avaliação foi feita com um dataset em condições controladas, com variações na iluminação que, apesar de extremas, não denotam casos reais. Sugere-se que para trabalhos futuros, a aplicação deste algoritmo em datasets mais complexos, com variações

que vão além da iluminação e uma análise comparativa com outras arquiteturas de reconhecimento de imagens, como Deep Learning e Redes Neurais Convolucionais.

REFERÊNCIAS

ARAUJO, W. O.; COELHO, C. J. **Análise de componentes principais (PCA)**. University Center of Anápolis, Annapolis, 2009.

BARELLI, F. **Introdução à visão computacional: Uma abordagem prática com Python e OpenCV**. Editora Casa do Código, 2018.

BRESSAN, G. M.; SANTOS, J. F.; MARTINEZ, A. L. M. **Aplicação da Decomposição em Valores Singulares para compressão de imagens**. C.Q.D. – Revista Eletrônica Paulista de Matemática, Bauru, v. 22, n. 1, p. 96–109, 2022.

CHAGAS, S. L. **Classificação de sinais de eletroencefalograma usando máquinas de vetores suporte**. 2009. Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós Graduação em Engenharia Elétrica, Universidade Presbiteriana Mackenzie. São Paulo, 2009.

CHANG, Liang. **Application of Computer Image Processing and Recognition Technology**. Advances in Computer and Communication, Heilongjiang, v. 5, n. 2, 118–121, 2024.

CORMEN, T. H.; CHARLES, E. L.; RONALD, L. R.; CLIFFORD, S. **Algoritmos: teoria e prática**. Rio de Janeiro, Editora Campus, v. 2, 2002.

HONGYU, K.; SANDANIELO, V. L. M.; OLIVEIRA JUNIOR, G. J. **Análise de componentes principais: resumo teórico, aplicação e interpretação**. E&S Engineering and science, Mato Grosso, v. 5, n. 1, p. 83–90, 2016.

LORENA, A. C.; CARVALHO, A. CPLF. **Uma introdução às support vector machines**. Revista de Informática Teórica e Aplicada, Porto Alegre, v. 14, n. 2, p. 43–67, 2007.

LUO, Z. **The Application and Development of Image Recognition Technology in the Field of Computer Vision**. Highlights in Science, Engineering and Technology, Guangzhou, v. 85, p. 909-914, 2024.

MILANO, D.; HONORATO, L. B.; **Visão Computacional**. Faculdade de Tecnologia, Universidade Estadual de Campinas, 2010.

MOREIRA, M.; CALLEFE, L. G. **Metodologia de Pesquisa para o Professor Pesquisador**. Rio de Janeiro, DP&A Editora, 2006.

NOBRE, S. G. G. **A decomposição em valores singulares e suas aplicações**. 2007. Dissertação (Mestrado em Matemática) - Faculdade de Ciências e Tecnologia, Universidade do Algarve, Faro, 2007.

OLIVEIRA JUNIOR, G. M. **Máquina de Vetores de Suporte: estudo e análise de parâmetros para otimização de resultado**. 2010. Trabalho de Graduação

(Graduação em Ciência da Computação) - Centro de Informática, Universidade Federal de Pernambuco, Recife, 2010.

RIBEIRO, I.; CHIACHIA, G.; MARANA, A. N. **Reconhecimento de Faces Utilizando Análise de Componentes Principais e a Transformada Census**. In: VI Workshop de Visão Computacional, Presidente Prudente, 04-07 de jul. 2010.

SCALER TOPICS. **Principal Component Analysis (PCA)**. 2023. Disponível em: <https://www.scaler.com/topics/nlp/what-is-pca/>. Acesso em: 14 jul. 2025.

SURVEY PRACTICE. **Using Support Vector Machines for Survey Research**. 2018. Disponível em: <https://www.surveypractice.org/article/2715-using-support-vector-machines-for-survey-research>. Acesso em: 14 jul. 2025.

ZHUANG, Y. **Researches advanced in image recognition**. Applied and Computational Engineering, Ontario, v. 4, n. 1, p. 205–214, 2023.