

Reconhecimento Facial: Um estudo comparativo sobre métodos cruzados de PCA e LDA

Gabriel Renato Moreira ^a e Robson Barcellos ^b

Departamento de Engenharia Elétrica da Universidade Federal de
São Carlos

^b Orientador de Trabalho de Conclusão de Curso

Resumo – Este trabalho apresenta um estudo comparativo de ferramentas comumente utilizadas para reconhecimento facial, a PCA e a LDA. Podem ser utilizadas de forma isolada ou em conjunto, com o objetivo de trazer melhor precisão na classificação dos indivíduos. A aplicação dessas ferramentas utiliza bibliotecas como o *Scikit-learn* (*Sklearn*), o *OpenCV* e o *NumPy*, sendo que com cada ferramenta utilizada, é necessário seguir sua metodologia para alcançar um resultado ideal.

Palavras-Chave – Inteligência artificial, redes neurais artificiais, reconhecimento facial, PCA, LDA.

1. INTRODUÇÃO

A área de biometria vem cada vez mais sendo utilizada por suas diversas aplicações, sendo o reconhecimento facial uma das mais populares do momento, no qual se busca identificar padrões faciais tais como formato da boca, rosto, distância entre olhos, entre outros [1]. Contudo o reconhecimento facial ainda apresenta muitos problemas a serem pesquisados e resolvidos, com o objetivo de obter melhores desempenhos. O objetivo deste trabalho é estudar e analisar o comportamento de duas técnicas frequentemente usadas para reconhecimento facial, a PCA e a LDA. Estas técnicas consistem em reduzir a redundância utilizando procedimentos da álgebra linear e estatística aplicada.

Dois métodos distintos, usando a linguagem Python, foram usados; o primeiro utilizando a biblioteca *Scikit-learn*, também conhecida como *Sklearn*, que possui funções para fazer os cálculos de PCA e LDA de forma direta, e o segundo constrói os modelos de PCA e LDA utilizando as funções matemáticas, da biblioteca *NumPy*.

O reconhecimento facial pode ser feito usando diversas técnicas, mas um passo em comum a todas elas é a extração de informações importantes a partir de uma imagem da face. Os desafios surgem principalmente devido a fatores como o posicionamento do rosto, expressões faciais, envelhecimento, oclusões e o principal, a variação de iluminação [2]. Como resposta a esses desafios, muitos métodos e algoritmos

diferentes foram desenvolvidos para extração de características e redução de dimensionalidade, como Análise de Componentes Principais (PCA) [3,4,5], Análise Discriminante Linear (LDA) [6], Transformada Discreta do Cosseno (DCT) [7], Modelos Ocultos de Markov (HMMs) [8], Redes Neurais (NNS) [9,10], Máquina de Vetores de Suporte (SVM) [11] e outros.

Este trabalho tem como objetivo desenvolver um estudo comparativo quanto à eficiência das técnicas de extração de atributos PCA e LDA. A análise de componentes principais (*Principal Component Analysis* ou PCA) é usada tanto para redução de dimensionalidade quanto para problemas de reconhecimento [12]. A aplicação do método PCA no reconhecimento facial gera imagens conhecidas como *Eigenfaces* [3,4]. A análise de discriminantes lineares (*Linear Discriminant Analysis* ou LDA) também é uma técnica de redução de dimensionalidade, que procura tornar os dados de classes diferentes o mais isolados possível. Para isso, essa técnica utiliza uma análise matricial de dispersão de dados [12]. A aplicação do método LDA no reconhecimento facial gera imagens conhecidas como *Fisherfaces* [5].

No método usado para comparação das técnicas PCA e LDA foram utilizados dois diferentes bancos de imagens, o primeiro conhecido como ORL que é constituído por 40 pessoas, com 10 imagens por pessoa, e o segundo banco de imagens é o conhecido como LFW, do qual será utilizada uma amostra com 8 pessoas e um mínimo de 60 imagens por pessoa. Os dados extraídos dos bancos de imagens foram processados por uma rede neural artificial SOM, e os resultados apresentados na seção 5. Resultados e discussões.

1. REDUÇÃO DE DIMENSIONALIDADE

Dimensionalidade é o número de características de uma representação. As características extraídas são informações de pixels de cada imagem. A dimensionalidade é um tópico que deve ser abordado por duas principais razões, o custo de medição e a precisão do classificador.

A redução de dimensionalidade é necessária para se evitar o problema da dimensionalidade que afeta a precisão de um classificador [13]. Este problema da dimensionalidade ocorre quando a quantidade de amostras de treinamento para que um classificador consiga bons resultados é uma função monotonicamente crescente do número de características [14].

Pode se mostrar que em alguns casos essa função é exponencial, pois, em reconhecimento de padrões, a quantidade necessária de amostras necessárias para a classificação cresce exponencialmente com a dimensionalidade [15].

A Figura 1 retrata o comportamento da taxa de acerto de um classificador com o aumento da dimensionalidade (número de características).

Quando a dimensionalidade está entre 0 e m_1 , a taxa de acerto é diretamente proporcional à dimensionalidade, pois quando se tem mais características para serem analisadas, o desempenho do classificador melhora. Isso ocorre porque

^{1a} E-mail autor: gabriel.moreira@estudante.ufscar.br

espaços com dimensões muito pequenas não possuem informações suficientes para se distinguir as classes [16].

Quando a dimensionalidade se encontra entre m_1 e m_2 , o aumento da dimensionalidade altera apenas sutilmente a precisão do classificador, mas com isso, informações redundantes ou indiferentes para a classificação também são processadas, gerando um desperdício de recursos [16].

Quando a dimensionalidade se encontra maior que m_2 , a inserção de novas características prejudica o desempenho do classificador, devido a insuficiência de amostras em relação ao número de características, gerando uma taxa de acerto reduzida [13,16].

O desafio, portanto, é encontrar um conjunto menor de características, que apresente o máximo de informações relevantes dos dados sem redundâncias.

O objetivo é fazer uma redução de dimensionalidade por duas etapas, primeiro utilizando-se da ferramenta PCA. Em seguida será aplicada a LDA nos dados gerados pela PCA, fazendo uma dupla redução de dimensionalidade.

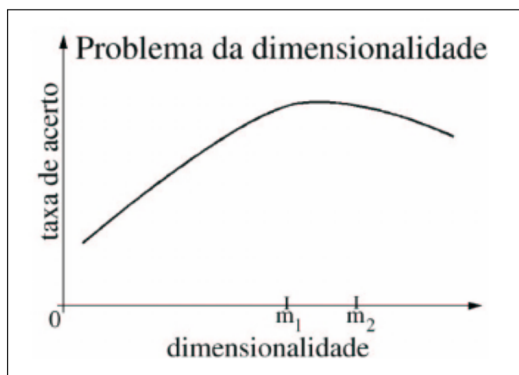


Figura 1: Problema da dimensionalidade.
Fonte: Campos, 2001 [16].

2. RECONHECIMENTO FACIAL

Problemas de reconhecimento facial geralmente trazem desafios semelhantes, como os explorados no tópico anterior. Existem algumas definições que envolvem esses problemas. Uma classe é um conjunto de imagens de faces associadas a um indivíduo, podendo ser entendida como o próprio indivíduo, e em um mesmo banco de faces.

Um objetivo do reconhecimento de faces é conseguir um nível elevado de desempenho no reconhecimento de uma face apresentada ao sistema. O desempenho de um algoritmo de reconhecimento de faces é julgado pela combinação de diversos fatores, como, por exemplo: precisão da resposta, velocidade no reconhecimento, custo baixo do equipamento e estabilidade da resposta. O algoritmo deve ser pouco sensível a fatores adversos, como variações nas condições de luminosidade, ruído na imagem, variações na expressão facial, presença de óculos, mudanças no cabelo, translação e rotação da face [17].

2.1. O Processo de reconhecimento facial

Sistemas de reconhecimento facial são baseados em sistemas comuns de reconhecimento de padrões, que podem ser compostos pelas seguintes partes: Aquisição de dados, Pré-processamento, Extrator de características, seletor de características e classificador [14,18].

A figura 2 mostra o diagrama de blocos da fase de treinamento utilizado.

A primeira fase do treinamento é a aquisição dos dados, que são os pixels das imagens.

A segunda fase do treinamento é o pré-processamento dos dados adquiridos das imagens, que remove ruídos e padroniza os níveis de cinza, mapeando-os no intervalo de 0 a 255.

Com os dados adquiridos e pré-processados, são extraídas e selecionadas as características padrão de entrada. Esta extração cria um subespaço de características onde os dados são mapeados de modo que informações redundantes sejam descartadas [19]. Os métodos utilizados para realizar esta etapa, são a PCA e a LDA.

Com o subespaço de características pronto, é realizado o treinamento do sistema, na qual um classificador associa uma imagem de face a uma classe, utilizando suas características. No presente trabalho o classificador será uma rede neural de Kohonen, também conhecida como *Self-Organizing Maps*, ou SOM.

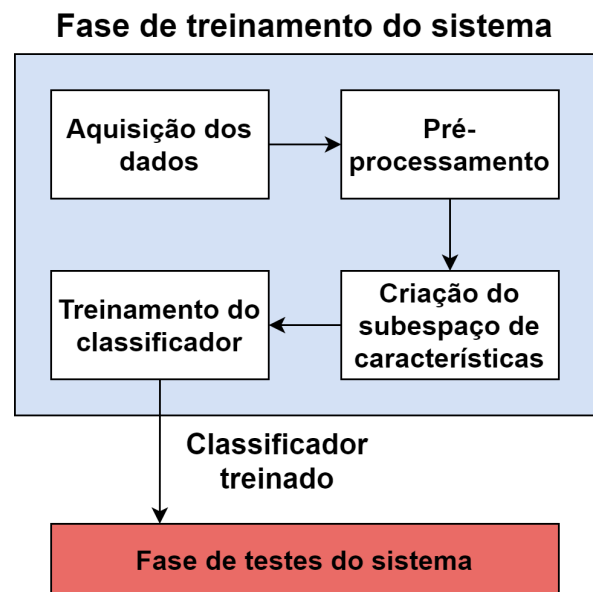


Figura 2: Diagrama de blocos da fase de treinamento
Fonte: Autor

Na fase de testes, são utilizadas imagens de faces diferentes das utilizadas no treinamento.

As imagens de teste são pré-processadas e mapeadas no mesmo subespaço de características usado na fase de treinamento, nossa PCA e LDA.

Por último, o algoritmo classificador irá determinar a qual classe está associada cada imagem de face que gerou as características utilizadas [14].

O reconhecimento facial utilizado, em relação ao modo de extração de características, é o método holístico. O sistema utiliza métodos estatísticos, aprendizado de máquina e transformações lineares para analisar a face como um todo.

Métodos holísticos costumam ser mais exatos, apesar de serem mais sensíveis às variações das condições em que as faces se encontram. Geralmente necessitam de um número grande de amostras de treinamento, sendo ideal utilização de ambientes controlados para a captura das imagens.

Métodos de redução de dimensionalidade dos dados devem ser aplicados para que o sistema de reconhecimento tenha um bom desempenho [17].

2.2. Análise de Componentes Principais (PCA)

A PCA é um método muito difundido no tratamento de características, por ser o primeiro método de reconhecimento facial a obter sucesso. Ainda hoje ele é muito usado para reconhecimento facial e como base de comparação para aferir o desempenho de novas propostas de reconhecimento facial [20].

A PCA consiste em um método de redução de dimensionalidade no qual ocorre uma rotação de eixos, de modo que seja possível descrever os dados através de eixos ortogonais correspondentes às direções de maior variabilidade dos dados.

Na figura 3 é mostrado um conjunto de dados definidos no eixo (x,y). Os componentes principais 1 e 2 são os eixos nas direções com a maior variabilidade de dados, na qual formam um sistema de coordenadas ortogonais (1,2).

A Figura 3 também mostra que os dados do eixo 1 apresentam a maior variabilidade, sendo assim o primeiro componente principal [21].




Figura 3: Representação gráfica de uma PCA
Fonte: Haykin, 1998 [21]

2.3. Análise de Discriminante Linear (LDA)

A LDA é uma ferramenta que procura um subespaço com a melhor separação entre as classes. Ela faz isso encontrando os eixos nas direções que maximizem a distância de separação entre as classes e minimizem a distância dentro de uma mesma classe. Em seguida, selecionam-se apenas os eixos com maiores informações sobre a separabilidade das classes para

formar um subespaço LDA. Desse modo, a representação obtida pela técnica possibilita a discriminação dos dados pela classe [22].

Essa separação é mostrada na Figura 4, onde as formas ovais representam a distribuição dos dados das classes 1 e 2, LD_1 é o eixo encontrado na LDA que melhor combina a separação das classes com a minimização das distâncias entre os dados das classes.




Figura 4: Representação gráfica de uma LDA
Fonte: Felipe, 2019 [24]

2.4. Redes Neurais SOM

Redes Neurais artificiais, ou RNAs, são modelos computacionais inspirados no sistema nervoso dos seres vivos, porém sendo constituídas por neurônios artificiais.

O modelo matemático de um neurônio j , é composto de um sinal de entrada $X = [x_1, x_2, \dots, x_i]$, um vetor ou matriz de pesos sinápticos $W = [w_{j1}, w_{j2}, \dots, w_{ji}]$, que ponderam as variáveis do sinal de entrada a fim de quantificar a sua relevância em relação a funcionalidade do neurônio, uma junção de soma, que agrega os sinais recebidos e a compara a um limiar de ativação b_j a fim de produzir um valor de ativação V_j , uma função de ativação $\phi(\cdot)$ limitadora de saída do neurônio dentro do intervalo de valores razoáveis para a aplicação, e um sinal de saída y_j [23], como observado na Figura 5.




Figura 5: Modelo matemático não-linear de um neurônio.
Fonte: Santos, 2005 [17].

A propriedade mais importante de uma rede neural é a capacidade de aprender pelo seu ambiente, e de melhorar seu desempenho, com o tempo, pelo aprendizado, e de acordo com algumas medidas prescritas. Uma rede neural aprende sobre seu ambiente por um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de ativação. Idealmente, a rede neural fica mais bem informada sobre o seu ambiente a cada iteração do processo de aprendizagem [21].

Será utilizado para o trabalho os mapas auto-organizáveis de Kohonen, ou SOM (*self-organizing maps*) como rede neural. Ela é uma arquitetura de redes neurais artificiais com aprendizado competitivo.

Nas redes neurais SOM, conhecido como mapa topológico de vizinhança, informa a disposição espacial dos neurônios da rede e das conexões laterais. Com isso os potenciais das conexões laterais são definidos de acordo com as distâncias dos neurônios ao neurônio vencedor da vizinhança [23].

A Figura 6 mostra uma SOM bidimensional com mapa topológico de vizinhança retangular. Ela é composta por duas camadas, a de entrada e a competitiva, que estão completamente interconectadas [17].

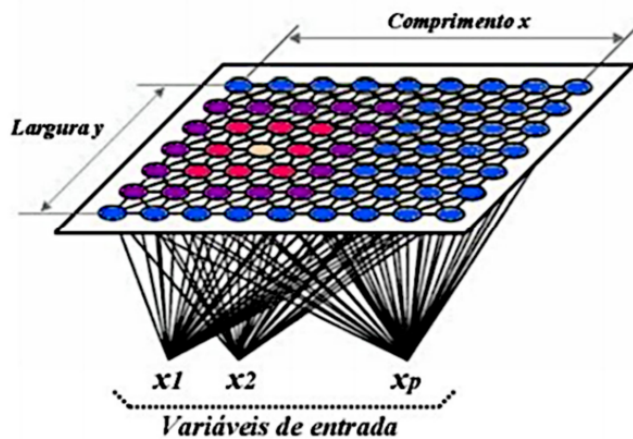


Figura 6: Exemplo de rede neural SOM.
Fonte: Santos, 2005 [17].

3. METODOLOGIA

Para o desenvolvimento do trabalho, foi utilizado uma metodologia similar ao apresentado pelo Felipe [24] e pelo Santos [17], na qual os autores utilizaram os métodos PCA e LDA para redução de dimensionalidade dos dados e redes neurais de Kohonen para classificação das faces. As principais diferenças deste trabalho para os trabalhos citados é que aqui foram utilizados códigos em Python no lugar do MATLAB, e que iremos utilizar mais de um método de PCA e LDA.

A Figura 7 exibe o diagrama de blocos da estrutura utilizada para os experimentos do trabalho, no qual foram utilizados dois bancos de imagens diferentes. Os métodos de PCA NP e LDA NP são os realizados utilizando a biblioteca *NumPy* e os métodos de PCA SK e LDA SK são os realizados

utilizando a biblioteca *SKLearn*, que serão explicados com mais detalhes no tópico “Extração, medição e seleção das características”.

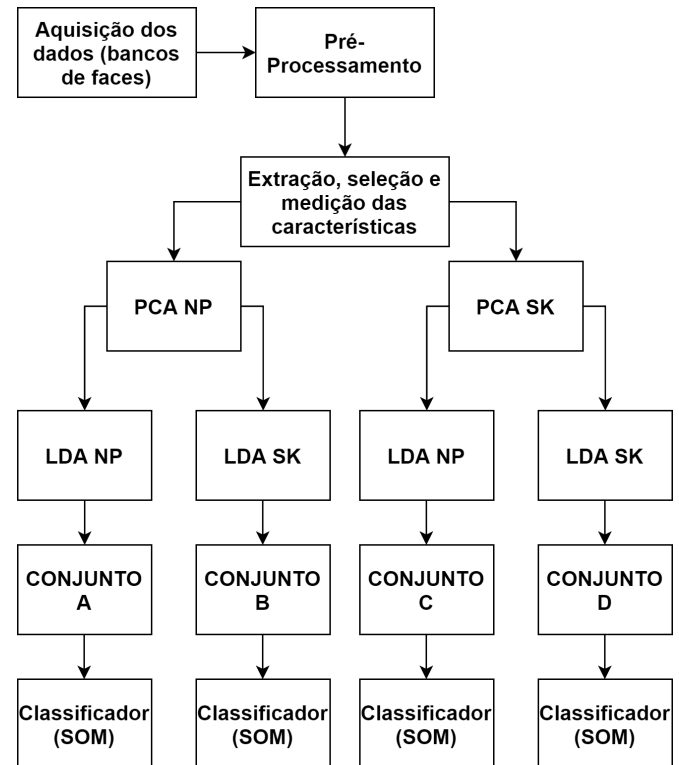


Figura 7: Estrutura da experimentação do trabalho.
Fonte: Autor.

3.1. Bancos de Faces

O primeiro banco de faces usado foi o banco ORL, que foi produzido pelo *Olivetti Research Laboratory* em *Cambridge, UK* [25]. Este banco de dados é gratuito e público, e contém 10 imagens diferentes de cada um dos 40 indivíduos, totalizando 400 imagens de faces. Nele há variações na expressão e detalhes faciais, além de diferentes condições de luminosidade, porém todas as imagens foram adquiridas sobre uma mesma cena de fundo, homogênea e escura. As imagens são em escala de cinza e com resolução de 64x64 pixels. Exemplos de faces presentes no banco de faces ORL são mostradas na Figura 8.



Figura 8: Exemplos de faces presentes no banco de faces ORL.

Fonte: OLIVETTI and ORACLE, 1994 [25].

O segundo é o banco de faces usado foi o *Labeled Faces in the Wild* LFW, produzido por Gary B. Huang, Manu

Ramesh, Tamara Berg, e Erik Learned-Miller na Universidade de Massachusetts, Amherst, US [26]. Este banco de imagens é gratuito e público. Contém mais de 13000 imagens coletadas da internet, de diversas pessoas influentes, e com isso não possui padronização das imagens como no primeiro banco de faces. Foi utilizada apenas uma amostra das imagens, com 1348 imagens e 8 classes. O banco possui no mínimo 60 imagens de cada pessoa, com dimensões de 62x47 pixels.

Exemplos de faces presentes no banco de faces LFW são mostrados na figura 9.



Figura 9: Exemplos de faces presentes no banco de faces LFW.

Fonte: HUANG, 2007 [26]

3.2. Pré-Processamento dos dados.

As faces retiradas dos bancos de faces passam por um pré-processamento dos dados, realizando operações que auxiliem no processo de reconhecimento facial.

O pré-processamento é feito em três etapas:

- Primeiro é realizada uma normalização de histograma.
- Depois é aplicado um filtro gaussiano, com objetivo de reduzir possíveis ruídos presentes nas imagens.
- Por último, é realizado um ajuste dos níveis de cinza através da diferença entre os níveis de cinza de uma imagem e os níveis de cinza da face média. Na face média, cada pixel é o valor médio do nível de cinza dos pixels correspondentes em todas as imagens do banco de face.

Exemplos de imagens pré-processadas dos bancos de faces ORL e LFW são mostradas nas figuras 10 e 11 respectivamente.



Figura 10: Exemplos de imagens pré-processadas do banco de faces ORL.

Fonte: OLIVETTI and ORACLE, 1994 [25].



Figura 11: Exemplos de imagens pré-processadas do banco de faces LFW.

Fonte: HUANG, 2007 [26]

3.3. Extração, medição e seleção das características

Com os dados adquiridos e pré-processados, é realizada a extração e seleção das características de cada base.

O primeiro passo é transformar as matrizes das imagens em vetores, que são utilizados para os cálculos da PCA, gerando autovetores PCA, que são um conjunto de vetores que descrevem os dados. Foram utilizados dois métodos distintos de PCA, que criaram dois subespaços PCA diferentes, uma será chamada de PCA NP e a outra de PCA SK.

A PCA NP foi desenvolvida utilizando ferramentas da biblioteca NumPy em linguagem Python, seguindo os passos matemáticos exigidos pela técnica, sendo eles:

- Cálculo de Matriz de Covariância
- Cálculo dos autovalores e autovetores
- Seleção dos melhores autovetores

A PCA SK foi desenvolvida utilizando a biblioteca SKLearn em linguagem Python, que possui uma ferramenta que calcula automaticamente a PCA de uma base de dados fornecida, sendo necessário apenas definir quantos autovetores ela deve retornar.

O código gera uma tabela com valores que indicam a significância de cada componente da PCA no conjunto de dados. Foram escolhidos da tabela, os 150 componentes com maior significância. Foi considerado um número de componentes cuja significância somada atinja 95%.

Os métodos foram utilizados para ambos os bancos de faces, gerando autofaces, que é o nome dado aos componentes principais encontrados na aplicação da PCA em sistemas de reconhecimento facial.

Exemplos de autofaces obtidas para os bancos de faces ORL e LFW são mostradas nas figuras 12 e 13 respectivamente.



Figura 12: Exemplos de autofaces obtidas utilizando métodos PCA no banco de faces ORL.
Fonte: OLIVETTI and ORACLE, 1994 [25].]



Figura 13: Exemplos de autofaces obtidas utilizando métodos PCA no banco de faces LFW
Fonte: HUANG, 2007 [26].

Em seguida, cada um dos subespaços PCA obtidos foi utilizado como conjunto de entrada para métodos de LDA.

Assim como para o caso da PCA, para a LDA também foram usados dois métodos distintos, a LDA NP e a LDA SK, obtendo-se 4 subespaços LDA diferentes, que foram denominados Conjuntos A a D.

A LDA NP foi desenvolvida utilizando ferramentas da biblioteca *NumPy* em Python, seguindo os passos matemáticos exigidos pela técnica, sendo eles:

- Cálculo das faces médias de cada classe
- Cálculo das matrizes de dispersão
- Cálculo dos autovalores e autovetores
- Seleção dos melhores autovetores

A LDA SK foi desenvolvida utilizando a biblioteca *SKLearn* em Python, que já possui uma ferramenta que calcula automaticamente a LDA de uma base de dados fornecida, sendo necessário apenas definir quantos autovetores ela deve retornar.

O código gera uma tabela com a divisão das variâncias inter-classe pelas variâncias intra-classes. São escolhidos os sete maiores valores dessa tabela para determinar os sete melhores autovetores.

O método utiliza o número de classes para definir quantos autovetores serão utilizados.

Ao fim do processo, como mostrado na figura 7, foram obtidos quatro conjuntos para cada banco de faces:

- Conjunto A: Composta pela PCA NP utilizada como conjunto de entrada para a LDA NP.
- Conjunto B: Composta pela PCA NP utilizada como conjunto de entrada para a LDA SK.

- Conjunto C: Composta pela PCA SK utilizada como conjunto de entrada para a LDA NP.
- Conjunto D: Composta pela PCA SK utilizada como conjunto de entrada para a LDA SK.

3.4. Classificador

Por fim, cada rede neural SOM criada recebeu os dados dos diferentes subespaços LDA obtidos anteriormente, a fim de testar a precisão da classificação obtida por cada conjunto.

Conjuntos de faces diferentes foram utilizados para o treinamento e teste da rede neural, numa proporção de 75% dos dados disponíveis para treinamento e 25% para teste.

A rede neural SOM foi construída com um mapa topológico com dimensões de 25x25.

A rede neural recebe na camada de entrada um total de sete dados por imagem dos conjuntos.

4. RESULTADOS E DISCUSSÕES

As taxas de reconhecimento encontradas para cada um dos conjuntos são apresentadas, além de um comparativo entre os resultados obtidos por Felipe [24] e Santos [17].

Para cada método aplicado a cada conjunto de faces foram realizados dez testes, utilizando validação cruzada, sendo que, em cada um, se utilizavam diferentes conjuntos de dados para treinamento e teste, selecionados de forma aleatória, mas sempre seguindo a proporção de 75% para treinamento e 25% para teste.

As tabelas I e II mostram cinco informações importantes acerca dos resultados.

As duas primeiras colunas trazem as informações de qual banco de faces foi utilizado para os testes e qual o conjunto utilizado, respectivamente.

A taxa de acerto é a média do percentual de reconhecimentos corretos realizados pela rede neural nos dados de teste, e será a principal métrica comparativa.

Os limites superior e inferior são respectivamente o melhor e o pior resultado de percentual de reconhecimento entre os dez testes realizados.

Tabela I. Resultados obtidos para cada conjunto utilizando o banco de faces ORL.

Banco de faces	Conjunto	Taxa de acerto	Limite superior	Limite inferior
ORL	A	91,2%	96,0%	84,0%
ORL	B	94,5%	98,0%	91,0%
ORL	C	89,1%	94,0%	84,0%
ORL	D	74,4%	80,0%	66,0%

Comparando os dados obtidos com o banco de faces ORL, o conjunto B obteve os melhores resultados, com uma taxa de acerto média de 94,5%. O melhor resultado dentre os dez

testes teve taxa de acerto de 98% e o pior resultado com uma taxa de acerto de 91%.

Os conjuntos A e C tiveram resultados piores, mas com uma precisão média próxima entre si, com diferenças de aproximadamente 2%.

O Conjunto D teve o pior resultado, não ultrapassando 80% de taxa de acerto em seus melhores casos.

Tabela II. Resultados obtidos para cada conjunto utilizando o banco de faces LFW.

Banco de faces	Conjunto	Taxa de acerto	Limite superior	Limite inferior
LFW	A	53,3%	59,0%	50,0%
LFW	B	82,6%	86,0%	78,0%
LFW	C	81,2%	85,0%	79,0%
LFW	D	82,6%	86,0%	79,0%

Comparando os dados obtidos com o banco de faces LFW, os conjuntos B e D obtiveram os melhores resultados, com uma taxa de acerto média de 86,2%. O melhor resultado dentre os dez testes teve taxa de acerto de 86% e o pior resultado dos conjuntos foi diferente, sendo 78% de taxa de acerto para o conjunto B e 79% de taxa de acerto para o conjunto D.

O conjunto A teve resultados piores, mas com uma taxa de acerto próxima dos vencedores, apenas 1,4% de diferença.

O Conjunto D teve o pior resultado, não ultrapassando 59% de taxa de acerto em seus melhores casos.

Por último, são comparados os resultados encontrados pelo Felipe [24] e pelo Santos [17], presentes na tabela III.

Tabela III. Precisão média obtida pelos trabalhos comparados utilizando a base de faces ORL.

Banco de faces	Conjunto	Taxa de acerto	Limite superior	Limite inferior
ORL	Dados Felipe [24]	92,9%	94,8%	91,0%
ORL	Dados Santos [17]	95,6%	96,9%	94,2%

Os resultados obtidos pelo Santos [17] foram ligeiramente melhores que os obtidos pelo Felipe [24], com uma taxa de acerto média 2,7% melhor.

O conjunto B foi o que obteve a melhor taxa de acerto na base de faces ORL. Obteve uma taxa de acerto média 1,1% menor que a obtida pelo Santos [17] e 1,6% maior que a obtida pelo Felipe [24].

Os resultados obtidos no banco de faces LFW em uma média geral foram piores que os obtidos no banco de faces ORL.

5. CONCLUSÃO

Um bom sistema de reconhecimento facial deve possuir altas taxas de acerto em imagens com diferentes condições de iluminação, variação de posição, qualidade da imagem, ruídos e outros fatores que dificultem o reconhecimento facial.

O Conjunto B, composto pela PCA NP e pela LDA SK, foi o conjunto com os melhores resultados do trabalho. Porém o resultado é válido apenas para as bases estudadas e seria necessário aplicar o método em outras bases para verificar se ele também apresentaria os melhores resultados.

Os resultados dos melhores métodos ficaram com taxas de acerto médio muito próximas dos trabalhos do Felipe [24] e do Santos [17], com variações inferiores a 2%.

6. REFERÊNCIAS

- [1] SILVA, A. L.; CINTRA, M. E. Reconhecimento de padrões faciais: Um estudo. In: Encontro Nacional de Inteligência ArtiAcial e Computacional, 2015, Proceedings ENIAC. [S.l.: s.n.], 2015. p. 224-231..
- [2] GOMATHI, E.; BASKARAN, K. An efficient method for face recognition based on fusion of global and local feature extraction. IJSCE International Journal of Soft Computing and Engineering, IJSCE, v. 4, n. 4, p. 56–60, 2014.
- [3] TURK, M. and PENTLAND, A.: 1991a, Eigenfaces for recognition, Journal of Cognitive Neuroscience 3(1), 71–86.
- [4] TURK, M. and PENTLAND, A.: 1991b, Face recognition using eigenface, Proc. IEEE Conf. on Comp. Vision and Pattern Recognition pp. 586–591.
- [5] BELHUMEUR, P.; HESPANHA, J.; KRIENGMAN, D. (1997). Eigenfaces vs. Fisherfaces: recognition using class specific linear projection, IEEE Trans
- [6] ZHAO, W.; KRISHNASWAMY, A.; CHELLAPPA, R.; SWETS, D. L.; WENG, J. Discriminant analysis of principal components for face recognition. In: Face Recognition. [S.l.]: Springer, 1998. p. 73–85.
- [7] JING, X.-Y.; ZHANG, D. A face and palmprint recognition approach based on discriminant dct feature extraction. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), IEEE, v. 34, n. 6, p. 2405–2415, 2004.
- [8] OTHMAN, H.; ABOULNASR, T. A separable low complexity 2d hmm with application to face recognition. IEEE Transactions on pattern analysis and machine intelligence, IEEE, v. 25, n. 10, p. 1229–1238, 2003.
- [9] ER, M. J.; WU, S.; LU, J.; TOH, H. L. Face recognition with radial basis function (rbf) neural networks. IEEE transactions on neural networks, IEEE, v. 13, n. 3, p. 697–710, 2002.
- [10] ER, M. J.; CHEN, W.; WU, S. High-speed face recognition based on discrete cosine transform and rbf neural networks. IEEE Transactions on Neural Networks, IEEE, v. 16, n. 3, p. 679– 691, 2005.
- [11] LEE, K.; CHUNG, Y.; BYUN, H. Svm-based face verification with feature set of small size. Electronics Letters, The Institution of Engineering & Technology, v. 38, n. 15, p. 1, 2002.
- [12] TOYGAR, O. and ADNAN, A. (2003). Face recognition using pca, lda and ica approaches on " colored images. IU-Journal of Electrical & Electronics Engineering, 3(1):735–743
- [13] MARTINS, D. C. J. Redução de Dimensionalidade Utilizando Entropia Condicional Média Aplicada a

- Problemas de Bioinformática e de Processamento de Imagens. Dissertação (Mestrado) — Universidade de São Paulo, São Paulo, 2004
- [14] JAIN, A. K.; DUIN, R. P. W.; MAO, J. Statistical pattern recognition: A review. *IEEE Transactions on pattern analysis and machine intelligence*, IEEE, v. 22, n. 1, p. 4–37, 2000.
- [15] PERLOVSKY, L. I. Conundrum of combinatorial complexity. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, IEEE, v. 20, n. 6, p. 666–670, 1998.
- [16] CAMPOS, T. E. Técnicas de Seleção de Características com Aplicações em Reconhecimento de Faces. Dissertação (Mestrado) — Universidade de São Paulo, São Paulo, 2001.
- [17] SANTOS, A. R. Identificação de faces humanas através de PCA-LDA e redes neurais SOM. 2005. Dissertação (Mestrado em Engenharia Elétrica) - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2005. doi:10.11606/D.18.2005.tde21042006-222231.
- [18] DUDA, R. O. and HART, P. E. (1973). *Pattern classification and scene analysis*. Wiley-Interscience, USA.
- [19] AMARAL, V. D. Extração e Comparação de Características Locais e Globais para o Reconhecimento Automático de Imagem de Faces. 2011. Dissertação (Mestrado em Engenharia Elétrica) - Centro Universitário da FEI, São Bernardo do Campo, 2011.
- [20] PENTEADO, B. E. Autenticação biométrica de usuários em sistemas de e-learning baseada em reconhecimento de faces a partir de vídeo. Universidade Estadual Paulista (UNESP), 2009.
- [21] HAYKIN, S. *Neural Networks: A Comprehensive Foundation*. Upper Saddle River: Prentice Hall, 1998.
- [22] SILVA, A. L. Redução de características para classificação de imagens de faces. 2016.
- [23] SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas*. São Paulo: Artliber, 2010.
- [24] FELIPPE, G. W. Reconhecimento facial utilizando redes neurais kohonen. 2019. TCC (Graduação) - Curso de Engenharia Elétrica, Universidade Federal de São Carlos, São Carlos, 2019.
- [25] OLIVETTI and ORACLE. Database of faces - ORL (www.camorl.co.uk). Olivetti and Oracle Research Laboratory, 1994.
- [26] HUANG G. G., RAMESH M., BERG T., MILLER E. L.. Labeled Faces in the Wild: A Database for Studying Face Recognition in Unconstrained Environments. University of Massachusetts, Amherst, Technical Report 07-49, October, 2007.