

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
ESCOLA DE CIÊNCIAS EXATAS E DA COMPUTAÇÃO
GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO**



**CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS DA PALMA DA MÃO
UTILIZANDO ANÁLISE DE COMPONENTES PRINCIPAIS**

WANDERSOM MOURA VIANA

GOIÂNIA

2020

WANDERSOM MOURA VIANA

**CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS DA PALMA DA MÃO
UTILIZANDO ANÁLISE DE COMPONENTES PRINCIPAIS**

Trabalho para conclusão de curso apresentado na faculdade de Ciências Exatas e da Computação da Pontifícia Universidade Católica de Goiás como requisito básico para a conclusão do curso de Engenharia de Computação.

Orientador: Prof. Me. Gustavo Siqueira Vinhal

GOIÂNIA

2020

WANDERSOM MOURA VIANA

**CLASSIFICAÇÃO DE IMAGENS MULTIESPECTRAIS DA PALMA DA MÃO
UTILIZANDO ANÁLISE DE COMPONENTES PRINCIPAIS**

Este Trabalho de Conclusão de Curso foi julgado adequado para a obtenção do título de Bacharel em Engenharia da Computação, e aprovado em sua forma final pela escola de Ciências Exatas e da Computação, da Pontifícia Universidade Católica de Goiás em ____/____/____.

Prof. Me. Gustavo Siqueira Vinhal

Banca examinadora:

Prof. Dr. Arlindo Rodrigues Galvão Filho

Profa. Dr. Sibelius Lellis Vieira

GOIÂNIA

2020

Dedico este trabalho a minha mãe, Ana Moura Viana, meu maior exemplo de garra e perseverança.

AGRADECIMENTOS

A todos os professores que tive oportunidade de adquirir conhecimento que contribuíram em minha formação.

Ao meu orientador acadêmico, professor Me. Gustavo Siqueira Vinhal, pelo apoio e confiança no desenvolvimento deste trabalho.

A minha família e aos meus amigos, por terem me proporcionado os momentos divertidos.

Sou grato a todo o corpo docente, à direção e administração desta universidade.

A todos que direta ou indiretamente colaboraram para materialização deste trabalho.

“Se A é o sucesso, então A é igual a X mais Y mais Z. O trabalho é X; Y é o lazer; e Z é manter a boca fechada.”

Albert Einstein

RESUMO

Estudos em Processamento Digital de Imagens (PDI) e Visão Computacional vêm fornecendo ferramentas para a extração de informações em imagens, desde o tratamento dos dados até o reconhecimento de padrões. Dentre essas aplicações pode-se destacar a biometria que consiste na identificação de indivíduos a partir do reconhecimento de padrões em características físicas ou comportamentais. O objetivo do trabalho é a classificação automática da palma da mão. A classificação é feita empregando a análise de componentes principais (*Principal Component Analysis*, PCA), para extrair as características mais importantes na identificação da palma das mãos previamente conhecidas e presentes no banco de dados, criando um espaço dimensional menor e discriminante com relação ao original, partir de um conjunto de dados de 315 imagens de palma das mãos. O equipamento utilizado para a captação das imagens é a JAI AD-080E que proporciona imagens multiespectrais. Tal câmera trabalha com o canal visível que capta as faixas de RGB (*red, green, blue*) ou vermelho, verde e azul e o canal infravermelho próximo (NIR). Os resultados obtidos pelo método K-ésimo Vizinho mais Próximo (*k-nearest neighbors algorithm*, KNN) foram satisfatórios para todas as imagens, apresentando, visualmente, maior nível de detalhes na detecção no RGB e Tons de cinza. Os resultados obtidos mostram uma acurácia de 93,97% no RGB e 90,16% no tons de cinza.

Palavra-Chave: *Principal Component Analysis* (PCA), K-ésimo vizinho mais próximo (*k-nearest neighbors algorithm*, KNN). Classificação de imagens das mãos, Biometria.

ABSTRACT

Studies in Digital Image Processing (PDI) and Computer Vision have resulted in tools for extracting information from images, from data processing to pattern recognition. Among these applications, biometrics can be highlighted, which consists in identifying conformity based on the recognition of patterns in physical or behavioral characteristics. The objective of the work is the automatic classification of the palm. The classification is made using an principal components analysis (PCA), to draw the most important characteristics in the identification of the prepared palms and present in the database, creating a smaller and discriminating dimensional space in relation to the original from a data set of 315 palm images. The equipment used to capture images is a JAI AD-080E that offers multispectral images. Such a camera works with the visible channel that it captures as RGB bands (red, green and blue) and the near infrared channel (NIR). The results obtained by the K-th Closest Neighbor method (k-nearest neighbors algorithm, KNN) were satisfactory for all images, visually reducing the greater level of detail in the detection in RGB and gray scale. The results found show an accuracy of 93,97% in RGB and 90,16% in gray scale.

Keyword: Principal Component Analysis (PCA), K-nearest neighbors algorithm (KNN).
Classification of hand images, Biometrics.

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação da imagem em função bidimensional.	Erro! Indicador não definido. 6
Figura 2 – Exemplo de uma imagem digital.	197
Figura 3 – Representação do espaço de mãos Cz.	18
Figura 4 – (a) Imagem contínua, (b) Imagem contínua representada em uma matriz, (c) Resultado da amostragem e quantização da imagem.	Erro! Indicador não definido. 9
Figura 5 – (a) Imagem Binária (b) Representação matricial.	240
Figura 6 – (a) Imagem de n=8, 256 tons de cinza e (b) Representação de uma área no formato matricial.	Erro! Indicador não definido.
Figura 7 – Formação de um vetor a partir de valores de pixels correspondentes em três imagens, em que cada uma delas representa uma cor. ...	Erro! Indicador não definido. 2
Figura 8 – Representação das imagens da mão para a PCA.	Erro! Indicador não definido. 3
Figura 9 – Representação gráfica das variáveis originais e as CP's.	Erro! Indicador não definido. 4
Figura 10 – Armazenamento de uma imagem em um vetor N-dimensional.	Erro! Indicador não definido.
Figura 11 – Equação de covariância.	28
Figura 12 – Ilustração de classificação de uma amostra.	29
Figura 13 – Método para classificação de indivíduos. ...	Erro! Indicador não definido. 0
Figura 14 – Ilustração do KNN.	Erro! Indicador não definido. 2
Figura 15 – Relação de erros e acertos imagem RGB utilizando todas componentes.	Erro! Indicador não definido. 4
Figura 16 – Relação de erros e acertos imagem RGB utilizando cinco componentes	Erro! Indicador não definido. 5
Figura 17 – Relação de erros e acerto com imagens em tons de cinza....	Erro! Indicador não definido.
Figura 18 – Relação de erros e acertos imagens tons de cinza utilizando cinco componentes.	Erro! Indicador não definido.

LISTA DE TABELAS

Tabela 1 – Relação de todos os testes.....**Erro! Indicador não definido.**6

LISTA DE SIGLAS

PDI = Processamento Digitais de Imagens

RGB = *Red, Green, Blue*

NIR = Near Infrared

PCA = *Principal Component Analysis*

KNN = *K-Nearest Neighbors*

CP's = Componentes principais

ML – Machine Learning

SUMÁRIO

1	INTRODUÇÃO.....	Erro!
	Indicador não definido.2	
1.1.	Objetivo geral.....	Erro!
	Indicador não definido.4	
1.2.1.	Objetivos específicos.....	Erro!
	Indicador não definido.4	
1.3.	Resultados esperados.....	Erro!
	Indicador não definido.4	
2	FUNDAMENTAÇÃO TEÓRICA.....	Erro!
	Indicador não definido.5	
2.1.	Representação de imagens digitais.....	Erro!
	Indicador não definido.5	
2.1.1.	Amostragem e quantização.....	Erro!
	Indicador não definido.7	
2.1.2.	Problemas de operações com imagens.....	18
2.1.3.	Imagens binárias.....	19
2.1.4.	Imagens em escala de cinza.....	Erro!
	Indicador não definido.0	
2.1.5.	Imagens coloridas.....	Erro!
	Indicador não definido.1	
2.1.6	Conversão de imagem RGB para tons de cinza.....	Erro! Indicador não definido.1
2.1.7.	Análise de componentes principais.....	Erro!
	Indicador não definido.2	
2.1.8	Características de uma componente principal.....	Erro! Indicador não definido.3
2.1.9.	Classificação	Erro!
	Indicador não definido.5	

2.2.2.	K-Nearest Neighbors.....	Erro!
	Indicador não definido.	9
3	RESULTADOS.....	Erro!
	Indicador não definido.	1
4	CONCLUSÃO.....	Erro!
	Indicador não definido.	
4.1.	Trabalhos futuros.....	38
	REFERÊNCIAS.....	40
	APÊNDICE A – CÓDIGO FONTE CLASSIFICAÇÃO IMAGEM TONS DE CINZA.....	Erro!
	Indicador não definido.	3
	APÊNDICE B – AMOSTRAS DE IMAGENS UTILIZADAS.....	45

1. INTRODUÇÃO

Estudos em Processamento Digital de Imagens (PDI) e Visão Computacional vêm fornecendo ferramentas para a extração de informações em imagens, desde o tratamento dos dados até o reconhecimento de padrões (GONZALEZ,1977). Sua aplicação ocorre em diversas áreas tais como na indústria (FELICIANO; DE SOUZA; LETA, 2010), na botânica com a classificação de pimentas (SILVA et al., 2016) e (SILVA et al, 2016), na biologia com a contagem de Leishmanias em imagens de células (COELHO, 2016), na segurança com a identificação de indivíduos (SILVA; CINTRA, 2015), e na medicina (DOUGHERTY, 2017).

Dentre essas aplicações pode-se destacar a biometria que consiste na identificação de indivíduos a partir do reconhecimento de padrões em características físicas ou comportamentais (GONZALEZ,1977) e (OLIVEIRA, 2017). Essa técnica é diretamente utilizada na área de segurança, mas como se trata da manipulação das características de pessoas por algoritmos computacionais, ela pode ser adaptada para o projeto de pesquisa no qual este trabalho está incluído, pois essas mesmas técnicas implementadas e testadas poderão ser oportunamente utilizadas para o diagnósticos de doenças em saúde pública.

Como o avanço da tecnologia, novas imagens vêm sendo geradas com espectros adicionais às regiões visíveis (JENSEN,1986). Um exemplo são as câmeras multiespectrais NIR (*Near Infrared*), que possibilitam a aquisição de imagens na região do visível juntamente com infravermelho. Os espectros NIR permitem obter informações adicionais anteriormente limitadas ao espectro do visível, aumentado ainda mais as informações a serem obtidas e conseqüentemente enriquecendo os modelos gerados (KLARE; JAIN, 2010). O aprimoramento dos modelos gerados com os métodos de classificação e PDI em imagens multiespectrais têm sido aproveitados na biometria, que consiste na verificação e reconhecimento de um indivíduo por uma característica única e pessoal, seja ela de cunho biológico ou comportamental (JAIN; BOLLE; PAKANTI, 2006). Métodos biométricos em geral lidam com dois problemas: o primeiro é de verificação, que consiste na confirmação ou negação de uma identidade reivindicada de uma pessoa, e o segundo é de reconhecimento (mais conhecido como identificação), que consiste em estabelecer a identidade de uma pessoa (sendo por um grupo de identidades já conhecidas ou não) (JAIN ; BOLLE ; PAKANTI, 2006).

Neste trabalho, as imagens da mão são as características escolhidas para o reconhecimento de indivíduos. Essas imagens podem ser geradas a partir do espectro da luz visível e outros próximos do infravermelho, como foi feito em (KITANI, THOMAZ, 2006), pois permitem uma maior quantidade de informações do que apenas a região visível. Em (DUARTE, 1998) foi feito o reconhecimento dos indivíduos utilizando o espectro NIR para análise das veias da palma da mão

Para o reconhecimento de indivíduos, podem-se destacar duas etapas principais: a extração dos dados, na qual a partir de um banco de imagens extrai-se as informações que serão armazenadas e organizadas no computador. A segunda etapa é a de classificação, na qual a partir de uma nova imagem faz-se a busca no banco de dados para ver se o indivíduo é identificado.

Métodos clássicos são vulneráveis a fraude ou até mesmo ao esquecimento, enquanto os métodos biométricos mostram uma maior robustez nestes aspectos (SVÁ B, 1973). Os métodos biométricos foram propostos no intuito de agregar uma maior segurança em relação aos métodos de autenticação convencionais (chaves, senhas etc.) (SVÁ B, 1973).

No método biométrico é necessário utilizar algoritmos de reconhecimento de padrões para verificação e identificação dos indivíduos (HAO,2007).

A técnica mais utilizada na primeira etapa é a Análise de Componentes Principais (*Principal Component Analysis*, PCA) (LOPES, 2011) e que será utilizada neste trabalho. Na segunda etapa é comumente utilizada a técnica de *K*-vizinhos mais próximos (*K-Nearest Neighbors*, KNN) (DUARTE, 1998).

1.1.Objetivo geral

Realizar estudos exploratórios de métodos para a análise de imagem multiespectral e sua classificação. Métodos de análise multivariada serão aplicados em imagens de palmas das mãos obtidas através da câmera JAI AD-080GE (estação de aquisição de imagens multiespectrais) no intuito de reconhecer os padrões da impressão da palma da mão e posteriormente classificá-la. Através do uso da Análise de Componentes Principais visualizar e identificar a relação entre características extraídas dos dados visando sua redução. As análises serão validadas com as informações reais da palma da mão do indivíduo ao qual foi obtida a imagem.

Neste contexto, este trabalho tem como objetivo propor um método de extração de características em imagens multiespectrais da impressão da palma da mão e sua classificação através da análise de componentes principais.

Pretende-se não apenas analisar o espectro NIR como também o espectro visível de forma integrada, com o intuito de obter resultados melhores.

1.1.1. Objetivos específicos

- Aprofundar o conhecimento de análise de componentes principais.
- Aprimorar o conhecimento a respeito da classificação de imagens multiespectrais de palmas das mãos.
- Determinar o algoritmo que possui maior eficácia e eficiência.

1.2. Resultados esperados

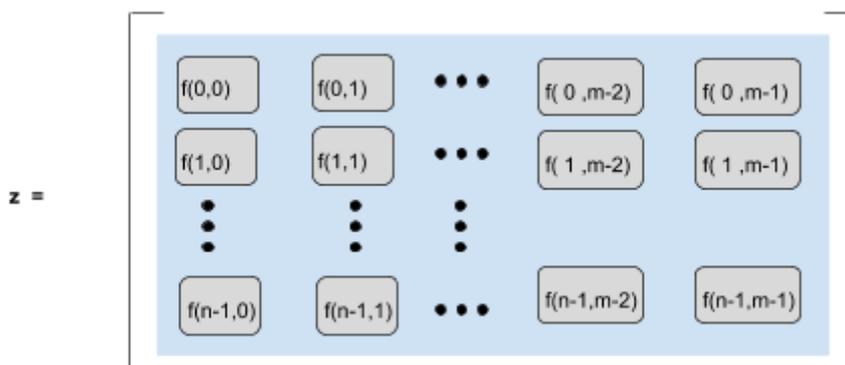
- Espera-se que os resultados desta pesquisa possam contribuir com o reconhecimento de palmas das mãos e comparar com trabalhos relacionados na literatura.

2 FUNDAMENTAÇÃO TEÓRICA

2.1. Representação de imagens digitais

Uma imagem é definida como uma função bidimensional, ou seja, uma matriz z de dimensão $m \times n$, onde m é o número de linhas e n é o número de colunas. Cada posição da matriz, um par ordenado $f(x, y)$, $x < m$ e $y < n$, é denominado um pixel com um valor, em escala de cinzas, que representa a luminosidade da imagem (GONZALEZ ; WOODS, 2009). Pixel é o menor elemento em um dispositivo de exibição, ao qual é possível atribuir-se uma cor. Uma imagem de 8 bits, um pixel pode variar de 0 a 255, no qual 0 representa a ausência de luminosidade (preto) e 255 a máxima luminosidade (branco). Quando os pontos x , y (linha e coluna) e os valores de nível de cinza são quantidade finita e discreta, a matriz é determinada como uma imagem digital (GONZALEZ; WOODS, 2008). A Figura 1 ilustra uma representação de uma imagem z de n linhas e m colunas, através de uma função bidimensional.

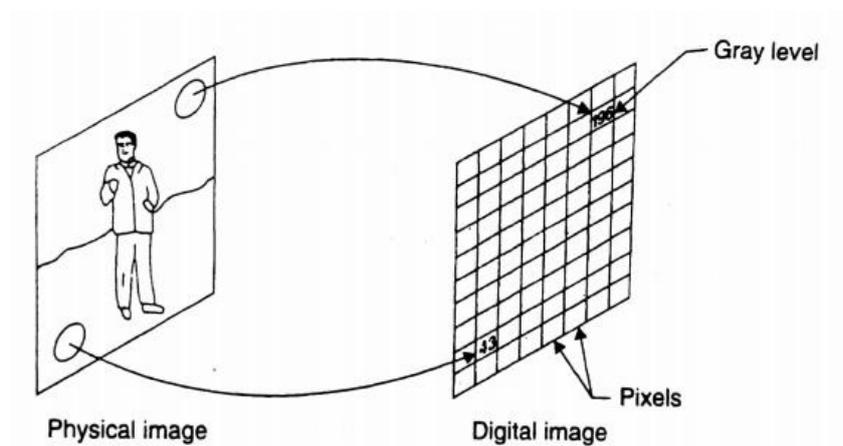
Figura 1 – Representação da imagem em função bidimensional



Fonte: Autoria própria (2020)

A Figura 2 ilustra uma imagem digital, que é obtida através da discretização, e cada ponto representa a intensidade de um pixel em tons de cinza.

Figura 2 – Exemplo de uma imagem digital



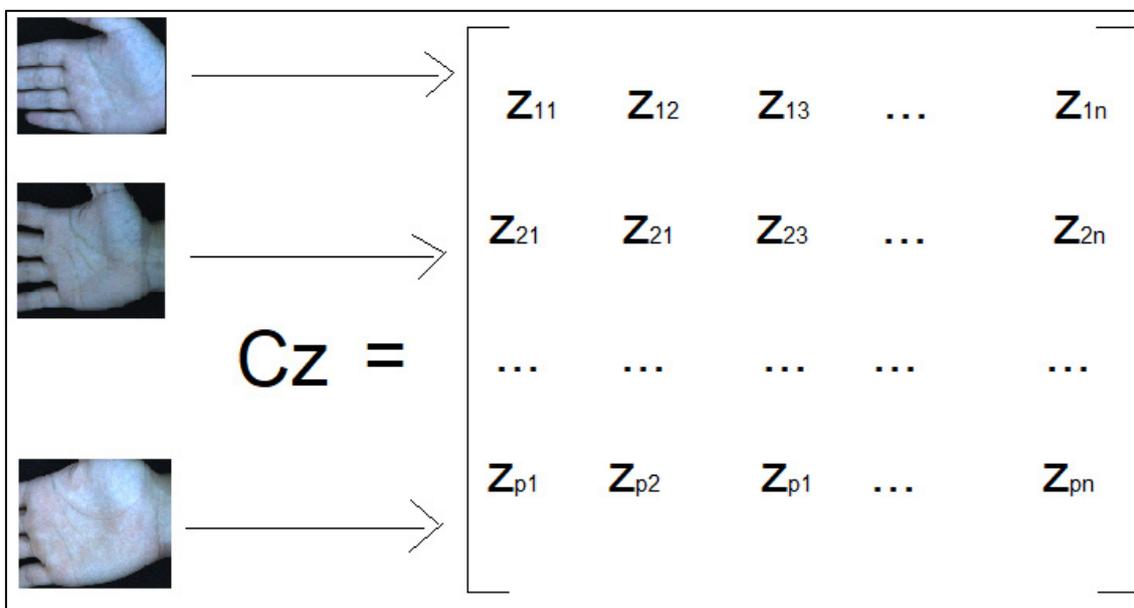
Fonte: Castleman, Kenneth R., 1979

No entanto, a matriz que representa a imagem também pode ser escrita como um vetor z^t N -dimensional, onde $N = m \times m$, que é a matriz da Figura 1 concatenada. Dessa forma representando a imagem como um vetor $(z^t) \mathfrak{R}^n$, essa imagem é um ponto nesse espaço \mathfrak{R}^n . Portanto um espaço de imagens Cz é um espaço multidimensional que contém todas as imagens (pontos) de um determinado conjunto de imagens. Para isso ser válido, considera-se um sistema de coordenadas ortonormais e os vetores unitários $\omega_1, \omega_2, \omega_3, \dots, \omega_n$ que representa essa base. Podemos escrever um ponto nesse espaço como uma combinação dos vetores unitários ortonormais e das projeções do vetor z de acordo com a Equação 01.

$$Cz_i = z_{i1} \cdot \omega_1 + z_{i2} \cdot \omega_2 + z_{i3} \cdot \omega_3 + \dots + z_{in} \cdot \omega_n, \quad (1)$$

Onde i é uma imagem do espaço de imagens Cz_i .

Para um conjunto de imagens de mãos (base de dados), as imagens são concatenadas, de modo que cada imagem i é um vetor (z^t) N -dimensional. Além disso, é realizado um agrupamento em uma matriz denominada Cz . A matriz conterà $P \times m \times m$, elementos, onde P é a quantidade de imagens. A Figura 3 ilustra o espaço de mão, cuja dimensão é de P linhas por N colunas, onde P é o número de mãos e N é o produto $m \times m$, que representa a dimensionalidade desse espaço (ARAÚJO, 2009), (KITANI; THOMAZ, 2006).

Figura 3 – Representação do espaço de mãos Cz 

Fonte: Autoria própria (2020)

O tamanho da matriz que representa a imagem é a sua resolução. A resolução das imagens de mãos são todas de 1024×768 , que é o total de células da matriz (1024 linhas e 768 colunas). Representando essa imagem como um vetor N -dimensional, o total de células desse vetor é de 786432 posições ($N = 1024 \times 768$) (KITANI; THOMAZ, 2006).

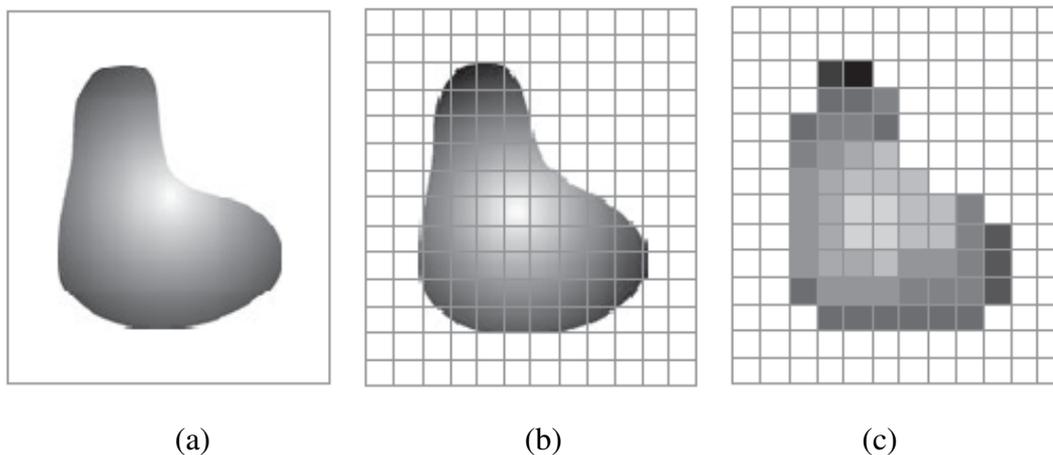
2.1.1. Amostragem e quantização

O processo de amostragem, também conhecido como discretização espacial, é a conversão da imagem do mundo real, ou seja, analógica, em uma matriz z de $m \times n$, onde m são as quantidades de linhas e n as colunas respectivamente. Cada posição desta matriz é definida como pixel ou elemento de imagem (MARQUES FILHO; VIEIRA NETO, 1999). Em outras palavras, a amostragem é a passagem da imagem analógica para digital, onde cada pixel é a medição da luminosidade, ou seja, a digitalização.

A quantização, também chamada de discretização em amplitude, determina o valor que o pixel receberá no processo de amostragem, que é um inteiro entre $2^n - 1$ onde n representa a quantidade de bits, por exemplo, em escala de cinza, o n é igual a 8 e o valor do pixel pode variar de 0 a 255 (MARQUES FILHO; VIEIRA NETO, 1999).

Todo esse processo é necessário porque o computador digital processa números inteiros, e os valores contínuos são passados para discreto para sua interpretação. A Figura 4 ilustra o processo de amostragem e quantização.

Figura 4 – (a) Imagem contínua, (b) Imagem contínua representada em uma matriz, (c) Resultado da amostragem e quantização da imagem.



Fonte: GONZALEZ; WOODS, 2008.

A Figura 4 (a) representa a imagem física. Posteriormente, esta imagem recebe o processo de discretização espacial, realizando a medição do nível de cinza em cada pixel da imagem, que pode ser observado na Figura 4 (b). A Figura 4 (c) representa o processo de discretização em amplitude, recebendo o valor medido no processo de amostragem.

A matriz de uma imagem digital é composta somente pelos valores das coordenadas x e y e de seu respectivo valor como ilustrado na figura 1 da seção 2.1.1.

2.1.2. Problemas de operações com imagens

As operações aritméticas podem ser aplicadas nos pixels, podendo ser na imagem inteira ou em uma região específica (BURGER et al., 2016). Para detecção e obtenção do tamanho de uma área, essas operações são fundamentais, visto que nestes tipos de procedimentos as características da imagem devem ser mantidas (SILVA, 2017).

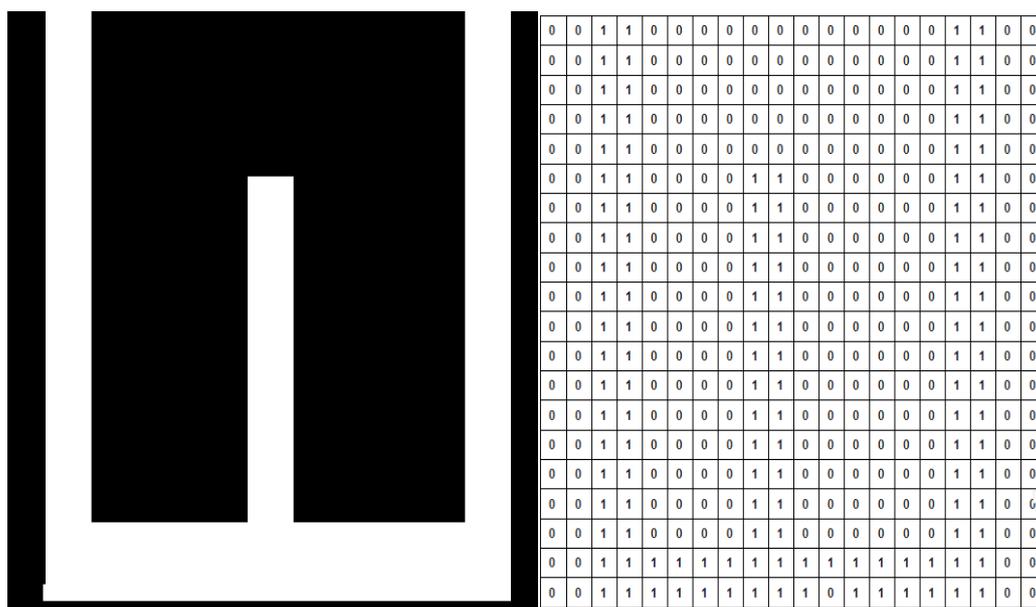
A representação de uma imagem de mão requer um número elevado de células, ou seja, os pixels, representam um espaço físico de memória. Considerando o tamanho de uma imagem (786432 células de memória, 1024×768 , resolução da imagem) qualquer cálculo envolvendo dados dessas magnitudes requer um grande esforço computacional. Um método para resolver esse problema de armazenamento e manipulação (cálculos) dos

dados é reduzir a dimensionalidade dos dados de forma que haja uma transformação na matriz Cz (espaço das mãos) de tal forma que gere uma nova matriz que tenha o máximo de informações de Cz ocupando um espaço muito menor do que o original, e para atingir tal resultado utiliza-se a *PCA*.

2.1.3. Imagens binárias

Uma imagem binária é representada por dois subconjuntos de pixels da imagem, plano e fundo. O primeiro tem o valor igual a 1, o branco, e o segundo o valor 0 que é o preto. A análise digital de imagens binárias está essencialmente relacionada a caracterização de propriedades no conjunto de pixels de primeiro plano (MARCHAND-MAILLET; SHARAIHA, 2000), ou seja, é uma imagem onde cada pixel pode assumir apenas dois valores, 0 ou 1. A Figura 5 ilustra uma imagem binária (a) 20x20 pixel e (b) uma matriz quadrada (20 linhas e 20 colunas).

Figura 5 – (a) Imagem binária (b) Representação matricial.



Fonte: Autoria própria

Os pixels brancos são elementos do primeiro plano, cuja sua intensidade é 1 e a cor é o branco. Os pixels pretos representam o subconjunto do fundo, recebendo o valor 0 como intensidade.

2.1.4 Imagens em escala de cinza

A representação de uma imagem em escala, tons ou níveis de cinza, é feita através de uma matriz, $M \times N$ e n , no qual $M \times N$ é a resolução da imagem, a quantidade de pixels e n a qualidade da imagem. A qualidade da imagem é calculada por 2^n , ou seja, os valores que cada pixel pode receber, por exemplo, n igual a 8 cada pixel pode receber um valor entre 0 a 255, no qual representa a intensidade do pixel, 0 ausência de luz, preto, e 255 o valor máximo de luz, o branco (GONZALEZ; WOODS, 2008).

Figura 6 – (a) Imagem de $n = 8$, 256 tons de cinza e (b) Representação de uma área no formato matricial



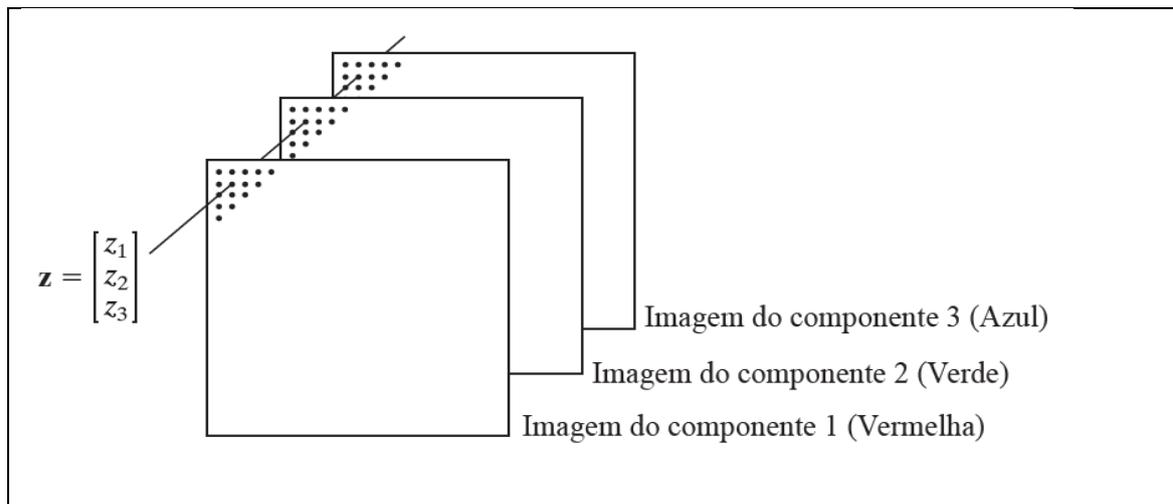
Fonte: Aatoria própria

A Figura 6 é uma imagem em tons de cinza, e o fragmento em destaque, uma matriz 8×6 , cada posição dessa matriz, é um pixel. O intervalo de tons de cinza é de 0 a 255, ou seja, 2^8 , $n = 8$. Nas primeiras posições do fragmento da imagem é possível notar que os valores estão bem próximos de 255, que representa a cor branca.

2.1.5 Imagens coloridas

Uma imagem colorida pode ser representada pelo modelo RGB (*red, green, blue* — vermelho, verde, azul). Nesta representação a imagem são divididas em três componentes de imagens, que são matrizes, no qual cada matriz representa uma cor primária, vermelho, verde e azul respectivamente. A imagem é produzida a partir da combinação dessas três matrizes (GONZALEZ; WOODS, 2008). A Figura 7 ilustra a representação de uma imagem colorida no formato RGB.

Figura 7 – Formação de um vetor a partir de valores de pixels correspondentes em três imagens, em que cada uma delas representa uma cor.



Fonte: Autoria própria

A Figura 7 ilustra o processo de formação de uma imagem RGB, no qual cada coordenada do vetor \mathbf{z} é a intensidade da cor da matriz que ela pertence, semelhante aos tons de cinza.

2.1.6 Conversão de imagem RGB para tons de cinza

A conversão de uma imagem colorida para uma de escala de cinza, é a redução das três matrizes do RGB para apenas uma, pois as três camadas tornam-se uma. Um dos mais utilizados para conversão é o cálculo da média entre cada canal de cor (BENEDETTI, 2012). A equação para conversão de uma imagem RGB para tons de cinza pode ser definida de acordo com a Equação 2.

$$f(x, y) = \frac{R(x, y) + G(x, y) + B(x, y)}{3} \quad (2)$$

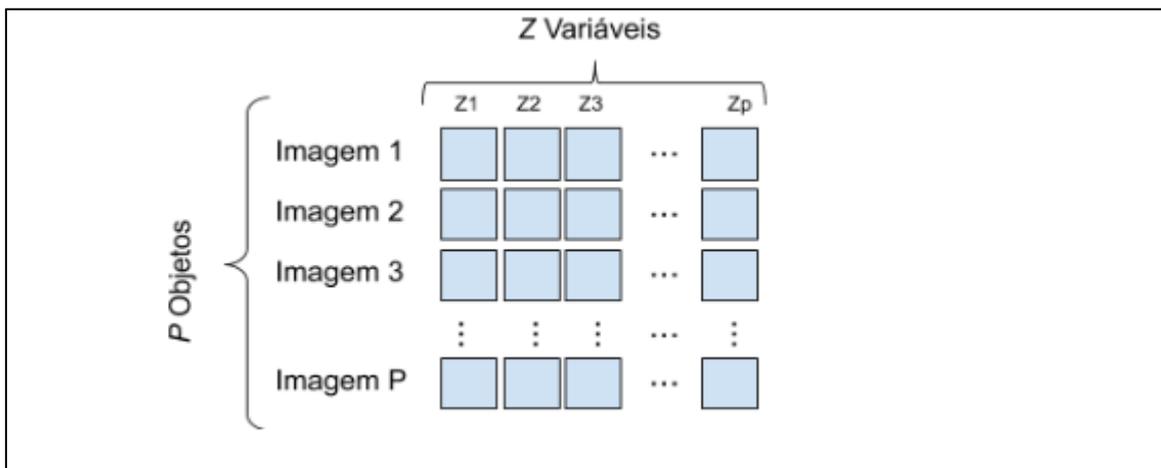
Nesta equação, cada par ordenado (x, y) , é um pixel, e cada valor é a intensidade de um pixel daquela determinada camada.

2.1.7 Análise de Componentes Principais

A *PCA* é uma técnica exploratória para a análise de séries estatísticas multidimensionais. A princípio o objetivo da PCA é conseguir visualizar graficamente o máximo de informações que está contida em uma matriz de dados ou um quadro de objetos variáveis (imagens da mão), com P linhas (cada linha uma imagem de mão) e Z

colunas(variáveis). Considerando que as Z variáveis da série multivariada tenham uma associação entre si, é interessante substituí-la por k variáveis não correlacionadas e que conte com quase todas informações dos dados originais, ou seja, a perda de informações seja a menor possível e que k seja muito menor que Z (DUARTE, 1998). A figura 8 mostra os dados para a PCA a partir das imagens da mão.

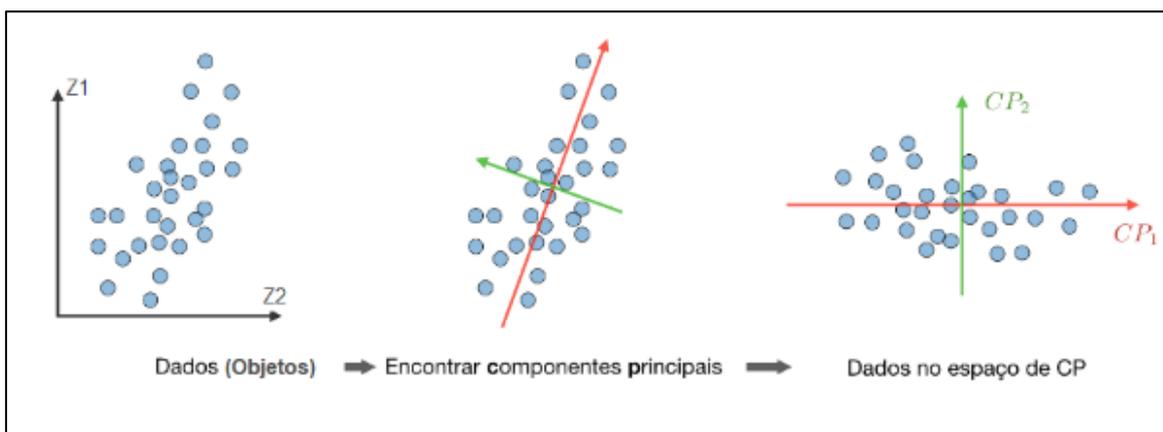
Figura 8: Representação das imagens da mão para a PCA.



Fonte: Autoria própria

Os componentes principais (CP's) são definidas como combinações lineares das variáveis (eixos), onde cada eixo está na direção de uma determinada variância dos dados (DUARTE, 1998), ou seja, são eixos de um novo sistema de coordenadas que é obtido através de uma rotação específica no qual os eixos estão na direção de variância máxima. Na figura 9 há duas variáveis $Z1$ e $Z2$, e duas componentes principais $CP1$ e $CP2$. Observa-se que foi feita uma rotação nos eixos e a primeira componente está na direção da maior variabilidade, a segunda para máxima variabilidade sem considerar a primeira. A $CP1$ responde pela maior parte da variabilidade das duas variáveis originais (ARAÚJO,2009), (KITANI; THOMAZ, 2006), (DUARTE,1998),(LOPES, 2011).

Figura 9: – Representação gráfica das variáveis originais e as CP's



Fonte: Autoria própria

As CP's representam um novo conjunto de variáveis, ou seja, novos eixos, que são funções lineares daquelas originais e que tem variância máxima. As CP's também podem ser definidas como vetores da matriz de covariância que são obtidos através dos autovalores dessa mesma matriz. CP's, portanto, são combinações lineares com coeficientes que são os autovetores da matriz de covariâncias, ordenadas decrescentemente pelos autovalores correspondentes.

Utilizando a PCA é possível reduzir o número de variáveis a serem analisadas através do descarte de CP's que tenha variância pequena, estudando então apenas as que tenham variância significativa. Um conjunto de dados, ou seja, as imagens da mão com z variáveis (colunas do vetor N -dimensional que representa a imagem da mão) é resumido em outro de k variáveis ($k \ll z$) que explique a maior parte da variabilidade apresentados pelas variáveis originais (ARAÚJO, 2009), (KITANI; THOMAZ, 2006), (DUARTE, 1998).

2.1.8 Características de uma componente principal

1. As CP's apresentam direções perpendiculares, os autovetores que determinam a rotação dos eixos são ortonormais, isso faz com que a diferenciação ou similaridade de objetos (imagens da mão) não dependa da correlação entre as variáveis (DUARTE, 1998).
2. A soma dos quadrados dos coeficientes da combinação linear é igual a um.

3. Na PCA cada nova componente obtida representa cada vez menos a variabilidade total dos dados. Isso faz com que alguns componentes podem ser desprezíveis por carregar uma parte muito pequena de informações dos dados (DUARTE, 1998).
4. As componentes são ordenadas de forma decrescente de acordo com a variância dos dados, a variabilidade da primeira CP decresce da primeira para segunda, da segunda para a terceira e assim por diante. Assim o estudo pode ser feito em um número k de componentes sem grandes distorções (KITANI, THOMAZ, 2006) (DUARTE, 1998).

Assim, a técnica PCA permite identificar padrões nos dados e expressá-los de uma maneira tal que suas semelhanças e diferenças sejam destacadas. Uma vez encontrados padrões nos dados, é possível comprimi-los, ou seja, reduzir suas dimensões, sem muita perda de informação. Deste modo, a PCA pode ser empregada como um método de compressão de imagens digitais sem grandes perdas de informações, tornando-se vantajosa, levando em consideração várias instâncias, como: compressão de imagens, representação dos dados, redução do cálculo necessário em processamentos posteriores etc. (HAYKIN, 1999), (SANTO, 2012).

Em uma matriz de dados (espaço Cz), na qual cada linha representa uma mão de um indivíduo específico, as P mãos de indivíduos são representadas por um conjunto de pontos em um espaço dimensional de Z variáveis. O objetivo da PCA é encontrar um espaço vetorial reduzido para uma melhor visualização das mãos. Dessa forma procura-se um número pequeno de CP's que forneçam a maior parte das informações existentes no grande conjunto de dados (matriz de dados) (KITANI, THOMAZ, 2006).

A maneira que as CP's são construídas maximizam a variância explicada. Essa construção é feita através do cálculo dos autovalores da matriz de covariância e dos autovetores a eles associados. Os Z autovalores calculados são as variâncias das imagens das mãos em relação as Z componentes principais (eixo principais). Esses autovalores são representados por λ_i ($i = 1, 2, 3, \dots, z$), que representam a magnitude da variabilidade das imagens das mãos captada pela i – ésima CP. Então deve-se organizar os autovalores de forma que $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_z$ (KITANI; THOMAZ, 2006), (DUARTE, 1998). Assim a variância da i – ésima CP pode ser calculada de acordo com a Equação 03.

$$CP_i = \lambda_i \div \left(\sum_{j=1}^z \lambda_j \right), j \neq i \quad (3)$$

Os autovetores representam os coeficientes associados às Z variáveis originais, a partir dos quais obtém-se os “scores” de cada CP, que são as translações assumidas pelas variáveis, formando assim um novo sistema de eixos coordenados. Todo esse processo de cálculo de autovalores e autovetores associados é chamado de diagonalização ou decomposição de valores singulares (DUARTE, 1998).

Uma boa prática ao montar a PCA é a normalização dos dados, que consiste em centrar cada elemento (variável) em relação à média e reduzir a unidade do desvio padrão. Com os dados em escala diferenciadas, faz com que as variáveis de maior variância estejam com maior peso nas primeiras CP's (KITANI, THOMAZ, 2006). Essa padronização é feita através da Equação 04.

$$z_{ij} = (z_{ij} - \mu) / \sigma \quad (4)$$

onde Z_{ij} representa o elemento, μ a média geral e σ o desvio padrão.

Geometricamente a PCA faz uma rotação nos eixos coordenados das variáveis originais, de modo que o novo sistema de eixos coordenados (CP's) capte a maior variabilidade contida entre os objetos (imagens das mãos de cada indivíduo). Assim uma nuvem de objetos (imagens que são representada por um ponto *n-dimensional*) pode ser representada em um sub-espaço, cujos eixos são os autovetores associados aos k primeiros autovalores (maiores) da matriz de covariâncias (KITANI, THOMAZ, 2006).

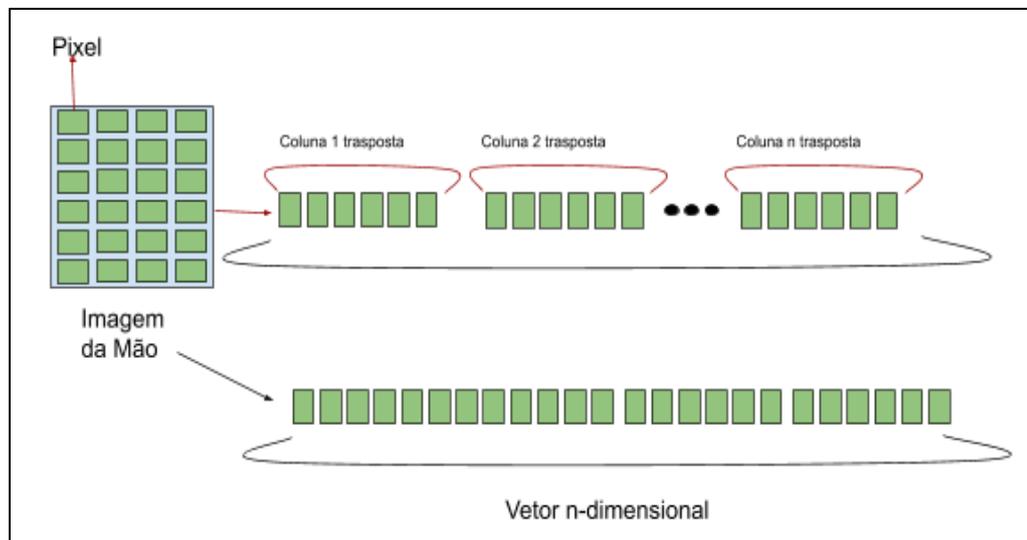
2.1.9 Classificação

Para fazer a classificação, ou seja, determinar se a imagem da mão é de determinado indivíduo, na implementação foram seguidos os passos:

Selecionar a quantidade de indivíduos e amostras (fotos) e armazenar em uma matriz de dados na qual cada linha representa uma amostra. A amostra será colocada em um vetor linha, para facilitar, cada coluna da amostra será colocada em uma linha, transpondo cada coluna e agregando-as, de modo que todas as colunas transpostas, 1, 2, . . . p , transformem-

se em apenas uma linha organizada pelas colunas transpostas (KITANI, THOMAZ, 2006). A Figura 10 mostra o processo.

Figura 10: Armazenamento de uma imagem em um vetor N-dimensional



Fonte: Autoria própria

Após a matriz de dados montada, então é feita a normalização, isto é aplicado a fim de evitar que as colunas da imagem principal tenham influência indevida nos componentes principais (SANTO, 2012). Para fazer a normalização, que consiste em pegar cada elemento da matriz menos a média da coluna, do elemento, e dividir pelo desvio padrão da coluna. A equação (2) mostra como é a equação da normalização (ARAÚJO, 2009). Em seguida é feita a matriz de covariância que é utilizada para relacionar os conjuntos de dados. Uma análise de componentes principais envolve encontrar os autovalores de uma matriz de covariâncias amostral (ARAÚJO, 2009). Primeiramente é feita uma matriz de covariância, conforme figura 11, que para facilitar os cálculos é feita a diferença de cada elemento pela média da sua respectiva coluna. Logo após essa subtração é feita uma multiplicação da matriz por sua transposta e, em seguida dividir cada elemento pela quantidade de linhas menos um (espaço amostral), isso resultará na matriz de covariância. Com a matriz de covariância montada são calculados os autovalores e seus respectivos autovetores. A matriz de translação (matriz de autovetores) consiste em organizar, os autovalores, em ordem decrescente, com seus respectivos autovetores, já que os autovalores indicam a variância dos dados, o maior autovalor está associado com o autovetor que indica a maior variância dos dados e assim respectivamente. A Figura 11 ilustra a equação.

Figura 11: Equação de covariância

$$COV_{i,j} = 1/(n-1) \sum_{i=1}^n (z_i - \bar{z}_i) \cdot (z_j - \bar{z}_j), i \neq j$$

Onde:

\bar{z}_i é a média aritmética da variável Z_i .

\bar{z}_j é a média aritmética da variável Z_j .

n é o número de dados observados.

z_i é o dado da série Z no instante i .

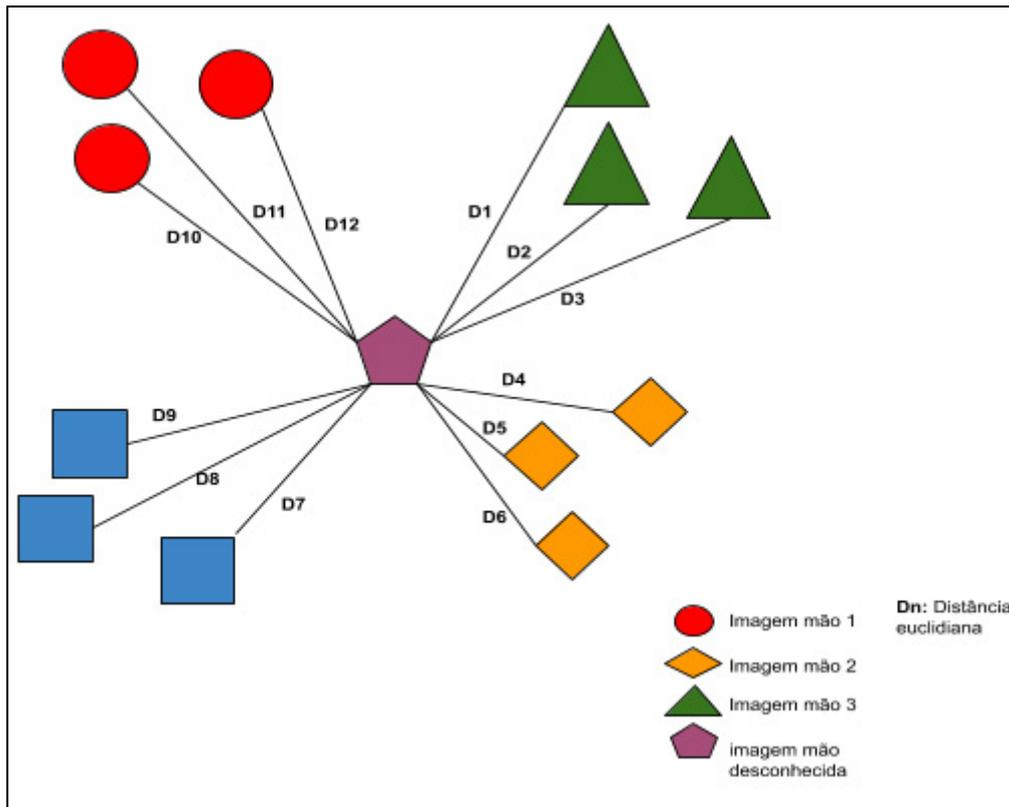
z_j é o dado da série Z_j no instante i .

COV_{z_i, z_j} é a covariância entre a série Z_i e a série Z_j .

Fonte: Autoria própria

Com a matriz de translação montada, a matriz de dados normalizada é multiplicamos pela matriz de translação (matriz de autovetores) e obtemos as componentes principais (PC's) (SANTO, 2012), (GONZALEZ, WOODS, 2010). Com as PC's montadas, um método de fazer uma classificação, ou seja, apontar qual imagem da mão que possui a maior gama de características semelhantes, basta pegar uma imagem da mão que desejamos classificar, colocar essa imagem da mão em um vetor n-dimensional, normalizar fazer a translação(multiplicar pelos autovetores) e calcular a distância euclidiana de cada uma das PC's, ver figura 6. A distância euclidiana é um parâmetro para comparar dois conjuntos(JOLLIFFE , 1986). A classificação é feita pegando a menor distância, que possivelmente será a imagem da mão com características que mais se aproxima daquela amostra. A Figura 13 mostra o processo e a ilustração da classificação.

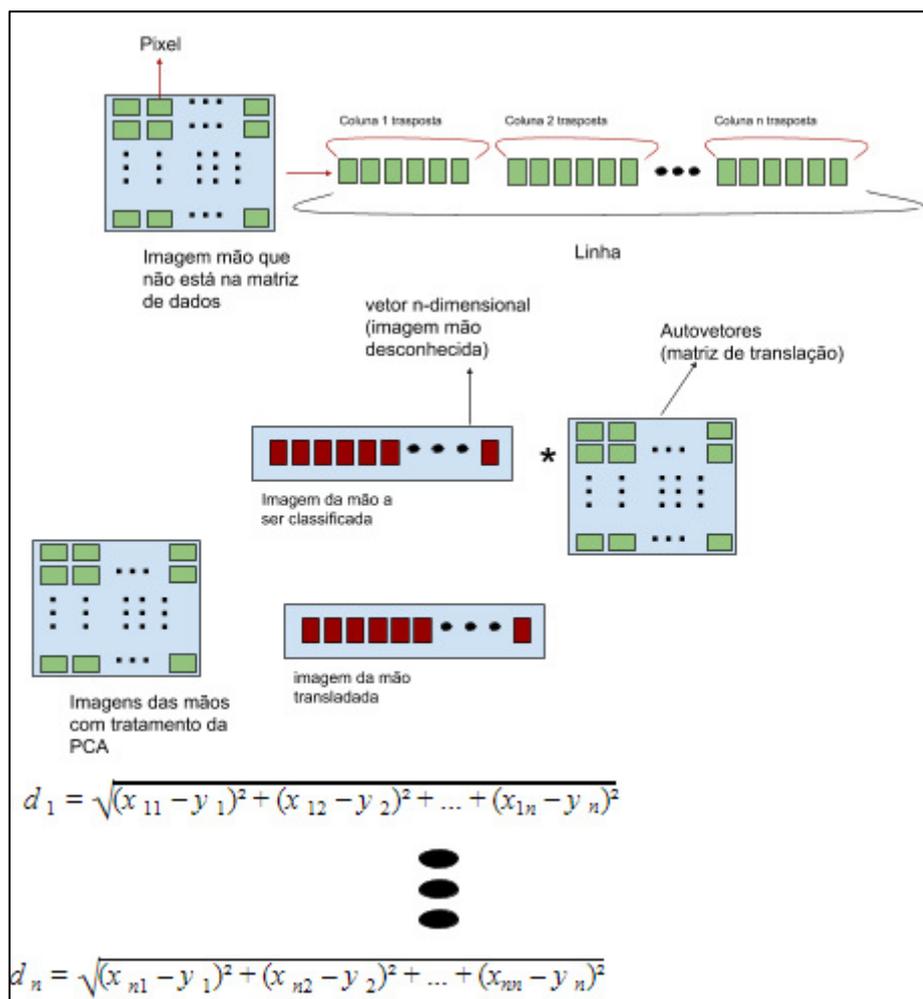
Figura 12- Ilustração de classificação de uma amostra



Fonte: Autoria própria

O pentágono da Figura 12 representa uma imagem da mão na qual desejamos classificar, ou seja, é uma imagem desconhecida. O círculo, triângulo, losango e quadrado são classes, e representam as imagens das mãos utilizadas para treinamento, e contém características de determinadas mãos. Para classificar o pentágono, pode ser usada como classificador a distância euclidiana, e é preciso calcular a distância do mesmo a todos os vizinhos, sendo que a menor distância representa qual foi a imagem da mão que possui características “parecidas” com a do pentágono, e então é atribuído a ela uma classe. A Figura 13 ilustra todo o processo até o cálculo da distância euclidiana.

Figura 13- Método para classificação de indivíduos.



Fonte: Autoria própria

Onde x_{ij} , $i=1,2,3,\dots,n$ e $j=1,2,3,\dots,n$, são os elementos da PC's e y_i os elementos da imagem da mão que não está no conjunto de imagens de treinamento

2.1.10K-Nearest Neighbors (KNN)

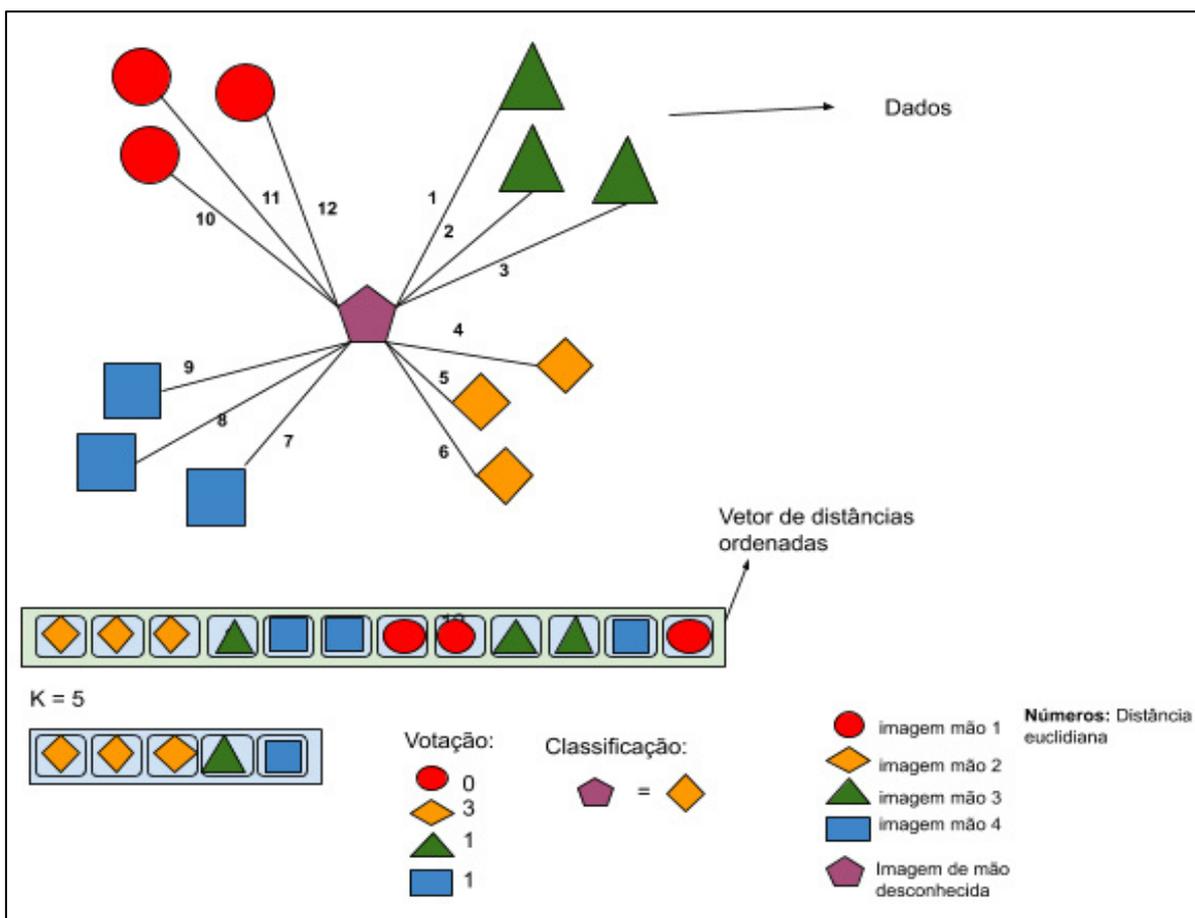
Outra forma que pode aumentar a acurácia da classificação é a aprendizagem de Máquina (ML — *Machine Learning*) que engloba técnicas que utilizam conceitos de inteligência artificial e/ou métodos estatísticos para realizar o reconhecimento de padrões (KITANI, THOMAZ, 2006), utilizadas no desenvolvimento de sistemas inteligentes capazes de adquirir conhecimento de forma automática por meio da análise de um conjunto de dados (imagens das mãos). Os algoritmos de classificação utilizados por essa abordagem são capazes de realizar aprendizagem interativa, mediante a análise de um

conjunto de dados chamados de amostra. Tais algoritmos podem ser utilizados para resolver problemas de classificação, regressão, *clustering* ou extração de regras, possibilitando, deste modo, a construção de modelos de predição (MITCHELL, 1997), (GHOTRA; MCLINTOSH; HASSAN, 2015).

Um método de aprendizagem supervisionado, que pode ser usado para classificação, é o KNN, na qual k é um número adotado para indicar a quantidade de vizinhos utilizados para a análise. Esse método realiza a aprendizagem por meio da analogia. O conjunto de treinamento é formado por vetores n -dimensionais e cada elemento deste conjunto representa um ponto no espaço n -dimensional, para classificar um nova imagem da mão (vetor n -dimensional), a similaridade com outras imagem da mão já conhecidos é calculada por meios da distância dessa nova imagem da mão para as já conhecidas (BISHOP , 2006).

Para a classificação de uma nova imagem da mão que não está no conjunto de treinamento, é definido um valor de k vizinhos, que é o intervalo que se deve fazer uma contagem e descobrir qual supostamente é a imagem da mão, dentro daquele intervalo, ou seja a imagem da mão que é mais frequente. A definição desse intervalo se dá de forma empírica. Após a definição do intervalo e o cálculo da distância euclidiana, é necessário ordenar as distâncias decrescentemente, e a partir delas indicar o resultado da classificação, ou seja, qual possivelmente é a classe daquela mão. A Figura 14 mostra o processo que é feito para a classificação com o KNN, com o número de vizinhos k é igual a cinco, que é o intervalo para fazer a votação e fazer a classificação.

Figura 14- Ilustração do KNN



Fonte: Autoria própria

3 RESULTADOS

Para consolidar o programa computacional foram utilizados para teste um banco de dados de mãos, contendo cento e cinco (105) indivíduos e para cada um deles dez (10) imagens das mãos diferentes. O banco de dados contém essas amostras em dois espectros: RGB e infravermelho, sendo cinco de cada indivíduo em RGB e as outras cinco em infravermelho. Foram feitos testes utilizando as cinco imagens de cada indivíduo RGB. As imagens também foram passadas para tons de cinza (monocromática).

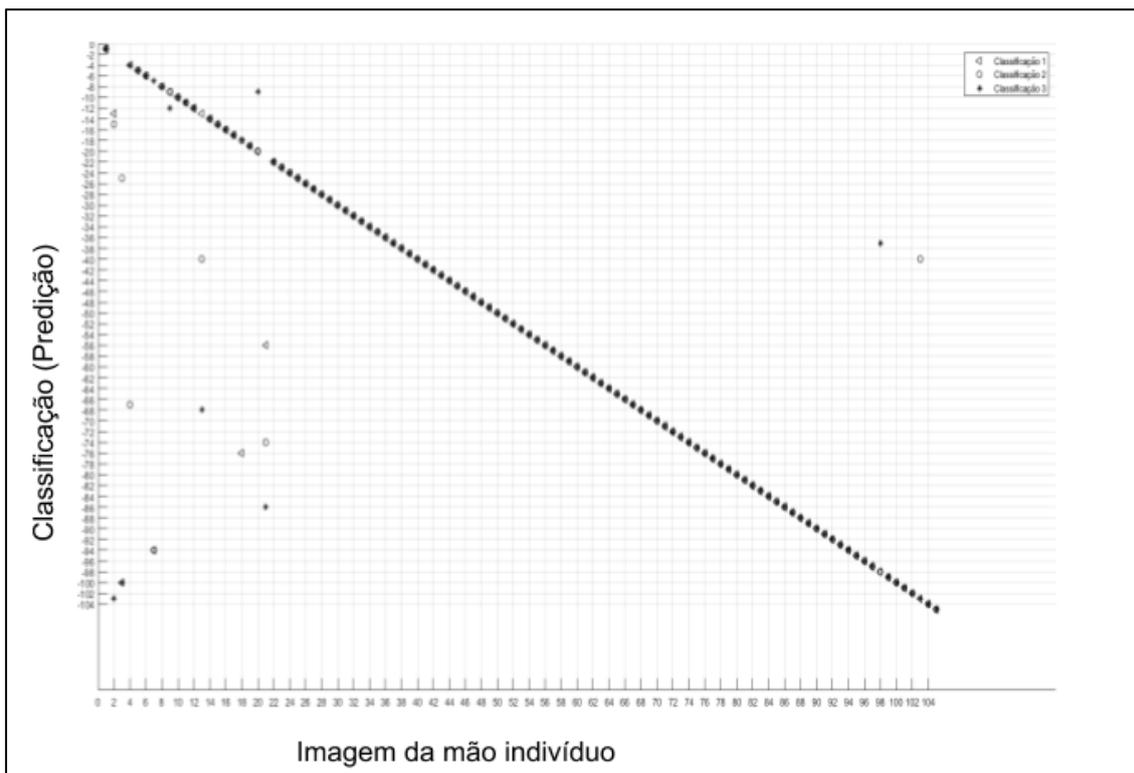
Foi implementado um programa que realiza o processo de identificação de indivíduos a partir de imagens utilizando o auxílio da PCA, seguindo o passo a passo descrito no referencial teórico, utilizando duas imagens da mão de cada indivíduo para treinamento e três para classificação para todos os testes.

Cada imagem da mão possui resolução igual a 1024x768, e a imagem é RGB que são três matrizes. Então, o número de células para o armazenamento da imagem deve ser multiplicado por três, totalizando 2.359.296 células.

Para o primeiro teste a imagem foi reduzida noventa por cento (95%) e mantida como RGB e o novo o número de células para armazenamento dessas imagens foi de 23793. Após essa redução e a montagem da PCA não foi descartada nenhuma componente para a classificação. O total de componentes é de 23793. Utilizando a distância euclidiana para a classificação a taxa de acerto obtida foi de 93,97%, com 315 imagens de teste com acerto 296 e de erro 19. A figura 9 mostra a relação de erros e acertos utilizando todas as componentes para a classificação.

Para o segundo teste cada imagem da mão foi reduzida noventa por cento do tamanho original e mantida como RGB. Após a redução da imagem e montagem da PCA, foram descartadas cerca de 23.693 componentes, que são os autovetores associados ao seu respectivo autovalor, ficando apenas com 100. Considerando o total de células de memória originais após a montagem da PCA, cerca de 566.106.849 (dimensão da imagem ao quadrado $(77*103*3)^2$), esse espaço foi reduzido para 100 componentes ficando com 2.379.300 células cerca de 0,42% dos dados originais. Com o processo de classificação, utilizando a distância euclidiana, a taxa de acerto obtida foi cerca de 93,97%. A quantidade total de imagens da mão para classificação foram de 315, tendo como acerto 296 e de erro 19, que é exatamente o mesmo resultado utilizando todas as componentes. A Figura 15 mostra a relação de acerto e erro do segundo teste. A diagonal principal indica as imagens da mão que corresponde aos indivíduos, o acerto é quando o símbolo está na diagonal principal e o erro quando está fora dela. O resultado da Figura 15 ilustra o resultado com todas as componentes e com cinco que é o mesmo.

Figura 15 - Relação de erros e acertos imagem RGB utilizando todas componentes

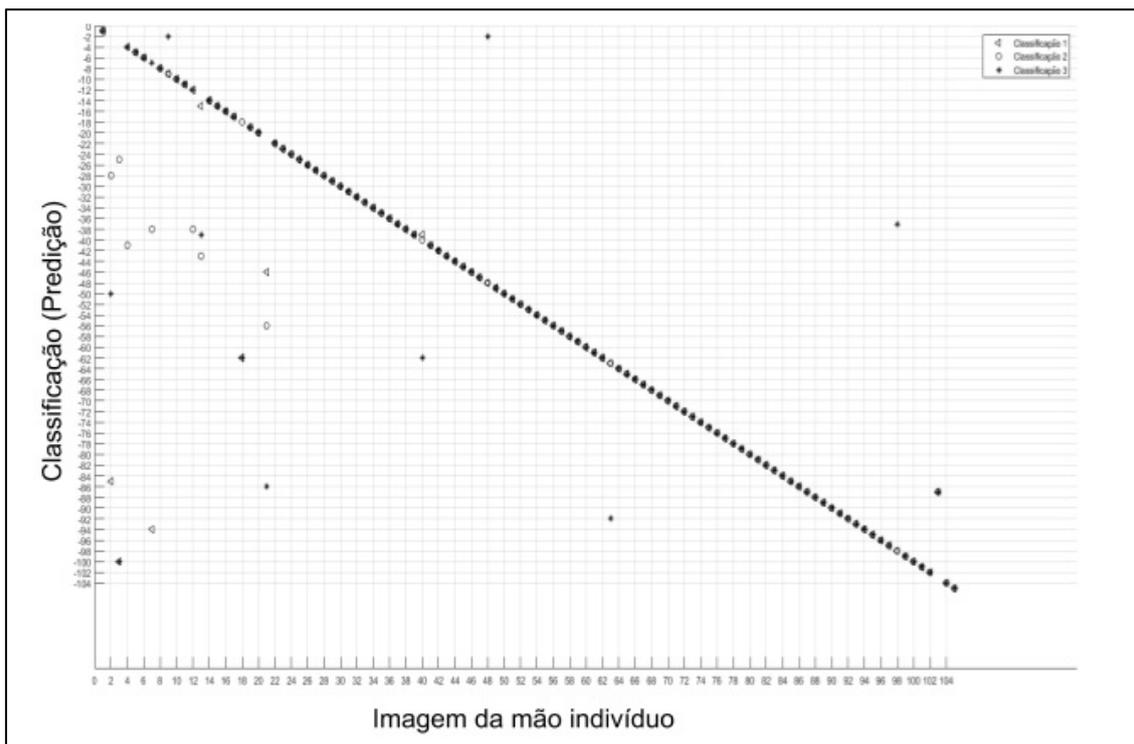


Fonte: Autoria própria

O indivíduo de número 13 (está entre 12 e 14 do eixo abcissa (imagem da mão indivíduo) a primeira classificação (símbolo de triângulo) está em cima da diagonal principal (coordenada (-13,13)) representando um acerto. A segunda classificação (símbolo de círculo) indica um erro, as coordenadas (13,-40) indicam que a imagem da mão do indivíduo 13 foi classificada como sendo a imagem da mão do indivíduo de número 40. A terceira (asterisco) indica que a imagem da mão indivíduo de número 13 é a da 68, também incorrendo em um erro.

O terceiro teste a redução da imagem foi de noventa por cento e utilizando a imagem RGB. depois da montagem da PCA foram descartadas 23788 componentes ficando com apenas cinco, isso é cerca de 0.022% de todas as componentes, ou seja, o espaço para armazenar as componentes para a análise é reduzido em cerca de 99,97%. Utilizando a distância euclidiana para a classificação obteve-se a taxa de acerto de 91,43%, com 315 imagens de teste com acerto 288 e de erro 27. A diferença da taxa de acerto em relação com a classificação de todas as componentes é de 2,54%. A Figura 16 mostra a relação de erros e acertos utilizando 5 componentes.

Figura 16 - Relação de erros e acertos imagem RGB utilizando cinco componentes

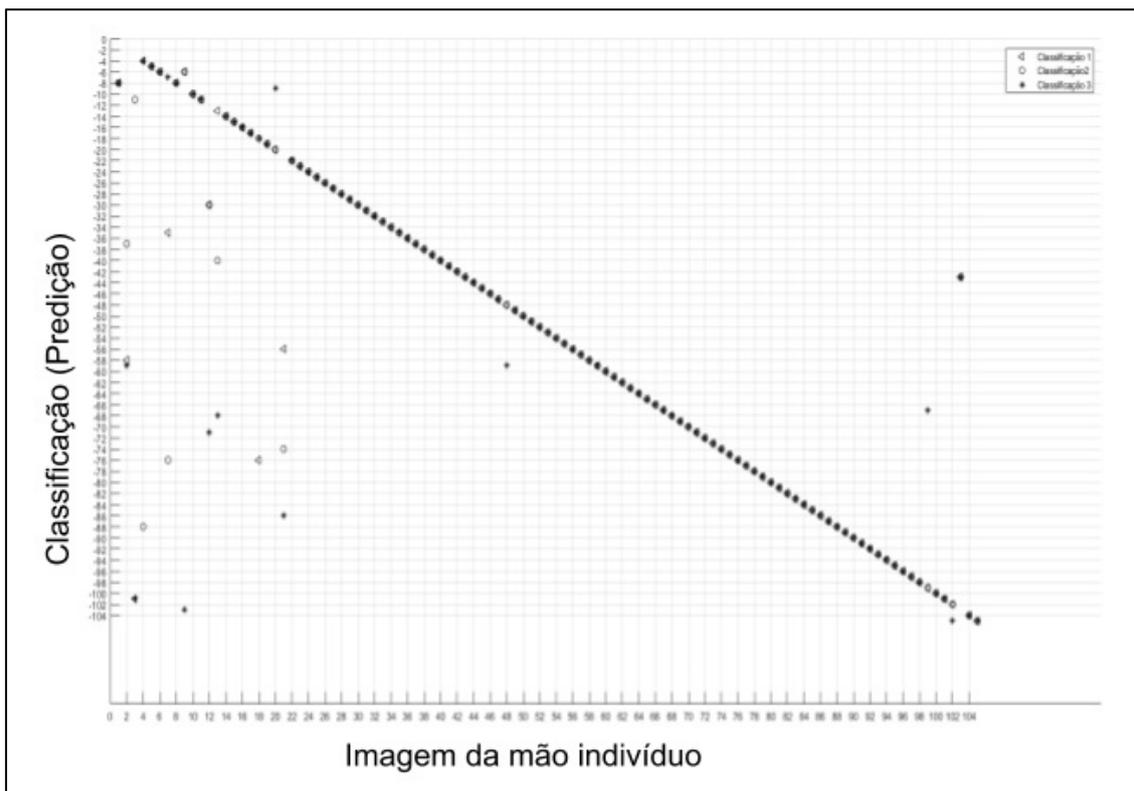


Fonte: Autoria própria

Para reduzir o número de células de armazenamentos é possível transformar as imagens RGB em escala de cinza.

O quarto teste transforma-se as imagens em escalas de cinza, ficando apenas com uma matriz ao invés das três do RGB, reduzindo o número de células de armazenamento é 7931(77x103) para cada imagem da mão. Realizando o mesmo processo de classificação com todas as componentes e distância euclidiana a taxa de acerto obtida foi de 90.16%, com 284 acertos e 31 erro. Em relação a classificação da imagem da mão RGB, o armazenamento das imagens em tons de cinza é de três vezes menor e a diferença da taxa de acerto é de 3.81%. Em relação as componentes RGB a quantidade em tons de cinza é cerca de 11,12%, uma redução de 88,88% dos dados. A Figura 17 ilustra a relação de erro e acerto, os símbolos na diagonal principal são os acertos e os fora dela são os erros. O eixo de classificação é a predição utilizando a distância euclidiana. A classificação da imagem da mão do indivíduo de número 12 não houve nenhum acerto, não há nenhum símbolo na coordenada (12,-12) em nenhuma das três classificações, e nesse caso as três classificações foram erradas.

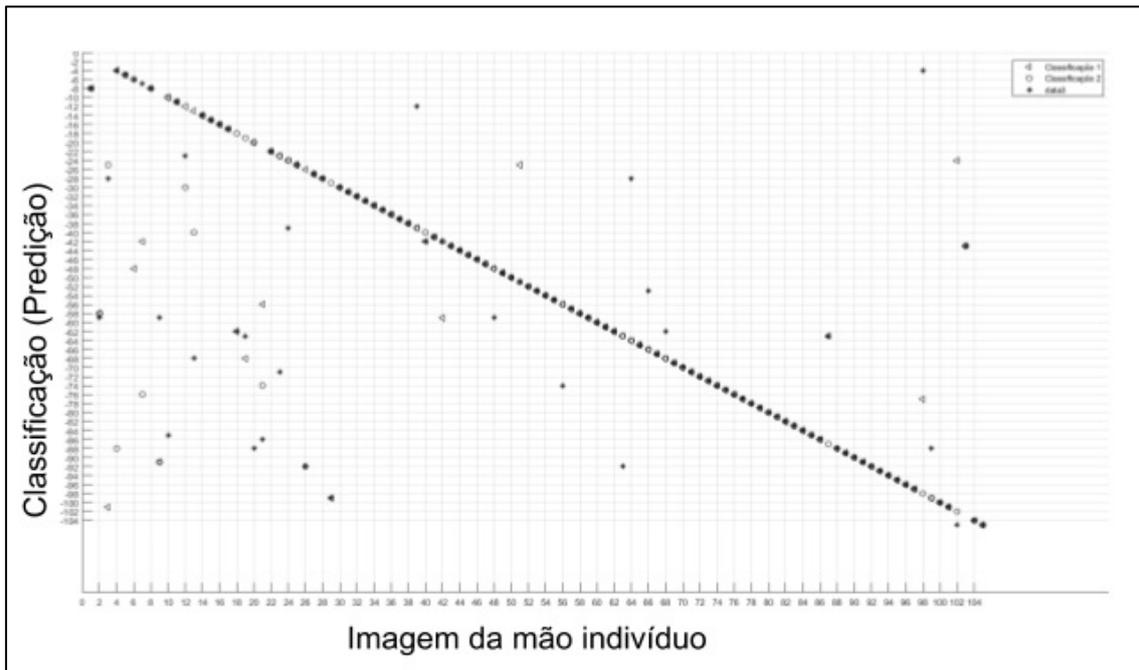
Figura 17 - Relação de erros e acerto com imagens em tons de cinza



Fonte: Autoria própria

O quinto teste reduz ainda mais a quantidade de células de armazenamento (dados), após a montagem da PCA, para a classificação utiliza-se cinco componentes que é 0.007% do espaço ocupado por todas as componentes. Utilizando a distância euclidiana como veredito da classificação, com 315 imagens da mão, a quantidade de acerto foi de 259 imagens e a de erro foi de 56. A porcentagem da taxa de acerto é de 82.22% e o módulo da diferença da taxa de acerto em relação a todas as componentes utilizando imagens de tons de cinza é de 9.96%. A Figura 18 ilustra a relação de acerto e erro da classificação.

Figura 18 - Relação de erros e acertos imagens tons de cinza utilizando cinco componentes



Fonte: Autoria própria

A Tabela 1 mostra a relação de erro, acerto e redução dos dados em relação a todas as componentes da imagem da mão em RGB de todos os testes. No segundo teste a redução dos dados em relação às componentes foi de 99,58% e a taxa de acerto é a mesma obtida utilizando todas as componentes.

Tabela 1 - Relação de todos os testes

Número do teste	Tipo da imagem	Quantidade de acertos	Quantidade de erros	Taxa de acerto	Quantidade de componentes	Taxa de redução dos dados
1°	RGB	296	19	93,97%	23793	0
2°	RGB	296	19	93,97%	100	99,58%
3°	RGB	288	27	91,43%	5	99,97%
4°	Tons de cinza	284	31	90,16%	7931	88,88%

5°	Tons de cinza	259	56	82,22%	5	99,99%
6°	RGB	296	19	93,97%	23793	0

O sexto e último teste, com a imagem da mão reduzida em noventa por cento e mantida como RGB, após a montagem da PCA e cálculo das distâncias euclidianas, utilizando todas as componentes, para tentar melhorar a classificação, utilizou-se o KNN com k igual a três (intervalo do vetor de distâncias). A taxa de acerto foi de 93,97%, o mesmo resultado utilizando apenas a distância euclidiana (pegando apenas a menor distância).

4 CONCLUSÃO

Este trabalho teve como objetivo a classificação de imagens multiespectrais (RGB) da palma da mão com o auxílio da PCA. Os resultados obtidos dos vários testes, comparando as imagens tanto em tons de cinza quanto RGB, demonstram que a PCA, para o problema em questão, além de conseguir diminuir uma grande quantidade de dados, através do descarte de alguns componentes, faz com que elimine dados não importantes para a análise (classificação).

Na realização deste plano de trabalho, como dificuldade encontrada pode ser citado a dimensões das imagens originais, para o cálculo das componentes (matriz de translação/autovetores) com a imagem resolução de 1024x768, com recursos utilizados nessa pesquisa, é impossível montar as componentes por falta de memória.

O objetivo foi atingido pois a classificação da imagem com o auxílio da PCA, conseguiu resultados satisfatórios, uma vez que a menor taxa de acerto foi acima de 80% com mais de 300 imagens para classificação, utilizando a distância euclidiana. Apesar do uso do KNN para tentar aumentar a acurácia da classificação, a distância euclidiana teve o mesmo resultado na classificação em imagens RGB.

4.1 TRABALHOS FUTUROS:

- Realizar um pré-processamento da imagem, com filtros para a retirada de ruídos e informações desnecessárias para a análise como o fundo da imagem e analisar apenas a parte da mão.
- Montar a PCA com a resolução da imagem original sem nenhuma redução.
- Paralelizar todo o processo de montagem da PCA, como cálculo da matriz de covariância e cálculo de autovalores e autovetores.
- Fazer a classificação com as imagens RGB, tons de cinza e monocromática, dessa forma utilizar uma quantidade maior de imagens para treinamento.
- Utilizar outros classificadores para suporte da distância euclidiana, fazendo uma hibridização para que a acurácia da classificação seja mais alta.

REFERÊNCIAS

ARAÚJO, W. O. **Análise de Componentes Principais (PCA)**. Anápolis: Centro Universitário de Anápolis, 2009.

BURGER, Wilhelm; BURGE, Mark J. **Digital Image Processing: An Algorithmic. Introduction Using Java**. 2. ed. London: Springer Verlag, 2016. 811 p. (18680941).

BISHOP, C. M. (2006). **Pattern recognition and machine learning (information science and statistics)** springer-verlag new york. Inc. Secaucus, NJ, USA.

COELHO, G., et al. **Análise de imagens microscópicas para a quantificação da infecção de macrófagos por Leishmania**. In: I JORNADA DE CIÊNCIA E TECNOLOGIA DA ECEC, 2016, Goiânia. Proceedings of the I JORNADA DE CIÊNCIA E TECNOLOGIA DA ECEC, Goiânia, v. 1, p. 1-6, 2016.

DUARTE, João Batista. **INTRODUÇÃO À ANÁLISE DE COMPONENTES PRINCIPAIS: (Com Aplicação do SAS ® - Statistical Analysis System)**. 1998. 23 f. Dissertação (Mestrado) - Curso de Agronomia, Universidade Federal de Goiás, Piracicaba, 1998.

DOUGHERTY, Geoff (Ed.). **Medical image processing: techniques and applications**. Springer Science & Business Média, 2011.

E. C. KITANI AND C. E. Thomaz. **"Um Tutorial sobre Análise de Componentes Principais para o Reconhecimento Automático de Faces"**. Technical Report 01/2006 (in portuguese), Department of Electrical Engineering, FEI, Sao Bernardo do Campo, São Paulo, Brazil, May 2006.

FELICIANO, Flávio F.; DE SOUZA, Igor L.; LETA, Fabiana Rodrigues. **Visão computacional aplicada à metrologia dimensional automatizada: considerações sobre sua exatidão**. Engevista, v. 7, n. 2, 2010.

GONZALEZ, Rafael C.; WOODS, **Richard E.** **Processamento Digital de Imagens. 3. ed.** São Paulo: Pearson, 2010.

GONZALES, Rafael C; WOODS, Richard E. **Digital Image Processing Using MATLAB.** 2. ed. New York: Gatesmark Publishing, 2009. 827 p.

GONZALES, Rafael C; WOODS, Richard E. **Digital Image Processing.** 3. ed. New York: Prentice Hall, 2007. 793 p.

GHOTRA, B., MCINTOSH, S., and Hassan, A. E. (2015). **Revisiting the impact of classification techniques on the performance of defect prediction models.** In Proceedings of the 37th International Conference on Software Engineering-Volume 1, pages 789–800. IEEE Press.

HAO, Y.; SUN, Z.; TAN, T. **Comparative studies on multispectral palm image fusion for biometrics.** Computer Vision–ACCV 2007, Tokyo: Springer, p. 12-21, 2007.

JENSEN, J. R. **Introductory Digital Image Processing: A Remote Sensing Perspective.** Univ. of South Carolina, Columbus, 1986

JAIN, A.; BOLLE, R.; PAKANTI, S. (Editor) **Biometrics: Personal Identification in Networked Society.** Springer Science & Business Media, 2006. 479 v., p. 1-20.

JOLLIFFE IT. **Principal component analysis.** New York: Springer-Verlag; 1986.

KLARE, B.; JAIN A. K. **Heterogeneous face recognition: Matching NIR to visible light images.** Pattern Recognition (ICPR), 2010 20th International Conference on. IEEE, p. 1513-1516, 2010.

LOPES, Luiz Gustavo Dias. **UMA CONTRIBUIÇÃO PARA ANÁLISE DE COMPONENTES PRINCIPAIS EM OTIMIZAÇÃO DE MÚLTIPLAS RESPOSTAS SOB CONDIÇÃO DE INCERTEZA.** 2011. 130 f. Dissertação (Mestrado) - Curso de Engenharia de Produção, Universidade Federal de Itajubá, Itajubá, Mg, 2011. Disponível em: <<https://saturno.unifei.edu.br/bim/0038226.pdf>>. Acesso em: 25 ago. 2020.

MITCHELL, T. M. (1997). **Machine learning**. 1997. Burr Ridge, IL: McGraw Hill, 45(37):870–877.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento digital de imagens**. Rio de Janeiro: Brasport Livros e Multimídia, 1999.

OLIVEIRA, Hygo Souza de. **Redes Neurais Convolucionais para Classificação de Expressões Faciais de Emoções**. Trabalho de Conclusão de Curso. Universidade Federal de Roraima, 2017.

SVÁ B, J. **Biometric methods in research**. 1973.

SANTO, Rafael do Espírito. **Principal Component Analysis applied to digital image compression**. Einstein, São Paulo, p.135-139, out. 2012.

SILVA, P. R. B., et al. **Classificação de Espécies de Pimentas Empregando Análise em Componentes Principais**. In: I JORNADA DE CIÊNCIA E TECNOLOGIA DA ECEC, 2016, Goiânia. Proceedings of the I JORNADA DE CIÊNCIA E TECNOLOGIA DA ECEC, Goiânia, v. 1, p. 1-6, 2016.

SILVA, P. R. B., et al. **Pré-Processamento de Imagens para a Classificação de Pimentas Empregando Análise em Componentes Principais**. In: I JORNADA DE CIÊNCIA E TECNOLOGIA DA ECEC, 2016, Goiânia. Proceedings of the I JORNADA DE CIÊNCIA E TECNOLOGIA DA ECEC, Goiânia, v. 1, p. 1-6, 2016.

SILVA, Alex Lima; CINTRA, Marcos Evandro. Reconhecimento de padrões faciais: Um estudo. In: **Encontro Nacional de Inteligência Artificial e Computacional, 2015, Proceedings ENIAC**. 2015. p. 224-231.

Apêndice A – Código fonte classificação imagem tons de cinza

1- MAIN

```

1  clear all
2  clc
3  close all
4  caminho = 'CaminhoImagens';
5  numero_de_ind = 40;
6  qtd_treino = 5;
7  ext_img = '.pgm';
8  matriz_dados = lerImagens(caminho,numero_de_ind,'',qtd_treino,ext_img);
9  [comp,auto_vetores,auto_valores] = montarPCA(normalizar(matriz_dados));
10 save('processamento');
11 %load('processamento');
12 mat_class = t_classificar(auto_vetores,comp);
13 [acerto,erro,percent] = taxaAcerto(mat_class);
14

```

2- LER IMAGENS

```

function
    imagensTreinamento = lerImagens(caminhoPasta , numeroInd, regioaoImagem,qtdTreino,extensaoImg)

    imagensTreinamento = []; %zeros(numeroInd*qtdTreino,1024*768); % cria uma matriz de zero
    contador = 1; % linha da matriz de amostra
    for i=1:numeroInd % numeroInd é o numero de individuos do banco de dados
        caminhoDaImagem = strcat(caminhoPasta ,'\..\ori_faces\'); %concatena o caminho para acessar
        caminhoDaImagem = strcat(caminhoDaImagem,'s',int2str(i));%acessar a pasta do individuo C:
        cd(caminhoDaImagem); % Ler as imagens da pasta
        for idImagem = 1:qtdTreino
            nomeDaImagem = strcat(regiaoImagem,int2str(idImagem),extensaoImg);%nome do arquivo da
            img = double(imread(nomeDaImagem));%ler a imagem e converter-la para double
            img = img(:)';%função que trasforma a imagem em vetor linha
            imagensTreinamento(contador,:) = img;% colocando as amostras do individuo na matriz de
            clear img ; % apagando o vetor linha para nao sobrecarregar a memoria
            contador = contador +1;% linha do proximo individuo
        end
    end
    cd(caminhoPasta);
end

```

3- MONTAR PCA

```

1 function [Pc,coeff,significancia] = montarPCA(matrizDados)
2 %% a matriz de dados já está normalizada
3 %%Montagem da matriz de covariancia
4 %Os dados cada linha representa uma amostra de um individuo
5 linhas = size(matrizDados,1); % quantidade de linhas da matriz de dados
6 % MatrizCov = matrizDados-repmat(mean(matrizDados),linhas,1); %subtrai p
7 MatrizCov = (matrizDados'*matrizDados)/(linhas-1); % matriz de covariâci
8 %%Calular auto valores da matriz de covariancia :
9 [Avetores,Avalores] = eig(MatrizCov); % matriz de auto vetores e matriz
10 Avalores=diag(Avalores); % pega somente a diagonal principal
11 soma = sum(Avalores); % soma dos autoValores
12 clear MatrizCov
13 [Avalores,indiceVet] = sort(Avalores,'descend');%Ordena de forma decrese
14 coeff = Avetores(:,indiceVet); % rearranja os autovetores pelos indices
15 % autoVetores = coef(:,1:0); % escolhe quantas componentes usar
16 % autoVetores = loadings
17 %%Representatividade dos dados de cada auto valor
18 significancia =(Avalores(:)/soma)*100; % calcula a porcentagem de cada a
19 clear Avetores Avalores;
20 %% PCS montadas
21 Pc = matrizDados*coeff;
22 end
23

```

4- CLASSIFICAR

```

1 function mat_class = t_classificar(auto_vetores,comp) % teste de classif
2 caminho ='G:\cassio\orl_faces\s';% caminho do teste para classificar
3 mat_class(40,5) = zeros();
4 for i = 1:40
5     caminho_testel = strcat(caminho,int2str(i)); %'G:\cassio\orl_faces\s
6     k=1;
7     for j =1:5 % quantidade de individuos para treinamento
8         caminho_teste = strcat(caminho_testel,'\',int2str(j),'.pgm');% c
9         trans_teste = lerImagemClassificar(caminho_teste,auto_vetores);
10        [p_ind,id_ind,indx] = distancia(comp,trans_teste);
11        p_ind=ceil(p_ind/5); % possivel individuo
12        mat_class(i,k)=p_ind;
13        k=k+1;
14    end
15 end
16
17 end

```

5 – TAXA DE ACERTO

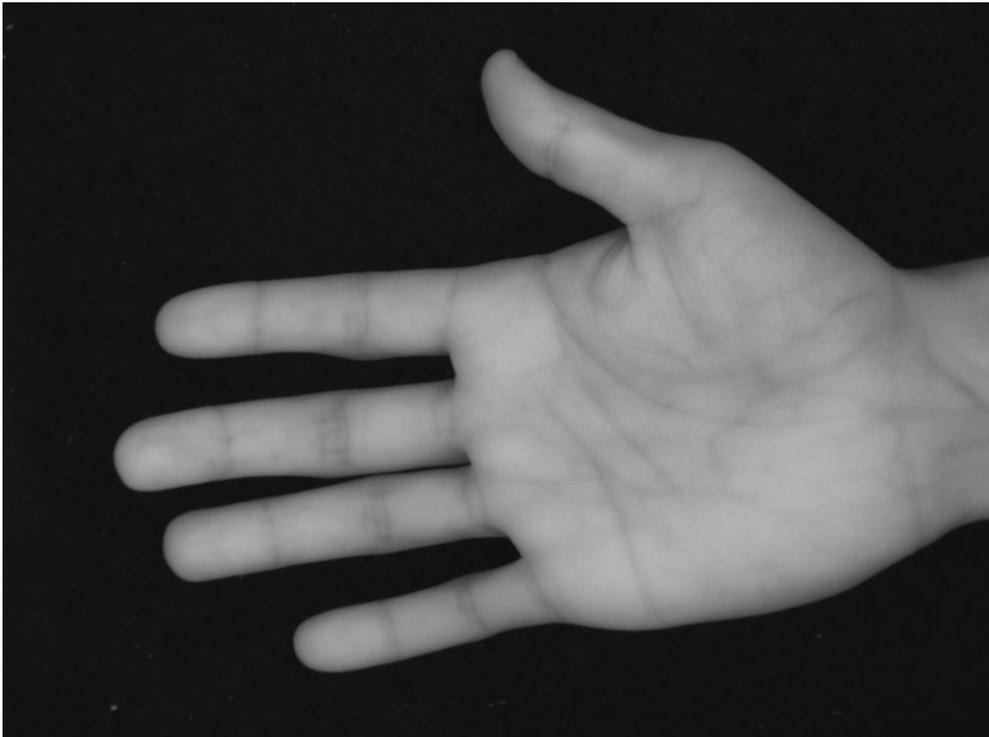
```
1 function [acerto,erro,percent] = taxaAcerto(matrizClass) % matrizClass:
2 [i,j] = size(matrizClass);
3 erro = 0;
4 acerto =0;
5 for linha=1:i
6     for coluna=1:j
7         if matrizClass(linha,coluna) == linha
8             acerto=acerto+1;
9         end
10        if matrizClass(linha,coluna) ~= linha
11            erro = erro+1;
12        end
13    end
14 end
15 percent = acerto/(i*j);
16 end
```

Apêndice B – AMOSTRAS DE IMAGENS UTILIZADAS

1- IMAGEM RGB



2- IMAGEM NIR





PONTIFÍCIA UNIVERSIDADE CATÓLICA DE GOIÁS
PRÓ-REITORIA DE GRADUAÇÃO

Av. Universitária, 1069 • Setor Universitário
Caixa Postal 86 • CEP 74605-010
Goiânia • Goiás • Brasil
Fone: (62) 3946.1021 | Fax: (62) 3946.1397
www.pucgoias.edu.br | prograd@pucgoias.edu.br

Termo de autorização de publicação de produção acadêmica

O estudante **WANDERSOM MOURA VIANA** do Curso de **Engenharia de Computação**, matrícula **2016.1.0033.0169-6**, telefone **(62) 9 9234-8822**, e-mail **wandersom.m.viana@gmail.com**, na qualidade de titular dos direitos autorais, em consonância com a Lei nº 9.610/98 (Lei dos Direitos do Autor), autoriza a Pontifícia Universidade Católica de Goiás (PUC Goiás) a disponibilizar o Trabalho de Conclusão de Curso intitulado **Classificação de Imagens Multiespectrais da Palma da Mão Utilizando Análise de Componentes Principais**, gratuitamente, sem ressarcimento dos direitos autorais, por 5 (cinco) anos, conforme permissões do documento, em meio eletrônico, na rede mundial de computadores, no formato especificado (Texto(PDF); Imagem (GIF ou JPEG); Som (WAVE, MPEG, AIFF, SND); Vídeo (MPEG, MWV, AVI, QT); outros), específicos da área para fins de leitura e/ou impressão pela internet, a título de divulgação da produção científica gerada nos cursos de graduação da PUC Goiás.

Goiânia, 03 de dezembro de 2020

Assinatura do autor:

Nome completo do autor:

Assinatura do professor – orientador:

Nome completo do professor – orientador:

Wandersom Moura Viana

Gustavo Siqueira Vinhal