



ISSN: 2230-9926

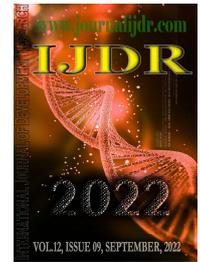
Available online at <http://www.journalijdr.com>

# IJDR

International Journal of Development Research

Vol. 12, Issue, 09, pp. 59061-59065, September, 2022

<https://doi.org/10.37118/ijdr.25417.09.2022>



RESEARCH ARTICLE

OPEN ACCESS

## RECONHECIMENTO DE IMAGENS UTILIZANDO SOMENTE CORRELAÇÃO ESTATÍSTICA E VIZINHOS MAIS PRÓXIMOS

\*Ernande F. Melo, Silvia Regina Freita and Raimundo Corrêa de Oliveira

Department of Computer Engineering, Amazonas State University, Manaus, Amazonas, Brasil

### ARTICLE INFO

#### Article History:

Received 10<sup>th</sup> August, 2022

Received in revised form

28<sup>th</sup> August, 2022

Accepted 09<sup>th</sup> September, 2022

Published online 30<sup>th</sup> September, 2022

#### Key Words:

Reconhecimento de imagens, Machine Learning, Vizinhos mais próximos, Correlação.

\*Corresponding author: Ernande F. Melo,

### ABSTRACT

Reconhecimento de Imagens é um tema recorrente na área de visão computacional. Passou por várias abordagens estatísticas como a Análise de Componentes Principais (PCA), e suas variantes. Atualmente incorpora elementos de Inteligência Artificial, mais especificamente, Machine Learning. De um modo geral o processo de reconhecimento tem uma fase de pré-processamento, com algoritmos explorando alguma característica da imagem, usando alguma ferramenta estatística, gerando uma base de dados de conhecimento, que na fase de reconhecimento é manipulada por algum algoritmo de Machine Learning. Neste artigo é proposto um processo para o reconhecimento de imagens onde a imagem é tratada como uma imagem composta de uma matriz de pixels sem nenhum outro parâmetro específico, o que torna o processo adaptável para o reconhecimento de uma grande variedade de tipos de imagens, desde imagens de faces até imagens de circuito impresso. Nesta abordagem são utilizadas ferramentas simples como vizinhos mais próximos e o conceito estatístico de Correlação.

Copyright © 2022, Ernande F. Melo et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

**Citation:** Ernande F. Melo, Silvia Regina Freita and Raimundo Corrêa de Oliveira. "Indicadores municipais no âmbito dos objetivos do desenvolvimento sustentável: um estudo do ods6 no contexto do sistema cantareira, em minas gerais", *International Journal of Development Research*, 12, (09), 59061-59065.

## INTRODUCTION

Atualmente, os algoritmos para o reconhecimento de imagens, seguem uma sequência de pré-processamento que envolve frequentemente a aplicação de filtros para a remoção de ruídos, normalização, extração de características com eventual aplicação de Análise de Componentes Principais (PCA) e suas variantes (TURK, 1991; KIRBY, 1990; SAMBROO, 2016 and MELO, 2010), em seguida a etapa de reconhecimento através do uso de métricas de distância geométrica distâncias Euclidiana (BASSEVILLE, 1989 and PREETI, 2019) e distância estatística de Mahalanobis (BASSEVILLE, 1989 and PREETI, 2019). Técnicas de Inteligência Artificial (IA) e mais especificamente Machine Learning (ML) foram incorporadas ao processo de reconhecimento, complementando ou substituindo as técnicas existentes, tais como o PCA e suas variantes (TURK, 1991; KIRBY, 1990; SAMBROO, 2016). As bases de dados de imagens frequentemente utilizadas para avaliar o desempenho destes sistemas de reconhecimento são: base da AT&T (AT & T. Laboratories Cambridge, 2022), para reconhecimento de faces, bases DBn-A e DBn-B da FVC 2006 (FVC, 2002) para o reconhecimento de impressão digital (MELO, 2010) e base Caltech (CALTECH, 2002) para reconhecimento de imagens diversas em especial de rostos com plano de fundos diferentes, entre outras. Este artigo apresenta uma proposta de algoritmo que não faz a extração de características

específicas da imagem, ou seja, trata uma imagem como imagem. A vantagem desta abordagem é o aproveitamento do mesmo processo em diversos tipos de problemas de reconhecimento de imagens, seja em biometria, imagens médicas, detecção de defeitos em placas de circuitos, reconhecimento de voz, entre outros. Além disso, diferente de outras abordagens mais recentes de IA (WILSON, 1993; MICHALSKI, 2013; KOTISIA99TIS, 2007), Deep Learning em redes neurais profundas (DNN) (CHOLLET, 2018; LeCun, 2015), neste trabalho são utilizados apenas os conceitos de Correlação (AJzenman, 2008) e Machine Learning (HUANG, 2011; GÉRON, 2017 and KOTSIANTIS, 2007) mais especificamente o algoritmo KNN (HU, 2016; Documentação do Scikit Learn, 2002; Portal Data Science, 2022), ou seja ferramentas mais simples e bem conhecidas em problemas de classificação. Na Seção II, são mostrados os Materiais e métodos onde são descritos os componentes e conceitos que compõem o ambiente necessários para desenvolvimento e implementação do sistema de reconhecimento. Na Seção III são apresentadas as análises dos resultados da implementação. Seção IV as discussões e na Seção V os agradecimentos.

## MATERIALS AND METHODS

Nesta seção são descritos os componentes e conceitos que compõem o ambiente de desenvolvimento do sistema, constituído basicamente

por um módulo de correlação estatística, e o algoritmo de vizinhos mais próximos(KNN) de Machine Learning, uma base de Imagens e as métricas de reconhecimento e de desempenho

**Correlação:** O termo correlação significa relação em dois sentidos e é usado em estatística para designar o grau da relação linear entre dois conjuntos (X, Y). A correlação será tanto mais forte quanto mais próximo estiver o coeficiente de 1, e será tanto mais fraca quanto mais próximo o coeficiente estiver de zero. Fazemos então a classificação de uma imagem pela avaliação do do coeficiente de correlação. Para o cálculo do coeficiente de correlação, utilizamos o coeficiente de correlação inear de Pearson (r) que é dado pela Equação 1. (AJIzenman, 2008).

$$r = \frac{S_{xy}}{S_x S_y} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad \text{Eq. (1)}$$

Onde:  $S_{xy}$  é a covariância;

$S_x$  e  $S_y$  representam o desvio padrão, respectivamente, das variáveis x e y

Para dados brutos (sem covariância ou desvio padrão) o coeficiente de correlação de Pearson (r) é dado pela Equação 2.

$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \quad \text{Eq.(2)}$$

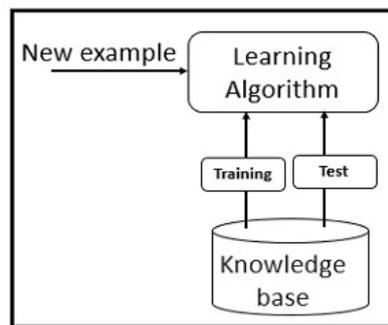
Uma estimativa para classificação do grau de correlação, depende do problema abordado, mas de um modo geral, pode ser classificada conforme descrito na Tabela 1.

**Tabela 1. Estimativa para classificação do grau de correlação**

Grau de correlação (valor Absoluto)	Classificação
0,9 -1,0	muito forte
0,7 - 0,9	Forte
0,5 - 0,7	Moderada
0,3 - 0,5	Fraca
0,0 - 0,3	muito fraca

No contexto deste trabalho X é o conjunto de pixels de uma imagem vetorizada a ser classificada a partir da medida da correlação com as imagens Y também vetorizadas da base de conhecimento. Calculamos a correlação (X, Y1), (X, Y2.), ... (X, Yn.). A maior correlação é candidata a classificar X, como próximo a imagem Yn, com uma chance de 98% de acerto como veremos na seção II.5

**Machine Learning:** A Figura 1 mostra o esquema de uma Machine Learning (ML), que consiste basicamente em uma base de conhecimento e um algoritmo de aprendizado. Os dados são estruturados em atributos e ,no caso de aprendizado supervisionado, uma classe para cada conjunto de atributos (HUANG, 2011; GÉRON, 2017 and KOTSIANTIS, 2007). No caso de dados de imagens cada conjunto de atributos (pixels) classificam uma imagem. Uma parte desses dados é usada para treinar o algoritmo de aprendizado, enquanto outra parte é usada para testar e avaliar o desempenho da ML. Quanto mais dados usados para treinar a ML, melhor é seu desempenho ou taxa de acertos no processo de reconhecimento. Entre os algoritmos de aprendizaem, os mais populares na literatura são:: KNN, DT3, SVM e RNA (HUANG, 2011 and GÉRON, 2017). Neste trabalho utilizamos o algoritmo KNN (HU, 2016; Documentação do Scikit Learn, 2012 and Portal Data Science, 2022), por sua simplicidade e por implementar métrica de menor distancia euclidiana que combinada com a correlação, resulta no moelo proposto neste artigo (BASSEVILLE, 1989 and PREETI, 2019).

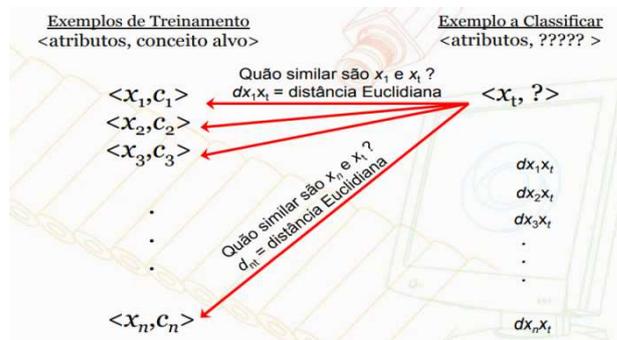


**Figura 1. Representação esquemática de uma ML que é composto por uma base de conhecimento com um conjunto de dados (para treinamento) e outro conjunto para testes, além de um algoritmo de aprendizado**

**Algoritmo KNN:** O KNN (*K-Nearest Neighbors* (*K-Vizinhos Mais Próximos*)) (HU, 2016; Documentação do Scikit Learn, 2022 and Portal Data Science, 2022) é um algoritmo que classifica as entradas através de um método de predição que utiliza a distância entre a entrada atual e seus k vizinhos mais próximos no conjunto de treinamento para definir qual será o resultado de sua predição e consequente classificação. Estas medidas de distância podem ser: distância Euclidiana, de Manhatta e de Minkowski (BASSEVILLE, 1989 and PREETI, 2019). Podemos definir estas métricas da seguinte forma: Dados dois vetores  $X=(X_1, X_2, X_3, \dots, X_n)$  e  $Y=(Y_1, Y_2, Y_3, \dots, Y_n)$  a distância de Minkowski é definida como:

$$D(X, Y) = \left( \sum_{i=1}^n |x_i - y_i|^p \right)^{1/p} \quad \text{Eq.(3)}$$

Se  $p=1$  a distância é euclidiana, se  $p=2$  é Manhattan. Com o número de vizinhos mais próximos escolhidos, o KNN calcula a distância da nova instância com os dados de treinamento, e reúne as k instâncias mais próximas. A figura 2 ilustra o funcionamento do KNN.



**Figura 2: Classificação baseada em menor vetor distância**

**Estrutura das bases de imagens:** Bases de imagens estruturadas são utilizadas para avaliação de desempenho dos algoritmos de classificação., dentre as quais é utilizada neste trabalho o Att\_faces que contém um conjunto de imagens de faces, tiradas entre abril de 1992 e abril de 1994 no Olivetti Research Laboratory (ORL) em Cambridge, Reino Unido. Existem 10 imagens diferentes do mesmo indivíduo com 40 indivíduos distintos, totalizando 400 imagens. Para os indivíduos, as imagens foram tiradas em momentos diferentes, variando a iluminação, expressões faciais (olhos abertos / fechados, sorrindo / não sorrindo) e detalhes faciais (óculos / sem óculos). Todas as imagens são tiradas contra um fundo escuro e homogêneo e os motivos estão posição frontal direita (com tolerância a algum movimento lateral). Os arquivos estão no formato PGM. O tamanho de cada imagem é 92x112, níveis de cinza de 8 bits. As imagens são organizadas em 40 pastas, uma para cada indivíduo. A Figura 3 mostra um exemplo de imagens destas bases.

# METHODS

Nesta seção são descritos os métodos aplicados no desenvolvimento do sistema de reconhecimento de imagens.

## Montagem da base de conhecimento da ML

- 1) Cada conjunto de imagens do mesmo individuo ou objeto é alocada em uma pasta numerada;
- 2) É construído um classificador tal que as pastas representam uma class e cada imagem na pasta recebe a classificação da pasta.
- 3) Esta estrutura organizacional de classificação por pasta e, imagem na pasta, permite a aplicação de algoritmos de aprendizagem com treinamento supervisionado.
- 4) A Tabela II mostra a representação da base Att\_faces com 3 pastas e 5 imagens em cada pasta.



Figura 3 -Exemplo da imagens da base Att\_faces do Olivetti Research Laboratory em Cambridge, Reino Unido

Neste caso, na pasta 1, cada imagem recebe o rótulo 1 e assim sucessivamente, gerando o dataframe mostrado na Tabela II, onde cada linha representa uma imagem e cada conjunto de uma mesma imagem está alocado na pasta com classificação indicada na coluna kclass.

- 5) O algoritmo de ML treina, testa e depois o seu desempenho é medido em relação aos erros e acertos na predição;

Tabela II- Dataframe de uma base de conhecimento att\_faces. Cada linha representa os atributos (pixels) de uma imagem vetorizada com sua classificação dada pelo número da pasta contém as imagens. Por exemplo as imagens de 0 a 4 são do individuo que está na pasta 1 e assim sucessivamente

Image	px0	px1	px2	px3	px4	...	px10300	px10301	px10302	px10303	kclass
0	47.0	49.0	46.0	45.0	47.0	...	46.0	46.0	46.0	46.0	1.0
1	60.0	62.0	61.0	58.0	54.0	...	34.0	33.0	34.0	33.0	1.0
2	40.0	43.0	50.0	49.0	42.0	...	29.0	28.0	27.0	29.0	1.0
3	62.0	54.0	42.0	35.0	36.0	...	75.0	27.0	13.0	25.0	1.0
4	63.0	71.0	75.0	68.0	52.0	...	36.0	36.0	37.0	40.0	1.0
5	35.0	36.0	37.0	37.0	36.0	...	122.0	128.0	128.0	124.0	2.0
6	37.0	35.0	35.0	36.0	37.0	...	26.0	27.0	28.0	28.0	2.0
7	30.0	36.0	35.0	34.0	34.0	...	26.0	26.0	28.0	31.0	2.0
8	34.0	35.0	35.0	36.0	36.0	...	28.0	28.0	25.0	25.0	2.0
9	35.0	32.0	34.0	34.0	33.0	...	25.0	26.0	28.0	29.0	2.0
10	103.0	105.0	105.0	105.0	107.0	...	42.0	42.0	39.0	43.0	3.0
11	101.0	99.0	104.0	105.0	101.0	...	44.0	43.0	43.0	44.0	3.0
12	101.0	104.0	103.0	103.0	104.0	...	43.0	47.0	48.0	45.0	3.0
13	104.0	103.0	105.0	106.0	104.0	...	42.0	38.0	36.0	38.0	3.0
14	101.0	103.0	104.0	103.0	102.0	...	44.0	44.0	45.0	43.0	3.0

**Hipótese:** A experiência mostra que fazer reconhecimento baseado em valor de pixel não é uma boa estratégia, para reconhecimento de imagem, uma vez que os valores dos pixels variam muito com as condições de iluminação do ambiente. Mas nossa Hipótese é de que os pixels ou suas variações das imagens de um mesmo objeto mantém uma correlação forte, e correlação fraca para objetos diferentes. Ou seja, dada uma imagem  $ImgX$ ,

$$ImgX = \begin{pmatrix} px11 & px12 & px13 & \dots & px1n \\ px21 & px22 & px23 & \dots & px2n \\ \dots & \dots & \dots & \dots & \dots \\ pxM1 & pxM2 & pxM3 & \dots & pxMn \end{pmatrix}$$

A matriz de variação dos pixels desta imagem  $Imgdx$  é:

$$Imgdx = \begin{pmatrix} px11 - px12 & px12 - px13 & px13 - px14 & \dots & px1(n-1) - px1n \\ px21 - px22 & px22 - px23 & px23 - px24 & \dots & px2(n-1) - px2n \\ \dots & \dots & \dots & \dots & \dots \\ pxM1 - pxM2 & pxM2 - pxM3 & pxM3 - pxM4 & \dots & pxM(N-1) - pxMn \end{pmatrix}$$

Dada um outro conjunto de imagens  $ImgY1, ImgY2, \dots, ImgYn$  e suas variações  $ImgdY1, ImgdY2, \dots, ImgdYn$ , vetorizando. Medindo o grau de correlação entre os pares  $(ImgX, ImgY1), (ImgX, ImgY2), \dots, (ImgX, ImgYn)$  ou das variações de pixels, a máxima correlação ocorre quando as imagens são do mesmo individuo ou objeto. Após o cálculo da correlação, são selecionadas as cinco pastas com maior correlação, de modo a formarem um novo data frame, no qual é aplicado o KNN para encontrar o vizinho mais próximo da imagem  $ImgX$ . Em seguida os resultados da correlação e do vizinho mais próximo devem ser iguais ou complementares. A Figura 4, mostra o fluxograma do sistema proposto, baseado na hipótese formulada.

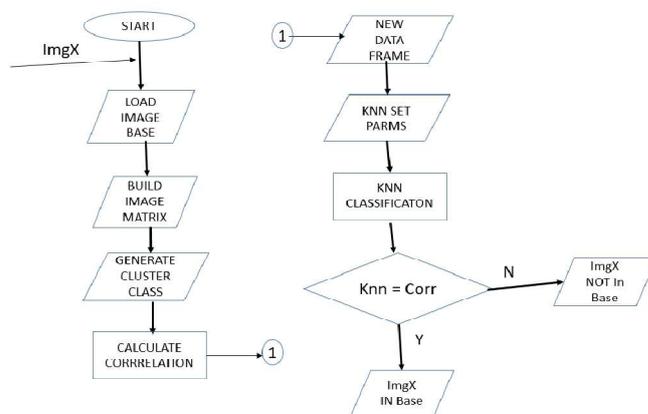


Figura 4. Fluxograma do Sistema de Reconhecimento proposto. Inicialmente é feita a leitura das Imagens da base  $ImgYn$  e da imagem de teste  $ImgX$ , m seguida a geração do data frame, a vetorização de  $ImgX$ , o cálculo da correlação  $(ImgX, ImgYn)$ , Em seguida são selecionadas as 5 pasta com maior correlação, gerando um novo data frame no qual é aplicado o KNN, Por fim a classe obtida pelo' KNN é comparada com os valores obtidos no cálculo da correlação

**Medida de desempenho:** Para medir o desempenho do sistema de reconhecimento, são utilizadas as métricas confusion matrix [23] [24] (da biblioteca sklearn). A Figura 5 mostra um esboço da confusão-matrix, no contexto deste artigo. Observa-se que os elementos da diagonal principal representam as respostas corretas na classificação, verdadeiro positivo (tp) está na base e a predição está correta e, verdadeiro negativo (tn) não está na base e a predição está correta., enquanto os demais elementos da matriz mostram a quantidade de erros de classificação falso positivo(fp) e falso negativo(fn). O desempenho (P) é calculado por  $P = (tp+tn)/(tp+tn+fp+fn)$

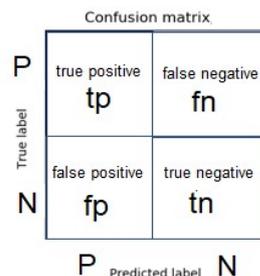


Figure 5 Structure of a confusion matrix. The elements in the main diagonal represent the correct answers in classification (true positive) while the other elements of the matrix give the amount of classification errors (false). The performance (P) is  $P = (tp+tn)/(tp+tn+fp+fn)$

**Experiments:** O objetivo dos experimentos é responder a seguinte questão: dada uma base de imagens, distribuídas em pastas e, uma imagem de teste, determinar se a imagem de teste está na base e mais especificamente, em que pasta, aplicando a Hipótese proposta. Para responder esta questão avaliamos dois cenários com a base Att\_faces do Olivetti Research Laboratory em Cambridge, Reino Unido. Cenário 1: sendo 40 pastas com 10 imagens em cada pasta, o dataframe que representa a base é formado pelas 7 primeiras imagens de cada pasta 7 x 40 totalizando 280 imagens na base. As outras 3 x 40 imagens, totalizando 120 vão para o modo de teste. O desempenho é mostrado na confusion\_matrix, Figura 6. Desempenho=  $(118+0)/(118+0+0+2)=95\%$

	P	N	
True label	P	118	2
	N	0	0
			Predicted label
			P
			N

**Figura 6. Confusion Matrix. Mostra o desempenho para o Cenário1  $(114+0)/(114+0+0+6)=95\%$**

Cenário 2 Este cenário é semelhante ao cenário 1, exceto pelo fato de que utilizamos a variação de pixel. O desempenho foi de 91%

#### Development Environment

Os experimentos foram desenvolvidos: no seguinte ambiente

Hardware: Note Book AVELL, 4 GB, 2.5 GHz, 64-bit

Framework Spyder3, Python 3.7.3, libraries numpy, pandas 1.16.4, scipy.org sklearn-0.21.2, , scikit-learn.org.

## RESULTS

Os experimentos confirmaram nossa hipótese de uma solução leve, simples, rápida e facilmente implementável para o problema de reconhecimento de imagens. É possível obter um desempenho muito maior para bases com melhor qualidade de imagens, pré-processamento com aplicação de filtros para a eliminação de ruídos, ou, para uma base bem comportada, deixar o usuário decidir visualmente, ou seja, dependendo da aplicação, o sistema pode exibir um conjunto das três ou cinco imagens com maior correlação e deixar o usuário decidir pelo reconhecimento. Também foi observado que a abordagem pela variação de pixels das imagens, não apresentou um desempenho melhor.

## DISCUSSIONS

A proposta deste artigo é descrever um sistema de reconhecimento de imagens utilizando ferramentas, bem conhecidas, a Correlação Estatística e Vizinhos mais próximo os. A base de conhecimento não requer muitos elementos, uma vez que o KNN não utiliza a noção de aprendizagem por indução e a Correlação Estatística também não requer uma base com muitos elementos uma vez que, neste caso trabalha com a largura e não com a profundidade do data frame, além de fazer cálculo aos pares de tuplas. Outro aspecto a ser considerado é a capacidade deste sistema de se adaptar a diversos tipos de imagens. Seja imagem de faces, impressão digital, médicas, entre outras, a estrutura do sistema de reconhecimento se mantém, com a base organizada em pastas e imagens nas pastas, a redução do problema em determinar se uma imagem pertence a um conjunto de imagens

em uma pasta. Esta é a estrutura do sistema proposto Há muito espaço para melhorias nesta abordagem.

**Acknowledgements:** Os resultados apresentados nesta publicação foram obtidos por meio das atividades de Pesquisa e Desenvolvimento realizadas no Projeto TecToy Finances, com recursos da Lei nº. 8.387/1991, devendo qualquer publicidade referir-se à referida lei de acordo com o art. 48 do Decreto 6.008/2006, tendo a empresa Tec Toy S.A financiado este Projeto nos termos da referida lei.

## REFERENCES

- AJzenman, Modern Multivariate Statistical Techniques. Springer, 2008. [8] MAGALHÃES, MN [16] LIMA, A. Notions of Probability and Statistics. São Paulo. Edusp. 7a. ed. 2015
- AT & T. Laboratories Cambridge. The Database of Faces. Available Online at <http://camorl.co.uk/facedatabase.html>. Visitado em: 06/07/2022.
- BASSEVILLE, M, Distance Measures for Signal Processing and Pattern Recognition, *Signal Processing*, vol. 18, N.4, pp.349-369, 1989.
- CALTECH. Available Online at [https://www.researchgate.net/figure/Figura-4-Exemplo-de-objetos-das-classes-da-base-de-dados-Caltech-101\\_fig4\\_312491975](https://www.researchgate.net/figure/Figura-4-Exemplo-de-objetos-das-classes-da-base-de-dados-Caltech-101_fig4_312491975). Visitado em: 10/07/2022.
- CHOLLET, François. Deep Learning with Python. Manning Publications Co. 2018.
- Documentação do Scikit Learn – KNeighborsClassifier. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html>. Visitado em 10/08/2022.
- FVC2006. Available Online at <http://bias.csr.unibo.it/fvc2006/download.asp>. Visitado em: 07/07/2022.
- GÉRON, Aurélien. Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems. O'Reilly Media, Inc., 2017
- HU, Li-Yu et al. The distance function effect on k-nearest neighbor classification for medical datasets. SpringerPlus, v. 5, n. 1, p. 1304, 2016.
- HUANG, G.B.; Wang, D. H.; Lan, Y. Extreme learning machines: a survey. International Journal of Machine Learning and Cybernetics, Springer, volume 2, n.2, p. 107–122, 2011.
- KIRBY, M. and Sirovich, L. Application of the Karhunen-Loève Procedure for the Characterization of Human Faces, IEEE PAMI, vol. 12, pp. 103-108, 1990.
- KOTISIA99TIS S.B. Supervised machine learning: A review of classification techniques. Emerging Artificial Intelligence. Applications in Computer Engineering. IOS Press Amsterdam, The Netherlands.2007.
- KOTSIANTIS, Sotiris B.; ZAHARAKIS, I.; PINTELAS, P. Supervised machine learning: A review of classification techniques. 2007.
- MELO, Ernande F., Oliveira, Hélio M. A Fingerprint-based Access Control using Principal Component Analysis and Edge Detection. IEEE/SBrT International Telecommunication Symposium, ITS 2010. 2010
- MICHALSKI, Ryszard S., Jaime G. Carbonell, and Tom M. Mitchell, eds. Machine learning: An artificial intelligence approach. Springer Science & Business Media, 2013.
- Portal Data Science. Disponível em: <https://portaldatascience.com/o-algoritmo-k-nearest-neighbors-knn-em-machine-learning/>. Visitado em: 10/08/2022.
- PREETI, Kumar D. Effect of Various Distance Classifiers on the Performance of Bat and CS-Based Face Recognition System. Harmony Search and Nature Inspired Optimization Algorithms pp 1209-122. 2019.
- REVSTAT: Statistical Journal.Metrics and scoring: quantifying the quality of predictions. Overview. Volume 12. Number 1. March, 1–20, 2014.
- RUUSKA, Salla et alli. Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. Behavioural Processes Volume 148, March 2018, Pages 56-62. Elsevier.

SAMBROO, Thomas D. and Goslin, Jeremy. Principal components analysis of reward prediction errors in a reinforcement learning task. *NeuroImage*, Volume 124. Part A, 1 January 2016, Pages 276-286

TURK, M. and Pentland, A. Eigenfaces for Recognition, *Journal of Cognitive Neuroscience*, vol.3, N.1, pp.71-86, 1991.

WILSON, C. Candela, G. Watson, C. Neural Network Fingerprint Classification, *J. Artificial Neural Networks*, vol.1, N.2, pp.1-25, 1993.

Y. LeCun, Y. Bengio, G. Hinton. Deep Learning. *Nature* 521(7), 436-444. 2015.

\*\*\*\*\*