



Pesquisa e Tecnologia na (pós) Pandemia

11, 12 e 13 de maio de 2022 – Presidente Prudente - SP

O USO DA FERRAMENTA *CUSTOM VISION* NO RECONHECIMENTO DE ÍRIS

Eixo Temático: Informação e Comunicação

**Wallison Freitas Cheli, Mariana Santos de Jesus, Aparecida Maria Zem Lopes,
Maria das Graças J. M. Tomazela, Adriane Cavichioli**

Resumo: A utilização de reconhecimento de íris no desenvolvimento de sistemas biométricos tem alcançado grande destaque em virtude de sua confiabilidade. Diversas técnicas e algoritmos foram desenvolvidos ao longo dos últimos anos, apresentando bons resultados. Técnicas tais como as Redes Neurais Convolucionais (abordagem que utiliza *deep learning*) têm alcançado ganhos significativos em desempenho nesse tipo de aplicação. Neste trabalho, propõe-se utilizar a ferramenta de Visão Personalizada do Azure para realizar a tarefa de reconhecimento de imagens de íris. Para isso, foi selecionada uma parte da base de imagens UBIRIS.v2, pré-processada para adequação às especificações da ferramenta. As imagens selecionadas foram divididas em dois conjuntos, um com imagens para treinar o modelo e outro para testes no modelo treinado. Depois, o algoritmo foi executado utilizando as imagens do conjunto de treinamento, e as do conjunto de teste foram submetidas ao modelo treinado para verificar sua acurácia. No Experimento 1, foram utilizadas imagens de 10 indivíduos (com imagens do olho esquerdo e direito), sendo selecionadas 80% das imagens para o conjunto de treinamento e 20% para o conjunto de teste. No Experimento 2, também foram selecionados 10 indivíduos e o modelo foi treinado com imagens apenas do olho direito e parte das imagens do olho esquerdo foram selecionadas para o conjunto de teste. O modelo obteve acurácia de 97,91% no Experimento 1 e 86,66% no Experimento 2, para as imagens do conjunto de teste. Estes valores foram considerados adequados para o estudo e confirmaram a eficácia da ferramenta *Custom Vision* nesta tarefa.

Palavras-chave: Redes Neurais Artificiais. Sistemas Biométricos. Inteligência Artificial. Aprendizado de Máquina.

THE USE OF THE CUSTOM VISION TOOL IN IRIS RECOGNITION

Abstract: The use of iris recognition in the development of biometric systems has achieved great prominence due to its reliability. Several techniques and algorithms have been developed over the last few years, with reliable results. Techniques such as Convolutional Neural Networks (an approach that uses deep learning) have achieved significant performance gains in this type of application. In this work, it is proposed to use the Azure Custom Vision Tools to perform the task of recognizing iris images. For this, a part of the UBIRIS.v2 image base was selected, pre-processed to suit the tool's specifications. The selected images were divided into two sets, one with images for training the model and another for testing the trained model. Afterwards, the algorithm was executed using the training set images, and the test set images were submitted to the trained model to verify its accuracy. In Experiment 1, images of 10 individuals were used (with images of the left and right eye), 80% of the images were selected for the training set and 20% for the test set. In Experiment 2, 10 subjects were also selected and the model was trained with images from the right eye only and part of the images from the left eye were selected for the test set. The model obtained an accuracy of 97.91% in Experiment 1 and 86.66% in Experiment 2, for the images of the test set. These values were considered adequate for the study and confirmed the effectiveness of the Custom Vision Tools in this task.

Keywords: Artificial Neural Networks. Biometric Systems. Artificial Intelligence. Machine Learning.

1 INTRODUÇÃO

O aprendizado de máquina (*machine learning*) é uma subárea da inteligência artificial (IA) voltada ao desenvolvimento de técnicas que permitam ao computador aprender com base em dados, identificação de padrões e tomada de decisões com o mínimo de intervenção humana (RICH e KNIGHT, 1991).

Uma maneira de treinar um computador para imitar o raciocínio humano é uma rede neural artificial (RNA), que modela o funcionamento do cérebro humano. Em meados dos anos 2000, aconteceu um crescimento exponencial do poder computacional e do volume de dados, levando os modelos de RNA a evoluírem e serem utilizados para representar problemas cada vez mais complexos (DATA SCIENCE ACADEMY, 2020).

Atualmente existem diversas arquiteturas de RNA, entre elas a *perceptron* multicamadas que é uma das mais utilizadas. Essa arquitetura é variável, mas em geral consiste em várias camadas de neurônios. Sendo uma camada de entrada, uma ou mais camadas ocultas (ou intermediárias) e, finalmente, uma camada de saída (DATA SCIENCE ACADEMY, 2020).

As Redes Neurais Profundas são RNAs com diversas camadas intermediárias, também conhecidas como *Deep Neural Networks* (DNN). O processo de treinamento das DNNs exige grande volume de dados e máquinas com alto poder computacional, o que gera um custo elevado no desenvolvimento de aplicações. Para solucionar este problema, empresas passaram a oferecer plataformas de IA como Serviço, conhecida pela sigla em inglês AIaaS (*Artificial Intelligence as a Service*) (MICROSOFT, 2021a).

Essas plataformas oferecem os mais variados tipos de serviços de IA, que permitem ao desenvolvedor criar uma grande variedade de aplicações, incluindo (MICROSOFT, 2021c): i) desenvolvimento de *chatbots* e assistentes de voz por meio de Processamento de Linguagem Natural (PNL); ii) classificação e reconhecimento de imagens, que incluem análise do conteúdo visual de imagens ou quadros de vídeo para entender o que se passa em uma cena; iii) processamento de fala; e iv) auxílio na tomada de decisão mais inteligente, que incluem assistente de métricas, moderador de conteúdos, detector de anomalias e personalizador.

Dentre estes serviços, destaca-se a ferramenta de Visão Personalizada do Azure, um serviço de reconhecimento de imagem que permite criar, implantar e aprimorar os próprios modelos identificadores de imagem.

O interesse na utilização do reconhecimento de íris em sistemas biométricos vem de uma de suas características fundamentais, que é a sua unicidade. Tal característica tornou o processo automatizado de reconhecimento de indivíduos, com base em seus padrões de íris, um dos mais confiáveis para realização de autenticação biométrica na atualidade (SOUZA; GONZAGA, 2017).

Neste contexto, este trabalho apresenta uma avaliação do uso da ferramenta *Custom Vision* (Visão Personalizada) do Azure na tarefa de reconhecimento de íris.

2 USO DE REDES NEURAIS ARTIFICIAIS NA TAREFA DE RECONHECIMENTO DE ÍRIS

O desenvolvimento da íris de um indivíduo não segue nenhum padrão genético e se forma, quase que totalmente, de forma aleatória, tem início no terceiro mês de gestação e término no oitavo mês. A probabilidade de se encontrar íris idênticas é de aproximadamente uma em 10^{72} , o que garante, praticamente, que não aconteçam padrões de íris repetidos em nenhum indivíduo (GTA, 2008).

O sucesso de sistemas de autenticação biométrica, baseados no reconhecimento da íris, deve-se ao desenvolvimento de descritores de características eficientes, especialmente o trabalho pioneiro de Daugman (2004), cujo algoritmo extrai os atributos de textura a partir da íris normalizada e sua codificação é, então, representada em *bits* que utilizam a transformada de Gabor (SOUZA et al., 2015).

Diversos descritores foram utilizados na tarefa de reconhecimento de íris, incluindo métodos tradicionais como transformada de wavelet (BOLES; BOASHASH, 1998), pirâmide laplaciana (WILDES et al., 1994), transformadas discretas de Fourier (DFT) (MIYAZAWA, 2008), bem como descritores de textura local como o LBP (OJALA; PIETIKÄINEN; HARWOOD, 1996), LMP (SOUZA; GONZAGA, 2017) e Median-LMP (SOUZA; GONZAGA, 2019).

O algoritmo de Daugman normalmente tem sido aplicado em base de imagens de íris estáticas, adquiridas em ambientes cooperativos, com iluminação controlada e curta distância focal (SOUZA; GONZAGA, 2017). Em ambientes não cooperativos como no caso de reconhecimento de íris à distância ou em movimento, ocorrem variações de textura, que pioram

o desempenho do sistema de reconhecimento de íris (SOUZA et al., 2015).

Recentemente, diversos trabalhos têm explorado o reconhecimento de íris em sistemas não cooperativos. Tais trabalhos apontam diversos fatores que podem comprometer o desempenho deste tipo de sistema, entre eles: baixa resolução das imagens capturadas, oclusões causadas pelas pálpebras, variação de iluminação e variação do diâmetro da pupila (SOUZA et al., 2015).

Além disso, abordagens de aprendizagem profunda (*deep learning*), tais como as Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNN) têm alcançado ganhos significativos de desempenho em muitas aplicações, incluindo reconhecimento de íris, como nos trabalhos de Lozej et al. (2019) e Ahmad e Fuller (2019).

Outra técnica recente e que tem alcançado excelentes resultados na atualidade é a transferência de aprendizagem (*Transfer Learning*) utilizada nos trabalhos de Minaee e Abdolrashidi (2019) e Barcellos et al. (2019).

2.1 A FERRAMENTA DE VISÃO PERSONALIZADA DO AZURE

É possível utilizar o serviço de Visão Personalizada (*Custom Vision*) do Azure por meio de um conjunto de SDKs (*Software Development Kits*) nativos ou, por sua interface baseada na Web, no site de Visão Personalizada da Microsoft. Esse serviço permite criar, testar e treinar um modelo para a identificação de imagens (MICROSOFT, 2021b).

O serviço de Visão Personalizada possui um algoritmo de *machine learning* pré-treinado com um grande volume de imagens, o qual usa as CNN para analisar imagens. O desenvolvedor pode criar seu próprio classificador enviando grupos de imagens e rotulando-as no momento do envio. Em seguida, o algoritmo é novamente treinado com os dados enviados pelo desenvolvedor e calcula a própria precisão realizando testes com as imagens enviadas (MICROSOFT, 2021b).


Após a fase de treinamento do algoritmo, o desenvolvedor pode testá-lo, retreiná-lo, usá-lo em seu aplicativo de reconhecimento de imagem ou exportar o modelo treinado para uso offline (MICROSOFT, 2021b). Com o serviço de Visão Personalizada é possível começar a criar protótipos de um modelo com uma pequena quantidade de dados. Geralmente, 50 imagens por classe são suficientes. Também é possível escolher variações do algoritmo que são otimizadas para determinados domínios, como por exemplo: geral, alimentos, pontos de

referência ou itens de varejo (MICROSOFT, 2021b).

3 METODOLOGIA

Com a finalidade de analisar o desempenho da ferramenta de Visão Personalizada do Azure na tarefa de reconhecimento de íris, foram utilizadas parte das imagens do banco de imagens UBIRIS.v2. A base contém imagens de íris de 261 indivíduos, separadas por imagens do olho esquerdo e olho direito, totalizando 11.102 imagens, com 522 classes de imagens de íris. As imagens originais possuem o tamanho 400 x 300 pixels, estão no formato .tiff e resolução de 72 dpi. Uma amostra de imagens de dez indivíduos é apresentada na Figura 1.

Figura 1: Amostra de 10 classes de imagens da base UBIRIS.v2



Fonte: Adaptada de PROENÇA et al (2010).

Como a ferramenta não aceita imagens no formato .tiff, as imagens foram convertidas para o formato .jpg. Para realizar o treinamento do classificador foi utilizada a interface baseada na Web no site de Visão Personalizada da Microsoft. Inicialmente foi realizado *login* no site, com o e-mail institucional, para permitir o acesso gratuito. A seguir, foi criado um novo projeto, do tipo classificação multiclasse (várias classes, nas quais cada imagem possui apenas um rótulo). Foi utilizado o domínio Geral [A2], recomendado para a maioria dos conjuntos de dados.

A seguir foi realizado o upload das imagens, enviando-as por classe e rotulando-as de acordo com cada grupo de imagens. A ferramenta permite que o grupo de imagens seja rotulado todo de uma vez.

Com as imagens carregadas, foi iniciado o processo de treinamento do classificador, ajustando o limiar de probabilidade (*probability threshold*) em 50%. Esse limiar de probabilidade representa o nível de confiança que uma previsão precisa ter para ser considerada correta. Após o treinamento, as imagens do conjunto de teste foram submetidas ao modelo.

4 RESULTADOS E DISCUSSÕES

Após a conclusão da etapa de treinamento, o desempenho do modelo é estimado e exibido pela ferramenta. O Serviço de Visão Personalizada usa as imagens que foram submetidas no treinamento para calcular as taxas de precisão e recuperação, por meio do processo de validação cruzada. O modelo treinado também apresenta uma média de precisão (AP), que sumariza as taxas de precisão e de recuperação em diferentes limiares de precisão (MICROSOFT, 2021d).

Com a finalidade de avaliar os resultados da ferramenta foram realizados 2 experimentos descritos a seguir.

4.1 EXPERIMENTO 1

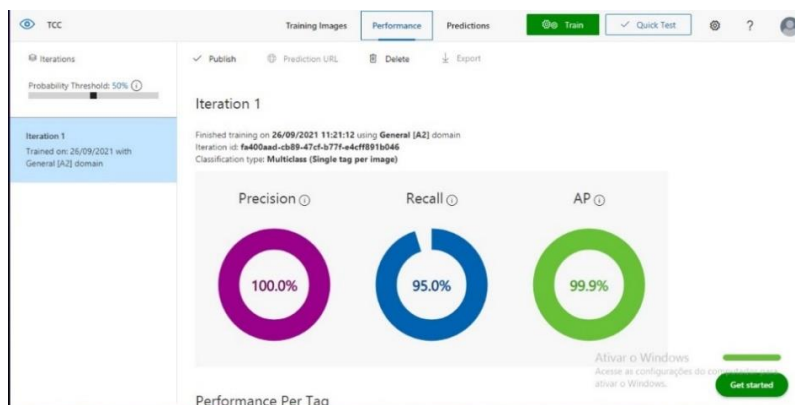
Como o banco de imagens é muito grande para ser processado, foram selecionadas, inicialmente, as primeiras 20 classes da base, contendo 480 imagens do olho esquerdo e direito de 10 indivíduos. As imagens foram agrupadas por indivíduos, e totalizaram 10 classes.

A seguir, as imagens foram divididas aleatoriamente em dois conjuntos: treinamento e teste. O conjunto de treinamento ficou com 80% das imagens (384 imagens), e as demais 20% das imagens (96 imagens) foram inseridas no conjunto de teste.

Após o treinamento, o modelo atingiu os seguintes resultados: precisão = 100%; recuperação = 95% e precisão média = 99,9%, conforme se pode observar na Figura 2.

Finalizado o processo de treinamento e após avaliação de seu desempenho, deu-se início à fase de predições, na qual foram submetidas as imagens do conjunto de teste (imagens das mesmas classes, mas que não fazem parte do conjunto usado no treinamento) ao modelo treinado.

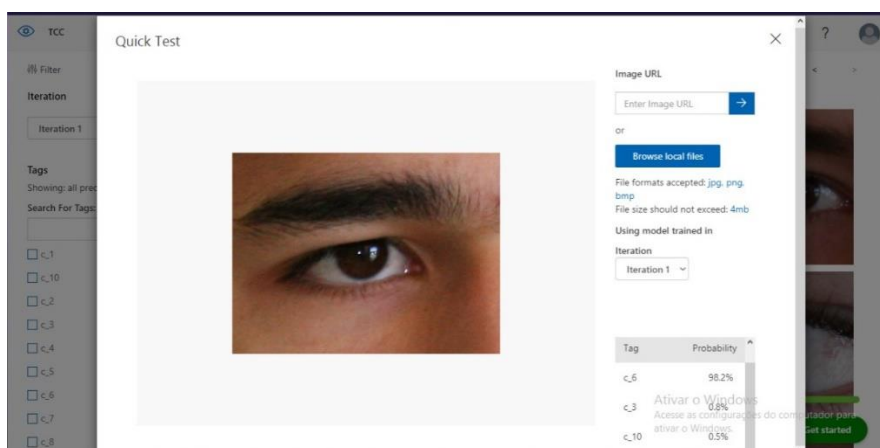
Figura 2: Resultado do modelo treinado no Experimento 1



Fonte: Elaborada pelos autores.

Cada imagem do conjunto de teste foi enviada ao modelo por meio da interface de teste rápido, disponível na ferramenta, conforme Figura 3.

Figura 3: Submissão das imagens do conjunto de teste ao modelo



Fonte: Elaborada pelos autores.

Com as imagens do conjunto de teste (composto de 96 imagens) apenas 2 imagens foram classificadas incorretamente, o que representa uma acurácia de 97,91%. A Tabela 1 apresenta a Matriz de Confusão do Modelo do Experimento 1, a qual permite a visualização do desempenho do algoritmo de classificação.

Tabela 1 – Matriz de Confusão do Modelo do Experimento 1

	c_1	c_2	c_3	c_4	c_5	c_6	c_7	c_8	c_9	c_10
c_1	91,66%	8,33%	0	0	0	0	0	0	0	0
c_2	0	100%	0	0	0	0	0	0	0	0
c_3	0	0	100%	0	0	0	0	0	0	0
c_4	0	0	0	100%	0	0	0	0	0	0
c_5	0	0	0	0	100%	0	0	0	0	0
c_6	0	0	0	0	0	100%	0	0	0	0
c_7	0	0	0	0	0	0	100%	0	0	0
c_8	0	0	0	0	0	0	0	100%	0	0
c_9	0	0	0	0	0	0	0	0	100%	0
c_10	0	0	0	0	0	0	8,33%	0	0	91,66%

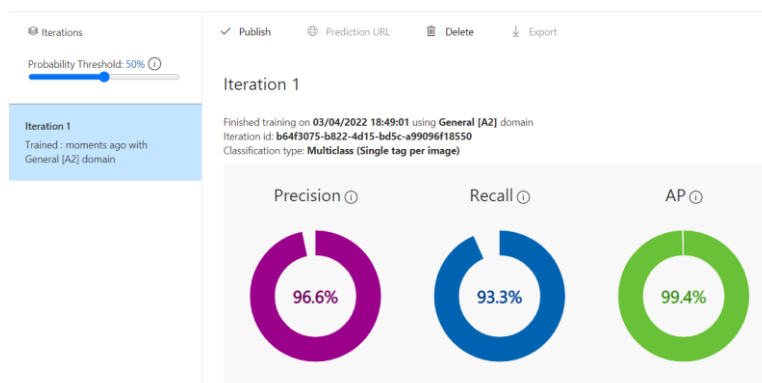
Fonte: Elaborada pelos autores.

4.2 EXPERIMENTO 2

Neste experimento foram selecionados aleatoriamente 10 indivíduos. O treinamento da rede foi realizado com 30 imagens do olho direito de cada um desses indivíduos e o conjunto de teste foi criado utilizando-se 3 imagens do olho esquerdo de cada indivíduo.

Após o treinamento, o modelo atingiu os seguintes resultados: precisão = 96,6%; recuperação = 93,3% e precisão média = 99,4%, conforme é possível verificar na Figura 4.

Figura 4: Resultado do modelo treinado no Experimento 2



Fonte: Elaborada pelos autores.

Com as imagens do conjunto de teste (composto de 30 imagens), 4 imagens foram classificadas incorretamente, o que representa uma acurácia de 86,66%. A Tabela 2 apresenta a Matriz de Confusão do Modelo do Experimento 2.

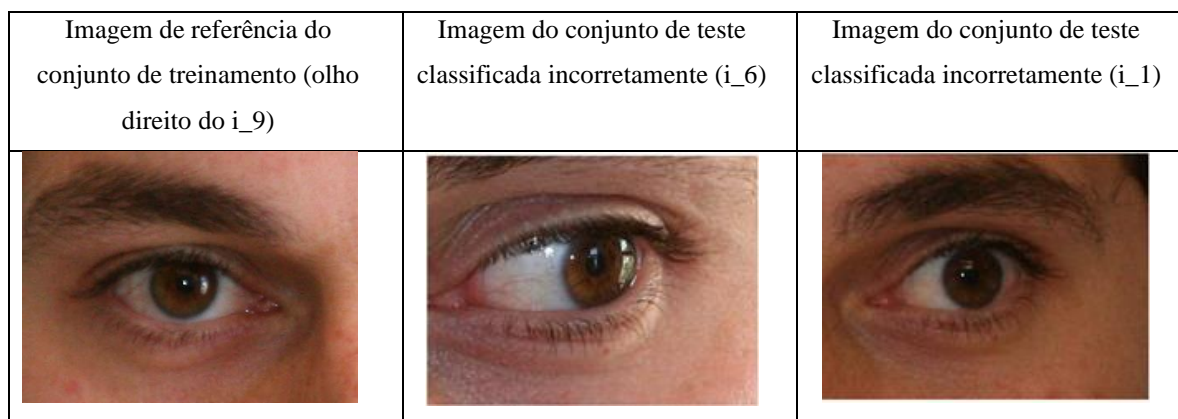
Tabela 2 – Matriz de Confusão do Modelo do Experimento 2

	i_1	i_2	i_3	i_4	i_5	i_6	i_7	i_8	i_9	i_10
i_1	100%	0	0	0	0	0	0	0	0	0
i_2	0	100%	0	0	0	0	0	0	0	0
i_3	0	0	100%	0	0	0	0	0	0	0
i_4	0	0	0	100%	0	0	0	0	0	0
i_5	0	0	0	0	100%	0	0	0	0	0
i_6	0	0	0	0	0	66,67%	33,33%	0	0	0
i_7	0	0	0	0	0	0	66,67%	0	0	0
i_8	0	0	0	33,33%	0	0	0	100%	0	0
i_9	33,34%	0	0	0	0	33,33%	0	0	33,33%	0
i_10	0	0	0	0	0	0	0	0	0	100%

Fonte: Elaborada pelos autores.

A Figura 5 mostra uma imagem do conjunto de treinamento do indivíduo de referência (i_9) e as imagens classificadas incorretamente, para uma análise visual.

Figura 5: Exemplos de classificação incorreta de imagens de acordo com a Matriz de Confusão da Tabela 2



Fonte: Elaborada pelos autores.

Foi escolhido o indivíduo 9 por apresentar a menor taxa de acerto, de modo que se pudesse compreender o processo.

5 CONSIDERAÇÕES FINAIS

Este trabalho apresentou um estudo sobre a eficiência da ferramenta *Custom Vision* na tarefa de reconhecimento de íris. Com base nos experimentos realizados, foi possível verificar que, mesmo treinando os modelos com um número reduzido de imagens (384 imagens no Experimento 1 e 300 imagens no Experimento 2), ambos se mostraram precisos.

Também pode ser verificado que o número de imagens em cada classe não foi decisivo para a precisão do modelo, uma vez que no Experimento 1 algumas classes possuíam 60 imagens e outras classes apenas 30 imagens. Neste experimento, as 2 imagens classificadas incorretamente pertenciam a classes com mais imagens (60 imagens no total, sendo 48 incluídas no conjunto de treinamento e 12 no conjunto de teste). A primeira imagem classificada incorretamente pertencia à classe 1 e a segunda pertencia à classe 10.

A proposta do Experimento 1 era validar um modelo que atingisse uma acurácia em torno de 90%. Utilizando-se as imagens do conjunto de treinamento, o modelo atingiu 100%, 95% e 99,9%, respectivamente de precisão, recuperação e precisão média. A partir das imagens do conjunto de teste (composto de 96 imagens), o modelo obteve a acurácia de 97,91%, sendo que apenas duas imagens foram classificadas incorretamente.

No Experimento 2, a proposta era treinar o modelo com imagens do olho direito de um indivíduo e, em seguida, testá-lo com imagens do olho esquerdo desse mesmo indivíduo. Após o treinamento, o modelo atingiu os seguintes resultados: precisão – 96,6%; recuperação – 93,3% e precisão média – 99,4%. O conjunto de teste (composto de 30 imagens), obteve uma acurácia de 86,66%, com 4 imagens classificadas erroneamente.

Neste contexto, os resultados obtidos nos experimentos verificados e analisados em relação à classificação de imagens de íris, por meio da ferramenta de Visão Personalizada da Microsoft, foram considerados satisfatórios.

Como trabalhos futuros pretende-se realizar novos experimentos, com número de classes maior, tanto para treinamento quanto para teste do modelo.

REFERÊNCIAS

- AHMAD, S.; FULLER, B. *Unconstrained Iris Segmentation Using Convolutional Neural Networks*. In: Carneiro G., You S. (eds) *Computer Vision – ACCV 2018 Workshops*. ACCV 2018. Lecture Notes in Computer Science, v. 11367. Springer, Cham, 2019. Disponível em: <https://link.springer.com/chapter/10.1007/978-3-030-21074-8_36>. Acesso em: 04 Ago. 2020.
- BARCELLOS, W.; SHITARA, N. H.; FERRAZ, C. T.; QUEIROGA, R. T. V.; SAITO, H.; GONZAGA, A. *Evaluation of Fine Tuning and Feature Extraction methods in Biometric Periocular Recognition*. Anais do Workshop de Visão Computacional (WVC), 2019. Disponível em: <<https://sol.sbc.org.br/index.php/wvc/article/view/7626>>. Acesso em: 07 Abr. 2022.
- BOLES, W. W.; BOASHASH, B. *A human identification technique using images of the iris and wavelet transform*. in *IEEE Transactions on Signal Processing*, vol. 46, no. 4, pp. 1185-1188, April 1998. Disponível em: <<https://ieeexplore.ieee.org/document/668573>>. Acesso em: 30 Jul. 2020.
- DATA SCIENCE ACADEMY. *Deep Learning Book – Capítulo 1: Deep Learning e a Tempestade Perfeita*, 2020. Disponível em: <<http://deeplearningbook.com.br/deeplearning-a-tempestade-perfeita/>>. Acesso em: 10 Set. 2021.
- DAUGMAN, J. *How iris recognition works*, in *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 14, no. 1, pp. 21-30, Jan. 2004, doi: 10.1109/TCSVT.2003.818350. Disponível em: <<https://ieeexplore.ieee.org/document/1262028>>. Acesso em: 28 Jul. 2020.
- GTA - GRUPO DE TELEINFORMÁTICA E AUTOMAÇÃO. Reconhecimento de Íris. Universidade Federal do Rio de Janeiro, 2008. Disponível em: <https://www.gta.ufrj.br/grad/08_1/iris/index.html>. Acesso em 04 Abr. 2022.
- LOZEJ, J; ŠTEPEC, D; ŠTRUC V; PEER, P. *Influence of segmentation on deep iris recognition performance*, 2019 7th International Workshop on Biometrics and Forensics (IWBF), Cancun, Mexico, 2019, pp. 1-6, doi: 10.1109/IWBF.2019.8739225. Disponível em: <<https://ieeexplore.ieee.org/document/8739225>>. Acesso em: 04 Ago. 2020.
- MICROSOFT. O que é Visão Personalizada?, 2021a. Disponível em: <<https://docs.microsoft.com/pt-br/azure/cognitive-services/custom-vision-service/overview>>. Acesso em 20 Out. 2021.
- MICROSOFT. Selecionar um domínio para um projeto de Visão Personalizada, 2021b. Disponível em: <<https://docs.microsoft.com/pt-br/azure/cognitive-services/custom-vision-service/select-domain>>. Acesso em 22 Out. 2021.
- MICROSOFT. O que são os Serviços Cognitivos do Azure?, 2021c. Disponível em: <<https://azure.microsoft.com/pt-br/services/cognitive-services/#overview>>. Acesso em: 22 Out. 2021.
- MICROSOFT. Quickstart: Construa um classificador com o site da Visão Personalizada?, 2021d. Disponível em: <<https://docs.microsoft.com/en-us/azure/cognitive-services/custom-vision-service/getting-started-build-a-classifier>>. Acesso em: 26 Out. 2021.

MINAEE, S.; ABDOLRASHIDI, A. *DeepIris: Iris Recognition Using A Deep Learning Approach*, arXiv:1907.09380 [cs.CV], julho de 2019.

MIYAZAWA, K; ITO, K; AOKI, T; KOBAYASHI, K; H. NAKAJIMA, H. *An Effective Approach for Iris Recognition Using Phase-Based Image Matching* in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 30, no. 10, pp. 1741-1756, Oct. 2008. Disponível em: <<https://ieeexplore.ieee.org/document/4407724>>. Acesso em: 30 Jul. 2020.

OJALA, T.; PIETIKÄINEN, M; HARWOOD, D. *A comparative study of texture measures with classification based on featured distributions*, Pattern Recognition, vol. 29, no. 1, pp. 51–59, Jan. 1996. Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/S0031320395000674>>. Acesso em: 30 Jul. 2020.

PROENÇA, Hugo; FILIPE, Sílvio; SANTOS, Ricardo; OLIVEIRA, João; ALEXANDRE, Luís A. *The UBIRIS.v2: A Database of Visible Wavelength Iris Images Captured On-The-Move and At-A-Distance*, IEEE Transactions on Pattern Analysis and Machine Intelligence, August, 2010, volume 32, number 8, pag. 1529-1535, ISSN: 0162-8828, Digital Object Identifier <http://doi.ieeecomputersociety.org/10.1109/TPAMI.2009.66>. Disponível em: <<http://iris.di.ubi.pt/publications.html>>. Acesso em: 28 Jul. 2020.

RICH, E.; KNIGHT, K. *Artificial Intelligence*. McGraw-Hill, New York, 1991.

SOUZA, J. M; GONZAGA, A. *Biometric iris classification when the eye's pupil reacts to light*. In: Anais do XIII Workshop de Visão Computacional, 2017, pp. 31–36. Disponível em: <<http://iris.sel.eesc.usp.br/lavi/adilson/publications/Jones.pdf>>. Acesso em: 28 Jul. 2020.

SOUZA, J. M.; VIEIRA, R. T.; GONZAGA, A. *Analysis of iris texture under pupil contraction/dilation for biometric recognition*. In: Proceedings of XI Workshop de Visão Computacional, 2015, pp. 128–133. Disponível em: <http://iris.sel.eesc.usp.br/lavi/adilson/publications/Jones-WVC_2015.pdf>. Acesso em: 28 Jul. 2020.

SOUZA, J.M; GONZAGA, A. *Human iris feature extraction under pupil size variation using local texture descriptors*. Multimedia Tools and Applications 78, 20557–20584 (2019). Disponível em: <<https://link.springer.com/article/10.1007/s11042-019-7371-4>>. Acesso em: 30 Jul. 2020.

WILDES, R.P. *et al. A system for automated iris recognition*. Proceedings of 1994 IEEE Workshop on Applications of Computer Vision, Sarasota, FL, USA, 1994, pp. 121-128, doi: 10.1109/ACV.1994.341298. Disponível em: <<https://ieeexplore.ieee.org/document/341298>>. Acesso em: 30 Jul. 2020.