

15º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2024

Avaliação dos padrões da íris sob patologias oculares

Gustavo Oliveira Amaral¹,
Jones Mendonça de Souza²

¹Graduando em Tecnologia de Análise e Desenvolvimento de Sistemas, Bolsista PIBIFSP, IFSP, Campus Barretos, o.amaral@aluno.ifsp.edu.br. Área de conhecimento (Tabela CNPq): 1.03.03.04-9 Sistemas de Informação.

²Orientador do projeto. Professor de Tecnologia de Análise e Desenvolvimento de Sistemas no IFSP Campus Barretos, jonessouza@ifsp.edu.br. Área de conhecimento (Tabela CNPq): 1.03.03.05-7 Processamento Gráfico.

RESUMO: Os padrões de íris são considerados confiáveis para a identificação de seres humanos. No entanto, algumas doenças oculares podem causar variações na textura da íris, comprometendo a etapa de classificação. Este trabalho apresenta uma nova abordagem para classificação da textura da íris em seres humanos com patologias oculares. Para isso, foi utilizada a base de dados BioBase-Disease-Iris v1.0, que contém amostras de íris de pacientes com diferentes enfermidades. A fim de avaliar o desempenho do método biométrico, foi implementada uma *convolutional neural network* (CNN), treinada com imagens de íris que possuem diferentes patologias. Foi separado um conjunto de treinamento/teste, contendo amostras de três tipos diferentes: saudáveis, com doenças e com textura modificada após procedimento cirúrgico. Os resultados apontam que a rede CNN é promissora para texturas contendo variações, podendo ser um método eficiente para a biometria de íris.

PALAVRAS-CHAVE: Biometria, Aprendizado de Máquina, Íris

Assessment of iris patterns under ocular pathologies

ABSTRACT: Iris patterns are considered reliable for identifying humans. However, some eye diseases can cause variations in the texture of the iris, compromising the classification stage. This work presents a new approach for classifying iris texture in humans with ocular pathologies. For this, the BioBase-Disease-Iris v1.0 database was used, which contains iris samples from patients with different illnesses. In order to evaluate the performance of the biometric method, a convolutional neural network (CNN) was implemented, trained with iris images that have different pathologies. A training/test set was separated, containing samples of three different types: healthy, diseased and texture modified after a surgical procedure. The results indicate that the CNN network is promising for textures containing variations, and can be an efficient method for iris biometrics.

KEYWORDS: *Biometry, Machine learning, Iris*

INTRODUÇÃO

A Biometria é uma área da computação que estuda as características dos seres vivos, e tem sido amplamente utilizada na área da segurança, por identificar indivíduos com precisão. A tecnologia de reconhecimento de indivíduos por meio da biometria já é amplamente difundida e utilizada em diversos ambientes, tais como urnas eletrônicas, pontos eletrônicos, celulares, hospitais, tribunais bancários, agências bancárias, etc (DAUGMAN, 1993).

Dentre as diferentes formas de biometria, uma das mais promissoras é o reconhecimento de padrão da íris, que por possuir uma grande quantidade de características, faz com que esse método tenha um peso maior no quesito "unicidade", uma medida biométrica que avalia a viabilidade de uso da biometria. Dessa forma, há um grande interesse em utilização da íris em situações que exijam maior segurança e, além disso, é um método que pode ser utilizado sem a necessidade de contato físico, em qualquer circunstância em que a íris da pessoa seja observável (SOUZA; GONZAGA, 2019).

Essa identificação pode ser realizada por algoritmos de inteligência artificial, que, através da análise de dados, armazenam padrões que podem ser utilizados em uma predição, assim conseguindo discernir as características de um indivíduo (NGUYEN; FOOKES; ROSS; SRIDHARAN, 2018). Este trabalho visa a se aprofundar em possíveis problemas que tais tecnologias podem vir a enfrentar, e, mais especificamente, visa a vislumbrar o potencial de reconhecimento de íris em pessoas que apresentam ou apresentaram patologias oculares, visto que tais enfermidades podem comprometer características que são utilizadas pelos algoritmos na hora de analisar os padrões da íris de um indivíduo.

MATERIAL E MÉTODOS

Para avaliar os padrões da íris sob as diferentes patologias oculares, foi utilizada a base de dados BioBase-Disease-Iris v1.0 (TROKIELEWICZ; CZAJKA; MACIEJEWICZ, 2015). Esta contém 2.996 amostras de íris coletadas de 115 pacientes. Parte das imagens foram capturadas em banda visível utilizando-se uma câmera profissional de marca/modelo Canon EOS 1000D. Outra parte foi capturada na banda infravermelha, utilizando-se o sensor IrisGuard AD100. O banco de dados é formado por amostras de pacientes afetados pelas seguintes doenças: catarata, glaucoma agudo, sinéquias posteriores e anteriores, deslocamento de retina, rubeose da íris, vascularização da córnea, úlcera da córnea, atrofia da íris, entre outras. Os pacientes foram examinados por um médico especialista, que diagnosticou as patologias e acompanhou os pacientes no tratamento, adquirindo amostras das íris ao longo de 8 meses. A Figura 1 ilustra três amostras de íris que sofreram variação na textura após procedimentos cirúrgicos.




Figura 1 - Exemplo de duas amostras contendo variação na textura após procedimento cirúrgico (TROKIELEWICZ; CZAJKA; MACIEJEWICZ, 2015).

Observando a Figura 1, é possível concluir que após o procedimento cirúrgico parte da textura da íris é ausente, em outras situações há deformidade da pupila. A fim de avaliar o desempenho biométrico da íris sob diferentes patologias, foram realizados experimentos com redes CNN,

utilizando o ambiente de execução do google colab, plataforma que permite acesso a máquinas fornecidas pelo site para execução remota de jupyter notebooks de maneira gratuita, com diversas ferramentas úteis para a prática de aprendizagem de máquina como acesso a python3, Tensorflow e Pytorch (GOOGLE, 2024). Os testes foram realizados comparando o desempenho das redes: VGG16, AlexNet e Resnet 50.

Redes neurais artificiais são constituídas por diversas camadas com diferentes funções, podendo variar de acordo com a tarefa que a rede foi projetada para desempenhar. As redes utilizadas durante esse projeto tem como base o uso de camadas de convolução, que filtram as entradas a fim de destacar informações importantes.

Uma convolução pode ser definida como uma operação matemática que define uma maneira de transformar duas funções ou informações em uma terceira função (SOVIERZOSKI, 2011). A representação matemática que define uma convolução entre duas funções f e x sobre o alcance t , onde \otimes representa a convolução pode ser observada na Equação 1.

$$y(t) = f \otimes x = \int_{-\infty}^{\infty} f(k).x(t - k)dk \quad (1)$$

Função de convolução.

Convolução 2D é o tipo de convolução mais presente em CNN's, sendo feita a partir de uma matriz de tamanho arbitrário denominado *kernel*, que “desliza” sobre as imagens formando uma saída com valores determinados pelo resultado da soma da multiplicação dos elementos, podendo ou não ter um viés somado após a operação, como demonstrado pela Figura 2. Esse processo é feito diversas vezes até o *kernel* percorrer a matriz da imagem inteira, e tem como saída uma nova matriz composta pelos resultados das operações em cada seção da imagem (CRÓSTA, 1992).




Figura 2 -Exemplo de convolução em uma imagem usando filtro de dimensão 3x3 (DUMOULIN; VISIN, 2018).

Durante o treino das redes neurais, são reajustados os parâmetros das camadas de forma que cada característica extraída, como cor e forma, seja devidamente atrelada à classe na qual ela pertence, nesse caso ao paciente que possui o olho apresentado na imagem. Esse procedimento é feito através de várias etapas, cada uma composta por uma fase de treino e validação.

Enquanto na fase de treino, os pesos da rede neural são ajustados de forma a minimizar os erros durante a classificação de imagens, na fase de validação a rede é utilizada para classificar imagens que não foram utilizadas durante o ajuste de parâmetros, a fim de testar sua eficácia com imagens novas.

RESULTADOS E DISCUSSÃO

Os experimentos foram divididos em três etapas, treino 1, treino 2 e treino 3. Para realizar os treinos 1 e 2 foram separadas do banco de dados as classes que possuíam mais de uma sessão de fotos, isto é, foram utilizadas apenas classes que possuíam imagens de antes e depois de algum procedimento cirúrgico ou doença.

Durante o treino 1, foi realizado o treinamento das CNN 's utilizando imagens de íris com textura de antes da cirurgia, e a validação com amostras da mesma classe apresentando íris com textura de pós procedimento cirúrgico.

No treino 2, a fase de treinamento e classificação são similares ao treino 1, tendo como diferença a inclusão de imagens retiradas após o processo cirúrgico na fase de treino.

Para o treino 3 foi utilizado o banco de dados completo, incluindo as classes que não possuíam mais de uma sessão de fotos. A base de dados utilizada tem uma documentação que descreve esses conjuntos separados, o que facilitou o treinamento/validação dos experimentos com os métodos propostos.

Analisando os resultados obtidos com o Treino 1, é possível perceber que as redes neurais demonstraram baixa acurácia para classificar as amostras recebidas no processo de validação/teste, apresentando taxas de acerto de aproximadamente 60% de acurácia. Na Figura 3 é possível visualizar o desempenho das redes neurais, a rede que obteve melhor acurácia foi a ResNet50, variando a taxa de acurácia de até 65%.




Figura 3 - Gráficos de acurácia da fase de validação do treino 1. Fonte: próprio autor.

Estes resultados indicam que as distorções causadas na textura da íris devido às cirurgias realizadas, podem comprometer o desempenho biométrico de íris, pois os padrões sofrem muita variação.

No próximo experimento com o Treino 2, foram incluídas somente amostras que foram tiradas após a cirurgia, ou seja, tanto a fase de treinamento quanto a de classificação foram realizadas utilizando somente conjuntos após a cirurgia. Observando os gráficos apresentados na Figura 4, é possível notar um aumento significativo na taxa de acurácia, passando dos 95% para os métodos propostos.




Figura 4 - Gráficos de acurácia da fase de validação do treino 2. Fonte: próprio autor.

É possível inferir que, apesar das mudanças drásticas apresentadas pela íris após realizado um procedimento cirúrgico, os padrões ainda podem ser utilizados para identificar o indivíduo de forma precisa.

Durante o treino 3, foram utilizadas todas as imagens presentes no banco de dados, a fim de avaliar as demais doenças presentes no banco de dados. As redes apresentaram uma taxa de acerto em torno dos 90% ao fim do treino, como pode ser observado na Figura 5.




Figura 5 - Gráficos de acurácia da fase de validação do treino 3. Fonte: próprio autor.

Apesar de os resultados apresentarem uma perda de 5% de acurácia em relação ao segundo teste, as redes neurais ainda apresentam resultados bons ao realizar a classificação das imagens apresentadas, conseguindo acertar uma grande parcela das imagens apresentadas para avaliação.

CONCLUSÕES

Dados os resultados apresentados, podemos dizer que, mesmo as patologias oculares distorcendo os padrões característicos apresentados pela íris a ponto de ela não ser mais reconhecida pelas redes neurais, caso as redes sejam treinadas novamente para se readaptar aos novos padrões, elas ainda apresentam a capacidade de classificá-los corretamente.

CONTRIBUIÇÕES DOS AUTORES

Gustavo Oliveira Amaral foi responsável pelo treinamento das redes neurais artificiais, levantamento bibliográfico e escrita do artigo.

Jones Mendonça de Souza realizou o levantamento bibliográfico, bem como realizou a aquisição do banco de dados utilizado na pesquisa. Além disso, preparou o material a ser utilizado e colaborou para o progresso da pesquisa, bem como para a escrita/revisão do artigo.

Todos os autores contribuíram com a revisão do trabalho e aprovaram a versão submetida.

AGRADECIMENTOS

Os autores agradecem ao apoio financeiro concedido pelo Instituto Federal de São Paulo, por meio do programa PIBIFSP.

REFERÊNCIAS

CRÓSTA, Alvaro Penteado. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: Unicamp, 1992. 139 p.

DAUGMAN, John. High confidence visual recognition of persons by a test of statistical independence. **Ieee Transactions On Pattern Analysis And Machine Intelligence**, Cambridge, v. 15, n. 11, p. 1148-1161, nov. 1993. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/34.244676>.

DUMOULIN, Vincent; VISIN, Francesco. **A guide to convolution arithmetic for deep learning**. 2018. Disponível em: <https://www.cs.cmu.edu/~bhiksha/courses/deeplearning/Spring.2019/archive-f19/www-bak11-22-2019/document/note/hwnotes/hw2/hw2.html>. Acesso em: 18 jun. 2024.

GOOGLE. **Google Colaboratory**. Disponível em: <https://colab.research.google.com/>. Acesso em: 13 abr. 2024.

NGUYEN, Kien; FOOKES, Clinton; ROSS, Arun; SRIDHARAN, Sridha. Iris Recognition With Off-the-Shelf CNN Features: a deep learning perspective. **Ieee Access**, v. 6, p. 18848-18855, 2018. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/access.2017.2784352>.

SOUZA, Jones Mendonça de; GONZAGA, Adilson. Human iris feature extraction under pupil size variation using local texture descriptors. **Multimedia Tools And Applications**, [S.L.], v. 78, n. 15, p. 20557-20584, 4 mar. 2019. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s11042-019-7371-4>.

SOVIERZOSKI, Miguel Antônio. Convolução de Sinais: Definição, Propriedades e Ferramentas. **Revista Ilha Digital**, Florianópolis, v. 2, p. 81–95, 2011. Disponível em: <https://ilhadigital.florianopolis.ifsc.edu.br/index.php/ilhadigital/article/view/24>. Acesso em: 7 set. 2024.

TROKIELEWICZ, Mateusz; CZAJKA, Adam; MACIEJEWICZ, Piotr. Database of iris images acquired in the presence of ocular pathologies and assessment of iris recognition reliability for disease-affected eyes. **2015 Ieee 2Nd International Conference On Cybernetics (Cybconf)**, Gdynia - Poland, p. 495-500, jun. 2015. IEEE. <http://dx.doi.org/10.1109/cybconf.2015.7175984>.