

Classificação de pessoas baseada em características da região periocular

Leonardo Ferreira Nascimento; Jones Mendonça de Souza. IFSP. f.leonardo@aluno.ifsp.edu.br

Palavras-chave: Biometria, Reconhecimento de padrões, Inteligência artificial, Computação visual.

Introdução

A biometria tem sido utilizada no mercado para autenticar a identidade de seres humanos. Dentre as tecnologias existentes podemos citar, impressão digital, face, íris entre outros. Estudos indicam que a região periocular de um ser humano possui atributos capazes de autenticar um indivíduo de maneira única (PARK, 2009). Com base neste problema, pode-se obter um sistema de autenticação de alta confiabilidade, visto que são utilizadas características peculiares da íris, e região ocular como: sobancelha, cílios, formato do olho, cor da íris e textura de pele da região ocular.

Objetivos

Este trabalho propõe um estudo comparativo entre diferentes bases de dados da região periocular. O objetivo específico foi investigar um algoritmo com maior confiabilidade para classificação dos padrões da região periocular.

Material e Métodos

Para realização deste trabalho foi proposto a utilização das bases de dados: UBIRIS.v2 (PROENÇA, 2010) e CASIA-Iris-V4-Distance (Chinese Academy of Sciences Institute of Automation. 2005) A base de dados UBIRIS.V2 possui amostras da região periocular (esquerda, direita), já a base de dados CASIA-Iris-V4-Distance possui amostras de face.

Para a classificação da textura foram utilizadas duas redes neurais: InceptionV1 (SZEGEDY, 2015) e MobilenetV2.7 (HOWARD, 2017).

Os experimentos com a base de dados CASIA-Iris-V4-Distance foram divididos em três subconjuntos, sendo um para o olho direito,

outro para o olho esquerdo, e outro para a faixa do rosto que compõem ambos os olhos, a segmentação foi realizada através da utilização do algoritmo Viola Jones. A base de dados UBIRIS.v2 foi dividida em dois novos conjuntos, um para cada olho.

Para cada subconjunto, foi realizado o treinamento das amostras, obtendo-se redes diferentes para cada subconjunto de treinamento. Dentre as amostras, foram separadas 60% para treinamento e 40% para teste.

Para validação dos dados multiclasse, foram utilizados 3 algoritmos: OneVersusAll com um treinador binário L-BFGS de regressão, L-BFGS de entropia máxima e Naive Bayes.

Resultados e Discussão

Taxa de sucesso - Inception V1

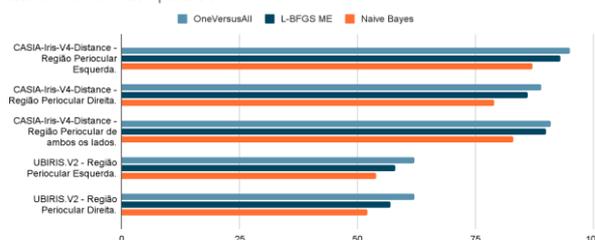


Figura 1 – Taxa de sucesso usando a rede InceptionV1

Taxa de sucesso - Mobilenet V2.7

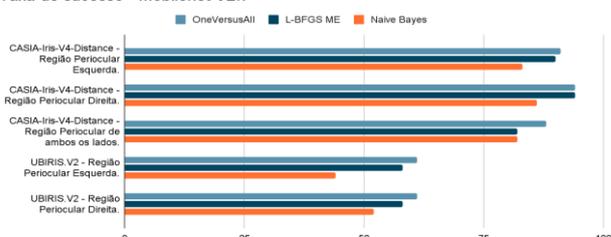


Figura 2 – Taxa de sucesso usando a rede MobilenetV2

A análise da taxa de sucesso dos métodos utilizados representados na Figura 1 e Figura 2 apresenta a influência que a qualidade e padronização dos dados possui sobre a capacidade de reconhecimento biométrico de uma rede neural. A base de dados UBIRIS.V2, diferentemente da base de dados CASIA-Iris-V4-Distance, apresenta dados com influência da iluminação local, além de estarem em uma resolução inferior, gerando um impacto na qualidade de classificação dos métodos aplicados. O algoritmo de treinamento OneVersusAll, por possuir uma maior complexidade no processo de classificação, gerou uma taxa de sucesso maior que os demais algoritmos, porém com um custo maior de desempenho, enquanto os algoritmos L-BFGS e Naive Bayes concluíram o processo de treinamento entre dois e cinco minutos, o algoritmo OneVersusAll realizou os mesmos treinamentos levando entre trinta e cinquenta minutos para a conclusão.

Conclusões

A eficiência de sistemas biométricos criados através de inteligência artificial se torna inerente à qualidade do material disposto para a criação do mesmo. Redes neurais convolucionais possuem a capacidade de abstrair informações de maneira eficiente em conjuntos de dados de grandes proporções, o que facilita o desenvolvimento de sistemas de reconhecimento biométrico, além de possuírem uma fácil integração com diversos sistemas computacionais atuais.

Agradecimentos

Os autores agradecem o apoio financeiro fornecido pelo IFSP, por meio da bolsa de iniciação científica PIBIFSP.

Referências Bibliográficas

CASIA-IrisV4. Chinese Academy of Sciences Institute of Automation.

<http://biometrics.idealteste.org/dbDetailForUser.do?id=4.html> Tech. Rep. 2005.

Howard, Andrew G. et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. ArXiv abs/1704.04861. 2017.

Park, U; Ross, A; Jain, A. K. Periocular biometrics in the visible spectrum: A feasibility study. 2009. IEEE 3rd International Conference on Biometrics: Theory, Applications, and Systems. pp. 1-6.

Proença, H. et al. The UBIRIS.v2: A Database of Visible Wavelength Images captured On-The-Move and At-A-Distance. IEEE Trans. PAMI, 2010. v. 32, n. 8, p. 1529-1536. 2010.

Szegedy, Christian et al. Going deeper with convolutions. IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015.