

COMPARAÇÃO DE DESEMPENHO DOS CLASSIFICADORES NAIVE BAYES, KNN E C4.5 PARA UM CONJUNTO DE DADOS DE IMAGENS DE GESTOS DE LINGUA DE SINAIS

João Felipe Moreira de Souza¹, Diego Saqui¹

¹Instituto Federal de Mato Grosso do Sul – Corumbá-MS

jfelipe7.souza@gmail.com, diego.saqui@ifms.edu.br

Resumo

Em 2015 a Organização Mundial da Saúde indicou que no Brasil existe um total de 28 milhões de pessoas com surdez, que representa 14% da população brasileira. Há leis que exigem o uso da Língua Brasileira de Sinais (LIBRAS) em algumas instituições públicas no Brasil, porém isso não é realidade na maior parte dos ambientes em que os surdos e mudos convivem. A falta de intérprete ou de um pessoal qualificado é o principal problema. Ao longo dos anos, tecnologias têm surgido para ajudar na comunicação com os ouvintes. Reconhecimento de padrões (RP) é uma área de computação onde tecnologias para essa finalidade podem ser desenvolvidas. Portanto, neste estudo é apresentado uma comparação dos algoritmos Naive Bayes, K-Nearest Neighbors (KNN) e C4.5, para classificar gestos de línguas de sinais e compor uma estratégia baseada em RP.

Palavras-chave: acurácia, classificador, C4.5, K-Nearest Neighbors (KNN), Libras, Naive Bayes.

Metodologia e desenvolvimento

Para desenvolver as etapas do fluxograma demonstrado na Figura 1, foram utilizados métodos e técnicas de Visão Computacional, de Aprendizado de Máquina e RP. A linguagem de programação Python foi escolhida para o desenvolvimento combinada com bibliotecas que facilitam a construção dessa análise.

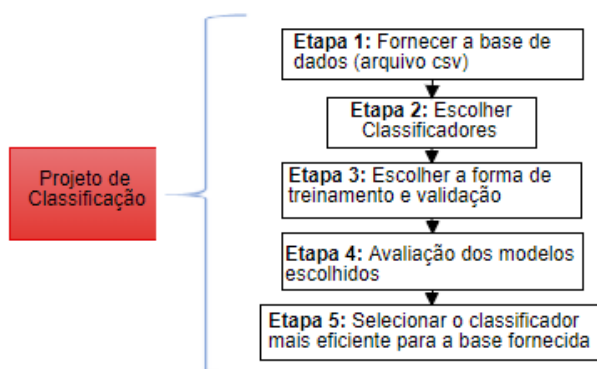


Figura 1. Fluxograma do Projeto de Classificação

A Etapa (1) consiste em informar a base de dados no formato .csv que será classificado. Na Etapa (2), o usuário escolhe o classificador que deseja usar na base selecionada. A Etapa (3) consiste em escolher a forma de validação. Na Etapa (4) é onde ocorre a classificação dos

dados. A Etapa (5) consiste em informar qual classificador é o mais adequado para a base de dados escolhida.

Resultados e Considerações Finais

O primeiro teste foi aplicado a técnica *holdout* utilizando 20% dos dados para testes e 80% dos dados para o treino.

Tabela 1. Taxa de acerto usando a técnica *holdout*

Classificadores	Acurácia
KNN(K=5)	89.05 %
C4.5	90.05 %
Naive Bayes	52.68 %

O segundo teste foi aplicado a validação cruzada com 10 *folds* e o teste estatístico t-pareado.

Tabela 2. Taxa de acerto usando a validação cruzada

Classificadores	Acurácia
KNN(K=5)	90.18 %
C4.5	91.13 %
Naive Bayes	52.33 %

Após os testes foi comprovado estatisticamente que o classificador C4.5 é o mais eficiente para a base de dados utilizada.

Agradecimentos

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) que tem apoiado o desenvolvimento deste projeto e ao Instituto Federal de Mato Grosso do Sul (IFMS) pela bolsa disponibilizada.

Referências

- BALLARD, D. H.; BROWN, C. B.: Computer Vision, 1982.
- GONZALES, R. C.; WOODS, R. E.: Digital Image Processing, 1993.
- MITCHELL, T. M.: Machine Learning, 1997.
- PSF (Python Software Foundation). Link: <https://www.python.org/>. Acessado em janeiro de 2019.
- SEBE, N.; COHEN, I.; GARG, A.; HUANG, T. S.: Machine Learning in Computer Vision. Dordrecht: Springer, 2005.