



Palavras-chave: Inteligência artificial. Machine learning. Ciência de dados. Rh. Desligamento de pessoal

Introdução/Objetivo:

O rotatividade de pessoal é um aspecto importante no ambiente empresarial, pois empresas precisam tanto contratar novas pessoas a fim de manter as equipes com ideias e pensamentos diferentes ou externos, quanto desligar funcionários que se tornaram desqualificados com o passar do tempo, inadequados ao ambiente da empresa ou simplesmente muito caros para a empresa. Há alguns indicativos quando um funcionário irá se demitir, mas o que será abordado será o desgaste dos funcionários, que é o deterioramento de sua relação com a empresa. O objetivo deste trabalho acadêmico é desenvolver uma IA que possa atuar em cenários empresariais para detectar e possivelmente prevenir o desligamento de um funcionário, assim reduzindo custos para a empresa e evitando a perda de capital intelectual.

Metodologia:

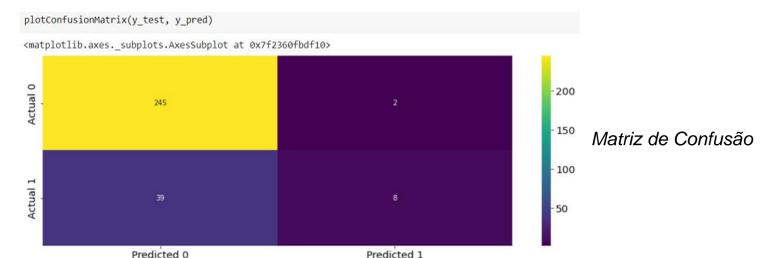
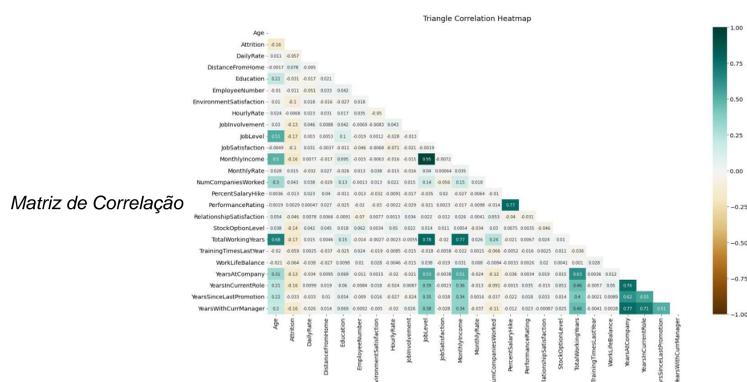
O tipo de pesquisa utilizada no presente resumo foi descritiva no sentido que utiliza conhecimento já disponível na internet, mas os aplica de forma prática. A coleta de dados foi feita através da plataforma Kaggle com uma abordagem quali-quantitativa, pois os dados serão relacionados para interpretação, o que influenciará no modelo de aprendizagem de máquina escolhido. Os dados foram analisados utilizando gráficos e tabelas de correlação para identificar padrões e o relacionamento entre as informações.

Resultados:

Após seguir as etapas de desenvolvimento da IA, como limpeza dos dados, pré-processamento, treinamento do algoritmo escolhido e predição, as métricas obtidas foram: Floresta randômica: Erro Absoluto médio: 13,94% Erro quadrático médio: 13,94% Raiz do erro médio quadrático: 37,34% R2: 86,05% Gradient Boosting Erro Absoluto médio: 13,94% Erro quadrático médio: 13,94% Raiz do erro médio quadrático: 37,34% R2: 86,05% Regressão Ridge Erro Absoluto médio: 24,24% Erro quadrático médio: 12,27% Raiz do erro médio quadrático: 35,03% R2: 8,60% É possível perceber que a floresta randômica obteve os melhores resultados e erros comparados com as outras opções. Por exemplo, o R2 da floresta é 86,05% e da regressão Ridge 8,60%, sendo uma grande diferença.

Conclusão:

Dentre os algoritmos, a floresta randômica obteve a maior acurácia, ou seja, pessoas que trabalham após o período, solteiras, com cargos de nível hierárquico baixo são mais propensas a pedir demissão. Por fim, o que causou uma menor acurácia dos algoritmos de aprendizado de máquina utilizados foi o número de atributos e o tamanho do dataset, que precisava ser bem maior para que o treinamento da inteligência artificial fosse efetivo.



Referências: GÉRON, Aurélien. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. Alta Books, 2019. HOLTOM, Brooks; ALLEN, David. *Better Ways to Predict Who's Going to Quit*. Harvard Business Review, 16 ago. 2019. Disponível em: <<https://hbr.org/2019/08/better-ways-to-predict-whos-going-to-quit?ab=hero-subleft-1>>. Acesso em: 2 set. 2022. ZACH. *Ridge Regression in Python (Step-by-Step)*. Statology, 12 nov. 2020. <<https://www.statology.org/ridge-regression-in-python/>>. Acesso em: 10 set. 2022.

Agradecimentos: Este trabalho de pesquisa pode ser realizado com a colaboração da UNICAMP, FACAMP e KAGGLE