

Aprendizado Profundo aplicado ao Reconhecimento Biométrico

Código do projeto: CL01

Responsável: Prof. Clodoaldo A M Lima

Linha de pesquisa: Inteligência de Sistemas

Número de vagas: 2

Descrição geral

Redes Neurais Convolucionais (RNCs) têm provado ser ferramentas poderosas para uma ampla gama de tarefas de visão computacional. RNCs aprendem automaticamente abstrações de nível médio e alto nível obtidas a partir de dados brutos (por exemplo, imagens). Resultados recentes indicam que os descritores genéricos extraídos a partir de RNCs são extremamente eficazes no reconhecimento e localização de objetos em imagens naturais. Pesquisadores da área de análise de imagens médicas têm alcançado resultados promissores com a aplicação de RNCs e outras metodologias de Aprendizado Profundo para uma ampla variedade de problemas. A principal vantagem de uma RNC reside na sua arquitetura profunda, que permite extrair um conjunto de características discriminantes em vários níveis de abstração.

Nos últimos anos, abordagens baseadas em Aprendizado Profundo têm sido aplicadas para reconhecimento facial e têm alcançado resultados promissores. Estas abordagens recebem dados brutos como entrada e convoluem com filtros em múltiplos níveis para automaticamente descobrir representações de baixo nível e alto nível a partir de dados rotulados ou não para tarefas de detecção e /ou classificação de padrões. Entretanto, a geração de arquiteturas de Aprendizado Profundo consiste na otimização de milhares de parâmetros, isto é, pesos das várias camadas da arquitetura, o que requer: (i) uma grande quantidade de dados de treinamento rotulados; (ii) grandes recursos computacionais, como unidades de processamento gráfico; (iii) vários ajustes na arquitetura ou nos parâmetros de aprendizagem da rede, a fim de garantir que todas as camadas estejam aprendendo com velocidade compatível.

Consequentemente, os métodos de Aprendizado por Transferência são aplicados de forma a reutilizar o conhecimento adquirido anteriormente a partir de um problema de reconhecimento visual para o novo domínio da tarefa desejada. Aprendizado por Transferência pode ser aplicado de duas maneiras diferentes no que diz respeito ao tamanho e à semelhança entre conjunto de dados de pré-treinamento e o novo de conjunto de dados. A primeira abordagem consiste em realizar um ajuste fino dos pesos da rede pré-treinada usando o novo conjunto de dados via algoritmo de retropropagação. Este método é apenas sugerido para grandes conjuntos de dados,

uma vez que o ajuste fino dos pesos da rede pré-treinada usando poucas amostras de treinamento pode conduzir a sobre ajuste.

A segunda abordagem consiste na utilização direta dos pesos de uma arquitetura já treinada no problema desejado para extrair as características e depois classificar. Este esquema é especialmente eficiente quando o novo conjunto de dados é pequeno e/ou há um número pequeno de classes. Dependendo da semelhança entre os dois conjuntos de dados, pode-se decidir se utiliza os pesos das camadas inferiores como extratores de características genéricas de baixo nível ou os pesos da camada superior como extratores da tarefa específica. O objetivo deste projeto visa propor uma arquitetura de Aprendizado Profundo, treiná-la para a tarefa de reconhecimento facial e comparar o desempenho quando é utilizado os pesos das camadas inferiores ou superiores de uma arquitetura já treinada..

Referências

Dan Amir and Ofra Amir. HIGHLIGHTS: Summarizing Agent Behavior to People, 2018.

Leila Amgoud, Henri Prade. Using arguments for making and explaining decisions, 2009.

Valdinei Freire, Karina Valdivia Delgado, Willy Reis. An Exact Algorithm to make a Trade-off between Cost and Probability in SSPs, 2019.

Isabella Kuo, Valdinei Freire. Probability-to-Goal and Expected Cost Trade-Off in Stochastic Shortest Path, 2021.

Rediet Abebe, Kira Goldner. Mechanism design for social good, 2018.

Rediet Abebe, Jon Kleinberg, S Matthew Weinberg. Subsidy allocations in the presence of income shocks, 2020.

Okan Dukkanci, Özlem Karsub, Bahar Y. Kara. Planning sustainable routes: Economic, environmental and welfare concerns, 2021.

Xuejing Zheng, Chao Yu, Chen Chen, Jianye Hao, Hankz Hankui Zhuo. Lifelong Reinforcement Learning with Temporal Logic Formulas and Reward Machines, 2021.

Roy Fox, Sanjay Krishnan, Ion Stoica, Ken Goldberg. Multi-Level Discovery of Deep Options, 2017.

Pashootan Vaezipoor, Andrew C. Li, Rodrigo Toro Icarte, Sheila McIlraith. LTL2Action Generalizing LTL Instructions for Multi-Task RL, 2021.