

Universidade de Pernambuco
Programa de Pós-Graduação em Engenharia da
Computação (PPGEC)

Proposta de Tese de Doutorado

Área: Computação Inteligente

Título: Análise comparativa das técnicas de Multi-Task Learning (MTL) em bases de dados que possuem diferentes tarefas

Orientador: Carmelo José Albanez Bastos Filho (carmelo.filho@upe.br)

Co-orientador: Rodrigo de Paula Monteiro (rodrigo.monteiro@poli.br)

Descrição:

O aprendizado multi-task (MTL) é uma abordagem que busca otimizar o desempenho de múltiplas tarefas relacionadas, utilizando representações compartilhadas para promover sinergias entre elas. Essa técnica é especialmente relevante em cenários onde as tarefas possuem dependências ou correlações, como no setor automotivo ou industrial, onde diferentes tipos de classificação ou predição podem ser realizados simultaneamente. A capacidade do MTL de compartilhar informações entre tarefas permite não apenas economizar recursos computacionais, mas também melhorar a generalização dos modelos, tornando-os mais robustos e eficientes. Uma questão central no aprendizado multi-task é o equilíbrio entre as diferentes tarefas durante o treinamento. A aplicação de estratégias de ponderação dinâmica, como a média ponderada dinâmica (DWA) ou métodos de balanceamento de gradientes, é fundamental para evitar que tarefas mais fáceis dominem o processo de aprendizado, ou que tarefas mais difíceis sejam negligenciadas. Essas estratégias têm demonstrado eficiência em contextos complexos, permitindo uma adaptação contínua às características das tarefas ao longo do treinamento e garantindo resultados mais consistentes e precisos. Em aplicações práticas, como a classificação de imagens ou a análise de dados multimodais, o MTL pode ser aplicado para abordar problemas variados de maneira integrada. Por exemplo, um modelo poderia simultaneamente identificar categorias de objetos em imagens, prever valores numéricos relacionados e realizar análises adicionais de segmentação. Essa abordagem reduz a necessidade de treinar modelos independentes para cada tarefa, otimizando tanto o desempenho quanto os recursos necessários para implantação e manutenção de sistemas em ambientes reais. O avanço em técnicas de ponderação para o MTL, juntamente com o desenvolvimento de modelos mais adaptativos, pode proporcionar ganhos significativos em eficiência e precisão. Além disso, há um potencial considerável para explorar a explicabilidade dos modelos multi-task, permitindo que pesquisadores e profissionais entendam melhor como as tarefas interagem e como as representações compartilhadas são formadas. Esses avanços podem beneficiar diversos setores, desde a indústria até a saúde, ampliando o impacto e as aplicações do aprendizado multi-task em problemas do mundo real. O objetivo geral deste projeto é realizar uma análise comparativa das técnicas de Multi-Task Learning (MTL) em bases de dados que possuem diferentes tarefas. Isso inclui avaliar a performance dessas técnicas em relação a modelos que realizam tarefas separadamente, bem como entender quais são as melhores abordagens para lidar com tarefas divergentes em bases de dados complexas. Além disso, este projeto também tem como objetivo contribuir para o entendimento geral do MTL, fornecendo uma revisão das principais abordagens e técnicas empregadas na área. Com isso, espera-se que este trabalho possa ser útil para pesquisadores e profissionais que desejam aplicar o MTL em seus projetos, bem como para aqueles que buscam ampliar seus conhecimentos sobre a área. Ao integrar essa análise com aplicações práticas, será possível identificar cenários nos quais o aprendizado multi-task pode oferecer vantagens significativas em termos de eficiência, generalização e alocação de recursos, permitindo uma compreensão mais profunda das interações entre as tarefas e das representações compartilhadas nos modelos desenvolvidos.

Referências Bibliográficas:

CHENNUPATI, S. et al. Multinet++: Multi-stream feature aggregation and geometric loss strategy for multi-task learning. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. [S.l.: s.n.], 2019.

CRAWSHAW, M.; KOŠECKÁ, J. Slaw: Scaled loss approximate weighting for efficient multi-task learning. arXiv preprint arXiv:2109.08218, 2021. Citado na página 12.

GONG, T. et al. A comparison of loss weighting strategies for multi task learning in deep neural networks. IEEE Access, v. 7, p. 141627–141632, 2019.

GUO, M. et al. Dynamic task prioritization for multitask learning. In: Proceedings of the European conference on computer vision (ECCV). [S.l.: s.n.], 2018.

KENDALL, A.; GAL, Y.; CIPOLLA, R. Multi-task learning using uncertainty to weigh losses for scene geometry and semantics. In: Proceedings of the IEEE conference on computer vision and pattern recognition. [S.l.: s.n.], 2018.

LAMPINEN, A. K.; GANGULI, S. An analytic theory of generalization dynamics and transfer learning in deep linear networks. arXiv preprint arXiv:1809.10374, 2018. Disponível em: <https://arxiv.org/abs/1809.10374>

LIEBEL, L.; KÖRNER, M. Auxiliary tasks in multi-task learning. arXiv preprint arXiv:1805.06334, 2018. Disponível em: <<https://arxiv.org/abs/1805.06334>>.

LIU, L. et al. Towards impartial multi-task learning. In: ICLR. [S.l.: s.n.], 2021.

LIU, S.; JOHNS, E.; DAVISON, A. J. End-to-end multi-task learning with attention. arXiv preprint arXiv:1803.10704, 2018. Disponível em: <<https://arxiv.org/abs/1803.10704>>.

LU, J. et al. 12-in-1: Multi-task vision and language representation learning. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S.l.: s.n.], 2020. p. 6448–6457.

NAVON, A.; SCHCLAR, A.; CHECHIK, G. Multi-task learning as a bargaining game. arXiv preprint arXiv:2202.01017, 2022.

SENER, O.; KOLTUN, V. Multi-task learning as multi-objective optimization. In: Advances in neural information processing systems. [S.l.: s.n.], 2018. p. 527–538.

SERMANET, P. et al. Overfeat: Integrated recognition, localization and detection using convolutional networks. In: International Conference on Learning Representations. [S.l.: s.n.], 2014.