Universidade Federal de Alagoas (UFAL)

Instituto de Computação (IC)

Programa de Pós-Graduação em Informática - PPGI

Tema para Pré-Projeto de Mestrado

Linha de pesquisa:	Computação Visual e Inteligente
Título:	Investigação e Mitigação do Esquecimento Catastrófico em Aprendizado Contínuo
Proponente:	Prof. Dr. Bruno Almeida Pimentel
Co-orientador:	Prof. Dr. Gustavo Henrique Ferreira de Miranda Oliveira

Descrição:

O aprendizado de máquina tem alcançado resultados expressivos em diversas aplicações, especialmente em tarefas de classificação e visão computacional. Entretanto, a maioria dos modelos é desenvolvida a partir de conjuntos de dados previamente disponíveis, pressupondo condições relativamente estáticas. Em aplicações reais, novos dados, padrões e classes surgem continuamente, exigindo que os sistemas sejam capazes de incorporar novas informações sem a necessidade de reiniciar todo o treinamento ou manter integralmente os dados históricos [1, 2, 3].

Nesse contexto, o Aprendizado Contínuo (Continual Learning) busca desenvolver modelos capazes de adquirir conhecimentos de maneira sequencial, preservando capacidades previamente aprendidas. Um dos principais desafios desse paradigma é o esquecimento catastrófico, caracterizado pela degradação do desempenho em tarefas anteriores após a aprendizagem de novas informações [1, 4]. Esse fenômeno está relacionado ao dilema entre estabilidade, necessária para preservar o conhecimento adquirido, e plasticidade, indispensável para incorporar novos padrões [1, 2].

Para enfrentar esse desafio, diferentes estratégias têm sido propostas na literatura, incluindo métodos baseados em regularização, repetição de exemplos anteriores (replay) e adaptações arquiteturais [1, 2, 3]. Essas abordagens são investigadas em diferentes cenários de Aprendizado Contínuo, como a incorporação progressiva de novas classes, tarefas ou domínios. Entretanto, sua eficácia depende das características dos dados, das configurações experimentais e dos recursos computacionais disponíveis, tornando a mitigação do esquecimento catastrófico um problema ainda relevante.

Apesar dos avanços na área, ainda existem desafios relacionados à compreensão dos mecanismos responsáveis pelo esquecimento e ao desenvolvimento de estratégias capazes de equilibrar a aquisição de novos conhecimentos e a preservação dos anteriores. Além disso, avaliações baseadas predominantemente em métricas agregadas podem ocultar alterações importantes no comportamento dos modelos ao longo do treinamento [6, 7]. Dessa forma,

investigar a evolução do desempenho e das representações aprendidas pode fornecer informações relevantes para orientar mecanismos adaptativos de aprendizagem.

Diante desse cenário, este tema de pesquisa visa investigar o esquecimento catastrófico em Aprendizado Contínuo e propor estratégias adaptativas para sua mitigação. Inicialmente, pretende-se analisar e comparar métodos representativos da literatura em diferentes cenários de aprendizagem sequencial. A partir dessas análises, busca-se investigar como mudanças no comportamento dos modelos ao longo do treinamento podem ser utilizadas para orientar mecanismos de adaptação, visando preservar conhecimentos anteriores sem comprometer a aquisição de novas informações.

A metodologia envolverá experimentos com conjuntos de dados de referência, considerando diferentes sequências de aprendizagem, níveis de complexidade e restrições computacionais. As estratégias propostas serão comparadas com métodos existentes por meio de métricas de desempenho, esquecimento, robustez e eficiência computacional. Espera-se, assim, contribuir para a compreensão do esquecimento catastrófico e para o desenvolvimento de modelos de Aprendizado Contínuo mais robustos, eficientes e capazes de se adaptar a ambientes dinâmicos.

Referências Bibliográficas:

[1] WANG, Liyuan et al. A Comprehensive Survey of Continual Learning: Theory, Method and Application. arXiv:2302.00487, versão 3, 2024.

[2] DE LANGE, Matthias et al. A continual learning survey: Defying forgetting in classification tasks. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2021. DOI: 10.1109/TPAMI.2021.3057446.

[3] ZHOU, Da-Wei et al. Class-Incremental Learning: A Survey. arXiv:2302.03648, versão 2, 2024.

[4] GOODFELLOW, Ian J. et al. An empirical investigation of catastrophic forgetting in gradient-based neural networks. arXiv:1312.6211, 2013.

[5] VAN DE VEN, Gido M.; TOLIAS, Andreas S. Three scenarios for continual learning. arXiv:1904.07734, 2019.

[6] SARMENTO, Gabriel F. et al. Understanding Catastrophic Forgetting: A Three-Axis Structural Analysis in Class-Incremental Learning. Manuscrito fornecido pelo proponente, s.d.

[7] LEITE, Liedson D. O. et al. M³-CIL: A Multidimensional Evaluation Protocol for Class-Incremental Learning. Manuscrito fornecido pelo proponente, s.d.

[8] KIRKPATRICK, James et al. Overcoming catastrophic forgetting in neural networks. Proceedings of the National Academy of Sciences, v. 114, n. 13, p. 3521–3526, 2017.

[9] REBUFFI, Sylvestre-Alvise et al. iCaRL: Incremental Classifier and Representation Learning. Proceedings of CVPR, 2017.

[10] YU, Dianzhi et al. Recent Advances of Multimodal Continual Learning: A Comprehensive Survey. arXiv:2410.05352, versão 2, 2024.