

# Avaliação de Abordagens de Aprendizagem Profunda para Cenários com Mudanças de Conceito

Antonio Michel Ferreira dos Santos<sup>a,b</sup>, André Gustavo Hochuli<sup>a</sup>, Jean Paul Barddal<sup>a</sup>

<sup>a</sup>*Programa de Pós-Graduação em Informática (PPGIA), Pontifícia Universidade Católica do Paraná (PUCPR), Curitiba, PR, Brasil*

<sup>b</sup>*Autor para correspondência: antonio.fsantos@ppgia.pucpr.br*

---

*Palavras-chaves:* Fluxos de Dados, Mudanças de Conceitos, Aprendizagem Profunda

---

A mineração de fluxos de dados tem adquirido cada vez maior importância em diversas aplicações cotidianas, como detecção de fraudes financeiras, combate a *spam* e *phishing*, e sistemas de recomendação em plataformas de *e-commerce* e *streaming*. Cenários envolvendo fluxos contínuos de dados apresentam duas principais restrições significativas: restrição de uso de memória e de tempo de processamento. Um dos principais desafios nesse campo é lidar com mudanças de conceito, que devem ser prontamente identificadas e demandam adaptações nos modelos utilizados. As mudanças de conceito ocorrem quando a distribuição dos dados se altera ao longo do tempo, comumente resultando em uma modificação na fronteira de decisão entre as classes do problema. Por outro lado, a área de aprendizagem profunda, embora em constante evolução e amplamente utilizada em diversos problemas envolvendo técnicas na área de inteligência artificial, não é comumente aplicada em trabalhos que abordam fluxos de dados e mudanças de conceito. Isso se deve, sobretudo, às restrições inerentes a um cenário de fluxos de dados e ao fenômeno conhecido como “*Catastrophic Forgetting*”. Nesse fenômeno, à medida que a rede tem seus pesos atualizados, as distribuições e características anteriores dos dados são esquecidas pelo modelo. Isso pode não ser desejável em certos casos de fluxos de dados, especialmente quando mudanças de conceito são recorrentes, cenário onde seria de grande valia possuir o modelo adaptado à um cenário passado que irá voltar a ocorrer, agilizando a resposta à mudança de conceito e consequentemente adaptação do modelo. O objetivo desta pesquisa é avaliar se o aumento de dados proporcionado por Redes Neurais Generativas Adversárias (GANs) proporciona resultados promissores em termos de qualidade preditiva e tempo de resposta razoável diante de mudanças de conceito em um ambiente de fluxo contínuo de imagens, em comparação com as técnicas de aumento de dados convencionais. Com isso, podemos explorar o efeito de “*catastrophic forgetting*” sofrido pela rede GAN, proporcionando o aumento de dados para o modelo implementado de acordo com a atual distribuição das classes do problema, possuindo assim o potencial de aprimorar significativamente o tempo de resposta do classificador às mudanças de conceito observadas.