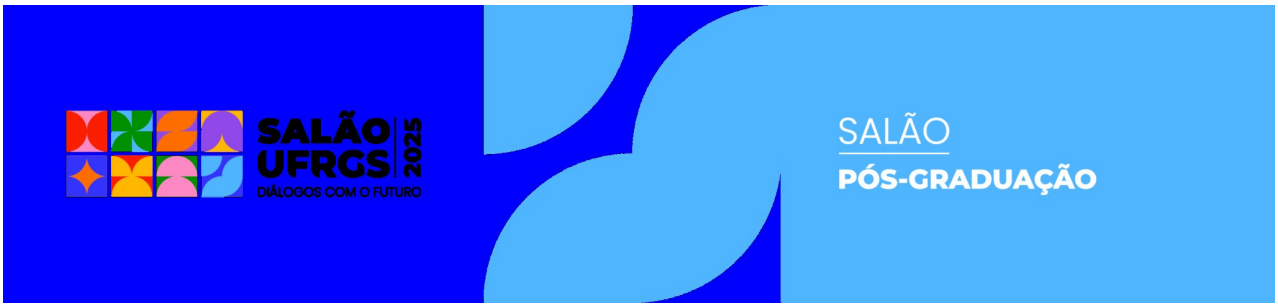


Evento	Salão UFRGS 2025: I SALÃO DA PÓS-GRADUAÇÃO
Ano	2025
Local	Campus do Vale - UFRGS
Título	Construindo modelos de visão robustos em ambientes com escassez de dados por meio da expansão controlada de conjuntos de dados de imagens
Autor	MATHEUS VINÍCIUS TODESCATO
Orientador	JOEL LUIS CARBONERA

RESUMO: Avanços recentes em aprendizado profundo, particularmente com grandes modelos de base pré-treinados, como aqueles baseados em arquiteturas *transformers*, alcançaram sucesso notável em áreas como PLN e Visão Computacional, demonstrando forte generalização de *zero-shot* e *few-shot*. No entanto, sua aplicação em áreas específicas de domínio, como imagens médicas, é limitada pela escassez de dados de treinamento especializados. O processo de rotulagem desses dados é trabalhoso, propenso a erros e requer conhecimento especializado, deixando grandes quantidades de dados não rotulados subutilizados. Essa situação limita severamente o desempenho de abordagens de aprendizado puramente supervisionado em contextos específicos de domínio. Embora métodos semi-supervisionados sejam uma alternativa, eles frequentemente assumem erroneamente que todos os dados não rotulados são úteis, ignorando o risco de contaminação por amostras de fora da distribuição, o que pode representar uma falha crítica em aplicações sensíveis. A detecção dessas amostras de fora da distribuição é, portanto, essencial para qualquer sistema robusto de aprendizado no mundo real e permite a aplicação seletiva de técnicas de aprendizado semi-supervisionado, melhorando o desempenho do modelo dentro do domínio alvo e minimizando o impacto de dados irrelevantes ou ruidosos. Dado essa perspectiva, esta pesquisa visa abordar essa lacuna crítica, integrando a detecção de amostras de fora da distribuição (*OOD detection*) com o aprendizado semi-supervisionado, propondo uma estrutura leve, modular e adaptável, projetada para ambientes com escassez de dados visuais. Nosso objetivo é projetar e implementar um método para *OOD detection* de alto desempenho, porém computacionalmente eficiente, capaz de operar nos modos *zero-shot* e *few-shot* e, em seguida, integrar esse mecanismo em um processo iterativo de expansão controlada do conjunto de dados usando técnicas de aprendizado semi-supervisionado. Para atingir o objetivo geral desta pesquisa, revisamos a literatura para identificar abordagens de última geração que lidem com as questões que são o foco desta pesquisa. Com base nessa investigação, foi possível identificar lacunas de pesquisa relacionadas à *OOD detection*. Para lidar com cenários de *zero-shot* e *few-shot*, várias abordagens fazem uso de poderosos modelos pré-treinados, como o CLIP. Vários métodos baseados em CLIP representam o estado-da-arte em *OOD detection* para *zero-shot*, incluindo MCM, GL-MCM, CLIPN e ZOC. No entanto, esses métodos têm limitações: alguns deles dependem fortemente do desempenho do CLIP (MCM e GL-MCM), enquanto outros (CLIPN e ZOC) tentam mitigar essa dependência treinando modelos auxiliares, tornando-os intensivos em dados e suscetíveis a *overfitting* específico de domínio. Identificar e entender esses desafios inspirou uma nova abordagem para *OOD detection*. Desenvolvemos essa nova abordagem chamada *Self-Learning OOD Detection* (SL-OOD), que minimiza os custos de treinamento treinando apenas um classificador leve em vez de um modelo auxiliar inteiro. O SL-OOD utiliza um ciclo de auto-aprendizagem para treinar o classificador usando modelos pré-treinados e uma estratégia para atribuir pseudo-rótulos aos dados. Desenvolvemos uma estratégia baseada na análise estatística dos *logits* de saída do classificador treinado para estimar a probabilidade de uma amostra estar fora de distribuição. Avaliações experimentais em conjuntos de dados de referência demonstram que o SL-OOD supera os métodos de detecção *zero-shot* de última geração, ao mesmo tempo em que oferece uma estrutura de detecção modular e versátil. Em trabalhos futuros, planejamos: aprimorar a abordagem SL-OOD, desenvolver novas abordagens para a detecção de amostras de fora da distribuição em *zero-shot* e integrar o aprendizado semi-supervisionado ao *pipeline* para, finalmente, expandir os conjuntos de dados.

PALAVRAS-CHAVE: Visão Computacional; Expansão de Conjuntos de Dados; Aprendizado Semi-supervisionado.