



**UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA**

Autorizada pelo Decreto Federal nº 77.496 de 27/04/76  
Recredenciamento pelo Decreto nº 17.228 de 25/11/2016



**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO**  
COORDENAÇÃO DE INICIAÇÃO CIENTÍFICA

## **XXIX SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS** **SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2025**

### **Investigação de Self-Supervised Learning para classificação de lesões em glomérulos renais**

**Anésio Sousa dos Santos Neto<sup>1</sup>; Angelo Amancio Duarte**<sup>2</sup>

1. Anésio Sousa dos Santos Neto, PVIC/UEFS, ENGENHARIA DE COMPUTAÇÃO, e-mail: 17111205@discente.uefs.br

2. Angelo Amancio Duarte, DEPARTAMENTO DE TECNOLOGIA, e-mail: angeloduarte@uefs.br


**PALAVRAS-CHAVE:** Patologia computacional; Aprendizado de Máquina; Processamento de imagens

### **INTRODUÇÃO**

As doenças renais crônicas exigem análise histopatológica detalhada dos glomérulos, mas o diagnóstico enfrenta desafios como divergência entre especialistas, tempo elevado e variações de corantes (Haas, 2020; Tiard, 2022). Além disso, métodos supervisionados dependem de grandes volumes de dados rotulados, o que torna o processo custoso e difícil (Stacke, 2021; Oliveira, 2022).

### **MATERIAL E MÉTODOS OU METODOLOGIA (ou equivalente)**


O estudo segue a visão original de Arthur Samuel (1949), que defendeu o aprendizado a partir de dados. Essa ideia evoluiu para redes neurais modernas treinadas com algoritmos como Stochastic Gradient Descent. A Figura 1 resume o processo moderno de treinamento (Howard, 2020).



**Figura 1:** Treinamento de um modelo de aprendizado de máquina

O dataset utilizado, concedido pela FIOCRUZ, contém 3346 imagens histológicas em diferentes colorações, como Hematoxilina-Eosina (HE), PAS, AZAN e PAMS, cada uma trazendo desafios específicos para a padronização e análise automatizada. Na Figura 2 podemos ver algumas amostras do dataset.

Foram usadas técnicas de *data augmentation* (recortes aleatórios e rebatimentos) no pré-treinamento auto-supervisionado para gerar representações mais invariantes. Isso reduz variações não semânticas e melhora a generalização do modelo.



**Figura 2:** Samples do dataset

No SSL, o **SimCLR** usa *augmentations* e amostras negativas para aprender representações, enquanto o **BYOL** dispensa amostras negativas e emprega redes gêmeas com atualização por média móvel. Ambos foram usados no pré-treinamento não supervisionado, seguido de *fine-tuning* com classificadores binários em esquema 1-vs-all, combinando representações robustas com refinamento supervisionado para melhorar o desempenho diagnóstico.

A avaliação dos modelos foi realizada por validação cruzada estratificada (k-fold), com F1-score como métrica central, complementado por AUROC, AP e matrizes de confusão para maior detalhamento. Essa metodologia assegura comparações justas entre os modelos, além de lidar com o desbalanceamento das classes por oversampling.

**RESULTADOS E/OU DISCUSSÃO (ou Análise e discussão dos resultados)**

A análise dos resultados mostrou que o dataset apresenta forte desequilíbrio entre classes e variações de corantes, reforçando a importância do uso de *oversampling* e da calibragem de limiares para maximizar o F1. Na Tabela 1 pode-se observar a distribuição das classes do dataset.

| Classe                          | Total | Subclasse (Corante) | Imagens |
|---------------------------------|-------|---------------------|---------|
| 0_endocapillaryHypercellularity | 92    | HE                  | 92      |
| 1_endomesagialHypercellularity  | 179   | HE                  | 179     |
| 2_membranous                    | 715   | AZAM                | 75      |
|                                 |       | HE                  | 315     |
|                                 |       | PAMS                | 234     |
|                                 |       | PAS                 | 91      |
| 3_mesangialHypercellularity     | 238   | HE                  | 238     |
| 4_normal                        | 1515  | AZAM                | 159     |
|                                 |       | HE                  | 769     |
|                                 |       | PAMS                | 237     |
|                                 |       | PAS                 | 350     |
| 5_sclerosis                     | 607   | AZAM                | 18      |
|                                 |       | HE                  | 293     |
|                                 |       | PAMS                | 100     |
|                                 |       | PAS                 | 196     |

**Tabela 1:** Distribuição de imagens por classe e subclasse.

Nos experimentos, o SimCLR alcançou métricas finais ligeiramente superiores ( $F1 \approx 0,91$ ;  $AUROC \approx 0,97$ ;  $AP \approx 0,94$ ), beneficiando-se de seu aprendizado contrastivo explícito, embora dependente de batches grandes e sensível a *augmentations*. Já o BYOL apresentou resultados competitivos ( $F1 \approx 0,89$ ;  $AUROC \approx 0,95$ ;  $AP \approx 0,87$ ), com destaque para sua estabilidade trazida pelo uso de EMA e pela ausência de negativos, o que o torna menos suscetível a falsos negativos e mais eficiente em cenários com dados limitados.

| Método | Melhor Época ( <i>Unfreeze</i> ) | F1           | AUROC        | AP           |
|--------|----------------------------------|--------------|--------------|--------------|
| BYOL   | 20                               | <b>0.892</b> | 0.952        | 0.871        |
| SimCLR | 20                               | <b>0.911</b> | <b>0.972</b> | <b>0.943</b> |

**Tabela 2:** Resultados dos treinamentos dos modelos SSL

Comparando os métodos, o SimCLR se mostrou mais preciso em termos de separação de classes e ranqueamento, enquanto o BYOL demonstrou robustez e maior eficiência amostral, contornando pontos fracos do SimCLR como a alta demanda de memória e a dependência de *hyperparameters*. Assim, embora o SimCLR ainda tenha alcançado melhor desempenho quantitativo, o BYOL se destaca como uma alternativa mais viável e escalável para aplicações médicas em contextos de desbalanceamento e recursos restritos, sendo capaz de manter representações robustas mesmo sob condições mais adversas.

### CONSIDERAÇÕES FINAIS (ou Conclusão)

O objetivo desta pesquisa foi desenvolver classificadores de imagens de glomérulos renais baseados nos diferentes corantes utilizados em biópsias, aplicando aprendizado auto-supervisionado seguido de fine-tuning supervisionado. Os resultados mostraram que métodos como SimCLR e BYOL são promissores para classificação binária em esquema one-vs-all, mas avanços recentes, como o DINOv2 com Vision Transformers, apontam maior robustez e generalização ao lidar com variações de corantes e padrões morfológicos dispersos, superando limitações das CNNs em capturar dependências de longo alcance (OQUAB, 2023). Como próximos passos, a disponibilização dos modelos em sistemas web containerizados com Kubernetes pode ampliar sua acessibilidade e aplicabilidade clínica, garantindo escalabilidade, eficiência de recursos, portabilidade entre *cloud providers* e tolerância a falhas, acelerando o ciclo de vida de *machine learning* e assegurando reprodutibilidade (REDHAT, 2023)

## REFERÊNCIAS

OQUAB, M. et al. *DINOv2: Learning Robust Visual Features without Supervision*. [S.l.: s.n.], 2023. ArXiv preprint.

REDHAT. *How Kubernetes can help AI/ML*. 2023. Acesso em: 31/08/2025. Disponível em: <<https://www.redhat.com/en/topics/cloud-computing/how-kubernetes-can-help-ai>>

CHEN, T. et al. *A Simple Framework for Contrastive Learning of Visual Representations*. [S.l.], 2020. 1597–1607 p.

GRILL, J.-B. et al. *Bootstrap Your Own Latent: A New Approach to Self-Supervised Learning*. [S.l.: s.n.], 2020. 21271–21284 p.

HAAS, M. et al. *Chronic kidney disease: global public health challenge*. Journal of Nephrology, 2020.

HE, K. et al. *Momentum Contrast for Unsupervised Visual Representation Learning*. [S.l.: s.n.], 2020. 9729–9738 p.

HE, K. et al. *Deep Residual Learning for Image Recognition*. [S.l.: s.n.], 2016. 770–778 p.

HOWARD, J.; GUGGER, S. *Deep Learning for Coders with fastai and PyTorch: AI Applications Without a PhD*. O'Reilly Media, Inc., 2020. ISBN 9781492045526. Disponível em: <<https://book.fast.ai>>.

OLIVEIRA, L. et al. *Pathospotter: Automated classification of glomerular lesions*. Computational Pathology Journal, 2022.

STACKE, K. et al. *Self-supervised learning in medical imaging*. Medical Image Analysis, 2021.

TIARD, R. et al. *Challenges of histopathological image analysis*. In: Medical Imaging Conference. [S.l.: s.n.], 2022.