

Detecção e classificação morfológica de neutrófilos com redes neurais convolucionais para auxílio diagnóstico do desvio à esquerda

Luan Carlos Verteiro Pereira^{1*}, Vanessa Aparecida Feijó de Souza²

¹Graduando do Curso de Medicina Veterinária da Universidade São Judas Tadeu. São Paulo, São Paulo, Brasil.

²Professora do Curso de Medicina Veterinária da Universidade São Judas Tadeu. São Paulo, São Paulo, Brasil.

*Autor para correspondência, e-mail: luancarlosverteiro@outlook.com

Resumo. O desvio à esquerda é caracterizado pelo aumento de neutrófilos imaturos (bastonetes) na circulação sanguínea, indicando uma resposta medular a processos infecciosos ou inflamatórios agudos. A contagem de leucócitos e a diferenciação morfológica entre neutrófilos segmentados e bastonetes constituem etapas cruciais na triagem laboratorial. Embora existam analisadores hematológicos automatizados, esses equipamentos apresentam alto custo e enfrentam limitações na distinção morfológica celular, especialmente os modelos de três partes (3-DIFF). Essa limitação gera frequentes alertas no sistema (flags), exigindo que a triagem seja complementada pela contagem microscópica manual, um processo demorado e sujeito à variabilidade interobservador. Este estudo teve como objetivo avaliar a viabilidade da arquitetura de visão computacional YOLOv8 para a detecção e classificação dessas estruturas leucocitárias. Um conjunto de imagens microscópicas digitais, obtido na plataforma Kaggle, foi submetido à curadoria e anotação por meio do software Roboflow, utilizando técnicas de aumento de dados (data augmentation). O modelo foi treinado em ambiente de computação em nuvem utilizando o Google Colab. Os resultados indicaram desempenho promissor do algoritmo, demonstrando viabilidade técnica tanto na localização celular quanto na diferenciação entre neutrófilos bastonetes e segmentados, alcançando uma precisão média (Mean Average Precision – mAP50) de 0,90. Como prova de conceito, foi desenvolvido um protótipo de aplicação web para demonstrar a capacidade de inferência do modelo. Dessa forma, a tecnologia de Deep Learning apresenta potencial para auxiliar na diferenciação celular e, em desenvolvimentos futuros, sua integração direta a equipamentos de microscopia poderá atuar como uma ferramenta de apoio à padronização do diagnóstico do desvio à esquerda.

Palavras-chave: Bastonetes, deep learning, desvio à esquerda, hematologia veterinária, neutrófilos, YOLOv8.

Detection and morphological classification of neutrophils using convolutional neural networks to support left shift diagnosis

Abstract. A left shift is characterized by an increased number of immature neutrophils (band cells) in the bloodstream, indicating a bone marrow response to acute infection or inflammation. Leukocyte counting and the morphological differentiation between segmented and band neutrophils are crucial steps in laboratory screening. Although automated hematology analyzers are available, they are expensive and often face challenges in accurately distinguishing cell morphology, particularly in three-part differential (3-DIFF) systems. This limitation frequently generates system alerts (flags), requiring manual microscopic review to complement the analysis. However, manual counting is time-consuming and subject to interobserver variability. This study aimed to evaluate the feasibility of the YOLOv8 computer vision architecture for the detection and classification of neutrophils. A dataset of digital microscopic images obtained from the

Kaggle platform was curated and annotated using Roboflow software, with the application of data augmentation techniques. The model was trained in a cloud-computing environment using Google Colab. The results demonstrated promising algorithm performance, showing technical feasibility for both cell localization and differentiation between band and segmented neutrophils, achieving a Mean Average Precision (mAP50) of 0.90. Furthermore, a web-based application prototype was developed as a proof of concept to demonstrate the model's inference capabilities. These findings suggest that Deep Learning technology has significant potential for automated cellular differentiation. In future developments, its direct integration into microscopy systems may serve as a valuable tool for supporting and standardizing left shift diagnosis.

Keywords: Band neutrophils, left shift, veterinary hematology, neutrophils, deep learning, YOLOv8

Introdução

O desvio à esquerda é caracterizado pelo aumento de neutrófilos imaturos (bastonetes) na circulação sanguínea, indicando uma resposta medular a processos infecciosos ou inflamatórios agudos ([Eurell & Frappier, 2012](#); [Ferreira et al., 2014](#); [Paes et al., 2009](#)). Por essa razão, a contagem de leucócitos e a diferenciação morfológica entre neutrófilos segmentados e bastonetes constituem etapas cruciais do leucograma, sendo fundamentais para a triagem laboratorial e para a avaliação da resposta imune na rotina clínica veterinária ([Thrall et al., 2022](#)).

Embora existam analisadores hematológicos automatizados, esses equipamentos apresentam alto custo e limitações na distinção de características nucleares sutis, especialmente nos modelos de três partes (3-DIFF), o que frequentemente exige a realização da contagem microscópica manual. Esse procedimento, por sua vez, está sujeito à subjetividade e à variabilidade inter observador ([Borges & Siqueira, 2009](#)).

Com o avanço das tecnologias aplicadas à saúde, técnicas de aprendizado de máquina (Machine Learning) e aprendizado profundo (Deep Learning) têm se destacado na automação de processos laboratoriais e na análise de imagens médicas ([Makrai et al., 2023](#); [Souza et al., 2019](#)). Essas abordagens vêm sendo empregadas em diferentes contextos diagnósticos, incluindo a identificação de tumores, câncer de pulmão, anemia, leucemia, malária e alterações hematológicas por meio de imagens microscópicas e outras modalidades de imagem ([Asghar et al., 2024](#); [González-Recio et al., 2009](#)). Na hematologia, a classificação automatizada de leucócitos em esfregaços sanguíneos tem sido apontada como uma das principais aplicações desses sistemas, uma vez que pode reduzir a carga de trabalho dos profissionais, acelerar a triagem e contribuir para a padronização dos resultados laboratoriais ([Asghar et al., 2024](#)).

A revisão global conduzida por [Asghar et al. \(2024\)](#) sobre a classificação de leucócitos por aprendizado de máquina e Deep Learning identificou 136 estudos publicados entre 2006 e maio de 2023, evidenciando uma tendência crescente no uso de redes neurais convolucionais para segmentação e classificação de células sanguíneas. Os autores destacam que a análise manual de esfregaços sanguíneos é lenta, trabalhosa e suscetível a erros, reforçando a importância de sistemas computacionais capazes de fornecer resultados mais rápidos, objetivos e reprodutíveis. Além disso, o estudo aponta que técnicas como transfer learning e data augmentation têm sido amplamente utilizadas para melhorar o desempenho dos modelos, especialmente diante da limitação de bancos de imagens adequados.

No contexto veterinário, aplicações semelhantes também vêm sendo exploradas. [Baruah et al. \(2025\)](#) desenvolveram um sistema automatizado para a detecção de *Babesia gibsoni* em esfregaços sanguíneos de cães, utilizando redes neurais convolucionais associadas ao aprendizado contrastivo. O modelo EfficientNet-B2 alcançou acurácia aproximada de 97%, demonstrando que a análise automatizada de imagens microscópicas pode auxiliar no diagnóstico de hemoparasitoses, especialmente em locais com escassez de especialistas ou com necessidade de resultados rápidos.

Diante desse cenário, o presente estudo propõe a aplicação da técnica de transfer learning em um conjunto de imagens hematológicas digitais previamente curado e submetido a técnicas de aumento de dados (data augmentation) para mitigar desequilíbrios amostrais. O objetivo foi treinar um modelo de

rede neural convolucional para a detecção e classificação automatizada de neutrófilos segmentados e bastonetes, avaliando sua viabilidade técnica como ferramenta de auxílio à triagem laboratorial e à otimização do tempo de resposta no diagnóstico veterinário.

Material e métodos

As imagens utilizadas neste estudo foram obtidas a partir de um banco de dados hematológico público (*Blood Cell Images*), disponível na plataforma Kaggle, e submetidas previamente a um processo de filtragem para isolar exclusivamente imagens contendo neutrófilos. O conjunto amostral final foi composto por 145 imagens microscópicas digitais. Posteriormente, esse conjunto foi importado para o software Roboflow ([Roboflow, 2025](#)), onde foi realizada a curadoria manual e a classificação morfológica das células.

As estruturas previamente catalogadas de forma genérica foram individualmente reanotadas em duas classes específicas: "bastonete", caracterizada por núcleo em formato de "C" ou bastão espesso, e "segmentado", caracterizada por núcleo subdividido em lóbulos interligados por constrições finas. Para o desenvolvimento do modelo, as imagens foram divididas em 70% para treinamento, 20% para validação e 10% para teste, garantindo a presença de ambas as classes em todas as partições e preservando a integridade estatística do processo de aprendizagem da rede neural.

A curadoria e a anotação das imagens permitiram a definição das regiões de interesse (*bounding boxes*), delimitadas manualmente para classificar as estruturas nucleares como bastonete ou segmentado ([Figura 1](#)). A distribuição quantitativa dessas anotações e a relação entre as variáveis do conjunto de treinamento são apresentadas na [figura 2](#).




Figura 1. Processo de curadoria manual e anotação morfológica das células por meio de caixas delimitadoras (*bounding boxes*) na plataforma Roboflow.

O treinamento da rede neural artificial baseou-se na arquitetura do modelo YOLOv8 (Ultralytics, Los Angeles, CA, EUA), aplicando a técnica de *transfer learning*. Todo o processamento computacional foi executado em ambiente de nuvem por meio da plataforma Google Colab (Google LLC, Mountain View, CA, EUA), utilizando um acelerador de hardware (T4 GPU). Os hiperparâmetros do modelo foram definidos para redimensionar as imagens padronizadas em 640 x 640 *pixels*. O algoritmo foi configurado com um tamanho de lote (*batch size*) de 16, programado para um treinamento de 100 épocas (*epochs*). Aplicou-se o recurso de parada antecipada (*early stopping*) com uma tolerância (*patience*) de 20 épocas, visando interromper o processamento caso o modelo não apresentasse evolução nas métricas de perda, garantindo assim a eficiência computacional e prevenindo o sobre ajuste (*overfitting*) dos dados.




Figura 2. Correlograma e distribuição quantitativa das anotações celulares por classe (bastonete e segmentado) referentes ao conjunto de dados de treinamento.

Resultados

O processamento do modelo YOLOv8 demonstrou desempenho promissor, apresentando rápida convergência e estabilidade durante o treinamento. A avaliação das métricas indicou que a rede neural alcançou uma Precisão Média (mAP50) de 0,90 na 39ª época.

A [figura 3](#) ilustra o comportamento das curvas de treinamento e validação, evidenciando a redução progressiva e a posterior estabilização das métricas de perda (*loss*). Esses resultados confirmam a capacidade do modelo de localizar com precisão as estruturas celulares e classificá-las corretamente. Além disso, não foram observados indícios significativos de sobreajuste (*overfitting*), sugerindo boa capacidade de generalização para os dados utilizados neste estudo.

A matriz de confusão ([Figura 4](#)) forneceu uma avaliação detalhada do desempenho do classificador. O modelo demonstrou viabilidade técnica na identificação de neutrófilos bastonetes, registrando 15 classificações corretas para essa categoria. A principal fonte de erro foi observada na diferenciação entre neutrófilos bastonetes e segmentados, com oito instâncias de classificação incorreta entre essas classes.

Esse resultado é biologicamente plausível e clinicamente esperado, uma vez que a distinção morfológica entre bastonetes e segmentados pode ser desafiadora devido à natureza contínua do

processo de segmentação nuclear, no qual existem formas intermediárias que dificultam uma categorização inequívoca. Tal limitação é amplamente reconhecida na hematologia veterinária e também pode contribuir para divergências entre observadores humanos.




Figura 3. Evolução das métricas de treinamento e validação ao longo das épocas, evidenciando a estabilização do aprendizado e o incremento da Precisão Média (mAP50), sem evidências expressivas de sobre ajuste durante o treinamento.

Adicionalmente, a taxa de confusão com a classe *background* (fundo da imagem) foi mínima, indicando elevada capacidade do modelo em distinguir as células de interesse dos demais elementos presentes no esfregaço sanguíneo. Esse desempenho sugere que as estratégias de aumento de dados (*data augmentation*) empregadas durante o treinamento contribuíram para aumentar a robustez do modelo frente a variações de iluminação, artefatos e detritos microscópicos, permitindo que a rede concentrasse sua atenção principalmente nas características nucleares relevantes para a classificação celular.




Figura 4. Matriz de confusão para avaliação quantitativa da performance do classificador na distinção entre neutrófilos bastonetes, segmentados e fundo da imagem (*background*).

Para consolidar os resultados obtidos durante o treinamento e demonstrar a viabilidade prática do algoritmo, os pesos finais do modelo YOLOv8 foram integrados a uma aplicação web interativa. As [figuras 5](#) e [6](#) ilustram o funcionamento da interface desenvolvida, que permite a submissão de microfotografias de esfregaços sanguíneos para análise computacional em tempo real.

Após o processamento da imagem, o sistema realiza automaticamente a detecção e classificação das células, projetando caixas delimitadoras (*bounding boxes*) acompanhadas dos respectivos índices de confiança para as classes de neutrófilos segmentados e bastonetes. O protótipo desenvolvido demonstra a aplicabilidade técnica do modelo, evidenciando a transição bem-sucedida do ambiente experimental de treinamento para uma ferramenta com potencial de utilização prática.

Esses resultados reforçam a possibilidade de integração de técnicas de visão computacional à microscopia laboratorial de rotina, disponibilizando um recurso auxiliar de baixa complexidade operacional para apoio à avaliação hematológica. Além disso, a ferramenta apresenta potencial para complementar a análise microscópica convencional e minimizar limitações inerentes aos analisadores hematológicos de três partes (3-DIFF), particularmente na diferenciação morfológica de neutrófilos.




Figura 5. Interface do protótipo computacional demonstrando a inferência do modelo em tempo real, com a sobreposição de *bounding boxes* e os respectivos índices de confiança para a classe identificada (segmentado). Disponível em: <https://luan-tcc-hematologia.streamlit.app>.




Figura 6. Interface do protótipo computacional demonstrando a inferência do modelo em tempo real, com a sobreposição de *bounding boxes* e os respectivos índices de confiança para a classe identificada (bastonete). Disponível em: <https://luan-tcc-hematologia.streamlit.app>.

Discussão

A aplicação da arquitetura de *Deep Learning* YOLOv8 demonstrou ser uma ferramenta tecnicamente viável e promissora para a identificação e classificação morfológica de neutrófilos em microfotografias de esfregaços sanguíneos. O modelo computacional treinado foi capaz de mitigar as ambiguidades estruturais intrínsecas à diferenciação entre neutrófilos bastonetes e segmentados, alcançando uma Precisão Média (mAP50) de 0,90. Este desempenho é considerado satisfatório para uma prova de conceito baseada em um conjunto amostral reduzido.

A precisão obtida reforça o argumento de [Black et al. \(2025\)](#), que sublinham que a eficácia de sistemas automatizados em hematologia é diretamente proporcional à qualidade da curadoria das imagens, e não apenas à quantidade bruta de dados. No presente estudo, o uso de 145 microfotografias selecionadas e submetidas a *data augmentation* permitiu que o algoritmo mantivesse a estabilidade diante de variações de coloração e luminosidade, comuns na rotina laboratorial. Contudo, é importante reconhecer que o tamanho amostral reduzido constitui uma limitação deste estudo. Assim, desenvolvimentos futuros deverão expandir o *dataset* para incluir uma maior diversidade de espécies e padrões de coloração de diferentes centros laboratoriais para aumentar a capacidade de generalização do modelo.

A distinção entre neutrófilos bastonetes e segmentados permanece como um dos principais gargalos na hematologia manual devido à existência de células em estágios intermediários de maturação. ([Borges & Siqueira, 2009](#)) afirmam que a subjetividade do observador é o fator que mais contribui para a discrepância entre laudos de diferentes patologistas. Ao utilizar a arquitetura YOLOv8 para padronizar essa classificação, este estudo demonstra que a visão computacional pode reduzir a variabilidade inter observador, fornecendo um critério computacional padronizado para auxiliar na identificação do desvio à esquerda.

Como desdobramento prático, os pesos do modelo foram integrados a uma aplicação *web* interativa. Esta interface demonstra a viabilidade de transformar a investigação acadêmica numa ferramenta auxiliar para o clínico, permitindo a execução da inferência de forma intuitiva. Tal como indicado por ([Souza et al., 2019](#)), o uso de redes neurais convolucionais para análise de imagens médicas possui potencial para auxiliar o diagnóstico clínico e otimizar o tempo de resposta laboratorial.

Conclusão

O presente trabalho demonstrou a viabilidade técnica da arquitetura *Deep Learning* YOLOv8 na diferenciação morfológica automatizada entre neutrófilos bastonetes e segmentados. A integração do modelo a uma aplicação web demonstrou o seu potencial prático como prova de conceito para a rotina laboratorial veterinária, oferecendo um método capaz de mitigar a variabilidade inter observador, auxiliando no diagnóstico do desvio à esquerda. Embora a ampliação e diversificação do banco de imagens sejam premissas para validações clínicas futuras, a visão computacional apresenta-se como um recurso auxiliar promissor, capaz de contribuir para a redução da variabilidade inter observador e para a padronização diagnóstica na microscopia de rotina.

Referências

- Asghar, R., Kumar, S., Shaukat, A., & Hynds, P. (2024). Classification of white blood cells (leucocytes) from blood smear imagery using machine and deep learning models: A global scoping review. *PLoS ONE*, 19(6), e0292026. <https://doi.org/10.1371/journal.pone.0292026>.
- Baruah, D. K., Boruah, K., Barman, N. N., Deka, A., Bharali, A., & Buragohain, L. (2025). Automated Detection of Canine Babesia Parasite in Blood Smear Images Using Deep Learning and Contrastive Learning Techniques. *Parasitologia*, 5(2). <https://doi.org/10.3390/parasitologia5020023>.
- Black, F. S., Melo, A. J. P., Giordani, T. S., Cripa, F. B., Scapin, D., & Machado, L. P. (2025). Estudo Comparativo da Contagem Diferencial de Leucócitos por Microscopia e por Analisador Hematológico Automático. *Revista Ibero-Americana de Humanidades, Ciências e Educação*, 11(3), 2164–2174. <https://doi.org/10.51891/rease.v11i3.18545>.

- Borges, L. F., & Siqueira, L. O. (2009). Validação de tecnologia 5diff do analisador hematológico sysmex XS-1000i para laboratório de pequeno/médio porte. *Revista Brasileira de Hematologia e Hemoterapia*, 31(4), 231–236. <https://doi.org/10.1590/s1516-84842009005000059>.
- Eurell, J. A., & Frappier, B. L. (2012). *Histologia Veterinária de Dellmann* (Vol. 1). Guanabara Koogan.
- Ferreira, Â. M., Castro, M. L. R., Murador, P., Ramos, R. J., & Castilho, S. L. (2014). Imuno-hematologia laboratorial. In *Ministério da Saúde* (Vol. 1).
- González-Recio, O., Maturana, E. L., Vega, A. T., Engelman, C. D., & Broman, K. W. (2009). Detecting single-nucleotide polymorphism by single-nucleotide polymorphism interactions in rheumatoid arthritis using a two-step approach with machine learning and a Bayesian threshold least absolute shrinkage and selection operator (LASSO) model. *BMC Proceedings*, 3(7), S63.
- Makrai, L., Fodróczy, B., Nagy, S. Á., Czeiszing, P., Csabai, I., Szita, G., & Solymosi, N. (2023). Annotated dataset for deep-learning-based bacterial colony detection. *Scientific Data*, 10(1). <https://doi.org/10.1038/s41597-023-02404-8>.
- Paes, P. R. O., Leme, F. O. P., & Carneiro, R. A. (2009). Hematologia dos animais domésticos. *FEPMVZ, Caderno Didático*.
- Roboflow. (2025). *Roboflow: Computer Vision Platform*. Roboflow Inc., Des Moines, IA, USA. Disponível em: <https://roboflow.com>.
- Souza, E. P., Gomes, C. M., Barroso, D. H., Miranda, V. L., & Gurgel-Gonçalves, R. (2019). Aplicações do Deep Learning para diagnóstico de doenças e identificação de insetos vetores. *Saúde em Debate*, 43(spe2), 147–154. <https://doi.org/10.1590/0103-11042019s211>.
- Thrall, M. A., Weiser, G., Allison, R. W., & Campbell, T. W. (2022). *Veterinary hematology, clinical chemistry, and cytology*. John Wiley & Sons.

Histórico do artigo:**Recebido:** 7 de abril de 2026**Aprovado:** 31 de maio de 2026**Licenciamento:** Este artigo é publicado na modalidade Acesso Aberto sob a licença Creative Commons Atribuição 4.0 (CC-BY 4.0), a qual permite uso irrestrito, distribuição, reprodução em qualquer meio, desde que o autor e a fonte sejam devidamente creditados.