



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

XXVIII SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2024

Investigação de métodos “few-shot learning” na construção de classificadores de lesões glomerulares renais raras

**Lyrton Marcell Dias Amorim¹; Michele Fulvia Angelo²; Angelo Amancio
Duarte³**

1. Bolsista – Modalidade Bolsa/PROBIC, Graduando em Engenharia de Computação, Universidade Estadual de Feira de Santana, e-mail: lymarcell@gmail.com
2. Orientadora, Departamento de Tecnologia, Universidade Estadual de Feira de Santana, e-mail: mfangelo@uefs.br
3. Co-orientador, Departamento de Tecnologia, Universidade Estadual de Feira de Santana, e-mail: angeloduarte@uefs.br

PALAVRAS-CHAVE: Few-Shot Learning; Aprendizado de Máquina; Classificação de Imagens Médicas.

INTRODUÇÃO

De acordo com a Sociedade Brasileira de Nefrologia (SBN), a prevalência da doença renal crônica é significativa, afetando 7,2% dos indivíduos acima de 30 anos e entre 28% e 46% das pessoas com mais de 64 anos. No Brasil, mais de dez milhões de pessoas vivem com a doença, e cerca de 90 mil dependem de diálise quando a função renal está abaixo de 10%. O trabalho visa criar um classificador utilizando Few-Shot Learning para a classificação de lesões glomerulares em imagens médicas. O estudo emprega a ResNet-50 para extração de características e validação cruzada para garantir a precisão e robustez do modelo. Além disso, são implementadas Redes Prototípicas, cálculos de métricas de distância e a abordagem N-way K-shot para treinar o modelo com poucos exemplos.

METODOLOGIA

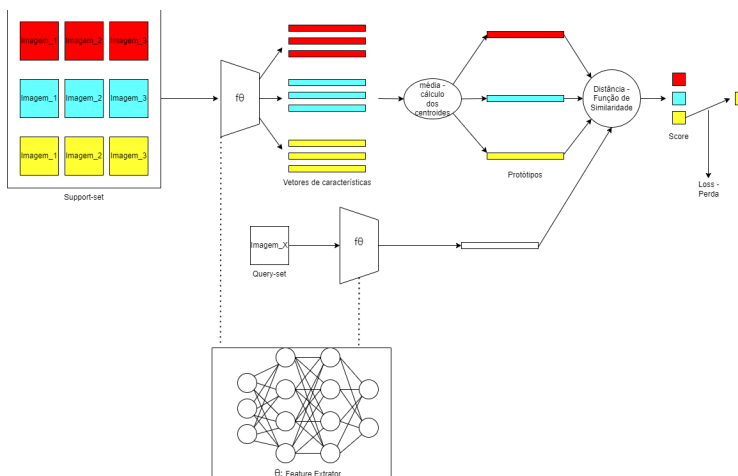


Figura 1: Arquitetura do experimento.

O estudo implementou e avaliou métricas como precisão, recall, F1-score e matriz de confusão, fundamentado por uma revisão bibliográfica sobre o estado da arte do Few-Shot Learning para lesões glomerulares. O conjunto de dados, desbalanceado e com poucas amostras, reflete a realidade clínica. Foram utilizadas Redes Prototípicas para criar protótipos de classes com base em embeddings de treinamento e as distâncias Manhattan, Euclidiana e Cosseno para medir similaridades. A metodologia N-way K-shot foi empregada para treinamento com poucos exemplos por classe. A padronização dos dados e a ResNet-50 como extrator de características aprimoraram a precisão e robustez do modelo e por fim a validação cruzada garantiu a capacidade de generalização e evitou sobreajuste, resultando em uma avaliação mais confiável.

RESULTADOS E/OU DISCUSSÃO

O primeiro experimento foi realizado com o dataset completo, com todos os corantes e utilizando a distância cosseno.

Accuracy	0.8539±0.0271
Precision	0.8592±0.0242
Recall	0.8539±0.0271
F1 Score	0.8532±0.0278
MCC	0.7130±0.0533

Tabela 1. Média com desvio padrão das métricas calculadas para os 5 folds do 1º experimento.

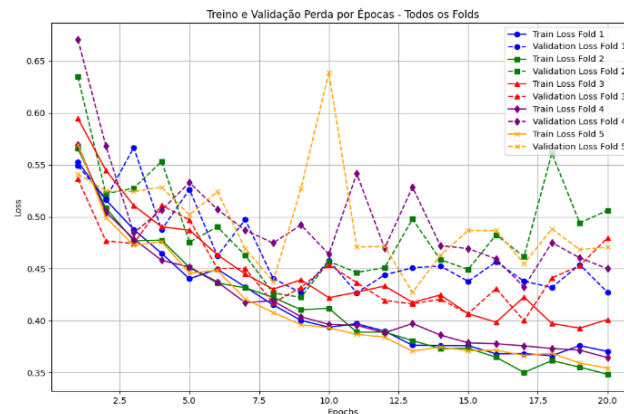


Figura 2: Perda de treino e validação de todos os folds do 1º experimento.

O resultado final foi obtido a partir de um teste realizado com 20% do conjunto de dados, após o processo de treinamento e validação do modelo utilizando 5 folds: Accuracy: 0.9094, F1 Score: 0.9093, MCC:0.8197, Precisão: 0.9104 e Recall: 0.9094.

O segundo experimento utilizou apenas o corante PAS, as três medidas de distância foram testadas: Manhattan, Euclidiana e Cosseno.

A. Distância Manhattan e somente o corante PAS

Accuracy	0.7673±0.0701
Precision	0.7739±0.0664

Recall	0.7673±0.0701
F1 Score	0.7648±0.0736
MCC	0.5410±0.1366

Tabela 2. Média com desvio padrão das métricas calculadas para os 5 folds do 2º experimento.

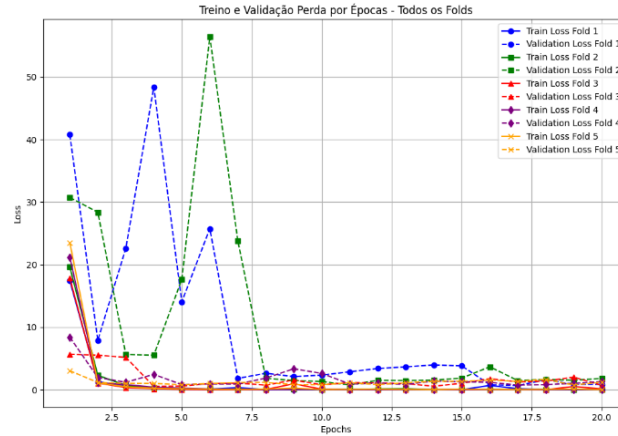


Figura 3: Perda de treino e validação de todos os folds do 2º experimento.

O resultado final foi obtido a partir de um teste realizado com 20% do conjunto de dados, após o processo de treinamento e validação do modelo utilizando 5 folds: Acurácia: 0.86996, F1-score: 0.87075, MCC: 0.75069, Precisão: 0.87075 e Recall: 0.88.

B. Distância Euclidiana e somente corante PAS

Accuracy	0.77048±0.050779
Precision	0.78734±0.04766
Recall	0.77047±0.05078
F1 Score	0.7664±0.054042
MCC	0.55724±0.097468

Tabela 3. Média com desvio padrão das métricas para os 5 folds do 2º experimento.




Figura 4: Perda de treino e validação de todos os folds do 2º experimento.

O resultado final foi obtido a partir de um teste realizado com 20% do conjunto de dados, após o processo de treinamento e validação do modelo utilizando 5 folds: Acurácia: 0.8695, F1-score: 0.8685, MCC: 0.7509, Precisão: 0.8815 e Recall: 0.8695.

C. Distância Cosseno e somente corante PAS

Accuracy	0.82126±0.0226812
Precision	0.85326±0.0288564
Recall	0.82126±0.0226812
F1 Score	0.81724±0.0229497
MCC	0.67366±0.0502436

Tabela 4. Média com desvio padrão das métricas dos 5 folds do 2º experimento.




Figura 5: Perda de treino e validação de todos os folds do 2º experimento.

O resultado final foi obtido a partir de um teste realizado com 20% do conjunto de dados, após o processo de treinamento e validação do modelo utilizando 5 folds: Acurácia: 0.9735, F1-score: 0.9735, MCC: 0.9483, Precisão: 0.9748 e Recall: 0.9735.

CONSIDERAÇÕES FINAIS

O trabalho investiga o uso do Few-Shot Learning para diagnosticar lesões glomerulares em imagens histológicas. Utilizando a ResNet-50 para conjuntos de dados esparsos, o projeto superou desafios relacionados a aprendizado métrico e configuração de GPUs. O Few-Shot Learning mostrou eficácia na categorização de lesões com poucos exemplos por classe, com o método N Way K Shot demonstrando boa generalização. As métricas de precisão, recall e F1 score confirmaram a confiabilidade do modelo. Futuras pesquisas devem incorporar técnicas como Early Stopping, data augmentation e regularização para evitar o overfitting.

REFERÊNCIAS

Ministério da Saúde. Dia Mundial do Rim 2029: Saúde dos Rins para Todos. Disponível em: <<https://bvsmis.saude.gov.br/14-3-dia-mundial-do-rim-2019-saude-dos-rins-para-todos/>> Acesso em: 29/08/2024