



Realimentação de Relevância para Aprimorar o Processamento de Consultas por Similaridade sobre Bases de Imagens de COVID-19

Renato Gomes Marcacini¹, Agma J. M. Traina¹

¹Universidade de São Paulo (USP), São Carlos, SP

renato.gomes.marcacini@usp.br, agma@icmc.usp.br

Resumo. O diagnóstico auxiliado por computador para COVID-19 baseia-se em técnicas de classificação confiável e eficiente sobre imagens de exames (frequentemente Raio-X) e de demais informações dos pacientes. Ter sistemas com tal funcionalidade tornou-se uma necessidade crucial durante a pandemia de 2020 a 2022. Neste contexto, tem sido necessário desenvolver metodologias computacionais que consigam classificar grandes conjuntos de imagens de Raio-X pulmonar de forma rápida e precisa. Porém, a descrição das imagens para realizar a tomada de decisão demanda que os melhores descritores sejam utilizados para que o processo de classificação seja eficaz. Este trabalho mostra que ao se utilizar, em nível de pré-processamento, a combinação de extratores de textura por técnica de Early Fusion conjuntamente com realimentação de relevância automática sobre uma base de imagens de Raio-X de pulmão, é possível obter e apurar uma combinação de extratores que conseguem alcançar resultados de até 90,27% de precisão em três classes de imagens. Ou seja, obtém-se resultados com alta precisão sem trazer ônus extra aos usuários e sem demandar custo computacional adicional para o seu processamento.

Abstract. Computer-aided diagnosis of coronavirus disease (COVID-19) is based on reliable and efficient classification techniques on medical images and other patients' exams. Having systems with such functionality has become a crucial need during the 2020-2022 pandemic. In this context, it has been necessary to develop computational methods that can classify large medical image databases (mostly lung X-rays) quickly and accurately. However, the description of the images to carry out the decision making demands that the best descriptors are used, so the classification process is effective. This work shows that when using, at the pre-processing level, the combination of texture extractors using the Early Fusion technique together with automatic relevance feedback on a dataset of lung X-ray images, it is possible to obtain and refine a combination of extractors that can reach results of up to 90.27% accuracy in three image classes. That is, results with high precision are obtained without bringing extra burden to users and without demanding additional computational cost for their processing.

Palavras-chave: Realimentação de Relevância; Covid-19; Classificação.

1. CONTEXTO E MOTIVAÇÃO

A COVID-19 é uma doença que afeta o sistema respiratório, podendo agravar-se para pneumonia severa e progredindo para óbito. Devido à sua alta transmissibilidade e gravidade, a COVID-19 é considerada uma doença que traz forte impacto também ao sistema de saúde (1). Utilizar as bases de dados e imagens armazenadas como fonte de conhecimento para tomada de decisão, pode auxiliar os especialistas no diagnóstico precoce e agilizar o tratamento dos pacientes, para ampliar suas chances de recuperação. Portanto, soluções baseadas em classificar devidamente imagens do tipo Raio-X de pulmão, que são os exames mais prevalentes para essa doença, de forma rápida e de menor custo são essenciais. Para isto, é preciso considerar metodologias que consigam extrair em larga escala e com baixo custo computacional e

alta disponibilidade, características das imagens para utilização em plataformas convencionais, e que tragam representação apropriada para a detecção de COVID-19.

A realimentação de relevância (RR) é uma técnica de aprendizado de máquina usada para melhorar a eficácia dos sistemas de recuperação de informações por meio de *feedback* interativo ou automático para refinamento de consultas ou medidas de similaridades. Novas pesquisas na literatura têm surgido com objetivo de utilizar a RR para otimização de consultas e diminuir o esforço do usuário com o sistema através de aprendizado de pesos que consigam ressaltar os atributos de um extrator de características (2). Através de testes exaustivos de combinação de extratores e aprendizado de pesos com RR, é possível obter novos extratores que apresentam resultados ótimos



para classificação de dados. As contribuições da técnica apresentada neste artigo levam aos altos níveis de acurácia alcançados, sem a demanda de plataformas de alto custo, em contraponto com o estado-da-arte atual, que exigem alto custo computacional com aprendizado profundo, e alcançam os mesmos valores de acurácia. Além disso, a nossa abordagem *Fusion Relevance Feedback* (FRF) não necessita de esforço por parte do usuário sobre o uso da técnica de RR, já que é realizada de modo automatizado. O diagrama da metodologia neste artigo é apresentado na Figura 1.

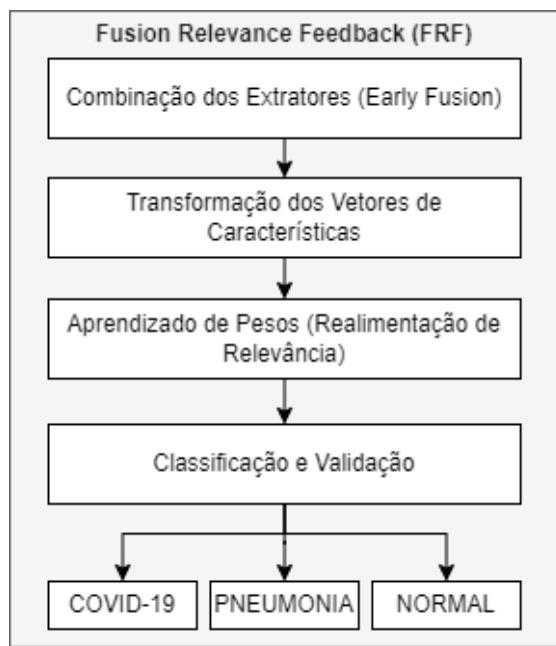


Figura 1. Diagrama da abordagem proposta.

2. DESCRIÇÃO DA SOLUÇÃO

Trabalhos Relacionados

A classificação precisa de imagens de Raio-X pulmonar relacionadas a COVID-19 pode servir como um esquema de detecção inicial de anormalidade da doença no domínio médico. Os estudos atuais detalham algumas metodologias para detecção automatizada computadorizada de COVID-19 usando imagens de Raio-X. No trabalho de Ozturk et al. (3), os autores desenvolveram uma arquitetura de rede neural denominada DarkCovidNet. Na classificação multiclasse, eles categorizaram COVID, não COVID e pneumonia, alcançando 87,02% de

precisão. Utilizando redes neurais convolucionais (CNN) para classificação de COVID, pneumonia e normal, os autores Apostolopoulos e Mpesiana (4) conseguiram alcançar 94,72% de precisão para classificação multiclasse. Como mostrado, na literatura, os recentes trabalhos de detecção de COVID-19 apoiam-se em técnicas de aprendizado profundo para classificação, alcançando altos níveis de acurácia. Porém, a maioria dessas estratégias demandam alto custo computacional de processamento, além de necessitarem de grandes conjuntos de dados para treinamento. Com foco neste cenário, este artigo apresenta uma metodologia computacional simples, porém efetiva, que utiliza estratégias de extração e classificação tradicionais que integradas apropriadamente permitem categorizar imagens de Raio-X pulmonar com COVID-19 de modo eficaz.

Abordagem Proposta: *Fusion Relevance Feedback* - FRF

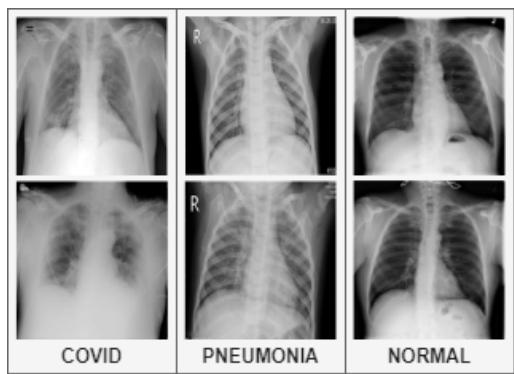
Este trabalho propõe a *Fusion Relevance Feedback* (FRF), que visa identificar qual descritor tem o melhor desempenho no domínio das imagens de Raio-X por meio da combinação de extratores de textura com o refinamento desses extratores através da ponderação de pesos aprendidos por uma RR automática. Isto é, o sistema faz a realimentação sem exigir esforço por parte do usuário, aprimorando o processo de modo transparente para o usuário. Nosso objetivo foi desenvolver uma abordagem que aumenta a acurácia de extratores para classificar imagens de Raio-X pulmonar visando o cenário da COVID-19, sem demandar esforço adicional do usuário.

Aquisição da Base de Imagens

A análise aqui apresentada utiliza uma base de imagens pública vencedora do *COVID-19 Dataset Award* da *Kaggle Community*. A base é constituída de imagens de Raio-X pulmonar para casos positivos de COVID-19 junto com imagens de pneumonia e imagens normais, disponível em (5). Todas as imagens estão no formato JPG, com resolução de 299x299 pixels. Para o estudo de caso foram selecionadas 750 amostras, sendo 250 imagens da classe COVID, 250 imagens da classe de pneumonia e 250 imagens da classe normal. A Figura 2 apresenta exemplos de imagens de cada classe para análise.

**Tabela 1 – Descrição e dimensões**

Extrator	Descrição
E1 - First Order Statistics	Calculados a partir de pixels individuais
E2 - Gray Level Co-occurrence Matrix	Estimativa das probabilidades condicional conjunta entre pixels
E3 - Gray Level Difference Statistics	Estatísticas de pixels adjacentes
E4 - Neighborhood Gray Tone Difference Matrix	Propriedades visuais de complexidade, como simetria e regularidade
E5 - Statistical Feature Matrix	Mede as propriedades de distâncias dentro de uma janela
E6 - Law's Texture Energy Measures	Mede a variação de intensidade ao percorrer a imagem
E7 - Fourier Power Spectrum	Obtém-se padrões de frequência das imagens
E8 - Local Binary Pattern	Mede energia e simetria
E9 - Local Phase Quantization	Usado em aplicativos de reconhecimento de rosto ou de borramento ou de rotulação

**Figura 2. Exemplos de imagens de Raio X pulmonar da base de imagens.**

Extração de Características

A extração de características captura o conteúdo visual de uma imagem para sua indexação e recuperação em bases de dados. A literatura tem mostrado que os extratores de textura têm tido as melhores precisões para a classificação de imagens do tipo Raio-X pulmonar (6-8). Cada extrator gera um vetor de característica que é a representação visual da imagem. Neste estudo, a classificação entre COVID-19, imagens de Raio-X normais e com pneumonia, é realizada através de nove extratores de textura indicados por Giakoumoglou (9), apresentados na Tabela 1.

Combinação de Extratores de Características

A combinação de extratores de características é uma técnica muito comum em aplicações de recuperação de imagens, sendo mais conhecida

como uma técnica de *Early Fusion* (10). Este método é usado antes do cálculo das distâncias entre os elementos de um conjunto de dados, utilizando a combinação de diferentes vetores de características para obter uma nova representação do dado complexo. Para realizar a combinação de extratores, diferentes operações entre vetores podem ser realizadas, como a soma ou a multiplicação dos vetores. A forma mais estável e conhecida de *Early Fusion* é a concatenação de vetores de características em único vetor (11). Neste estudo, foi realizada a combinação na forma de concatenação dos vetores, utilizando a combinação sem repetição formando grupos de dois e três extratores de textura, obtendo um total de 120 novas combinações para análise.

Aprendizado de Pesos por Realimentação de Relevância Automática

A base das técnicas de RR é de que a partir de um conjunto de amostras capturadas a partir de uma consulta por similaridade, o sistema aprende padrões de características relevantes das imagens e gradualmente apresenta melhores resultados nas próximas consultas (12). A ponderação de pesos é uma abordagem que incorpora técnicas de RR, a qual consiste na ponderação das dimensões do vetor de características com base no inverso do desvio padrão de cada dimensão das imagens rotuladas como relevantes (2). Métodos estatísticos como o desvio padrão e variância inversa, conseguem medir a dispersão dos elementos e aprender pesos com base em amostras de imagens fornecidas para aprendizado. No trabalho de Young Rui et al. (13), a utilização de amostras relevantes para RR demonstram um alto aumento na primeira realimentação em comparação a outros tipos de abordagem, mas o ganho da precisão satura em poucas iterações. Neste contexto, a primeira iteração é importante para aprimorar extratores de características de forma automática, a fim de evitar a propagação de erros.

Nossa técnica proposta atribui a cada imagem um valor para rotular cada classe entre COVID, pneumonia e normal e, em seguida, faz uma seleção aleatória exaustiva de uma classe e a utiliza como uma amostra para RR, ou seja, ocorre várias iterações, selecionando diferentes conjuntos de imagens da mesma classe para encontrar a melhor



amostra que efetue resultados significantes na RR. Para cada imagem selecionada, é calculado o inverso do desvio padrão ao longo do eixo do vetor de características, obtendo um vetor de pesos normalizado. A FRF aprende um peso para cada dimensão no espaço da função L_p , refinando a medida da similaridade. O vetor de pesos é utilizado para remodelar os vetores de características multiplicando toda matriz de características, ressaltando os atributos relevantes. A equação (1) demonstra a ponderação dos pesos sobre a função de distância da família Minkowski, onde w_i é o peso sobre a dimensão, mantendo

sempre $\sum w_i = 1$. A Figura 3 apresenta o processo realizado pela técnica FRF para realizar o refinamento dos vetores de características.

$$L_p(x, y) = \sqrt[p]{\sum_{i=0}^n w_i |x_i - y_i|^p}$$

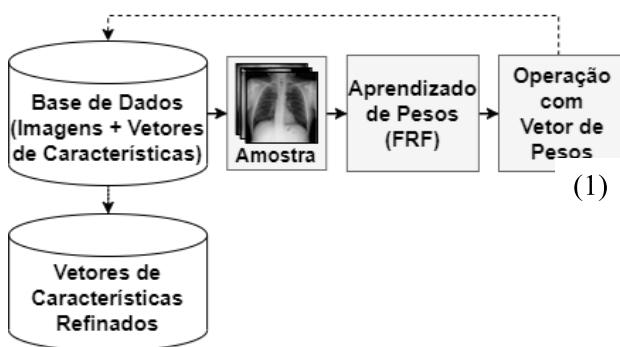


Figura 3. Diagrama do processo de refinamento sobre um extrator.

Classificação e Validação

Os vetores de características extraídos das imagens de Raio-X pulmonar, são alimentados ao classificador para detectar a qual classe uma imagem pertence. Para isso, é utilizado o classificador *K Nearest Neighbor* (KNN). Para precisão do classificador, a validação cruzada de até 10 vezes é utilizada. O classificador e seus respectivos parâmetros são:

- **KNeighborsClassifier:** `n_neighbors:3, metric='wminkowski',` potência=1 e 2, `metric params='w', weights`, onde `weights` é um vetor de pesos.

Para análises preditivas, é possível obter em um classificador a frequência de elementos falsos positivos (FP), falsos negativos (FN), verdadeiros positivos (VP) e verdadeiros negativos (VN). Em sistemas para classificação de dados complexos é preciso um método para mensurar a precisão das consultas, métricas como a Acurácia (ACC) e *F1-Score* (F1) são amplamente utilizadas como parâmetros para predição das consultas.

Resultados

Após todas as combinações possíveis de grupos de dois e três extratores, são obtidas 120 combinações, e o sistema seleciona automaticamente um subconjunto sobre toda base de imagem para aprendizado dos pesos através da técnica de RR utilizando o inverso do desvio padrão, denominado neste artigo como RR Desvio Padrão. A Tabela 2 apresenta a acurácia (ACC) e *F1-Score* (F1) alcançado pela classificação com cada extrator original e as melhores combinações comparando a técnica com e sem RR na base de imagens. É possível observar que a RR consegue um ganho considerável na maioria das combinações, obtendo 90,27% de acurácia com a combinação *E1+E2+E9*.

Tabela 2 – ACC e F1 por descritor de textura, Sem RR e com RR Desvio Padrão.

Extrator	Sem RR		RR Desvio Padrão		
	ACC (%)	F1 (%)	ACC (%)	F1 (%)	Ganho (%)
<i>E1</i>	60,93	60,59	73,60	73,58	20,79
<i>E2</i>	52,40	51,68	83,20	83,13	58,77
<i>E3</i>	58,13	57,68	60,66	60,43	4,35
<i>E4</i>	64,00	63,82	73,20	73,00	14,37
<i>E5</i>	61,19	61,06	75,86	75,76	23,97
<i>E6</i>	56,26	55,77	69,46	69,22	23,46
<i>E7</i>	55,33	55,19	58,00	57,46	4,82
<i>E8</i>	48,26	47,63	48,26	47,70	0
<i>E9</i>	83,33	83,34	85,86	85,95	3,03
<i>E2+E9</i>	53,60	52,92	88,67	88,66	65,42
<i>E1+E9</i>	60,67	60,33	89,07	89,12	46,81
<i>E1+E8+E9</i>	62,13	61,85	89,20	89,27	43,56
<i>E2+E4+E9</i>	64,40	64,24	89,33	89,35	38,74
<i>E1+E2+E9</i>	60,80	60,23	90,27	90,32	48,47

A Tabela 3 apresenta a comparação da acurácia obtida pela técnica proposta em relação às pesquisas existentes que utilizam aprendizado



profundo. As bases de imagens utilizadas nos trabalhos de Ozturk et al. (3) e Apostolopoulos e Mpesiana (4) estão incluídas na coleção da *COVID-19 Radiography Database* (5) utilizada neste trabalho. É importante observar que o uso de técnicas de menor custo computacional podem obter resultados similares e até superiores em relação às técnicas de aprendizado profundo, que são mais caras.

Tabela 3 – Acurácia obtida pelas técnicas, (DarkCovidNet e CNN usam Aprendizado Profundo)

Técnica	Nº Classes	Dataset	ACC (%)
DarkCovidNet (3)	3	(14)	87,02
CNN (4)	3	(14-15)	94,72
FRF	3	(5)	90,27

3. PONTOS RELEVANTES DA INOVAÇÃO

O processo de analisar e tomar decisões baseadas em exames de pacientes é primordial para o diagnóstico e tratamento corretos de pacientes. O processamento de consultas é um dos pilares de sistemas de recuperação e possuem a necessidade de serem altamente acurados. A proposta neste artigo apresenta uma abordagem para aprimorar o processamento de consultas por similaridade por meio de RR, com o objetivo de detecção de casos de COVID-19. O critério de inovação para este estudo está no uso de técnicas tradicionais de aprendizado de máquina de baixo custo computacional para melhorar a classificação de imagens pulmonares, contrapondo-se ao estado da arte que utilizam técnicas de aprendizado profundo, que, apesar de serem altamente acurados, os ambientes computacionais que fazem uso desta tecnologia são muito caros e não acessíveis a qualquer instituição. Uma vez que a técnica proposta atinge acurácia semelhante às técnicas do estado da arte para detecção de imagens pulmonares com uma estratégia mais simples, pode-se desenvolver sistemas de apoio ao diagnóstico médico precisos e mais aceitos pela comunidade de saúde.

4. CONSIDERAÇÕES FINAIS

Este artigo propôs uma abordagem de baixo custo computacional denominada FRF que utiliza a combinação de extratores de textura e técnica de RR automática sobre um conjunto de dados para

classificação de COVID-19. A utilização da RR automática sobre a combinação de extratores chega a ter ganhos de até 65,42%, mantendo sempre ganhos em relação aos extratores sem RR. O método foi aplicado sobre uma base de imagens pública e comparado às técnicas de aprendizado profundo, alcançando precisões de até 90,27% de acurácia para classificação entre as classes COVID, pneumonia e normal. É importante ressaltar que a nossa proposta usa em média até 54% do tempo necessário durante o treinamento para os métodos de aprendizado profundo realizarem a mesma tarefa, em média. E além disso, pode ser executada sem a dependência de unidades gráficas de processamento (GPU). Como trabalhos futuros, a utilização de diferentes classificadores, novas técnicas de RR e uso de técnicas de redução de dimensionalidade sobre a combinação dos extratores, podem oferecer novos ganhos computacionais diminuindo o ruído de atributos não relevantes após a concatenação dos vetores.

Agradecimentos

Os autores agradecem a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) em possibilitar a realização deste estudo.

REFERÊNCIAS

1. Guan W, Ni Z, Hu Y, Liang W, Ou C, He J, et al. Clinical Characteristics of Coronavirus Disease 2019 in China. *New England Journal of Medicine* [Internet]. 2020 Feb 28;382(18). Available from: <https://www.nejm.org/doi/full/10.1056/nejMoa2002032>
2. Guldogan E, Gabbouj M. Dynamic feature weights with relevance feedback in content-based image retrieval. In 2009 24th International Symposium on Computer and Information Sciences, 2009.
3. Ozturk T, Talo M, Yildirim EA, Baloglu UB, Yildirim O, Rajendra Acharya U. Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine* [Internet]. 2020 Apr 28; Available from:



- <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7187882/>
4. Apostolopoulos ID, Mpesiana TA. Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, 2020, pp. 635–640.
 5. COVID-19 Radiography Database [Internet]. kaggle.com. Available from: <https://www.kaggle.com/tawsifurrahman/covid-19-radiography-database>
 6. Pereira RM, Bertolini D, Teixeira LO, Silla CN, Costa YMG. COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios. *Computer Methods and Programs in Biomedicine*, 2020; 194:105532.
 7. Rahman T, Khandakar A, Qiblawey Y, Tahir A, Kiranyaz S, Abul Kashem SB, et al. Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*, 2021; 132:104319.
 8. Scalco E, Rizzo G. Texture analysis of medical images for radiotherapy applications. *The British Journal of Radiology* [Internet]. 2017. 90(1070):20160642. Available from: <https://www.birpublications.org/doi/pdf/10.1259/bjr.20160642>
 9. Giakoumoglou, N. (2021). Pyfeats: Open source software for image feature extraction. <https://github.com/giakou4/pyfeats>
 10. Snoek CGM, Worring M, Smeulders AWM. Early versus late fusion in semantic video analysis. *Proceedings of the 13th annual ACM international conference on Multimedia - MULTIMEDIA '05*. 2005.
 11. Yu J, Qin Z, Wan T, Zhang X. Feature integration analysis of bag-of-features model for image retrieval. *Neurocomputing*. 2013 Nov;120:355–64.
 12. Pardede J, Sitohang B, Akbar S, Khodra ML. Re-weighting Relevance Feedback in HSV Quantization for CBIR. *2018 19th IEEE/ACIS International Conference on Software Engineering, Artificial Intelligence, Networking and Parallel/Distributed Computing (SNPD)*, 2018.
 13. Yong Rui, Huang TS, Ortega M, Mehrotra S. Relevance feedback: a power tool for interactive content-based image retrieval. *IEEE Transactions on Circuits and Systems for Video Technology*. 1998; 8(5):644–55.
 14. Cohen JP, Morrison P, Dao L. COVID-19 Image Data Collection. arXiv:200311597 [cs, eess, q-bio] [Internet]. 2020 Mar 25; Available from: <https://arxiv.org/abs/2003.11597>
 15. COVID-19 X rays [Internet]. kaggle.com. Available from: <https://www.kaggle.com/tawsifurrahman/covid-19-radiography-database>