



## Uma nova abordagem de padrões binários em radiografias de tórax para avançar o diagnóstico de tuberculose

### A novel binary patterns approach on chest radiographs to advance tuberculosis diagnosis

### Un nuevo enfoque de patrones binarios en las radiografías de tórax para avanzar en el diagnóstico de la tuberculosis

Afonso Ueslei da Fonseca<sup>1</sup>, Emilia Alves Nogueira<sup>2</sup>, Ana Luisa de Bastos Chagas<sup>3</sup>,  
Juliana Paula Felix<sup>1</sup>, Deborah Silva Alves Fernandes<sup>1</sup>, Fabrizzio Soares<sup>1</sup>

1 Doutor(a), Instituto de Informática, Universidade Federal de Goiás, GO, Brasil.

2 Doutoranda, Instituto de Informática, Universidade Federal de Goiás, GO, Brasil.

3 Graduanda, Instituto de Informática, Universidade Federal de Goiás, GO, Brasil.

Autor correspondente: Doutor Afonso Ueslei da Fonseca

E-mail: afonsoueslei@ufg.br

#### Resumo

**Objetivo:** A tuberculose (TB) afeta milhões de pessoas, principalmente as mais miseráveis, revelando desigualdades sociais. Apesar dos avanços da inteligência artificial (IA) no controle da TB, poucos benefícios chegam aos mais necessitados. Este estudo propõe uma IA otimizada para discriminar casos de TB de indivíduos saudáveis. **Método:** A abordagem incorpora descritores por congruência de fase e padrões binários locais em um modelo de otimização mínima sequencial (SMO) na análise de radiografias de tórax (RXT). **Resultados:** A IA otimizada apresenta desempenho superior a abordagens existentes na literatura, entregando valor de especificidade superior a 97% em diferentes bases e cenários de segmentação. **Conclusão:** A aplicação da IA proposta na análise de RXT pode representar um avanço significativo no controle da TB, especialmente em populações mais necessitadas, pois constitui uma solução acessível e eficaz que abre possibilidades para o desenvolvimento de novos sistemas de apoio ao diagnóstico.

**Descritores:** Tuberculose; Inteligência Artificial; Diagnóstico



## Abstract


**Objective:** Tuberculosis (TB) affects millions of people, especially the most miserable, revealing social inequalities. Despite advances in artificial intelligence (AI) in TB control, few benefits reach those most in need. This study proposes an optimized AI to discriminate TB cases from healthy individuals. **Method:** The approach incorporates phase congruence descriptors and local binary patterns into a sequential minimum optimization (SMO) model to analyze chest radiographs (CXR). **Results:** The optimized AI performs better than existing approaches in the literature, delivering a specificity value greater than 97% in different bases and segmentation scenarios. **Conclusion:** Applying the proposed AI in RXT analysis could represent a significant advance in TB control, especially in populations most in need, as it constitutes an accessible and effective solution that opens up possibilities for developing new diagnostic support systems.

**Keywords:** Tuberculosis; Artificial intelligence; Diagnosis

## Resumen

**Objetivo:** La tuberculosis (TB) afecta a millones de personas, especialmente a las más miserables, revelando desigualdades sociales. A pesar de los avances en inteligencia artificial (IA) en el control de la tuberculosis, pocos beneficios llegan a quienes más los necesitan. Este estudio propone una IA optimizada para discriminar los casos de tuberculosis de los individuos sanos. **Método:** el enfoque incorpora descriptores de congruencia de fase y patrones binarios locales en un modelo de optimización mínima secuencial (SMO) para analizar radiografías de tórax (CXR). **Resultados:** La IA optimizada funciona mejor que los enfoques existentes en la literatura, entregando un valor de especificidad superior al 97% en diferentes bases y escenarios de segmentación. **Conclusión:** La aplicación de la IA propuesta en el análisis RXT podría representar un avance significativo en el control de la tuberculosis, especialmente en las poblaciones más necesitadas, ya que constituye una solución accesible y eficaz que abre posibilidades para el desarrollo de nuevos sistemas de apoyo al diagnóstico.

**Descriptores:** Tuberculosis; Inteligencia artificial; Diagnóstico



## Introdução

A tuberculose (TB) é ainda um problema crítico de saúde pública global, apesar de prevenível, tratável e curável. Anualmente, milhões de pessoas são acometidas por essa enfermidade, que continua a ser uma das mais letais em todo o mundo. Somente em 2023, cerca de 1,4 milhão de vidas foram perdidas para a TB, com maior incidência principalmente entre os mais pobres e vulneráveis<sup>(1)</sup>. Por outro lado, o uso de inteligência artificial (IA) para detectar TB em radiografias de tórax (RXT) progrediu significativamente nas últimas décadas. Mais recentemente, as redes neurais artificiais (RNA) impulsionaram um rápido progresso na análise de imagens médicas, onde a detecção e o diagnóstico de TB estão surgindo como áreas de interesse de pesquisa<sup>(2)</sup>.

Contudo, apesar de todo esse progresso, as populações mais necessitadas ainda não têm percebido esses benefícios<sup>(1)</sup>. Nesse sentido, fortalece a percepção da comunidade científica de que os benefícios de tais tecnologias devem assistir principalmente aqueles nas regiões mais vulneráveis e com menos recursos<sup>(3)</sup>.

Assim, pesquisadores ao redor do mundo têm trabalhado em soluções computacionais para diagnóstico e triagem de TB em imagens RXT. Esses usando várias técnicas computacionais e métodos de IA, desde abordagens tradicionais de aprendizado de máquina (AM) até modelos *Deep Learning* (DL). A literatura conta com várias revisões que evidenciam a evolução deste campo de pesquisa ao longo do tempo, mostrando a diversidade de estratégias utilizadas<sup>(4,5)</sup>.

A extração artesanal de características em RXT e métodos de AM foram utilizados por Jaeger *et al.*<sup>(6)</sup> com abordagens para detecção de objetos e recuperação de imagens baseada em conteúdo (CBIR), combinadas com regressão logística linear (RLL). Em Sousa *et al.*<sup>(7)</sup> classificadores para pneumonia em sistemas de detecção e diagnóstico assistidos por computador (CADx) foram avaliados com características extraídas de nove subespaços das *Wavelets* de Haar. Uma combinação de características GIST e histograma piramidal de gradientes orientados (PHoG) foi experimentada por Chauhan *et al.*<sup>(8)</sup> em RXT com pulmões segmentados, utilizando seleção por Qui-quadrado e um classificador de máquina de vetores de suporte (SVM). Outras técnicas incluem características de histogramas, texturas, canais de cor, formas e arestas<sup>(9,10)</sup>, padrões binários<sup>(11,12)</sup> e



SURF<sup>(13)</sup>. Entre métodos de aprendizado de máquina, os mais usados são SVM, RLL e *Perceptron* multicamadas (MLP).

Modelos DL têm sido usados sobretudo com re-treino ou transferência de aprendizado, usando pesos de diferentes modelos ou domínios<sup>(14,15)</sup>, usando ajuste fino de parâmetros<sup>(16,17)</sup> ou construindo a partir do zero<sup>(18,19)</sup>. Além disso, características extraídas de modelos DL (DFE) também são combinadas com AM para classificar automaticamente casos de TB<sup>(20,21,22)</sup>. Ainda, redes *Feedforward* (FFN), as primeiras e mais simples categorias de RNA, também são comuns na pesquisa relacionada à TB<sup>(23,24,25)</sup> como alternativa de menor custo às DL.

Dessa forma, dado o exposto e buscando contribuir com esta área, neste estudo é proposta uma solução computacional de baixo custo e alta eficiência para avançar no diagnóstico da TB pulmonar (TBP). A solução é especialmente desenvolvida para regiões, ambientes e equipamentos com poucos recursos, com enfoque originalmente brasileiro, tem como um dos objetivos a busca ativa da TB, a fim de melhorar o manejo da doença pelo apoio à decisão médica, contribuindo com diagnóstico e tratamento mais acessível. Além disso, métodos de extração e seleção de características são combinados a um algoritmo AM otimizado e apresentam resultados que superam a literatura relacionada em diferentes cenários de configuração.

As principais contribuições de pesquisa deste estudo são:

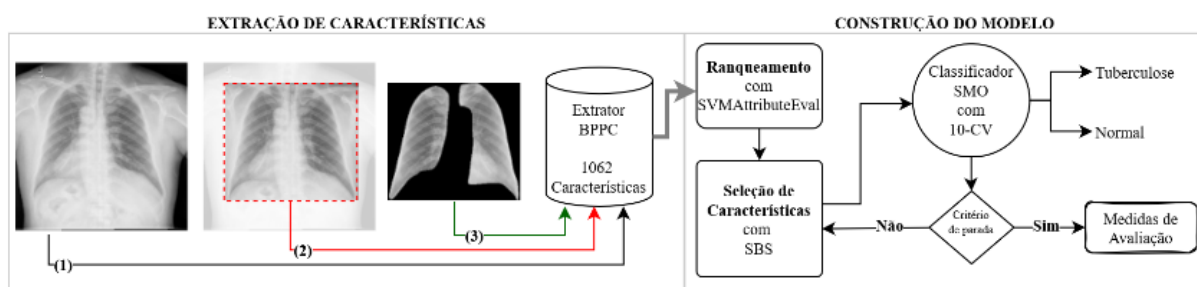
- Extração de características radiômicas com alto poder discriminante da expressão TBP, por padrões binários de congruência de fase (BPPC);
- Ranqueamento das características mais expressivas por algoritmo SVMAttributeEval e escolha por seleção reversa sequencial (SBS);
- Avaliação da segmentação em RXT no processo de diagnóstico da TB;
- Análises comparativas com estudos de última geração.

## Método proposto

Esta estudo explora padrões binários de congruência de fase (BPPC) para discriminar manifestações TB em imagens RXT. Características radiômicas das RXT são extraídas por BPPC e então ranqueadas com o algoritmo SVMAttributeEval. No processo de extração por BPPC, adota-se como parâmetros 6 direções no cálculo das fases de congruência (PC) e 177 faixas para os histogramas, resultando em um



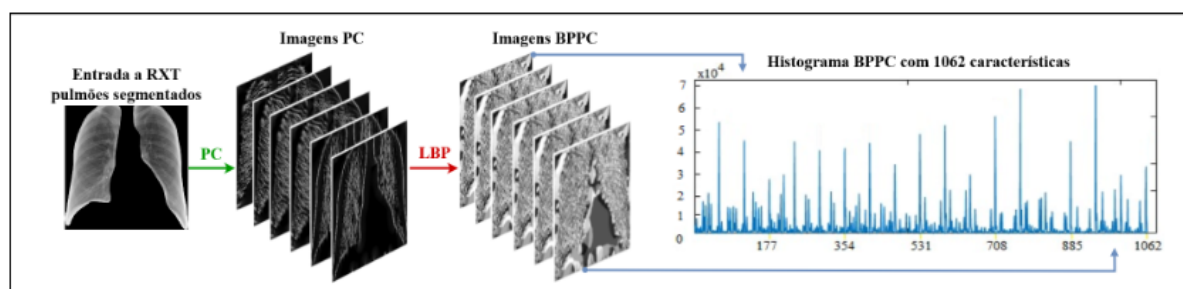
vetor de 1062 características representando a imagem RXT. Como estratégia de seleção de características, usa-se a seleção reversa sequencial (SBS), e como algoritmo de aprendizado de máquina, a otimização mínima sequencial (SMO). Adicionalmente, experimentos para verificar o possível impacto do processo de segmentação das imagens RXT são realizados. Assim, a classificação de casos normais e TB é avaliada para três cenários distintos: (1) com toda a imagem RXT, sem qualquer segmentação; (2) tomando o recorte em caixa da região dos pulmões; e (3) considerando apenas a região segmentada dos pulmões. A Figura 1 traz uma visão das etapas da proposta.




**Figura 1** - Etapas do método de detecção de TBP por extração e seleção de características pelo extrator BPPC e algoritmo *SVMAttributeEval* para os três cenários de segmentação.

### Padrões Binários de Congruência de Fase (BPPC)

BPPC é uma nova adaptação para os padrões binários locais (LBP), onde o valor de intensidade utilizado para calcular o LBP é substituído pelo valor da *Phase Congruency* (PC) no *pixel* correspondente. A Figura 2 ilustra as fases da extração de características BPPC para uma imagem RXT com pulmões segmentados. Uma explicação mais detalhada do BPPC pode ser encontrada em Fonseca *et al.*<sup>(25)</sup>.





**Figura 2** - Processo de extração de características por BPPC. Imagem RXT, 6 imagens PC resultantes e suas respectivas BPPC, cada uma delas levando a um histograma de 177 faixas. Concatenados, esses histogramas formam o vetor de 1062 características.

### Algoritmo Otimização Mínima Sequencial (SMO)

O SMO é uma resposta avançada desenvolvida por Platt<sup>(26)</sup> para treinar um SVM. Como isso requer responder a um problema de otimização de programação quadrática (PQ) massiva, o SMO divide o problema de PQ em uma série de problemas menores, resolvidos analiticamente. Como a computação de matriz massiva é evitada, o SMO escala em algum lugar entre linear e quadrático no comprimento do conjunto de treinamento para vários problemas<sup>(26)</sup>.

Neste estudo, a detecção de TB é realizada pela classificação binária das imagens RXT em Normal (saudáveis) ou com TB. Usa-se a implementação SMO que normaliza todos os recursos por padrão (os coeficientes na saída são baseados nos dados normalizados, não nos dados originais – importante para interpretar o classificador). Além disso, também utiliza-se a precisão do algoritmo como função objetivo no processo de seleção de atributos, conforme explicado a seguir.

### Seleção Reversa Sequencial (SBS)

Depois de ranquear as características da mais para a menos significativas com o algoritmo *SVMAttributeEval*, o método de seleção SBS<sup>(27)</sup> é aplicado tomando a precisão do SMO como função objetivo. Para otimizar este processo é definido um número máximo de características para cada conjunto, equivalente a 30% do número de imagens no conjunto. Assim, 42, 199 e 240 características são definidas para os conjuntos de dados Montgomery (MC), Shenzhen (SH) e agrupado (MCSH), respectivamente. O processo começa com esse limite e remove características menos significativas que não afetam negativamente a precisão do modelo. O método continua iterativamente até percorrer todas as características sem fazer nenhuma remoção.

### Dinâmica de Testes

Dois conjuntos públicos de RXT de TB são usados neste estudo. O SH da China com 662 imagens, e o MC dos Estados Unidos com 138 imagens<sup>(6)</sup>. Adicionalmente, um maior, aqui nomeado como MCSH que agrupa os dois



primeiros. Para cada conjunto, o SMO é treinado e testado em validação cruzada com 10 dobras avaliando número de características e cenários de segmentação. Definidos número de características por SBS os resultados são comparados a literatura. A Tabela 1 uma descrição dos conjuntos, imagens RXT e máscaras (pulmões segmentados) podem ser baixadas em nih.gov<sup>1</sup> e kaggle.com<sup>2</sup>, respectivamente.

**Tabela 1** - Breve descrição das imagens RXT nos conjuntos de dados

Conjunto	Montgomery (MC)	Shenzhen (SH)	MCSH
No. casos TB+	58	336	39
No. casos Normal	80	326	40
Resolução das Imagens	4020 X 4892	948-3001 X 1130-3001	-
Idade média (anos)	33,1 ± 18,1	33,4 ± 14	33,3 ± 14,7
Homens (%)	44,2	66,4	62,6
TB+ derrame pleural (%)	12/58 (20,7)	22/336 (6,5)	34/394 (8,6)
TB+ miliar (%)	2/58 (3,5)	3/336 (0,9)	5/394 (1,3)
TB+ cavitação (%)	11/58 (19)	34/336 (10,1)	45/394 (11,4)

TB+: Casos positivos para Tuberculose

## Avaliação dos Resultados

Iniciando a avaliação pelo gráfico da Figura 3(a) que traz a relação entre a acurácia do método, o número de características e os cenários de segmentação para o conjunto MC. O gráfico mostra que a máxima acurácia pode ser alcançada com 27, 31 e 36 características, respectivamente, nos cenários sem segmentação, pulmões segmentados e recorte em caixa. Da Figura 3(b-d), as matrizes de confusão da melhor acurácia alcançada, em cada cenário de segmentação.


Na Figura 4 tem-se os resultados para o conjunto SH com máxima acurácia alcançada com 166 características em RXT não segmentadas, 174 em recorte em caixa e 183 com pulmões segmentados. Estes números de características são bem superiores ao do conjunto MC, mas mantém-se proporcional ao tamanho do conjunto, indicando uma relação entre o tamanho do conjunto e o número de características necessárias para atingir a melhor acurácia ( $\approx 1/5$  característica/RXT).

<sup>1</sup> <https://lhncbc.nlm.nih.gov/LHC-downloads/dataset.html>

<sup>2</sup> <https://www.kaggle.com/yoctoman/shcxr-lung-mask>




A Figura 5 traz agora o resultado para o conjunto MCSH, resultante da combinação dos dois primeiros. O modelo alcança os melhores resultados de acurácia com 214, 224 e 228 características, nas RXT com recorte em caixa, não segmentadas e com pulmões segmentados, respectivamente. Novamente, a relação entre número de características e tamanho do conjunto se mantém.



**Figura 3** - Conjunto MC, gráfico da performance de acurácia e matrizes de confusão médias para esquemas de segmentação, usando a melhor resposta da etapa de seleção de características, classes Normal (0) e TB (1).


A análise dos gráficos revela que a estratégia de seleção de características combinada ao modelo de classificador, é capaz de distinguir casos normais de TB de forma eficaz, independentemente do tipo de segmentação adotado. Mesmo que o tipo de segmentação e o tamanho do conjunto influenciem o número de características selecionadas, a acurácia máxima ainda é alcançada. No entanto, é necessário avaliar melhor a estabilidade do modelo à medida que o tamanho do conjunto aumenta, para garantir que o número de características extraídas seja suficiente para discriminar corretamente as classes ou alcançar a taxa de seleção definida.







**Figura 4** - Conjunto SH, gráfico da performance de acurácia e matrizes de confusão médias para esquemas de segmentação, usando a melhor resposta da etapa de seleção de características, classes Normal (0) e TB (1).



**Figura 5** - Conjunto MCSH, gráfico da performance de acurácia e matrizes de confusão médias para esquemas de segmentação, usando a melhor resposta da etapa de seleção de características, classes Normal (0) e TB (1).

Na Tabela 2, comparação no cenário de RXT sem segmentação mostra que os resultados alcançados neste estudo são iguais ou superiores em todos os conjuntos. Mesmo no conjunto MCSH, com desempenho menor, supera trabalhos anteriores, como os de Gozes & Greenspan<sup>(28)</sup> e Nafisah *et al.*<sup>(17)</sup>, ainda que considerado o desvio padrão. Nossa solução combina um modelo de classificação e processo de extração de características mais simples, fornecendo características radiômicas altamente discriminantes e exigindo menos recursos computacionais e tempo de treinamento em comparação com os modelos de aprendizado profundo utilizados nos trabalhos relacionados. Isso sugere que a proposta deste trabalho pode ser mais robusta e menos suscetível a sobreajuste.

**Tabela 2.** Sem segmentação - Comparação da detecção de TB com literatura.

Estudo	Metodologia	Conjunto	Resultado nos Testes (%)			
			ACC±σ	TPR	TNR	AUC±σ
Lakhani <i>et al.</i> 2017 <sup>(3)</sup>	GoogleNet e AlexNet	MC,SH,BE,T J	96,00	97,30	94,7,	99,00
Pasa <i>et al.</i> 2019 <sup>(18)</sup>	CNN customizada	MC	79,00	-	-	81,10
		SH	84.40	-	-	90,00
Gozes & Greenspan 2019 <sup>(28)</sup>	ChexNet	MC	-	-	-	95,20
	MetaChexNet (DFE + Metadata)	SH	-	-	-	96,50
	ChexNet	MCSH	-	-	-	94,40



Oltu <i>et al.</i> 2021 <sup>(22)</sup>	DFE (MobileNet), SVM	SH	96,60	-	-	99,00
Rajaraman <i>et al.</i> 2021 <sup>(15)</sup>	VGG-16 e supressão óssea	MC	92,30±3,12	87,70	96,90	96,40±1,06
		SH	88,80±2,47	88,00	89,50	95,40±1,86
Nafisah <i>et al.</i> 2022 <sup>(17)</sup>	EfficientNetB3, DA	MC	85,50	85,70	85,20	-
		SH	92,60	93,40	91,80	-
		MCSH	91,70	87,60	94,30	-
<b>Nossa proposta</b>	FE (BPPC), FS (SVM), SMO	MC	100	100	100	100
		SH	100	100	100	100
		MCSH	97,63±2,16	97,49	97,79	97,64±2,14

**FE:** Processo de extração de características, **FS:** Processo de seleção de características, **DFE:** Processo de extração profunda de características, **DA:** Aumento de dados, **BE:** Conjunto TB de Belarus, **TJ:** Conjunto TB do Hospital Universitário Thomas Jefferson. **ACC:** Acurácia, **TPR:** Sensibilidade, **TNR:** Especificidade, **AUC:** Área sobre a curva,  $\sigma$ : Desvio Padrão.

Nas Tabela 3 e Tabela 4, respectivamente, a comparação com trabalhos que realizam a segmentação em recorte e segmentação dos pulmões. Novamente, nossos resultados estão em linha com os trabalhos relacionados e superam com boa margem a maioria deles. É importante ressaltar que, nesses cenários, as características extraídas são mais representativas, uma vez que são obtidas apenas das regiões de interesse na RXT, logo, são mais fidedignas às patologias sob análise. Desde forma, os resultados alcançados mostram que nossa estratégia para extração e seleção de características de fato captura os padrões discriminantes necessários para classificar com precisão casos TB e normais em imagens RXT.

**Tabela 3.** Segmentação em recorte - Comparação da detecção de TB com literatura.

Estudo	Metodologia	Conjunto	Resultado nos Testes (%)			
			ACC± $\sigma$	TPR	TNR	AUC± $\sigma$
Rajaraman <i>et al.</i> 2018 <sup>(20)</sup>	AlexNet customizada	MC	72,50	-	-	81,80
		SH	85,30	-	-	92,60
Srimathi <i>et al.</i> 2020 <sup>(21)</sup>	DFE (AlexNet), SVM	MC	72,70	-	-	80,10
		SH	84,30	-	-	91,30
Rajaraman <i>et al.</i> 2021 <sup>(16)</sup>	VGG-16 Fine-tuned	SH,BE,IND	92,30	96,90	85,60	95,30
		MC	100	100	100	100
<b>Nossa proposta</b>	FE (BPPC), FS (SVM), SMO	SH	100	100	100	100
		MCSH	98,63±1,09	98,22	99,00	98,61±1,10

**Tabela 4.** Segmentação dos pulmões - Comparação da detecção de TB com literatura.

Estudo	Metodologia	Conjunto	Resultado nos Testes (%)			
--------	-------------	----------	--------------------------	--	--	--



			ACC±σ	TPR	TNR	AUC±σ
Lopes <i>et al.</i> 2017 <sup>(14)</sup>	Bag (GoogleNet, VggNet, ResNet)	MC	82,60	-	-	92,60
		SH	84,70	-	-	92,60±0,05
Vajda <i>et al.</i> 2018 <sup>(10)</sup>	FE (SetA,B,C), FS exaustivo, MLP	MC	84,70±11,16	-	-	91,00±0,11
		SH	97,00±1,71	-	-	99,00±0,05
Singh <i>et al.</i> 2019 <sup>(9)</sup>	FE (SetA,B), SVM	MC	96,00	91,00	100	98,00
		SH	97,80	95,00	100	96,00
Fonseca <i>et al.</i> 2022 <sup>(11)</sup>	FE (LBP), FS (MBO), KNN	MC	83,33±7,16	65,50	96,25	82,90
		SH	90,33±3,06	85,42	95,40	92,40
		MCSH	87,00±3,29	80,00	93,80	88,90
Nafisah <i>et al.</i> 2022 <sup>(17)</sup>	EfficientNetB3, DA	MC	89,90	89,30	90,70	-
		SH	93,70	93,60	93,80	-
		MCSH	98,70	98,30	99,00	-
<b>Nossa proposta</b>	FE (BPPC), FS (SVM), SMO	MC	100	100	100	100
		SH	99,40±0,78	98,83	100	99,40±0,77
		MCSH	99,38±1,01	99,23	99,51	99,37±1,13

Ainda, as comparações com a literatura indicam que esta proposta tem desempenho em linha com trabalhos relacionados, com acurácia estável e invariante aos cenários de segmentação ou conjunto de dados. Dessa forma, a proposta coloca-se como mais uma alternativa viável para a classificação de TB em imagens RXT, apresentado como diferenciais o baixo custo, alta precisão, e um processo de extração e seleção de características radiômicas com alto poder discriminante.

## Conclusão

A detecção precoce e precisa da TBP é desafiadora, especialmente em regiões com recursos limitados, sendo crucial para o manejo eficaz da doença. Logo, ferramentas confiáveis e acessíveis que apoiem essa tarefa são esperança para os mais necessitados e um grande aliado dos profissionais de linha de frente pela erradicação da doença. Neste estudo, foi apresentada uma solução computacional inovadora de baixo custo e alta eficiência para avançar na detecção de casos de TBP em RXT. A abordagem combina extração de características radiômicas por BPPC e um algoritmo de AM otimizado SMO para melhorar a resposta na discriminação de casos TB entre casos normais.

Os resultados promissores obtidos em diferentes conjuntos de dados e cenários de segmentação indicam alta precisão, mesmo para o conjunto combinado



MCSH, alcançando AUC de no mínimo  $97,64 \pm 2,14$ . Além disso, a solução superou os trabalhos relacionados, tanto em termos de acurácia quanto de eficiência computacional, destacando sua robustez e potencial para aplicação prática em contextos de saúde pública.


Este estudo contribui para o avanço da detecção da TBP, fornecendo uma solução acessível e eficaz que abre possibilidades para o desenvolvimento de novos sistemas de apoio ao diagnóstico, visando reduzir o impacto global da TB. Contudo, sabemos que são necessárias mais pesquisas e validações clínicas para garantir a generalização e a aplicabilidade clínica de nossa abordagem. Nesse sentido, este estudo é mais um passo na criação da ferramenta XmartTB, realizada em conjunto com a Faculdade de Medicina da Universidade Federal de Goiás, que tem como objetivo apoiar a identificação precoce de casos TBP por busca ativa.

## Referências

1. WHO (2023). Global tuberculosis report 2023. World Health Organization, Geneva. License: CC BY-NC-SA 3.0 IGO.
2. Kulkarni, S. and Jha, S. (2020). Artificial intelligence, radiology, and tuberculosis: a review. *Academic radiology*, 27(1):71–75.
3. Lakhani, P. and Sundaram, B. (2017). Deep learning at chest radiography: automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology*, 284(2):574–582.
4. Jaeger, S., Karargyris, A., Candemir, S. *et al.* (2013). Automatic screening for tuberculosis in chest radiographs: a survey. *Quantitative imaging in medicine and surgery*, 3(2):89.
5. Çalli, E., Sogancioglu, E., van Ginneken, B., van Leeuwen, K. G., and Murphy, K. (2021). Deep learning for chest x-ray analysis: A survey. *Medical Image Analysis*, 72:102125.
6. Jaeger, S., Candemir, S., Antani, S. *et al.* (2014). Two public chest x-ray datasets for computer-aided screening of pulmonary diseases. *Quantitative imaging in medicine and surgery*, 4(6):475.
7. Sousa, R. T., Marques, O., Curado, G. T. *et al.* (2014). Evaluation of classifiers to a childhood pneumonia computer-aided diagnosis system. In 2014 IEEE 27th International Symposium on Computer-Based Medical Systems, p. 477–478. IEEE.
8. Chauhan, A., Chauhan, D., and Rout, C. (2014). Role of Gist and PHOG features in computer-aided diagnosis of tuberculosis without segmentation. *PloS one*, 9(11):e112980.
9. Singh, N. and Hamde, S. (2019). Tuberculosis detection using shape and texture features of chest X-rays. In *Innovations in Electronics and Communication Engineering*, p. 43–50. Springer.



10. Vajda, S., Karargyris, A., Jaeger, S., *et al.* (2018) Feature selection for automatic tuberculosis screening in frontal chest radiographs. *Journal of medical systems*, 42(8):1–11.
11. Fonseca, A. U., Rocha, B. M., Nogueira *et al.* (2022). Tuberculosis detection in chest radiography: A combined approach of local binary pattern features and monarch butterfly optimization algorithm. In 2022 IEEE 46th Annual Computers, Software, and Applications Conference (COMPSAC), p. 1408–1413. IEEE.
12. Xu, T., Cheng, I., Long, R., and Mandal, M. (2013). Novel coarse-to-fine dual scale technique for tuberculosis cavity detection in chest radiographs. *EURASIP Journal on Image and Video Processing*, 2013(1):1–18.
13. Alfadhli, F. H. O., Mand, A. A., Sayeed, M. S. *et al.* (2017). Classification of tuberculosis with surf spatial pyramid features. In 2017 International Conference on Robotics, Automation and Sciences (ICORAS), p. 1–5. IEEE.
14. Lopes, U. and Valiati, J. F. (2017). Pre-trained convolutional neural networks as feature extractors for tuberculosis detection. *Computers in biology and medicine*, 89:135–143.
15. Rajaraman, S., Zamzmi, G., Folio, L. *et al.* (2021). Chest X-ray bone suppression for improving classification of tuberculosis-consistent findings. *Diagnostics*, 11(5):840.
16. Rajaraman, S., Folio, L. R., Dimperio, J. *et al.* (2021). Improved semantic segmentation of tuberculosis—Consistent findings in chest x-rays using augmented training of modality-specific U-Net models with weak localizations. *Diagnostics*, 11(4):616.
17. Nafisah, S. I. and Muhammad, G. (2022). Tuberculosis detection in chest radiograph using convolutional neural network architecture and explainable artificial intelligence. *Neural Computing and Applications*, p. 1–21.
18. Pasa, F., Golkov, V., Pfeiffer, F. *et al.* (2019). Efficient deep network architectures for fast chest X-ray tuberculosis screening and visualization. *Scientific reports*, 9(1):1–9.
19. Alawi, A. E. B., Al-basser, A., Sallam, A. *et a.* (2021). Convolutional neural networks model for screening tuberculosis disease. In 2021 International Conference of Technology, Science and Administration (ICTSA), p. 1–5. IEEE.
20. Rajaraman, S., Antani, S., Candemir, S. *et al.* (2018). Comparing deep learning models for population screening using chest radiography. In *Medical Imaging 2018: Computer-Aided Diagnosis*, volume 10575, p. 322–332. SPIE.
21. Srimathi, D. H., Rose, D. P., *et al.* (2020). A Comparative Study On Performance Of Pre-Trained Convolutional Neural Networks In Tuberculosis Detection. *European Journal of Molecular & Clinical Medicine*, 7(3):4852–4858.
22. Oltu, B., Güney, S., Dengiz, B., and Agildere, M. (2021). Automated Tuberculosis Detection Using Pre-Trained CNN and SVM. In 2021 44th International Conference on Telecommunications and Signal Processing (TSP), p. 92–95.
23. Khobragade, S., Tiwari, A., Patil, C., and Narke, V. (2016). Automatic detection of major lung diseases using chest radiographs and classification by feed-forward artificial neural network. In 2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES), p. 1–5.
24. Fonseca, A. U., Parreira, P. L., da Silva Vieira, G. S. *et al.* (2024). A novel tuberculosis diagnosis approach using feedforward neural networks and binary pattern of phase congruency. *Intelligent Systems with Applications*, 21:200317.



25. Fonseca, A. U., Felix, J. P., Vieira, G. S. *et al.* (2023). Diagnosticando Tuberculose com Redes Neurais Artificiais e Recursos BPPC. *Journal of Health Informatics*, 15(Especial).
26. Platt, J. (1998). Fast training of support vector machines using sequential minimal optimization. In *Advances in Kernel Methods - Support Vector Learning*. MIT Press.
27. Reeves, S. and Zhe, Z. (1999). Sequential algorithms for observation selection. *IEEE Transactions on Signal Processing*, 47(1):123–132.
28. Gozes, O. and Greenspan, H. (2019). Deep feature learning from a hospital-scale chest x-ray dataset with application to TB detection on a small-scale dataset. In 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), p. 4076–4079. IEEE.