

# Ensemble de especialistas para avaliação de adesão ao procedimento operacional padrão de fotografias de radiografias de tórax

Cecília Aparecida Santos Silva  
Departamento de Automática  
Universidade Federal de Lavras  
Lavras, Brasil  
cecilia.silva1@estudante.ufla.br

Lucas Alexandre Alvarenga Cardoso  
Departamento de Automática  
Universidade Federal de Lavras  
Lavras, Brasil  
lucas.cardoso@estudante.ufla.br

Danton Diego Ferreira  
Departamento de Automática  
Universidade Federal de Lavras  
Lavras, Brasil  
danton@ufla.br

José Manoel de Seixas  
Laboratório de Processamento de  
Sinais  
Universidade Federal do Rio de  
Janeiro  
Rio de Janeiro, Brasil  
seixas@lps.ufjf.br

Mayara Lisboa Soares de Bastos  
McGill University  
International TB Centre  
Rio de Janeiro, Brasil  
mayara\_bastos@yahoo.com.br

Anete Trajman  
Departamento de Clínica Médica  
Universidade Federal do Rio de  
Janeiro  
Rio de Janeiro, Brasil  
atrajman@gmail.com

**Resumo**—Sistemas de apoio ao diagnóstico baseados em inteligência computacional (*computer-aided diagnosis*, CAD) para interpretação de imagens vêm sendo desenvolvidos e aplicados em diferentes especialidades médicas. A Organização Mundial da Saúde recomendou recentemente o uso de CAD para a detecção de tuberculose em radiografias de tórax (RxT). No contexto do desenvolvimento de um CAD, muitas vezes é necessário fotografar imagens de RxT. No entanto, para melhores resultados é preciso que as imagens sigam um padrão, por isso desenvolveu-se um procedimento operacional padrão (POP) para fotografá-las. O objetivo deste estudo é o de criar um modelo baseado em máquinas de comitê (*ensemble*) para avaliar se fotografias de RxT aderem ao POP e classificar eventuais desvios do POP, para então corrigi-los e usar as imagens para a triagem de tuberculose ativa no CAD. Uma base de dados composta por 783 fotografias de radiografias de tórax com diferentes desvios do POP foi dividida em 10 grupos, de acordo com os desvios. Um grupo controle era composto de imagens sem desvios do POP. Os desvios referiam-se ao uso de aplicativos, tripé e temporizador, resolução, luz do ambiente, cobertura total do espaço não ocupado do negatoscópio e centralização. Um modelo *ensemble*, baseado em especialistas, aliado a *transfer learning* e análise de componentes principais (PCA) foi projetado para identificar cada um dos grupos. As acurácias médias para detecção dos desvios foram superiores a 79%.

**Palavras-chave**—Diagnóstico assistido por computador, Tuberculose, *Ensemble*, Redes Neurais, Análise de Componentes Principais.

## I. INTRODUÇÃO

Ferramentas computacionais que auxiliam na detecção e classificação de doenças têm sido desenvolvidas com o propósito de ajudar o profissional de saúde na tomada de decisão. Modelos preditivos de *machine learning* (ML) podem auxiliar na tomada de decisão em inúmeros momentos da atenção à saúde, especialmente no diagnóstico, intervenção e acompanhamento de problemas de saúde [1]. Algoritmos de ML têm sido usados para, por exemplo, prever risco de mortalidade em uma população idosa [2], para predição de incidência de casos de malária [3], diagnóstico baseado em imagem de COVID-19 [4],

detecção de câncer de mama [5] e identificação de grau de risco de pé diabético [6], [7].

Sistemas computadorizados utilizando técnicas de *deep learning* [8] têm sido aprimorados. Entre eles, destacam-se as análises de imagens, em particular de radiografias e tomografias. Estudos de desenvolvimento de diagnóstico auxiliado por computador (CAD) baseados em *deep learning* têm sido apresentados em diversas áreas, como no auxílio ao diagnóstico de COVID-19 e outras pneumonias em imagens de radiografias de tórax (RxT) [8] e na classificação de linfomas malignos com base em imagens de exames histopatológicos [9].

A qualidade de um exame médico com imagem depende da qualidade da imagem e da habilidade do radiologista que a interpreta. A análise computadorizada de imagens tenta melhorar a interpretação do exame de imagens médicas, fornecendo uma segunda opinião ao radiologista, o que caracteriza o uso do CAD.

A Organização Mundial da Saúde recomendou recentemente o uso de CAD em RxT para o rastreamento de tuberculose [10]. Em 2019, no mundo, cerca de 10 milhões de pessoas adoeceram e 1,4 milhões morreram vítimas da tuberculose [11]. Como agravante, os contatos de pacientes com a doença na sua forma mais comum, a pulmonar, correm o risco de contrair o *Mycobacterium tuberculosis* com elevado risco de adoecimento principalmente nos dois primeiros anos após a infecção [12]. Esta e outras populações expostas ou imunodeprimidas, como população privada de liberdade e pessoas vivendo com HIV, têm indicação de rastreio de tuberculose periodicamente. Entre elas, a maior é a de contatos com infecção recente: 56 milhões de pessoas.

Para o rastreamento de contatos, o Ministério da Saúde do Brasil recomenda, para sintomáticos respiratórios, aqueles com prova tuberculínica positiva ou pessoas vivendo com HIV e imunodepressão acentuada, a exclusão da tuberculose ativa por meio da RxT [12] antes de iniciar o tratamento preventivo [12]. No entanto, a falta da RxT e a necessidade de especialistas para interpretar os resultados atrasam ou impedem o processo e, conseqüentemente, o início do tratamento preventivo [13], [14]. Nosso grupo se

propõe a desenvolver um CAD para o apoio diagnóstico de contatos de pacientes com tuberculose pulmonar no Sistema Único de Saúde via técnicas de ML. Como os bancos públicos internacionais de RxT têm limitações, vamos construir um banco de dados com imagens de RxT de diferentes países que participaram de um ensaio clínico internacional [15]. Este banco será disponibilizado publicamente.

Para isso, é preciso que as fotos das radiografias sejam padronizadas e sua qualidade garantida. Sendo assim, foi desenvolvido um procedimento operacional padrão (POP) que descreve o passo a passo que deverá ser seguido pelo operador para garantir o resultado esperado da tarefa [16], conferindo reprodutibilidade às imagens e segurança na triagem. A classificação de desvios ao POP é importante para que se possa informar ao usuário que está fotografando a RxT para que ele ajuste as condições e obtenha uma imagem de melhor qualidade, aderente ao POP. A ideia é que apenas as imagens classificadas como aderentes ao POP sejam processadas pelo sistema de triagem de tuberculose.

Dentre os métodos de ML, os métodos de máquinas de comitê (*ensemble*) [17] têm se destacado por combinarem vários algoritmos de aprendizado para obter melhor desempenho preditivo do que poderia ser obtido com qualquer um dos algoritmos constituintes isoladamente [18]. No presente trabalho, um método *ensemble* foi desenvolvido para avaliar se fotografias de RxT aderem ao POP e classificar eventuais desvios do POP, para então corrigi-los e usar as imagens obtidas para a triagem de tuberculose. O *ensemble* foi construído a partir de classificadores especialistas. Cada classificador ficou especializado em identificar uma combinação de parâmetros que podem fazer a fotografia da RxT divergir do POP. Os desvios referem-se ao uso de aplicativos, tripé e temporizador, resolução, luz

ambiente, cobertura completa do negatoscópio e centralização. A estrutura *ensemble* via especialistas busca explorar a capacidade dos classificadores especialistas de extrair características (*features*) relevantes das imagens que sejam úteis na identificação dos problemas de não adesão ao POP. Os *features* extraídos por cada especialista são concatenados em um único vetor de *features*, usado em uma rede neural do tipo perceptron multi-camadas (multi-layer perceptron, MLP) [19].

A Seção II apresenta base de dados. A Seção III mostra a técnica usada para extrair as características das imagens, bem como todo o processo de classificação. Os resultados são apresentados e discutidos na Seção IV. A Seção V apresenta as conclusões.

## II. BASE DE DADOS

A base de dados é composta por 783 fotografias de RxT, de 128x128 pixels, com diversas características referentes à forma com que a fotografia é registrada, que juntas formam uma configuração de adesão ou não ao POP. A dimensão 128x128 foi escolhida por manter a qualidade requerida pelo sistema de reconhecimento de padrões. A combinação destas características gera um total de dez configurações, em que nove não aderem ao POP e uma é considerada o controle aderente ao POP (a sexta configuração). A Figura 1 detalha cada uma das configurações e suas características. Cada imagem tem uma informação referente à iluminação do ambiente (luz ambiente acesa, apagada ou iluminação por lanterna do celular), uso ou não de tripé, cobertura do negatoscópio (totalmente coberto, descoberto ou parcialmente coberto), centralização da radiografia (centralizada, descentralizada ou rotacionada), resolução (baixa ou normal), uso do temporizador e de aplicativo específico para fotografar.

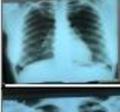
Configuração	Luz	Trípé	Negatoscópio	Centralidade	Resolução	Temporizador	App
	1 ambiente apagada	sem tripé	cobrindo completamente	foto centralizada	normal	com temporizador	sem app
	2 ambiente apagada	sem tripé	cobrindo completamente	foto centralizada	normal	com temporizador	com app
	3 ambiente acesa	sem tripé	cobrindo completamente	foto centralizada	normal	com temporizador	sem app
	4 lanterna do celular	sem tripé	cobrindo completamente	foto centralizada	normal	com temporizador	sem app
	5 ambiente apagada	sem tripé	sem cobrir	foto centralizada	normal	com temporizador	sem app
	6 ambiente apagada	com tripé	cobrindo completamente	foto centralizada	normal	com temporizador	sem app
	7 ambiente apagada	sem tripé	cobrindo completamente	foto centralizada	baixa	com temporizador	sem app
	8 ambiente apagada	sem tripé	cobrindo completamente	foto centralizada	normal	sem temporizador	sem app
	9 ambiente apagada	sem tripé	cobrindo completamente	foto rotacionada	normal	com temporizador	sem app
	10 ambiente apagada	sem tripé	cobrindo completamente	foto centralizada	normal	com temporizador	sem app

Fig. 1. Configurações presentes nas classes da base de dados usada sendo a sexta referente ao POP.

### III. MÉTODO PROPOSTO

A primeira etapa do método proposto consiste em apresentar as imagens a uma rede neural convolucional (CNN) já treinada. Essa estratégia foi adotada já que a base de dados é composta por apenas 783 imagens e as CNN têm muitos parâmetros para serem treinados. Portanto, optou-se pela técnica de *transfer learning* [20], ou seja, aproveitaram-se os pesos de uma rede pré-treinada para imagens com o conjunto *ImageNet*, que é generalista [21]. A ideia do *transfer learning* no contexto deste trabalho é processar as imagens RxT por uma rede profunda já treinada e aproveitar os *features* extraídos pelas camadas profundas. Usou-se a Resnet-18 [22] como rede profunda pré-treinada para realizar o papel de extrator de características. Ela apresenta boa capacidade de extração de características para um espaço de dimensão menor em comparação com redes

profundas de apenas 512 *features*, o que é positivo em termos de custo computacional.

Após a extração de características via *transfer learning*, os dados foram processados pela técnica de Análise de Componentes Principais (*principal component analysis*, PCA) a fim de reduzir a dimensão e eliminar redundâncias. O PCA foi configurado para manter uma variância de 95% dos dados originais. O gráfico de energia do PCA é mostrado na Figura 2.

As novas características geradas pelo PCA com a dimensão reduzida são então apresentadas às redes neurais especialistas com o intuito de obter novas informações em relação a cada classe. Uma rede foi treinada para cada classe considerada (configuração com adesão e as configurações sem adesão ao POP), totalizando 10 redes neurais especialistas. As redes especialistas foram treinadas considerando um problema de classificação binário, fazendo-se Configuração *i* versus demais configurações, para  $i = 1, 2, \dots, 10$ . Cada rede especialista é composta por

um MLP, tipo de rede neural artificial generalista e com grande capacidade de adaptabilidade, que tem como principal função a extração de características de cada classe ao colocá-la em confronto com todas as outras em um processo de classificação binária. Dessa forma é garantido que para cada uma das redes especialistas serão extraídas características referentes à classe (configuração) da imagem em questão.

Para o treinamento e validação das redes especialistas, utilizou-se o *k-fold*, um tipo de validação cruzada (*cross-validation*). O *k-fold* consiste em dividir o conjunto de dados em *k* partes, usando *k-1* para treinamento e o restante para validação. Ao executar um *k-fold* com 10 *folds* para o treinamento de cada especialista, o melhor modelo foi selecionado com base em métricas de acurácia.

A arquitetura das redes especialistas consiste de uma camada intermediária com 2 neurônios. As saídas das camadas intermediárias das redes especialistas serão fonte de informações para o *ensemble*. As características obtidas das redes especialistas por meio de sua camada intermediária foram então concatenadas e assim apresentadas a uma MLP que fez a classificação final do *ensemble*.

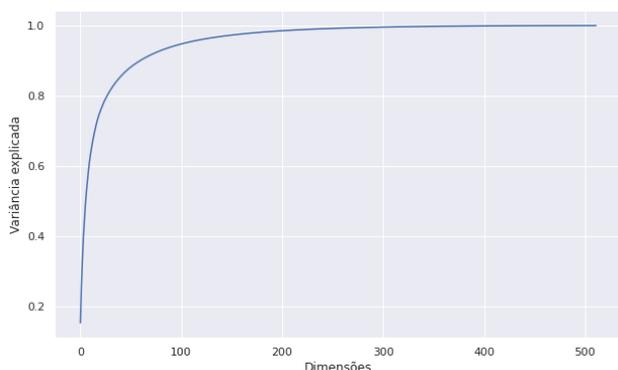


Fig. 2. Energia do PCA em função do número de variáveis.

Seguiu-se então para o projeto do *ensemble*. Nesta etapa, uma MLP foi projetada para que fizesse classificação multiclasse do problema em questão (qual configuração de adesão ou não ao POP a fotografia apresenta). As características das imagens RxT extraídas pela CNN foram submetidas ao PCA, que realiza a redução de dimensão, e, em seguida, às MLPs de cada especialista. As funções de ativação usadas foram a Tangente Hiperbólica e a Sigmoid, sendo a primeira aquela das características submetidas ao PCA. Os valores referentes à saída da camada intermediária de cada especialista, uma representação em menor dimensão das entradas da especialista, foram concatenados. Como resultado foi formado um vetor de 20 características com o rótulo da foto em questão. Com isso, o classificador que indicou qual configuração de não-adesão ao POP foi projetado. Esse classificador é uma MLP com 15 neurônios na camada intermediária e função de ativação Tangente Hiperbólica. Foram utilizados 10 neurônios na última camada, usando a função de ativação *softmax* e o otimizador *AdaptiveMomentEstimation* [23]. O diagrama em blocos do método proposto é apresentado na Figura 3.

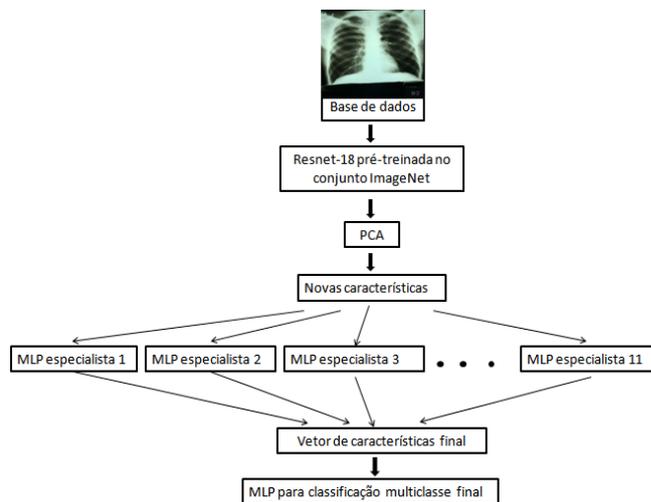


Fig. 3. Método proposto do ensemble

Foi usado o *k-fold*, com *k* igual a 10, para avaliar o *ensemble*. Com isso, foram obtidas as sensibilidade, especificidade e acurácia médias bem como seus respectivos desvios padrões para cada classe (configuração) abordada.

O modelo desse trabalho será implementado em Smartphone e é desejável que ele funcione em todas as marcas. Por isso, trabalhar com o menor custo computacional possível é necessário. Dessa forma, o número de neurônios nas camadas intermediárias das MLPs das especialistas e da MLP do *ensemble* foi ajustado experimentalmente, buscando-se por modelos parcimoniosos.

#### IV. RESULTADOS E DISCUSSÃO

Na Tabela I estão dispostos os valores de acurácia média do *k-fold*, seu desvio padrão e a acurácia do melhor *fold* por especialista para dados de teste. Os valores de acurácia média variaram entre 69,00% e 99,20% com desvio padrão inferior a 6,30%. Nesta etapa, o importante é buscar por especialistas que possuam boa capacidade de extrair características por meio de suas camadas intermediárias. Neste sentido, o bom desempenho de cada especialista alcançado na validação cruzada é um bom indicativo da capacidade de extração de características. Por outro lado, o resultado final do *ensemble* vai também mostrar o quão representativo os *features* extraídos por meio da camada intermediária de cada especialista foram para o classificador.

TABELA I

Acurácia do *k-fold* e do melhor *fold* por especialista para dados de validação

%	Acurácia média do k-fold	Acurácia do melhor fold
Especialista 1	73,80±6,27	81
Especialista 2	93,20±3,76	97
Especialista 3	99,20±1,40	100
Especialista 4	91,30±3,41	95
Especialista 5	89,70±2,86	96
Especialista 6	83,40±4,05	91
Especialista 7	83,60±4,45	90
Especialista 8	69,00±5,08	78
Especialista 9	83,70±5,00	90
Especialista 10	83,80±4,51	91

O pré-processamento aplicado, por meio de *transfer learning*, PCA e redes especialistas, gerou um espaço de características composto por apenas 20 *features*, referentes às saídas das camadas intermediárias das 10 redes especialistas. Com este espaço de características foi possível obter uma MLP final com uma arquitetura mais simples para o *ensemble*, de 20 nodos de entrada, 15 neurônios na camada intermediária e 10 neurônios de saída (20x15x10).

Na Tabela II estão apresentados os valores de sensibilidade, especificidade e acurácia encontrados para cada classe e seus respectivos desvios padrões para o *ensemble* considerando dados de validação. Já na Tabela III encontra-se a matriz de confusão do *k-fold* para o *ensemble*.

TABELA II  
Sensibilidade, especificidade e acurácia por classe no *k-fold* para o *ensemble*

%	Sensibilidade	Especificidade	Acurácia
Classe 1	56,67±23,8	95,44±3,28	91,58±3,43
Classe 2	96,90±6,21	99,61±1,17	99,36±1,17
Classe 3	98,46±4,62	100,00±0,00	99,75±0,75
Classe 4	95,64±5,74	98,54±1,49	98,09±1,92
Classe 5	93,62±9,15	98,29±1,98	97,58±1,84
Classe 6	85,01±6,65	96,65±1,53	95,28±2,06
Classe 7	77,94±21,26	98,52±0,94	97,32±1,66
Classe 8	50,46±21,35	95,66±2,13	90,30±3,69
Classe 9	84,39±14,93	97,72±1,66	96,05±1,99
Classe 10	74,84±16,02	98,07± 1,38	96,17±1,51

As especificidades e as acurácias encontradas no *ensemble* para cada classe foram altas, superiores a 90,00%, e homogêneas, com desvios padrão inferiores a 4,00%. Em contrapartida, as taxas de sensibilidade foram baixas, as das classes 1 e 8 foram inferiores a 57,00%. Como a classe 1 tem temporizador e a classe 8 não tem, e ambas se assemelham (Tabela III), o *ensemble* encontra dificuldades em distinguir esse parâmetro. A classe 1 também é muito confundida com a classe 7, sugerindo que a resolução da imagem, único fator diferente entre essas duas classes, também confunde o *ensemble*. A classe 8 e a classe 6 se confundem também, embora se diferenciem pelo tripé e pelo temporizador.

A baixa sensibilidade das classes 1 e 8 reflete o baixo desempenho das respectivas redes especialistas, conforme mostra a Tabela I. Este resultado pode ser um indicativo de que apenas dois neurônios na camada intermediária destes especialistas podem ser insuficientes para gerar padrões sólidos que representem as imagens destas classes.

As classes 7 e 10 possuem sensibilidade sub-ótima (77,94±21,26% e 74,84±16,02%, respectivamente), porém a classe 7 é mais confundida com a classe 6, que se diferencia por ter tripé e resolução normal. A classe 10 é confundida com a 9. A classe 9 tem imagens rotacionadas e a 10 tem

imagens centralizadas, o que pode ser observado na Figura 1.

A classe 3 é aquela que menos é confundida com as demais, seguida pela classe 2. Ambas se diferem das outras classes por terem a luz do ambiente acesa e por terem feito o uso de aplicativo, respectivamente, no momento de fotografar. Assim, entende-se que esses dois fatores são bem reconhecidos pelo *ensemble*.

A Tabela IV apresenta a matriz de confusão para o modelo *ensemble* que obteve o melhor resultado dentre os 10 *folds*. Pode-se perceber que no melhor modelo *ensemble*, a classe 8 também apresenta resultados inferiores aos demais e é confundida com a classe 1 e com a classe 9, sugerindo que o tripé e a centralização confundem o *ensemble* em cada caso. As classes 1 e 10 apresentaram resultados medianos. Em contrapartida, as classes restantes obtiveram resultados iguais a 100%.

Ao comparar a acurácia da especialista 6, que corresponde a especialista do POP, presente na Tabela I, e a acurácia do modelo *ensemble* para a classe 6, nas Tabelas III e IV, é possível perceber que o *ensemble* apresentou resultados superiores aos encontrados por uma rede individual no que tange à detecção do POP.

TABELA III  
Matriz de confusão do *k-fold* para o *ensemble*

Classe verdadeira	Classe predita										
	%	classe 1	classe 2	classe 3	classe 4	classe 5	classe 6	classe 7	classe 8	classe 9	classe 10
classe 1	56,67±23,84					5,99±6,54		13,45±29,33	15,99±14,30	5,87±10,46	2,02±4,06
classe 2		96,90±6,21								1,43±4,29	1,60±4,80
classe 3			98,46±4,61			1,54±4,61					
classe 4	1,92±4,05				95,64±5,74	1,68±3,37	0,77±2,31				
classe 5	1,82±3,64				4,56±6,12	93,62±9,15					
classe 6	0,77±2,31				1,11±3,33		85,01±6,65	2,02±4,18	8,98±6,77	2,11±4,23	
classe 7	3,33±9,99				2,50±7,50	1,67±4,99	9,22±11,97	77,94±21,26			5,33±11,07
classe 8	19,28±17,21				2,16±4,38	0,77±2,31	14,63±8,62	1,91±3,82	50,46±21,35	3,61±7,86	7,19±9,85
classe 9	5,80±7,51	2,73±8,19					2,68±5,37		2,50±5,34	80,39±26,04	1,91±3,82
classe 10	2,93±6,07				1,67±5,00		1,25±3,75	6,43±15,14	5,79±7,40	7,10±12,56	68,48±23,07

TABELA IV  
Matriz de confusão do melhor modelo do *ensemble*

Classe verdadeira	Classe predita										
	%	classe 1	classe 2	classe 3	classe 4	classe 5	classe 6	classe 7	classe 8	classe 9	classe 10
classe 1		85,71						14,29			
classe 2			100								
classe 3				100							
classe 4					100						
classe 5						100					
classe 6							100				
classe 7								100			
classe 8		12,5							62,5	25	
classe 9										100	
classe 10							12,5		12,5		75

## V. CONCLUSÃO

Um modelo *ensemble* foi proposto para ajudar na verificação da adesão de fotografias de RxT ao POP. Este método foi constituído por 1 CNN pré-treinada no conjunto *ImageNet* 10 MLPs de classificação binária, chamadas especialistas, que atuaram como extratores de características. Estas, por sua vez, formaram uma nova base de dados, que, ao ser submetida à MLP final, identificou em qual parâmetro a fotografia desvia do POP. O uso de PCA para redução de dimensionalidade e de apenas 2 neurônios na camada intermediária das especialistas satisfaz a questão computacional e obteve bons resultados, gerando modelos parcimoniosos.

Conclui-se que o modelo *ensemble* é uma boa alternativa, visto que alcança desempenhos superiores aos classificadores individuais (redes especialistas) que o compõem.

Desdobramentos futuros deste trabalho incluem a testagem de outras ferramentas de redução de dimensionalidade, alterações das dimensões das imagens buscando um menor custo computacional e o aumento da quantidade de neurônios nas camadas intermediárias das redes especialistas com menor desempenho para que possam contribuir mais efetivamente no vetor final de característica.

## REFERÊNCIAS

- [1] Z. Obermeyer, e T. H. Lee, "Lost in thought: the limits of the human mind and the future of medicine". *The New England journal of medicine*, vol. 337, no. 13, pp. 1209, Set. 2017. [Online]. Acessível: <https://doi.org/10.1056/NEJMp1705348>
- [2] S. Rose, "Mortality Risk Score Prediction in an Elderly Population Using Machine Learning", *American Journal of Epidemiology*, vol. 177, no. 5, pp. 443-452, mar. 2013. [Online]. Acessível: <https://doi.org/10.1093/aje/kws241>
- [3] M. Barboza, V. Sampaio, e P. Endo, "Análise e predição de incidência de casos de malária no tempo e no espaço utilizando modelos de deep learning", *Anais Estendidos do XVII Simpósio Brasileiro de Sistemas de Informação*, pp. 175-177, jun. 2021. [Online]. Acessível: <https://doi.org/10.5753/sbsi.2021.15372>
- [4] M. A. Elaziz, K. M. Hosny, A. Salah, M. M. Darwish, S. Lu, e A. T. Sahlol, "New machine learning method for image-based diagnosis of COVID-19", *Plos one*, vol. 15, no. 6, e0235187, jun. 2020. [Online]. Acessível: <https://doi.org/10.1371/journal.pone.0235187>
- [5] L. Marques, R. Magalhães, e D.D. Ferreira, "Inteligência computacional aplicada à detecção de câncer de mama", *Revista Brasileira de Computação Aplicada*, vol. 11, no. 1, pp. 28-35, abr. 2019. [Online]. Acessível: <https://doi.org/10.5335/rbca.v11i1.8727>
- [6] I. C. Resende, L. A. Cardoso, A. C. B.H. Ferreira, B. H. Barbosa, and, D. D. Ferreira, "Identificação de Grau de Risco de Pé Diabético por meio de Técnicas de Aprendizado de Máquinas", *Anais da Sociedade Brasileira de Automática*, vol. 2, no. 1, dez. 2020. [Online]. Acessível: <https://doi.org/10.48011/asba.v2i1.1231>
- [7] A. C. B. H. Ferreira, D.D. Ferreira, H.C. Oliveira, I. C. Resende, A. Anjos, e M. H. B. M. Lopes, "Competitive neural layer-based method to identify people with high risk for diabetic foot", *Computers in biology and medicine*, vol. 120, pp. 103744, maio 2020. [Online]. Acessível: <https://doi.org/10.1016/j.combiomed.2020.103744>
- [8] M.E. Karar, E.E.D. Hemdane, M.A. Shouman, Cascaded deep learning classifiers for computer-aided diagnosis of COVID-19 and pneumonia diseases in X-ray scans. *Complex & Intelligent Systems*, vol. 7, no. 1, pp. 235-247, set. 2021. [Online]. Acessível: <https://doi.org/10.1007/s40747-020-00199-4>
- [9] H. Miyoshi, et al, Deep learning shows the capability of high-level computer-aided diagnosis in malignant lymphoma. *Laboratory Investigation*, vol. 100, no. 10, pp. 1300-1310, maio 2020 [Online]. Acessível: <https://doi.org/10.1038/s41374-020-0442-3>
- [10] WHO. (2021). WHO consolidated guidelines on tuberculosis: module 2: screening: systematic screening for tuberculosis disease. [Online]. Acessível: <https://apps.who.int/iris/bitstream/handle/10665/340255/9789240022676-eng.pdf>
- [11] WHO. (2020). Global Tuberculosis Report 2020. [Online]. Acessível: <https://www.who.int/teams/global-tuberculosis-programme/tb-reports/global-tuberculosis-report-2020>
- [12] Biblioteca Virtual em Saúde. (2019). Manual de recomendações para o controle da tuberculose no Brasil. [Online]. Acessível: [http://bvsmms.saude.gov.br/bvs/publicacoes/manual\\_recomendacoes\\_controle\\_tuberculose\\_brasil\\_2\\_ed.pdf](http://bvsmms.saude.gov.br/bvs/publicacoes/manual_recomendacoes_controle_tuberculose_brasil_2_ed.pdf)
- [13] F. M. Salame, et al, "Knowledge about tuberculosis transmission and prevention and perceptions of health service utilization among index cases and contacts in Brazil: understanding losses in the latent tuberculosis cascade of care". *PLoS One*, vol. 12, no. 9, e0184061, set. 2017. [Online]. Acessível: <https://doi.org/10.1371/journal.pone.0184061>
- [14] M. L. Bastos, et al, "A public health approach to increase treatment of latent TB among household contacts in Brazil". *The International Journal of Tuberculosis and Lung Disease*, vol. 24, no. 10, pp. 1000-1008, out. 2020. [Online]. Acessível: <https://doi.org/10.5588/ijtld.19.0728>
- [15] D. Menzies, et al, "Four months of rifampin or nine months of isoniazid for latent tuberculosis in adults", *New England Journal of Medicine*, vol. 379, no. 5, pp. 440-453, ago. 2018. [Online]. Acessível: DOI: 10.1056/NEJMoa17134283.
- [16] P. O. Estándar, e E. E. S. Hospitalarios, "Procedimento operacional padrão: utilização na assistência de enfermagem em serviços hospitalares", *Rev Latinoam Enfermagem*, vol. 16, no. 6, pp. 16-26, nov. 2008.
- [17] Z. H. Zhou, Ensemble learning. *Encyclopedia of Biometrics*, 2009.
- [18] X. Gao, C. Shan, C. Hu, Z. Niu e Z. Liu, "An Adaptive Ensemble Machine Learning Model for Intrusion Detection", *Institute of Electrical and Electronics Engineers*, vol. 7, pp. 82512-82521, jun. 2019. [Online]. Acessível: <https://doi.org/10.1109/ACCESS.2019.2923640>
- [19] S. S. Haykin, *Redes neurais: princípios e prática*. Bookman Editora, 2007.
- [20] J. Yosinski, J. Clune, Y. Bengio, e H. Lipson, "How transferable are features in deep neural networks?", *Advances in Neural Information Processing Systems*, vol. 27, pp. 3320-3328, dez. 2014. [Online]. Acessível: <https://arxiv.org/abs/1411.1792v1>
- [21] Huh, P. Agrawal, e A. A. Efros, "What makes ImageNet good for transfer learning?", *arXiv preprint*, vol. 2, dez. 2016. [Online]. Acessível: <https://arxiv.org/abs/1608.08614v2>
- [22] K. He, X. Zhang, S. Ren, e J. Sun, December (2016) "Deep residual learning for image recognition", *IEEE conference on computer vision and pattern recognition (CVPR)*, pp. 770-778, dez. 2016. [Online]. Acessível: doi: 10.1109/CVPR.2016.90.
- [23] R.N. Singarimbun, "Adaptive Moment Estimation To Minimize Square Error In Backpropagation Algorithm", *Journal of Computing*

