
Estratégia de Seleção de Clientes no Aprendizado Federado para a Classificação de Imagens Médicas com Otimização por Enxame de Partículas

Leonardo Gabriel Ferreira Rodrigues



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE COMPUTAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Leonardo Gabriel Ferreira Rodrigues

**Estratégia de Seleção de Clientes no Aprendizado
Federado para a Classificação de Imagens Médicas com
Otimização por Enxame de Partículas**

Dissertação de mestrado apresentada ao Programa de Pós-graduação da Faculdade de Computação da Universidade Federal de Uberlândia como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

Área de concentração: Ciência da Computação

Orientador: André Ricardo Backes

Uberlândia
2025

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

R696 Rodrigues, Leonardo Gabriel Ferreira, 1999-
2025 Estratégia de Seleção de Clientes no Aprendizado Federado
para a Classificação de Imagens Médicas com Otimização por
Enxame de Partículas [recurso eletrônico] / Leonardo Gabriel
Ferreira Rodrigues. - 2025.

Orientador: André Ricardo Backes.
Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Ciência da Computação.
Modo de acesso: Internet.
DOI <http://doi.org/10.14393/ufu.di.2025.680>
Inclui bibliografia.
Inclui ilustrações.

1. Computação. I. Backes, André Ricardo, 1981-, (Orient.). II.
Universidade Federal de Uberlândia. Pós-graduação em Ciência da
Computação. III. Título.

CDU: 681.3

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Computação
Av. João Naves de Ávila, 2121, Bloco 1A, Sala 243 - Bairro Santa Mônica, Uberlândia-MG,
CEP 38400-902

Telefone: (34) 3239-4470 - www.ppgco.facom.ufu.br - cpgfacom@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Ciência da Computação			
Defesa de:	Dissertação, 43/2025, PPGCO			
Data:	27 de Novembro de 2025	Hora de início:	14:00	Hora de encerramento: 16:15
Matrícula do Discente:	12412CCP018			
Nome do Discente:	Leonardo Gabriel Ferreira Rodrigues			
Título do Trabalho:	Estratégia de Seleção de Clientes no Aprendizado Federado para a Classificação de Imagens Médicas com Otimização por Enxame de Partículas			
Área de concentração:	Ciência da Computação			
Linha de pesquisa:	Ciência de Dados			
Projeto de Pesquisa de vinculação:	-----			

Reuniu-se por videoconferência, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Ciência da Computação, assim composta: Professores Doutores: Marcelo Zanchetta do Nascimento - FACOM/UFU, Priscila Tiemi Maeda Saito - DC/UFSCar e André Ricardo Backes - DC/UFSCar, orientador do(a) candidato(a).

Os examinadores participaram desde as seguintes localidades: André Ricardo Backes - São Carlos/SP, Priscila Tiemi Maeda Saito - São Carlos/SP. O outro membros da banca e o aluno participaram da cidade de Uberlândia.

Iniciando os trabalhos o presidente da mesa, Prof. Dr. André Ricardo Backes, apresentou a Comissão Examinadora e o(a) candidato(a), agradeceu a presença do público, e concedeu ao(a) Discente a palavra para a exposição do seu trabalho

A seguir o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato(a):

Aprovado

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente

ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **André Ricardo Backes, Usuário Externo**, em 28/11/2025, às 10:26, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Priscila Tiemi Maeda Saito, Usuário Externo**, em 01/12/2025, às 21:13, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcelo Zanchetta do Nascimento, Professor(a) do Magistério Superior**, em 11/12/2025, às 11:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6846130** e o código CRC **15570E56**.

Referência: Processo nº 23117.080535/2025-19

SEI nº 6846130

*Dedico este trabalho a Cristo, que é minha razão de vida, e aos meus pais e irmã, por sempre
acreditarem em mim.*

Agradecimentos

Agradeço a Deus pelo dom da vida, que pela graça nos foi concedida por seu Filho Cristo Jesus. Sou grato a Ele por sempre me amar, me fortalecer e por me ter feito trilhar os caminhos de um pesquisador.

Agradeço aos meus pais, pelo apoio e incentivo de sempre, por cada uma das orações. Ser filho deles e ter sido educado por eles foi e sempre será um privilégio, pois cada degrau acadêmico que obtive êxito e pude alcançar, é resultante dos ensinamentos deles. Nenhuma palavra é suficiente para expressar a gratidão que tenho por eles.

Sou grato pela vida da minha irmã, por ser uma inspiração de vida para mim, principalmente no âmbito acadêmico. Seu esforço como pesquisadora é uma referência para mim e para muitos, resultando em bons frutos de dedicação e persistência. Gratidão ao meu cunhado por cada um dos ensinamentos e contribuições que muito me acrescentaram, não só nesta pesquisa, mas em minha jornada acadêmica, desde a universidade. Cada apoio e incentivo dele foram imprescindíveis em minha trajetória.

Agradeço à Universidade Federal de Viçosa (UFV) pela oportunidade que tive de cursar a graduação. Sou grato a cada um de seus profissionais por cada aprendizado obtido, matérias lecionadas, bem como por me possibilitarem aprimorar o dom de ensinar, por meio de monitorias, pesquisas e publicações de artigos.

Agradeço à Universidade Federal de Uberlândia (UFU), por me ter aberto as portas para o mestrado. Gratidão a cada um de seus profissionais, por todo ensinamento, apoio e incentivo. Graças a esses profissionais aumentei ainda mais minha curva de aprendizagem, e também compreendi os caminhos desta pesquisa.

Por fim, agradeço ao meu orientador, professor André Backes, pelo apoio e incentivo demonstrados em todo o tempo desde o dia em que o solicitei para me orientar nesta pesquisa. Agradeço a ele pelo profissionalismo manifesto em sabedoria por meio de cada um dos ensinamentos, ajustes e valiosas contribuições. Isso me permitiu nortear o melhor caminho, desde a escolha do tema até a escrita final deste trabalho.

“Assim como tu não sabes qual o caminho do vento, nem como se formam os ossos no ventre da mulher grávida, assim também não sabes as obras de Deus, que faz todas as coisas. Porque dele, e por meio dele, e para ele, são todas as coisas. A ele, pois, a glória eternamente.

Amém!”

(Eclesiastes 11.5, Romanos 11.36)

Resumo

Este trabalho propõe uma abordagem baseada em Aprendizado Federado para a avaliação da qualidade de imagens biomédicas, preservando a privacidade dos dados sensíveis dos pacientes. Diferente de métodos tradicionais que centralizam os dados em um único servidor, o Aprendizado Federado permite que o treinamento do modelo ocorra de forma descentralizada, com os dados permanecendo localmente nos dispositivos das instituições participantes. Apesar de seus benefícios de privacidade, o Aprendizado Federado enfrenta a heterogeneidade dos dados e a participação ineficiente dos clientes. A fim de otimizar a eficiência do treinamento colaborativo, e de superar desafios referentes à heterogeneidade dos dados, é incorporado ao sistema um mecanismo de seleção de clientes baseado em Otimização por Enxame de Partículas (PSO), que considera critérios como a qualidade dos dados, diversidade amostral e capacidade computacional dos clientes. Essa estratégia visa melhorar a performance global do modelo ao mesmo tempo em que reduz custos de comunicação e evita o uso ineficiente de recursos. Além disso, supera desafios relacionados à seleção aleatória de clientes realizada com *FedAvg*, que pode se tornar um problema intratável na análise combinatória para obtenção dos melhores clientes. Os experimentos foram conduzidos com conjuntos de dados públicos de doenças, avaliando a robustez do modelo em ambientes heterogêneos. Os resultados demonstram que a combinação entre Aprendizado Federado e *PSO* permite selecionar diferentes quantidades de clientes independente da heterogeneidade dos dados, mantendo os dados seguros e respeitando as restrições de privacidade inerentes ao domínio médico. Dessa forma, o presente trabalho obteve como um dos principais ganhos 99,84% de acurácia com esta proposta.

Palavras-chave: Aprendizado Federado, Seleção de Clientes, Otimização por Enxame de Partículas (*Particle Swarm Optimization - PSO*), *FedAvg*, Preservação de Privacidade em Aprendizado de Máquina.

Abstract

This work introduces a Federated Learning approach to assess the quality of biomedical images while protecting sensitive patient data. Unlike traditional methods that centralize data on a single server, Federated Learning trains models in a decentralized way, keeping data on the local devices of participating institutions. While Federated Learning offers privacy benefits, it struggles with data heterogeneity and inefficient client participation. To address this and improve the efficiency of collaborative training under heterogeneous data, the system integrates a client selection mechanism based on Particle Swarm Optimization (PSO), using factors such as data quality, sample diversity, and computational capacity. This strategy aims to boost overall model performance, reduce communication overhead, and avoid wasting resources. In addition, the proposed method overcomes limitations of random client selection as used in FedAvg, which can become combinatorially intractable when searching for the best subset of clients. Experiments conducted on public disease datasets evaluate model robustness in heterogeneous environments. Results indicate that combining Federated Learning with PSO enables adaptive client selection across varying data heterogeneity levels while maintaining data security and complying with inherent medical domain privacy constraints, achieving up to 99.84% accuracy as one of the main performance gains of this work.

Keywords: Federated Learning, Client Selection, Particle Swarm Optimization, FedAvg, Privacy-Preserving Machine Learning.

Lista de ilustrações

Figura 1 – Principais características das imagens médicas. Adaptado de [Zhou et al. 2021].	23
Figura 2 – Funcionamento do Aprendizado Federado	26
Figura 3 – Etapas da metodologia proposta.	35
Figura 4 – Exemplos de imagens dos conjuntos utilizados, agrupadas por classes: a linha superior representa amostras de classes normais, a linha inferior representa classes de câncer	37
Figura 5 – Etapas do Primeiro Experimento.	42
Figura 6 – Evolução dos valores de loss e acurácia ao longo dos rounds de treinamento de C_1 (imagens de pulmão – esquerda) e C_2 (imagens de cólon – direita).	44
Figura 7 – Comparação das abordagens de acordo com o número de rounds.	46
Figura 8 – Visualização 3D do F1-Score em função do número de clientes e rounds de comunicação.	47
Figura 9 – Processo de seleção de clientes nos experimentos com <i>PSO</i> (Clientes Totais/Selecionados).	48
Figura 10 – Comparação das abordagens avaliadas.	49
Figura 11 – Comparação das abordagens <i>PSO</i> e <i>Baseline</i> quanto ao desempenho das <i>CNNs</i> avaliadas	52
Figura 12 – Seleção de Clientes de acordo com cada <i>CNN</i>	52
Figura 13 – Acuácia Delta de acordo com a <i>CNN</i>	53
Figura 14 – Relação entre a Acurácia, Tempo de Execução e Total de Clientes.	54

Lista de tabelas

Tabela 1 – Resumo dos trabalhos relacionados sobre Aprendizado Federado para detecção de doenças.	33
Tabela 2 – Desempenho de classificação considerando Aprendizado Centralizado e Federado.	43
Tabela 3 – Comparação entre as configurações de melhor desempenho usando <i>PSO</i> e <i>FedAvg</i>	47
Tabela 4 – Resultado comparativo das acurácia do <i>PSO</i> e <i>FedAvg (Baseline)</i> com a SqueezeNet.	50
Tabela 5 – Resultado comparativo das acurácia do <i>PSO</i> e <i>FedAvg (Baseline)</i> com a MobileNet.	50
Tabela 6 – Resultado comparativo das acurácia do <i>PSO</i> e <i>FedAvg (Baseline)</i> com a ResNet.	51
Tabela 7 – Resultado comparativo das acurácia do <i>PSO</i> e <i>FedAvg (Baseline)</i> com a EfficientNet.	51

Lista de algoritmos

1	Seleção Dinâmica de Clientes via <i>PSO</i>	38
---	---	----

Listas de siglas

CNN Rede Neural Convolucional

FedAvg *Federated Averaging*

GANs Redes Adversárias Generativas

HCPA Hospital das Clínicas de Porto Alegre

HIPAA *Health Insurance Portability and Accountability Act*

IA Inteligência Artificial

ILSVRC *ImageNet Large Scale Visual Recognition Challenge*

IoT Internet das Coisas

LC25000 *Histopathological Images of Lung and Colon Cancer*

LLA Leucemia Linfoide Aguda

non-IID Dados não Independentes e não Identicamente Distribuídos

PSO Otimização por Enxame de Partículas

RGPD Regulamento Geral de Proteção de Dados

SMOTE Superamostragem Minoritária Sintética

SVM Máquina de Vetores de Suporte

Sumário

1	INTRODUÇÃO	17
1.1	Motivação	18
1.2	Objetivos e Desafios da Pesquisa	19
1.3	Hipótese	20
1.4	Contribuições	20
1.5	Organização da Dissertação	20
2	FUNDAMENTAÇÃO TEÓRICA	22
2.1	Diagnóstico por Imagem	22
2.2	Redes Neurais Convolucionais	24
2.2.1	Arquitetura Leve (<i>Lightweight Architecture</i>)	25
2.3	Aprendizado Federado	26
2.3.1	Agregação com <i>FedAvg</i>	27
2.3.2	Tipos de Distribuição de Dados entre Clientes	28
2.4	Otimização por Enxame de Partículas (<i>PSO</i>)	28
3	TRABALHOS RELACIONADOS	30
4	MATERIAL E MÉTODOS	34
4.1	Conjuntos de Imagens	35
4.2	Seleção de Clientes no Aprendizado Federado baseada em <i>PSO</i>	36
5	EXPERIMENTOS E ANÁLISE DOS RESULTADOS	41
5.1	Aprendizado Centralizado <i>vs</i> Aprendizado Federado	41
5.2	<i>PSO</i> <i>vs</i> <i>FedAvg</i>	46
5.3	<i>PSO</i> dinâmico <i>vs</i> <i>FedAvg</i>	49
6	CONCLUSÃO	56
6.1	Principais Contribuições	56

6.2	Trabalhos Futuros	57
6.3	Contribuições em Produção Bibliográfica	58
REFERÊNCIAS		59

CAPÍTULO 1

Introdução

O uso de imagens no diagnóstico médico tem se mostrado altamente eficaz, permitindo diagnósticos precisos de diversas enfermidades [Bysani et al. 2023]. Entre essas doenças, destacam-se o câncer, em suas diferentes formas, e doenças respiratórias [Mahmood et al. 2023, Bysani et al. 2023]. Com a crescente digitalização de prontuários médicos e arquivos de imagens, há um interesse crescente em utilizar Inteligência Artificial (IA) para desenvolver sistemas automatizados de diagnóstico que possam auxiliar os médicos e melhorar a precisão diagnóstica [Rodrigues Moreira et al. 2025, Chen, Mat Isa e Liu 2025].

No contexto do aprendizado profundo, destaca-se a utilização de Redes Neurais Convolucionais (*CNNs*) na classificação de imagens provenientes de radiografias, tomografias e microscopia [Mahmood et al. 2023, Vezeteu, Andronescu e Năstac 2025]. As *CNNs* são arquiteturas neurais projetadas para processar dados com estrutura em grade, como imagens, sendo capazes de extrair automaticamente características relevantes a partir de padrões visuais complexos por meio de camadas convolucionais, ao mesmo tempo em que reduzem a complexidade dos dados por meio de camadas de agrupamento (*pooling*) [Li et al. 2022]. A aplicação dessas redes em imagens de microscopia destaca-se como um dos métodos mais promissores no auxílio à detecção de câncer e de doenças autoimunes [Rodrigues, Naldi e Mari 2020, Costa et al. 2023, Li et al. 2022].

Uma característica relevante das *CNNs* é a profundidade. Grande parte dessas redes possuem centenas de camadas e milhões de parâmetros treináveis. Esse aumento de complexidade tornou-se mais evidente após competições de grande escala como o *ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*), que impulsionaram o desenvolvimento de arquiteturas profundas e complexas [Russakovsky et al. 2015, Tan et al. 2023]. Por exemplo, a arquitetura VGG-16 ainda serve como base de comparação para diversos modelos modernos, mesmo com a emergência de arquiteturas mais leves e eficientes como *MobileNetV3* [Howard et al. 2019].

Uma abordagem promissora no diagnóstico médico baseado em imagens é o Aprendizado Federado (*Federated Learning*), uma técnica descentralizada que permite o treinamento colaborativo de modelos mantendo os dados localmente, ao invés de centralizá-los em um único servidor. Essa abordagem apresenta vantagens significativas em termos de escalabilidade e

privacidade, possibilitando que múltiplos conjuntos de dados, armazenados localmente, contribuam para o treinamento do modelo global [McMahan et al. 2017, Guan et al. 2024].

O Aprendizado Federado é particularmente relevante no contexto médico, onde a privacidade dos dados sensíveis dos pacientes é uma preocupação central. Regulamentações como o Regulamento Geral de Proteção de Dados (RGPD) e a *Health Insurance Portability and Accountability Act (HIPAA)* proíbem a transferência direta de dados médicos entre instituições, com o objetivo de evitar a exposição de informações pessoais. A centralização desses dados pode acarretar em violações de privacidade, ataques cibernéticos ou uso indevido das informações, comprometendo a confiança entre pacientes e instituições [Guan et al. 2024].

Nesse cenário, o Aprendizado Federado surge como uma solução robusta, promovendo a segurança dos dados ao evitar sua transferência e garantindo conformidade com as regulamentações éticas [Nguyen et al. 2022]. Além disso, essa abordagem permite lidar com grandes volumes de dados sensíveis, como imagens categorizadas em classes, por exemplo, “câncer” ou “saudável”, sem a necessidade de compartilhar informações pessoais, como nome, idade ou sexo. Apenas os parâmetros dos modelos treinados de forma colaborativa são agregados no servidor central, preservando a confidencialidade dos dados dos pacientes [Guan et al. 2024, Sohan e Basalamah 2023].

No contexto do Aprendizado Federado, estratégias como a seleção inteligente de clientes, têm sido adotadas para priorizar dados mais relevantes e reduzir problemas de inconsistência [Souza et al. 2024, Rehman et al. 2024] por meio de algoritmos evolutivos. Ainda assim, desafios como a heterogeneidade dos dados e a comunicação eficiente entre os clientes permanecem presentes [Tan et al. 2023]. Tais estratégias contribuem para a robustez dos modelos, mesmo em cenários com recursos computacionais limitados [Jiang et al. 2023].

Um dos principais desafios é que a seleção de clientes é um problema combinatório que se torna computacionalmente intratável à medida que o número de clientes aumenta. Este problema é formalmente classificado como NP-difícil, pois requer a análise de um subconjunto ótimo a partir de um conjunto amplo e dinâmico de clientes candidatos sob restrições de heterogeneidade de recursos e dados [Nishio e Yonetani 2019]. Apesar de sua importância, a maioria das implementações de Aprendizado Federado adota estratégias simples de amostragem aleatória, que ignoram a utilidade variável de clientes individuais e podem levar a uma convergência abaixo do ideal, particularmente na área médica, onde os dados são frequentemente escassos, desequilibrados ou especializados.

1.1 Motivação

Diversas pesquisas vêm explorando a integração de Redes Neurais Convolucionais (*CNNs*) ao Aprendizado Federado no contexto do diagnóstico médico por imagem. Entre essas iniciativas, destaca-se a classificação de câncer de mama, um dos temas mais recorrentes na literatura recente. Abordagens incluem o uso combinado de *Redes Adversárias Geradoras (GANs)* com

Aprendizado Federado [Rehman et al. 2024], além da aplicação de modelos leves, como a MobileNetV3 e a EfficientNet, em arquiteturas federadas [Tan et al. 2023]. No entanto, desafios persistem, como a dependência entre amostras e o desequilíbrio na distribuição dos dados, que comprometem a capacidade de generalização dos modelos e dificultam a captura de padrões relevantes em subconjuntos heterogêneos [McMahan et al. 2017, Guan et al. 2024].

No campo do diagnóstico médico assistido por computador, as *CNNs* representam o estado da arte e têm sido amplamente utilizadas em diversas especialidades médicas [Li et al. 2022]. Além disso, configuram-se como uma alternativa economicamente viável em países emergentes quando comparadas a métodos diagnósticos tradicionais [Mahmood et al. 2023]. Apesar de seu potencial, a adoção de soluções baseadas em aprendizado profundo em cenários clínicos reais ainda enfrenta obstáculos, como exigências regulatórias, questões éticas e, sobretudo, preocupações com a privacidade e a segurança dos dados dos pacientes. Tais fatores impõem restrições severas ao compartilhamento de informações entre instituições de saúde [Guan et al. 2024, Nguyen et al. 2022].

Diante desse cenário, este trabalho busca contribuir para o avanço do estado da arte em Aprendizado Federado, enfrentando de forma eficaz os efeitos da abordagem de *Dados não Independentes e não Identicamente Distribuídos (non-IID)* [Souza et al. 2024]. Propõe-se, para isso, uma estratégia de seleção dinâmica de clientes baseada em otimização por enxame de partículas (*PSO*), capaz de lidar com a complexidade combinatória da seleção, um problema classificado como *NP-difícil*. A abordagem visa promover maior robustez e confiabilidade nos modelos treinados em ambientes clínicos, nos quais a precisão na classificação de doenças é essencial para apoiar decisões médicas seguras e eficazes.

1.2 Objetivos e Desafios da Pesquisa

O presente trabalho tem como objetivo aplicar técnicas de Aprendizado Federado, *CNNs* e otimização para enfrentar desafios na classificação de diferentes tipos de câncer, assegurando a preservação da privacidade dos dados. Os objetivos específicos incluem:

- ❑ Propor uma abordagem baseada em Aprendizado Federado e *CNNs* para realizar a classificação de câncer a partir de imagens médicas, utilizando diferentes conjuntos de dados;
- ❑ Avaliar o *PSO* para seleção de clientes no Aprendizado Federado, com foco na preservação da privacidade dos dados durante a transmissão;
- ❑ Avaliar o desempenho do Aprendizado Federado tradicional, da combinação *PSO + Aprendizado Federado* e da abordagem com *PSO* dinâmico para a seleção de clientes;
- ❑ Comparar os resultados obtidos com os presentes na literatura, buscando alcançar ou superar os desempenhos relatados em termos de taxa de classificação, privacidade e eficiência do treinamento.

1.3 Hipótese

O trabalho tem por objetivo investigar a seguinte hipótese referente ao Aprendizado Federado no contexto da detecção de doenças por imagem:

A aplicação de Aprendizado Federado, combinada ao uso do otimizador PSO, permite a seleção dinâmica e eficiente de clientes para o treinamento colaborativo em ambientes de dados heterogêneos, oriundos de múltiplas bases.

1.4 Contribuições

As principais contribuições deste trabalho são:

- Aplicação do Aprendizado Federado para o processamento de dados sensíveis provenientes de diferentes instituições médicas, assegurando conformidade com normas éticas e regulamentações de privacidade;
- Estratégia dinâmica e otimizada de seleção de clientes com base no algoritmo *PSO*, considerando critérios como diversidade e variação amostral, e capacidade computacional, a fim de maximizar a contribuição de cada cliente para o modelo global;
- Análise focada na diversidade dos dados oncológicos, fornecendo subsídios para o desenvolvimento de modelos mais robustos e com maior capacidade de generalização;
- Eficiência computacional e estabilidade do treinamento, por meio da redução do uso de clientes com dados redundantes ou pouco representativos, ao mesmo tempo em que se promove uma participação mais equilibrada dos clientes no processo de Aprendizado Federado.

1.5 Organização da Dissertação

Este trabalho está organizado da seguinte forma:

- **Capítulo 1 - Introdução:** Apresenta o contexto, motivação, objetivos e contribuições do trabalho, além desta organização textual.
- **Capítulo 2 - Fundamentação Teórica:** Aborda os conceitos teóricos essenciais para o entendimento do trabalho, incluindo Aprendizado Federado, Otimização por Enxame de Partículas (*PSO*) e técnicas de processamento de imagens médicas.

- ❑ **Capítulo 3 - Trabalhos Relacionados:** Discute pesquisas anteriores relevantes na área de seleção de clientes em Aprendizado Federado e otimização inteligente.
- ❑ **Capítulo 4 - Material e Métodos:** Detalha a abordagem proposta de seleção dinâmica de clientes usando *PSO*, incluindo arquitetura, algoritmos e configurações experimentais.
- ❑ **Capítulo 5 - Experimentos e Análise dos Resultados:** Apresenta as etapas e configurações dos experimentos realizados, conjuntos de dados utilizados, metodologia de avaliação e análise dos resultados obtidos.
- ❑ **Capítulo 6 - Conclusão:** Sumariza as principais contribuições do trabalho, discute limitações e propõe direções futuras de pesquisa.

CAPÍTULO 2

Fundamentação Teórica

Esta seção aborda os principais conceitos que sustentam o desenvolvimento desta pesquisa, bem como os estudos mais relevantes relacionados ao tema. Além disso, realiza-se uma análise comparativa das abordagens mais avançadas presentes na literatura, com ênfase naquelas que se destacam por seu potencial em superar os desafios do diagnóstico médico assistido por computador com uso de aprendizado federado, principalmente em cenários que envolvem a aplicação em sistemas embarcados.

2.1 Diagnóstico por Imagem

As imagens médicas constituem uma das principais fontes de evidência para análises clínicas e intervenções médicas, correspondendo a aproximadamente 90% dos dados gerados na área da saúde. Essas imagens desempenham um papel essencial no diagnóstico e são amplamente utilizadas no acompanhamento de pacientes, no planejamento de procedimentos cirúrgicos e na aquisição de imagens em tempo real durante intervenções operatórias [Zhou et al. 2021]. Com o avanço das técnicas de Inteligência Artificial (IA), abordagens como o Aprendizado Federado emergem como soluções promissoras para transformar o diagnóstico médico por imagem, ao automatizar tarefas tradicionalmente demoradas e suscetíveis à subjetividade dos especialistas.

Conforme ilustrado na Figura 1, as imagens médicas apresentam características singulares que impõem desafios específicos à visão computacional, influenciando diretamente na escolha de arquiteturas de *deep learning* e no desenho de estratégias baseadas em Aprendizado Federado.

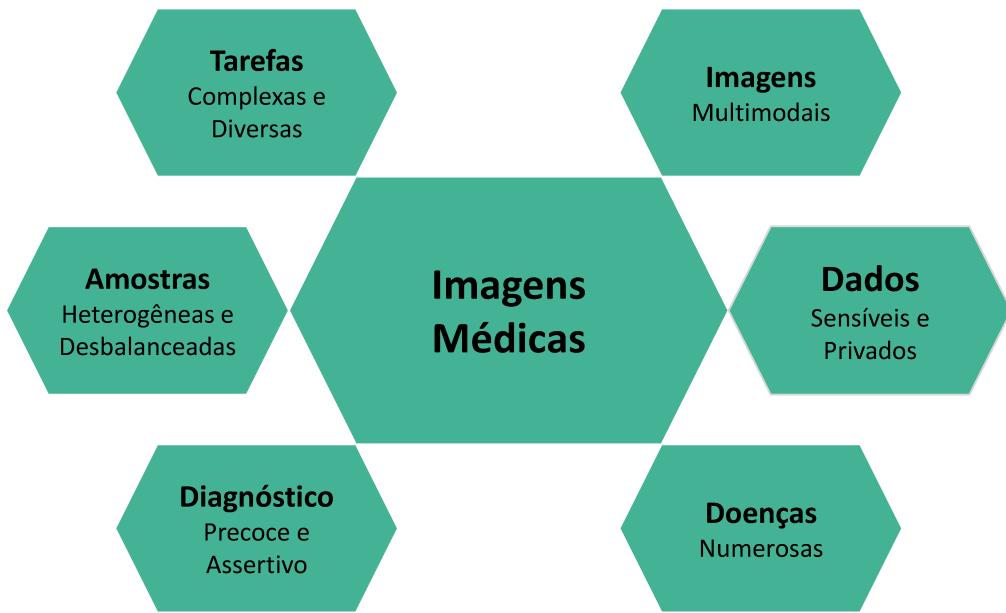


Figura 1 – Principais características das imagens médicas. Adaptado de [Zhou et al. 2021].

Essas imagens englobam diversas modalidades como raio-X, tomografia computadorizada, ressonância magnética, ultrassom e patologia digital, que são frequentemente adquiridas de forma isolada, sem padronização, utilizando equipamentos e configurações de digitalização distintas [Esteva et al. 2019]. Além disso, restrições relacionadas à privacidade dos pacientes e à gestão de dados clínicos dificultam o acesso a grandes bases de dados públicas, o que limita o desenvolvimento de modelos robustos [Zhou et al. 2021].

Outro obstáculo relevante é a expressiva variabilidade nos padrões patológicos presentes nas imagens médicas. Na radiologia, por exemplo, são reconhecidos mais de 12 mil sintomas e mais de 4 mil doenças detectáveis por imagem [Budovec, Lam e Kahn 2014]. Embora algumas condições sejam amplamente representadas em bases de dados, a maioria é rara no ambiente clínico, o que, aliado ao surgimento de novas enfermidades, como evidenciado pela pandemia de COVID-19, impõe desafios adicionais à generalização dos modelos [Esteva et al. 2019] [Rodrigues et al. 2020] [Rodrigues Moreira et al. 2023].

A rotulagem das imagens médicas também representa um ponto crítico. Trata-se de um processo demorado, caro e dependente da expertise dos profissionais da área. Como ainda não há um consenso sobre os critérios de anotação, é comum encontrar inconsistências entre diferentes especialistas [Esteva et al. 2019]. Além disso, muitos conjuntos de dados apresentam desbalanceamento significativo entre classes, o que compromete a eficácia dos modelos de aprendizado. Diante disso, técnicas avançadas de classificação, detecção, segmentação e restauração tornam-se indispensáveis para enfrentar a complexidade inerente ao processamento dessas imagens [Zhou et al. 2021].

2.2 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (do inglês, *Convolutional Neural Networks - CNNs*) são amplamente utilizadas para tarefas de classificação de imagens. Essas redes realizam diversas operações em etapas, aproveitando o contexto espacial das imagens e o compartilhamento de pesos entre os pixels. Isso permite extrair representações hierárquicas e de alto nível dos dados [Goodfellow, Bengio e Courville 2016, Ponti et al. 2017]. As bases para o desenvolvimento das *CNNs* surgiram ainda no final da década de 1970 [Fukushima 1980]. Em 1995, elas foram aplicadas na detecção de nódulos pulmonares em radiografias torácicas [Lo et al. 1995], e, em 1998, a arquitetura LeNet teve sucesso no reconhecimento de dígitos manuscritos [Lecun et al. 1998].

Apesar dos resultados promissores, as *CNNs* só tiveram maior viabilidade com o avanço dos recursos computacionais, principalmente com a popularização da computação paralela e distribuída. A partir de 2012, a arquitetura AlexNet [Krizhevsky, Sutskever e Hinton 2017] marcou um divisor de águas ao vencer a competição *ImageNet Large Scale Visual Recognition Challenge - ILSVRC*, superando significativamente os métodos tradicionais baseados em extração manual de características. Desde então, diversas arquiteturas mais profundas e sofisticadas foram propostas, consolidando as *CNNs* como referência em tarefas de visão computacional [Russakovsky et al. 2015] [Rodrigues Moreira et al. 2025].

O núcleo das *CNNs* é a operação de convolução, que aplica filtros sobre as imagens de entrada para gerar os chamados mapas de características. Esses mapas são essenciais para que a rede possa realizar tarefas como classificação [Goodfellow, Bengio e Courville 2016]. A convolução é definida matematicamente como uma operação local entre a imagem e um filtro, que percorre cada região da imagem e calcula a soma ponderada dos *pixels*. A Equação 1 formaliza esse processo, em que a nova imagem $g(x,y)$ é obtida a partir da imagem original $f(x,y)$ e de um filtro $w(x,y)$ de tamanho $m \times n$:

$$g(x,y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s,t)f(x-s, y-t), \quad (1)$$

sendo $a = \frac{(m-1)}{2}$ e $b = \frac{(n-1)}{2}$.

De forma geral, uma *Rede Neural Convolucional (CNN)* é estruturada em três tipos principais de camadas [Ponti et al. 2017]:

- **Camada Convolucional:** aplica filtros (ou *kernels*) sobre a imagem para extrair padrões locais, como bordas, texturas e formas. Essa camada gera os mapas de características, enquanto funções de ativação, como a *ReLU*, introduzem não linearidade para capturar relações mais complexas;
- **Camada de Pooling:** reduz a dimensionalidade dos mapas de características, mantendo as informações mais relevantes e diminuindo o custo computacional. Os tipos mais co-

mens são *max pooling* (seleciona o valor máximo em uma região) e *average pooling* (calcula a média dos valores);

- **Camada Totalmente Conectada:** transforma os mapas de características em vetores unidimensionais, conectando todos os neurônios entre as camadas. Essa etapa combina as informações extraídas para realizar classificações, normalmente utilizando a função *softmax* para estimar as probabilidades das classes.

A depender da arquitetura, essas camadas podem ser modificadas ou substituídas por outras com funcionalidades semelhantes.

2.2.1 Arquitetura Leve (*Lightweight Architecture*)

Arquiteturas Leves de *CNNs* são variantes projetadas para manter bom desempenho com menor demanda computacional, tornando-se ideais para dispositivos com recursos limitados [Zhou et al. 2021]. A seguir, são descritas algumas dessas arquiteturas.

- **SqueezeNet:** é uma *CNN* compacta apresentada em 2016, com cerca de 50 vezes menos parâmetros que a AlexNet. Sua estrutura é composta por uma camada inicial de convolução, oito módulos denominados “*fire*” e uma camada final de convolução. Cada módulo *fire* inclui um filtro 1×1 seguido de uma camada de expansão, que utiliza filtros 1×1 e 3×3 . Esses módulos desempenham papéis similares aos das camadas densas das redes tradicionais [Iandola et al. 2016] [Koone 2021];
- **MobileNet:** é uma *CNN* eficiente, projetada para dispositivos com recursos computacionais limitados. Introduzida em 2017, sua principal inovação é o uso de convoluções separáveis em profundidade, que decompõem a convolução padrão em duas etapas: uma convolução espacial por canal e uma convolução 1×1 para combinação dos canais. Essa abordagem reduz o número de parâmetros e operações, mantendo desempenho competitivo. A MobileNet é estruturada com uma camada inicial de convolução, seguida por múltiplos blocos com convoluções separáveis e, por fim, camadas densas para classificação. Assim como os módulos *fire* da SqueezeNet, os blocos da MobileNet atuam como unidades modulares de processamento, otimizadas para eficiência em tarefas de visão computacional em tempo real [Sandler et al. 2018] [Howard et al. 2019];
- **ResNet:** apresentada em 2015, revolucionou o treinamento de *CNNs* ao introduzir conexões de atalho, conhecidas como blocos residuais. Esses blocos permitem que os gradientes fluam mais facilmente durante o treinamento, reduzindo o problema do desaparecimento do gradiente. A estrutura da ResNet é composta por uma camada inicial de convolução, seguida por vários blocos residuais que incluem convoluções 3×3 e conexões de identidade, finalizando com uma camada de classificação totalmente conectada.

Os blocos residuais funcionam como unidades modulares, facilitando a construção de arquiteturas com centenas de camadas sem degradação de desempenho [He et al. 2016];

- **EfficientNet:** foi desenvolvida em 2019 com foco em escalabilidade eficiente. Ela introduz um método composto de dimensionamento, que expande de forma equilibrada a profundidade, largura e resolução da rede para otimizar acurácia e eficiência. A base dessa *CNN* é construída sobre blocos de inversões residuais, com convoluções separáveis em profundidade e conexões tipo atalho. Sua estrutura modular e escalável permite atingir alta precisão com menos parâmetros e FLOPs em comparação a outras *CNNs*, como ResNet e MobileNet [Tan e Le 2019].

2.3 Aprendizado Federado

O Aprendizado Federado é um paradigma que visa superar os desafios relacionados à privacidade e à governança de dados, permitindo o treinamento colaborativo de modelos sem a necessidade de centralizar os dados em um único repositório [Guan et al. 2024]. Nessa abordagem, o treinamento é distribuído entre os dispositivos participantes, de forma que os dados sensíveis permaneçam armazenados localmente [Guan et al. 2024]. Tal estratégia garante conformidade com restrições legais e éticas sobre privacidade, sendo especialmente relevante em domínios como a saúde, onde o compartilhamento irrestrito de informações de pacientes é proibido [Rieke et al. 2020, Beutel et al. 2020].

Ao contrário dos métodos tradicionais, no Aprendizado Federado apenas os parâmetros do modelo, como pesos e gradientes, são compartilhados entre os dispositivos e o servidor central. Os dados em si nunca deixam os dispositivos de origem, reduzindo significativamente o risco de exposição de informações sensíveis [Konečný et al. 2016, McMahan et al. 2017]. Além disso, a descentralização do processo permite contornar restrições impostas por *firewalls* institucionais, mantendo os dados sob controle exclusivo das instituições, como hospitais e centros de pesquisa [Rieke et al. 2020].

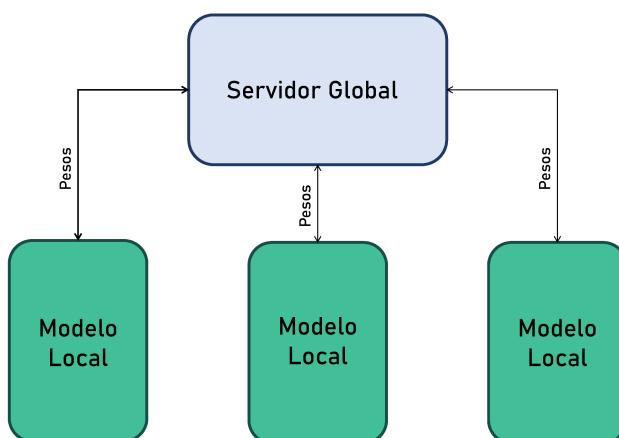


Figura 2 – Funcionamento do Aprendizado Federado

Conforme ilustrado na Figura 2, o processo típico do Aprendizado Federado envolve as seguintes etapas:

- **Treinamento Local:** Cada dispositivo (cliente) treina um modelo local utilizando seus próprios dados;
- **Envio de Atualizações:** Após o treinamento local, os clientes transmitem as atualizações dos parâmetros do modelo (por exemplo, os pesos de uma rede neural) a um servidor central;
- **Agregação Global:** O servidor central realiza a agregação das atualizações recebidas de todos os clientes, construindo um modelo global que reflete as contribuições de cada dispositivo;
- **Redistribuição:** O modelo global é então redistribuído aos clientes, que reiniciam o processo com os parâmetros atualizados.

Esse ciclo iterativo proporciona diversas vantagens, como a preservação da privacidade, o uso eficiente da largura de banda e a capacidade de lidar com dados heterogêneos e geograficamente distribuídos. O Aprendizado Federado tem se mostrado particularmente eficaz em aplicações sensíveis à privacidade, como as da área médica, permitindo realizar tarefas como classificação, segmentação e detecção em imagens clínicas sem comprometer a confidencialidade dos dados [Guan et al. 2024] [McMahan et al. 2017].

2.3.1 Agregação com *FedAvg*

O algoritmo *Federated Averaging (FedAvg)* constitui o método padrão para agregação de modelos locais em ambientes de Aprendizado Federado [McMahan et al. 2017]. Nesta abordagem, cada cliente realiza o treinamento do modelo de forma independente utilizando seus dados locais, enviando posteriormente os parâmetros atualizados para um servidor central. O processo de agregação considera o tamanho do conjunto de dados de cada cliente para ponderar suas contribuições, conforme estabelecido pela Equação 2:

$$L(\mathbf{w}) = \sum_{i=1}^N \frac{n_i}{n} L_i(\mathbf{w}), \quad (2)$$

onde n_i denota o número de amostras no cliente i e $n = \sum_{i=1}^N n_i$ representa o total de amostras considerando todos os clientes. L_i é a função de perda do modelo no cliente i , calculada usando os parâmetros do modelo, que são representados por w . Cada *round* de comunicação compreende uma iteração completa de treinamento local nos clientes e subsequente agregação no servidor. Ao final de cada rodada, o modelo global é atualizado mediante a agregação ponderada dos modelos locais, conforme definido pela Equação 3:

$$\mathbf{w}_{t+1} = \sum_{i=1}^N \frac{n_i}{n} \mathbf{w}_i^{(t)}, \quad (3)$$

sendo \mathbf{w}_{t+1} os parâmetros do modelo global após a rodada $t + 1$. Este mecanismo permite explorar dados distribuídos entre múltiplos clientes, aprimorando o desempenho do modelo enquanto preserva a privacidade dos dados locais.

2.3.2 Tipos de Distribuição de Dados entre Clientes

Esta seção discute os tipos de distribuição de dados utilizados neste trabalho.

□ Distribuição Independente e Identicamente Distribuída (*IID*)

Na distribuição *IID* os dados de cada cliente seguem a mesma distribuição de probabilidade e são estatisticamente independentes entre si. Esta configuração assume que as amostras de um cliente não influenciam as dos outros, todos os clientes possuem a mesma distribuição de classes e características, e mantêm proporções similares de classes em todos os dispositivos. Este cenário é comum em ambientes controlados, mas raro em aplicações reais de Aprendizado Federado, onde os dados naturalmente exibem heterogeneidade [McMahan et al. 2017, Nergiz 2023].

□ Distribuição Não-Independente e Não-Identicamente Distribuída (*non-IID*)

A distribuição *non-IID* reflete a heterogeneidade natural dos dados em ambientes federados reais. Suas principais manifestações incluem variação na distribuição de classes entre clientes, diferenças na distribuição de características dos dados, e disparidades quantitativas na quantidade de amostras por cliente. Esta heterogeneidade introduz desafios significativos para a convergência do modelo, podendo levar a viés de aprendizado e degradação de desempenho, representando o cenário mais comum e desafiador em aplicações práticas de Aprendizado Federado [Nergiz 2023, Sohan e Basalamah 2023].

2.4 Otimização por Enxame de Partículas (*PSO*)

O algoritmo *PSO* é uma técnica metaheurística de otimização populacional inspirada no comportamento coletivo de organismos sociais, como bandos de pássaros e cardumes de peixes [Kennedy e Eberhart 1995]. Introduzido por Kennedy e Eberhart em 1995, o *PSO* simula a interação entre partículas em um espaço de busca multidimensional, onde cada partícula representa uma possível solução para um problema de otimização.

No contexto do Aprendizado Federado, o *PSO* tem se destacado como uma ferramenta eficaz para a seleção dinâmica de clientes participantes do treinamento colaborativo [Souza et al. 2024]. Nesse cenário, cada cliente é modelado como uma partícula que se movimenta em um

espaço de busca definido por atributos como a qualidade dos dados locais, a diversidade amostral, a disponibilidade computacional e a largura de banda da rede. O objetivo é identificar, a cada rodada de treinamento, o subconjunto ideal de clientes que contribuirão com maior eficiência para a atualização do modelo global, maximizando o desempenho e reduzindo o custo de comunicação.

O movimento de cada partícula no espaço de busca é guiado por duas componentes principais: a melhor posição já alcançada individualmente ($pbest$) e a melhor posição conhecida pelo enxame ($gbest$). A atualização da velocidade \mathbf{v}_i e da posição \mathbf{x}_i de cada partícula i em uma iteração t é dada pelas Equações 4 e 5:

$$\mathbf{v}_i(t+1) = w \cdot \mathbf{v}_i(t) + c_1 \cdot r_1 \cdot (\mathbf{pbest}_i - \mathbf{x}_i(t)) + c_2 \cdot r_2 \cdot (\mathbf{gbest} - \mathbf{x}_i(t)) \quad (4)$$

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \mathbf{v}_i(t+1) \quad (5)$$

Onde:

- ❑ w é o fator de inércia, responsável por balancear a exploração e o espaço de busca;
- ❑ c_1 e c_2 são os coeficientes de aceleração, que controlam a influência dos componentes cognitivo (local) e social (global), respectivamente;
- ❑ r_1 e r_2 são variáveis aleatórias com distribuição uniforme em $[0, 1]$, introduzindo estocasticidade ao processo;
- ❑ \mathbf{pbest}_i representa a melhor posição já encontrada pela partícula i ;
- ❑ \mathbf{gbest} representa a melhor posição conhecida por todo o grupo de partículas.

No Aprendizado Federado, o valor da função objetivo associada a cada partícula pode ser definido com base em uma métrica composta, considerando acurácia local, qualidade dos dados, taxa de perda e até mesmo a eficiência energética do dispositivo. Com isso, a seleção de clientes torna-se mais inteligente e adaptativa ao ambiente heterogêneo típico de redes federadas.

Essa estratégia tem se mostrado eficaz na mitigação dos problemas de heterogeneidade (*non-IID*), desbalanceamento e limitação de recursos, promovendo maior robustez, eficiência e escalabilidade do modelo treinado globalmente [Souza et al. 2024].

CAPÍTULO 3

Trabalhos Relacionados

A aplicação do Aprendizado Federado na detecção de doenças tem ganhado destaque em diversos contextos clínicos, devido à sua capacidade de preservar a privacidade dos dados sensíveis. Um exemplo relevante é o trabalho de Rehman et al. 2024, que propõe uma abordagem denominada *FedCSCD-GAN*, a qual integra o Aprendizado Federado com Redes Adversárias Generativas (*GANs*) para a classificação de distintos tipos de câncer, incluindo câncer de próstata, pulmão e mama. Nesse estudo, diferentes hospitais são considerados como clientes distribuídos, possibilitando o treinamento colaborativo do modelo com dados heterogêneos provenientes de múltiplas instituições. A proposta demonstrou resultados expressivos, alcançando acuráncias de 97,80% na detecção de câncer de pulmão, 96,95% para câncer de próstata e 97% para câncer de mama, evidenciando a eficácia da metodologia empregada.

Nergiz 2023 propôs uma abordagem para a classificação de câncer colorretal utilizando aprendizado profundo, Aprendizado Federado e técnicas de aprendizado centralizado. O modelo emprega uma estrutura chamada *Big Transfer*, que é um método de Aprendizado de Representação Visual Geral, juntamente com a arquitetura de aprendizado profundo *VGG* como classificador. Os resultados demonstram o potencial do Aprendizado Federado para generalizar bem em diversos cenários médicos, proporcionando uma avaliação robusta de imagens médicas.

Tan et al. 2023 propuseram o uso de Aprendizado Federado para classificação de câncer de mama, garantindo a privacidade dos dados dos pacientes ao evitar o compartilhamento de informações entre hospitais. A abordagem emprega Aprendizado por Transferência para extrair características de imagens de mamografia, melhorando a precisão diagnóstica. Além disso, aplica a técnica de *Superamostragem Minoritária Sintética (SMOTE)* para balancear o conjunto de dados e aprimorar o desempenho do modelo. Os resultados experimentais mostram que a abordagem proposta atingiu uma acurácia de classificação de aproximadamente 98%.

Subashchandrabose et al. 2023 propuseram uma abordagem baseada em Aprendizado Federado para classificação de câncer de pulmão em múltiplas ordens. Eles integraram modelos de aprendizado de máquina convencionais, especificamente *Máquina de Vetores de Suporte (SVM)* e redes neurais, treinados em diversos conjuntos de dados contendo imagens de câncer de pulmão. Agbley et al. Agbley et al. 2024 propuseram uma abordagem que combina diferentes

fatores de ampliação de imagens histopatológicas utilizando uma rede residual e fusão de informações em Aprendizado Federado para apoiar a classificação automática de câncer de mama. Hossain et al. Hossain et al. 2024 utilizaram o mesmo conjunto de dados considerado em nosso estudo e avaliaram uma Inception-V3 com Aprendizado Federado. No entanto, a abordagem deles abordou apenas dados *IID*, ao contrário do nosso estudo, que examinou um cenário mais complexo de *non-IID*.

Ning et al. 2024 introduziram o *framework FedGCS*, que utiliza uma abordagem gerativa para selecionar clientes de maneira eficiente no Aprendizado Federado. Ele combina otimização baseada em gradientes com métricas como desempenho do modelo, consumo de energia e latência. O método se baseia na geração de representações contínuas de clientes, que são usadas para selecionar os participantes mais adequados para cada rodada de treinamento. Os experimentos mostraram que o *FedGCS* melhora o desempenho do modelo global em até 15% em relação a métodos tradicionais de seleção, ao mesmo tempo que reduz a latência de comunicação em cenários com alta heterogeneidade de dispositivos.

Jiang et al. 2024 abordam a seleção de clientes com restrições de recursos, focando no aprendizado federado para dispositivos de (*Internet das Coisas (IoT)*). Eles utilizaram uma método baseado em clusters para otimizar a seleção de clientes, levando em consideração os limites de energia e capacidade de processamento dos dispositivos. Os resultados mostraram que a estratégia proposta melhora a eficiência do treinamento, reduzindo o consumo de energia e tempo de comunicação em comparação com métodos convencionais

Para abordar os desafios de comunicação no Aprendizado Federado, Souza et al. 2024 propuseram uma técnica de seleção adaptativa de clientes, onde a participação é ajustada com base na relevância de suas contribuições para o modelo global. Este método, além de reduzir o custo de comunicação, mostrou-se eficaz em melhorar a personalização do modelo, especialmente em cenários com dados *non-IID*. Os resultados indicam uma convergência mais rápida e uma melhor precisão global, demonstrando a importância de estratégias adaptativas em sistemas distribuídos.

Miao et al. 2025 propuseram o *FedSAF*, um novo algoritmo de Aprendizado Federado voltado para a detecção de câncer gástrico, visando melhorar o desempenho em cenários com dados não independentes e identicamente distribuídos *non-IID*. O *FedSAF* incorpora técnicas de passagem de mensagens baseadas em atenção e utiliza a Matriz de Informação de Fisher para aprimorar a acurácia do modelo, além de implementar uma função de divisão de modelo para reduzir os custos computacionais e de transmissão. Em experimentos conduzidos com o conjunto de dados GC196, o *FedSAF* alcançou acurácia de até 99,45%, superando métodos como *FedAvg*, *FedProx* e *FedAMP*, o que evidencia sua eficácia em ambientes de dados heterogêneos e com requisitos de privacidade.

Ouyang et al. 2025 propuseram o método *FedDPSO* (*Enhanced Knowledge Distillation and Particle Swarm Optimization for Federated Learning*) para lidar com ruído extremo em rótulos. Nos experimentos, o método alcançou 70,29% de acurácia no CIFAR-10 e 51,96% no CIFAR-

100 sob alta taxa de ruído, superando o *FedAvg* em até 15% e o estado da arte FOCUS em até 11% de acurácia. Além disso, Muntaqim e Smrity 2025 propuseram um método baseado em mecanismos de explicabilidade, com Aprendizado Federado e *VGG19*. Eles alcançaram 98,45% de acurácia na classificação de tumores cerebrais em imagens de ressonância magnética num cenário *non-IID*.

Em contraste com estudos anteriores, este trabalho compara aprendizado federado e centralizado em diferentes contextos. Ao desvincular o processo de otimização da agregação e do treinamento local, preservamos a simplicidade e a eficiência do *FedAvg*, ao mesmo tempo em que introduzimos um mecanismo adaptativo que prioriza os clientes com base no desempenho empírico. Essa estratégia garante a compatibilidade com *pipelines* e Aprendizado Federado padrão e aumenta a robustez em condições heterogêneas e *non-IID*. Consequentemente, o Aprendizado Federado oferece um *framework* promissor para detecção de doenças, permitindo que as instituições mantenham os dados localmente para privacidade e segurança, ao mesmo tempo em que se beneficiam de um modelo global treinado em dados distribuídos de várias fontes, como hospitais ou unidades de saúde. Além disso, o *PSO* permite que essa detecção seja ainda mais assertiva, ao priorizar clientes com melhor desempenho na seleção dinâmica. A Tabela 1 sumariza os trabalhos relacionados abordados na presente seção.

Tabela 1 – Resumo dos trabalhos relacionados sobre Aprendizado Federado para detecção de doenças.

Trabalho	Objetivo	Metodologia	Resultados
[Rehman et al. 2024]	Classificação de câncer (pulmão, próstata, mama)	<i>FedCSCD-GAN</i> com GANs e hospitais como clientes	Acurácia: 97,80% (pulmão), 96,95% (próstata), 97% (mama)
[Nergiz 2023]	Classificação de câncer colorretal	<i>Big Transfer + VGG</i>	Generalização robusta em cenários médicos
[Tan et al. 2023]	Classificação de câncer de mama com privacidade	Transferência + <i>SMOTE</i>	Acurácia: aproximadamente 98%
[Agbley et al. 2024]	Classificação de câncer de mama com fusão multiescala	ResNet e fusão de representações em Aprendizado Federado	Desempenho melhorado em imagens histopatológicas
[Hossain et al. 2024]	Classificação de câncer com Aprendizado Federado	Inception-V3 em contexto <i>IID</i>	Aplicado ao mesmo conjunto de dados deste trabalho
[Ning et al. 2024]	Seleção eficiente de clientes para Aprendizado Federado	<i>FedGCS</i> , representações contínuas e gradientes	Melhoria de até 15% no desempenho, redução de latência
[Jiang et al. 2024]	Seleção de clientes com restrição de recursos (<i>IoT</i>)	Clustering considerando energia e CPU	Redução de tempo e energia na comunicação
[Souza et al. 2024]	Seleção adaptativa de clientes para Aprendizado Federado	Relevância com dados <i>non-IID</i>	Convergência mais rápida e maior personalização
[Miao et al. 2025]	Detecção de câncer gástrico em dados <i>non-IID</i>	Atenção espacial/canal, Fisher Information Matrix, divisão de modelo	Acurácia: 99,45% no conjunto GC196
[Ouyang et al. 2025]	Robustez a ruído extremo em rótulos	<i>FedDPSO</i> com <i>PSO</i> e distilação de conhecimento	CIFAR-10: 70,29%; CIFAR-100: 51,96%
[Muntaqim e Smriti 2025]	Classificação de tumores cerebrais com dados <i>non-IID</i>	Atenção espacial e de canal com Aprendizado Federado	Acurácia: 98,45%
Presente Trabalho	Diagnóstico médico por imagem com Aprendizado Federado	<i>FedAvg + PSO: PSO</i> para seleção de clientes + Aprendizado Federado + DNNs	Utilizando dados heterogêneos, a estratégia alcançou resultados muito relevantes, como 99,84% de acurácia.

CAPÍTULO 4

Material e Métodos

O presente trabalho aplica técnicas de Aprendizado Federado e *PSO* para classificação e avaliação de imagens médicas em ambientes distribuídos. A proposta visa atender às crescentes demandas por privacidade e segurança no contexto do diagnóstico médico por imagem por meio de uma estratégia de seleção dinâmica de clientes.

A junção do paradigma de Aprendizado Federado com o algoritmo *PSO*, emprega um mecanismo de seleção de um subconjunto de clientes com melhor desempenho em um conjunto total de clientes no espaço de busca. Essa abordagem evita a centralização de dados e promove uma escolha mais criteriosa dos participantes, respeitando as limitações de comunicação e processamento.

A arquitetura do método define um modelo global baseado em redes neurais convolucionais, projetado para tarefas de classificação e extração complexa de características. Arquiteturas como SqueezeNet, MobileNet, ResNet e EfficientNet são compatíveis e utilizadas de acordo com as características computacionais do ambiente. A escolha de tais *CNNs* reside no fato de que são arquiteturas leves e também profundas. Isso possibilita o treinamento de modelos tanto em sistemas com menor quantidade de recursos computacionais, quanto em sistemas mais robustos.

Posteriormente, o *PSO* seleciona, de forma inteligente, os clientes que terão maior contribuição para o avanço do modelo global em cada rodada do Aprendizado Federado. Com essa estratégia, promove-se uma otimização tanto da performance do modelo quanto do uso dos recursos computacionais de rede e processamento.

Após a seleção dos clientes, o treinamento do modelo ocorre nos clientes escolhidos. Cada um realiza o ajuste local dos parâmetros do modelo com base em seus dados privados e, ao final da iteração, envia apenas os parâmetros atualizados ao servidor central. Este, por sua vez, realiza a agregação global, e redistribui o modelo atualizado para os clientes, reiniciando o ciclo de treinamento.

O método proposto apresenta os seguintes diferenciais:

- Garante privacidade total dos dados, uma vez que nenhuma imagem médica deixa o dis-

positivo de origem;

- ❑ Implementa uma seleção adaptativa e otimizada de clientes por meio do *PSO*, priorizando qualidade e diversidade dos dados;
- ❑ Suporta ambientes com dados heterogêneos e distribuídos geograficamente, característica comum em aplicações médicas em larga escala;
- ❑ É compatível com múltiplas arquiteturas de redes neurais, permitindo sua aplicação em diferentes contextos e conjuntos de dados.

Na Figura 3 é ilustrado o fluxo operacional do método proposto, organizado em etapas sequenciais, mas com estrutura flexível para permitir reavaliações iterativas do processo. Os experimentos foram conduzidos com conjuntos de dados publicamente disponíveis, o que possibilita reproduzibilidade e comparações futuras com abordagens distintas.

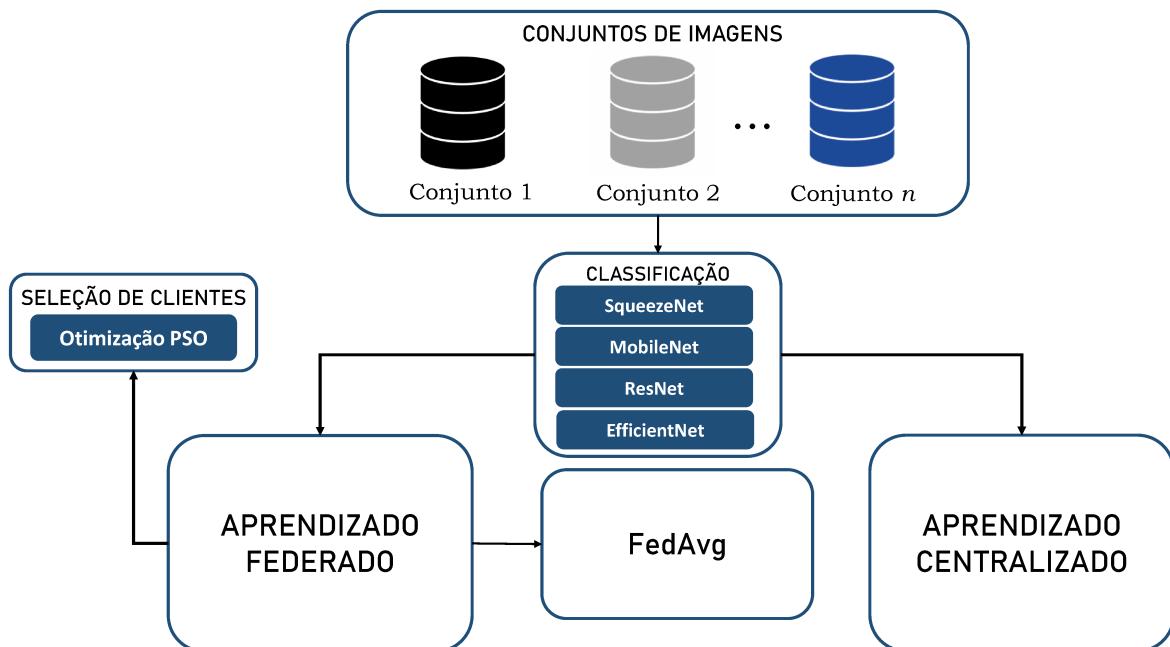


Figura 3 – Etapas da metodologia proposta.

4.1 Conjuntos de Imagens

Este trabalho explora três conjuntos distintos de imagens médicas, abrangendo diferentes domínios clínicos: *Histopathological Images of Lung and Colon Cancer (LC25000)*¹, *Biglycan*² e *ALL-IDB*³. Esses conjuntos de imagens apresentam diferentes desafios de complexidade

¹ <<https://www.kaggle.com/andrewmvd/lung-and-colon-cancer-histopathological-images>>

² <<https://data.mendeley.com/datasets/mpsrccwxb7/3>>

³ <<https://scotti.di.unimi.it/all/>>

e granularidade, fornecendo um cenário propício para a avaliação *non-iid* para o método proposto. A Figura 4 mostra exemplos de imagens dos conjuntos de imagens utilizados, incluindo classes normais e cancerígenas.

O conjunto de dados *LC25000* contém 25.000 imagens RGB de 768×768 pixels, igualmente distribuídas em cinco categorias histopatológicas [Borkowski et al. 2019]. O conjunto *LC25000* é composto por dois subconjuntos: imagens de tecido de cólon e de pulmão. O subconjunto de cólon possui duas classes: tecido de cólon normal (10.000 imagens) e adenocarcinoma de cólon (10.000 imagens), que foram usadas diretamente para a classificação binária. O subconjunto de pulmão contém três classes: tecido pulmonar benigno (5.000 imagens), adenocarcinoma de pulmão (5.000 imagens) e carcinoma de células escamosas pulmonares (5.000 imagens). Nos experimentos, as duas classes malignas de pulmão foram categorizadas em uma única classe de câncer, resultando em uma tarefa de classificação binária que contrastou tecidos normais e cancerosos.

O conjunto *Biglycan* comprehende fotomicrografias imuno-histoquímicas de amostras de tecido mamário coletadas dos arquivos de patologia do Hospital das Clínicas de Porto Alegre (HCPA), Brasil. As imagens foram adquiridas usando um microscópio óptico acoplado a uma câmera digital colorida. O conjunto de dados contém 336 imagens RGB, cada uma com resolução de 128×128 pixels, e está organizado em duas classes: câncer (203 imagens) e tecido saudável (133 imagens) [Silva Neto et al. 2023].

O *ALL-IDB* reúne imagens microscópicas de esfregaços sanguíneos, produzido pela Universidade de Milão em parceria com o Laboratório de Citomorfologia do Hospital Maggiore Policlinico, e projetado para avaliar métodos automatizados para diagnóstico de leucemia. Ele visa especificamente a classificação binária de leucócitos em termos da presença ou ausência de Leucemia Linfoide Aguda (LLA). O conjunto de dados contém imagens com recortes centralizados em células individuais adquiridas usando microscopia óptica com resolução e condições de iluminação consistentes. Cada imagem foi rotulada como normal ou leucêmica, permitindo aplicação direta em tarefas de aprendizado supervisionado [Labati, Piuri e Scotti 2011]. Neste estudo, utilizamos o subconjunto *ALL-IDB2*, que inclui imagens de células individuais pré-extraídas, adequadas para treinamento e avaliação de *CNNs*.

4.2 Seleção de Clientes no Aprendizado Federado baseada em *PSO*

A escolha de quais clientes participarão de cada rodada de treinamento em Aprendizado Federado é uma tarefa desafiadora diante da diversidade de dados e da variação dos recursos computacionais disponíveis entre os dispositivos. Métodos tradicionais, como o *FedAvg*, normalmente selecionam os clientes de forma aleatória a cada rodada [McMahan et al. 2017, Guan et al. 2024, Naghib, Gharehchopogh e Zamanifar 2025]. Embora essa estratégia seja simples

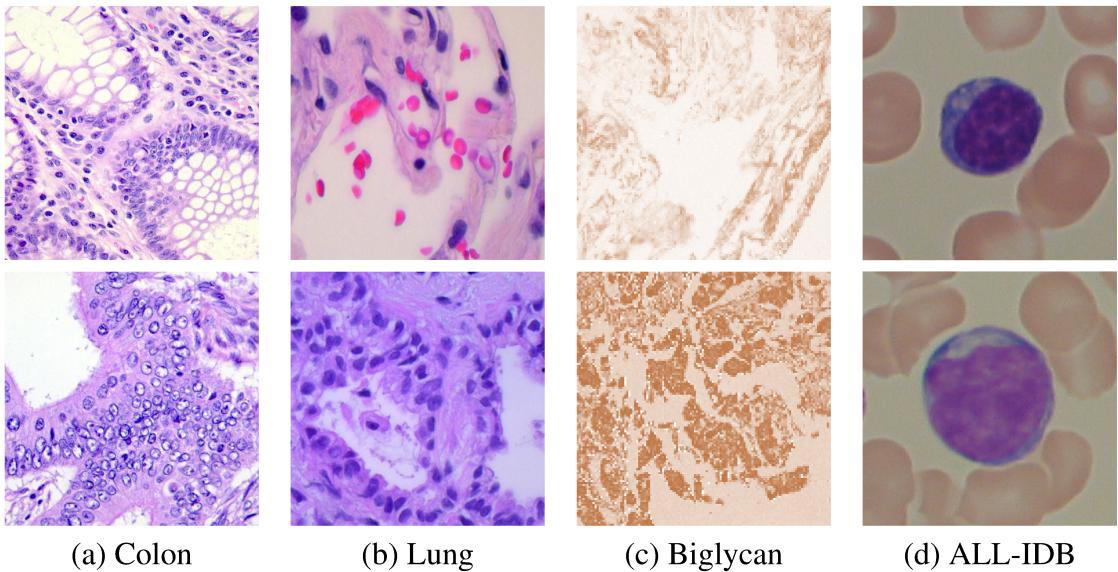


Figura 4 – Exemplos de imagens dos conjuntos utilizados, agrupadas por classes: a linha superior representa amostras de classes normais, a linha inferior representa classes de câncer

e eficiente, ela ignora aspectos importantes, como o histórico de desempenho dos clientes ou suas capacidades locais, o que pode comprometer a qualidade do modelo treinado.

Neste trabalho, é proposta uma abordagem que substitui a seleção aleatória por um mecanismo baseado em *PSO*, com o objetivo de tornar o processo de seleção mais eficiente e orientado por dados. O *FedAvg* direciona a estratégia de agregação, dada sua simplicidade e robustez. A seleção dinâmica dos clientes é realizada com base no desempenho empírico de cada cliente. Esse processo prioriza clientes com dados potencialmente mais úteis, promovendo melhorias na convergência e na precisão do modelo em cenários com dados médicos heterogêneos.

O *PSO* [Kennedy e Eberhart 1995] utilizado, trata-se de uma metaheurística populacional que é eficiente na exploração de espaços de busca complexos e de alta dimensionalidade. Em contraste a métodos exaustivos ou gananciosos, o *PSO* realiza uma busca adaptativa que equilibra exploração e aproveitamento ao simular partículas em movimento, ajustando suas posições com base nas melhores soluções individuais e coletivas. Isso permite identificar subconjuntos de clientes com alto potencial de contribuição ao modelo, considerando métricas recentes de desempenho e mantendo baixo custo computacional. Aplicações anteriores do *PSO* em contextos federados reforçam sua adequação para esta tarefa.

O Algoritmo 1 descreve o método proposto para a seleção dinâmica de clientes com base em *PSO*. A população foi inicializada com 20 soluções candidatas, com o intuito de se obter equilíbrio entre eficiência na busca das melhores partículas e desempenho computacional. Os parâmetros c_1 , c_2 e w foram inicializados com 1,8 e 0,7 respectivamente de acordo com a literatura, para melhor convergência dos movimentos no espaço de busca [Kennedy e Eberhart 1995].

O processo inicia com a identificação dos clientes cujo desempenho recente está disponí-

Algoritmo 1 Seleção Dinâmica de Clientes via *PSO*

Require: Pontuações dos clientes disponíveis, número de clientes a selecionar k

Ensure: Conjunto de clientes selecionados

Obter a lista de clientes disponíveis no gerenciador

Filtrar apenas clientes com identificadores válidos

if número de clientes válidos < k **then**

 Selecionar aleatoriamente k clientes

return clientes selecionados

end if

Obter os IDs e as pontuações correspondentes

Definir o problema de *PSO* para maximizar a soma das pontuações dos k melhores clientes

Iniciar o *PSO* com população = 20, $c_1 = c_2 = 1,8$, $w = 0,7$

Executar a otimização por 500 iterações

Selecionar os k clientes com maiores valores de prioridade na melhor partícula

for all clientes selecionados **do**

 Incrementar o contador de participação do cliente

end for

return clientes selecionados

vel. Se o número de clientes com dados for insuficiente, aplica-se uma seleção aleatória. Caso contrário, o problema é formulado como uma tarefa de otimização, cuja função objetivo busca maximizar a soma das pontuações dos k clientes mais promissores. Nesse cenário, cada partícula no *PSO* representa uma solução candidata, que é um vetor com valores contínuos, cujos elementos indicam a prioridade de seleção dos clientes. A cada iteração, os k clientes correspondentes aos maiores valores da partícula são selecionados.

Após 500 avaliações com parâmetros fixos, a melhor partícula encontrada determina o subconjunto de clientes que participará da rodada. Esse mecanismo adaptativo permite ao sistema favorecer automaticamente os clientes com maior probabilidade de gerar atualizações de qualidade para o modelo global, promovendo melhorias de desempenho e reduzindo a aleatoriedade do processo. O processo de seleção dinâmica de clientes opera através de um mecanismo adaptativo baseado em otimização por enxame de partículas (*PSO*) pode ser detalhado nas seguintes etapas:

1. **Identificação de Clientes Disponíveis:** O sistema verifica quais clientes possuem dados de desempenho recentes armazenados no servidor central. Estes dados correspondem às métricas de avaliação (acurácia, *loss*, F1-Score) obtidas nas rodadas anteriores.
2. **Verificação de Viabilidade:** Se o número de clientes com histórico disponível for inferior a um *threshold* pré-definido (ex: 5 clientes), o algoritmo recorre a uma seleção aleatória tradicional como recuo, garantindo que o treinamento não seja interrompido.
3. **Formulação do Problema de Otimização:** Com clientes suficientes, o problema é mo-

delado como uma tarefa de maximização:

$$\max \sum_{i=1}^k s_i \cdot x_i \quad (6)$$

onde s_i representa a pontuação do cliente i e x_i é uma variável binária indicando seleção, sujeita à restrição $\sum x_i = k$.

4. **Representação das Partículas:** Cada partícula no enxame PSO é um vetor $\mathbf{p} = [p_1, p_2, \dots, p_N]$ onde $p_i \in \mathbb{R}$ representa a prioridade de seleção do cliente i . Valores mais altos indicam maior aptidão para participação.
5. **Decodificação das Soluções:** A cada iteração, decodifica-se a partícula selecionando os k clientes com os maiores valores no vetor. Esta abordagem é contínua, e permite buscas mais eficiente no espaço de soluções.
6. **Função de Avaliação:** A qualidade de cada partícula é calculada através de uma função objetivo que considera:

$$f(\mathbf{p}) = \sum_{j=1}^k \alpha \cdot s_j + \beta \cdot d_j + \gamma \cdot (1 - c_j) \quad (7)$$

onde s_j é o score de desempenho, d_j mede a diversidade dos dados, c_j representa o custo computacional, e α, β, γ são pesos de ponderação. No presente trabalho, estes parâmetros foram inicializados com valores *default*. Apenas no α que utilizamos com valores de 0,5 e 0,6. Essa estratégia tornou o desempenho do PSO ainda mais eficiente.

7. **Processo Iterativo:** O PSO executa 500 avaliações da função objetivo. Esse número está relacionado com o equilíbrio entre convergência e custo computacional, visto que 50 pode resultar em menor convergência, e 5000 em maior consumo de recursos computacionais [Kennedy e Eberhart 1995]. Assim, o processo mantém:

- ❑ p_{best} : Melhor solução encontrada por cada partícula
- ❑ g_{best} : Melhor solução global do enxame
- ❑ Atualização de velocidades e posições pelas equações clássicas do PSO

8. **Seleção Final:** Após convergência, a partícula g_{best} determina o subconjunto ótimo de clientes. Os k clientes com maiores valores em g_{best} são selecionados para a rodada.

Este mecanismo permite que o sistema adapte-se dinamicamente às condições variáveis da rede, priorizando clientes que oferecem maior potencial de contribuição para o modelo global. A abordagem reduz significativamente a aleatoriedade do processo de seleção enquanto mantém diversidade suficiente para evitar *overfitting* e viés de seleção.

Ao integrar o *PSO* ao processo de seleção de clientes a abordagem proposta oferece uma alternativa eficaz à seleção aleatória. A estratégia busca formar subconjuntos com maior potencial de contribuição, promovendo melhor convergência do modelo, maior acurácia e uso mais eficiente dos recursos computacionais disponíveis no ambiente federado.

CAPÍTULO 5

Experimentos e Análise dos Resultados

Com o intuito de avaliar a solução do método proposto, diversos experimentos foram realizados com configurações distintas de: quantidade de clientes, número de clientes selecionados por rodada e rodadas de transmissão. Os experimentos foram executados no ambiente de teste *Fabric* [Baldin et al. 2019], utilizando uma máquina virtual com 32 GB de RAM, 16vCPUs e uma GPU NVIDIA Quadro RTX 6000. O ambiente de simulação foi construído utilizando Python 3.12.8, PyTorch 2.5.1 com CUDA 12.1 e Flower 1.17.0, e executando no Ubuntu 20.04.6 LTS.

Os experimentos compararam o método proposto com um *baseline* adotado pelo algoritmo *FedAvg*, que realiza a seleção aleatória de clientes [McMahan et al. 2017]. A avaliação de cada abordagem foi feita por meio de quatro arquiteturas *CNNs*: SqueezeNet, MobileNet-V2, ResNet-18 e EfficientNet-B0. Também foi feita uma comparação entre o *FedAvg* e o *PSO* dinâmico, utilizando a distribuição de dados *non-IID*.

5.1 Aprendizado Centralizado vs Aprendizado Federado

Como ponto de partida, conduziu-se um estudo comparativo entre as abordagens de Aprendizado Centralizado e Federado para avaliar sua eficácia na classificação de dados heterogêneos e não independentemente distribuídos (*non-IID*). Utilizou-se o conjunto *LC25000*, onde na configuração centralizada todos os dados foram consolidados em um único servidor para treinamento e teste do modelo, conforme ilustrado na Figura 5.

A metodologia proposta, detalhada na Figura 5, organiza os dados em duas configurações distintas. Na abordagem centralizada, os dados são processados em um único servidor, enquanto no Aprendizado Federado, dois clientes (C_1 e C_2) realizam treinamentos locais com distribuição *non-IID*.

A escolha por dois clientes baseia-se na representatividade da heterogeneidade de domínios, onde cada cliente incorpora um conjunto distinto de imagens (ex.: câncer colorretal vs. pulmo-

nar). Um outro fator fundamental na decisão foi o controle experimental, que isola o impacto da heterogeneidade dos dados sem a complexidade adicional de múltiplos clientes. Esta configuração desbalanceada torna o processo de agregação no servidor particularmente desafiador, testando a robustez do método em condições adversas. Os gradientes ou parâmetros dos modelos locais são agregados periodicamente no servidor central apesar de cada rodada de comunicação, atualizando o modelo global através do algoritmo *FedAvg* ou similar.

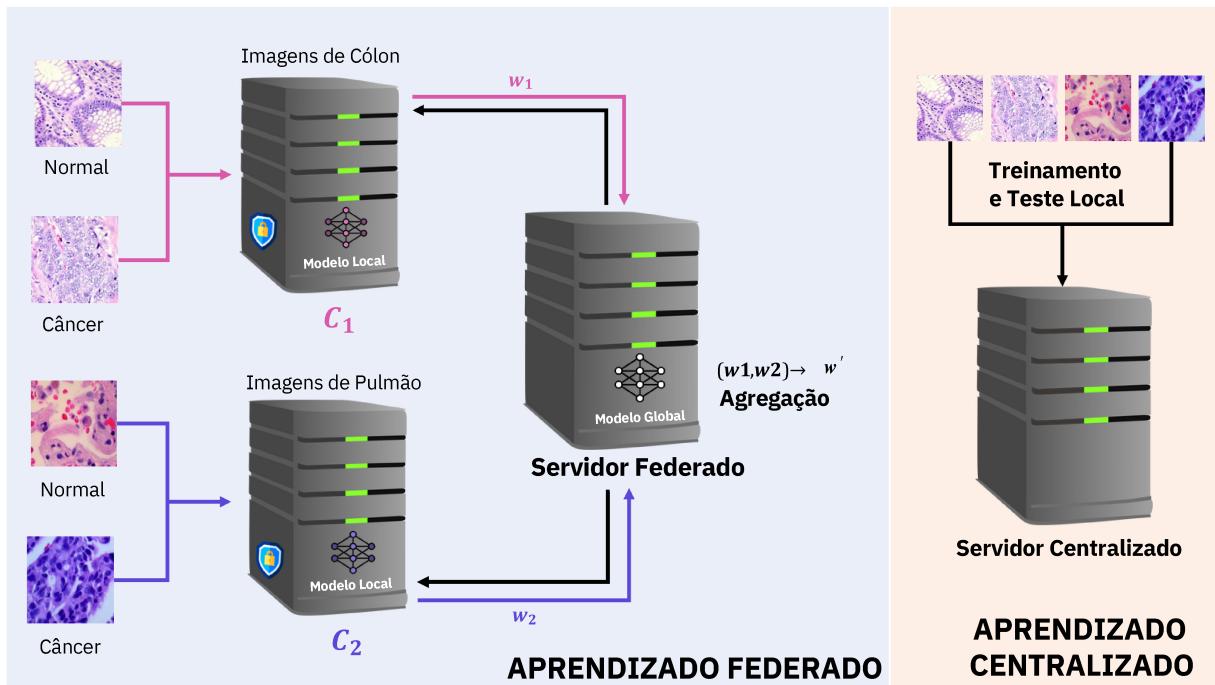


Figura 5 – Etapas do Primeiro Experimento.

Essas imagens foram divididas em duas classes: normal e câncer. Os dados foram treinados em cada um desses clientes considerando três *rounds* de treinamento. A quantidade de *rounds* foi escolhida como ponto de partida para uma convergência válida dos modelos treinados. Ao fim do terceiro *round*, o servidor global agrupa todas as informações obtidas pelos clientes e atualiza o modelo.

O pré-processamento das imagens incluiu redimensionamento para 224×224 pixels, formato compatível com a arquitetura SqueezeNet. A configuração de treinamento empregou o otimizador SGD com taxa de aprendizado de 0,001, tamanho de lote de 64 e 30 épocas – parâmetros definidos mediante experimentos preliminares que demonstraram estabilidade de convergência nestas condições.

A implementação do Aprendizado Federado foi feita com o algoritmo *FedAvg*, organizando os clientes nos grupos C_1 e C_2 e utilizando um servidor central para agregação. Neste paradigma, cada cliente treina seu modelo local com dados particulares, enquanto o servidor consolida periodicamente os parâmetros dos modelos locais para atualizar o modelo global.

Esta arquitetura evidencia contrastes fundamentais entre métodos centralizados e federados quanto à privacidade, comunicação e fluxo de treinamento. O ambiente simulado reproduziu cenários realistas de dados distribuídos em múltiplos dispositivos, onde a privacidade é preser-

vada pela retenção local dos dados, ainda que se permita o treinamento colaborativo através de agregação segura de parâmetros.

Na abordagem centralizada, foram conduzidos experimentos abrangendo seis cenários distintos de treinamento e teste. Em todos os cenários, considerou-se a estratégia *holdout* com particionamento de 80% dos dados para treinamento e 20% para teste. O primeiro cenário utilizou imagens colorretais para treinamento e um conjunto híbrido (colorretal e pulmonar) para teste. O segundo cenário inverte esta configuração, empregando imagens pulmonares para treinamento e o conjunto híbrido para validação. Os cenários três e cinco mantêm o treinamento com dados colorretais, porém diferem nos conjuntos de teste: pulmonar no terceiro e colorretal no quinto. Similarmente, os cenários quatro e seis utilizam dados pulmonares para treinamento, mas variam entre testes colorretais (quarto) e pulmonares (sexto). Todos os experimentos empregaram a arquitetura SqueezeNet, visto que o intuito era apenas a comparação entre a abordagem centralizada e federada. Os resultados estão sumarizados na Tabela 2.

Tabela 2 – Desempenho de classificação considerando Aprendizado Centralizado e Federado.

Experimento	Treino	Teste	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
Centralizado	Côlon	Côlon + Pulmão	89,86	89,45	89,41	89,43
	Pulmão	Côlon + Pulmão	60,00	30,00	50,00	37,50
	Côlon	Pulmão	66,67	33,33	50,00	40,00
	Pulmão	Côlon	50,00	25,00	50,00	33,33
	Côlon	Côlon	50,55	50,00	25,27	33,58
	Pulmão	Pulmão	100	100	100	100
Aprendizado Federado	C₁: Côlon	Servidor:	99,32	99,28	99,31	99,32
	C₂: Pulmão	Côlon + Pulmão				
Federado	C ₁ : Côlon	Servidor:	98,43	98,85	97,64	98,21
	C ₂ : Pulmão	Pulmão				
	C ₁ : Côlon	Servidor:	48,40	50,00	24,20	32,61
	C ₂ : Pulmão	Côlon				

Os resultados demonstram que a estratégia de Aprendizado Federado emulou eficazmente um ambiente hospitalar na detecção simultânea de duas patologias distintas. Para fins de classificação, todas as imagens patológicas foram agrupadas numa única classe denominada câncer, enquanto as imagens saudáveis constituíram a classe normal.

A Figura 6 ilustra a dinâmica temporal da função de perda e da acurácia durante o treinamento dos clientes C_1 e C_2 através de múltiplas rodadas. Cada round corresponde a um ciclo completo de treinamento local, transmissão de parâmetros ao servidor central, e agregação global. A convergência acelerada para baixos valores de perda e altas taxas de acurácia em ambos os clientes indica que os modelos locais se adaptaram adequadamente aos seus respectivos conjuntos de dados. Esta observação sugere que o processo de agregação no Aprendizado Federado combina eficientemente as contribuições dos clientes, produzindo modelos com boa capacidade de generalização.

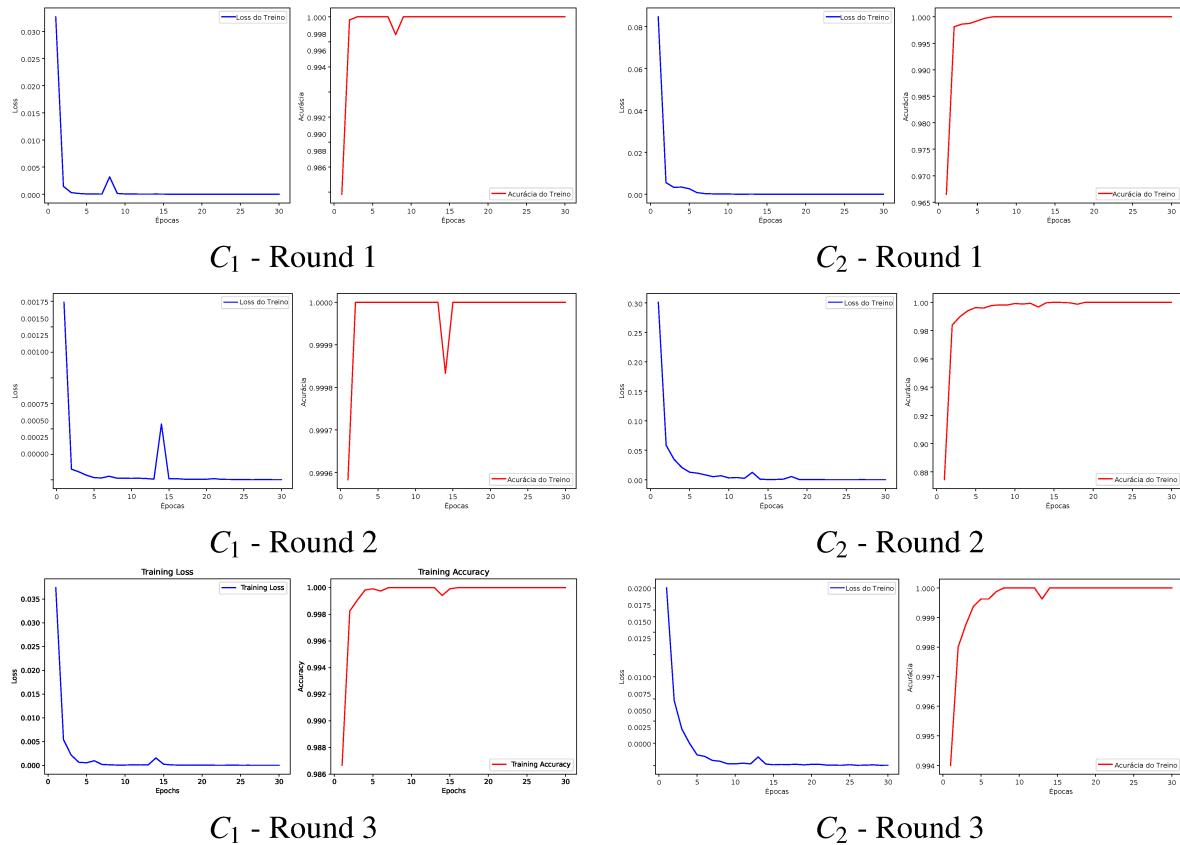


Figura 6 – Evolução dos valores de loss e acurácia ao longo dos rounds de treinamento de C_1 (imagens de pulmão – esquerda) e C_2 (imagens de cólon – direita).

A acurácia de treinamento atingiu valores próximos à unidade (100%) após poucas épocas em todas as rodadas, demonstrando a capacidade do modelo em adaptar-se rapidamente aos dados locais de cada cliente enquanto mantém desempenho consistente. A estabilização das curvas de perda e acurácia nas rodadas subsequentes (2 e 3) indica que, após uma rodada inicial de treinamento bem-sucedida, atualizações adicionais não produzem alterações significativas no desempenho do modelo, sugerindo que o modelo já atingiu uma configuração otimizada para os dados locais.

Foram considerados três cenários de classificação adicional: no primeiro, o servidor central possui acesso a imagens colorretais e pulmonares; no segundo, apenas imagens colorretais; e no terceiro, exclusivamente imagens pulmonares. Este último cenário apresentou os resultados mais modestos do estudo, indicando que o modelo não assimilou adequadamente as informações necessárias para generalizar entre as classes pulmonar e colorretal.

O primeiro cenário destacou-se como o mais desafiador e melhor desempenho, tendo sido treinado com dados distribuídos entre clientes diferentes e testado com amostras aleatórias de ambos os conjuntos. A abordagem superou as dificuldades inerentes aos dados *non-IID*, alcançando acurácia de 99,32% e recall de 99,31% para detecções positivas de câncer.

Na abordagem centralizada, observou-se que modelos treinados com um tipo específico de câncer (ex: colorretal) e testados com outro tipo (ex: pulmonar) apresentam desempenho

substancialmente reduzido, com métricas de acurácia e precisão significativamente menores, além de tempo médio de 14 minutos. Esta limitação decorre das diferenças histopatológicas marcantes entre os tipos cancerígenos, que impedem a transferência eficaz do conhecimento entre domínios morfológicos distintos.

Em contraste, o desempenho melhora consideravelmente quando o treinamento e teste ocorrem no mesmo tipo cancerígeno, particularmente no câncer pulmonar, onde se atingiu acurácia de 100%. Este resultado sugere que as imagens pulmonares do conjunto de dados exibem maior homogeneidade ou características visuais mais distintivas, facilitando o processo de classificação.

O experimento de treinar com imagens colorretais e testar com pulmonares representa um cenário relevante, pois investiga a capacidade do modelo em capturar características oncogênicas transversais a diferentes tipos cancerígenos. Contudo, os resultados obtidos (precisão próxima a 50%) confirmam que estas características gerais não são discriminativas para permitir generalização eficaz entre domínios morfológicos distintos.

No cenário federado, os testes com ambos os tipos de câncer (côlon e pulmão) resultaram em valores de precisão, acurácia, *recall* e F1-Score próximos a 99%. Este desempenho pode ser atribuído à combinação de dados que favorece a generalização para ambos os tipos cancerígenos no conjunto de teste. A capacidade do Aprendizado Federado de agregar conhecimento proveniente de diferentes clientes produz um modelo mais robusto quando aplicado a conjuntos de teste diversificados. Estes resultados evidenciam as vantagens da integração de dados de fontes diversas – neste caso, diferentes tipos de câncer – e da utilização do Aprendizado Federado para treinamento do modelo, possibilitando melhor generalização em comparação a ambientes centralizados.

O Aprendizado Federado mostrou vantagem em cenários com conjuntos de dados heterogêneos. Esta abordagem possibilita que o modelo global agregue informações de múltiplas fontes de dados, resultando em um modelo mais adaptável. Em contrapartida, o aprendizado centralizado, que treina o modelo em apenas um tipo de dado, não captura a diversidade inerente a conjuntos heterogêneos, limitando sua capacidade de generalização.

O aprendizado centralizado também apresenta desempenho reduzido quando testado em domínios diferentes dos utilizados no treinamento. Por exemplo, nesses experimentos, o modelo centralizado treinado com dados de câncer colorretal teve desempenho inferior quando testado com dados de câncer pulmonar. Em comparação, o Aprendizado Federado mostrou eficácia na generalização de dados diversos, atingindo valores elevados de precisão, *recall* e F1-Score, mesmo execuções de tempo maiores do que o centralizado (cerca de 10 horas). Além disso, o Aprendizado Federado oferece benefícios de privacidade, mantendo os dados nos dispositivos dos clientes e transmitindo apenas atualizações do modelo para o servidor. Esta característica impede o compartilhamento direto de dados brutos com o servidor, reforçando a segurança e proteção dos dados.

5.2 PSO vs FedAvg

Visto que a comparação anterior entre aprendizado centralizado e federado validou o uso do paradigma federado para cenários heterogêneos, esta seção avança para a otimização do processo através da seleção inteligente de clientes. O propósito dessa abordagem foi avaliar a seleção dos melhores clientes num cenário desafiador de dados *non-IID*.

Nesta configuração, o *baseline* de desempenho foi desenvolvido com uma seleção aleatória de clientes no aprendizado federado. O algoritmo FedAvg foi utilizado na estratégia de agregação da atualização de modelos dos clientes selecionados. Além disso, na seleção aleatória, um número fixo e aleatório de clientes foi escolhido a cada rodada sem considerar o desempenho e a qualidade dos dados, e com nenhuma estratégia de otimização.

Os conjuntos de dados foram combinados de forma global em um único conjunto por meio do aprendizado federado. Os dados foram distribuídos de forma *non-IID*, ou seja, não há distinção das contribuições individuais dos conjuntos de dados, tanto no treinamento quanto na avaliação.

A Tabela 3 compara as configurações de melhor desempenho obtidas com *PSO* contra a seleção aleatória padrão. Os resultados mostram que a estratégia *PSO* supera de forma consistente a abordagem aleatória em todas as configurações testadas, com diferenças mais significativas nos cenários de 50 a 100 clientes, onde se observa uma vantagem de 2,7% a 2,8% no F1-Score. A análise da Figura 7 revela que o desempenho do modelo tende a se estabilizar após aproximadamente 30 rodadas de comunicação, com a abordagem *PSO* mantendo uma vantagem estável desde as rodadas iniciais. Essa diferença é notável nas primeiras 10 a 20 rodadas e varia de acordo com a escala do modelo, sendo mais notável em configurações com 50 a 100 clientes, onde a seleção adaptativa mostra seu maior impacto.

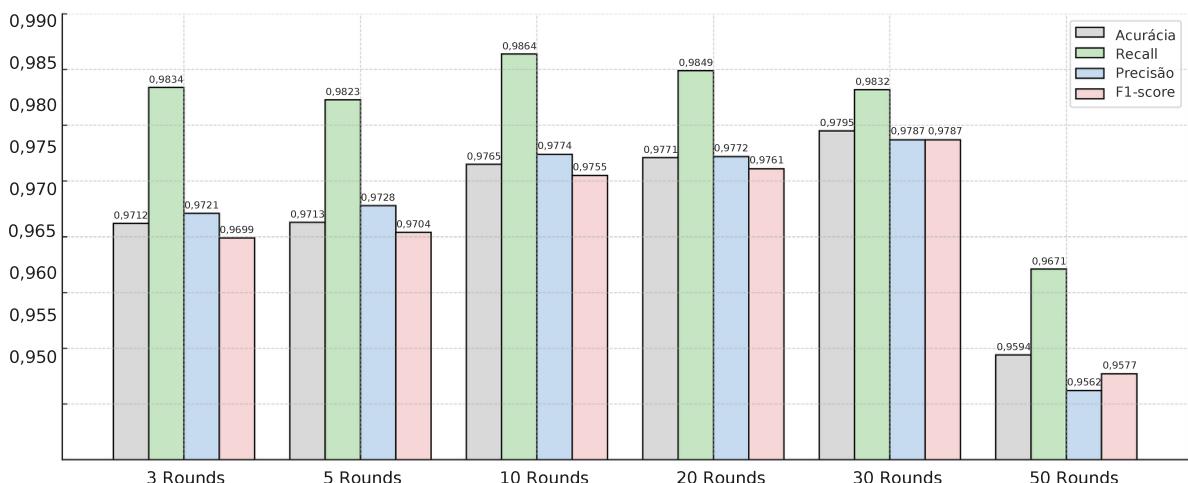


Figura 7 – Comparação das abordagens de acordo com o número de rounds.

Tabela 3 – Comparação entre as configurações de melhor desempenho usando *PSO* e FedAvg.

Abordagem	Clientes	Selecionados	Rodadas	Acurácia (%)	Recall (%)	Precisão (%)	F1-Score (%)
<i>PSO</i>	10	2	3	99,00	99,00	99,00	99,00
FedAvg	10	2	3	98,01	98,00	97,85	97,92
<i>PSO</i>	30	2	10	98,57	99,84	98,79	98,51
FedAvg	30	2	10	97,97	97,88	97,89	97,89
<i>PSO</i>	50	5	10	98,50	99,71	98,69	98,43
FedAvg	50	5	10	95,84	95,35	96,25	95,72
<i>PSO</i>	100	10	30	98,24	98,63	98,19	98,17
FedAvg	100	10	30	96,00	96,00	95,00	96,00
<i>PSO</i>	500	30	50	97,09	97,49	96,05	96,97
FedAvg	500	30	50	96,70	96,53	96,60	96,57

A Tabela 3 apresenta os resultados dos experimentos realizados. Conforme ilustrado na Figura 8, o método *PSO* demonstra convergência mais eficiente que o FedAvg, com incrementos progressivos no F1-Score a cada round adicional de comunicação, particularmente em ambientes com grande número de clientes. Esse comportamento indica menor sensibilidade à heterogeneidade dos dados e atualizações mais eficazes do modelo global quando comparado à seleção aleatória tradicional.

Observa-se que o desempenho do aprendizado federado segue uma relação não-linear com a quantidade de clientes e rounds. Configurações com poucos clientes atingem bons resultados com número reduzido de rounds, enquanto cenários mais complexos demandam maior quantidade de clientes para compensar os efeitos da heterogeneidade.

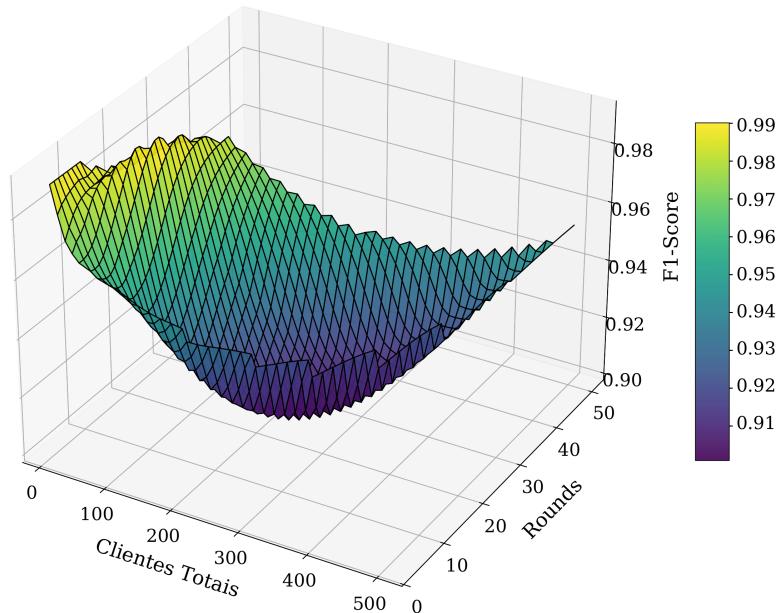


Figura 8 – Visualização 3D do F1-Score em função do número de clientes e rounds de comunicação.

A Figura 9 detalha o processo de seleção nos experimentos de melhor desempenho, pontos azuis, representando clientes disponíveis; cruzes vermelhas, melhores seleções do *PSO*.

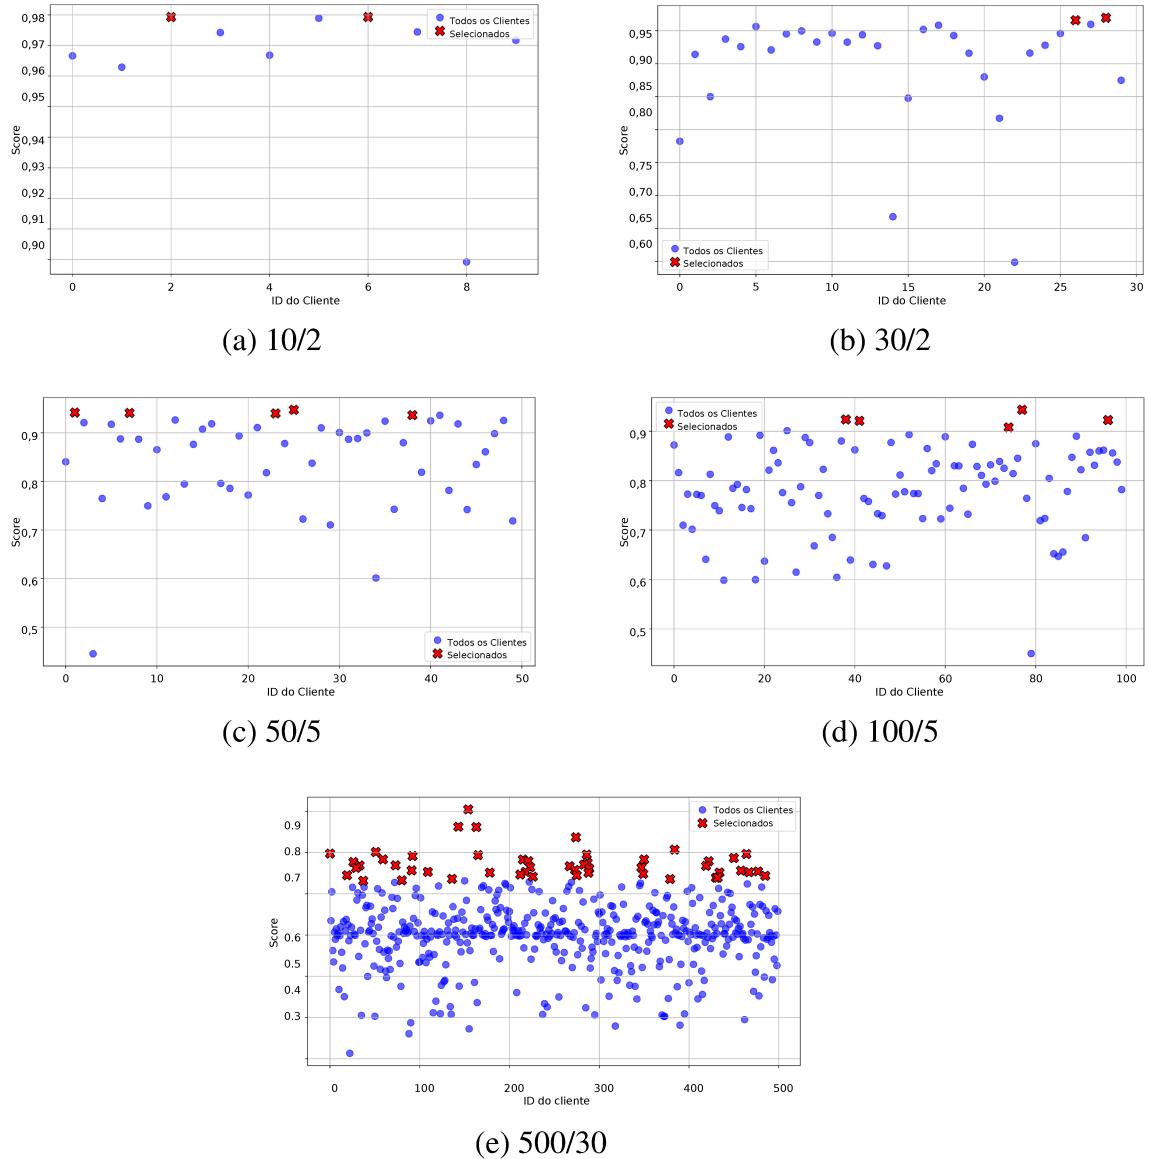


Figura 9 – Processo de seleção de clientes nos experimentos com *PSO* (Clientes Totais/Selecionados).

A arquitetura SqueezeNet mostrou-se particularmente eficaz, alcançando convergência estável mesmo com apenas 10 clientes e poucos *rounds*. Essa característica revela baixa dependência de ajustes de hiperparâmetros em cenários homogêneos. Contudo, conforme aumenta o número de clientes (30, 50, 100), observa-se maior variabilidade nos resultados iniciais, principalmente quando poucos clientes são selecionados, evidenciando os desafios impostos pela heterogeneidade crescente.

O *PSO* supera a abordagem aleatória ao identificar sistematicamente os clientes cujos gradientes contribuem mais significativamente para o modelo global. Como demonstrado na Figura 10, essa estratégia proporciona melhor exploração do espaço de soluções e redução da variabilidade entre clientes, com base no F1-Score obtido para diferentes combinações de: total de clientes, clientes selecionados e quantidade de rounds.

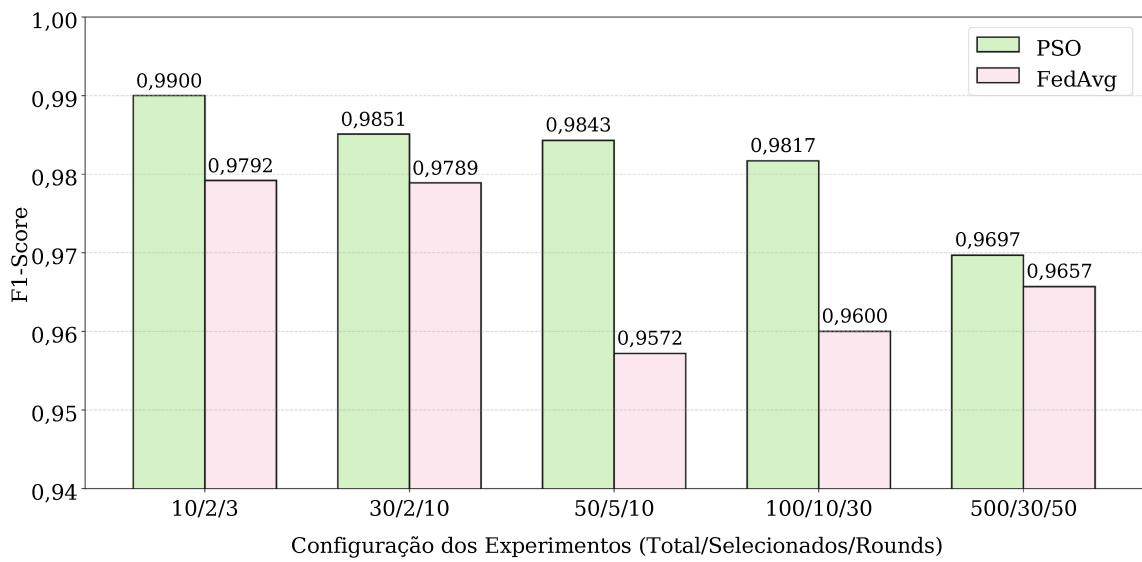


Figura 10 – Comparação das abordagens avaliadas.

5.3 PSO dinâmico vs FedAvg

Para elevar o nível dos experimentos e torná-los ainda mais desafiadores e próximos de cenários reais, optou-se por uma abordagem de seleção dinâmica de clientes utilizando *PSO*, comparando seu desempenho com o *FedAvg* como linha de base. Diferentemente do *PSO* convencional, que opera com parâmetros estáticos, a versão dinâmica proposta adapta-se continuamente às condições do ambiente federado e heterogêneo, ajustando automaticamente a seleção de clientes com base em seu desempenho histórico e contribuição para o modelo global.

Esta comparação direta com o *FedAvg* justifica-se pela necessidade de avaliar não apenas a eficácia da seleção inteligente frente à aleatoriedade, mas também a capacidade de adaptação em ambientes heterogêneos em constante mudança. Enquanto o *FedAvg* mantém uma seleção aleatória fixa, o *PSO* dinâmico redefine estrategicamente o subconjunto de clientes a cada rodada, priorizando aqueles com maior potencial de contribuição para a convergência do modelo. A Tabela 4 mostra que tanto o número total de clientes quanto a forma como são selecionados impactam diretamente o desempenho do modelo.

A relação entre o número de clientes e a quantidade de *rounds* foi escolhida com base em parâmetros consolidados na literatura para balancear custo computacional e eficácia [McMahan et al. 2017]. No presente trabalho, notou-se que em alguns casos uma quantidade baixa de rounds em função de muitos clientes resultava em baixa convergência. Assim, em casos como: 100 clientes totais, 5 selecionados e 3 rounds, foram realizados outros experimentos com quantidades maiores de rounds na busca de melhores convergências.

Com o uso da SqueezeNet, observa-se que o *PSO* obtém melhores resultados em cenários com menor número de clientes selecionados e maior espaço de busca, já que a estratégia de otimização permite priorizar os clientes mais relevantes. Por outro lado, o *FedAvg* tende a alcançar melhores acurárias quando mais clientes são selecionados por rodada, pois isso aumenta

a chance de agregar contribuições estatisticamente significativas, o que está de acordo com sua abordagem de agregação.

Tabela 4 – Resultado comparativo das acurácia do *PSO* e *FedAvg (Baseline)* com a SqueezeNet.

Total de Clientes	Clientes Selecionados	Rounds	PSO (%)	Baseline (%)	Diferença (%)
20	5	3	97,36	98,09	-0,73
30	3	5	97,77	98,03	-0,26
30	5	10	98,20	98,32	-0,12
50	5	3	96,70	94,79	+1,91
50	10	5	96,04	97,38	-1,34
100	5	3	92,36	92,23	+0,13
100	5	10	96,35	94,88	+1,47

De acordo com os dados da Tabela 5, o *PSO* demonstrou desempenho superior ao *FedAvg* na maioria dos cenários analisados. A MobileNet, por ter uma arquitetura mais leve e com menos parâmetros, mostra-se mais sensível à seleção dos dados, o que favorece a abordagem do *PSO* ao priorizar clientes com informações mais relevantes. Nos poucos casos em que o *FedAvg* teve desempenho melhor, é possível que a escolha aleatória de clientes tenha incluído, por acaso, dados com alto valor informativo, o que pode ser explicado pela variabilidade elevada entre os conjuntos locais.

Tabela 5 – Resultado comparativo das acurácia do *PSO* e *FedAvg (Baseline)* com a MobileNet.

Total de Clientes	Clientes Selecionados	Rounds	PSO (%)	Baseline (%)	Diferença (%)
20	5	3	96,46	96,41	+0,05
30	3	5	96,54	96,15	+0,39
30	5	10	97,38	88,71	+8,67
50	5	3	91,54	96,97	-5,43
50	10	5	94,57	94,12	+0,45
100	5	3	75,14	71,86	+3,28
100	5	10	92,99	94,51	-1,52

Entre as redes avaliadas, a ResNet destacou-se pela estabilidade e desempenho consistente, como visto na Tabela 6. Sua profundidade e capacidade de extração de características conferem maior robustez frente à variabilidade dos dados entre os clientes. Por conta disso, as diferenças entre o desempenho do *PSO* e do *FedAvg* se tornam menos evidentes, com ambos os métodos apresentando resultados similares em grande parte dos experimentos.

No caso da EfficientNet, a abordagem tradicional com *FedAvg* obteve melhores resultados em diversos cenários (ver Tabela 7). Isso pode ser atribuído à alta capacidade de generalização da *CNN*, que se beneficia da diversidade de dados promovida pela seleção aleatória de clientes. Em contraste, o *PSO* tende a selecionar repetidamente os mesmos clientes com desempenho elevado, o que pode reduzir a variedade de padrões apresentados ao modelo — especialmente

Tabela 6 – Resultado comparativo das acurárias do *PSO* e *FedAvg (Baseline)* com a ResNet.

Total de Clientes	Clientes Selecionados	Rounds	PSO (%)	Baseline (%)	Diferença (%)
20	5	3	97,93	97,85	+0,08
30	3	5	98,20	97,68	+0,52
30	5	10	98,48	98,52	-0,04
50	5	3	96,39	96,74	-0,35
50	10	5	96,99	97,21	-0,22
100	5	3	93,65	91,68	+1,97
100	5	10	97,44	96,76	+0,68

aqueles menos frequentes, mas relevantes. Assim, para arquiteturas como o EfficientNet, manter uma rotação diversificada de clientes parece ser mais vantajoso.

Tabela 7 – Resultado comparativo das acurárias do *PSO* e *FedAvg (Baseline)* com a EfficientNet.

Total de Clientes	Clientes Selecionados	Rounds	PSO (%)	Baseline (%)	Diferença (%)
20	5	3	97,01	96,60	+0,41
30	3	5	96,97	96,80	+0,17
30	5	10	97,42	97,62	-0,20
50	5	3	94,59	93,34	+1,25
50	10	5	93,93	95,96	-2,03
100	5	3	77,17	79,37	-2,20
100	5	10	93,07	94,75	-1,68

A Figura 11 mostra que a SqueezeNet tem resultados melhores com o *PSO* dinâmico, principalmente em cenários com seleção limitada de clientes. A ResNet apresenta desempenho estável em ambas as abordagens, sugerindo baixa sensibilidade ao método de seleção. Por outro lado, a EfficientNet apresenta melhor desempenho com o FedAvg, devido à sua forte generalização com diferentes dados de treinamento.

A Figura 12 apresenta os clientes selecionados pelo *PSO* na rodada 10, avaliados mediante as métricas de acurácia e F1-Score em diferentes arquiteturas *CNNs*. A SqueezeNet destacou-se pela seleção criteriosa de clientes com elevado desempenho local, maximizando sua contribuição para o modelo global em ambientes heterogêneos. Embora a MobileNet também tenha se beneficiado da seleção direcionada, a menor variação observada em suas pontuações sugere certa limitação na diversidade de contribuições. A ResNet apresentou comportamento homogêneo, com clientes selecionados e não selecionados obtendo desempenhos comparáveis. Já na EfficientNet, o *PSO* priorizou clientes de desempenho relativamente inferior em detrimento de opções mais qualificadas disponíveis, o que pode impactar na variedade de padrões incorporados ao modelo global.

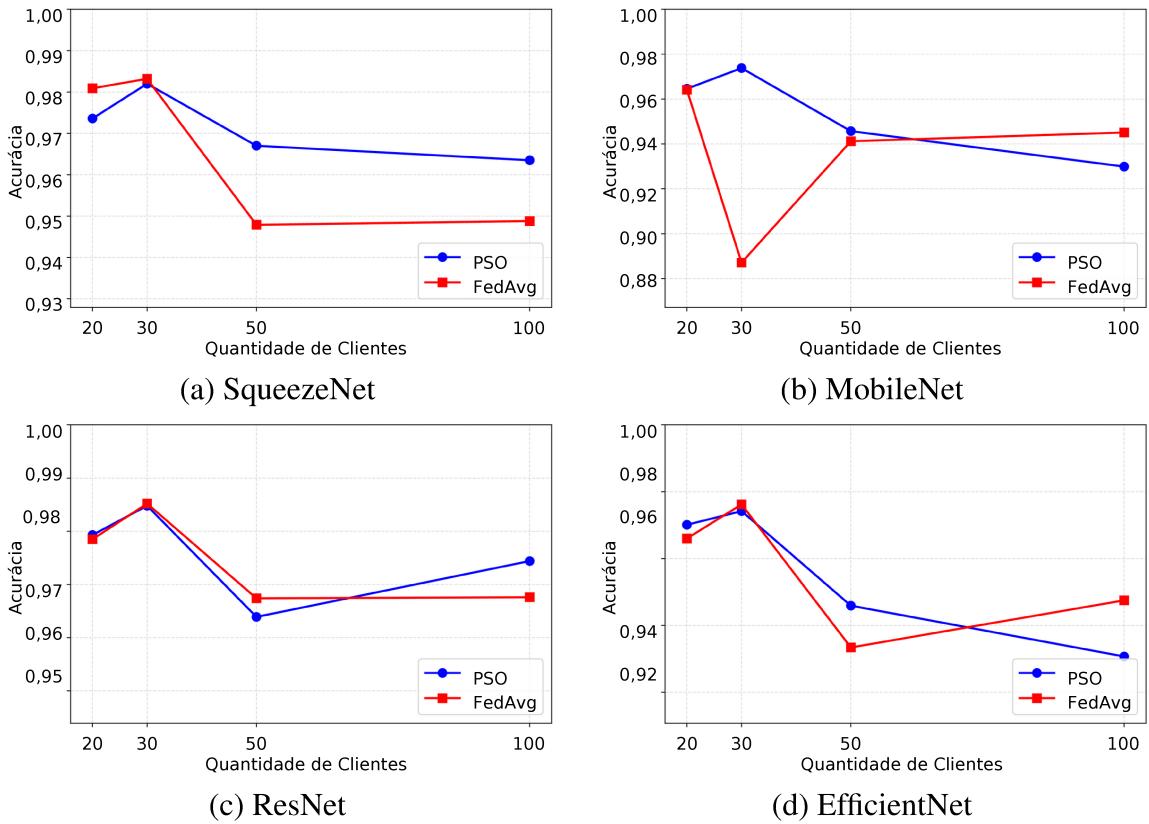


Figura 11 – Comparação das abordagens *PSO* e *Baseline* quanto ao desempenho das *CNNs* avaliadas

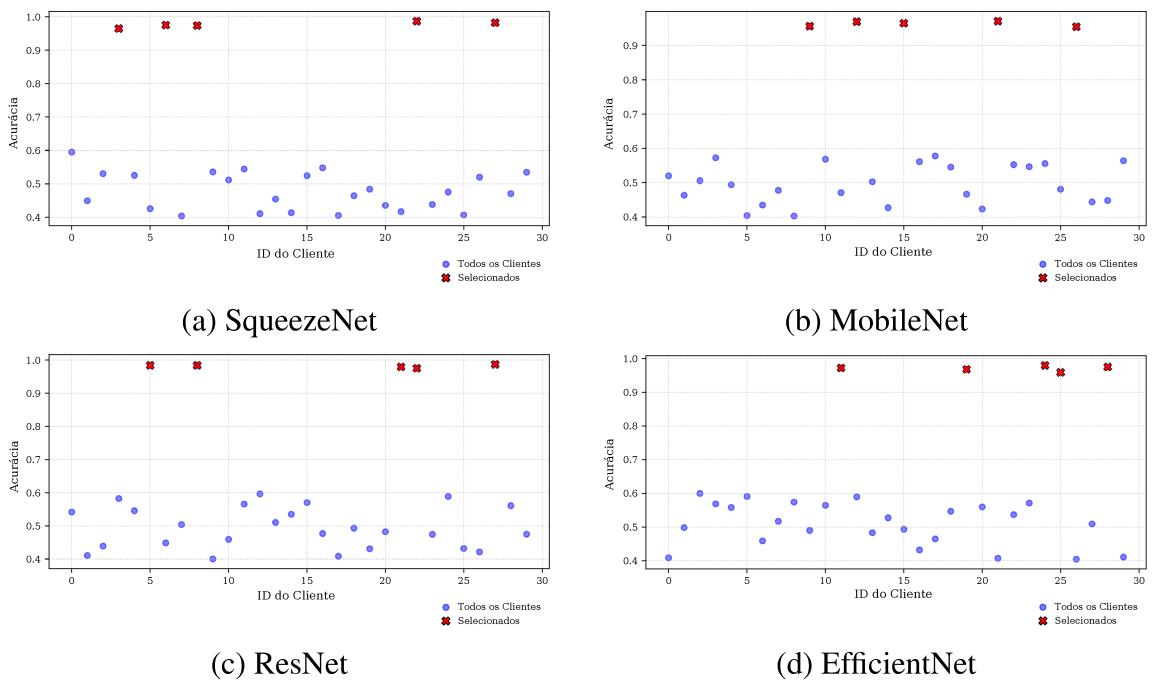


Figura 12 – Seleção de Clientes de acordo com cada *CNN*.

Para avaliar a eficiência do método *PSO* na seleção de clientes, comparamos seus resultados com a abordagem tradicional *FedAvg* através da diferença percentual de acurácia. Esta métrica

calcula, para cada cenário testado, o quanto o *PSO* superou ou ficou abaixo do *FedAvg* em termos de acurácia. Valores positivos mostram superioridade do *PSO*, enquanto negativos indicam melhor desempenho do *FedAvg*. Na Figura 13, visualizamos essas comparações para todas as *CNNs* analisadas, onde cada marca representa o desempenho relativo considerando diferentes combinações de clientes totais, clientes selecionados e rounds de treinamento.

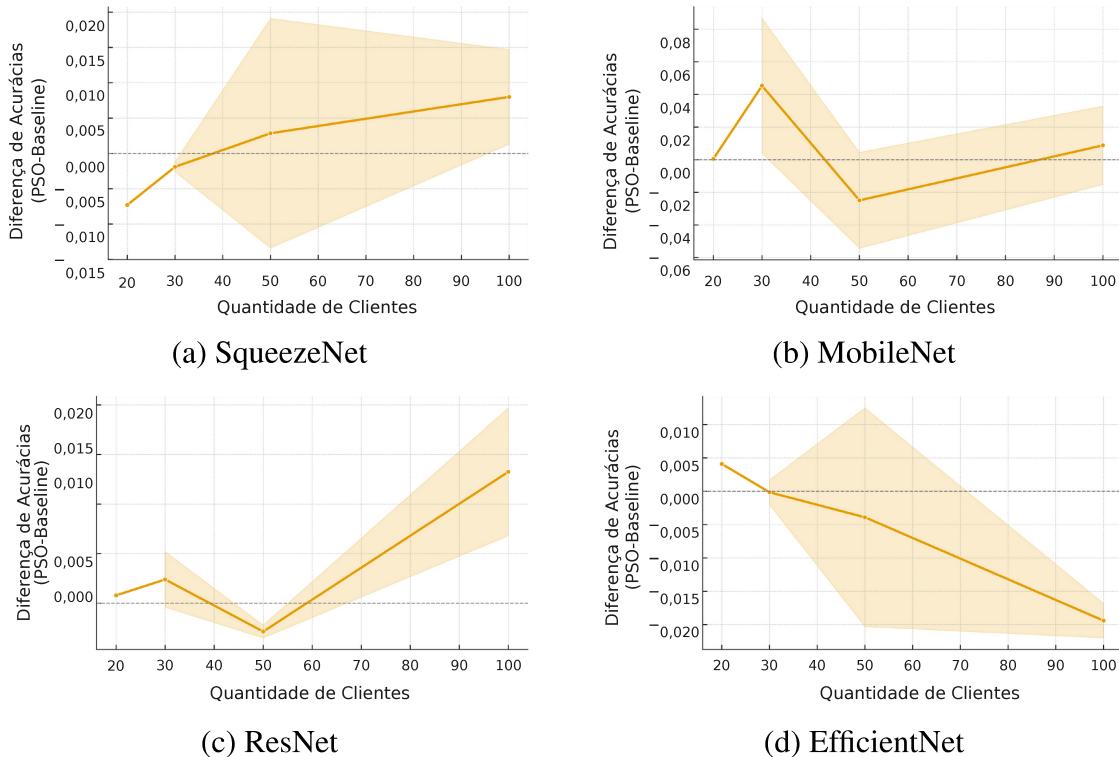


Figura 13 – Acuácia Delta de acordo com a *CNN*.

Os experimentos demonstram que a MobileNet foi a arquitetura que mais se beneficiou da seleção por *PSO* dinâmico, alcançando melhorias superiores a 8% em cenários intermediários. Contrastando estes resultados, a ResNet manteve estabilidade nas comparações, com ligeira preferência pelo *PSO* em configurações mais complexas. A EfficientNet exibiu variações notáveis, com desempenho inferior do *PSO* em ambientes com elevado número de clientes. Quanto à SqueezeNet, os resultados foram heterogêneos, o *PSO* mostrou-se mais eficaz em configurações expandidas, enquanto o *FedAvg* obteve melhor desempenho em cenários reduzidos. Estas observações sugerem que a seleção dinâmica de clientes atinge seu potencial máximo em modelos compactos operando em ambientes com heterogeneidade controlada e número moderado de rodadas de atualização.

A Figura 14 apresenta uma análise comparativa do desempenho das estratégias em diferentes cenários operacionais. O gráfico demonstra a relação entre três parâmetros fundamentais: tempo de processamento (eixo X), escala de participação dos clientes (eixo Y) e desempenho obtido (eixo Z), onde cada marcador corresponde a uma configuração específica de treinamento. Os resultados do *PSO* (representados por marcadores circulares vermelhos) revelam superioridade em cenários com recursos limitados, enquanto a abordagem *Baseline* (indicada

por triângulos azuis) mantém padrões de comportamento previsíveis que se fortalecem proporcionalmente ao aumento da base de clientes participantes.

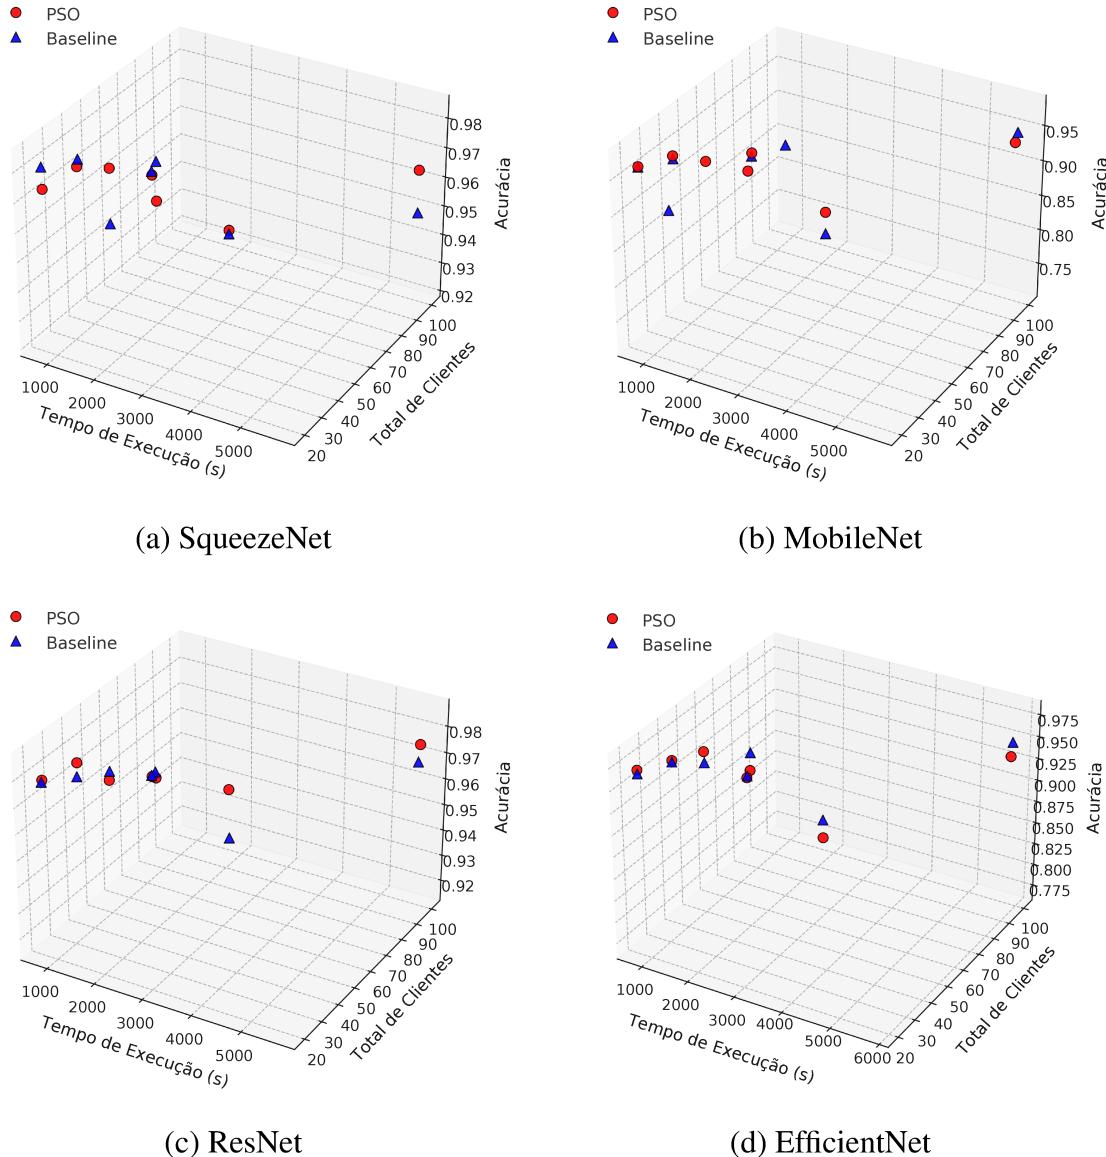


Figura 14 – Relação entre a Acurácia, Tempo de Execução e Total de Clientes.

Os experimentos realizados demonstram que a estratégia de seleção dinâmica baseada em *PSO* influencia positivamente no desempenho dos modelos, com ganhos mais expressivos em arquiteturas compactas e em cenários de participação restrita. Além disso, os tempos de execução do *PSO* e do *FedAvg*, que foram de aproximadamente 36 minutos, são muito próximos para configurações equivalentes. Isso indica que o *PSO* praticamente não adiciona custo computacional significativo em relação ao treinamento federado em si.

A metodologia propicia ganhos de acurácia em ambientes *non-IID* ao direcionar a seleção para os clientes mais relevantes, preservando o mecanismo de agregação. Entretanto, esse benefício é diretamente influenciado pela arquitetura *CNN* empregada, em virtude de retornos decrescentes em modelos generalistas submetidos a seleções aleatórias. Essas evidências re-

forçam a necessidade de adequar as estratégias de seleção de clientes às particularidades do modelo e às condições operacionais do sistema.

CAPÍTULO 6

Conclusão

O presente trabalho atingiu seus objetivos ao propor e validar um método de Aprendizado Federado para classificação de diferentes tipos de câncer, integrando técnicas de otimização por enxame de partículas (*PSO*) para seleção inteligente de clientes. A pesquisa demonstrou concretamente como cada objetivo específico foi alcançado.

Inicialmente, a comparação sistemática entre paradigmas de aprendizado centralizado e federado permitiu quantificar as vantagens e limitações de cada abordagem em cenários médicos realistas. Posteriormente, a implementação do mecanismo de seleção dinâmica com *PSO* evidenciou ganhos significativos de eficiência e desempenho em relação às estratégias tradicionais de seleção aleatória. Por fim, a validação em ambientes intencionalmente heterogêneos (*non-IID*) confirmou a robustez da abordagem proposta sob condições adversas, aproximando-a de aplicações clínicas reais.

Diante dos resultados apresentados, o trabalho demonstra a viabilidade da aplicação de Aprendizado Federado combinado com *PSO* para classificação de imagens médicas em cenários realistas. Os experimentos realizados avaliaram de forma comparativa as abordagens *FedAvg*, *PSO* estático e *PSO* dinâmico na classificação de diferentes tipos de câncer, mantendo o foco na preservação da privacidade dos dados sensíveis. A utilização intencional de distribuições *non-IID* nos conjuntos de imagens aproximou o estudo a cenários reais de aplicação clínica, onde a heterogeneidade de dados é notória, validando a robustez do método proposto em condições adversas.

6.1 Principais Contribuições

As principais contribuições deste trabalho podem ser resumidas em três aspectos fundamentais:

1. **Método de Seleção Dinâmica:** adoção de um mecanismo adaptativo baseado em *PSO* para seleção inteligente de clientes em ambientes federados, capaz de identificar e priori-

zar automaticamente os participantes com maior potencial de contribuição para o modelo global;

2. **Validação em Cenários Realistas:** demonstração da eficácia do método em condições de heterogeneidade extrema (*non-IID*), com dados distribuídos de forma não balanceada entre clientes, simulando desafios reais de aplicações médicas distribuídas;
3. **Preservação de Privacidade com Eficiência:** combinação bem-sucedida dos benefícios de privacidade do Aprendizado Federado com a eficiência computacional do *PSO*, reduzindo o custo de comunicação enquanto mantém ou melhora o desempenho do modelo.

Os resultados obtidos mostram que a abordagem proposta em muitos casos supera o desempenho de métodos tradicionais como *FedAvg*, principalmente em cenários complexos com alta variabilidade de dados. A capacidade do método de generalizar para diferentes tipos de câncer sugere seu potencial como ferramenta de apoio aos especialistas médicos na detecção precoce e classificação de câncer.

6.2 Trabalhos Futuros

Com base nas limitações identificadas e nos resultados promissores obtidos, sugere-se as seguintes direções para trabalhos futuros:

- **Extensão para Arquiteturas Complexas:** investigação do método proposto em conjunto com arquiteturas mais complexas como EfficientNet e Vision Transformers, e comparando o *PSO* com algoritmos bioinspirados avaliando sua capacidade de generalização em cenários de ainda maior heterogeneidade;
- **Otimização de Hiperparâmetros:** desenvolvimento de estratégias adaptativas para ajuste automático dos parâmetros do *PSO* durante o processo de treinamento, melhorando ainda mais a eficiência da seleção de clientes;
- **Expansão de Domínios Médicos:** aplicação da metodologia a outros domínios médicos além da oncologia, como cardiologia, neurologia e radiologia, validando sua utilidade em diferentes contextos de diagnóstico por imagem;
- **Validação Clínica Real:** testes em ambientes clínicos reais com fluxos de trabalho operacionais, avaliando não apenas a acurácia técnica mas também a usabilidade e integrabilidade com sistemas existentes.

Estas direções de pesquisa têm o potencial de expandir significativamente o impacto do presente trabalho, contribuindo para o avanço tanto da área de Aprendizado Federado quanto para a melhoria de ferramentas de apoio ao diagnóstico médico baseado em imagem.

6.3 Contribuições em Produção Bibliográfica

- **Rodrigues et al. 2025:** “*Medical Image Classification with Privacy: Centralized and Federated Learning Comparison.*” *Revista de Informática Teórica e Aplicada* 32.1 (2025): 180-187.

Neste artigo, são apresentados os resultados da comparação entre o Aprendizado Federado e o Aprendizado Centralizado na classificação de câncer utilizando o conjunto de dados *LC25000* tendo a SqueezeNet como *CNN* avaliada.

- **Rodrigues et al. 2025** “*PSO-based Client Selection to Improve Medical Image Classification in Federated Learning.*” *Revista de Informática Teórica e Aplicada* (aceito).

Neste trabalho são mostrados os resultados da comparação entre a seleção de clientes usando *PSO* e o algoritmo *FedAvg* avaliando dois conjuntos de dados *LC25000* e *ALL-IDB*. Nesta configuração, foi utilizada a SqueezeNet.

- **Rodrigues et al. 2025** “*Dynamic Client Selection in Federated Learning using Particle Swarm Optimization for Medical Image Classification.*” *Cluster Computing* (em revisão).

Por fim, este trabalho utilizou três conjuntos de dados: *LC25000*, *ALL-IDB* e *Biglycan* comparando a seleção dinâmica de clientes com *PSO* com o *FedAvg*. Foram utilizadas as seguintes *CNNs*: ResNet, MobileNet, SqueezeNet e EfficientNet.

Referências

- AGBLEY, B. L. Y.; LI, J. P.; HAQ, A. U.; BANKAS, E. K.; MAWULI, C. B.; AHMAD, S.; KHAN, S.; KHAN, A. R. Federated fusion of magnified histopathological images for breast tumor classification in the internet of medical things. **IEEE Journal of Biomedical and Health Informatics**, v. 28, n. 6, p. 3389–3400, 2024. Disponível em: <<https://doi.org/10.1109/JBHI.2023.3256974>>.
- BALDIN, I.; NIKOLICH, A.; GRIFFIOEN, J.; MONGA, I. I. S.; WANG, K.-C.; LEHMAN, T.; RUTH, P. FABRIC: A national-scale programmable experimental network infrastructure. **IEEE Internet Computing**, IEEE, v. 23, n. 6, p. 38–47, 2019. Disponível em: <<https://doi.org/10.1109/MIC.2019.2958545>>.
- BEUTEL, D. J.; TOPAL, T.; MATHUR, A.; QIU, X.; FERNANDEZ-MARQUES, J.; GAO, Y.; SANI, L.; LI, K. H.; PARCOLLET, T.; GUSMÃO, P. P. B. de et al. Flower: A friendly federated learning research framework. **arXiv preprint arXiv:2007.14390**, 2020. Disponível em: <<https://doi.org/10.48550/arXiv.2007.14390>>.
- BORKOWSKI, A. A.; BUI, M. M.; THOMAS, L. B.; WILSON, C. P.; DELAND, L. A.; MASTORIDES, S. M. **Lung and Colon Cancer Histopathological Image Dataset (LC25000)**. 2019. Disponível em: <<https://doi.org/10.48550/arXiv.1912.12142>>.
- BUDOVEC, J. J.; LAM, C. A.; KAHN, C. E. Informatics in radiology: Radiology gamuts ontology: Differential diagnosis for the semantic web. **RadioGraphics**, v. 34, n. 1, p. 254–264, 2014. PMID: 24428295. Disponível em: <<https://doi.org/10.1148/rg.341135036>>.
- BYSANI, H.; GARG, S.; DANDA, A.; SINGH, T.; C, J.; DURAISAMY, P. Detection of pneumonia in chest x-ray using ensemble learners and transfer learning with deep learning models. In: **2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT)**. [s.n.], 2023. p. 1–8. Disponível em: <<https://doi.org/10.1109/ICCCNT56998.2023.10307035>>.
- CHEN, C.; Mat Isa, N. A.; LIU, X. A review of convolutional neural network based methods for medical image classification. **Computers in Biology and Medicine**, v. 185, p. 109507, 2025. ISSN 0010-4825. Disponível em: <<https://doi.org/10.1016/j.combiomed.2024.109507>>.
- COSTA, C. L.; LIMA, D. A.; BARCELOS, C. A. Z.; TRAVENÇOLO, B. A. N. Ensemble architectures and efficient fusion techniques for convolutional neural networks: An analysis on resource optimization strategies. In: NALDI, M. C.; BIANCHI, R. A. C. (Ed.).

- Intelligent Systems.** Cham: Springer Nature Switzerland, 2023. p. 107–121. Disponível em: <https://doi.org/10.1007/978-3-031-45389-2_8>.
- ESTEVA, A.; ROBICQUET, A.; RAMSUNDAR, B.; KULESHOV, V.; DEPRISTO, M.; CHOU, K.; CUI, C.; CORRADO, G.; THRUN, S.; DEAN, J. A guide to deep learning in healthcare. **Nature medicine**, Nature Publishing Group US New York, v. 25, n. 1, p. 24–29, 2019. Disponível em: <<https://doi.org/10.1038/s41591-018-0316-z>>.
- FUKUSHIMA, K. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. **Biological Cybernetics**, v. 36, n. 4, p. 193–202, Apr 1980. ISSN 1432-0770. Disponível em: <<https://doi.org/10.1007/BF00344251>>.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. Deep learning. Book in preparation for MIT Press. 2016. Disponível em: <<http://www.deeplearningbook.org>>.
- GUAN, H.; YAP, P.-T.; BOZOKI, A.; LIU, M. Federated learning for medical image analysis: A survey. **Pattern Recognition**, v. 151, p. 110424, 2024. ISSN 0031-3203. Disponível em: <<https://doi.org/10.1016/j.patcog.2024.110424>>.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: **2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Las Vegas, NV, USA: IEEE, 2016. p. 770–778. Disponível em: <<https://doi.org/10.1109/CVPR.2016.90>>.
- HOSSAIN, M. M.; ISLAM, M. R.; AHAMED, M. F.; AHSAN, M.; HAIDER, J. A Collaborative Federated Learning Framework for Lung and Colon Cancer Classifications. **Technologies**, v. 12, n. 9, 2024. ISSN 2227-7080. Disponível em: <<https://doi.org/10.3390/technologies12090151>>.
- HOWARD, A.; SANDLER, M.; CHU, G.; CHEN, L.-C.; CHEN, B.; TAN, M.; WANG, W.; ZHU, Y.; PANG, R.; VASUDEVAN, V.; LE, Q. V.; ADAM, H. **Searching for MobileNetV3**. 2019. Disponível em: <<https://doi.org/10.48550/arXiv.1905.02244>>.
- IANDOLA, F. N.; HAN, S.; MOSKEWICZ, M. W.; ASHRAF, K.; DALLY, W. J.; KEUTZER, K. **SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size**. 2016. Disponível em: <<https://doi.org/10.48550/arXiv.1602.07360>>.
- JIANG, L.; ZHAI, X. B.; ZHU, J.; LI, J. Resource-constrained client selection via cluster-driven federated learning for internet of things. In: **2024 IEEE Wireless Communications and Networking Conference (WCNC)**. Dubai, United Arab Emirates: IEEE, 2024. p. 1–6. Disponível em: <<https://doi.org/10.1109/WCNC57260.2024.10570641>>.
- JIANG, Z.; XU, Y.; XU, H.; WANG, Z.; QIAN, C. Heterogeneity-aware federated learning with adaptive client selection and gradient compression. In: **IEEE INFOCOM 2023 - IEEE Conference on Computer Communications**. [s.n.], 2023. p. 1–10. Disponível em: <<https://doi.org/10.1109/INFOCOM53939.2023.10229029>>.
- KENNEDY, J.; EBERHART, R. Particle swarm optimization. In: **Proceedings of ICNN'95 - International Conference on Neural Networks**. Perth, WA, Australia: IEEE, 1995. v. 4, p. 1942–1948 vol.4. Disponível em: <<https://doi.org/10.1109/ICNN.1995.488968>>.
- KONEČNÝ, J.; MCMAHAN, H. B.; RAMAGE, D.; RICHTÁRIK, P. Federated Optimization: Distributed Machine Learning for On-Device Intelligence. **CoRR**, abs/1610.02527, 2016. Disponível em: <<http://arxiv.org/abs/1610.02527>>.

- KOONCE, B. SqueezeNet. In: _____. **Convolutional Neural Networks with Swift for Tensorflow: Image Recognition and Dataset Categorization**. Berkeley, CA: Apress, 2021. p. 73–85. ISBN 978-1-4842-6168-2. Disponível em: <https://doi.org/10.1007/978-1-4842-6168-2_7>.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. **Commun. ACM**, Association for Computing Machinery, New York, NY, USA, v. 60, n. 6, p. 84–90, maio 2017. ISSN 0001-0782. Disponível em: <<https://doi.org/10.1145/3065386>>.
- Labati, R. D.; Piuri, V.; Scotti, F. All-idb: The acute lymphoblastic leukemia image database for image processing. In: **2011 18th IEEE International Conference on Image Processing**. Brussels, Belgium: IEEE, 2011. p. 2045–2048. Disponível em: <<https://doi.org/10.1109/ICIP.2011.6115881>>.
- LECUN, Y.; BOTTOU, L.; BENGIO, Y.; HAFFNER, P. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998. Disponível em: <<https://doi.org/10.1109/5.726791>>.
- LI, Z.; LIU, F.; YANG, W.; PENG, S.; ZHOU, J. A survey of convolutional neural networks: Analysis, applications, and prospects. **IEEE Transactions on Neural Networks and Learning Systems**, v. 33, n. 12, p. 6999–7019, 2022. Disponível em: <<https://doi.org/10.1109/TNNLS.2021.3084827>>.
- LO, S.-C.; LOU, S.-L.; LIN, J.-S.; FREEDMAN, M.; CHIEN, M.; MUN, S. Artificial convolution neural network techniques and applications for lung nodule detection. **IEEE Transactions on Medical Imaging**, v. 14, n. 4, p. 711–718, 1995. Disponível em: <<https://doi.org/10.1109/42.476112>>.
- MAHMOOD, T.; REHMAN, A.; SABA, T.; NADEEM, L.; BAHAJ, S. A. O. Recent advancements and future prospects in active deep learning for medical image segmentation and classification. **IEEE Access**, v. 11, p. 113623–113652, 2023. Disponível em: <<https://doi.org/10.1109/ACCESS.2023.3313977>>.
- MCMahan, B.; Moore, E.; Ramage, D.; Hampson, S.; Arcas, B. A. y. Communication-Efficient Learning of Deep Networks from Decentralized Data. In: SINGH, A.; ZHU, J. (Ed.). **Proceedings of the 20th International Conference on Artificial Intelligence and Statistics**. PMLR, 2017. (Proceedings of Machine Learning Research, v. 54), p. 1273–1282. Disponível em: <<https://proceedings.mlr.press/v54/mcmahan17a.html>>.
- MIAO, Y.; YANG, X.; FAN, H.; LI, Y.; HONG, Y.; GUO, X.; BRAYTEE, A.; HUANG, W.; ANAISSI, A. FedSaf: A federated learning framework for enhanced gastric cancer detection and privacy preservation. **arXiv preprint arXiv:2503.15870**, 2025. Disponível em: <<https://doi.org/10.48550/arXiv.2503.15870>>.
- MUNTAQIM, M.; SMRITY, T. A. Federated learning framework for brain tumor detection using mri images in non-iid data distributions. **Journal of Imaging Informatics in Medicine**, Springer, p. 1–19, 2025. Disponível em: <<https://doi.org/10.1007/s10278-025-01484-9>>.
- NAGHIB, A.; GHAREHCHOPOGH, F. S.; ZAMANIFAR, A. A comprehensive and systematic literature review on intrusion detection systems in the internet of medical things: current status, challenges, and opportunities. **Artificial Intelligence Review**, v. 58, n. 4, p. 114, Jan 2025. ISSN 1573-7462. Disponível em: <<https://doi.org/10.1007/s10462-024-11101-w>>.

- NERGIZ, M. Federated learning-based colorectal cancer classification by convolutional neural networks and general visual representation learning. **International Journal of Imaging Systems and Technology**, Wiley Online Library, v. 33, n. 3, p. 951–964, 2023. Disponível em: <<https://doi.org/10.1002/ima.22875>>.
- NGUYEN, D. C.; PHAM, Q.-V.; PATHIRANA, P. N.; DING, M.; SENEVIRATNE, A.; LIN, Z.; DOBRE, O.; HWANG, W.-J. Federated learning for smart healthcare: A survey. **ACM Computing Surveys (Csur)**, ACM New York, NY, v. 55, n. 3, p. 1–37, 2022. Disponível em: <<https://doi.org/10.1145/3501296>>.
- NING, Z.; TIAN, C.; XIAO, M.; FAN, W.; WANG, P.; LI, L.; WANG, P.; ZHOU, Y. Fedgcs: A generative framework for efficient client selection in federated learning via gradient-based optimization. **arXiv preprint arXiv:2405.06312**, 2024. Disponível em: <<https://doi.org/10.48550/arXiv.2405.06312>>.
- NISHIO, T.; YONETANI, R. Client selection for federated learning with heterogeneous resources in mobile edge. In: **ICC 2019 - 2019 IEEE International Conference on Communications (ICC)**. Shanghai, China: IEEE, 2019. p. 1–7. Disponível em: <<https://doi.org/10.1109/ICC.2019.8761315>>.
- OUYANG, C.; MAO, J.; LI, Y.; LI, T.; ZHU, D.; ZHOU, C.; XU, Z. Federated learning for extreme label noise: Enhanced knowledge distillation and particle swarm optimization. **Electronics**, MDPI AG, v. 14, n. 2, p. 366, 2025. Disponível em: <<https://doi.org/DOI:10.3390/electronics14020366>>.
- PONTI, M. A.; RIBEIRO, L. S. F.; NAZARE, T. S.; BUI, T.; COLLOMOSSE, J. Everything you wanted to know about deep learning for computer vision but were afraid to ask. In: **2017 30th SIBGRAPI Conference on Graphics, Patterns and Images Tutorials (SIBGRAPI-T)**. Niterói, Brazil: IEEE, 2017. p. 17–41. ISSN 2474-0705. Disponível em: <<https://doi.org/10.1109/SIBGRAPI-T.2017.12>>.
- REHMAN, A.; XING, H.; FENG, L.; HUSSAIN, M.; GULZAR, N.; KHAN, M. A.; HUSSAIN, A.; SAEED, D. Fedcscd-gan: A secure and collaborative framework for clinical cancer diagnosis via optimized federated learning and gan. **Biomedical Signal Processing and Control**, Elsevier, v. 89, p. 105893, 2024. Disponível em: <<https://doi.org/10.1016/j.bspc.2023.105893>>.
- RIEKE, N.; HANCOX, J.; LI, W.; MILLETARI, F.; ROTH, H. R.; ALBARQOUNI, S.; BAKAS, S.; GALTIER, M. N.; LANDMAN, B. A.; MAIER-HEIN, K. et al. The future of digital health with federated learning. **NPJ digital medicine**, Nature Publishing Group UK London, v. 3, n. 1, p. 119, 2020. Disponível em: <<https://doi.org/10.1038/s41746-020-00323-1>>.
- RODRIGUES, L.; RODRIGUES, L.; SILVA, D. da; MARI, J. F. Evaluating convolutional neural networks for covid-19 classification in chest x-ray images. In: **Anais do XVI Workshop de Visão Computacional**. Porto Alegre, RS, Brasil: SBC, 2020. p. 52–57. ISSN 0000-0000. Disponível em: <<https://doi.org/10.5753/wvc.2020.13480>>.
- RODRIGUES, L. F.; NALDI, M. C.; MARI, J. F. Comparing convolutional neural networks and preprocessing techniques for hep-2 cell classification in immunofluorescence images. **Computers in Biology and Medicine**, v. 116, p. 103542, 2020. ISSN 0010-4825. Disponível em: <<https://doi.org/10.1016/j.combiomed.2019.103542>>.

- RODRIGUES, L. G. F.; BARBOSA, G. V. G.; MOREIRA, R.; MOREIRA, L. F. R.; BACKES, A. R. Medical image classification with privacy: Centralized and federated learning comparison. **Revista de Informática Teórica e Aplicada**, v. 32, n. 1, p. 180–187, Feb. 2025. Disponível em: <<https://doi.org/10.22456/2175-2745.143478>>.
- RODRIGUES MOREIRA, L. F.; MOREIRA, R.; TRAVENÇOLO, B. A. N.; BACKES, A. R. An Artificial Intelligence-as-a-Service Architecture for deep learning model embodiment on low-cost devices: A case study of COVID-19 diagnosis. **Applied Soft Computing**, v. 134, p. 110014, 2023. ISSN 1568-4946. Disponível em: <<https://doi.org/10.1016/j.asoc.2023.110014>>.
- _____. Deep learning based image classification for embedded devices: A systematic review. **Neurocomputing**, v. 623, p. 129402, 2025. ISSN 0925-2312. Disponível em: <<https://doi.org/10.1016/j.neucom.2025.129402>>.
- RUSSAKOVSKY, O.; DENG, J.; SU, H.; KRAUSE, J.; SATHEESH, S.; MA, S.; HUANG, Z.; KARPATHY, A.; KHOSLA, A.; BERNSTEIN, M.; BERG, A. C.; FEI-FEI, L. Imagenet large scale visual recognition challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211–252, Dec 2015. ISSN 1573-1405. Disponível em: <<https://doi.org/10.1007/s11263-015-0816-y>>.
- _____. Imagenet large scale visual recognition challenge. **International Journal of Computer Vision**, v. 115, n. 3, p. 211–252, Dec 2015. ISSN 1573-1405. Disponível em: <<https://doi.org/10.1007/s11263-015-0816-y>>.
- SANDLER, M.; HOWARD, A.; ZHU, M.; ZHMOGINOV, A.; CHEN, L.-C. Mobilenetv2: Inverted residuals and linear bottlenecks. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**. Salt Lake City: IEEE, 2018. Disponível em: <<https://doi.org/10.48550/arXiv.1801.04381>>.
- Silva Neto, P. C. da; KUNST, R.; BARBOSA, J. L. V.; LEINDECKER, A. P. T.; SAVARIS, R. F. Breast cancer dataset with biomarker Biglycan. **Data in Brief**, v. 47, p. 108978, 2023. ISSN 2352-3409. Disponível em: <<https://doi.org/10.1016/j.dib.2023.108978>>.
- SOHAN, M. F.; BASALAMAH, A. A Systematic Review on Federated Learning in Medical Image Analysis. **IEEE Access**, v. 11, p. 28628–28644, 2023. Disponível em: <<https://doi.org/10.1109/ACCESS.2023.3260027>>.
- SOUZA, A. M. de; MACIEL, F.; COSTA, J. B. da; BITTENCOURT, L. F.; CERQUEIRA, E.; LOUREIRO, A. A.; VILLAS, L. A. Adaptive client selection with personalization for communication efficient federated learning. **Ad Hoc Networks**, Elsevier, v. 157, p. 103462, 2024. Disponível em: <<https://doi.org/10.1016/j.adhoc.2024.103462>>.
- SUBASHCHANDRABOSE, U.; JOHN, R.; ANBAZHAGU, U. V.; VENKATESAN, V. K.; RAMAKRISHNA, M. T. Ensemble Federated Learning Approach for Diagnostics of Multi-Order Lung Cancer. **Diagnostics**, v. 13, n. 19, 2023. ISSN 2075-4418. Disponível em: <<https://doi.org/10.3390/diagnostics13193053>>.
- TAN, M.; LE, Q. V. Efficientnet: Rethinking model scaling for convolutional neural networks. **CoRR**, abs/1905.11946, 2019. Disponível em: <<https://doi.org/10.48550/arXiv.1905.119466>>.

- TAN, Y. N.; TINH, V. P.; LAM, P. D.; NAM, N. H.; KHOA, T. A. A transfer learning approach to breast cancer classification in a federated learning framework. **IEEE Access**, IEEE, v. 11, p. 27462–27476, 2023. Disponível em: <<https://doi.org/10.1109/ACCESS.2023.3257562>>.
- VEZETEU, P.-V.; ANDRONESCU, A.-D.; NăSTAC, D.-I. A literature review on artificial intelligence in dermatological diagnosis and tissue microscopy. **IEEE Photonics Journal**, v. 17, n. 3, p. 1–14, 2025. Disponível em: <<https://doi.org/10.1109/JPHOT.2025.3557447>>.
- ZHOU, S. K.; GREENSPAN, H.; DAVATZIKOS, C.; DUNCAN, J. S.; GINNEKEN, B. V.; MADABHUSHI, A.; PRINCE, J. L.; RUECKERT, D.; SUMMERS, R. M. A review of deep learning in medical imaging: Imaging traits, technology trends, case studies with progress highlights, and future promises. **Proceedings of the IEEE**, v. 109, n. 5, p. 820–838, 2021. Disponível em: <<https://doi.org/10.1109/JPROC.2021.3054390>>.