



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE TELEINFORMÁTICA
CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO

MATHEUS ROCHA MONTEIRO

**FEDKMEANS: UMA ABORDAGEM BASEADA EM CLUSTERIZAÇÃO PARA
AGREGAÇÃO EM APRENDIZADO FEDERADO APLICADO À GERAÇÃO DE ECG
SINTÉTICO**

FORTALEZA

2024

MATHEUS ROCHA MONTEIRO

FEDKMEANS: UMA ABORDAGEM BASEADA EM CLUSTERIZAÇÃO PARA
AGREGAÇÃO EM APRENDIZADO FEDERADO APLICADO À GERAÇÃO DE ECG
SINTÉTICO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Orientadora: Profa. Dra. Atslands Rego da Rocha

FORTALEZA

2024

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- M778f Monteiro, Matheus Rocha.
FedKMeans : uma abordagem baseada em clusterização para agregação em aprendizado federado aplicado à geração de ECG sintético / Matheus Rocha Monteiro. – 2024.
66 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia de Computação, Fortaleza, 2024.
Orientação: Profa. Dra. Atslands Rego da Rocha.
1. ECG. 2. PPG. 3. Aprendizado federado. 4. Privacidade de dados. 5. Dispositivos vestíveis. I. Título.
CDD 621.39
-

MATHEUS ROCHA MONTEIRO

FEDKMEANS: UMA ABORDAGEM BASEADA EM CLUSTERIZAÇÃO PARA
AGREGAÇÃO EM APRENDIZADO FEDERADO APLICADO À GERAÇÃO DE ECG
SINTÉTICO

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Aprovada em:

BANCA EXAMINADORA

Profa. Dra. Atslands Rego da Rocha (Orientadora)
Universidade Federal do Ceará (UFC)

Prof. Dr. César Lincoln Cavalcante Mattos
Universidade Federal do Ceará (UFC)

Prof. Dr. Régis Pires Magalhães
Universidade Federal do Ceará (UFC)

À minha mãe, cujo amor incondicional e força incansável foram meu porto seguro em todos os momentos. Você não apenas me ensinou a caminhar, mas também a correr atrás dos meus sonhos. Este trabalho é tanto seu quanto meu.

AGRADECIMENTOS

Aos meus amigos Vitor Rosa, Helano Fontenele, Davi Queiroz, Danilo Meireles, Lucas Noronha, Catherine Markert, Marcos Augusto, Yago Oliveira e Vandemberg Júnior que estiveram ao meu lado em diversos momentos desta jornada. Vocês foram mais do que companheiros, vocês foram pilares de apoio e motivos de sorrisos nos dias mais desafiadores. Cada conversa, cada risada e cada momento compartilhado contribuíram para que eu chegasse até aqui. Obrigado por tornarem essa trajetória mais leve e significativa.

À minha orientadora, Atslands Rego, por acreditar em mim desde o início e por me oferecer a oportunidade de crescer academicamente e pessoalmente. Sua paciência, dedicação e receptividade foram fundamentais para o desenvolvimento deste trabalho. Agradeço por toda a confiança depositada em mim e por ter me guiado com tanto atenção e profissionalismo. Foi um privilégio contar com sua orientação.

Aos meus avós, Maria e Airton, por todo o amor, carinho e ensinamentos que me transmitiram ao longo da vida. Vocês são exemplos de força, generosidade e sabedoria, e tudo o que conquistei até hoje carrega um pedacinho de vocês. Obrigado por sempre estarem presentes, mesmo que de longe, e por me ensinarem o valor da família e da perseverança.

Aos meus tios, Alexandre e Airton, pelo apoio incondicional e pelo carinho que sempre demonstraram. Vocês foram importantes em diversos momentos da minha vida, e sou grato por cada conselho, cada palavra de incentivo e cada gesto de afeto. Saber que posso contar com vocês é um dos meus maiores tesouros.

Ao meu pai, Marcos, por ser um exemplo de dedicação. Obrigado por sempre me ensinar a importância do trabalho honesto e do compromisso com aquilo que acreditamos. Seus ensinamentos foram fundamentais para que eu chegasse até aqui, e sou imensamente grato por tudo o que você fez por mim.

À minha mãe, por ser a pessoa mais incrível que já conheci. Você nunca mediu esforços para me proporcionar o melhor, sempre colocando meu bem-estar e felicidade acima de tudo. Lembro de cada momento, de cada sacrifício e de cada gesto de amor. Você é minha maior inspiração, e tudo o que sou hoje é graças ao seu apoio incondicional. Obrigado por tudo, por cada ensinamento, por cada abraço e por cada palavra de incentivo. Saiba que sou eternamente grato por tudo o que você fez por mim.

“Life is what happens in-between the dreams
you’re trying to remember”

(Ron "Bumblefoot" Thal)

RESUMO

O eletrocardiograma (ECG) é uma ferramenta essencial para o diagnóstico de condições cardíacas, fornecendo informações detalhadas sobre o ritmo e a atividade elétrica do coração. No entanto, sua obtenção tradicional é invasiva, exigindo equipamentos especializados, eletrodos fixados ao corpo do paciente e colaboração ativa, o que limita sua acessibilidade e monitoramento contínuo. Com o advento de dispositivos vestíveis, como relógios inteligentes, tornou-se possível coletar biosinais de forma passiva, como a fotopletismografia (PPG). Entretanto, o PPG isoladamente não oferece a riqueza diagnóstica do ECG, e a medição direta de ECG nesses dispositivos ainda enfrenta barreiras técnicas.

Neste trabalho é proposto uma abordagem baseada em aprendizado de máquina para estimar sinais de ECG a partir de dados de PPG, utilizando redes neurais BiLSTM (Bidirecionais de Memória de Longo Curto Prazo) e técnicas de aprendizado federado para aprimorar a privacidade dos dados e a robustez dos modelos em ambientes distribuídos. A metodologia inclui o pré-processamento dos sinais de PPG e ECG da base de dados MIMIC-II, a modelagem do problema como uma tarefa de regressão sequencial e a implementação de duas estratégias de agregação federada: o FedAvg (padrão) e o FedKMeans, desenvolvida neste trabalho, que introduz uma etapa de clusterização (K-Means) para agrupar modelos locais com características semelhantes antes da agregação. Nos experimentos, quatro cenários foram comparados: treinamento centralizado, local individual, federado com FedAvg e federado com FedKMeans. As métricas de avaliação incluíram RMSE, MSE, coeficiente de Pearson, tempo de execução e uso de memória. Os resultados demonstraram que o FedKMeans apresenta vantagens em cenários heterogêneos, oferecendo maior precisão na geração de ECG sintéticos e melhor eficiência computacional em comparação ao FedAvg. Além disso, a abordagem proposta aborda questões éticas associadas à coleta centralizada de dados médicos, garantindo a privacidade dos pacientes.

Essa combinação de técnicas transforma dispositivos vestíveis em ferramentas avançadas para detecção precoce de doenças cardiovasculares, com potencial para aplicações clínicas práticas e escaláveis. O trabalho contribui para a área de aprendizado federado ao explorar uma solução eficiente e segura para a geração de dados médicos sintéticos, preservando a privacidade e a utilidade clínica.

Palavras-chave: ECG. PPG. Aprendizado Federado. Privacidade de Dados. Dispositivos Vestíveis

ABSTRACT

The electrocardiogram (ECG) is an essential tool for diagnosing cardiac conditions, providing detailed information about the heart's rhythm and electrical activity. However, traditional ECG acquisition is invasive, requiring specialized equipment, electrodes attached to the patient's body, and active collaboration, which limits its accessibility and continuous monitoring. With the advent of wearable devices, such as smartwatches, it has become possible to passively collect biosignals, such as photoplethysmography (PPG). However, PPG alone does not offer the diagnostic richness of ECG, and direct ECG measurement on these devices still faces technical barriers.

This work proposes a machine learning-based approach to estimate ECG signals from PPG data, using Bidirectional Long Short-Term Memory (BiLSTM) neural networks and federated learning techniques to enhance data privacy and model robustness in distributed environments. The methodology includes preprocessing PPG and ECG signals from the MIMIC-II database, modeling the problem as a sequential regression task, and implementing two federated aggregation strategies: FedAvg (standard) and FedKMeans, which introduces a clustering step (K-Means) to group local models with similar characteristics before aggregation. Experiments compared four scenarios: centralized training, individual local training, federated training with FedAvg, and federated training with FedKMeans. Evaluation metrics included RMSE, MSE, Pearson correlation coefficient, execution time, and memory usage. The results demonstrated that FedKMeans offers advantages in heterogeneous scenarios, providing higher accuracy in synthetic ECG generation and better computational efficiency compared to FedAvg. Additionally, the proposed approach overcomes the diagnostic limitations of PPG and addresses ethical concerns associated with centralized medical data collection, ensuring patient privacy.

This combination of techniques transforms wearable devices into advanced tools for early detection and management of cardiovascular diseases, with potential for practical and scalable clinical applications. The work contributes to the federated learning field by exploring an efficient and secure solution for generating synthetic medical data, preserving privacy and clinical utility.

Keywords: Synthetic ECG. PPG. Federated Learning. Data Privacy. Wearable Devices

LISTA DE FIGURAS

Figura 1 – Exemplo de ECG anotado	21
Figura 2 – Exemplo de PPG anotado	23
Figura 3 – Arquitetura do Aprendizado Federado (<i>Federated Learning</i>) (FL).	28
Figura 4 – Exemplos de Dados do <i>The Medical Information Mart for Intensive Care II</i> (MIMIC-II) (Paciente 0)	39
Figura 5 – Fluxo de pré-processamento dos sinais de ECG e PPG	40
Figura 6 – Arquitetura da rede <i>Bidirecional Long Short-Term Memory</i> (BiLSTM) implementada para a geração de sinais de Eletrocardiograma (ECG) sintéticos a partir de Fotopletismografia (PPG). A camada de entrada recebe sequências de PPG com 125 pontos (equivalente a 1 segundo de sinal a 125 Hz), que são processadas por 128 neurônios na camada bidirecional. Cada neurônio analisa a sequência temporal tanto na direção direta quanto reversa. A camada de saída gera a sequência de ECG sintético correspondente, também com 125 pontos, mantendo o alinhamento temporal com o sinal de entrada.	42
Figura 7 – Arquitetura do FedAvg	44
Figura 8 – Arquitetura do algoritmo FedKMeans	44
Figura 9 – Comparativo do RMSE durante o treinamento e validação	52
Figura 10 – Coeficientes de Pearson ao decorrer do processo de treinamento	53
Figura 11 – Comparativo do MSE durante o treinamento e validação	54
Figura 12 – Exemplo de ECG gerado pelo método FedAvg (em vermelho) comparado com o ECG real (em azul)	56
Figura 13 – Exemplo de ECG gerado pelo método FedKMeans (em vermelho) comparado com o ECG real (em azul)	57
Figura 14 – Distribuição de Clientes por <i>Cluster</i> a cada 10 Rodadas	58

LISTA DE TABELAS

Tabela 1 – Comparativo de trabalhos relacionados à conversão PPG-ECG	32
Tabela 2 – Trabalhos relacionados ao aprendizado federado em saúde	34
Tabela 3 – Hiperparâmetros do modelo BiLSTM.	42
Tabela 4 – Comparativo de performance com dados de teste dos cenários base	51
Tabela 5 – Comparativo dos coeficientes de Pearson entre FedAvg e FedKMeans após o treinamento	53
Tabela 6 – Comparativo de performance com dados de teste entre FedAvg e FedKMeans	55
Tabela 7 – Comparativo do uso de memória entre FedAvg e FedKMeans	60
Tabela 8 – Comparativo do tempo de execução de uma rodada de treinamento entre FedAvg e FedKMeans	60

LISTA DE ABREVIATURAS E SIGLAS

API	Interface de Programação de Aplicação (<i>Application Programming Interface</i>)
BiLSTM	<i>Bidirecional Long Short-Term Memory</i>
CNN	Redes Neurais Convolucionais (<i>Convolutional Neural Network</i>)
DCT	Transformada Discreta de Cosseno (<i>Discrete Cosine Transform</i>)
DCVs	Doenças Cardiovasculares
DP	Desvio Padrão
ECG	Eletrocardiograma
FedBN	<i>Federated Batch Normalization</i>
FedMA	<i>Federated Matched Averaging</i>
FL	Aprendizado Federado (<i>Federated Learning</i>)
GAN	Rede Adversária Generativa (<i>Generative Adversarial Networks</i>)
GB	gigabytes
Hz	hertz
IncResU-Net	<i>Inception Residual U-Net</i>
LSTM	<i>Long Short-Term Memory</i>
MB	megabytes
MIMIC-II	<i>The Medical Information Mart for Intensive Care II</i>
MIT	<i>Massachusetts Institute of Technology</i>
MLPNN	<i>Multi-layer Perceptron Neural Network</i>
MSE	Erro Quadrático Médio
mV	milivolts
não-IID	não independentes e identicamente distribuídos
PCA	Análise de Componentes Principais (<i>Principal Component Analysis</i>)
PPG	Fotopletismografia
Ridge	Regressão Ridge
RMSE	Raiz do Erro Quadrático Médio
RNN	Rede Neural Recorrente (<i>Recurrent Neural Network</i>)
SAE	<i>Stacked Autoencoder</i>
SVM	Máquina de Vetores de Suporte (<i>Support Vector Machine</i>)
TLS	<i>Transport Layer Security</i>
Transformer-SPA	<i>Transformer with Shifted Periodic Attention</i>

ua

unidades arbitrárias

UTI

Unidade de Terapia Intensiva

LISTA DE SÍMBOLOS

SpO_2	Saturação de oxigênio
r	Coefficiente de <i>Pearson</i>
y_i	Valor real da <i>i</i> -ésima amostra
\hat{y}_i	Valor previsto da <i>i</i> -ésima amostra
n	Número de amostras
\bar{x}	Média dos valores reais
\bar{y}	Média dos valores previstos
MSE	Erro Quadrático Médio (<i>Mean Square Error</i>)
$RMSE$	Raiz do Erro Quadrático Médio (<i>Root Mean Square Error</i>)

SUMÁRIO

1	INTRODUÇÃO	17
1.1	Contextualização do Problema	17
1.2	Motivação	18
1.3	Objetivos	19
<i>1.3.1</i>	<i>Objetivos Gerais</i>	<i>19</i>
<i>1.3.2</i>	<i>Objetivos Específicos</i>	<i>19</i>
1.4	Contribuição	19
1.5	Organização do Trabalho	19
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Eletrocardiograma ECG	21
<i>2.1.1</i>	<i>Desafios em Dispositivos Vestíveis</i>	<i>22</i>
2.2	Fotopletismografia PPG	22
2.3	Aprendizado de Máquina	24
<i>2.3.1</i>	<i>Fundamentos de Redes Neurais</i>	<i>24</i>
<i>2.3.2</i>	<i>Arquiteturas para Processamento de Séries Temporais</i>	<i>24</i>
<i>2.3.2.1</i>	<i>Redes LSTM e BiLSTM</i>	<i>24</i>
<i>2.3.2.2</i>	<i>Redes Generativas Adversariais (GANs)</i>	<i>25</i>
<i>2.3.2.3</i>	<i>Arquiteturas Transformer</i>	<i>26</i>
<i>2.3.3</i>	<i>Comparação entre Arquiteturas</i>	<i>26</i>
<i>2.3.4</i>	<i>Desafios e Considerações</i>	<i>26</i>
<i>2.3.5</i>	<i>Técnicas de Agrupamento</i>	<i>27</i>
<i>2.3.5.1</i>	<i>Algoritmo K-means</i>	<i>27</i>
2.4	Aprendizado Federado	28
<i>2.4.1</i>	<i>Princípios Básicos</i>	<i>28</i>
<i>2.4.2</i>	<i>Estratégias de Agregação</i>	<i>29</i>
<i>2.4.2.1</i>	<i>FedAvg</i>	<i>29</i>
<i>2.4.2.2</i>	<i>Variantes do FedAvg</i>	<i>29</i>
<i>2.4.3</i>	<i>Desafios e Considerações</i>	<i>30</i>
<i>2.4.3.1</i>	<i>Heterogeneidade dos Dados</i>	<i>30</i>
3	TRABALHOS RELACIONADOS	31

3.1	Conversão de PPG para ECG	31
3.1.1	<i>Análise de Trabalhos Seleccionados</i>	31
3.1.1.1	<i>Tendências Observadas</i>	32
3.1.1.2	<i>Problemas Comuns</i>	33
3.2	Aprendizado Federado em Saúde	34
3.2.1	<i>Tendências Observadas</i>	35
3.2.2	<i>Desafios</i>	35
3.3	Diferencial deste Trabalho	36
4	METODOLOGIA	37
4.1	Introdução	37
4.2	Base de Dados	37
4.2.1	<i>Descrição Geral</i>	37
4.2.2	<i>Sobre os Sinais</i>	38
4.3	Pré-processamento dos Dados	38
4.3.1	<i>Fluxo de Pré-processamento</i>	38
4.3.2	<i>Nota sobre as Ferramentas Utilizadas</i>	40
4.4	Aprendizado de Máquina	41
4.4.1	<i>BiLSTM</i>	41
4.4.2	<i>Hiperparâmetros do Modelo</i>	41
4.5	Aprendizado Federado	43
4.5.1	<i>FedAvg</i>	43
4.5.2	<i>FedKMeans</i>	44
4.5.2.1	<i>Etapas</i>	45
4.6	Métricas de Avaliação	45
4.6.1	<i>Métricas de Qualidade do Sinal</i>	45
4.6.2	<i>Métricas de Desempenho Computacional</i>	46
4.7	Experimentos	46
4.7.1	<i>Cenários de Experimentação</i>	47
4.7.2	<i>Configuração dos Experimentos</i>	48
4.7.3	<i>Protocolo de Avaliação</i>	48
4.8	Implementação e Ferramentas	48
5	RESULTADOS	50

5.1	Introdução	50
5.2	Análise dos Cenários Base	51
5.3	Desempenho do Modelo	52
5.3.1	<i>Índices de Erro ao Longo das Rodadas</i>	52
5.3.2	<i>Coefficientes de Pearson</i>	52
5.3.3	<i>Análise de Convergência</i>	54
5.3.4	<i>Comparativo entre as Estratégias Federadas</i>	55
5.4	Análise Visual dos Sinais Gerados	56
5.5	Análise dos Clusters	57
5.6	Eficiência Computacional	59
5.6.1	<i>Uso de Memória</i>	60
5.6.2	<i>Tempo de Treinamento</i>	60
5.7	Discussão dos Resultados	61
5.7.1	<i>Comparação com o Treinamento Centralizado</i>	61
5.7.2	<i>Comparação com o Treinamento Local Individual</i>	61
5.7.3	<i>Desempenho do FedAvg e FedKMeans</i>	62
5.7.4	<i>Eficiência Computacional</i>	62
5.7.5	<i>Implicações Práticas</i>	62
6	CONCLUSÃO E TRABALHOS FUTUROS	63
	REFERÊNCIAS	65

1 INTRODUÇÃO

1.1 Contextualização do Problema

Atualmente, as Doenças Cardiovasculares (DCVs) são uma das principais causas de mortalidade global, sendo responsáveis por 17,5 milhões de óbitos por ano (MAGNUSSEN *et al.*, 2023). O diagnóstico precoce e o monitoramento contínuo são essenciais para reduzir os impactos dessas condições, e o ECG desempenha um papel central nesse processo (SUMALATHA *et al.*, 2024). O ECG é um exame médico que registra a atividade elétrica do coração, permitindo a identificação de arritmias, isquemias e outras anomalias cardíacas. No entanto, a aquisição tradicional de ECG é limitada por sua natureza invasiva: requer equipamentos especializados, eletrodos fixados ao corpo do paciente e, frequentemente, a presença de um profissional de saúde. Essas limitações tornam o ECG pouco acessível para monitoramento contínuo ou em ambientes não clínicos, como residências ou locais de trabalho.

Com o avanço das tecnologias vestíveis, como *smartwatches* e pulseiras inteligentes, surgiu a possibilidade de coletar biosinais de forma não invasiva e contínua. Entre esses sinais, o PPG destaca-se por sua simplicidade e baixo custo (LEE; LEE, 2021). O PPG mede variações no volume sanguíneo por meio de sensores ópticos, sendo amplamente utilizado para estimar frequência cardíaca e saturação de oxigênio. No entanto, o PPG não oferece a mesma riqueza diagnóstica do ECG, pois não captura diretamente a atividade elétrica do coração. Além disso, a medição direta de ECG em dispositivos vestíveis ainda enfrenta desafios técnicos, como a necessidade de múltiplos eletrodos e a interferência de movimentos do usuário.

Nesse contexto, a geração de sinais de ECG sintéticos a partir de dados de PPG emerge como uma solução promissora. Essa abordagem combina a conveniência dos dispositivos vestíveis com a precisão diagnóstica do ECG, permitindo o monitoramento contínuo e não invasivo de pacientes (SARKAR; ETEMAD, 2020). No entanto, o desenvolvimento de modelos capazes de realizar essa conversão com alta precisão e robustez é um desafio complexo, especialmente em cenários onde os dados são distribuídos e heterogêneos. Além disso, a centralização de dados médicos para treinamento de modelos de aprendizado de máquina levanta preocupações significativas sobre a privacidade dos pacientes, uma vez que informações sensíveis precisam ser compartilhadas e armazenadas em servidores centralizados.

O FL surge como uma abordagem viável para treinar modelos de forma distribuída, preservando a privacidade dos dados. No FL, os modelos são treinados localmente em cada

dispositivo, e apenas os parâmetros atualizados são compartilhados com um servidor central para agregação (HARD *et al.*, 2018). No entanto, a heterogeneidade dos dados em ambientes federados, especialmente em aplicações médicas, representa um desafio adicional (ANNAPPA *et al.*, 2024). Dispositivos diferentes podem coletar dados de pacientes com características distintas, como idade, gênero e condições de saúde, o que pode levar a modelos locais com desempenho variado. Essa heterogeneidade pode comprometer a eficácia da agregação de modelos, resultando em um modelo global menos preciso.

1.2 Motivação

A principal motivação deste trabalho surge da convergência de três fatores críticos no cenário atual da saúde cardiovascular: o aumento da incidência de DCVs, as limitações dos métodos tradicionais de monitoramento cardíaco e os desafios de privacidade no processamento de dados médicos.

O primeiro fator é a necessidade urgente de métodos mais acessíveis e contínuos para monitoramento cardíaco, considerando o impacto global das DCVs na mortalidade. Os métodos tradicionais de ECG, embora precisos, são limitados em termos de disponibilidade e praticidade para monitoramento contínuo. A popularização de dispositivos vestíveis oferece uma oportunidade única para democratizar o acesso ao monitoramento cardíaco, mas esbarra em desafios técnicos significativos.

O segundo fator motivador é a crescente preocupação com a privacidade dos dados médicos. O desenvolvimento de modelos de aprendizado de máquina tradicionalmente requer a centralização de grandes volumes de dados sensíveis, o que levanta questões éticas e regulatórias importantes. O FL emerge como uma solução promissora para este desafio, permitindo o treinamento de modelos sem comprometer a privacidade dos pacientes.

Por fim, a heterogeneidade dos dados médicos entre diferentes pacientes representa tanto um desafio quanto uma oportunidade de inovação. As técnicas tradicionais de agregação em aprendizado federado podem não ser adequadas para lidar com esta variabilidade, motivando o desenvolvimento de abordagens mais sofisticadas que possam adaptar-se às características individuais dos pacientes enquanto mantêm a eficácia do modelo global.

1.3 Objetivos

Diante desses desafios, este trabalho propõe uma abordagem que combina técnicas de aprendizado profundo e aprendizado federado para gerar sinais de ECG sintéticos, abordando tanto as limitações técnicas quanto as questões éticas.

1.3.1 *Objetivos Gerais*

O objetivo geral deste trabalho é desenvolver e avaliar uma abordagem baseada em aprendizado federado para a geração de sinais de ECG sintéticos a partir de dados de PPG, utilizando técnicas de clusterização para melhorar a agregação de modelos em cenários heterogêneos.

1.3.2 *Objetivos Específicos*

Os objetivos específicos incluem:

1. Utilizar o algoritmo FedAvg, e implementar uma nova estratégia de agregação baseada em clusterização, denominada FedKMeans, comparando o desempenho de ambas abordagens
2. Avaliar a qualidade dos sinais sintéticos gerados por meio de métricas como Raiz do Erro Quadrático Médio (RMSE), Erro Quadrático Médio (MSE) e coeficiente de Pearson.
3. Analisar a eficiência computacional das abordagens propostas, considerando tempo de execução e uso de memória.

1.4 Contribuição

Este trabalho contribui para a área de aprendizado federado ao propor uma abordagem inovadora para a geração de sinais de ECG sintéticos, utilizando técnicas de clusterização para melhorar a agregação de modelos em cenários heterogêneos.

1.5 Organização do Trabalho

Este trabalho está organizado em cinco capítulos, cada um abordando aspectos específicos da pesquisa.

A estrutura é a seguinte:

- **Capítulo 2 - Fundamentação Teórica:** Apresenta os conceitos teóricos essenciais para

o entendimento do trabalho, incluindo uma revisão sobre ECG, PPG, FL e técnicas de clusterização. Este capítulo fornece a base necessária para a compreensão das metodologias e técnicas utilizadas no desenvolvimento da pesquisa.

- **Capítulo 3 - Trabalhos Relacionados:** Discute estudos e abordagens anteriores relevantes para o tema, destacando as lacunas e oportunidades identificadas na literatura. São revisados trabalhos que abordam a geração de sinais de ECG sintéticos, o uso de PPG em dispositivos vestíveis e aplicações de aprendizado federado em saúde.
- **Capítulo 4 - Metodologia:** Descreve em detalhes a metodologia adotada no trabalho, incluindo a seleção e pré-processamento dos dados, a arquitetura do modelo BiLSTM, as estratégias de agregação federada (FedAvg e FedKMeans) e as métricas de avaliação utilizadas. Este capítulo também apresenta o fluxo de trabalho e as ferramentas utilizadas na implementação.
- **Capítulo 5 - Resultados:** Apresenta e analisa os resultados obtidos nos experimentos, comparando o desempenho das abordagens propostas (FedAvg e FedKMeans) em diferentes cenários. São discutidas as métricas de qualidade dos sinais de ECG sintéticos gerados, bem como a eficiência computacional das estratégias de agregação.
- **Capítulo 6 - Conclusão:** Resume as principais contribuições do trabalho, destacando os resultados alcançados e suas implicações práticas. São discutidas as limitações do estudo e propostas direções futuras para pesquisas na área de geração de sinais de ECG sintéticos e aprendizado federado aplicado à saúde.

2 FUNDAMENTAÇÃO TEÓRICA


Neste capítulo, são apresentados os conceitos teóricos fundamentais para o entendimento do trabalho, abordando desde os princípios básicos do ECG e do PPG até técnicas de aprendizado de máquina, como redes neurais BiLSTM e FL. A compreensão desses tópicos é essencial para contextualizar a proposta do trabalho e justificar as escolhas metodológicas.

2.1 Eletrocardiograma ECG

O eletrocardiograma (ECG) é um dos métodos mais amplamente utilizados para a avaliação da atividade elétrica do coração. Ele registra as variações de potencial elétrico geradas pela despolarização e repolarização das células cardíacas ao longo do tempo, fornecendo informações críticas sobre o ritmo, a condução e a saúde geral do sistema cardiovascular. Por ser um exame não invasivo, de baixo custo e altamente informativo, o ECG é considerado um "padrão-ouro" no diagnóstico e monitoramento de diversas condições cardíacas (BERKAYA *et al.*, 2018).

O sinal de ECG é gerado a partir da atividade elétrica do coração, que se propaga através do tecido cardíaco durante cada ciclo cardíaco. Essa atividade é registrada por eletrodos posicionados na superfície do corpo, que captam as diferenças de potencial elétrico entre diferentes pontos. O resultado é um sinal temporal que reflete a atividade cardíaca em múltiplas derivações (ex.: 12 derivações no ECG clínico padrão).

Figura 1 – Exemplo de ECG anotado



Fonte: Elaborado pelo autor.

Como ilustrado na Figura 1, a morfologia do sinal de ECG é composta por ondas, segmentos e intervalos que possuem significados clínicos específicos. Primeiramente, a Onda P corresponde à despolarização atrial, onde alterações em sua amplitude ou duração podem

indicar condições como fibrilação atrial ou hipertrofia atrial. O Complexo QRS representa a despolarização ventricular, sendo sua duração e forma críticas para identificar bloqueios de ramo ou arritmias ventriculares. Já a Onda T está associada à repolarização ventricular, cujas inversões ou elevações podem sugerir isquemia miocárdica ou infarto. Por fim, o Segmento ST, localizado entre o complexo QRS e a onda T, é crucial para o diagnóstico de infarto agudo do miocárdio. O ECG é amplamente utilizado em diversas aplicações clínicas. Principalmente no diagnóstico de arritmias, permitindo a identificação de ritmos cardíacos anormais, como fibrilação atrial, taquicardia ventricular e bradicardia. Além disso, é fundamental na detecção de isquemia e infarto, onde alterações no segmento ST e na onda T são indicativas de problemas no suprimento sanguíneo do miocárdio. O ECG também é essencial no monitoramento contínuo em Unidade de Terapia Intensiva (UTI) ou durante procedimentos cirúrgicos, sendo utilizado para acompanhar a função cardíaca em tempo real.

2.1.1 Desafios em Dispositivos Vestíveis

Apesar de sua importância clínica, o uso do ECG em dispositivos vestíveis enfrenta desafios significativos. Um dos principais limitantes é o número reduzido de derivações, pois dispositivos como *smartwatches* geralmente utilizam apenas uma ou duas derivações, restringindo a riqueza de informações quando comparado ao ECG clínico tradicional de 12 derivações. Além disso, os artefatos de movimento representam um obstáculo considerável, uma vez que a movimentação do usuário pode introduzir ruídos significativos no sinal, comprometendo sua interpretação e confiabilidade.

Outro desafio crucial é a necessidade de coleta ativa do sinal. Mesmo em dispositivos vestíveis modernos, a aquisição do ECG requer uma ação deliberada do usuário, como posicionar os dedos em eletrodos específicos do dispositivo por um determinado período. Esta limitação impossibilita o monitoramento contínuo e passivo da atividade cardíaca ao longo do dia, reduzindo significativamente a quantidade e frequência dos dados coletados em comparação com outras modalidades de sensoriamento.

2.2 Fotopletismografia PPG


A aquisição de PPG é uma técnica óptica não invasiva amplamente utilizada para medir variações no volume sanguíneo na microcirculação, geralmente na pele. Essa técnica

tem ganhado popularidade em dispositivos vestíveis devido à sua simplicidade, baixo custo e facilidade de integração. O PPG é comumente empregado para monitorar frequência cardíaca, saturação de oxigênio (SpO_2) e para inferir informações sobre a atividade cardiovascular (LEE; LEE, 2021).

O princípio baseia-se na emissão de luz sobre a pele e na detecção da quantidade refletida ou transmitida. As variações na absorção de luz devido ao fluxo sanguíneo são captadas por um fotodetector, gerando um sinal PPG.

Como é possível observar na Figura 2, o sinal PPG possui morfologia característica correlacionada com eventos cardíacos:

Figura 2 – Exemplo de PPG anotado



Fonte: Elaborado pelo autor.

- Onda sistólica: pico do sinal, relacionada ao complexo QRS do ECG
- Vale diastólico: vale do sinal, associada à onda T do ECG
- Incisura dicrótica: depressão na onda diastólica devido ao fechamento da válvula aórtica

A qualidade e características do sinal PPG são influenciadas por diversos fatores, incluindo a perfusão sanguínea do tecido, a presença de artefatos de movimento durante a aquisição e características individuais como o tom de pele e a espessura do tecido no local de medição.

O sinal PPG apresenta importantes correlações com o ECG, principalmente no que diz respeito ao intervalo RR, que pode ser estimado pelo tempo entre ondas sistólicas consecutivas, e ao atraso do pulso, medido entre o complexo QRS e o pico do PPG. No entanto, o PPG apresenta algumas limitações quando comparado ao ECG, como a ausência de informação elétrica direta do coração, maior sensibilidade a artefatos de movimento e significativa dependência da localização do sensor no corpo.

A tecnologia PPG tem se mostrado particularmente adequada para aplicações em

dispositivos vestíveis devido à sua natureza não invasiva, baixo consumo de energia e custo reduzido. Estas características têm impulsionado sua adoção em uma ampla gama de dispositivos de monitoramento contínuo da saúde, desde *smartwatches* até *smartbands*, permitindo o acompanhamento de parâmetros cardiovasculares de forma conveniente e acessível.

2.3 Aprendizado de Máquina

O Aprendizado Profundo tem revolucionado o campo da Inteligência Artificial, permitindo o desenvolvimento de modelos cada vez mais sofisticados para processamento de dados complexos, como sinais biomédicos. Esta seção apresenta os fundamentos das redes neurais e discute arquiteturas relevantes para a geração de sinais de ECG sintéticos.

2.3.1 Fundamentos de Redes Neurais

As redes neurais artificiais são modelos computacionais inspirados no funcionamento do cérebro humano, compostos por unidades de processamento interconectadas (neurônios) organizadas em camadas (HASSOUN *et al.*, 1996). Cada neurônio recebe entradas ponderadas, aplica uma função de ativação e produz uma saída, permitindo a modelagem de relações complexas e não-lineares nos dados. Como destacado por Hassoun *et al.* (1996), essa estrutura baseada em neurônios artificiais e suas interconexões permite que a rede aprenda representações hierárquicas dos dados, tornando-as particularmente eficazes em tarefas complexas de reconhecimento de padrões.

2.3.2 Arquiteturas para Processamento de Séries Temporais

2.3.2.1 Redes LSTM e BiLSTM

As Rede Neural Recorrente (*Recurrent Neural Network*) (RNN) foram as primeiras arquiteturas especificamente projetadas para processar dados sequenciais. Diferentemente das redes neurais tradicionais, a RNN possui conexões recorrentes que permitem que informações anteriores da sequência influenciem o processamento atual (YU *et al.*, 2019). Essa característica as torna naturalmente adequadas para análise de séries temporais, como sinais biomédicos.

As redes *Long Short-Term Memory* (LSTM) foram originalmente propostas por Hochreiter e Schmidhuber (1997) para solucionar o problema de desvanecimento do gradiente

(*vanishing gradient*) que afetava as RNNs tradicionais. Por meio de um mecanismo de portas (*input, forget e output*), as LSTMs conseguem controlar o fluxo de informação, permitindo que a rede mantenha ou esqueça informações relevantes ao longo de sequências temporais extensas. Esta característica tornou as LSTMs particularmente eficazes em tarefas de forecasting (previsão), onde padrões históricos precisam ser identificados para prever valores futuros. Contudo, as LSTMs convencionais apresentam limitações, como processamento unidirecional que considera apenas informações passadas, potencial sobreajuste em conjuntos de dados menores e alto custo computacional.

No entanto, a RNN tradicional enfrenta limitações significativas, principalmente o problema do desvanecimento do gradiente, que dificulta o aprendizado de dependências temporais de longo prazo. Isso é particularmente problemático no contexto de sinais de ECG, onde padrões importantes podem se estender por longos períodos.

As redes BiLSTM são especialmente projetadas para processar sequências temporais, superando limitações das RNNs tradicionais ao lidar com dependências de longo prazo (GRAVES; SCHMIDHUBER, 2005). A arquitetura BiLSTM, utilizada neste trabalho, estende esse conceito ao processar a sequência em ambas as direções (*forward e backward*), permitindo que o modelo capture padrões temporais mais complexos. As BiLSTM são adequadas para a geração de sinais de ECG sintéticos devido a diversas capacidades importantes. Primeiramente, elas conseguem capturar dependências temporais bidirecionais nos sinais fisiológicos, essenciais para compreender a dinâmica cardíaca completa. Além disso, estas redes são capazes de modelar relações complexas entre os componentes do sinal, como as ondas P, o complexo QRS e a onda T, preservando as características morfológicas essenciais. Adicionalmente, as BiLSTM demonstram excelente capacidade de lidar com variações na morfologia do sinal ao longo do tempo, aspecto crucial para gerar ECGs sintéticos que reflitam adequadamente as nuances dos sinais reais.

2.3.2.2 Redes Generativas Adversariais (GANs)

As Rede Adversária Generativa (*Generative Adversarial Networks*) (GAN)s têm emergido como uma alternativa promissora para a geração de sinais sintéticos. Compostas por um gerador e um discriminador que competem entre si, as GANs podem produzir sinais de ECG altamente realistas. Trabalhos como (KUMARI *et al.*, 2024) demonstraram sua eficácia, embora enfrentem desafios relacionados à estabilidade do treinamento e à consistência dos sinais

gerados.

2.3.2.3 *Arquiteturas Transformer*

Os *Transformers*, originalmente propostos para processamento de linguagem natural, têm sido adaptados com sucesso para processamento de sinais biomédicos. Sua capacidade de modelar dependências de longo alcance através do mecanismo de atenção os torna particularmente interessantes para a geração de ECG. (LAN, 2023) demonstrou resultados promissores utilizando uma arquitetura *Transformer-SPA* para conversão PPG-ECG.

2.3.3 *Comparação entre Arquiteturas*

A escolha da arquitetura mais apropriada depende de diversos fatores, incluindo:

- **Complexidade Computacional:** A BiLSTM oferece um bom equilíbrio entre capacidade de modelagem e eficiência computacional, enquanto GAN e *Transformers* geralmente demandam mais recursos.
- **Qualidade dos Sinais Gerados:** A GAN pode produzir sinais mais realistas, mas com menor controle sobre características específicas. BiLSTM e *Transformers* tendem a gerar sinais mais estáveis e controláveis.

2.3.4 *Desafios e Considerações*

No contexto de geração de ECG sintético, diversos desafios técnicos emergem e demandam abordagens sofisticadas para sua superação. A preservação de características morfológicas constitui um dos aspectos mais críticos neste processo, exigindo que os modelos computacionais sejam capazes de manter com precisão os elementos fundamentais do ECG, como a correta relação entre intervalos temporais e a fidelidade das amplitudes em cada componente do sinal.

Paralelamente, a questão da robustez a ruídos apresenta-se como um desafio significativo, uma vez que os dados reais frequentemente contêm artefatos e interferências que podem comprometer a qualidade do sinal de entrada, demandando algoritmos que filtrem eficientemente estas perturbações sem perder informações clinicamente relevantes.

O terceiro desafio fundamental reside na capacidade de generalização dos modelos, sendo imprescindível que as técnicas desenvolvidas apresentem desempenho consistente quando

aplicadas a dados de diferentes pacientes e condições clínicas variadas, garantindo assim a aplicabilidade ampla da solução em contextos clínicos heterogêneos.

A escolha da arquitetura BiLSTM neste trabalho fundamenta-se justamente em sua capacidade comprovada de endereçar estes desafios, combinando a habilidade de modelar sequências temporais complexas com eficiência computacional e estabilidade durante o treinamento, características que se tornam ainda mais relevantes quando consideramos as particularidades do aprendizado federado, onde a consistência e a eficiência do modelo são requisitos críticos.

2.3.5 *Técnicas de Agrupamento*

A clusterização é uma técnica de aprendizado não supervisionado que visa identificar grupos naturais em um conjunto de dados, onde objetos dentro do mesmo grupo são mais similares entre si do que com objetos de outros grupos. No contexto deste trabalho, técnicas de agrupamento são fundamentais para identificar padrões similares entre modelos locais no processo de agregação federada.

2.3.5.1 *Algoritmo K-means*

O *K-means* é um dos algoritmos de agrupamento mais populares e eficientes, proposto inicialmente por MacQueen *et al.* (1967). O algoritmo particiona n observações em k grupos, onde cada observação pertence ao grupo com a média mais próxima, minimizando a soma dos quadrados das distâncias dentro de cada grupo.

O algoritmo *K-means* opera através dos seguintes passos:

1. **Inicialização:** Seleciona k pontos aleatórios como centróides iniciais
2. **Atribuição:** Associa cada ponto ao centróide mais próximo
3. **Atualização:** Recalcula os centróides como a média dos pontos atribuídos
4. **Iteração:** Repete os passos 2 e 3 até convergir ou atingir um número máximo de iterações

O algoritmo apresenta algumas características importantes que influenciam diretamente seu desempenho e aplicabilidade. Em termos de convergência, o método oferece garantia matemática de atingir um mínimo local na função objetivo, embora não assegure a obtenção do mínimo global, o que pode resultar em agrupamentos subótimos em determinadas circunstâncias.

Esta característica está intrinsecamente relacionada à sua sensibilidade quanto à inicialização, uma vez que o resultado final do agrupamento pode variar significativamente dependendo da seleção inicial dos centróides, tornando recomendável a execução de múltiplas

inicializações com diferentes pontos de partida para identificar a solução mais robusta.

Estas particularidades, quando adequadamente consideradas na implementação, permitem explorar o potencial do algoritmo enquanto se mitigam suas limitações inerentes.

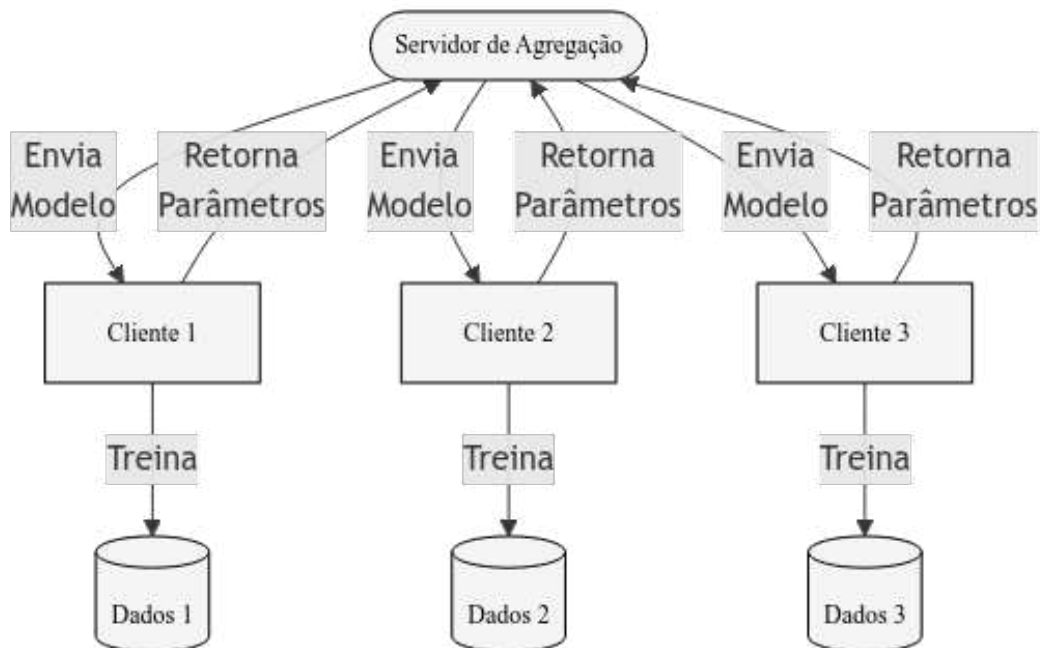
No contexto do aprendizado federado, o *K-means* é utilizado para agrupar modelos locais com características similares, permitindo uma agregação mais eficiente em cenários com alta heterogeneidade de dados. Esta abordagem é particularmente relevante para dados médicos, onde diferentes dispositivos podem coletar dados de pacientes com características distintas.

2.4 Aprendizado Federado

O FL é um paradigma de aprendizado de máquina distribuído que permite treinar modelos em dados descentralizados sem a necessidade de compartilhá-los diretamente. Introduzido por Hard *et al.* (2018), o FL surge como uma solução para cenários onde existem preocupações com privacidade, limitações práticas para centralizar dados e limitações de largura de banda e armazenamento que tornam impraticável a transmissão contínua de grandes volumes de dados para um servidor central, como é o caso de aplicações médicas e dispositivos vestíveis.

2.4.1 Princípios Básicos

Figura 3 – Arquitetura do FL.



Fonte: Elaborado pelo autor.

Como exemplificado na Figura 3, O FL opera através de um processo iterativo onde múltiplos clientes (dispositivos ou instituições) colaboram para treinar um modelo global, mantendo seus dados localmente. O processo típico inclui as seguintes etapas:

1. **Inicialização:** Um servidor central define a arquitetura do modelo e inicializa os parâmetros.
2. **Distribuição:** O modelo é enviado para os clientes participantes.
3. **Treinamento Local:** Cada cliente treina o modelo com seus dados locais.
4. **Agregação:** Os parâmetros atualizados são enviados ao servidor, que os combina para atualizar o modelo global.
5. **Iteração:** O processo se repete até atingir convergência ou um número predefinido de rodadas.

2.4.2 Estratégias de Agregação

As estratégias de agregação são fundamentais no aprendizado federado, pois determinam como o conhecimento dos modelos locais será combinado para formar um modelo global mais robusto. Embora o FedAvg seja o algoritmo mais básico e amplamente utilizado, suas limitações em cenários heterogêneos motivaram o desenvolvimento de várias extensões. Esta seção apresenta o FedAvg e suas principais variantes, destacando como cada uma aborda desafios específicos do aprendizado federado.

2.4.2.1 FedAvg

O FedAvg é o algoritmo mais fundamental no FL, proposto por Hard *et al.* (2018). Nesta abordagem, o servidor realiza uma média ponderada dos parâmetros dos modelos locais, onde os pesos são proporcionais ao tamanho do conjunto de dados de cada cliente. Apesar de sua simplicidade e eficácia em cenários homogêneos, o FedAvg pode enfrentar problemas de convergência quando os dados são não independentes e identicamente distribuídos (não-IID) ou quando há grande variabilidade nas capacidades computacionais dos clientes.

2.4.2.2 Variantes do FedAvg

Diversas variações do FedAvg foram propostas para lidar com desafios específicos do aprendizado federado:

- **FedProx**: Introduzido por Sahu *et al.* (2018), este algoritmo adiciona um termo de proximidade à função objetivo local para limitar a divergência entre modelos locais e o modelo global. O termo de proximidade penaliza grandes desvios dos parâmetros locais em relação ao modelo global, ajudando a estabilizar o treinamento em ambientes heterogêneos. Esta abordagem é particularmente útil quando os clientes possuem diferentes capacidades computacionais ou quando o número de épocas locais varia entre os clientes.
- **FedMA**: Proposto por Wang *et al.* (2020), o *Federated Matched Averaging* (FedMA) realiza agregação por camada, considerando explicitamente a permutação de neurônios em redes neurais. Este método resolve o problema de permutação de neurônios, onde diferentes modelos locais podem aprender representações similares em diferentes neurônios. O FedMA primeiro agrupa neurônios correspondentes entre diferentes modelos e então realiza a média dos parâmetros dentro de cada grupo, resultando em uma agregação mais precisa para redes neurais profundas.
- **FedBN**: Desenvolvido por Li *et al.* (2021), o *Federated Batch Normalization* (FedBN) modifica o processo de agregação para lidar com a heterogeneidade dos dados mantendo as estatísticas da normalização em lote (média e variância) localmente em cada cliente. Esta abordagem reconhece que as estatísticas de normalização são específicas da distribuição de dados de cada cliente e não devem ser agregadas globalmente. O FedBN melhora significativamente o desempenho em cenários não-IID, especialmente em tarefas de visão computacional e processamento de sinais.

2.4.3 *Desafios e Considerações*

2.4.3.1 *Heterogeneidade dos Dados*

Um dos principais desafios no FL é lidar com dados não-IID. Em aplicações médicas, como a geração de ECG sintético, os dados de diferentes pacientes podem apresentar distribuições significativamente distintas, afetando a convergência e o desempenho do modelo global.

No contexto de dispositivos vestíveis e sinais biomédicos, essa abordagem permite o desenvolvimento de modelos robustos sem comprometer a privacidade dos usuários, tornando-o especialmente adequado para a tarefa de geração de ECG sintético a partir de PPG.

3 TRABALHOS RELACIONADOS

Esta seção apresenta uma análise da literatura, focando em dois aspectos fundamentais: as técnicas de conversão PPG-ECG e as aplicações de aprendizado federado em dados de saúde. A primeira vertente explora os avanços nas metodologias de geração de ECG sintético, destacando as diferentes arquiteturas de aprendizado profundo e suas respectivas performances. A segunda examina como o aprendizado federado tem sido empregado no contexto de saúde, com ênfase especial nas estratégias de agregação e nas considerações sobre privacidade dos dados.

3.1 Conversão de PPG para ECG

A geração de sinais de ECG a partir de PPG tem atraído crescente interesse da comunidade científica, impulsionada pela popularidade de dispositivos vestíveis e pela necessidade de métodos não invasivos para monitoramento cardíaco. A Tabela 1 apresenta um resumo dos principais trabalhos nesta área, destacando suas abordagens, métricas de avaliação e limitações.

3.1.1 Análise de Trabalhos Selecionados

Pinto *et al.* (2023) utilizou uma arquitetura chamada de *Inception Residual U-Net* (IncResU-Net), alcançando boa precisão em conjuntos de dados como BIDMC e CAPNO. No entanto, o trabalho enfrenta desafios de generalização em ambientes não controlados, onde ruídos e artefatos de movimento são mais comuns.

(CHIU *et al.*, 2020) propôs uma abordagem com Redes Neurais Convolutiva (*Convolutional Neural Network*) (CNN), obtendo resultados promissores em termos de erro (L1, NMAE) e correlação. A instabilidade na detecção de picos, no entanto, limita sua aplicação em cenários clínicos.

Kumari *et al.* (2024) introduziu uma abordagem baseada em GAN, demonstrando alta fidelidade na geração de sinais de ECG. Apesar disso, o método mostrou-se menos eficaz em cenários reais, onde a qualidade do sinal de PPG pode variar significativamente.

Lan (2023) utilizou uma arquitetura *Transformer with Shifted Periodic Attention* (Transformer-SPA), alcançando alta precisão em bases como UQVSD e MIMIC-III. O trabalho destacou a necessidade de mais dados de longo prazo para melhorar a generalização do modelo.

Tabela 1 – Comparativo de trabalhos relacionados à conversão PPG-ECG

Referência	Arquitetura	Conjunto de Dados	Métricas	Pré-Processamento	Hardware	Tempo	Limitações
(PINTO <i>et al.</i> , 2023)	IncResU-Net	BIDMC, CAPNO, DA-LIA, WESAD	DTW, Pearson, MSE, MAE	Butterworth, FIR, Z-score, Min-Max	Não informado	Não	Generalização limitada para ambientes não controlados
(CHIU <i>et al.</i> , 2020)	CNN	UQVSD, BIDMC	L1, NMAE, NRMSE, MLE, MME	Min-Max, HPF, LPF, Data Augmentation	NVIDIA GTX1070	Sim	Instabilidade na detecção de picos
(DIANI; BOUKA-DOUM, 2024)	Ridge Regression + ResNet-50	CAPNO	RMSE, R ² , Pearson	Detecção de picos, LPF, HPF, Normalização	Macbook Air M2	Sim	Necessidade de alinhamento preciso
(TIAN <i>et al.</i> , 2022)	XDJDL	MIMIC-III	RMSE, R ² , Pearson, MLE, MME	Alinhamento de Picos, Segmentação de Ciclos	i7-8650U; 24GB RAM	Sim	Performance reduzida em dados ruidosos
(TIAN <i>et al.</i> , 2020)	XDJDL	MIMIC-III, CAPNO	Pearson, rRMSE, MAE	Alinhamento e segmentação de ciclos, Interpolação linear	i7-8650U, 24GB RAM	Sim	Menor precisão nas ondas P e T
(ZHU <i>et al.</i> , 2019)	DCT, Ridge	CAPNO	rRMSE, Pearson	Alinhamento, Segmentação, Normalização	Não informado	Não	Requer sinais de alta qualidade
(KUMARI <i>et al.</i> , 2024)	GAN	BIDMC, MIMIC-II	RMSE, MAE, PRD	Butterworth, Janelamento, Reamostragem 128 Hz	NVIDIA Tesla V100, FPGA	-	Limitações em cenários reais
(LAN, 2023)	Transformer-SPA	UQVSD, BIDMC, MIMIC-III	RMSE, Acurácia	Reamostragem 128 Hz, BioSPPY	NVIDIA Tesla T4	Não	Necessidade de mais dados de longo prazo
(MURMU <i>et al.</i> , 2024)	SAE, MLPNN, LSTM-RNN	MIMIC-II, MIMIC-III	MSE, MAE, RMSE, Pearson	Filtragem passa-banda, Pan-Tompkins	Broadcom 2835	Sim	Ineficaz para arritmias
Este trabalho	BiLSTM + Aprendizado Federado	MIMIC-II	RMSE, MSE, Pearson	Filtragem passa-baixa, Detecção de picos, Alinhamento temporal	NVIDIA GeForce RTX 3090	Sim	Generalização do modelo global quando utilizado o FedAvg como estratégia de agregação

Fonte: Elaborado pelo autor.

3.1.1.1 Tendências Observadas

A área de conversão de PPG para ECG tem observado uma evolução significativa nas arquiteturas utilizadas. Inicialmente, métodos mais simples, como Transformada Discreta de Cosseno (*Discrete Cosine Transform*) (DCT) e Regressão Ridge (Ridge) (ZHU *et al.*, 2019), eram predominantes. Essas abordagens, embora eficientes em cenários controlados, mostravam limitações na captura de padrões complexos e na generalização para dados ruidosos.

Com o avanço do aprendizado profundo, arquiteturas mais sofisticadas emergiram. Chiu *et al.* (2020) explorou o uso de CNNs, enquanto Murmu *et al.* (2024) investigou a com-

binção de *Stacked Autoencoder* (SAE), *Multi-layer Perceptron Neural Network* (MLPNN) e LSTMs. Mais recentemente, abordagens ainda mais avançadas foram propostas, como as GANs (KUMARI *et al.*, 2024) e arquiteturas Transformer-SPA (LAN, 2023). Essas arquiteturas permitem a modelagem de relações não lineares e dependências temporais complexas, resultando em sinais de ECG sintéticos mais precisos e realistas.

Em termos de pré-processamento, observa-se uma convergência para técnicas robustas de filtragem e normalização. Trabalhos como Pinto *et al.* (2023) e Kumari *et al.* (2024) utilizam filtros *Butterworth*, enquanto Tian *et al.* (2022) e Tian *et al.* (2020) enfatizam a importância do alinhamento de picos e segmentação de ciclos.

As bases de dados MIMIC (II e III), BIDMC e CAPNO emergiram como as mais utilizadas na literatura, devido à sua abrangência e disponibilidade pública. Esses conjuntos contêm sinais de PPG e ECG coletados em ambientes clínicos e não clínicos, proporcionando um cenário diversificado para treinamento e avaliação de modelos. Trabalhos recentes como Diani e Boukadoum (2024) e Tian *et al.* (2022) demonstram a preferência por estas bases de dados em suas avaliações.

3.1.1.2 Problemas Comuns

Apesar dos avanços consideráveis, diversos desafios técnicos persistem na área de conversão de PPG para ECG, impondo limitações que demandam soluções inovadoras.

A sensibilidade a ruídos constitui um obstáculo fundamental, uma vez que a qualidade do sinal de PPG depende criticamente das condições de aquisição, incluindo fatores como iluminação ambiente, pressão aplicada ao sensor e sutis movimentos do usuário durante o registro. Estas variáveis introduzem ruídos e artefatos que podem comprometer significativamente a precisão dos modelos de conversão, exigindo técnicas robustas de filtragem e pré-processamento.

Paralelamente, a necessidade de alinhamento temporal preciso entre os sinais de PPG e ECG emerge como outro desafio crítico, sendo este sincronismo essencial para a geração de sinais sintéticos fidedignos. Embora os métodos de alinhamento baseados em picos sejam amplamente empregados, sua eficácia é reduzida em cenários clínicos complexos, particularmente na presença de arritmias ou quando ocorrem variações significativas na morfologia do sinal cardíaco.

O terceiro desafio significativo relaciona-se à presença de artefatos de movimento, especialmente relevante no contexto de dispositivos vestíveis, que são tipicamente utilizados

em ambientes dinâmicos do cotidiano. Nestas condições, movimentos corporais do usuário frequentemente introduzem perturbações no sinal de PPG, exigindo que os modelos desenvolvidos possuam mecanismos sofisticados para identificar e compensar estes artefatos, garantindo assim a aplicabilidade prática das soluções em cenários reais de monitoramento contínuo.

3.2 Aprendizado Federado em Saúde

O aprendizado federado tem se mostrado uma abordagem promissora para o desenvolvimento de modelos de aprendizado de máquina em dados de saúde, preservando a privacidade dos pacientes. A Tabela 2 sumariza trabalhos relevantes neste contexto, destacando suas abordagens, métricas de avaliação e limitações.

Tabela 2 – Trabalhos relacionados ao aprendizado federado em saúde

Referência	Tipo de Tarefa	Dados Médicos	Arquitetura	Dispositivos Edge	Métricas de Comunicação	Métricas de Performance	Agregação	Limitações
(HWANG <i>et al.</i> , 2023)	Classificação binária e multiclasse	eICU, ISIC19, PhysioNet	Transformers, EfficientNet-B0, ResNet-NC-SE	Não	Número de rodadas, Consumo de energia, Tamanho dos parâmetros	AUROC, AUPRC, CinC score, Consumo de energia, Tempo de execução	FedAvg, FedProx, FedBN, FedDyn	Experimentos em máquina única; Testes limitados
(DAS <i>et al.</i> , 2024)	Análise de dados e detecção de anomalias	Dados vestíveis (ECG, pressão, glicose, etc.)	One-Class SVM, Autoencoders, Isolation Forest	Smartwatches, Sensores médicos	TLS, Criptografia homomórfica	RMSE, MAE, R ²	FedPer, FedMa, FedAvg	Problemas de escalabilidade; Interpretabilidade limitada
(MOON; LEE, 2023)	Segmentação de Imagens e Classificação	Imagens de raio-x, ultrassom, dados de sono	Não informado	Servidores edge, IoT, dispositivos móveis	Custo computacional, Uso de memória, Volume de dados	AUC, F1-Score, Dice, Precisão, Cohen's Kappa	FedAvg	Vulnerabilidade a ataques; Performance comparável a centralizado
Este trabalho	Regressão de sinais	ECG, PPG	BiLSTM	Simulação	Tempo de execução, Consumo de memória	RMSE, MSE, Pearson	FedAvg, FedKMeans	Requisito de clusterização adicional complexidade computacional

Fonte: Elaborado pelo autor.

Hwang *et al.* (2023) explorou o uso de FL para tarefas de classificação binária e multiclasse em *datasets* como eICU e PhysioNet. Foram testadas diversas arquiteturas, incluindo Transformers e ResNet, com agregação via FedAvg, FedProx e FedBN. O estudo destacou a importância de métricas de comunicação, como o número de rounds e o consumo de energia, mas foi limitado por experimentos em máquina única e testes restritos.

Já Das *et al.* (2024), focado em análise de dados e detecção de anomalias, este trabalho utilizou dados vestíveis (ECG, pressão, glicose) e arquiteturas como *One-Class* Máquina de Vetores de Suporte (*Support Vector Machine*) (SVM) e *Autoencoders*. A agregação foi realizada

com FedPer e FedMa, mas o estudo enfrentou desafios de escalabilidade e interpretabilidade limitada.

Por fim, Moon e Lee (2023) abordou a segmentação de imagens médicas e classificação, utilizando dados de raio-x e ultrassom. Apesar de alcançar performance comparável a métodos centralizados, o estudo destacou vulnerabilidades a ataques e a necessidade de otimizar métricas de comunicação, como custo computacional e uso de memória.

3.2.1 Tendências Observadas

O FedAvg continua sendo a estratégia de agregação mais utilizada na literatura, devido à sua simplicidade e eficácia em cenários homogêneos. No entanto, como evidenciado pelos trabalhos analisados, o FedAvg apresenta limitações em cenários heterogêneos, como dados médicos, onde a distribuição dos dados pode variar significativamente entre dispositivos. Trabalhos como Hwang *et al.* (2023), Moon e Lee (2023) exploraram variações do FedAvg, como FedProx e FedBN, para melhorar a estabilidade e a convergência do modelo. Ainda assim, a falta de abordagens mais sofisticadas, representa uma lacuna na literatura.

A eficiência da comunicação é um dos principais desafios no FL, especialmente em aplicações médicas onde dispositivos podem ter recursos limitados. Trabalhos como Moon e Lee (2023) destacaram a importância de métricas como o número de rounds, o custo computacional e o uso de memória. Essas métricas são críticas para garantir que o FL seja viável em cenários reais, onde dispositivos de borda podem ter restrições de energia e conectividade. Além disso, técnicas como criptografia homomórfica e *Transport Layer Security* (TLS) foram exploradas para garantir a segurança e a privacidade dos dados durante a comunicação.

3.2.2 Desafios

A implementação eficaz de soluções federadas no contexto de dados médicos enfrenta obstáculos significativos que demandam consideração cuidadosa. A heterogeneidade dos dados emerge como um desafio primordial neste cenário, uma vez que informações médicas são frequentemente caracterizadas por distribuições não-IID, resultando em modelos locais com desempenho consideravelmente variado entre diferentes instituições ou dispositivos.

Esta variabilidade intrínseca pode comprometer substancialmente o processo de convergência do modelo global, exigindo estratégias de agregação especialmente adaptadas para ambientes heterogêneos. Simultaneamente, questões relacionadas à segurança e privacidade

constituem preocupações fundamentais quando se trabalha com informações médicas sensíveis.

Embora a proteção dos dados dos pacientes represente uma prioridade inegociável, as técnicas avançadas de criptografia e anonimização necessárias para garantir esse nível de segurança frequentemente introduzem sobrecarga computacional significativa, aumentando os custos de processamento e os tempos de comunicação entre os nós da rede federada.

Este compromisso entre privacidade e eficiência operacional representa um equilíbrio delicado que deve ser cuidadosamente calibrado conforme as necessidades específicas de cada aplicação médica.

3.3 Diferencial deste Trabalho

O presente trabalho se diferencia ao propor uma intersecção entre estas áreas apresentadas, aplicando técnicas de aprendizado federado especificamente ao problema de geração de ECG sintético. Esta abordagem não foi encontrada na literatura atual, onde os trabalhos de geração de ECG são predominantemente centralizados, enquanto as aplicações de aprendizado federado em saúde focam principalmente em tarefas de classificação e detecção de anomalias.

Esta lacuna identificada na literatura reforça a relevância da proposta apresentada, que busca combinar os benefícios da geração de ECG sintético com as vantagens do aprendizado federado em termos de privacidade e distribuição dos dados. A abordagem proposta tem potencial para viabilizar o desenvolvimento de modelos mais robustos e representativos, aproveitando dados de múltiplas fontes sem comprometer a privacidade dos pacientes.

4 METODOLOGIA

4.1 Introdução

Neste capítulo, é descrita a metodologia utilizada para desenvolver e avaliar os métodos FedAvg e FedKMeans na geração de sinais de ECG sintéticos a partir de sinais de PPG, utilizando uma abordagem baseada em Aprendizado Federado. O objetivo principal é explorar técnicas de agregação que sejam eficientes em cenários distribuídos e heterogêneos, como é o caso de dispositivos vestíveis, onde a privacidade e a eficiência computacional são fundamentais. A metodologia foi dividida em etapas claras e interconectadas, que incluem:

1. **Seleção e pré-processamento dos dados:** Foi utilizada a base de dados MIMIC-II (GOLDBERGER *et al.*, 2000), que contém sinais de PPG e ECG de pacientes internados em unidades de terapia intensiva. Os dados foram pré-processados para remover ruídos, normalizados e alinhados para garantir consistência.
2. **Modelagem do problema:** A tarefa de conversão de PPG para ECG foi abordada como um problema de regressão sequencial, utilizando uma arquitetura de rede neural BiLSTM.
3. **Aprendizado Federado:** Foram implementadas duas estratégias de agregação: o FedAvg, que realiza uma agregação simples dos modelos locais, e o FedKMeans, que introduz uma etapa de *clustering* para agrupar modelos com características semelhantes antes da agregação.
4. **Avaliação dos resultados:** Foram utilizadas métricas como RMSE, MSE, Coeficiente de Pearson, tempo de execução e uso de memória para avaliar a qualidade e a eficiência computacional dos métodos.

A seguir, é detalhada cada uma dessas etapas, desde a preparação dos dados até a avaliação dos resultados.

4.2 Base de Dados

4.2.1 Descrição Geral

Neste estudo, utilizou-se a base de dados MIMIC-II (GOLDBERGER *et al.*, 2000). Desenvolvida por meio de uma colaboração entre o *Massachusetts Institute of Technology* (MIT) e diversas instituições médicas, o MIMIC-II é um dos maiores e mais abrangentes repositórios de dados clínicos e fisiológicos coletados em ambiente de terapia intensiva.

O MIMIC-II contém registros detalhados de cerca de 33000 pacientes internados em UTI, abrangendo uma ampla gama de parâmetros fisiológicos e variáveis clínicas. Além dos sinais fisiológicos, como ECG e PPG, a base inclui diagnósticos, prescrições medicamentosas, resultados laboratoriais e anotações clínicas, proporcionando um contexto abrangente para análises multifacetadas. Todos os dados são anonimizados, garantindo a privacidade dos pacientes.

4.2.2 Sobre os Sinais

Os sinais de PPG e ECG disponíveis no MIMIC-II são relevantes para estudos cardiovasculares e respiratórios. Ambos os sinais foram coletados com uma frequência de amostragem de 125 hertz (Hz) e uma resolução de 16 bits, garantindo precisão temporal e amplitude. Nesse conjunto de dados, o ECG é medido em milivolts (mV), com uma faixa de amplitude típica de 5 mV. Esse sinal é considerado o padrão-ouro para o diagnóstico de condições cardíacas. Ainda, o PPG é medido em unidades arbitrárias (ua), com uma banda de frequência de 0,5 Hz a 5 Hz. Esse sinal é amplamente utilizado em dispositivos vestíveis devido à sua facilidade de aquisição e baixo custo.

Na Figura 4, é possível observar alguns exemplos de sinais de PPG e ECG disponibilizados nesse conjunto de dados.

4.3 Pré-processamento dos Dados


O pré-processamento dos sinais de ECG e PPG é uma etapa crucial para garantir a qualidade dos dados e o bom desempenho dos modelos de aprendizado de máquina. Neste estudo, utilizou-se um fluxo de pré-processamento composto por etapas sequenciais, que incluem a limpeza dos sinais, a detecção de picos e o alinhamento temporal. A Figura 5 ilustra o fluxo completo do pré-processamento.

4.3.1 Fluxo de Pré-processamento

O fluxo de pré-processamento inicia-se com os sinais brutos de ECG e PPG, que são submetidos às seguintes etapas:

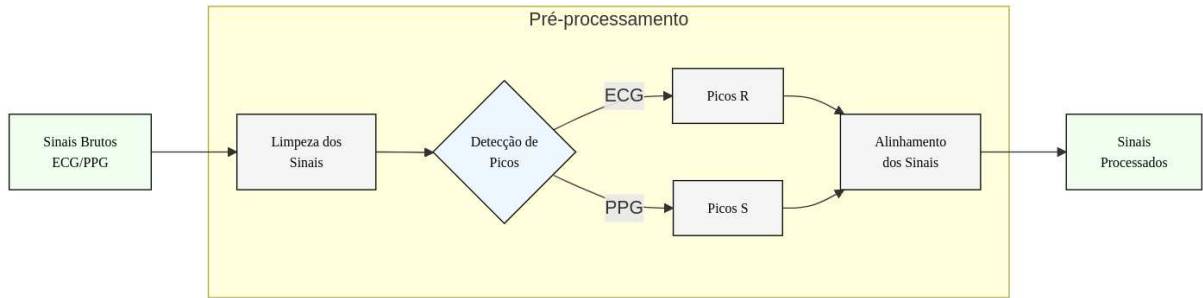
1. **Limpeza dos Sinais:** Nesta etapa, realizou-se a remoção de ruídos e artefatos presentes nos sinais brutos. Para isso, aplicou-se um filtro passa-baixa com frequência de corte de 40 Hz para o ECG e 5 Hz para o PPG, visando eliminar interferências de alta frequência.

Figura 4 – Exemplos de Dados do MIMIC-II (Paciente 0)



Fonte: Elaborado pelo autor.

Figura 5 – Fluxo de pré-processamento dos sinais de ECG e PPG



Fonte: Elaborado pelo autor.

Além disso, utilizou-se uma técnica de suavização para reduzir variações abruptas nos sinais.

2. **Detecção de Picos:** Após a limpeza, realizou-se a detecção dos picos característicos de cada sinal:

- Para o ECG, detectaram-se os picos R, que correspondem ao ponto mais alto do complexo QRS e representam a despolarização dos ventrículos.
- Para o PPG, detectaram-se os picos S, que correspondem ao ponto máximo de cada pulso arterial.

A detecção dos picos foi realizada utilizando algoritmos baseados em limiares adaptativos, que identificam os pontos de máximo local em cada sinal.

3. **Alinhamento dos Sinais:** Com os picos detectados, realizou-se o alinhamento temporal dos sinais de ECG e PPG. Essa etapa é essencial para garantir que os sinais estejam sincronizados. O alinhamento foi feito com base na correspondência temporal entre os picos R do ECG e os picos S do PPG.

4. **Sinais Processados:** Ao final do pré-processamento, obtiveram-se sinais de ECG e PPG limpos, com picos detectados e alinhados temporalmente. Esses sinais foram então separados em segmentos de 1 segundo e utilizados como entrada para os modelo de aprendizado de máquina.

4.3.2 Nota sobre as Ferramentas Utilizadas

Todos os algoritmos de pré-processamento, incluindo a filtragem, a detecção de picos e o alinhamento dos sinais, foram implementados utilizando a biblioteca NeuroKit2 (MAKOWSKI *et al.*, 2021). Essa biblioteca oferece uma ampla gama de ferramentas para o processamento de sinais fisiológicos, garantindo precisão e eficiência nas etapas de pré-

processamento.

4.4 Aprendizado de Máquina

Nesta seção, descreve-se a arquitetura de rede neural utilizada para essa tarefa. Optou-se por uma rede BiLSTM, que combina a capacidade de capturar dependências temporais de longo prazo com a flexibilidade de processar sequências bidirecionais. A escolha dessa arquitetura baseia-se em sua eficácia comprovada em tarefas de processamento de sinais temporais, conforme demonstrado em (GRAVES; SCHMIDHUBER, 2005).

4.4.1 BiLSTM

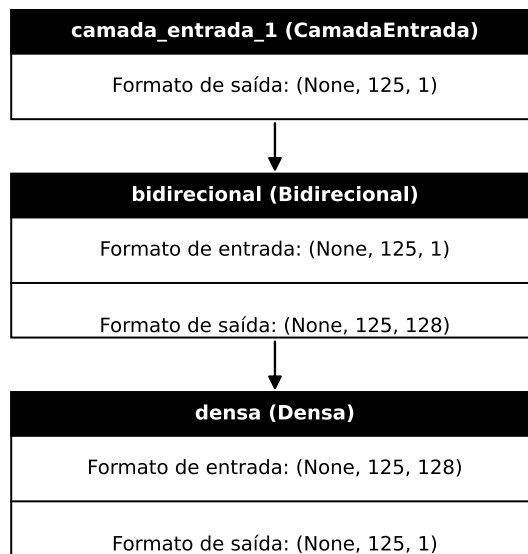
A arquitetura BiLSTM consiste em duas camadas LSTM que processam a sequência de entrada em ambas as direções (passado para futuro e futuro para passado). Essa abordagem permite que o modelo capture informações contextuais tanto do passado quanto do futuro, melhorando a precisão na geração de sinais temporais. A saída das duas camadas LSTM é combinada e passada para uma camada densa, que produz a saída final do modelo.

A Figura 6 detalha a arquitetura da rede BiLSTM implementada neste trabalho. A rede recebe como entrada sequências de PPG com dimensão 125, representando um segundo de sinal amostrado a 125 Hz. Estas sequências são processadas por uma camada BiLSTM contendo 128 neurônios, onde cada neurônio analisa a sequência temporal em ambas as direções (do início para o fim e do fim para o início). Esta análise bidirecional permite que a rede capture dependências temporais complexas e relações contextuais em ambos os sentidos da sequência, característica fundamental para a geração precisa de sinais cardíacos. A saída da camada BiLSTM é então conectada a uma camada densa com ativação linear, que produz a sequência de ECG sintético com 125 pontos, mantendo a correspondência temporal ponto a ponto com o sinal de entrada. Esta configuração foi escolhida para preservar a relação temporal entre os sinais de PPG e ECG, essencial para aplicações de monitoramento cardíaco.

4.4.2 Hiperparâmetros do Modelo

A configuração dos hiperparâmetros é uma etapa crucial para o desempenho do modelo. Neste estudo, os hiperparâmetros foram selecionados com base em experimentos preliminares e na literatura relacionada. A Tabela 3 resume os principais hiperparâmetros

Figura 6 – Arquitetura da rede BiLSTM implementada para a geração de sinais de ECG sintéticos a partir de PPG. A camada de entrada recebe sequências de PPG com 125 pontos (equivalente a 1 segundo de sinal a 125 Hz), que são processadas por 128 neurônios na camada bidirecional. Cada neurônio analisa a sequência temporal tanto na direção direta quanto reversa. A camada de saída gera a sequência de ECG sintético correspondente, também com 125 pontos, mantendo o alinhamento temporal com o sinal de entrada.



Fonte: Elaborado pelo autor.

utilizados no treinamento da rede BiLSTM.

Tabela 3 – Hiperparâmetros do modelo BiLSTM.

Hiperparâmetro	Valor
Tamanho do Lote	64
Taxa de Aprendizado	0,001
Número de Neurônios	128
Regularização L1	0,0001
Regularização L2	0,0001

Fonte: Elaborado pelo autor.

- **Tamanho do Lote:** Define o número de amostras processadas antes de atualizar os pesos do modelo. Um valor de 64 foi escolhido para equilibrar eficiência computacional e estabilidade no treinamento.
- **Taxa de Aprendizado:** Controla o tamanho dos passos durante a atualização dos pesos. Utilizou-se uma taxa de 0,001, que mostrou-se eficaz para a convergência do modelo.
- **Número de Neurônios:** Define a capacidade da camada BiLSTM. Um valor de 128 neurônios foi escolhido para capturar padrões complexos sem aumentar excessivamente o

custo computacional.

- **Regularização L1 e L2:** Adicionada para evitar *overfitting*, com valores de 0,0001 para ambos os termos. A combinação de L1 e L2 promove a esparsidade e penaliza pesos grandes, melhorando a generalização do modelo.

4.5 Aprendizado Federado

O Aprendizado Federado é uma abordagem distribuída que permite o treinamento de modelos de aprendizado de máquina sem a necessidade de centralizar os dados. Neste estudo, utilizou-se o Aprendizado Federado para treinar o a rede neural BiLSTM, preservando a privacidade dos dados dos pacientes. Duas estratégias de agregação foram exploradas: o FedAvg, que é a abordagem padrão, e o FedKMeans, proposto para superar os desafios da heterogeneidade dos dados.

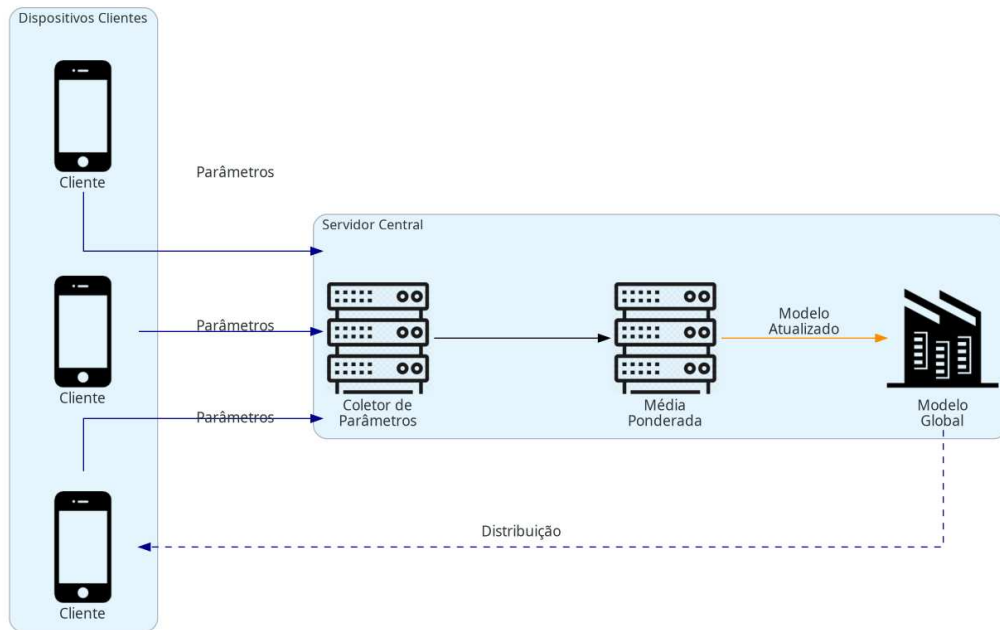
4.5.1 FedAvg

O FedAvg é a estratégia de agregação mais comum no Aprendizado Federado. Nessa abordagem, os modelos locais são treinados em cada cliente com seus respectivos dados, e os parâmetros dos modelos são agregados por meio de uma média ponderada. A agregação é realizada da seguinte forma:

1. Cada cliente treina seu modelo local com os dados disponíveis.
2. Os parâmetros dos modelos locais são enviados para o servidor.
3. O servidor calcula a média ponderada dos parâmetros, onde o peso de cada cliente é proporcional ao tamanho de seu conjunto de dados.
4. O modelo global atualizado é enviado de volta aos clientes para o próximo ciclo de treinamento.

A Figura 7 ilustra o fluxo de operação do algoritmo FedAvg, destacando o processo de média ponderada simples realizado no servidor central. Embora o FedAvg seja eficiente em cenários homogêneos, ele pode apresentar limitações em ambientes com alta heterogeneidade de dados, como é o caso de sinais fisiológicos de diferentes pacientes.

Figura 7 – Arquitetura do FedAvg

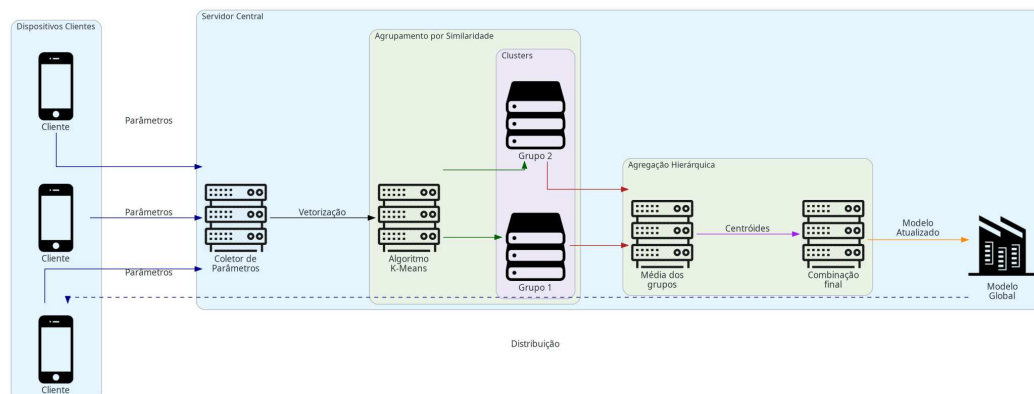


Fonte: Elaborado pelo autor.

4.5.2 FedKMeans

Para lidar com a heterogeneidade dos dados, propôs-se uma estratégia de agregação baseada em *clustering*, denominada FedKMeans. Essa abordagem agrupa os modelos locais com base na similaridade de seus parâmetros antes de realizar a agregação, permitindo uma adaptação mais eficiente às características individuais dos clientes.

Figura 8 – Arquitetura do algoritmo FedKMeans



Fonte: Elaborado pelo autor.

Como ilustrado na Figura 8, o FedKMeans introduz uma etapa de clusterização entre a coleta de parâmetros e a agregação final. Após receber os parâmetros dos clientes, o servidor realiza um agrupamento utilizando o algoritmo *K-Means*, identificando modelos com

características similares. A agregação ocorre então de forma hierárquica: primeiro dentro de cada *cluster* e depois entre os *clusters* para formar o modelo global.

4.5.2.1 Etapas

O FedKMeans consiste nas seguintes etapas:

1. **Treinamento Local:** Cada cliente treina seu modelo local com os dados disponíveis.
2. **Coleta de Parâmetros:** Os parâmetros dos modelos locais são enviados para o servidor.
3. **Clusterização:** Utiliza-se o algoritmo *K-Means* para agrupar os modelos locais em clusters com base na similaridade de seus parâmetros. O número de *clusters* é um hiperparâmetro definido durante a inicialização do servidor de agregação.
4. **Agregação por Cluster:** Dentro de cada cluster, os parâmetros dos modelos são agregados por meio de uma média ponderada.
5. **Atualização Global:** O servidor combina os modelos agregados de cada cluster para formar o modelo global atualizado.
6. **Distribuição:** O modelo global é enviado de volta aos clientes para o próximo ciclo de treinamento.

O FedKMeans supera as limitações do FedAvg em cenários heterogêneos, permitindo que modelos com características semelhantes sejam agregados de forma mais eficiente. Essa abordagem resulta em uma melhor adaptação às particularidades dos dados de cada cliente, melhorando a precisão e a convergência do modelo global.

4.6 Métricas de Avaliação

Para avaliar o desempenho do método proposto, foram definidas duas categorias de métricas: métricas de qualidade do sinal e métricas de desempenho computacional. Esta divisão permite uma análise abrangente tanto da qualidade dos ECGs sintéticos gerados quanto da eficiência do sistema em termos de recursos computacionais.

4.6.1 Métricas de Qualidade do Sinal

Para avaliar a qualidade dos sinais de ECG sintéticos gerados, foram utilizadas três métricas principais:

O MSE é calculado como a média aritmética dos quadrados das diferenças entre os

valores previstos e os valores reais, sendo definido pela equação:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.1)$$

onde n é o número de amostras, y_i é o valor real e \hat{y}_i é o valor previsto.

O RMSE é obtida através da raiz quadrada do MSE, fornecendo uma medida de erro na mesma unidade dos dados originais:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.2)$$

O coeficiente de correlação de Pearson (r) mede o grau de correlação linear entre os sinais real e sintético, sendo calculado como:

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4.3)$$

onde \bar{x} e \bar{y} são as médias dos valores reais e previstos, respectivamente.

4.6.2 Métricas de Desempenho Computacional

Para avaliar o desempenho computacional do sistema, foram consideradas duas métricas principais:

O tempo de execução é medido em segundos e considera:

- Tempo de treinamento do modelo
- Tempo de comunicação entre os clientes no processo federado
- Tempo de inferência para geração dos ECGs sintéticos

O consumo de memória é medido em megabytes (MB) e avalia:

- Utilização de memória RAM no servidor durante o treinamento
- Memória adicional necessária durante o processo de agregação federada

Todas as métricas foram coletadas utilizando um ambiente computacional padronizado, com hardware e software consistentes para garantir a reprodutibilidade dos resultados.

4.7 Experimentos

Nesta seção, são descritos os experimentos realizados para avaliar o desempenho do modelo proposto. Os experimentos foram projetados para comparar quatro cenários de

treinamento: centralizado (acesso a todos os dados), local individual (cada cliente treina apenas com seus dados), federado com FedAvg e federado com FedKMeans. A seguir, detalham-se a configuração e a execução dos experimentos.

4.7.1 Cenários de Experimentação

Os experimentos foram organizados em quatro cenários distintos para permitir uma avaliação abrangente da abordagem proposta. No primeiro cenário, denominado Treinamento Centralizado, todos os dados foram disponibilizados em um único local, representando a situação ideal onde não existem restrições de privacidade. Este cenário serviu como referência de desempenho máximo, com o modelo sendo treinado por 150 épocas com acesso ao conjunto completo de dados.

O segundo cenário, Treinamento Local Individual, representou o extremo oposto, onde cada cliente treinou seu próprio modelo utilizando exclusivamente seus dados locais, sem qualquer colaboração entre os participantes. Neste caso, cada modelo local foi treinado por 150 épocas, permitindo avaliar o impacto da ausência de colaboração na qualidade dos resultados.

No terceiro cenário, implementou-se o Treinamento Federado com FedAvg, utilizando o algoritmo padrão proposto por McMahan et al. (2017). O treinamento consistiu em 150 rodadas federadas, com cada cliente realizando 1 época de treinamento local por rodada antes da agregação dos modelos pelo servidor central.

Por fim, no quarto cenário, foi implementado o Treinamento Federado com FedKMeans, algoritmo proposto neste trabalho. Similar ao cenário anterior, o treinamento também consistiu em 150 rodadas federadas com 1 época de treinamento local por rodada. A principal diferença está na estratégia de agregação, que utilizou o algoritmo K-means para agrupar os modelos locais em 3 clusters, com base na similaridade entre os aproximadamente 177 mil parâmetros da rede BiLSTM. É importante destacar que não foi aplicada nenhuma técnica de redução de dimensionalidade antes da clusterização, o que pode limitar a escalabilidade dessa implementação do FedKMeans para cenários com número significativamente maior de clientes. No entanto, para o contexto deste estudo com 10 clientes, espera-se que isso não represente um problema significativo de desempenho. O número de *clusters* foi definido por meio de uma heurística, fundamentada na premissa de que os clientes podem ser naturalmente agrupados em três perfis principais de acordo com as características dos sinais de seus pacientes.

4.7.2 *Configuração dos Experimentos*

Para garantir uma comparação justa e metodologicamente rigorosa entre os cenários experimentais, foram mantidas diversas configurações constantes ao longo de todos os experimentos.

A estratégia de particionamento dos dados seguiu proporções idênticas em todos os casos, com 70% destinados ao conjunto de treinamento, 15% para validação e 15% para testes, assegurando assim consistência na avaliação do desempenho dos modelos.

Quanto à dimensão da amostra, foram selecionados os 10 primeiros pacientes do conjunto de dados, uma escolha deliberada para observar e analisar o comportamento do aprendizado federado mesmo em contextos com número reduzido de clientes, simulando cenários reais onde poucos dispositivos ou instituições participam da federação.

A arquitetura neural empregada permaneceu constante em todos os experimentos, utilizando-se o modelo BiLSTM com configuração idêntica, eliminando assim possíveis variações de desempenho decorrentes de diferenças estruturais.

Os hiperparâmetros de treinamento, incluindo configurações de otimização e taxa de aprendizado, foram padronizados conforme detalhado na Tabela 3, garantindo que as diferenças observadas nos resultados não fossem influenciadas por variações nestes parâmetros.

Por fim, todos os experimentos foram executados no mesmo ambiente computacional, minimizando potenciais discrepâncias de desempenho relacionadas a diferenças de hardware ou software durante os processos de treinamento e avaliação.

4.7.3 *Protocolo de Avaliação*

Para cada cenário federado, foram coletadas métricas de qualidade e desempenho a cada 10 rodadas de treinamento, permitindo uma análise comparativa da evolução do aprendizado e do consumo de recursos computacionais.

4.8 **Implementação e Ferramentas**

O desenvolvimento e implementação do método proposto foram realizados utilizando a linguagem de programação Python¹ em sua versão 3.11, escolhida por sua ampla adoção na comunidade científica e vasto ecossistema de bibliotecas para aprendizado de máquina.

¹ <https://www.python.org/>

Para a implementação das redes neurais e do aprendizado profundo, foi utilizado o *framework* TensorFlow², que oferece uma Interface de Programação de Aplicação (*Application Programming Interface*) (API) de alto nível para construção e treinamento de modelos

Para a implementação do ambiente de aprendizado federado, foi utilizado o *framework* Flower³ em modo simulação. O Flower oferece uma abstração robusta para o desenvolvimento de sistemas federados, permitindo a simulação de múltiplos clientes em um único ambiente computacional, facilitando assim o processo de desenvolvimento e avaliação do método proposto.

O algoritmo de K-means foi implementado utilizando a biblioteca scikit-learn⁴, que é amplamente reconhecida por sua implementação eficiente e bem documentada de algoritmos de aprendizado de máquina. A escolha desta biblioteca se justifica pela sua maturidade e confiabilidade na comunidade científica.

Para o pré-processamento dos sinais de ECG e PPG, foi utilizada a biblioteca Neurokit2⁵, que oferece um conjunto abrangente de ferramentas específicas para o processamento de sinais fisiológicos. Esta biblioteca foi fundamental para garantir a qualidade e padronização dos sinais utilizados no estudo.

A visualização dos resultados foi realizada através da biblioteca Matplotlib⁶, que permitiu a geração de gráficos e figuras para análise e apresentação dos resultados obtidos.

Todo o desenvolvimento e experimentos foram conduzidos em um ambiente computacional em nuvem com as seguintes especificações:

- Processador: 12 Cores
- Memória RAM: 40 gigabytes (GB)
- GPU: NVIDIA GeForce RTX 3090

O código-fonte completo da implementação está disponível em um repositório público⁷, garantindo a reprodutibilidade dos experimentos e resultados apresentados neste trabalho.

² <https://www.tensorflow.org/>

³ <https://flower.dev/>

⁴ <https://scikit-learn.org/>

⁵ <https://neuropsychology.github.io/NeuroKit/>

⁶ <https://matplotlib.org/>

⁷ Link do repositório: <https://github.com/matheus3301/tcc>

5 RESULTADOS

5.1 Introdução

Nesta seção são apresentados os resultados dos experimentos realizados para avaliar a eficácia de diferentes técnicas de agregação no contexto do Aprendizado Federado aplicado à geração de sinais de ECG sintético a partir de PPG. Inicialmente, foram estabelecidos dois cenários base: o treinamento centralizado e o treinamento local individual, que servem como referência para comparar o desempenho das abordagens federadas. Em seguida, foram comparadas duas estratégias de agregação: o método tradicional FedAvg e a proposta FedKMeans, que utiliza clusterização para lidar com a heterogeneidade dos dados. Os experimentos foram conduzidos na base MIMIC-II, utilizando um subconjunto de 10 pacientes e um modelo BiLSTM treinado de forma federada.

Para garantir a robustez e confiabilidade das análises apresentadas neste capítulo, todos os experimentos foram executados considerando os 10 clientes participantes do ambiente federado. As métricas de avaliação (RMSE, MSE e Coeficiente de Pearson) foram calculadas individualmente para cada cliente utilizando seus respectivos conjuntos de teste locais, e os valores reportados representam a média aritmética dessas métricas entre os 10 clientes, acompanhados do desvio padrão correspondente.

Esta abordagem de avaliação distribuída é particularmente relevante no contexto do aprendizado federado, pois permite mensurar o desempenho do modelo global quando aplicado às particularidades dos dados de cada cliente. O desvio padrão entre os resultados dos diferentes clientes fornece uma medida importante da equidade do sistema, indicando se o modelo favorece certos clientes em detrimento de outros ou se oferece benefícios consistentes para todos os participantes.

Para acompanhar a evolução do treinamento, as métricas foram coletadas a cada 10 rodadas de treinamento federado, permitindo analisar a convergência dos modelos ao longo do tempo. Em cada ponto de avaliação, o modelo global atual foi enviado para todos os clientes, e cada um calculou as métricas usando seus dados de teste locais. Para os cenários de referência (centralizado e local individual), as métricas foram calculadas seguindo a mesma metodologia, ao final do treinamento completo.

Esta metodologia de consolidação garante uma avaliação justa e abrangente das diferentes abordagens, considerando as particularidades de cada cliente e fornecendo uma visão

holística do desempenho do sistema federado como um todo.

5.2 Análise dos Cenários Base

Para estabelecer parâmetros de comparação, foram inicialmente avaliados dois cenários base: o treinamento centralizado (com acesso a todos os dados) e o treinamento local individual (onde cada cliente treina apenas com seus próprios dados). Esses cenários servem como referência para entender o impacto do Aprendizado Federado na qualidade do modelo e na heterogeneidade dos dados.

Tabela 4 – Comparativo de performance com dados de teste dos cenários base

Cenário	RMSE	MSE	Pearson
Centralizado	0,216	0,049	0,639
Treinamento Local Individual			
Média dos Clientes	0,199	0,044	0,752
Melhor Cliente	0,137	0,019	0,851
Pior Cliente	0,352	0,125	0,573

Fonte: Elaborado pelo autor.

A Tabela 4 apresenta os resultados dos cenários base em termos de RMSE, MSE e Coeficiente de Pearson no conjunto de teste. A análise desses resultados fornece evidências empíricas da natureza não-IID dos dados:

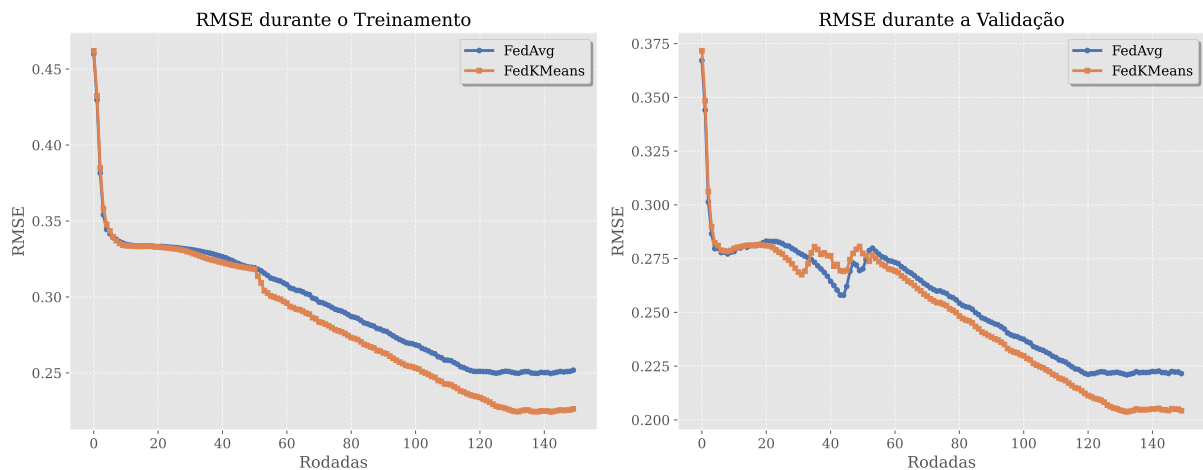
- **Treinamento Centralizado:** O modelo centralizado alcançou um RMSE de 0,216 e um Coeficiente de Pearson de 0,639. Embora teoricamente este cenário devesse apresentar o melhor desempenho por ter acesso a todos os dados durante o treinamento, os resultados inferiores ao treinamento local individual evidenciam a forte heterogeneidade na distribuição dos dados entre os clientes. Esta discrepância sugere que as características específicas de cada paciente são suficientemente distintas para prejudicar a capacidade do modelo centralizado de generalizar efetivamente para todos os casos.
- **Treinamento Local Individual:** No treinamento local, cada cliente treinou um modelo independente com seus próprios dados. A média dos clientes resultou em um RMSE de 0,199 e um Coeficiente de Pearson de 0,752, superando o modelo centralizado. Este resultado reforça a natureza não-IID dos dados, pois demonstra que modelos especializados em subconjuntos específicos dos dados alcançam melhor desempenho que um modelo único treinado com todos os dados. A significativa variabilidade entre os clientes (melhor caso: RMSE de 0,137 e Pearson de 0,851; pior caso: RMSE de 0,352 e Pearson de 0,573)

quantifica o grau de heterogeneidade dos dados, evidenciando a necessidade de estratégias que possam lidar efetivamente com distribuições não-IID.

5.3 Desempenho do Modelo

5.3.1 Índices de Erro ao Longo das Rodadas

Figura 9 – Comparativo do RMSE durante o treinamento e validação



Fonte: Elaborado pelo autor.

A Figura 9 mostra a evolução do RMSE ao longo das rodadas de treinamento para os métodos FedAvg e FedKMeans. Nota-se que o FedKMeans alcançou valores de erro consistentemente menores a partir da rodada 45, atingindo um RMSE final de 0,226 durante o treinamento, em comparação com 0,251 do FedAvg. Essa superioridade se mantém na fase de validação, onde o FedKMeans obteve um RMSE de 0,204, enquanto o FedAvg registrou 0,221. A melhoria observada pode ser atribuída à estratégia de agregação baseada em *clusters* do FedKMeans, que agrupa modelos com características semelhantes, reduzindo assim os efeitos da heterogeneidade dos dados e resultando em uma geração mais coerente de ECG sintético.

5.3.2 Coeficientes de Pearson

O coeficiente de Pearson foi utilizado para avaliar a qualidade do ECG sintético gerado através do Aprendizado Federado pelos métodos FedAvg e FedKMeans, medindo a correlação entre os sinais preditos e os sinais esperados. Valores próximos de 1 indicam uma alta correlação e, portanto, uma maior fidelidade na geração do ECG sintético.

A Tabela 5 apresenta uma análise estatística dos coeficientes de Pearson obtidos

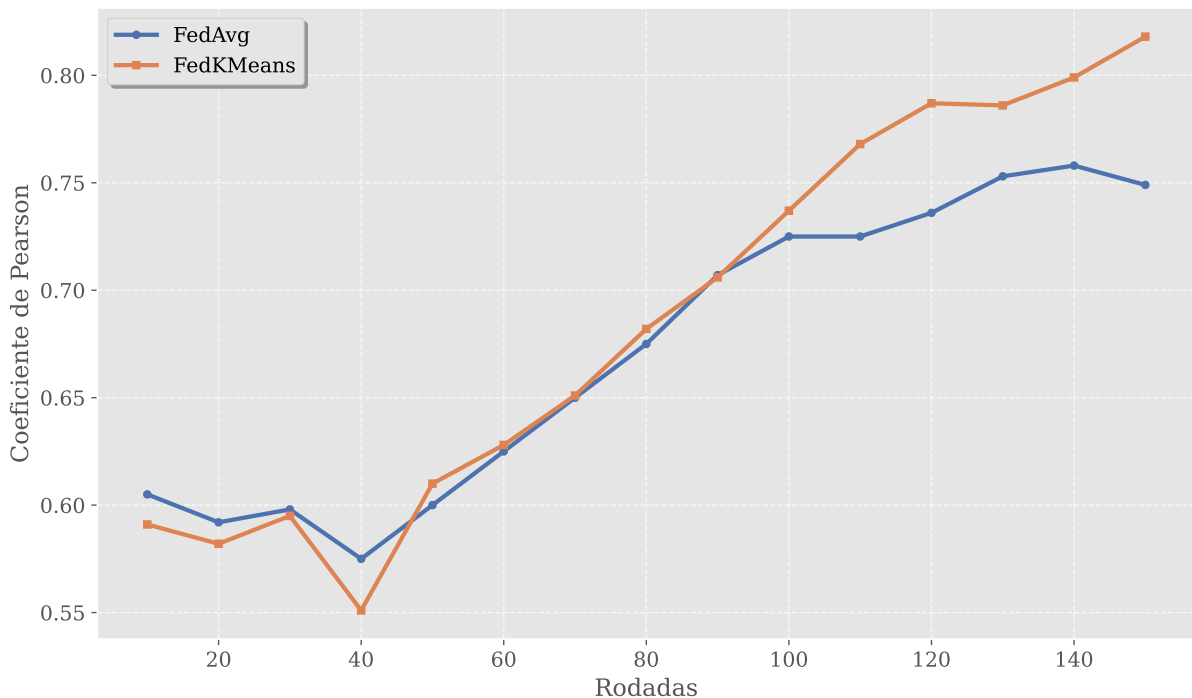
Tabela 5 – Comparativo dos coeficientes de Pearson entre FedAvg e FedKMeans após o treinamento

Algoritmo	Média	Desvio Padrão	Mediana	Máximo	Mínimo
FedAvg	0,72	0,08	0,76	0,83	0,38
FedKMeans	0,81	0,06	0,83	0,87	0,61

Fonte: Elaborado pelo autor.

para ambos os métodos após o treinamento completo. O método proposto FedKMeans alcançou um coeficiente médio de 0,81 (Desvio Padrão (DP) = 0,06), enquanto o FedAvg obteve média de 0,72 (DP = 0,08). A mediana do FedKMeans atingiu 0,83, superior à mediana de 0,76 do FedAvg, evidenciando uma distribuição mais favorável dos coeficientes. O FedKMeans também demonstrou maior robustez, com valores mínimo e máximo de 0,61 e 0,87, respectivamente, em contraste com o intervalo mais amplo do FedAvg (0,38 a 0,83), indicando maior consistência na qualidade da geração.

Figura 10 – Coeficientes de Pearson ao decorrer do processo de treinamento



Fonte: Elaborado pelo autor.

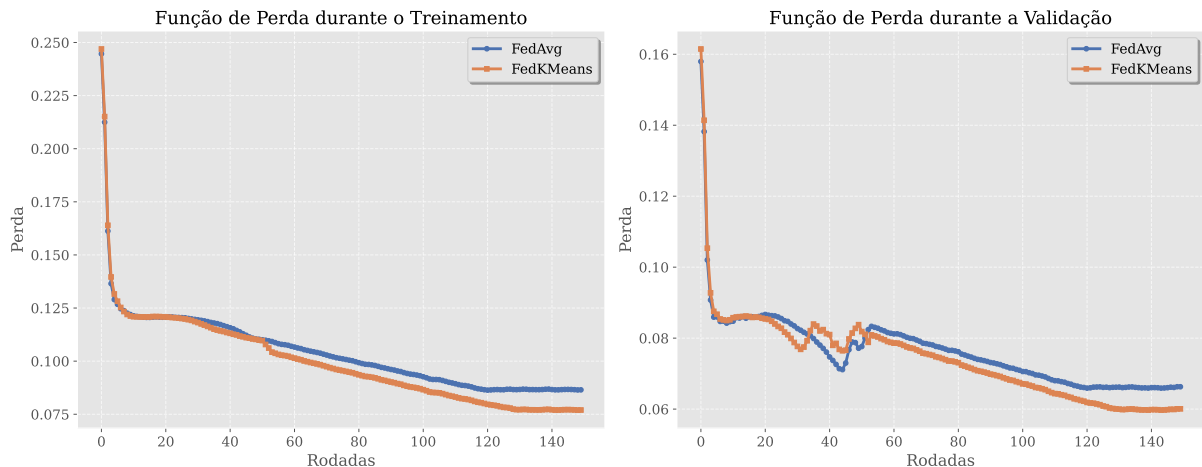
A Figura 10 revela a dinâmica temporal dos coeficientes de Pearson durante o processo de treinamento. O FedKMeans apresenta uma fase inicial de adaptação nas primeiras 40 rodadas, com coeficientes marginalmente inferiores ao FedAvg. Entre as rodadas 40 e 100, observa-se uma convergência entre os métodos. A partir da rodada 100, o FedKMeans demonstra superioridade progressiva, com coeficientes aumentando consistentemente até aproximadamente

0,81 nas rodadas finais, enquanto o FedAvg estabiliza em torno de 0,72.

Os resultados demonstram que, embora o FedKMeans demande um período inicial de adaptação, ele supera o FedAvg em termos de qualidade dos sintéticos gerados, especialmente nas rodadas finais. A maior consistência e os valores mais altos dos coeficientes de Pearson reforçam a eficácia da estratégia de agregação baseada em *clusters*, que se adapta melhor à heterogeneidade dos dados e resulta em uma geração mais precisa do ECG sintético. Esses achados corroboram os resultados observados nas seções anteriores, onde o FedKMeans também se destacou em métricas como RMSE e MSE.

5.3.3 Análise de Convergência

Figura 11 – Comparativo do MSE durante o treinamento e validação



Fonte: Elaborado pelo autor.

A Figura 11 apresenta a evolução da função de perda (MSE) ao longo das rodadas de treinamento para os métodos FedAvg e FedKMeans. Observa-se que o FedAvg estabiliza seu valor de perda mais cedo, convergindo por volta da rodada 120. No entanto, o FedKMeans, embora demore algumas rodadas adicionais para estabilizar, converge para um valor de MSE significativamente menor (0,076 contra 0,086 do FedAvg). Esse comportamento sugere que, embora o FedKMeans demande um tempo ligeiramente maior para estabilizar. Tal diferença pode ser atribuída à capacidade do FedKMeans de agrupar modelos com características semelhantes, reduzindo o impacto da heterogeneidade dos dados e refinando os parâmetros do modelo de forma mais eficiente.

5.3.4 Comparativo entre as Estratégias Federadas

Após a análise da evolução dos erros e da convergência dos modelos, é importante estabelecer uma comparação direta entre as estratégias federadas propostas. A Tabela 6 apresenta um comparativo detalhado das métricas de desempenho entre os métodos FedAvg e FedKMeans.

Tabela 6 – Comparativo de performance com dados de teste entre FedAvg e FedKMeans

Método	RMSE	MSE	Pearson
FedAvg	0,221 ± 0,015	0,049 ± 0,007	0,721 ± 0,082
FedKMeans	0,204 ± 0,011	0,042 ± 0,005	0,813 ± 0,063

Fonte: Elaborado pelo autor.

Os resultados apresentados na Tabela 6 demonstram a superioridade consistente do método FedKMeans em todas as métricas avaliadas. O FedKMeans alcançou um RMSE de 0,204, representando uma redução de 7,7% em relação ao FedAvg (0,221). De forma similar, o MSE apresentou uma melhoria ainda mais significativa de 14,3%, diminuindo de 0,049 no FedAvg para 0,042 no FedKMeans.

A correlação entre os sinais gerados e os sinais reais, medida pelo coeficiente de Pearson, também foi substancialmente superior no FedKMeans (0,813) quando comparada ao FedAvg (0,721), representando uma melhoria de 12,8%. Este resultado é particularmente relevante, pois indica que o FedKMeans não apenas reduz o erro absoluto, mas também preserva melhor as características morfológicas dos sinais de ECG, aspecto crucial para aplicações diagnósticas.


Além dos valores médios, é importante observar que o FedKMeans apresentou menor desvio padrão em todas as métricas, indicando maior consistência nos resultados entre diferentes clientes. Esta característica é especialmente valiosa em cenários federados heterogêneos, onde a variabilidade de desempenho entre clientes pode comprometer a utilidade prática do sistema.

Esses resultados corroboram a hipótese inicial de que a estratégia de agregação baseada em clusterização pode melhorar significativamente o desempenho do aprendizado federado em cenários com alta heterogeneidade de dados, como é o caso dos sinais biomédicos de diferentes pacientes.

5.4 Análise Visual dos Sinais Gerados

Para complementar a análise quantitativa apresentada anteriormente, esta seção oferece uma comparação visual dos sinais de ECG gerados pelos métodos FedAvg e FedKMeans. As Figuras 12 e 13 mostram exemplos representativos de sinais de ECG sintéticos produzidos por cada abordagem, comparados com o sinal ECG real correspondente.

Figura 12 – Exemplo de ECG gerado pelo método FedAvg (em vermelho) comparado com o ECG real (em azul)



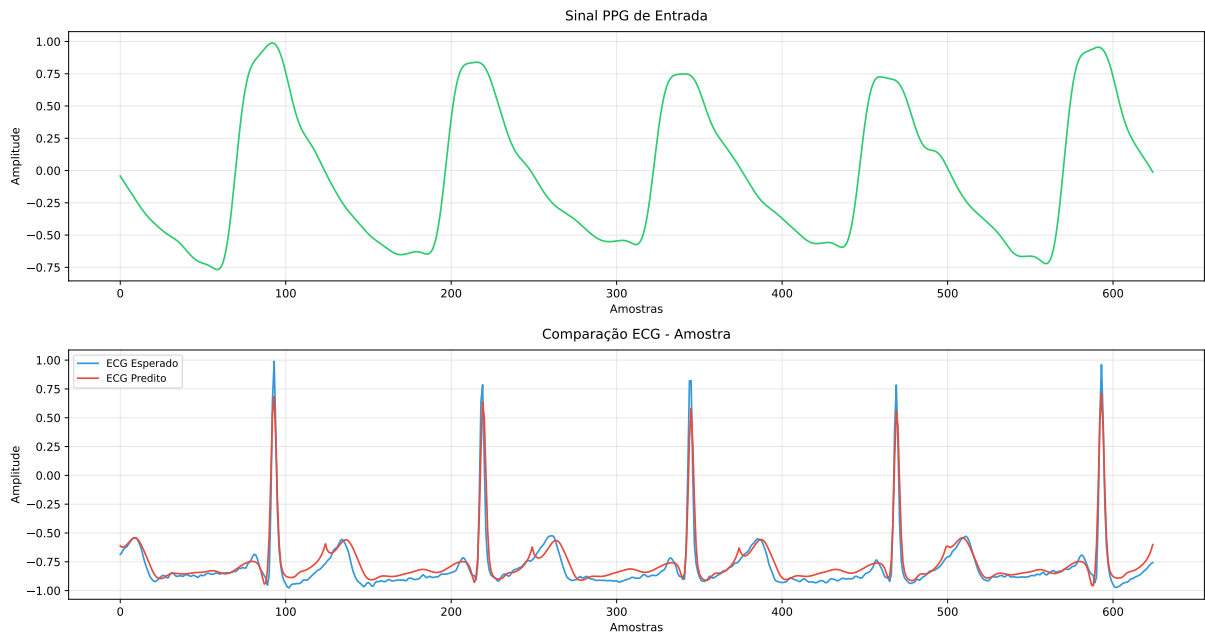
Fonte: Elaborado pelo autor.

A análise visual corrobora os resultados quantitativos apresentados anteriormente. Observa-se que o sinal gerado pelo FedKMeans (Figura 13) apresenta contornos mais suaves e maior fidelidade ao sinal original, principalmente nas transições entre as ondas P, Q, R, S e T. O complexo QRS, em particular, é reproduzido com maior precisão pelo FedKMeans, tanto em amplitude quanto em forma.

Em contraste, o sinal gerado pelo FedAvg (Figura 12) exibe algumas oscilações de alta frequência e transições mais abruptas entre os segmentos. Nota-se também uma leve defasagem temporal em alguns picos, bem como diferenças na amplitude de alguns componentes do sinal.

A maior suavidade do sinal gerado pelo FedKMeans pode ser atribuída à sua capacidade de agrupar modelos locais com características similares, permitindo uma melhor modelagem das nuances do sinal de ECG. Essa característica é particularmente importante em aplicações

Figura 13 – Exemplo de ECG gerado pelo método FedKMeans (em vermelho) comparado com o ECG real (em azul)



Fonte: Elaborado pelo autor.

clínicas, onde pequenas variações na morfologia do sinal podem ter significados diagnósticos relevantes.

Essa análise visual confirma que o FedKMeans não apenas supera o FedAvg em métricas quantitativas como RMSE, MSE e coeficiente de Pearson, mas também produz sinais visualmente mais fidedignos, o que é crucial para aplicações práticas de monitoramento cardíaco em dispositivos vestíveis.

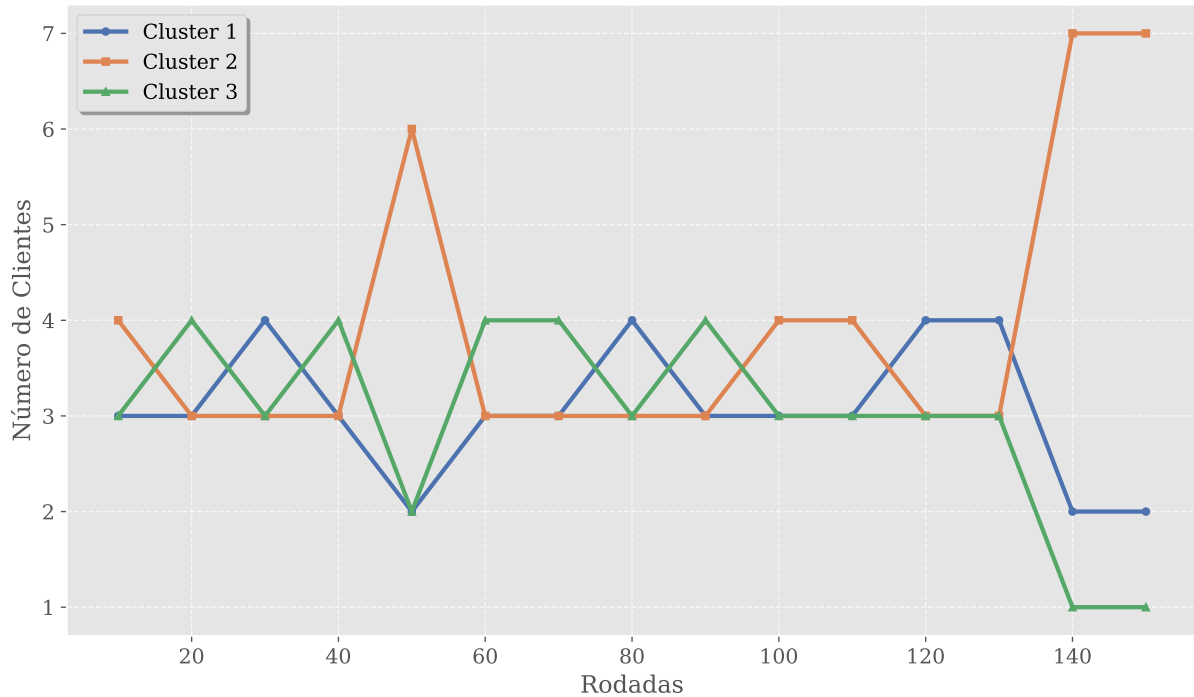
5.5 Análise dos *Clusters*

A Figura 14 ilustra a distribuição dos clientes entre os três *clusters* ao longo das rodadas de treinamento do FedKMeans. A evolução desta distribuição revela comportamentos interessantes que ajudam a compreender a dinâmica do algoritmo proposto.

Inicialmente, observa-se uma flutuação na alocação dos clientes, com os *clusters* competindo por representatividade. Esta fase inicial de instabilidade reflete o período de adaptação do modelo, onde os parâmetros da rede neural ainda estão se ajustando e as características distintas dos clientes não estão completamente estabelecidas.

Um primeiro momento crucial ocorre na rodada 50, quando o *Cluster 2* dispara, atingindo um pico de 6 clientes (60% do total). Este salto coincide com uma fase de rápida redução do MSE (como visto na Figura 11), sugerindo que esta reorganização dos clusters

Figura 14 – Distribuição de Clientes por *Cluster* a cada 10 Rodadas



Fonte: Elaborado pelo autor.

contribuiu significativamente para a melhoria do desempenho do modelo. Esta concentração inicial pode ser interpretada como uma primeira identificação de características comuns entre a maioria dos clientes.

Particularmente notável é o segundo momento crítico que ocorre aproximadamente na rodada 135, quando se observa outra reorganização significativa: o *Cluster 2* consolida sua dominância, passando a abranger 7 clientes (70% do total). Este salto tardio é especialmente relevante pois ocorre em uma fase avançada do treinamento, quando o modelo já alcançou considerável estabilidade. Esta mudança coincide com a fase final de refinamento do modelo, como evidenciado pela estabilização das curvas de RMSE e MSE nas Figuras 9 e 11. A consolidação do *Cluster 2* neste estágio sugere que o algoritmo FedKMeans foi capaz de identificar padrões fundamentais compartilhados pela maioria dos clientes, mesmo após extenso treinamento, permitindo uma agregação mais eficiente nos estágios finais.

É importante observar que, mesmo após ambos os saltos (rodadas 50 e 135), os *Clusters 1 e 3* não desaparecem completamente, mantendo representação de alguns clientes. Isto indica que, apesar da convergência para um padrão dominante, o FedKMeans preserva a capacidade de reconhecer e manter subgrupos distintos que representam características minoritárias mas potencialmente importantes nos dados.

Esses padrões de agrupamento evidenciam fenômenos significativos que caracteri-

zam o comportamento do algoritmo proposto. A concentração progressiva no *Cluster 2* revela uma convergência natural para padrões dominantes, indicando que a maioria dos clientes compartilha características fundamentais nos parâmetros de seus modelos locais, as quais foram eficientemente identificadas e agrupadas pelo FedKMeans durante o processo de federação.

Esta tendência de agrupamento é complementada pela notável resiliência do algoritmo frente à heterogeneidade dos dados, manifestada através das flutuações iniciais que refletem o período de adaptação à diversidade inerente das informações processadas, seguida por uma estabilização que demonstra sua capacidade de identificar e consolidar grupos com características verdadeiramente coerentes.

O processo de refinamento se revela contínuo ao longo do treinamento, como evidenciado pelo salto observado na rodada 135, demonstrando que mesmo em estágios avançados do processo iterativo, o mecanismo de clusterização continua aprimorando os agrupamentos, contribuindo assim para melhorias incrementais no desempenho global do sistema.

A eficácia desta estratégia de agregação é corroborada pela observação de que o *Cluster 2*, ao representar uma parcela majoritária dos clientes, assume naturalmente o papel de componente principal na ponderação da agregação global, fator que explica substancialmente a superioridade do FedKMeans em métricas quantitativas cruciais como RMSE e MSE, validando assim a abordagem proposta em termos de resultados mensuráveis.

A capacidade do FedKMeans de adaptar dinamicamente seus *clusters* ao longo do treinamento, com reorganizações significativas tanto em estágios iniciais (rodada 50) quanto avançados (rodada 135), demonstra sua flexibilidade e eficácia na identificação de padrões em ambientes heterogêneos, contribuindo para os resultados superiores observados nas seções anteriores.

5.6 Eficiência Computacional

Nesta seção, é avaliada a eficiência computacional dos métodos FedAvg e FedKMeans em termos de uso de memória e tempo de execução por rodada. A Tabela 7 resume o consumo de memória para ambos os métodos. Já a Tabela 8 mostra o desempenho de tempo para cada uma das abordagens.

Tabela 7 – Comparativo do uso de memória entre FedAvg e FedKMeans

Algoritmo	Média (MB)	Desvio Padrão (MB)	Mediana (MB)	Máximo (MB)	Mínimo (MB)
FedAvg	1884,92	19,88	1890,37	1902,94	1809,37
FedKMeans	1906,19	3,85	1907,19	1911,38	1894,9

Fonte: Elaborado pelo autor.

5.6.1 *Uso de Memória*

A Tabela 7 apresenta o consumo de memória dos métodos FedAvg e FedKMeans ao longo das rodadas de treinamento. O FedAvg demonstrou um uso médio de memória de 1884,92 MB, valor ligeiramente inferior ao do FedKMeans, que registrou uma média de 1906,19 MB. No entanto, o FedKMeans apresentou um desvio padrão significativamente menor (3,85 MB) em comparação ao FedAvg (19,88 MB), indicando uma maior consistência no consumo de memória ao longo das rodadas.

Essa diferença pode ser atribuída à utilização do algoritmo de clusterização no FedKMeans, que demanda um maior uso de memória. Apesar do aumento médio de 21,27 MB no uso de memória, o FedKMeans mantém-se viável para aplicações práticas, especialmente considerando sua maior estabilidade e os ganhos em precisão observados nas seções anteriores.

5.6.2 *Tempo de Treinamento*

Tabela 8 – Comparativo do tempo de execução de uma rodada de treinamento entre FedAvg e FedKMeans

Algoritmo	Média (s)	Desvio Padrão (s)	Mediana (s)	Máximo (s)	Mínimo (s)
FedAvg	65,12	10,32	66,33	76,15	50,00
FedKMeans	71,42	11,01	69,41	85,82	54,12

Fonte: Elaborado pelo autor.

A Tabela 8 compara o tempo de execução por rodada de treinamento entre os métodos FedAvg e FedKMeans. O FedAvg apresentou um tempo médio de 65,12 segundos por rodada, com um desvio padrão de 10,32 segundos, enquanto o FedKMeans registrou um tempo médio de 71,42 segundos e um desvio padrão de 11,01 segundos. A mediana do tempo de execução também foi menor para o FedAvg (66,33 segundos) em comparação ao FedKMeans (69,41 segundos).

O aumento médio de 6,30 segundos por rodada no FedKMeans também pode ser explicado pela etapa adicional de clusterização, que adiciona complexidade ao processo de agre-

gação. No entanto, essa diferença é relativamente pequena em termos absolutos e é compensada pela melhoria significativa na precisão e na convergência do modelo, como demonstrado nas seções anteriores. Além disso, o tempo máximo de execução do FedKMeans (85,82 segundos) permanece dentro de limites aceitáveis para aplicações em dispositivos vestíveis, reforçando a viabilidade prática do método.

5.7 Discussão dos Resultados

Os resultados demonstram que o FedKMeans superou o FedAvg em cenários com alta heterogeneidade de dados, reduzindo o erro na geração de ECG sintético e melhorando a convergência do modelo. No entanto, para uma análise mais completa, é fundamental comparar essas abordagens com os cenários tradicionais de treinamento centralizado e treinamento local individual.

5.7.1 Comparação com o Treinamento Centralizado

O treinamento centralizado, que tem acesso a todos os dados, alcançou um RMSE de 0,216 e um Coeficiente de Pearson de 0,639. Embora esse cenário represente o melhor desempenho teórico, ele não é viável em aplicações reais devido a restrições de privacidade e distribuição dos dados. Além disso, o desempenho inferior ao treinamento local individual pode ser atribuído à heterogeneidade dos dados, que dificulta a adaptação do modelo centralizado às características específicas de cada paciente. Esse resultado reforça a necessidade de abordagens que equilibrem desempenho global e adaptação local, como o Aprendizado Federado.

5.7.2 Comparação com o Treinamento Local Individual

No treinamento local individual, a média dos clientes resultou em um RMSE de 0,199 e um Coeficiente de Pearson de 0,752, superando ligeiramente o modelo centralizado. Esse resultado sugere que, em cenários com alta heterogeneidade, modelos locais podem se adaptar melhor às características específicas de cada cliente. No entanto, a grande variabilidade entre os clientes (RMSE variando de 0,137 a 0,352) destaca a inconsistência dessa abordagem. Enquanto alguns clientes alcançaram desempenho superior, outros tiveram resultados significativamente piores, o que inviabiliza a aplicação direta do treinamento local em cenários práticos.

5.7.3 Desempenho do FedAvg e FedKMeans

O FedAvg, apresentou um desempenho pior que o treinamento centralizado e o local individual. Essa abordagem é eficiente em cenários homogêneos, mas pode ser limitada em ambientes com alta heterogeneidade, como observado neste estudo.

Já o FedKMeans, mostrou-se mais robusto à heterogeneidade dos dados. Ao agrupar modelos com características semelhantes, o FedKMeans conseguiu reduzir o RMSE e melhorar o Coeficiente de Pearson em comparação ao FedAvg, aproximando-se do desempenho do melhor cliente no treinamento local individual. Além disso, a convergência mais estável do FedKMeans reforça sua eficácia em cenários federados.

5.7.4 Eficiência Computacional

Em termos de eficiência computacional, o FedKMeans demandou um uso de memória ligeiramente maior e um tempo de execução um pouco mais longo por rodada em comparação ao FedAvg. No entanto, essas diferenças são justificadas pelos ganhos em precisão e estabilidade do método proposto. O tempo de execução e o uso de memória permaneceram dentro de limites práticos, reforçando a viabilidade do FedKMeans para aplicações em dispositivos com recursos limitados, como dispositivos vestíveis.

5.7.5 Implicações Práticas

A melhoria na qualidade dos resultados (menor RMSE e MSE) e a maior consistência na convergência tornam o FedKMeans uma abordagem promissora para a geração de ECG sintético em cenários federados. Essa técnica não apenas supera as limitações do FedAvg em ambientes heterogêneos, mas também oferece um equilíbrio entre desempenho global e adaptação local, sem comprometer a privacidade dos dados.

6 CONCLUSÃO E TRABALHOS FUTUROS

Neste trabalho, foi apresentada uma abordagem para a geração de sinais de ECG sintéticos a partir de dados de PPG utilizando aprendizado federado, com foco especial no tratamento da heterogeneidade dos dados através do método proposto FedKMeans. A pesquisa buscou endereçar um desafio fundamental: a necessidade de lidar com a natureza heterogênea dos sinais fisiológicos provenientes de diferentes pacientes. Para isso, foi desenvolvida uma estratégia de agregação baseada em *clustering* que visa melhorar a convergência e a qualidade dos modelos em ambientes federados.

Os experimentos foram conduzidos utilizando a base de dados MIMIC-II, comparando quatro cenários distintos: treinamento centralizado, treinamento local individual, FedAvg e FedKMeans. A implementação foi realizada em um ambiente computacional controlado, utilizando uma rede BiLSTM como arquitetura base e avaliando tanto aspectos de qualidade dos sinais gerados quanto métricas de eficiência computacional. O protocolo experimental envolveu 150 rodadas de treinamento, com avaliações periódicas do desempenho dos modelos e análise detalhada do comportamento dos agrupamentos no método proposto.

Uma das principais limitações deste estudo é a ausência de uma avaliação clínica por especialistas da área médica dos sinais de ECG sintéticos gerados. Embora as métricas quantitativas como RMSE, MSE e coeficiente de Pearson forneçam indicadores objetivos da qualidade dos sinais, a utilidade clínica real dos ECGs sintéticos requer uma validação por cardiologistas experientes. A interpretação clínica dos sinais de ECG depende de nuances sutis que podem não ser completamente capturadas pelas métricas utilizadas.

Os resultados demonstraram a superioridade do FedKMeans em relação ao FedAvg tradicional. A estratégia de clusterização mostrou-se efetiva em agrupar modelos com características semelhantes, resultando em uma convergência mais estável e sinais sintéticos de maior qualidade. Embora o FedKMeans tenha apresentado um pequeno aumento no consumo de recursos computacionais, esse custo adicional é compensado pela melhoria significativa na qualidade dos resultados. A análise da distribuição dos clientes entre *clusters* revelou um padrão de convergência que sugere a eficácia do método em identificar e agrupar características similares nos dados dos pacientes.

Como direções para trabalhos futuros, destaca-se inicialmente a possibilidade de tornar dinâmico o número de *clusters* durante o treinamento. Na implementação atual, o valor k do algoritmo *K-means* é definido uma única vez durante a inicialização do servidor ($k = 3$)

e permanece fixo ao longo de todo o processo de treinamento, apenas realocando os clientes entre esses três *clusters* pré-definidos. Uma evolução natural seria desenvolver algoritmos que permitam a otimização dinâmica desse parâmetro k durante o treinamento, utilizando técnicas como o método do cotovelo ou o método da silhueta. Estas técnicas poderiam ser adaptadas para execução em tempo real durante o processo de agregação federada, permitindo que o sistema ajuste automaticamente o número ideal de *clusters* com base nas características evolutivas dos modelos locais.

Ainda, a investigação de algoritmos alternativos de clusterização além do *K-means*. Métodos como *DBSCAN*, que não requer especificação prévia do número de *clusters* e pode identificar grupos de formato arbitrário, ou algoritmos hierárquicos como *Agglomerative Clustering*, poderiam capturar relações mais complexas entre os modelos locais. Técnicas de clusterização espectral ou baseadas em densidade também poderiam ser exploradas para lidar com distribuições não-esféricas dos parâmetros dos modelos. A comparação sistemática desses diferentes algoritmos poderia revelar abordagens mais eficientes para cenários específicos de heterogeneidade de dados.

Uma das limitações observadas no método FedKMeans proposto é o alto custo computacional associado ao cálculo de distâncias entre modelos em espaços de alta dimensionalidade. Os parâmetros das redes BiLSTM utilizadas podem facilmente alcançar milhares de dimensões, tornando o processo de clusterização computacionalmente intensivo. Uma abordagem promissora para superar esta limitação seria a aplicação de técnicas de redução de dimensionalidade antes da etapa de clusterização. Propõe-se como trabalho futuro a investigação de métodos como Análise de Componentes Principais (*Principal Component Analysis*) (PCA) para projetar as distâncias entre os modelos em espaços de dimensões significativamente menores. Esta abordagem não apenas reduziria o custo computacional do algoritmo, mas também poderia melhorar a qualidade da clusterização ao mitigar os efeitos da "maldição da dimensionalidade", fenômeno que torna a identificação de clusters mais desafiadora em espaços de alta dimensão.

Além disso, a validação em múltiplas bases de dados, como MIMIC-III e CAPNO, permitiria avaliar a robustez e generalização do método em diferentes contextos. Experimentos em maior escala, com 50 a 100 clientes, são necessários para compreender o comportamento do sistema em cenários mais próximos de implementações reais.

REFERÊNCIAS

- ANNAPPA, B.; HEGDE, S.; ABHIJIT, C. S.; AMBESANGE, S. *et al.* Fedcure: A heterogeneity-aware personalized federated learning framework for intelligent healthcare applications in iomt environments. **IEEE Access**, IEEE, v. 12, p. 15867–15883, 2024.
- BERKAYA, S. K.; UYSAL, A.; GUNAL, E. S.; ERGIN, S.; GÜNAL, S.; GÜLMEZOĞLU, M. B. A survey on ecg analysis. **Biomed. Signal Process. Control.**, v. 43, p. 216–235, 2018.
- CHIU, H.-Y.; SHUAI, H.-H.; CHAO, P. C.-P. Reconstructing qrs complex from ppg by transformed attentional neural networks. **IEEE Sensors Journal**, IEEE, v. 20, n. 20, p. 12374–12383, 2020.
- DAS, S.; DUTTA, S.; HAZRA, S.; NANDI, S.; BANDYOPADHYAY, A.; DISHA, M. Personalized healthcare empowered: Federated learning integration with wearable device data for enhanced patient insights. In: IEEE. **2024 IEEE Region 10 Symposium (TENSYP)**. [S.l.], 2024. p. 1–6.
- DIANI, M. S.; BOUKADOUM, M. Ppg-ecg conversion and classification for cardiac activity diagnosis. In: IEEE. **2024 22nd IEEE Interregional NEWCAS Conference (NEWCAS)**. [S.l.], 2024. p. 258–262.
- GOLDBERGER, A. L.; AMARAL, L. A. N.; GLASS, L.; HAUSDORFF, J. M.; IVANOV, P. C.; MARK, R. G.; MIETUS, J. E.; MOODY, G. B.; PENG, C.-K.; STANLEY, H. E. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. **Circulation**, v. 101, n. 23, p. e215–e220, 2000. Circulation Electronic Pages: <http://circ.ahajournals.org/content/101/23/e215.full> PMID:1085218; doi: 10.1161/01.CIR.101.23.e215.
- GRAVES, A.; SCHMIDHUBER, J. Framewise phoneme classification with bidirectional lstm and other neural network architectures. **Neural Networks**, v. 18, n. 5, p. 602–610, 2005. ISSN 0893-6080. IJCNN 2005. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0893608005001206>>.
- HARD, A.; KIDDON, C. M.; RAMAGE, D.; BEAUFAYS, F.; EICHNER, H.; RAO, K.; MATHEWS, R.; AUGENSTEIN, S. **Federated Learning for Mobile Keyboard Prediction**. 2018. Disponível em: <<https://arxiv.org/abs/1811.03604>>.
- HASSOUN, M.; INTRATOR, N.; MCKAY, S.; CHRISTIAN, W. Fundamentals of artificial neural networks. **Proceedings of the IEEE**, v. 84, p. 906–, 1996.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, MIT press, v. 9, n. 8, p. 1735–1780, 1997.
- HWANG, H.; YANG, S.; KIM, D.; DUA, R.; KIM, J.-Y.; YANG, E.; CHOI, E. Towards the practical utility of federated learning in the medical domain. In: PMLR. **Conference on Health, Inference, and Learning**. [S.l.], 2023. p. 163–181.
- KUMARI, R.; SARKAR, S.; DUTTA, D.; DAS, P.; ACHARYYA, A. P2e-Igan: Ppg to ecg reconstruction methodology using lstm based generative adversarial network. In: IEEE. **2024 IEEE International Symposium on Circuits and Systems (ISCAS)**. [S.l.], 2024. p. 1–5.

LAN, E. Performer: A novel ppg-to-ecg reconstruction transformer for a digital biomarker of cardiovascular disease detection. In: **Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision**. [S.l.: s.n.], 2023. p. 1991–1999.

LEE, E.; LEE, C.-Y. Ppg-based smart wearable device with energy-efficient computing for mobile health-care applications. **IEEE Sensors Journal**, v. 21, p. 13564–13573, 2021.

LI, X.; JIANG, M.; ZHANG, X.; KAMP, M.; DOU, Q. Fedbn: Federated learning on non-iid features via local batch normalization. **CoRR**, abs/2102.07623, 2021. Disponível em: <<https://arxiv.org/abs/2102.07623>>.

MACQUEEN, J. *et al.* Some methods for classification and analysis of multivariate observations. In: OAKLAND, CA, USA. **Proceedings of the fifth Berkeley symposium on mathematical statistics and probability**. [S.l.], 1967. v. 1, n. 14, p. 281–297.

MAGNUSSEN, C.; OJEDA, F.; LEONG, D. P.; ALEGRE-DIAZ, J.; AMOUYEL, P.; AVILÉS-SANTA, L.; BACQUER, D. D.; BALLANTYNE, C.; BERNABÉ-ORTIZ, A.; BOBÁK, M.; BRENNER, H.; CARRILLO-LARCO, R.; LEMOS, J. de; DOBSON, A.; DÖRR, M.; DONFRANCESCO, C.; DRYGAS, W.; DULLAART, R.; ENGSTRÖM, G.; FERRARIO, M.; FERRIÈRES, J.; GAETANO, G. de; GOLDBOURT, U.; GONZALEZ, C.; GRASSI, G.; HODGE, A. M.; HVEEM, K.; IACOVIELLO, L.; IKRAM, M.; IRAZOLA, V.; JOBE, M.; JOUSILAHTI, P.; KALEEBU, P.; KAVOUSI, M.; KEE, F.; KHALILI, D.; KOENIG, W.; KONTSEVAYA, A.; KUULASMAA, K.; LACKNER, K.; LEISTNER, D.; LIND, L.; LINNEBERG, A.; LORENZ, T.; LYNGBAKKEN, M. N.; MALEKZADEH, R.; MALYUTINA, S.; MATHIESEN, E.; MELANDER, O.; METSPALU, A.; MIRANDA, J.; MOITRY, M.; MUGISHA, J.; NALINI, M.; NAMBI, V.; NINOMIYA, T.; OPPERMAN, K.; D'ORSI, E.; PAJÁK, A.; PALMIERI, L.; PANAGIOTAKOS, D.; PERIANAYAGAM, A.; PETERS, A.; POUSTCHI, H.; PRENTICE, A.; PRESCOTT, E.; RISÉRUS, U.; SALOMAA, V.; SANS, S.; SAKATA, S.; SCHÖTTKER, B.; SCHUTTE, A.; SEPANLOU, S.; SHARMA, S. K.; SHAW, J.; SIMONS, L.; SÖDERBERG, S.; TAMOŠIŪNAS, A.; THORAND, B.; TUNSTALL-PEDOE, H.; TWERENBOLD, R.; VANUZZO, D.; VERONESI, G.; WAIBEL, J.; WANNAMETHEE, S.; WATANABE, M.; WILD, P.; YAO, Y.; ZENG, Y.; ZIEGLER, A.; BLANKENBERG, S. Global impact of modifiable risk factors on cardiovascular disease and mortality. **The New England journal of medicine**, v. 389, p. 1273 – 1285, 2023.

MAKOWSKI, D.; PHAM, T.; LAU, Z. J.; BRAMMER, J. C.; LESPINASSE, F.; PHAM, H.; SCHÖLZEL, C.; CHEN, S. H. A. NeuroKit2: A python toolbox for neurophysiological signal processing. **Behavior Research Methods**, Springer Science and Business Media LLC, v. 53, n. 4, p. 1689–1696, feb 2021. Disponível em: <<https://doi.org/10.3758%2Fs13428-020-01516-y>>.

MOON, S.; LEE, W. H. Privacy-preserving federated learning in healthcare. In: IEEE. **2023 International Conference on Electronics, Information, and Communication (ICEIC)**. [S.l.], 2023. p. 1–4.

MURMU, N.; GUPTA, R.; SHARMA, K. D. Real-time ppg-to-ecg reconstruction model with on-device recalibration facility. **IEEE Transactions on Instrumentation and Measurement**, IEEE, 2024.

PINTO, R. A.; OLIVEIRA, H. de; SOUTO, E.; GIUSTI, R. Rede neural incresu-net para inferência de sinais eletrocardiograma a partir de sinais fotopletismograma. In: SBC. **Anais do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde**. [S.l.], 2023. p. 419–430.

- SAHU, A. K.; LI, T.; SANJABI, M.; ZAHEER, M.; TALWALKAR, A.; SMITH, V. On the convergence of federated optimization in heterogeneous networks. **CoRR**, abs/1812.06127, 2018. Disponível em: <<http://arxiv.org/abs/1812.06127>>.
- SARKAR, P.; ETEMAD, A. **CardioGAN: Attentive Generative Adversarial Network with Dual Discriminators for Synthesis of ECG from PPG**. 2020.
- SUMALATHA, U.; PRAKASHA, K.; PRABHU, S.; NAYAK, V. C. Deep learning applications in ecg analysis and disease detection: An investigation study of recent advances. **IEEE Access**, v. 12, p. 126258–126284, 2024.
- TIAN, X.; ZHU, Q.; LI, Y.; WU, M. Cross-domain joint dictionary learning for ecg reconstruction from ppg. In: IEEE. **ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.l.], 2020. p. 936–940.
- TIAN, X.; ZHU, Q.; LI, Y.; WU, M. Cross-domain joint dictionary learning for ecg inference from ppg. **IEEE Internet of Things Journal**, IEEE, v. 10, n. 9, p. 8140–8154, 2022.
- WANG, H.; YUROCHKIN, M.; SUN, Y.; PAPALIOPOULOS, D. S.; KHAZAENI, Y. Federated learning with matched averaging. **CoRR**, abs/2002.06440, 2020. Disponível em: <<https://arxiv.org/abs/2002.06440>>.
- YU, Y.; SI, X.; HU, C.; ZHANG, J. xun. A review of recurrent neural networks: Lstm cells and network architectures. **Neural Computation**, v. 31, p. 1235–1270, 2019.
- ZHU, Q.; TIAN, X.; WONG, C.-W.; WU, M. Ecg reconstruction via ppg: A pilot study. In: IEEE. **2019 IEEE EMBS international conference on biomedical & health informatics (BHI)**. [S.l.], 2019. p. 1–4.