

Investigando o Uso de Aprendizado Federado na Detecção e Controle de Diabetes

Lucas S. de Oliveira¹, Alison R. Panisson¹, Jim Lau¹,
Iwens G. Sene², Analucia Schiaffino Morales¹

¹Engenharia de Computação– Universidade Federal de Santa Catarina (UFSC)
R. Gov. Jorge Lacerda, 3201 - Jardim das Avenidas, Araranguá - SC, 88906-072

²Instituto de Informática–Universidade Federal de Goiás (UFG)
Alameda Palmeiras, Quadra D, Campus Samambaia, Goiânia - GO, 74690-900

engcomp.lucasedu@gmail.com, iwens@ufg.br,
{alison.panisson, jim.lau, analucia.morales}@ufsc.br

Abstract. This study explores federated learning for diabetes detection and monitoring using physiological data from wearable-like devices. A server and two ESP32 devices form the system, aiming to enhance early diagnosis and personalized care. Three datasets—Ohio T1DM, DiaHealth, and GBS—were processed with dimensionality reduction, outlier removal, and balancing techniques. Key biomarkers include glycemic index, heart rate, temperature, sweat, and oxygen saturation. Machine learning models were trained in Orange Data Mining and evaluated via precision, recall, F1-score, and accuracy. Random Forest excelled as the global model within the federated framework, with local customization on ESP32 despite memory constraints. Federated learning proves promising for personalized diabetes monitoring, with future improvements suggested through daily activity data integration. **Keywords:** Federated Learning, Diabetes

Resumo. Este estudo explora o uso de aprendizado federado para detecção e monitoramento do diabetes com dados fisiológicos de dispositivos semelhantes a wearables. O sistema é composto por um servidor e dois dispositivos ESP32, visando melhorar o diagnóstico precoce e o cuidado personalizado. Três conjuntos de dados—Ohio T1DM, DiaHealth e GBS—foram processados com redução de dimensionalidade, remoção de outliers e técnicas de balançamento. Os principais biomarcadores incluem índice glicêmico, frequência cardíaca, temperatura corporal, suor e saturação de oxigênio. Modelos de aprendizado de máquina foram treinados no Orange Data Mining e avaliados por precisão, recall, F1-score e acurácia. O Random Forest destacou-se como modelo global dentro do framework federado, permitindo personalização local nos ESP32, apesar das limitações de memória. O aprendizado federado mostrou-se promissor para o monitoramento personalizado do diabetes, com possíveis melhorias ao integrar dados de atividades diárias. **Palavras-Chave:** Aprendizado Federado, Diabetes

1. Introdução

De acordo com a Organização Mundial da Saúde (OMS), as doenças crônicas não transmissíveis (DCNT) são responsáveis por cerca de 74% dos óbitos anuais, lideradas por

doenças cardiovasculares, câncer, condições respiratórias e diabetes. No Brasil, as DCNT também se apresentam como um problema de saúde de grande magnitude, e atingem indivíduos de todas as camadas socioeconômicas. Sendo de forma mais intensa, indivíduos pertencentes a grupos vulneráveis, como os idosos e os de baixa escolaridade e renda [Malta et al. 2015]. Nesse contexto, destaca-se a diabetes mellitus, caracterizada pela incapacidade do corpo de produzir ou utilizar adequadamente a insulina, possuindo três grupos principais: diabetes Tipo 1, diabetes Tipo 2 e diabetes gestacional [Rodriguez-León et al. 2021]. De acordo com o portal da Sociedade Brasileira de Diabetes, os fatores que impulsionam o desenvolvimento da doença incluem: tabagismo, consumo de álcool, obesidade e hipertensão, sendo mais prevalentes em homens. Dentre as maiores consequências da falta de acompanhamento da doença, destacam-se cegueira, necrose e doenças cardiovasculares [Biessels et al. 2006]. Em 2023, o Brasil registrou cerca de 30 milhões de atendimentos relacionados ao diabetes nas Unidades Básicas de Saúde, refletindo a gravidade da doença, que resultou em aproximadamente 80 mil óbitos no país em 2022 [Butt et al. 2024]. Além do impacto na saúde pública, os custos associados ao tratamento são elevados [Nilson et al. 2020]..

Diante do cenário global, a prevenção e o monitoramento contínuo da diabetes são estratégias mais acessíveis e eficazes do que o tratamento de complicações severas. Tecnologias como *smartphones*, *smartwatches* ou dispositivos vestíveis apresentam grande potencial para transformar o cuidado de pacientes com doenças crônicas, permitindo um acompanhamento preciso e personalizado. Sensores acoplados a esses dispositivos possibilitam a medição de parâmetros fisiológicos essenciais para o controle de doenças crônicas, incluindo glicose no sangue, pressão arterial, atividade física e níveis de estresse, promovendo maior autonomia e engajamento dos pacientes no autocuidado [Golledge et al. 2020]. Isso se aplica ao diabetes, entretanto, existem poucos estudos relacionados as evidências dos biomarcadores para auxiliar o acompanhamento da doença [Jabara et al. 2024]. O uso de dados de sensores associado à inteligência artificial (IA) permite processar grandes volumes de dados, identificar padrões e prever complicações, possibilitando um tratamento mais eficaz e auxiliando na tomada de decisão médica e do paciente no acompanhamento e monitoramento do uso de insulina, principalmente. No entanto, a adoção de novas tecnologias no setor de saúde, especialmente considerando o diabetes, enfrenta barreiras substanciais, como integração de dados, tratamento de dados sensíveis, dispersão de dados entre diferentes instituições (clínicas e hospitais), datasets públicos recorrentes, alto custo de dispositivos vestíveis, responsabilização por informações que levem a diagnósticos errados, custos de implementação, regulamentação e problemas de privacidade e segurança [Jabara et al. 2024]. Adicionalmente, existe o desafio da personalização de resultados, pois cada indivíduo é único, e as recomendações devem ser individualizadas, de acordo com o tipo de diabetes, a idade, o peso, fatores genéticos, a qualidade de vida, sinais fisiológicos e outras condições de saúde relacionadas [Oliveira et al. 2024, Rodriguez-León et al. 2021].

Nesse contexto, o aprendizado federado apresenta-se como uma solução interessante para muitos destes desafios [Dhade and Shirke 2024], permitindo que dispositivos realizem o treinamento de modelos de IA de forma local, sem a necessidade de transferir todos os dados para servidores centralizados. Isso não só garante a privacidade dos pacientes, mas também possibilita a escalabilidade do uso da IA no tratamento de doenças

crônicas. O objetivo principal deste estudo é investigar o uso de aprendizado federado como ferramenta auxiliar no acompanhamento de doenças crônicas (neste caso, o diabetes) e validar uma aplicação para identificação da doença usando apenas parâmetros fisiológicos.

2. Materiais e Métodos

A metodologia adotada para a pesquisa iniciou por um estudo da literatura sobre a doença Diabetes Mellitus de forma a identificar trabalhos relacionados, algoritmos de aprendizado de máquina utilizados e o uso de parâmetros fisiológicos. Em seguida, foram pesquisados diferentes bases de datasets, e selecionados os mais indicados para os testes: Ohio T1DM [Marling and Bunescu 2020] DiaHealth [Prama et al. 2024] e Dataset sobre Glicose e Biomarcadores Superficiais (GBS) [Javale and Desai 2021]. Foi realizada uma etapa de tratamento de dados com o GBS. Em seguida, foram testados diferentes algoritmos, incluindo Redes Neurais Artificiais (ANN), k-Nearest Neighbors (k-NN), Random Forest (RF), Regressão Logística (RL) e Support Vector Machines (SVM), com métricas como acurácia, recall e F1-score analisadas usando o Orange Datamining. Após a seleção do modelo mais eficiente, foi realizada a implementação do aprendizado federado em dispositivos ESP32, permitindo a simulação de um ambiente distribuído para validar a personalização dos modelos no monitoramento contínuo da diabetes.

2.1. Diabetes Mellitus

Diabetes Mellitus é uma doença crônica que pode se apresentar como Tipo 1, Tipo 2 ou como diabetes gestacional. Embora menos comum, o Tipo 1 é a segunda mais prevalente e está fortemente relacionada à fatores genéticos [Malta et al. 2015]. Ela é caracterizada pela redução da produção de insulina pelo corpo, necessitando de injeções regulares do hormônio para regular os níveis de glicose. Em contraste, o Tipo 2 é a mais comum e pode se desenvolver devido a uma combinação de fatores sociais, físicos ou emocionais [Oliveira et al. 2024]. Neste caso, o corpo começa a desenvolver resistência à insulina e, eventualmente, a produção do hormônio é afetada, requerendo mudanças no estilo de vida do portador. A diabetes gestacional, por sua vez, está relacionada à incapacidade do corpo de produzir insulina suficiente para lidar com o aumento dos níveis glicêmicos decorrentes das mudanças hormonais durante a gravidez [Ghozali 2024].

De acordo com as informações do portal do Ministério da Saúde, em média, um em cada dois pré-diabéticos desenvolve a doença, muitas vezes devido à despreocupação ou falta de monitoramento, sendo esse o maior desafio ao lidar com a diabetes e outras DCNT. Muitos portadores desconhecem sua condição e, frequentemente, o diagnóstico é tardio, resultando em sequelas ou dificuldades no tratamento adequado. Existem duas frentes distintas quando se aborda estudos para auxiliar no diabetes: diagnóstico e monitoramento [Rodacki et al. 2024]. Diagnóstico é um evento pontual, que define a qual grupo o indivíduo se enquadra, enquanto o monitoramento envolve o acompanhamento contínuo da evolução da doença e do tratamento, fazendo ajustes conforme necessário. Assim como há uma diferença na representatividade, também há nas variáveis coletadas e nas métricas utilizadas [Rodacki et al. 2024]. O diagnóstico tende a ser realizado por intermédio de exames laboratoriais, como hemoglobina glicada, teste oral de tolerância a glicose e glicemia em jejum. Por vezes, esses exames são acompanhados por outros dados, como medidas de índice de obesidade, número de gestações, bem como um

cálculo que considera o histórico familiar de incidência da doença [Gross et al. 2002]. Em contrapartida, o monitoramento deve ser realizado de maneira contínua, coletando parâmetros fisiológicos e avaliando o que o conjunto representa, geralmente mediante o uso de sensores apropriados [Zou et al. 2024]. A utilização contínua destes dispositivos permite ajustes terapêuticos em tempo real, promovendo uma abordagem proativa na prevenção de complicações relacionadas a doença. Entretanto, são poucos trabalhos que apresentam resultados sobre o uso de sensores no acompanhamento de pacientes [Mutunhu et al. 2023] [Jabara et al. 2024].

2.2. Trabalhos Relacionados

A pesquisa por métodos computacionais para detecção, monitoração e controle de diabetes tem sido uma área de investigação ativa desde 2010 [Barakat et al. 2010]. Estudos iniciais exploraram a aplicação de Máquinas de Vetores de Suporte (SVMs) com técnicas de clusterização para lidar com o desbalanceamento de classes, alcançando acurácia de 94% e sensibilidade de 93% [Barakat et al. 2010]. Redes Neurais Artificiais (RNAs) também foram investigadas, com modelos multicamadas obtendo acurácia de 87.3% usando dados de exames laboratoriais e medidas corporais [El_Jerjawi and Abu-Naser 2018]. A seleção de parâmetros relevantes tem sido um foco importante, com estudos utilizando cálculos de correlação para filtrar entradas e avaliar o desempenho de múltiplos algoritmos, incluindo SVM, Random Forest (RF), Naïve Bayes (NB), Árvores de Decisão (AD) e k-Nearest Neighbors (KNN) [Sneha and Gangil 2019]. Técnicas de pré-processamento avançadas, como Análise de Componentes Principais (PCA), foram exploradas para melhorar o desempenho de modelos como SVM, RF e Redes Neurais Profundas, com RNAs alcançando acurácia de 89% em um dataset de diabetes do Kaggle [Awoniran et al. 2022]. Modelos de aprendizado profundo mais complexos, como Redes Neurais de Memória de Longo e Curto Prazo (LSTM), têm sido aplicados para superar limitações de modelos tradicionais, demonstrando acurácia, precisão, recall e F1-score superiores a 97% [Upamanyu et al. 2024]. Abordagens de ensemble, combinando RF e XGBoost com técnicas de remoção de outliers, também foram exploradas para aumentar a robustez dos diagnósticos, alcançando acurácia de 93.75% [Xu and Wang 2019]. Mais recentemente, o aprendizado federado tem surgido como uma alternativa promissora para lidar com questões de segurança e privacidade, e prevenção de riscos da doença [Su et al. 2023]. Com relação a monitoração de parâmetros fisiológicos e IA foi encontrada uma revisão de literatura [Jabara et al. 2024]. De acordo com os autores, para a diabetes tipo 2, dados de sensores como: eletrocardiograma, fotopletismografia, acelerômetro, atividade eletrodérmica e temperatura da pele podem ser usados como entradas para modelos de IA, sendo importante aliado nos estágios iniciais da manifestação da doença, sendo útil para estratificar o risco de desenvolver a doença ou estimar o valor de parâmetros relacionados ao monitoramento de diabetes. Dois estudos experimentais sobre a monitoração de diabetes com uso de IoT [Ara and Ara 2017] [Mutunhu et al. 2023]. E uma revisão sistemática que aborda a monitoração remota em pacientes com diabetes [Mutunhu et al. 2022], destacando oportunidades e desafios associados, como a redução de custos hospitalares, satisfação de pacientes, redução do uso de medicações e integração de serviços.

3. Predição de Diabetes utilizando Aprendizado Federado

O aprendizado federado é uma configuração de aprendizado de máquinas em que vários clientes treinam um modelo de forma colaborativa. Esse processo é liderado por um coordenador central, e os dados de treinamento permanecem descentralizados [Zhang et al. 2021]. De modo resumido, o coordenador central possui um modelo global que é compartilhado com os demais dispositivos que estão participando do treinamento. Cada dispositivo treina o modelo com os dados locais e, periodicamente, envia um vetor com os pesos para o coordenador. Esse coordenador vai calcular os pesos atualizados com base nos vetores com ele compartilhados e irá enviar os novos pesos aos dispositivos, onde o ciclo de treinamento irá continuar com os pesos atualizados [Ramos et al. 2021]. A estrutura federada desenvolvida nesse trabalho, ilustrada pela Figura 1, dispõe de quatro requisições, sendo elas a coleta dos pesos de dispositivos decentralizados (ESPs), o download do modelo inicial, a coleta do gradiente de alteração dos pesos e a inserção dos ESPs na estrutura. Sempre que um ESP se conectar à API do servidor federado, é aberta uma conexão websocket (WS) para envio de alertas, como heartbeat e a realização do cálculo de agregação do gradiente. Após, o dispositivo salva localmente, o modelo inicial do servidor. Para o estudo foram utilizados dois dispositivos ESP32 Wemos D1 R32 (módulo com Bluetooth e Wi-Fi) para simular dois clientes, um classificado como diabético com 19 anos, e outro indivíduo classificado como saudável e com 30 anos. Os dados utilizados por cada um dos clientes foram gerados sinteticamente com base nos dados coletados pelo dataset *Glucose and Superficial Biomarkers*(GBS) e armazenados em bases distintas. O intuito da configuração de teste foi simular os biomarcadores coletados dos usuários em tempo real como se fossem coletados por dispositivos vestíveis, e avaliar em qual classe estes biomarcadores enquadrariam o usuário. Um teste simples, mas que apresenta desafios para quem deseja aprimorar o estudo neste tipo de estrutura. Destaca-se o fluxo básico do funcionamento da estrutura:

1. Um dispositivo se conecta à API e ao serviço WS;
2. O servidor dá-lhe um ID, salva a conexão na lista de dispositivos ativos;
3. O dispositivo requisita o modelo, que é enviado por requisição HTTP no formato JSON;
4. Em intervalo regulares, o dispositivo coleta registros de dados do dataset de forma aleatória, salvando-o em um vetor;
5. Após dez coletas, o dispositivo treina o modelo local e atualiza os pesos localmente;
6. Finalizada a inferência, o dispositivo coleta os pesos do modelo e envia para o servidor;
7. O servidor obtém os vetores de todos os dispositivos conectados e inicia o processo de agregação;
8. O servidor calcula o gradiente de mudança dos pesos e envia uma mensagem pelo WS, avisando todas as conexões ativas;
9. Os dispositivos coletam os gradientes e atualizam seus pesos;
10. O ciclo de coleta e atualização se reinicia.

3.1. Datasets e Preparação de Dados

Foram investigados os repositórios de bases de dados: Kaggle, Google Dataset Search, UCI Machine Learning Repository, Physionet e Harvard Dataverse. O objetivo foi investigar diferentes bases de dados com parâmetros fisiológicos (ou biomarcadores) os quais

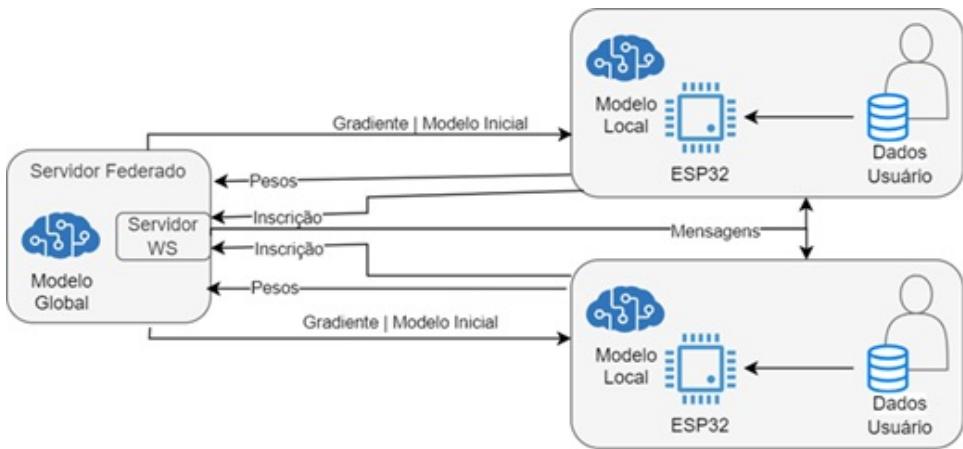


Figura 1. Estrutura do aprendizado federado

pudessem ser utilizados nesse estudo. Três datasets foram avaliados como elegíveis: (i) Ohio T1DM, o qual apresenta dados de monitoramento contínuo de pacientes com diabetes tipo 1 [Marling and Bunescu 2020]; (ii) DiaHealth, um dataset bengalês para predição de diabetes tipo II [Prama et al. 2024]; e, (iii) Dataset sobre Glicose e Biomarcadores Superficiais (GBS) [Javale and Desai 2021].

O Ohio T1DM apresenta resultados de injeção de insulina nos pacientes e possui uma única classe de pacientes (diabetes tipo I). Além disso, não possui domínio público e requer um acordo de uso de dados para permitir o acesso aos dados. O Dia Health oferece uma visão mais ampla, contendo dados de classes diabéticas e não-diabéticas, embora levemente desbalanceado, pendendo para a classe majoritária não-diabética. Contudo, os valores de glicose refere-se à concentração de glicose na urina, e não no sangue ou através de sensores. Apresentando um desequilíbrio para a classe majoritária diabética, o dataset GBS apresenta dez colunas, sendo sete delas, dados similares coletados por sensores, duas, não coletáveis e uma, com o diagnóstico binário, mostrando-se apto a ser utilizado para o treinamento do modelo. A única ressalva é a proporção de 50:1 entre as classes, necessitando de um pré-processamento para equilíbrio de classes.

3.2. Tratamento dos dados

Por ser o dataset mais adequado para os testes, o resultado do estudo precisou ser dimensionado para a classificação da presença ou não de diabetes, a partir de parâmetros fisiológicos. Realizou-se a remoção de outliers do GBS. A Figura 2 apresenta uma comparação entre o dataset inicial e os métodos de remoção de outliers aplicados (MAD, BADk, MAD-BADk). Originalmente, há a presença de clusters vagamente definidos e espalhados, bem como uma zona de sobreposição das classes. O método MAD tornou mais evidente a forma dos clusters, tanto sozinho quanto quando aplicado ao método BADk, e, apesar de não ter separado completamente as classes, o que pode indicar a presença de outliers não removidos, demonstra eficácia equilibrada, sem remover muitos valores dúbios. Contudo, o mesmo não pode ser afirmado sobre o método BADk, o qual demonstra certa agressividade nas remoções, eliminando dados cruciais aos clusters, sendo tal comportamento observado tanto sozinho quanto aliado ao método MAD. Portanto, há fortes indicativos de que o método MAD é o mais efetivo para o tratamento do dataset GBS.

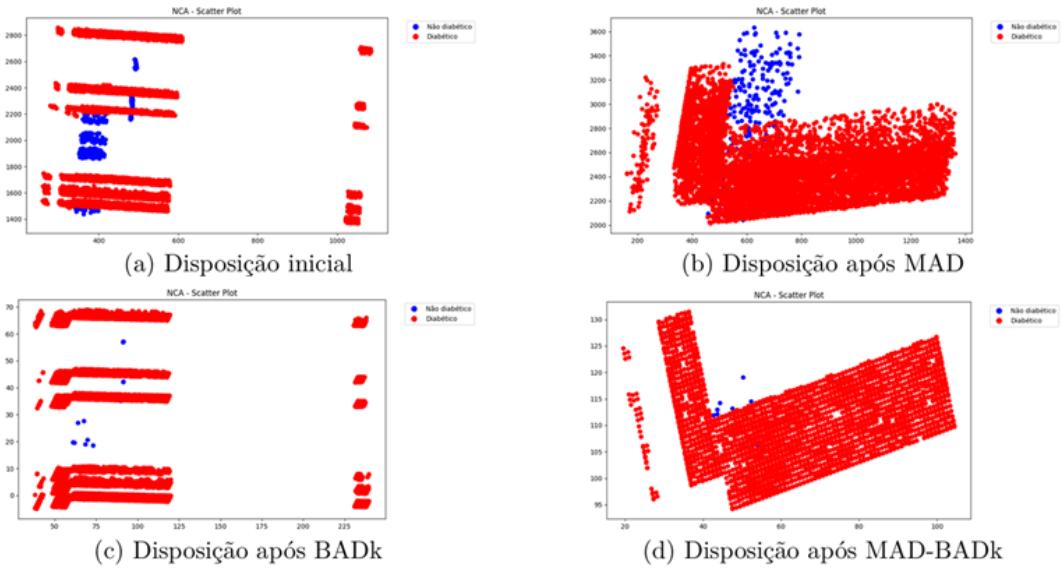


Figura 2. Visualização das disposições dos dados de cada dataset após tratamento de remoção de outliers

3.3. Treinamento de Modelos de Machine Learning

Para o treinamento dos modelos de ML, manteve-se as três versões pré-processadas do GBS, conforme apresentado na seção 3.1, cada qual correspondendo à seleção filtrada por um método e, em seguida, as quatro versões passaram pelos métodos de平衡amento *Undersampling*, *SMOTE* e *SMOTENN*, gerando assim as 16 variações do dataset inicial. Embora o método MAD tenha demonstrado ser o mais eficaz para a remoção de outliers, todas as 16 versões do dataset foram utilizadas na avaliação dos modelos. O objetivo foi analisar de forma abrangente o impacto das remoções no desempenho de aprendizagem dos modelos e identificar qual deles seria o mais adequado para classificar o indivíduo com diabetes. As avaliações foram realizadas utilizando as seis métricas de desempenho nos 80 modelos, os quais alcançaram resultados variados, oscilando entre ruim e excelente.

3.4. Avaliação

A Tabela 1 mostra os resultados da remoção de outliers e uso das técnicas de balanceamento do dataset. Como pode ser observado na Tabela 2, o melhor resultado dentre os modelos testados foi obtido pelo algoritmo k-NN, seguido pelo Random Forest (RF). Além disso, contrário aos indícios iniciais, MAD não foi o método que gerou os melhores modelos, mas sim BADk e sua proposta híbrida, ambos servidos com dados sintéticos. Porém, como o k-NN é muito sensível a inserções de dados sintéticos, a probabilidade de estar enviesado é considerada, fator esse evidenciado pela indiferença em utilizar valores superiores a dois para o k.

Portanto, o modelo RF treinado com o dataset SMOTENN MAD-BADk foi escolhido para ser utilizado como modelo inicial para a estrutura de aprendizado federada. Como o algoritmo RF não é diretamente replicável nos dispositivos distribuídos, dada suas limitações de processamento e memória, o seguinte processo foi adotado: (1) Replicar o modelo treinado com base em árvores binárias, onde cada nó era representado no formato da estrutura Node, apresentada abaixo; (2) Separar o modelo em 25 arquivos

Tabela 1. Estatísticas das versões do dataset

| | Remoção | Balanço | Diabéticos | Não diabéticos | Total | Razão |
|----|----------|---------------|------------|----------------|-------|--------|
| 1 | - | - | 16373 | 328 | 16701 | 49.92 |
| 2 | - | SMOTE | 16311 | 16251 | 32562 | 1.00 |
| 3 | - | SMOTEENN | 16168 | 16009 | 32177 | 1.01 |
| 4 | - | Undersampling | 656 | 328 | 984 | 2.00 |
| 5 | MAD | - | 8841 | 233 | 9074 | 37.94 |
| 6 | MAD | SMOTE | 8841 | 8793 | 17634 | 1.01 |
| 7 | MAD | SMOTEENN | 8765 | 8499 | 17264 | 1.03 |
| 8 | MAD | Undersampling | 466 | 233 | 699 | 2.00 |
| 9 | BADk | - | 15823 | 59 | 15882 | 268.19 |
| 10 | BADk | SMOTE | 15823 | 15761 | 31584 | 1.00 |
| 11 | BADk | SMOTEENN | 15818 | 15392 | 31210 | 1.03 |
| 12 | BADk | Undersampling | 118 | 59 | 177 | 2.00 |
| 13 | MAD-BADk | - | 8518 | 45 | 8563 | 189.29 |
| 14 | MAD-BADk | SMOTE | 8518 | 8470 | 16988 | 1.01 |
| 15 | MAD-BADk | SMOTEENN | 8497 | 8087 | 16584 | 1.05 |
| 16 | MAD-BADk | Undersampling | 90 | 45 | 135 | 2.00 |

Tabela 2. Melhores métricas de cada algoritmo de aprendizado

| Algoritmo | Dataset | Acc | Prec | Recall | F1 | MCC | Kappa |
|-----------|---------------------|--------------|--------------|--------------|--------------|--------------|--------------|
| ANN | Smoteenn BADk | 0.986 | 1.000 | 0.972 | 0.986 | 0.973 | 0.973 |
| k-NN | Smoteenn BADk | 1.000 | 1.000 | 0.999 | 1.000 | 0.999 | 0.999 |
| RF | Smoteen MAD-BADk | 0.997 | 1.000 | 0.994 | 0.997 | 0.994 | 0.994 |
| RL | Under MAD | 0.904 | 0.893 | 0.979 | 0.934 | 0.771 | 0.760 |
| SVM | Smoteen MAD-BADk | 0.974 | 0.957 | 0.990 | 0.973 | 0.949 | 0.948 |

JSON menores, cada qual representando uma das árvores criada pelo modelo inicial; (3) Criar uma função de inferência e atualização dos pesos locais a cada inferência errada, mudando somente os pesos dos nodos pelos quais o dado passou na árvore; (4) Criar uma função para coletar todos os pesos de todos os 25 arquivos, para enviar os valores para o servidor calcular a agregação; (5) Criar uma função para agregar o gradiente enviado do servidor aos nós das árvores correspondentes.

```
struct Node{
    int feature_index;
    float threshold;
    int left_index;
    int right_index;
    float value; };
```

Por fim, após um período da estrutura trabalhando com os dados locais, tornou-se evidente a diferença nos pesos entre os dois ESPs. Isso se deve por conta das atualizações locais dos pesos a cada inferência errada, bem como à atualização via gradientes, o que demonstra a possibilidade de personalização da estratégia federada, haja vista a tendência do modelo se adequar aos dados por ele processados. Os pesos coletados dos ESPs no final do período de testes apresentam resultados diferentes. Ressalta-se que esse teste nos

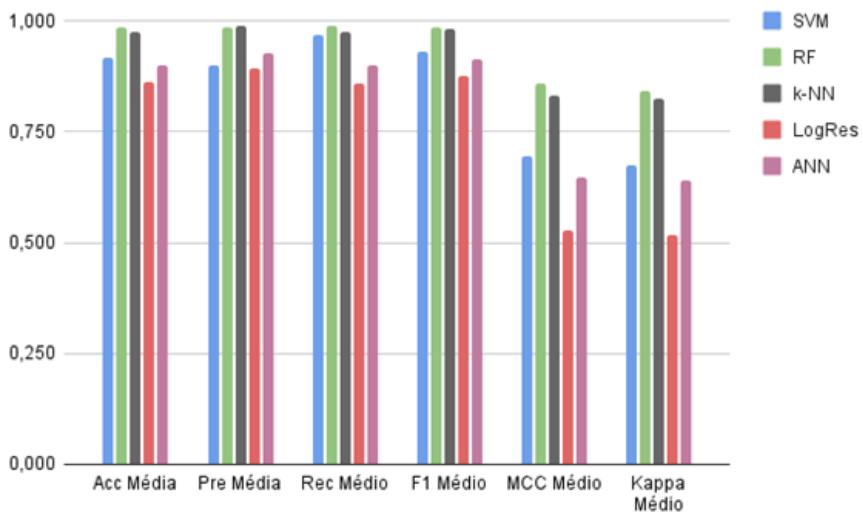


Figura 3. Comparação de métricas entre os algoritmos de ML

dispositivos ESPs foi feito com o intuito de avaliar a personalização e, como os dados utilizados eram, em sua maioria, sintéticos, não foram avaliadas as métricas das versões locais do modelo, sendo os detalhes anteriormente nessa seção referentes aos modelos iniciais.

4. Discussão

O presente estudo explorou diferentes modelos de aprendizado de máquina para monitoramento de diabetes, a serem aplicados a uma rede federada, identificando resultados promissores. Ressalta-se entretanto, que existem limitações significativas que precisam ser abordadas para garantir a aplicabilidade prática e a confiabilidade do sistema. Dentro elas, destacam-se: o desequilíbrio de classes, as limitações dos *datasets*, desafios de implementação no ESP32 e aspectos éticos relacionados à privacidade dos dados.

Desequilíbrio de Classes: Modelos desequilibrados tendem a carregar uma visão enViésada, dificultando a convergência correta. Mesmo aplicando técnicas de balanceamento de classes, como o SMOTEEENN, estas se revelam como medidas paliativas que reforçam relações já existentes no *dataset*. Embora baseados em dados reais, dados sintéticos não capturam toda a complexidade do mundo real e podem impactar negativamente o desempenho de alguns algoritmos, como foi o caso verificado no uso do k-NN.

Limitações dos Datasets: O *dataset* GBS contém variáveis relevantes (biomarcadores fisiológicos), porém os dados foram coletados em ambientes controlados, comprometendo sua capacidade de representar situações do cotidiano. Existe a necessidade de geração de dados que conte com uma maior variabilidade fisiológica, abrangendo condições reais, extremas e coletadas nas atividades diárias de pessoas com diabetes.

Desafios de Implementação no ESP32: A implementação do modelo em dispositivos ESP32 revelou limitações relacionadas à capacidade de armazenamento do dispositivo. O modelo inicial ocupava cerca de 80% espaço disponível, sendo necessário cindir o modelo em árvores binárias salvas como arquivos .json via SPIFFS. Isso permitiu a alocação momentânea apenas da árvore em processamento. Embora essa abordagem tenha reduzido a velocidade de processamento devido às alocações sequenciais, o intervalo entre leituras

e requisições é suficientemente longo para que o impacto seja mínimo. Estas limitações demonstram a dificuldade em aplicar a solução federadas nestes dispositivos.

Aspectos éticos relacionados à privacidade dos dados: Embora o aprendizado federado minimize o compartilhamento direto de informações sensíveis ao manter os dados localmente, ainda deve-se buscar agregar camadas de segurança e pesquisar melhor este tema. É essencial que os dados sejam anonimizados e que dispositivos e servidores sigam normas de segurança robustas.

Apesar dos pontos limitantes identificados no desenvolvimento do trabalho, os marcadores fisiológicos analisados desempenham papel fundamental, principalmente no monitoramento do diabetes. Esses biomarcadores, em associação com o modelo binário de classificação de diferentes tipos da doença, permitem o monitoramento em tempo real, identificando mudanças críticas e auxiliando no controle dos parâmetros e tomadas de decisão de médicos e pacientes. Os dados apresentaram um bom resultado, mas é necessário aprofundar de que forma aplicações que monitorem estes parâmetros poderiam auxiliar no controle da doença. O protótipo desenvolvido tem potencial para ser utilizado em dispositivos vestíveis para monitoramento de indivíduos em suas atividades diárias. Por exemplo, uma pessoa não diagnosticada como diabética poderia usar um dispositivo integrado ao modelo que, durante suas atividades cotidianas, poderia detectar alterações das frequências cardíacas e outros marcadores fora do padrão para auxiliar no diagnóstico precoce da doença. O modelo poderia classificar o indivíduo, como potencialmente diabético, emitindo um alerta para procurar orientação médica. Essa abordagem pode evitar complicações futuras, oferecendo um sistema preventivo que desafoga os sistemas de saúde ao alertar a população sobre o desenvolvimento da doença.

5. Conclusão

Nesse trabalho foi apresentado uma estrutura de aprendizado federado para classificação de diabetes. Apesar de um cenário bem limitado, os resultados reforçam o potencial dessa abordagem para soluções de monitoramento não invasivas e personalizáveis na área da saúde. Apesar dos resultados obtidos, várias limitações foram identificadas, principalmente relacionadas ao dataset utilizado, que apresentava baixa variabilidade e dados coletados em condições controladas. Isso restringe a generalização do modelo para cenários do dia a dia, onde as condições são naturalmente mais dinâmicas. Com base nisso, em trabalhos futuros, pretende-se criar datasets mais representativos, que capturem maior diversidade de parâmetros fisiológicos e comportamentos reais dos usuários, incluindo marcadores como: frequência cardíaca, sudorese, pressão arterial sistólica e diastólica, temperatura da pele, frequência respiratória. Além de dados com classificação de diferentes níveis de estágio da doença para que possam ser mais efetivos os resultados. Além disso, a continuidade dos estudos pode explorar formas de melhorar a eficiência computacional dos modelos implantados em dispositivos com restrições de hardware, como os utilizados neste trabalho.

Referências

- Ara, A. and Ara, A. (2017). Case study: Integrating iot, streaming analytics and machine learning to improve intelligent diabetes management system. In *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)*, pages 3179–3182.

- Awoniran, O., Oyelami, M., Ikono, R., Famutimi, R., and Famutimi, T. (2022). A machine learning technique for detection of diabetes mellitus. In *2022 5th Information Technology for Education and Development (ITED)*, pages 1–6. IEEE.
- Barakat, N., Bradley, A. P., and Barakat, M. N. H. (2010). Intelligible support vector machines for diagnosis of diabetes mellitus. *IEEE transactions on information technology in biomedicine*, 14(4):1114–1120.
- Biessels, G. J., Staekenborg, S., Brunner, E., Brayne, C., and Scheltens, P. (2006). Risk of dementia in diabetes mellitus: a systematic review. *The Lancet Neurology*, 5(1):64–74.
- Butt, M. D., Ong, S. C., Rafiq, A., Kalam, M. N., Sajjad, A., Abdullah, M., Malik, T., Yaseen, F., and Babar, Z.-U.-D. (2024). A systematic review of the economic burden of diabetes mellitus: contrasting perspectives from high and low middle-income countries. *Journal of pharmaceutical policy and practice*, 17(1):2322107.
- Dhade, P. and Shirke, P. (2024). Federated learning for healthcare: A comprehensive review. *Engineering Proceedings*, 59(1):230.
- El-Jerjawi, N. S. and Abu-Naser, S. S. (2018). Diabetes prediction using artificial neural network.
- Ghozali, M. T. (2024). Improving self-management of type 2 diabetes: Evaluating the effectiveness of a mobile app-based patient education approach. In *2024 4th International Conference on Emerging Smart Technologies and Applications*, pages 1–5.
- Golledge, J., Fernando, M., Lazzarini, P., Najafi, B., and G. Armstrong, D. (2020). The potential role of sensors, wearables and telehealth in the remote management of diabetes-related foot disease. *Sensors*, 20(16):4527.
- Gross, J. L., Silveiro, S. P., Camargo, J. L., Reichelt, A. J., and Azevedo, M. J. d. (2002). Diabetes melito: diagnóstico, classificação e avaliação do controle glicêmico. *Arquivos Brasileiros de Endocrinologia & Metabologia*, 46:16–26.
- Jabara, M., Kose, O., Perlman, G., Corcos, S., Pelletier, M.-A., Possik, E., Tsoukas, M., and Sharma, A. (2024). Artificial intelligence-based digital biomarkers for type 2 diabetes: A review. *Canadian Journal of Cardiology*, 40(10):1922–1933. Theme Issue: Rapidly Evolving Clinical Applications of Artificial Intelligence.
- Javale, D. and Desai, S. (2021). Dataset for people for their blood glucose level with their superficial body feature readings. *IEEE Dataport*.
- Malta, D. C., Stopa, S. R., Szwarcwald, C. L., Gomes, N. L., Silva Júnior, J. B., and Reis, A. A. C. d. (2015). A vigilância e o monitoramento das principais doenças crônicas não transmissíveis no brasil - pesquisa nacional de saúde, 2013. *Revista Brasileira de Epidemiologia*, 18:03–16.
- Marling, C. and Bunescu, R. (2020). The ohiot1dm dataset for blood glucose level prediction: Update 2020. In *CEUR workshop proceedings*, volume 2675, page 71.
- Mutunhu, B., Chipangura, B., and Twinomurinzi, H. (2022). A systematized literature review: internet of things (iot) in the remote monitoring of diabetes. In *Proceedings of Seventh International Congress on Information and Communication Technology: ICICT 2022, London, Volume 2*, pages 649–660. Springer.

- Mutunhu, B., Chipangura, B., and Twinomurinzi, H. (2023). A systematized literature review: Internet of things (iot) in the remote monitoring of diabetes. In Yang, X.-S., Sherratt, S., Dey, N., and Joshi, A., editors, *Proceedings of Seventh International Congress on Information and Communication Technology*, pages 649–660.
- Nilson, E. A. F., Andrade, R. d. C. S., Brito, D. A. d., and Oliveira, M. L. d. (2020). Custos atribuíveis a obesidade, hipertensão e diabetes no sistema único de saúde, brasil, 2018. *Revista Panamericana de Salud Pública*, 44:e32.
- Oliveira, G. P. M., Amâncio, N. d. F. G., and da Silva, J. L. (2024). A relação dos fatores socioeconômicos no desenvolvimento e tratamento do diabetes mellitus tipo 2. *Brazilian Journal of Implantology and Health Sciences*, 6(2):1873–1887.
- Prama, T. T., Zaman, M., Sarker, F., and Mamun, K. A. (2024). Diahealth: A bangladeshi dataset for type 2 diabetes prediction.
- Ramos, H. S., Maia, G., Papa, G. L., Alvim, M. S., Loureiro, A. A., Cardoso-Pereira, I., Campos, D. H., Filipakis, G., Riquetti, G., Chagas, E. T., et al. (2021). Aprendizado federado aplicado à internet das coisas.
- Rodacki, M., Cobas, R., Zajdenverg, L., da Silva Júnior, W., Giacaglia, L., Calliari, L., Noronha, R., Valerio, C., Custódio, J., Scharf, M., et al. (2024). Diagnóstico de diabetes mellitus. *Diretriz Oficial da Sociedade Brasileira de Diabetes*.
- Rodriguez-León, C., Villalonga, C., Munoz-Torres, M., Ruiz, J. R., and Banos, O. (2021). Mobile and wearable technology for the monitoring of diabetes-related parameters: Systematic review. *JMIR mHealth and uHealth*, 9(6):e25138.
- Sneha, N. and Gangil, T. (2019). Analysis of diabetes mellitus for early prediction using optimal features selection. *Journal of Big data*, 6(1):1–19.
- Su, Y., Huang, C., Zhu, W., Lyu, X., and Ji, F. (2023). Multi-party diabetes mellitus risk prediction based on secure federated learning. *Biomedical Signal Processing and Control*, 85:104881.
- Upamanyu, M., Chandan, M., Amrutha, H., Veena, K., Upendra, R., and Karthik, R. (2024). Early prediction of type-ii diabetes mellitus in young adults using lstm. In *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, pages 1–6. IEEE.
- Xu, Z. and Wang, Z. (2019). A risk prediction model for type 2 diabetes based on weighted feature selection of random forest and xgboost ensemble classifier. In *2019 eleventh international conference on advanced computational intelligence*, pages 278–283.
- Zhang, C., Xie, Y., Bai, H., Yu, B., Li, W., and Gao, Y. (2021). A survey on federated learning. *Knowledge-Based Systems*, 216:106775.
- Zou, Y., Chu, Z., Yang, T., Guo, J., and Li, D. (2024). Research progress and prospects of intelligent diabetes monitoring systems: a review. *IEEE Sensors Journal*.