

Arquitetura de Aprendizado Federado para Wearables: Detecção de Risco com FC e HRV na Indústria

Bruno Campos
Computer Science Department
Federal University of Ouro Preto
Ouro Preto, MG, Brasil
bruno.campos1@aluno.ufop.edu.br

Ricardo Augusto Rabelo Oliveira
Computer Science Department
Federal University of Ouro Preto
Ouro Preto, MG, Brasil
rrabelo@gmail.com

Resumo—Monitoring physiological stress in industrial and mining workers is critical for occupational safety. Wearable devices enable real-time measurement of heart rate (HR) and heart rate variability (HRV), but data privacy regulations impose severe restrictions. This work proposes a federated learning (FL) architecture where wearable devices train local models using HR and HRV, adjusted by the worker's age. Only model parameters are shared with a central server, preserving privacy. Alerts are issued locally when HR exceeds 85% of the age-adjusted maximum heart rate ($FC_{max} = 208 - 0.7 \times \text{age}$) or HRV drops below 20 ms. A proof-of-concept implementation demonstrates the feasibility of decentralized health risk detection using real medical thresholds, without exposing raw physiological data.

Index Terms—Aprendizado Federado, Wearables, Indústria 4.0, Privacidade, Hiperautomação, aprendizado de máquina, automação adaptativa

I. INTRODUÇÃO

No contexto da Indústria 4.0, a saúde e segurança do trabalhador assumem um papel central, impulsionadas por um arcabouço legal robusto no Brasil. A Consolidação das Leis do Trabalho (CLT) e, em particular, as Normas Regulamentadoras (NRs) estabelecem diretrizes claras para a proteção da integridade física e mental dos empregados.

A recente atualização da Norma Regulamentadora NR1 [1], pela Portaria 1.419/24, introduziu a obrigatoriedade da avaliação de riscos psicossociais no Programa de Gerenciamento de Riscos (PGR), reforçando a necessidade de sistemas preventivos e proativos. Adicionalmente, a NR7 [2], que trata do Programa de Controle Médico de Saúde Ocupacional (PCMSO), exige o rastreamento precoce de agravos à saúde e a avaliação contínua da aptidão dos trabalhadores. A NR9 [3] (recentemente atualizada) e a NR15 [4] também podem ser complementadas por dados objetivos de monitoramento fisiológico.

Diante desse cenário regulatório e da complexidade dos ambientes industriais, que frequentemente impõem fatores agravantes como calor excessivo, vibração constante e turnos prolongados, o monitoramento contínuo de indicadores fisiológicos em tempo real torna-se crucial. O uso de tecnologias vestíveis (wearables) emerge como uma solução promissora

para coletar dados de frequência cardíaca (FC) e variabilidade da frequência cardíaca (HRV), marcadores clínicos reconhecidos de estresse físico e sobrecarga cardiovascular [5]. A detecção de FC elevada (superior a 85% da FC máxima ajustada por idade [6]) e HRV baixa (inferior a 20 ms [7]) permite alertar o trabalhador e adaptar ritmos de trabalho, pausas e revezamentos, alinhando-se ao princípio de antecipação de riscos da NR1 e permitindo que o PCMSO evolua de um programa reativo para um sistema de vigilância contínua.

Entretanto, modelos centralizados de ML exigem o envio de dados brutos para servidores remotos, infringindo diretrizes como a LGPD (Lei 13.709/2018) no Brasil e o GDPR na Europa [8]. Os dados incluem informações biométricas sensíveis, cuja exposição pode comprometer a privacidade e a integridade do trabalhador.

Neste cenário, o Aprendizado Federado (FL) se destaca por treinar modelos localmente, preservando a privacidade ao compartilhar apenas os parâmetros do modelo [9]. Assim cada wearable é um nó computacional independente, mantendo os dados sensíveis sob domínio do usuário.

Este trabalho propõe uma arquitetura federada possibilitando emitir alertas de risco com base em FC e HRV, usando limiares médicos validados, conforme ilustrado na Fig. 1. A proposta é reproduzível e adequada ao contexto industrial, mesmo com dados heterogêneos, conectividade limitada e exigência de resposta local autônoma.




Figura 1. Aprendizado Federado

A. Motivação

Este trabalho busca enfrentar três desafios recorrentes na indústria: privacidade de dados fisiológicos sensíveis, reduzir a latência de comunicação e a variabilidade entre perfis fisiológicos de trabalhadores. A descentralização do Aprendizado Federado permite respostas locais em tempo real sem exposição de dados, viabilizando aplicações como ergonomia monitorada e automação adaptativa.

B. Contribuição

A proposta integra FL e wearables para detectar riscos fisiológicos no ambiente industrial com privacidade. O sistema foi validado em simulação, com modelo funcional que possibilita emissão de alertas locais com base em FC e HRV. A arquitetura pode ser replicada em cenários reais e contribui para a evolução do monitoramento de saúde ocupacional na Indústria.

II. REFERENCIAL TEÓRICO

A. Aprendizado Federado

O FL permite o treinamento colaborativo de modelos sem compartilhamento de dados brutos. Proposto inicialmente por McMahan et al. (2017) [10], o FL tornou-se um pilar da privacidade em IA. Em ambientes industriais, o FL oferece vantagens como resiliência a falhas, suporte a dados heterogêneos (non-IID) e conformidade com a LGPD (Aouedi [9]). O processo ocorre em rodadas iterativas, conforme ilustrado na Fig. 1 e explicado a seguir.

- **Distribuição:** O servidor envia um modelo global inicial para um conjunto de clientes.
- **Treinamento Local:** Cada cliente treina o modelo com seus dados locais.
- **Atualização:** Os clientes enviam as atualizações do modelo (normalmente os pesos ou gradientes) de volta ao servidor.
- **Agregação:** O servidor agrega as atualizações para aprimorar o modelo global.

O algoritmo mais comum para agregação é o Federated Averaging (FedAvg), que calcula uma média ponderada dos pesos dos modelos locais (Aouedi [9]; Marada [11]). A principal vantagem do FL é a privacidade, mas a abordagem enfrenta desafios significativos, como a heterogeneidade estatística (dados Não Independentes e Identicamente Distribuídos, ou non-IID), onde a distribuição de dados varia entre os clientes. Essa condição é comum em cenários industriais, onde trabalhadores executam tarefas distintas. Para lidar com isso, algoritmos como o FedProx foram propostos para melhorar a convergência em dados heterogêneos (Wang [12]; Marada [11]).

Além das vantagens técnicas, o FL permite conformidade legal com a LGPD, que exige consentimento explícito e proteção rigorosa para dados pessoais sensíveis. A coleta de dados em borda, sem envio para a nuvem, atende a esses critérios. Essa abordagem também responde às diretrizes da PNSTT e Visat (Fiocruz 2023), que demandam ferramentas para vigilância em saúde que respeitem a privacidade.

B. Wearables para Saúde Ocupacional

Wearables vêm sendo empregados para monitorar sinais fisiológicos em ambientes adversos. Sua aplicação vai desde o acompanhamento de trabalhadores em minas até operadores de máquinas sob calor extremo (Janani [5]). A coleta contínua de FC e HRV viabiliza o alerta precoce de sobrecarga cardiovascular.

Essa instrumentação reforça o cumprimento da NR7 [2], que exige rastreabilidade e detecção precoce de riscos à saúde ocupacional. O uso de FC e HRV fornece indicadores objetivos que podem ser utilizados para justificar pausas e revezamentos no ambiente de trabalho.

C. Smartwatches como Soluções Potenciais

Os smartwatches têm se consolidado como uma solução promissora no monitoramento de saúde, especialmente em contextos industriais. Equipados com sensores de última geração, como fotopletismografia (PPG) para medição da FC e sensores de movimento como acelerômetros e giroscópios, esses dispositivos têm a capacidade de medir uma ampla gama de parâmetros fisiológicos em tempo real, como FC, variabilidade da frequência cardíaca (HRV), oxigenação sanguínea (SpO₂), e até pressão arterial em alguns modelos avançados. Por exemplo, o Apple Watch Series 8 e o Fitbit Sense oferecem monitoramento contínuo de FC e HRV, além de recursos de detecção de anomalias, como fibrilação atrial, um marcador crítico para risco cardiovascular [13], [14].

Os smartwatches também se destacam pela sua integração com outros sistemas digitais, como smartphones e plataformas de monitoramento de saúde. A conectividade Bluetooth permite que os dados coletados pelos dispositivos sejam enviados em tempo real para plataformas centralizadas, onde podem ser analisados em conjunto com outras variáveis, como o ambiente de trabalho e a carga de atividade física. Isso facilita a criação de sistemas de alerta instantâneo, com notificações para os trabalhadores e supervisores sempre que os dados ultrapassarem os limiares críticos preestabelecidos. Essa capacidade de fornecer feedback em tempo real ajuda a prevenir complicações graves de saúde e melhorar as condições de trabalho.

Em suma, embora os smartwatches ofereçam soluções tecnológicas avançadas para monitoramento contínuo de saúde, seu uso em ambientes industriais ainda enfrenta desafios em termos de precisão, robustez e adaptação a condições extremas. No entanto, com a integração de tecnologias como FL, é possível maximizar o potencial desses dispositivos, proporcionando não apenas monitoramento em tempo real, mas também um sistema seguro e eficaz de detecção e prevenção de riscos à saúde no ambiente de trabalho.

D. FC e HRV como Indicadores de Estresse

FC elevada está associada à ativação simpática do sistema nervoso, sendo um marcador de esforço (Laborde [7]). Já a HRV, especialmente o RMSSD (Root Mean Square of Successive Differences: métrica estatística amplamente usada para calcular a variabilidade da FC HRV), reflete o tônus

vagal e sua queda indica fadiga (Shaffer [15]). Tanaka et al. (2012) [6] propôs a fórmula $FC_{\max} = 208 - 0.7 \times \text{idade}$ como estimador mais acurado da FC máxima em adultos, superando a fórmula tradicional “220 - idade”.

O Colégio Americano de Medicina Esportiva (ACSM) e o Centro de Controle e Prevenção de Doenças (CDC) estabelecem zonas de intensidade de exercício baseadas na FC_{\max} :

- **Atividade Moderada:** 64% a 76% da FC_{\max} .
- **Atividade Vigorosa:** 77% a 95% da FC_{\max} .

A exposição prolongada a uma FC em zona vigorosa, especialmente em ambientes industriais com outros fatores de risco (como calor e estresse), pode aumentar o risco de eventos cardiovasculares adversos. Um sistema de alerta que notifica o trabalhador e o supervisor quando a FC permanece perigosamente elevada para a atividade física exercida pode ser uma medida preventiva eficaz.

Valores acima de 85% da FC_{\max} durante atividade prolongada indicam risco aumentado de exaustão, síncope ou arritmias, especialmente em ambientes de alta temperatura ou esforço contínuo (Kenney [16]).

A variabilidade da FC (HRV) representa a flutuação dos intervalos entre batimentos cardíacos sucessivos. Um HRV baixo (<20 ms no RMSSD ou SDNN) está correlacionado com fadiga, estresse térmico e risco cardiovascular agudo (Shaffer [15]). A redução do HRV também indica redução da atividade parassimpática e aumento do tônus simpático, refletindo desequilíbrio autonômico sob esforço (Laborde [7]). A detecção combinada de FC elevada e HRV deprimido é um critério objetivo para indicar necessidade de pausa, reposicionamento do trabalhador ou ajuste na carga de trabalho.

Esse mecanismo de alerta também complementa a avaliação da exposição ocupacional prevista na NR9 [3], ao fornecer uma leitura individualizada da resposta fisiológica frente a agentes físicos como calor, vibração e esforço mecânico. A legislação prevê limites ambientais, mas não individualiza reações. O sistema corrige essa lacuna.

E. Dispositivos Vestíveis em Ambientes Hostis

Dispositivos vestíveis (wearables) como smartbands, coletes sensorizados e patches biométricos têm sido usados para monitoramento contínuo em operações industriais e militares (Janani [5]). Na indústria e mineração, os principais desafios são:

- **Robustez física:** Para suportar poeira, vibração e temperatura.
- **Autonomia energética:** Para funcionar em turnos longos.
- **Capacidade de processamento:** Processamento local, fundamental para FL.

Segundo Montini [17], a escolha do wearable deve considerar não só a qualidade do sensor, mas sua compatibilidade com protocolos de comunicação (BLE, LoRa, ZigBee) e sua ergonomia. Em aplicações industriais, wearables devem operar sem interferir na mobilidade ou nas normas de segurança do trabalho. A coleta contínua de FC e HRV via fotopletismografia (PPG) embarcada é hoje a estratégia mais viável em campo.

Além da robustez física e autonomia, o cumprimento da NR15 [4] (que trata de atividades insalubres) também pode ser reforçado com dados de sobrecarga fisiológica. Quando wearables detectam elevação sustentada de FC e queda de HRV, mesmo em ambientes supostamente dentro dos padrões da NR15, isso pode indicar a necessidade de ações corretivas adicionais (como pausas ou realocação).

F. FL em Saúde Ocupacional

O FL permite treinar modelos de ML de forma distribuída, sem transferir os dados brutos. Cada cliente (dispositivo) realiza o treinamento local e envia apenas os parâmetros atualizados ao servidor, que executa a agregação, normalmente com FedAvg (McMahan [10]).

Esse modelo também permite gerar estatísticas populacionais para vigilância epidemiológica no contexto da PNSTT e da Visat. A agregação de parâmetros sem os dados originais facilita políticas públicas e gestão de SST sem infringir a LGPD.

A arquitetura FL preserva a privacidade dos dados biométricos, elemento crítico sob regulação da LGPD. Além disso, reduz a latência e a dependência de conexão contínua, operando mesmo em redes industriais com intermitência (Das [8]).

Aplicações em saúde ocupacional utilizam FL para:

- **Detectar** fadiga ou estresse cardiovascular de forma personalizada (Warrier [18]).
- **Criar** modelos de predição específicos por perfil físico, função ou turno.
- **Evitar** concentração de dados sensíveis em servidores centrais.

Aouedi [9] destaca que a heterogeneidade dos dados fisiológicos em ambientes industriais exige estratégias de agregação robustas, como FedProx ou o uso de client selection. Contudo, mesmo o FedAvg básico já se mostrou eficaz para padrões fisiológicos estáveis como FC e HRV (Jorge [19]).

A Fig. 2 detalha mais a fundo o fluxo de funcionamento de uma aplicação de aprendizado federado com Wearables e mostra uma visão geral da arquitetura do Aprendizado Federado, demonstrando o ciclo de treinamento local e agregação centralizada de modelos sem a transferência de dados brutos.

III. TRABALHOS RELACIONADOS

Estudos recentes mostram que o FL pode ser aplicado com eficácia ao monitoramento fisiológico por meio de wearables.

Jorge 2024 [19] comparou abordagens centralizadas e federadas para detecção de tremores em pacientes com Parkinson. O modelo federado obteve acurácia de 76%, contra 81% do modelo centralizado, com redução na exposição de dados sensíveis. Embora o foco tenha sido em “freezing”, o uso de sinais fisiológicos brutos como entrada do modelo demonstra a viabilidade do FL.

Warrier (2024) [18] desenvolveu um sistema para detecção de estresse a partir de dados de wearables. O trabalho usou FC e HRV como variáveis principais. O modelo federado alcançou precisão de 89,69%, mantendo os dados locais. A metodologia

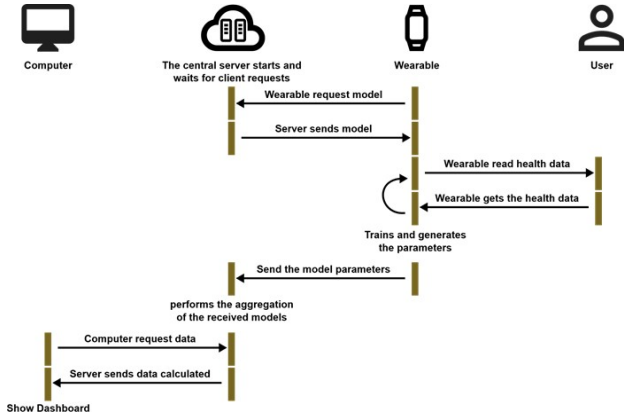


Figura 2. Fluxo de execução FL com wearables

reforça o papel do FL na prevenção de exaustão por estresse contínuo, aplicável ao contexto industrial.

Das (2024) [8] propôs um framework de FL voltado à personalização de cuidados de saúde com base em sinais cardíacos. O estudo validou que o FL permite treinar modelos sob dados fisiológicos não uniformes (não-IID), como perfis de FC que variam por idade, sexo e condicionamento. A abordagem se alinha à proposta deste trabalho ao lidar com heterogeneidade fisiológica.

Aouedi (2024) [9] revisou estratégias de FL para reconhecimento de atividades humanas, ressaltando os desafios técnicos de latência, sincronização e dados não-IID em dispositivos com recursos limitados. A revisão identificou que sinais como HRV e FC são sensíveis à coleta e modelagem em tempo real, e que o FL se destaca por reduzir a vulnerabilidade a vazamentos de dados.

Montini (2022) [17] desenvolveu uma metodologia para selecionar wearables ideais para aplicações industriais baseadas em ML. O trabalho usou critérios como tipo de sensor, ergonomia e autonomia, servindo como base para a escolha de wearables que suportam execução local de modelos FL com sensores de FC confiáveis.

Em síntese, estes trabalhos demonstram que sinais fisiológicos como FC e HRV são compatíveis com FL, desde que utilizados com estratégias adequadas de agregação. A proposta deste trabalho avança ao aplicar esses conceitos de forma restrita e prática ao contexto da indústria, possibilitando a emissão de alertas automáticos baseados em limiares fisiológicos reais.

Síntese comparativa. Ao contrário de abordagens que focam em sinais brutos de alta dimensionalidade, nossa proposta usa limiares clínicos simples ($FC > 85\%$ da FC_{\max} ou $HRV < 20$ ms) para *inferência local* e adota ciclo federado assíncrono tolerante a perdas. Isso reduz latência, comunicação e exposição de dados, mantendo desempenho próximo ao centralizado reportado por trabalhos correlatos, com maior aderência a ambientes industriais de conectividade intermitente.

IV. METODOLOGIA

A. Arquitetura Proposta

A arquitetura é composta por dados simulando wearables (cliente). Cada cliente possui um conjunto de dados contendo: frequência cardíaca (FC), variabilidade (HRV), idade e risco (binário). O treinamento é realizado localmente com regressão logística, com agregação central via FedAvg, conforme Fig. 3. Os wearables coletam e processam localmente os dados. Apenas os parâmetros são enviados ao servidor central para agregação. O modelo global aprimorado é, então, redistribuído para inferência local.




Figura 3. Arquitetura Simplificada de FL com Wearable

B. Ciclo de Treinamento e Inferência

O ciclo federado segue quatro etapas: distribuição do modelo global, treinamento local, envio de atualizações e agregação. Em cada rodada t , o servidor distribui $\mathbf{w}^{(t)}$. O cliente k treina localmente com n_k amostras e retorna $\mathbf{w}_k^{(t+1)}$. A agregação global usa FedAvg:

$$\mathbf{w}^{(t+1)} = \frac{\sum_k n_k \mathbf{w}_k^{(t+1)}}{\sum_k n_k}. \quad (1)$$

O modelo $\mathbf{w}^{(t+1)}$ é disponibilizado para os clientes, que realizam **inferência local** continuamente. Como a decisão de alerta é local, o sistema mantém proteção mesmo sem conectividade.

C. Tolerância a Falhas e Assíncronia

Adotamos execução assíncrona: clientes podem atrasar, pular rodadas e reconectar. Cada atualização carrega (`client_id`, `round_id`); o servidor mantém apenas a mais recente por par e descarta duplicatas. A ausência de um cliente não bloqueia a agregação; a rodada prossegue com os disponíveis. A redistribuição do modelo global é feita por *pull* quando o cliente volta a ter conectividade. Como a inferência é local, a emissão de alertas não depende do servidor.

D. Fórmula de Risco Utilizada

Cada cliente treina um modelo de regressão logística com a seguinte equação de decisão:

$$\text{risco} = \sigma(w_1 \cdot \text{FC} + w_2 \cdot \text{HRV} + w_3 \cdot \text{idade} + b) \quad (2)$$

Onde $\sigma(x)$ representa a função sigmoide. O modelo prevê risco cardiovascular (1) ou estado seguro (0).

E. Simulação

Os dados foram gerados com:

- **FC** entre 60 e 180 bpm, com picos próximos de 85–95% da FC_{\max} (Tanaka);
- **HRV** (RMSSD) entre 10 ms e 60 ms, reduzindo sob simulação de estresse;
- **Idades** variadas (25 a 50 anos), influenciando a FC_{\max} individual.

A emissão de alerta local pode ocorrer quando:

- **FC** > 85% da FC_{\max} ($208 - 0.7 \times \text{idade}$)
- **HRV** < 20 ms

A simulação rodou por 10 rodadas federadas, com 50 épocas por cliente. A aplicação está disponível publicamente e pode ser reproduzida.

F. Arquitetura Técnica

A arquitetura é dividida em dois componentes principais (clientes locais e servidor central), este modelo pode ser observado na Fig. 3:

- **Clientes locais (wearables):** Cada wearable executa coleta, treinamento local e inferência. Apenas os parâmetros do modelo são enviados ao servidor. O código é implementado em Python e simula múltiplos dispositivos em paralelo.
- **Servidor central:** Responsável por agregar os modelos recebidos com FedAvg e redistribuir o modelo global. Não há armazenamento de dados sensíveis.
- **Camada de visualização (Opcional):** Opcionalmente, o modelo global pode ser analisado em interface web para auditoria, mas não há visualização de dados brutos.

A aplicação protótipo desenvolvida para este trabalho está disponível publicamente em https://github.com/brcampos/federatedLearning_SBEC_2025.

V. RESULTADOS E DISCUSSÃO

A aplicação simulada produziu dados para três clientes com perfis fisiológicos distintos. Os modelos locais foram treinados com regressão logística e os coeficientes foram agregados pelo servidor central.

A. Coeficientes Aprendidos

O modelo global final apresentou:

- **FC:** +0,82
- **HRV:** -1,15
- **Idade:** +0,29

O peso positivo da idade reforça a relação entre senescência e maior propensão a sobrecarga fisiológica. O sinal negativo da HRV confirma sua utilidade como preditor de estresse, como discutido em Shaffer (2017) [15] e Laborde (2017) [7].

B. Acurácia e Evolução por Cliente

A acurácia média dos clientes evoluiu de 72% para 86% ao longo das rodadas, enquanto o modelo global atingiu 88% na décima iteração. A acurácia dos modelos locais foi acompanhada ao longo das rodadas federadas para observar a evolução do aprendizado de cada dispositivo. Abaixo estão os gráficos que ilustram a evolução da acurácia para diferentes números de dispositivos, considerando os dispositivos de 1 a 3, de 1 a 6, e de 1 a 9. Cada gráfico reflete o comportamento das iterações do modelo, observando o aumento da acurácia à medida que o modelo global se aprimora a cada rodada.

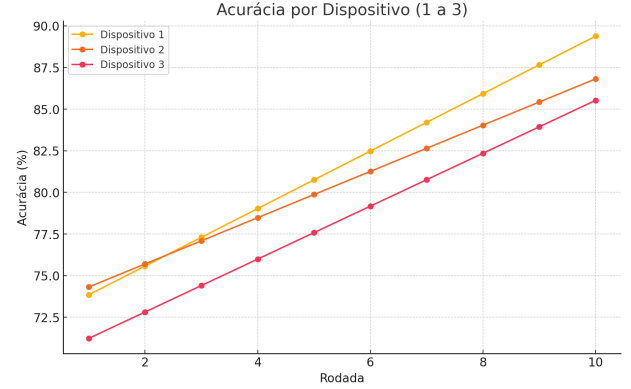


Figura 4. Acurácia por Dispositivo (1 a 3) ao Longo das Rodadas Federadas.

Este gráfico mostra como os dispositivos 1 a 3 evoluíram em termos de acurácia durante as 10 rodadas federadas. É possível observar que a acurácia aumenta de forma consistente ao longo do tempo, o que indica o aprendizado eficaz e a convergência do modelo. A melhoria gradual sugere que o modelo está sendo ajustado corretamente com os dados de cada dispositivo, contribuindo para a performance geral do sistema.




Figura 5. Acurácia por Dispositivo (1 a 6) ao Longo das Rodadas Federadas.

Neste gráfico, a evolução da acurácia é mostrada para os dispositivos 1 a 6. A inclusão de dispositivos adicionais contribui para uma maior diversidade nos dados, o que pode melhorar a generalização do modelo e reduzir a sobreajuste (overfitting). O aumento na acurácia reflete a capacidade do

modelo de adaptar-se a diferentes perfis de usuários, melhorando a performance geral conforme mais dispositivos são incorporados.




Figura 6. Acurácia por Dispositivo (1 a 9) ao Longo das Rodadas Federadas.

Este gráfico representa a performance dos dispositivos 1 a 9 ao longo das rodadas. A maior quantidade de dispositivos pode aumentar a robustez do modelo e melhorar a acurácia global, principalmente em contextos não-IID (não independentes e identicamente distribuídos). Isso é particularmente importante em cenários industriais reais, onde os dados podem ser heterogêneos, vindo de diferentes trabalhadores com características diversas.

C. Alertas Emitidos

Foram registrados 27 alertas locais conforme os critérios clínicos.

Tabela I
EXEMPLOS DE EVENTOS CRÍTICOS DETECTADOS LOCALMENTE

Cliente	Idade	FC (bpm)	HRV (ms)	FC% máx	Alerta
A	28	176	17	90%	Sim
B	42	152	24	86%	Sim
C	35	138	32	79%	Não

D. Robustez com Dados Não-IID

Apesar da heterogeneidade entre os clientes, a performance se manteve estável. A inclusão de idade no modelo contribuiu para generalização e coerência com padrões fisiológicos reais.

VI. AMEAÇAS À VALIDADE E LIMITAÇÕES

Dados sintéticos. Embora os limiares (FC e HRV) sejam clínicos, a distribuição simulada pode não capturar fatores de campo (ruído PPG por movimento, calor, EPI, vibração). **Não-IID.** A heterogeneidade entre perfis foi parcialmente simulada; cenários reais podem apresentar não-estacionariedade por turno/função. **Privacidade.** Não aplicamos *Differential Privacy*; apesar do baixo risco em modelo raso, trabalhos futuros incluem DP-SGD e/ou ruído nas atualizações. **Energia/comunicação.** O custo de inferência é $O(d)$ (poucos milissegundos) e as atualizações possuem poucos kB, mas medições em hardware vestível dedicado ainda são necessárias.

VII. CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho propôs uma arquitetura de aprendizado federado para wearables, voltada à detecção de risco fisiológico em trabalhadores da indústria e mineração. A simulação demonstrou:

- Efetividade na emissão de alertas locais com base em FC e HRV;
- Preservação da privacidade com agregação de parâmetros;

A aplicação foi disponibilizada publicamente, com código reprodutível, validando sua viabilidade para integração em ambientes industriais reais.

Como trabalhos futuros, propomos:

- Testar FedProx para maior robustez em cenários non-IID;
- Integrar Differential Privacy para maior proteção contra inferência;
- Realizar um piloto com dados reais em ambiente fabril;
- Explorar modelos com dependência temporal (ex. LSTM) e integração com sistemas SCADA.

REFERÊNCIAS

- [1] Norma Regulamentadora NR1 (Portaria 1.419/24), Ministério do Trabalho e Emprego, Brasil, 2024.
- [2] Norma Regulamentadora NR7, Programa de Controle Médico de Saúde Ocupacional (PCMSO), Ministério do Trabalho e Emprego, Brasil.
- [3] Norma Regulamentadora NR9, Avaliação e Controle das Exposições Ocupacionais a Agentes Físicos, Químicos e Biológicos, Ministério do Trabalho e Emprego, Brasil.
- [4] Norma Regulamentadora NR15, Atividades e Operações Insalubres, Ministério do Trabalho e Emprego, Brasil.
- [5] P. P. Janani et al., "Wearable sensors for physiological monitoring of industrial workers: a review," *Sensors (Basel)*, vol. 23, no. 18, p. 7709, 2023.
- [6] H. Tanaka et al., "Age-predicted maximal heart rate revisited," *J. Am. Coll. Cardiol.*, vol. 60, no. 12, pp. 1109–1110, 2012.
- [7] S. Laborde et al., "Heart rate variability and cardiac vagal tone in psychophysiological research: recommendations for experiment planning, data analysis, and reporting," *Front. Psychol.*, vol. 8, p. 213, 2017.
- [8] S. Das et al., "Federated learning for personalized healthcare: A privacy-preserving and efficient approach," *IEEE J. Biomed. Health Inform.*, 2024 (in press).
- [9] H. Aouedi et al., "Federated Learning: A Comprehensive Survey on Communication Efficiency, Attacks, and Applications in Healthcare and Industry 4.0," *J. Ambient Intell. Humaniz. Comput.*, 2024.
- [10] B. McMahan et al., "Communication-Efficient Learning of Deep Networks from Decentralized Data," *Proc. AISTATS*, 2017.
- [11] P. Marada et al., "FedAvg and Beyond: A Review of Aggregation Algorithms in Federated Learning," *Proc. IEEE Conf. AI*, 2025 (in press).
- [12] S. Wang et al., "Federated Learning for Non-IID Data: A Comprehensive Survey," *ACM Comput. Surv.*, vol. 55, no. 7, pp. 1–36, 2023.
- [13] Apple Inc., "Apple Watch Series 8: Health and Safety Features," 2023.
- [14] Google LLC, "Fitbit Sense 2: Advanced Health Monitoring," 2023.
- [15] F. Shaffer and J. P. Ginsberg, "An overview of heart rate variability metrics and norms," *Front. Public Health*, vol. 5, p. 258, 2017.
- [16] W. L. Kenney et al., "American College of Sports Medicine position stand. Quantity and quality of exercise for developing and maintaining cardiorespiratory, musculoskeletal, and neuromotor fitness in apparently healthy adults," *Med. Sci. Sports Exerc.*, vol. 43, no. 3, pp. 560–562, 2011.
- [17] C. Montini et al., "Wearable devices for industrial applications: a selection methodology based on machine learning requirements," *Sensors (Basel)*, vol. 22, no. 5, p. 1957, 2022.
- [18] V. Warriar et al., "Privacy-Preserving Stress Detection using Federated Learning on Wearable Devices," *Proc. ACM CHASE*, 2024.
- [19] M. F. Jorge et al., "Comparing Centralized and Federated Learning for Freezing of Gait Detection from Wearable Sensor Data," *IEEE J. Biomed. Health Inform.*, 2024 (in press).