

Sistemas de monitoramento de pacientes com IoMT e aprendizado de máquina em cuidados de saúde

Marcos Vinicius¹, Aline Ciane¹, Gustavo Callou²,
Cleunio França³, Eduardo Tavares³, Thiago Bezerra^{1,3}

¹ Instituto Federal de Pernambuco, Palmares, Brasil

²Departamento de Computação,
Universidade Federal Rural de Pernambuco, Recife, Brasil

³Centro de Informática,
Universidade Federal de Pernambuco, Recife, Brasil

{tvb,cbff,eagt}@cin.ufpe.br, {acgs8,mvvm@}discente.ifpe.edu.br

gustavo.callou@ufrpe.br, thiago.bezerra@palmares.ifpe.edu.br

Abstract. *A Internet das Coisas (IoT) facilita a vigilância e o monitoramento remoto, por meio de redes e protocolos integrados, sendo amplamente utilizada na área da saúde. As instalações médicas estão integrando tecnologias de saúde conectadas para coletar informações dos pacientes, otimizando o diagnóstico, o atendimento e a eficiência operacional. Esta pesquisa apresenta uma estrutura de monitoramento para instalações de serviços médicos, combinando Internet das Coisas Médicas (IoMT) com abordagens de aprendizado de máquina. A solução realiza reconhecimento facial, detecta quedas por meio de padrões de movimento e dispara alertas para cuidadores. Os testes produziram resultados promissores, demonstrando bom desempenho tanto no reconhecimento facial quanto na detecção de quedas.*

Abstract. *Internet of Things (IoT) facilitates remote surveillance and monitoring through integrated networks and protocols, and is widely used in the healthcare sector. Medical facilities are integrating connected health technologies to collect patient information, optimizing diagnosis, care, and operational efficiency. This research presents a monitoring framework for medical service facilities, combining the Internet of Medical Things (IoMT) with machine learning approaches. The solution performs facial recognition, detects falls through motion patterns, and triggers alerts for caregivers. Testing yielded promising results, demonstrating good performance in both facial recognition and fall detection.*

1. Introdução

A rápida expansão da Internet das Coisas (IoT) está transformando a interconexão entre dispositivos físicos e virtuais, aproveitando um conjunto diversificado de tecnologias. Essa evolução tem implicações profundas em diversos domínios, incluindo saúde,

indústria e agricultura [Patel et al. 2016]. A crescente adoção de tecnologias médicas baseadas em IoT tem impulsionado investimentos substanciais, refletindo uma demanda crescente por inovação na área da saúde e no monitoramento remoto de pacientes [Shaik et al. 2023]. Essa tendência levou ao surgimento do conceito de Internet das Coisas Médicas (IoMT). Em ambientes hospitalares, está sendo realizada a integração de sistemas IoMT para otimizar a coleta e transmissão de dados, aprimorando o monitoramento contínuo de pacientes críticos [Patel et al. 2016].

A convergência da IoT e do aprendizado de máquina (ML) introduziu capacidades avançadas de monitoramento, especialmente para idosos. Essas tecnologias possibilitam uma vigilância inteligente e proativa da saúde, identificando e respondendo a condições que podem representar riscos. Câmeras equipadas com algoritmos de ML podem analisar padrões de movimento e comportamentos, distinguindo entre atividades normais e eventos anômalos, como quedas. Essa capacidade permite a geração imediata de alertas, facilitando a intervenção oportuna por parte de cuidadores ou sistemas de saúde [Kulurkar et al. 2023].

Além da detecção de quedas, o reconhecimento facial em sistemas IoMT expande as aplicações na área da saúde. A identificação e o rastreamento contínuos de pacientes garantem que os tratamentos médicos e o monitoramento sejam associados corretamente aos indivíduos. O reconhecimento facial também pode contribuir para avaliações emocionais e cognitivas, analisando expressões faciais para detectar sinais de dor, desconforto ou angústia, o que é particularmente relevante no cuidado a idosos e em aplicações de saúde mental. Algoritmos de ML, treinados com dados de movimentação dos pacientes, podem detectar indicadores precoces de deterioração da saúde, como padrões de movimento irregulares ou períodos prolongados de inatividade. Como resultado, sistemas IoMT podem acionar alertas automaticamente, permitindo que cuidadores intervenham antes que a condição do paciente se agrave.

Este estudo apresenta um sistema de monitoramento de pacientes para ambientes hospitalares que integra IoT e aprendizado de máquina. O sistema realiza reconhecimento facial e detecta padrões de movimento associados a quedas, gerando alertas em tempo real para cuidadores e profissionais de saúde. Ao combinar monitoramento automatizado com notificações inteligentes, a abordagem visa melhorar a segurança dos pacientes e a qualidade do atendimento. Além disso, a integração com sistemas hospitalares permite o envio automático de alertas para enfermeiros e médicos, garantindo uma resposta rápida a situações críticas.

O restante deste artigo está organizado da seguinte forma. A Seção 2 apresenta os trabalhos relacionados disponíveis na literatura. A Seção 3 fornece uma visão geral dos conceitos fundamentais para a compreensão da abordagem proposta. Na Seção 4, a metodologia é explicada. A Seção 5 apresenta as arquiteturas IoMT analisadas, e a Seção 6 demonstra a aplicação prática da solução proposta e apresenta os resultados da avaliação do modelo. Por fim, a Seção 7 conclui este estudo e aponta direções para pesquisas futuras.

2. Trabalhos relacionados

Esta seção apresenta conceitos-chave sobre IoT e aprendizado de máquina aplicados ao monitoramento de pacientes, analisando trabalhos relevantes da literatura. Rajan e Na-

dar [Rajan Jeyaraj and Nadar 2022] propuseram um sistema IoMT para monitoramento fisiológico de idosos, utilizando aprendizado de máquina para detecção de anomalias em sinais vitais, como EEG, ECG, temperatura e pulso, alcançando uma precisão média de 97,5%. Além de monitorar os pacientes, o sistema fornece recomendações para que busquem assistência médica quando necessário.

No contexto do reconhecimento facial aplicado à área da saúde, Masud *et al.* [Masud et al. 2020] desenvolveram um modelo de aprendizado profundo baseado em árvores para reconhecimento facial em sistemas IoMT, integrando computação em nuvem para melhorar a escalabilidade. O modelo atingiu até 99% de precisão em bases de dados públicas como FEI, ORL e LFW, demonstrando maior eficiência em comparação com abordagens convencionais. Bisogni *et al.* [Bisogni et al. 2022] também exploraram o reconhecimento facial, mas com foco na detecção de expressões faciais em tempo real para melhorar os serviços de saúde. Sua abordagem utilizou redes neurais convolucionais (CNN) e imagens faciais em múltiplas resoluções, superando métodos existentes em avaliações públicas.

Altameem *et al.* [Altameem and Altameem 2020] propuseram uma técnica de análise de visualização multimodal (MMVA) para monitoramento de pacientes por meio do reconhecimento de expressões faciais com um modelo CNN de três camadas, atingindo 95,702% de precisão. Já Talaat [Talaat 2023] apresentou um sistema baseado em redes neurais convolucionais profundas (DCNN) para reconhecimento facial e detecção de emoções em crianças autistas, contribuindo para o diagnóstico precoce do autismo. Esse sistema integrou computação em névoa e IoT, minimizando a latência e alcançando uma precisão de 99,99%, apesar do uso de um conjunto de dados relativamente pequeno.

Outro aspecto relevante no monitoramento de pacientes é a detecção de quedas. Doan [Doan 2022] desenvolveu um sistema inteligente para detectar quedas e alertar profissionais de saúde, utilizando a biblioteca MediaPipe Pose para estimativa de postura corporal, combinada com uma rede LSTM (*Long Short-Term Memory*) para classificação das ações dos pacientes. O sistema obteve uma precisão de 96,84%, apresentando vantagens como baixo custo e facilidade de implementação. Koçak [Koçak and Çetin 2021] também explorou a detecção de quedas, propondo um modelo baseado em LSTM para análise de dados de sensores IoT em tempo real. Seu modelo alcançou uma pontuação F1 de 98% e foi integrado a um aplicativo móvel para notificação imediata de cuidadores.

A Tabela 1 resume os principais estudos encontrados na literatura, destacando as estratégias adotadas e suas métricas de desempenho. Observa-se que alguns trabalhos focaram exclusivamente na detecção de quedas [Doan 2022], [Koçak and Çetin 2021], enquanto outros exploraram reconhecimento facial e análise de expressões [Masud et al. 2020], [Bisogni et al. 2022], [Altameem and Altameem 2020], [Talaat 2023] no monitoramento de pacientes.

Diferentemente dos estudos anteriores, que abordam aspectos específicos do monitoramento, este trabalho propõe uma solução mais abrangente, combinando detecção de postura, identificação de quedas e análise de padrões de movimento para avaliar os riscos dos pacientes. Além disso, oferece alertas em tempo real para cuidadores e profissionais de saúde, permitindo respostas imediatas a possíveis incidentes e garantindo um atendimento mais seguro e eficiente.

Tabela 1. Resumo dos trabalhos relacionados

Trabalho	Reconhecimento facial	Detecção Queda	Detecção Pose	Alertas Tempo real	Técnicas ML/DL
Rajan and Nadar	-	-	-	-	ML
Masud et al.	✓	-	-	-	DL baseado em árvore
Bisogni et al.	✓	-	-	-	CNN
Altameem et al.	✓	-	-	-	CNN
Talaat	✓	-	-	-	DCNN
Doan	-	✓	✓	✓	LSTM
Koçak	-	✓	-	✓	LSTM
Este trabalho	✓	✓	✓	✓	ML

3. Fundamentação teórica

Esta seção apresenta conceitos essenciais para a melhor compreensão deste trabalho.

3.1. Arquitetura IoT

A IoT permite o monitoramento remoto por meio de redes existentes, integrando sistemas computacionais para coletar e processar dados em diversas aplicações, como saúde e agricultura. Sua comunicação dinâmica entre dispositivos é essencial para ambientes adversos. Uma arquitetura típica de IoT (Figura 1) é composta por quatro camadas: dispositivo, responsável pela coleta de dados via sensores e microcontroladores; comunicação, que transmite esses dados utilizando protocolos padronizados; processamento e apresentação, que analisam e exibem as informações coletadas [Patel et al. 2016].




Figura 1. Arquitetura básica IoT

A camada de processamento é encarregada de gerenciar, analisar e armazenar os dados coletados. Ela pode realizar agregação, filtragem e computação de dados, muitas vezes utilizando computação em nuvem ou na borda (*edge computing*). Essa camada transforma os dados brutos em informações valiosas, que podem ser usadas para fornecer serviços do sistema ou acionar ações específicas. Além disso, a camada de processamento pode incorporar algoritmos de aprendizado de máquina, análise de dados e inteligência artificial para aprimorar a tomada de decisões e automatizar respostas a eventos.

ou condições específicas. Por fim, a camada de apresentação fornece uma interface para os usuários interagirem com o sistema IoT. Essa camada inclui painéis de controle, ferramentas de visualização, aplicativos móveis e interfaces web que apresentam os dados processados de maneira acessível e intuitiva.

3.2. Algoritmo de Reconhecimento Facial: Local Binary Patterns Histograms (LBPH)

Este trabalho adota o algoritmo *Local Binary Patterns Histograms* (LBPH), implementado via módulo de aprendizado de máquina da biblioteca OpenCV (OpenCV ML), como técnica central para reconhecimento facial. O LBPH é reconhecido por sua simplicidade e robustez frente a variações de iluminação e expressões faciais, sendo apropriado para aplicações em tempo real e ambientes não controlados [Ahonen et al. 2006].

O método baseia-se na comparação da intensidade de cada pixel com seus vizinhos locais, gerando padrões binários convertidos em valores decimais. Esses valores são organizados em histogramas que descrevem as características faciais. Durante o treinamento, os histogramas são associados a identificadores (IDs), e na etapa de predição, a correspondência é determinada com base na menor distância entre histogramas, comumente utilizando a métrica do qui-quadrado.

Em relação a abordagens como Eigenfaces e Fisherfaces, o LBPH apresenta vantagens significativas, como menor sensibilidade à iluminação e ausência de necessidade de normalização global [Ahonen et al. 2006]. Essas propriedades o tornam especialmente adequado para sistemas embarcados e aplicações com restrições computacionais.

3.3. Detecção de Quedas por Estimativa de Pose Corporal

A detecção automatizada de quedas é uma funcionalidade crítica em sistemas inteligentes de monitoramento de pacientes, especialmente em cenários voltados ao cuidado de idosos ou indivíduos com mobilidade comprometida. Abordagens baseadas em visão computacional têm ganhado destaque ao oferecerem soluções não intrusivas, evitando a necessidade de sensores vestíveis ou dispositivos físicos de contato. Estudos recentes demonstram que técnicas de estimativa de pose corporal, utilizando câmeras RGB comuns, podem detectar quedas com alta precisão, sem a necessidade de hardware especializado [Alam et al. 2022].

Neste trabalho, a detecção de quedas é conduzida por meio da análise postural derivada da estimativa da pose corporal, utilizando imagens capturadas por câmeras RGB. A extração dos pontos-chave do corpo humano é realizada com o apoio da biblioteca *cvzone*, que encapsula modelos de estimativa de pose do *MediaPipe*. Esses modelos são capazes de identificar em tempo real até 33 pontos anatômicos relevantes, como cabeça, ombros, quadris, joelhos e tornozelos, fornecendo as coordenadas bidimensionais de cada ponto em relação ao plano da imagem [Lugaresi et al. 2019].

A principal heurística utilizada para inferência de queda consiste na comparação da posição vertical (eixo *y*) da cabeça (*landmark* 0) em relação ao joelho (*landmark* 26). Situações em que a cabeça se encontra em um plano inferior ao dos joelhos (contrariando a configuração esperada em posturas normais) são interpretadas como indícios de uma possível queda. Essa estratégia, embora baseada em uma regra geométrica simples,

tem se mostrado eficaz para a identificação rápida de eventos anômalos de colapso físico [Chen et al. 2021].

É importante destacar que o sistema é projetado para operar com imagens oriundas de duas fontes distintas: (i) fluxos de vídeo capturados em tempo real por câmeras integradas ao sistema embarcado, como o Raspberry Pi com módulo de câmera; e (ii) conjuntos de dados públicos que fornecem imagens ou vídeos previamente rotulados para validação experimental.

4. Metodologia

Esta seção descreve a metodologia adotada para o desenvolvimento de um sistema inteligente de monitoramento de pacientes, com foco na detecção de quedas e no reconhecimento facial. O sistema integra técnicas de IoT e ML, sendo executado em dispositivos embarcados com capacidade de processamento local. A abordagem metodológica é estruturada em três fases principais, conforme ilustrado na Figura 2: (i) aquisição e preparação dos dados, (ii) processamento e inferência dos modelos, e (iii) avaliação quantitativa dos resultados. Na figura, as fases (ii) e (iii) estão destacadas como Etapa 1 e Etapa 2, respectivamente.

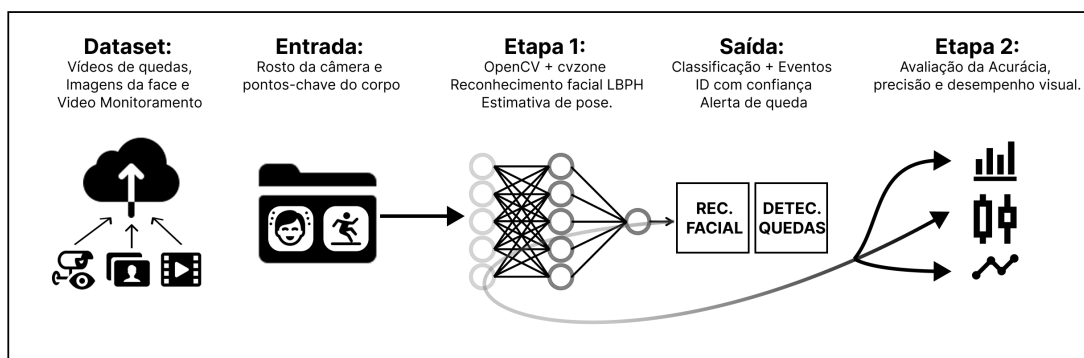


Figura 2. Metodologia

Na etapa de aquisição de dados (Dataset), são utilizadas imagens faciais, vídeos simulando quedas e gravações de vídeo monitoramento. Esses dados podem ser obtidos de repositórios públicos ou capturados em tempo real por meio de câmeras conectadas ao sistema, como aquelas embarcadas em dispositivos como o Raspberry Pi 5. A entrada do sistema inclui imagens do rosto e pontos-chave do corpo humano, extraídos dos fluxos de vídeo por meio de bibliotecas especializadas.

Na Etapa 1 (Processamento e Classificação), os dados são processados com o auxílio das bibliotecas OpenCV e cvzone. O reconhecimento facial é realizado utilizando o algoritmo LBPH, enquanto a detecção de quedas é feita com base na estimativa de pose, por meio da análise de pontos-chave do corpo. O sistema realiza a extração de características, gera representações discriminativas dos rostos (por meio de histogramas) e identifica padrões de movimento abruptos para disparar alertas de queda.

A saída dessa etapa inclui a classificação dos indivíduos (ID com nível de confiança), a detecção de eventos relevantes, como quedas, e o envio de alertas imediatos para os cuidadores. Na Etapa 2 (Análise Quantitativa), os resultados são avaliados

com base em métricas como acurácia, precisão e desempenho visual. Essa avaliação permite validar a eficácia do sistema em diferentes cenários, identificando eventuais falhas e possibilitando ajustes iterativos nos dados de entrada ou nos parâmetros dos modelos.

5. Arquitetura IoMT

As arquiteturas de IoMT são ambientes inteligentes com dispositivos e sensores para monitorar sinais fisiológicos dos pacientes, oferecendo dados em tempo real para apoiar decisões médicas e melhorar o atendimento. Esses sistemas incluem protocolos de comunicação, armazenamento e análise de dados, além de ferramentas de visualização, permitindo o monitoramento remoto da saúde dos pacientes. A arquitetura coleta dados de dispositivos vestíveis e móveis, proporcionando uma visão completa da saúde do paciente [Askar et al. 2022]. A Figura 3 mostra a arquitetura de IoMT adotada, composta por quatro camadas integradas para reconhecimento facial e detecção de quedas.

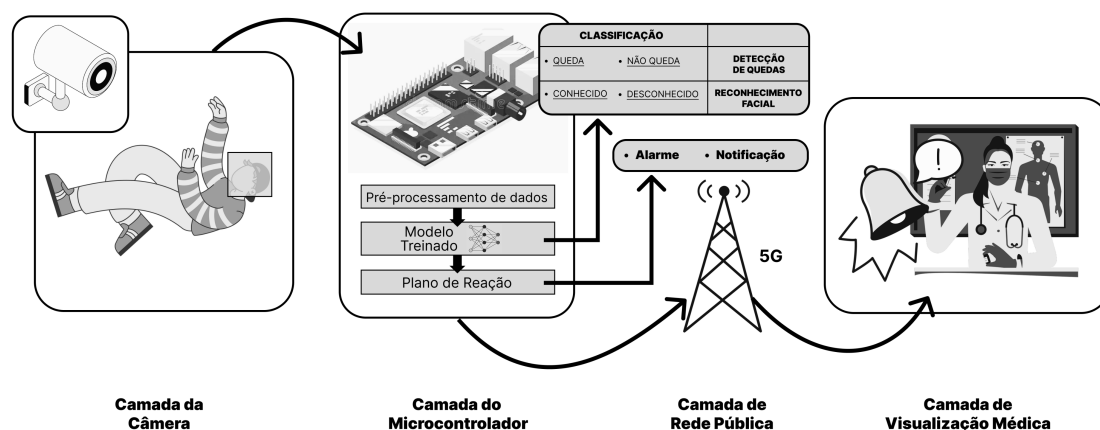


Figura 3. Arquitetura IoMT

A camada de câmera captura dados iniciais, registrando imagens usadas para reconhecimento facial e detecção de quedas, por meio da análise de movimentos e posições corporais. Ela é a interface primária com o paciente, garantindo a coleta precisa das informações. Os dados são então enviados para a camada de microcontrolador, responsável pela execução de algoritmos de aprendizado de máquina. Após o processamento, os dados são transferidos pela rede pública (Internet) para conectividade e armazenamento. A camada de visualização médica permite que médicos e cuidadores acessem e analisem as informações geradas por meio de painéis interativos.

6. Estudo de caso

Esta seção apresenta um estudo de caso da arquitetura IoMT proposta, integrando IoT e aprendizado de máquina para monitorar pacientes e detectar quedas. A Figura 4 ilustra o processo, destacando o reconhecimento facial (Figura 4(a)), que permite a identificação contínua e o monitoramento das atividades dos pacientes.

Os algoritmos de ML garantem o reconhecimento facial preciso sob diferentes condições de iluminação e ângulos de visão. Além disso, o sistema rastreia a posição do

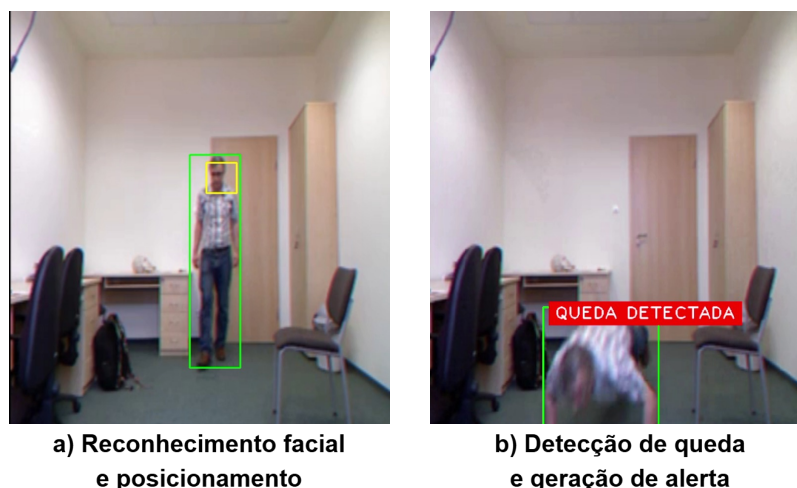


Figura 4. Operação do sistema

paciente dentro do ambiente monitorado, facilitando a supervisão adequada. Ao aproveitar algoritmos de visão computacional e análise de imagens, os movimentos do paciente são continuamente monitorados, permitindo que o sistema detecte o posicionamento e padrões comportamentais que possam indicar um risco elevado de quedas. A Figura 4(b) ilustra o momento em que uma queda é detectada.

Além do reconhecimento facial, o sistema integra algoritmos de reconhecimento de padrões de movimento capazes de identificar comportamentos relacionados a quedas. Após a detecção, um alerta é automaticamente acionado, notificando os cuidadores ou profissionais de saúde em tempo real. Esse processo de identificação individualizada garante que cada incidente seja registrado separadamente, melhorando a confiabilidade e a responsabilidade em cenários críticos.

6.1. Avaliação do modelo

Esta subseção avalia a eficácia do modelo, com foco no reconhecimento facial e na detecção de quedas. A avaliação utiliza métricas de classificação bem estabelecidas, derivadas da matriz de confusão, para quantificar a capacidade do modelo de diferenciar entre classes predefinidas. Para a detecção de quedas, o modelo deve classificar com precisão as instâncias como “Sem Queda”(Classe 0) ou “Queda”(Classe 1), enquanto para o reconhecimento facial, ele deve distinguir entre “Não Reconhecido”(Classe 0) e “Reconhecido”(Classe 1), indicando falha ou sucesso na identificação facial [Visa et al. 2011].

A avaliação de modelos busca minimizar erros de classificação e categorizar entradas com precisão. A matriz de confusão organiza as previsões em verdadeiros e falsos positivos/negativos, permitindo o cálculo de métricas como acurácia, precisão, recall e F1-score. Essas métricas oferecem uma visão detalhada do desempenho do modelo, identificando pontos fortes e áreas de melhoria. A biblioteca Scikit-learn é utilizada para calcular essas métricas, oferecendo ferramentas eficientes e padronizadas para avaliação de modelos de aprendizado de máquina [Pedregosa et al. 2011].

O processo de avaliação utiliza 100 instâncias para cada tarefa, incluindo imagens faciais sob diferentes condições de iluminação e orientações, e dados de detecção

de quedas com indivíduos em diferentes posturas. Para garantir a robustez, o modelo é treinado com conjuntos de dados de acesso público, especificamente o VGG-Face2 [Cao et al. 2018] para reconhecimento facial e o UR Fall Detection Dataset [Kwolek and Kepski 2014] para detecção de quedas. Como esses conjuntos de dados são amplamente utilizados em pesquisas e estão disponíveis publicamente, não foi necessária a participação de seres humanos reais, eliminando preocupações éticas relacionadas à privacidade e ao consentimento.

6.2. Reconhecimento facial

Avaliar o desempenho do sistema de reconhecimento facial é essencial para entender sua confiabilidade em distinguir entre rostos reconhecidos e não reconhecidos. A Tabela 2 resume esses resultados, destacando a capacidade do sistema de classificar corretamente as instâncias de reconhecimento facial. O modelo obteve uma acurácia geral de 95%, indicando que 95 de 100 instâncias foram classificadas corretamente. Para a categoria “Não Reconhecido”, o modelo obteve uma precisão de 0,86 e um recall de 1,00, resultando em um F1-score de 0,92. Isso indica que todos os casos reais de “Não Reconhecido” foram classificados corretamente. No entanto, algumas instâncias previstas como “Não Reconhecido” eram, na verdade, “Reconhecidas”, o que levou a uma leve redução na precisão. Isso sugere que o modelo ocasionalmente classifica rostos reconhecidos como “Não Reconhecido”, causando falsos negativos.

Tabela 2. Métricas de classificação de reconhecimento facial

Relatório de classificação				
	Precisão	Recall	F1-score	Suporte
0	0,86	1,00	0,92	30
1	1,00	0,93	0,96	70
Precisão	-	-	0,95	100,0
Média macro	0,93	0,96	0,94	100,0
média ponderada	0,96	0,95	0,95	100,0

Por outro lado, a categoria “Reconhecido” obteve precisão de 1,00 e um recall de 0,93, resultando em um F1-score de 0,96. Esse resultado indica que todas as instâncias previstas como “Reconhecido” estavam, de fato, corretas, mas 7% dos casos reais de “Reconhecido” foram classificados erroneamente como “Não Reconhecido”.

As métricas de média macro (precisão de 93%, recall de 96% e F1-score de 94%) representam a média simples entre as duas classes, oferecendo uma avaliação equilibrada do desempenho do modelo. Por outro lado, a média ponderada, que leva em conta o desequilíbrio de classes (70 instâncias para a Classe 1 contra 30 para a Classe 0), obteve valores ligeiramente mais altos: 96% de precisão, 95% de recall e 95% de F1-score. O aumento nas pontuações ponderadas sugere que o modelo tem um desempenho melhor para a classe majoritária (“Reconhecido”), influenciando a avaliação geral. Os valores de suporte (30 para a Classe 0 e 70 para a Classe 1) fornecem contexto para a distribuição do conjunto de dados, mostrando que o modelo foi testado em um conjunto de dados onde os rostos reconhecidos eram mais frequentes do que os não reconhecidos. Essa diferença na distribuição das classes é crucial para entender o impacto do desequilíbrio de classes no desempenho do modelo.

6.3. Detecção de quedas

Avaliar a eficácia do sistema de detecção de quedas é fundamental para entender sua confiabilidade em aplicações no mundo real. A Tabela 3 resume esses resultados, demonstrando a capacidade do sistema de distinguir entre eventos de queda e não queda. O modelo obteve uma acurácia geral de 0,97, o que significa que 97% de todas as previsões estavam corretas.

Para o desempenho de cada classe, a Classe 0 (“Sem Queda”) obteve uma precisão de 1,00 e um recall de 0,93, levando a um F1-score de 0,96. Isso indica que, embora todas as instâncias previstas como “Sem Queda” estejam corretas (precisão = 1,00), alguns casos reais de “Sem Queda” foram classificados erroneamente como quedas (recall = 0,93), sugerindo uma leve tendência a superdetectar quedas. Por outro lado, a Classe 1 (“Queda”) mostrou uma precisão de 0,95 e um recall de 1,00, resultando em um F1-score de 0,98. Isso sugere que todas as quedas reais foram corretamente identificadas (recall = 1,00), mas algumas instâncias de “Sem Queda” foram classificadas erroneamente como quedas (precisão = 0,95). Esse compromisso entre precisão e recall reflete o viés do modelo em priorizar a detecção de quedas em vez de reduzir falsos alarmes, uma escolha razoável em aplicações críticas de segurança.

Tabela 3. Métricas de classificação de detecção de queda

Relatório de classificação				
	Precisão	Recall	F1-score	Suporte
0	1,00	0,93	0,96	40
1	0,95	1,00	0,98	60
Precisão	-	-	0,97	100,0
Média macro	0,98	0,96	0,97	100,0
média ponderada	0,97	0,97	0,97	100,0

Além disso, as métricas de média macro e média ponderada resultaram em F1-scores fortes de 0,97, reforçando o desempenho equilibrado do modelo em ambas as classes. A média macro trata cada classe igualmente, enquanto a média ponderada leva em consideração a distribuição do conjunto de dados, onde a Classe 1 contém mais instâncias (60 contra 40). A semelhança entre esses valores sugere que o desequilíbrio de classes teve pouco impacto no desempenho geral. Os valores de suporte (40 para a Classe 0 e 60 para a Classe 1) fornecem informações sobre a composição do conjunto de dados. Com mais casos de queda do que casos de “Sem Queda”, o modelo foi treinado em um conjunto de dados que reflete cenários do mundo real, onde as quedas são mais frequentes na população alvo.

7. Conclusão

Este artigo apresentou o desenvolvimento e a implementação de um sistema de monitoramento de pacientes para centros de saúde, integrando tecnologia IoT, visão computacional e aprendizado de máquina (ML). O sistema foi projetado para reconhecer pacientes por meio de reconhecimento facial e detectar padrões de movimento associados a quedas, utilizando câmeras equipadas com visão computacional para enviar alertas em tempo real para cuidadores e profissionais de saúde.

A validação experimental confirmou a confiabilidade do sistema, demonstrando sua viabilidade e eficácia em cenários práticos. Os resultados foram promissores, com o sistema alcançando 95% de precisão no reconhecimento facial e 97% de acurácia na detecção de quedas. Essas métricas de desempenho indicam que o sistema pode distinguir com precisão entre indivíduos e identificar efetivamente incidentes de quedas, minimizando falsos alarmes enquanto garante intervenções em tempo hábil. Além de seu desempenho técnico, o sistema proposto demonstra versatilidade, tornando-se adequado tanto para ambientes de saúde institucionais quanto para monitoramento domiciliar. Sua capacidade de fornecer previsões precisas e permitir acompanhamento contínuo diário aprimora sua praticidade, especialmente para pacientes idosos ou indivíduos com deficiências de mobilidade.

Ao automatizar o monitoramento de pacientes e fornecer alertas em tempo real, o sistema contribui para a melhoria da segurança dos pacientes, redução da carga de trabalho dos cuidadores e incentivo a intervenções proativas de saúde. Pesquisas futuras poderiam explorar aprimoramentos na robustez do modelo, integração com sensores vestíveis e adaptação para aplicações mais amplas na área da saúde.

Referências

- Ahonen, T., Hadid, A., and Pietikainen, M. (2006). Face description with local binary patterns: Application to face recognition. *IEEE transactions on pattern analysis and machine intelligence*, 28(12):2037–2041.
- Alam, E., Sufian, A., Dutta, P., and Leo, M. (2022). Vision-based human fall detection systems using deep learning: A review. *Computers in biology and medicine*, 146:105626.
- Altameem, T. and Altameem, A. (2020). Facial expression recognition using human machine interaction and multi-modal visualization analysis for healthcare applications. *Image and Vision Computing*, 103:104044.
- Askar, N. A., Habbal, A., Mohammed, A. H., Sajat, M. S., Yusupov, Z., and Kodirov, D. (2022). Architecture, protocols, and applications of the internet of medical things (iomt). *Journal of Communications*, 17(11).
- Bisogni, C., Castiglione, A., Hossain, S., Narducci, F., and Umer, S. (2022). Impact of deep learning approaches on facial expression recognition in healthcare industries. *IEEE Transactions on Industrial Informatics*, 18(8):5619–5627.
- Cao, Q., Shen, L., Xie, W., Parkhi, O. M., and Zisserman, A. (2018). Vggface2: A dataset for recognising faces across pose and age. In *2018 13th IEEE international conference on automatic face & gesture recognition (FG 2018)*, pages 67–74. IEEE.
- Chen, K., Zhang, D., Yao, L., Guo, B., Yu, Z., and Liu, Y. (2021). Deep learning for sensor-based human activity recognition: Overview, challenges, and opportunities. *ACM Computing Surveys (CSUR)*, 54(4):1–40.
- Doan, T.-N. (2022). An efficient patient activity recognition using lstm network and high-fidelity body pose tracking. *International Journal of Advanced Computer Science and Applications*, 13(8).

- Koçak, H. and Çetin, G. (2021). A deep learning-based iot implementation for detection of patients' falls in hospitals. In *Trends in Data Engineering Methods for Intelligent Systems: Proceedings of the International Conference on Artificial Intelligence and Applied Mathematics in Engineering (ICAIAME 2020)*, pages 465–483. Springer.
- Kulurkar, P., kumar Dixit, C., Bharathi, V., Monikavishnuvarthini, A., Dhakne, A., and Preethi, P. (2023). Ai based elderly fall prediction system using wearable sensors: A smart home-care technology with iot. *Measurement: Sensors*, 25:100614.
- Kwolek, B. and Kepski, M. (2014). Human fall detection on embedded platform using depth maps and wireless accelerometer. *Computer methods and programs in biomedicine*, 117(3):489–501.
- Lugaresi, C., Tang, J., Nash, H., McClanahan, C., Uboweja, E., Hays, M., Zhang, F., Chang, C.-L., Yong, M. G., Lee, J., et al. (2019). Mediapipe: A framework for building perception pipelines. *arXiv preprint arXiv:1906.08172*.
- Masud, M., Muhammad, G., Alhumyani, H., Alshamrani, S. S., Cheikhrouhou, O., Ibrahim, S., and Hossain, M. S. (2020). Deep learning-based intelligent face recognition in iot-cloud environment. *Computer Communications*, 152:215–222.
- Patel, K. K., Patel, S. M., and Scholar, P. (2016). Internet of things-iot: definition, characteristics, architecture, enabling technologies, application & future challenges. *International journal of engineering science and computing*, 6(5).
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., et al. (2011). Scikit-learn: Machine learning in python. *the Journal of machine Learning research*, 12:2825–2830.
- Rajan Jeyaraj, P. and Nadar, E. R. S. (2022). Smart-monitor: Patient monitoring system for iot-based healthcare system using deep learning. *IETE Journal of Research*, 68(2):1435–1442.
- Shaik, T., Tao, X., Higgins, N., Li, L., Gururajan, R., Zhou, X., and Acharya, U. R. (2023). Remote patient monitoring using artificial intelligence: Current state, applications, and challenges. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 13(2):e1485.
- Talaat, F. M. (2023). Real-time facial emotion recognition system among children with autism based on deep learning and iot. *Neural Computing and Applications*, 35(17):12717–12728.
- Visa, S., Ramsay, B., Ralescu, A. L., and Van Der Knaap, E. (2011). Confusion matrix-based feature selection. *Maics*, 710(1):120–127.