

ARTIGO ORIGINAL

Sistema inteligente para prevenção de doenças ocupacionais na indústria

Intelligent system for occupational disease prevention in the industry

Agda B. G. Costa ¹, Matheus A. Rodrigues ¹, Wilson S. Melo Jr. ¹,
Charles B. Prado ¹

¹Instituto Nacional de Metrologia, Qualidade e Tecnologia – Inmetro

*abcosta@colaborador.inmetro.gov.br, {macaciorodrigues@inmetro.gov.br, wsjunior@inmetro.gov.br, cbprado@inmetro.gov.br}

Recebido: 23/08/2023. Revisado: 12/04/2024. Aceito: 25/04/2024.

Resumo

As doenças ocupacionais são um problema global que gera diversos prejuízos. Algumas delas podem ser evitadas se o trabalhador tiver um limite de tolerância para realizar atividades laborais, assim, evitando a fadiga. Realizar a troca de atividade depois de um tempo, propondo um esforço físico distinto, ajuda o corpo a restabelecer, mitigando o risco de lesão. Propõe-se um sistema inteligente para monitoramento de trabalhadores na realização de suas tarefas, visando prevenir doenças ocupacionais. Um dispositivo IoT que possui sensor acelerômetro pode ser usado para coletar dados das atividades dos trabalhadores. Os dados são avaliados por um sistema que implementa o reconhecimento da atividade, onde o foco é limitar o tempo máximo de execução. Ao identificar o limite de tolerância de uma tarefa, o sistema emite um alerta para que seja realizada a troca de atividade. Na ausência de outra atividade, um período de pausa será necessário para não sobrecarregar o corpo. Os resultados são promissores e apresentam acurácia de 93,12% para o reconhecimento da atividade. Para a troca de atividade, a acurácia atinge 85,36%. Com base no experimento computacional realizado, a implementação deste dispositivo IoT no ambiente laboral pode melhorar a saúde e segurança no trabalho.

Palavras-Chave: Acelerômetro; Doença ocupacional; DORT; IoT; Trabalhador.

Abstract

Occupational disease is a global problem that causes various damages. Some of these can be avoided if the worker has a tolerance limit for performing work activities, thus avoiding fatigue. Performing a change of activity after a while, proposing a different physical effort, helps the body to recover, mitigating the risk of injury. A smart system is proposed to monitor workers' performance of their tasks, aiming to prevent occupational diseases. An IoT device equipped with an accelerometer sensor can be used to collect data on workers' activities. The data is evaluated by a system that implements activity recognition focusing on limiting the maximum execution time. When identifying the tolerance limit for a task, the system issues an alert for an activity change. In the absence of another activity, a break period will be necessary to avoid the body stress. The results are promising and present an accuracy of 93.12% for recognizing the activity. For the activity change, the accuracy reaches 85.36%. Based on the computational experiment conducted, implementing this IoT device in the workplace can improve health and safety.

Keywords: Accelerometer; IoT; Occupational disease; WMSD; Worker.

1 Introdução

Doenças e distúrbios relacionados ao trabalho constituem um grande problema global e afetam as sociedades, organizações e indivíduos. Em 2019, os custos atribuídos às doenças ocupacionais foram estimados globalmente em torno de 3,9% do Produto Interno Bruto (Lind et al., 2020). Os trabalhadores estão continuamente expostos a uma ampla gama de riscos de segurança e saúde que aumentam o potencial de doenças ocupacionais e podem gerar até mesmo incapacidade para o trabalho (Kim et al., 2019). Distúrbios osteomusculares relacionados ao trabalho (DORTs) estão entre os problemas mais comuns de saúde relacionados ao ambiente laboral (Vega-Barbas et al., 2019). As dores provocadas pelas DORTs podem ser incapacitantes, afastando o profissional do trabalho ou obrigando a troca de sua função (Low et al., 2019). Atualmente, o uso do equipamento de proteção individual é a principal forma dos trabalhadores prevenirem doenças, mas estes são escassos e nem sempre apresentam resultados efetivos (Lind et al., 2020; Ferraro et al., 2018).

A Indústria 4.0 é a nova revolução industrial centrada em sistemas ciber-físicos. A conexão em tempo real de sistemas físicos e digitais, juntamente com novas tecnologias facilitadoras, modifica a maneira como o trabalho é feito e, portanto, como o trabalho pode ser gerenciado (Olsen e Tomlin, 2020; Jiang et al., 2022). O uso de novas tecnologias da informação, em especial aquelas pervasivas, pode constituir uma alternativa promissora para obtenção e compartilhamento de informações sobre a saúde de um trabalhador e os riscos relacionados às suas atividades. Aliadas a recursos já disponíveis, estas tecnologias se tornam um complemento para a detecção e prevenção de doenças ocupacionais (Ferraro et al., 2017).

A coleta, análise e monitoramento contínuo das métricas de segurança dos trabalhadores usando tecnologias IoT ajudam a mitigar os riscos para a saúde no trabalho (Awo-lusi et al., 2019; Jiang et al., 2022). Dispositivos *wearables* combinados com diferentes sensores podem ser usados para monitoramento fisiológico, detecção ambiental, detecção de proximidade e rastreamento de localização com o intuito de prevenir perigos à segurança e saúde ocupacional (Nnaji et al., 2021). Os *smartwatches* e *smartphones* de hoje têm muitos sensores internos (como por exemplo acelerômetros) e são tecnologias acessíveis. Graças a esses sensores, estes dispositivos de fácil utilização são amplamente empregados em estudos atuais de reconhecimento de atividade humana (RAH) (Balli et al., 2019; Lima et al., 2019; Grouios et al., 2023; Martins, 2019). A principal vantagem da aplicação dessas tecnologias é permitir o monitoramento contínuo dos movimentos e também do estado fisiológico de um usuário (por exemplo, frequência cardíaca, pressão arterial e temperatura corporal), fornecendo *feedback* em tempo real (Choi et al., 2017). O monitoramento de diferentes parâmetros ambientais também é fundamental para manter o controle das atividades dentro dos níveis aceitáveis e prover melhores condições de trabalho a um colaborador (Wu et al., 2019). Câmeras de vigilância de alta resolução podem ser usadas para monitoramento do ambiente laboral, produzindo informação para análise em tempo real (Nozaki et al., 2018).

Uma das possíveis formas de se utilizar tecnologias 4.0

na prevenção de DORTs consiste em gerenciar de forma automática o tempo máximo de realização de uma atividade repetitiva. Realizar atividade que exigem muito esforço físico por um tempo prolongado pode rapidamente levar o corpo à exaustão. Portanto, alternar o tipo de atividade com a frequência adequada ajuda o corpo a recuperar suas condições normais de trabalho, evitando que chegue a uma fadiga. Quando este controle não é feito de forma adequada, a incidência de lesões afeta diretamente o trabalhador, que fica inapto para o trabalho, e também a empresa, que acaba custeando despesas indiretas relacionadas às doenças ocupacionais. O monitoramento das atividades laborais através de sensores pode auxiliar na prevenção de DORTs, emitindo um alerta quando o trabalhador chegar ao limite de tempo de execução de uma atividade. Além disso, responsáveis pela segurança no trabalho podem monitorar esses parâmetros de forma remota e ter acesso a dados históricos, possibilitando apontar melhores soluções.

Este trabalho propõe uma solução baseada em RAH para detectar a correta troca de atividades laborais ou pausas temporárias no âmbito laboral através do uso de acelerômetros, com o auxílio de dispositivos IoT simples, como *smartphones* e *smartwatches*. Usando essas tecnologias para o monitoramento das atividades, o trabalhador pode ser notificado quando houver a necessidade de troca, evitando chegar à exaustão. Desse modo pode-se minimizar o surgimento de uma doença ocupacional.

As principais contribuições científicas deste artigo são:

- Propomos um sistema inteligente que monitora a atividade de um trabalhador e auxilia na prevenção de doenças ocupacionais, em especial as DORTs. Este sistema emprega tecnologias IoT de sensoriamento e estratégias de RAH para controlar o tempo despendido em atividades repetitivas. Deste modo é possível sinalizar corretamente o momento de troca de atividade, prevenindo lesões por esforço;
- Implementamos um experimento computacional para simular e avaliar a viabilidade da solução proposta. O experimento se baseia em um *dataset* de RAH disponível na literatura e compara o desempenho de três classificadores de *machine learning*: KNN, SVM e Regressão Logística. A análise é organizada em duas fases distintas, e apresenta resultados promissores;
- Apresentamos uma discussão abrangente sobre a ideia da aplicação do sistema inteligente, dificuldades de implementação, requisitos necessários, e desafios envolvidos, os quais servem como base para trabalhos futuros e também como referência para outros pesquisadores que desenvolvem temas correlatos.

As próximas seções estão distribuídas da seguinte forma: a Seção 2 aborda os trabalhos relacionados ao tema, a Seção 3 apresenta a proposta de metodologia, a Seção 4 descreve os resultados experimentais, e por fim a Seção 5 apresenta as conclusões e trabalhos futuros.

2 Trabalhos Relacionados

2.1 DORTs

A doença ocupacional, também chamada de doença profissional, está definida no artigo 20, item I da Lei n. 8.213 de 24 de julho de 1991 como a enfermidade produzida ou desencadeada pelo exercício do trabalho peculiar a determinada atividade e constante da relação elaborada pelo Ministério do Trabalho e da Previdência Social. Vale ressaltar que a mesma Lei esclarece que toda doença ocupacional é classificada como um acidente de trabalho (Brasil, 1991). Registros do Anuário Estatístico da Previdência Social mostram que no ano de 2020 houve um total de 30.599 afastamentos decorrentes de doenças do trabalho, sendo este um aumento considerável em comparação aos afastamentos dos anos de 2018 e 2019, que ficaram em 10.597 e 10.034, respectivamente (Brasil, 2020).

DORTs são um conjunto de doenças causadas por alta repetição, posturas inadequadas, sessão prolongada de sobrecargas que fadigam o corpo e afetam músculos, tendões, nervos e vasos, reduzindo a capacidade de recuperação, e que têm relação direta com as exigências das tarefas e o ambiente laboral (Alberto et al., 2018; ANAMT, 2015; Low et al., 2019; Vega-Barbas et al., 2019). DORTs são comuns em muitas atividades laborais, constituindo 40% dos custos globais de compensação de acidentes e doenças ocupacionais (Lind et al., 2020). A incidência anual de DORTs no mundo industrializado é responsável por um terço a um quarto de todas as doenças ocupacionais, tornando estes transtornos a forma mais cara de inaptidão no local de trabalho (Alberto et al., 2018). Além disso, DORTs são responsáveis por 64% do número total de profissionais associados a casos de transtorno laboral (Alberto et al., 2018).

Cerca de 30 doenças são denominadas como DORTs. Alguns exemplos são: tendinite, fibromialgia, bursite e lesões. As dores provocadas pelas doenças podem ser incapacitantes, afastando o profissional do trabalho (ANAMT, 2015). Podem surgir dores e inflamações nas articulações dos punhos, cotovelos e ombros. Sensação de perda de força, dores, câibras e tremores dos músculos são comuns. Esse quadro pode se apresentar de forma leve ou mais intensa, com importante repercussão na atividade do trabalhador (Hugo Sefrian et al., 2019).

Os métodos existentes relacionados a segurança do ambiente de trabalho e usados para detectar perigos ou monitorar o comportamento dos trabalhadores têm muitas vezes se mostrado inadequados, pois são baseados apenas em observação subjetiva (Choi et al., 2017; Nnaji et al., 2021). Nesses métodos, a tomada de decisão usualmente parte apenas de uma análise visual, e na maioria dos casos o profissional em campo nem sempre é capaz de capturar todos os movimentos, principalmente quando se trata de um trabalho não rotineiro (Low et al., 2019). Métodos de observação são fáceis de usar, baratos e amplamente acessíveis, mas são relativamente pobres em termos de confiabilidade (Vega-Barbas et al., 2019).

2.2 Tecnologias de Sensoriamento

As tecnologias 4.0 têm o potencial de aumentar a segurança do trabalhador por meio de coleta eficiente de dados, análise e fornecimento de informações em tempo real so-

bre segurança e riscos da saúde pessoal. A aplicação da tecnologia pode abrir uma nova porta para a gestão de segurança e saúde ocupacional (Nnaji et al., 2021; Jiang et al., 2022).

As tecnologias IoT estão sendo amplamente difundidas em diversos setores industriais devido a uma combinação de desempenho técnico crescente com a redução dos preços de compra. Assim, novas ferramentas são avaliadas para adoção em novos campos de aplicação, como segurança no trabalho (Gnoni et al., 2020). *Wearables* são dispositivos projetados para serem usados como acessórios e são considerados um subconjunto de IoT (Awolusi et al., 2019). A vantagem dos dispositivos *wearables* é que eles permitem com facilidade monitorar o desempenho humano continuamente e em ambientes fora de um laboratório ou clínica (Chander et al., 2020). O uso de tecnologias *wearable* no local de trabalho pode ser uma solução de sucesso para o monitoramento do movimento humano, especialmente para ocupações de alto risco. Estudos existentes indicam que a tecnologia tem o potencial para melhorar a segurança e a saúde dos trabalhadores (Nnaji et al., 2021). Eles podem fornecer dados objetivos e em tempo real, que por sua vez permitem tomar decisões eficientes e proativas, mostrando os primeiros índices de alerta de problemas e constatação de insegurança para os trabalhadores (Awolusi et al., 2019; Jayasree e Kumari, 2020; Vega-Barbas et al., 2019).

A coleta de dados no ambiente laboral com um sistema IoT visa abordar não apenas requisitos tecnológicos (como funcionalidades, por exemplo), mas também as necessidades do usuário, com uma abordagem centrada no ser humano, implementando conforto e leveza no dispositivo. Ao projetar tecnologias *wearables*, é importante compreender as necessidades de usuários ou consumidores em potencial para que de fato o dispositivo seja eficaz na seleção de informações e promoção de melhorias (Ferraro et al., 2017; Vega-Barbas et al., 2019). Receber notificações sobre o condicionamento físico dos trabalhadores pode salvá-los de problemas graves em caso de emergência. Portanto, é possível usar essas tecnologias para diminuir a taxa de doenças dos trabalhadores (Jayasree e Kumari, 2020). A redução do risco de lesões e o aumento da satisfação, bem-estar e produtividade dos funcionários foram identificados como potenciais vantagens do uso de dispositivos *wearable* no local de trabalho (Chander et al., 2020).

Algumas barreiras, incluindo preocupações em relação a confiabilidade e durabilidade do sensor, a relação custo/benefício do uso constante do dispositivo, manutenção, possíveis falhas, requisitos de boas práticas de fabricação e sobrecarga das informações, são descritas como desafios que a ciência ainda precisa investigar (Lind et al., 2020; Ferraro et al., 2017; Chander et al., 2020).

2.3 Reconhecimento de Atividade Humana

O reconhecimento da atividade humana (RAH) é a tecnologia-chave de interação humano-computador e análise da atividade humana. A tarefa básica do RAH é selecionar o sensor apropriado e implantá-lo para monitorar e capturar a atividade do usuário (Zhang et al., 2019; Lima e Souto, 2020; Grouios et al., 2023). A aplicabilidade de *machine learning* em RAH se baseia em um método de análise

de dados que automatiza a construção de modelos, podendo identificar padrões e tomar decisões com o mínimo de intervenção humana (Lima et al., 2019; Zimmermann, 2019). Com o uso de sensores, câmeras, acelerômetros, entre outros, um sistema RAH tem por tarefa identificar as atividades que uma pessoa realiza em um determinado momento. As informações coletadas pelos sensores e os dados do usuário são processados por algoritmos de aprendizado de máquina para identificar a atividade humana realizada (Martins, 2019; Zimmermann, 2019).

O uso de tecnologias 4.0 em RAH no âmbito laboral pode desenvolver a conscientização dos trabalhadores sobre condições inseguras, ajudar a eliminar perigos na fase de projeto através do gerenciamento do local de trabalho, reduzir os DORTs, facilitar a investigação de acidentes, melhorar a visualização dos riscos e aperfeiçoar as inspeções de segurança (Chung et al., 2020; Nnaji et al., 2021; Yeou et al., 2020).

3 Proposta de monitoramento inteligente para prevenção de DORTs

O presente estudo visa contribuir com a área de saúde e segurança no trabalho, propondo o uso de uma solução baseada em RAH dentro do âmbito laboral. Uma doença ocupacional pode ser consequência de inúmeros fatores, que incluem movimentos repetitivos, sobrecarga de trabalho, ritmo de trabalho intenso, móveis e equipamentos incômodos, postura inadequada e exposição a vibrações. Portanto, busca-se trabalhar com a prevenção dessas doenças, sabendo que elas não tem cura.

Nossa proposta consiste em um sistema inteligente de gerenciamento e controle das trocas de atividades realizadas por um trabalhador, delimitando um limite de tempo máximo para a execução da atividade com o propósito de prevenir lesões. Para o monitoramento do trabalhador em tempo real, o sistema inteligente faz a aquisição de dados de acelerômetros (i.e., valores de aceleração nos eixos x , y e z) descrevendo os movimentos ergonômicos do trabalhador de forma contínua, identifica a atividade e emite uma notificação quando se atinge o tempo limite para sua repetição. O sistema é configurado com um limite de tolerância (LT) em cada atividade, detectando a necessidade de troca de modo a evitar a fadiga do corpo. O LT deve ser predeterminado, sendo fundamentado em uma análise de um profissional de segurança do trabalho. É importante observar que nesta aplicação não há a necessidade de classificação da atividade com precisão, pois o interesse maior é simplesmente detectar corretamente que as atividades são diferentes, e assim gerenciar intervalos que envolvam um esforço físico distinto, para que o corpo consiga se recuperar antes que ocorra uma exaustão.

Conforme a Fig. 1, o trabalhador será monitorado e avaliado continuamente de acordo com seus esforços físicos, sendo estipulado um LT de sobrecarga em atividades repetitivas. Conforme a avaliação do sistema inteligente, pode-se tomar duas decisões:

- i. alternância de atividades com outras tarefas que permitam variar as posturas, os grupos musculares utilizados, ou o ritmo de trabalho;

- ii. pausas para propiciar a recuperação psicofisiológica dos trabalhadores, que devem ser computadas como tempo de trabalho efetivo.

Ambas as medidas de prevenção mencionadas são pautadas na NR 17¹ (Brasil, 2022). O monitoramento pode ser realizado de três formas distintas:

- Em tempo real, enviando algum sinal para o próprio trabalhador, podendo ser por SMS, WhatsApp, sinal sonoro ou vibratório para que ele saiba o momento em que é necessário trocar de atividade ou realizar uma pausa;
- Em tempo real, sendo possível o envio de um alerta para o responsável local, podendo ser o Técnico de Segurança do Trabalho ou o Encarregado, para que através do responsável, seja solicitado ao trabalhador a troca de atividade imediata ou a pausa;
- Avaliação posterior através da análise de um banco de dados em nuvem. Desse modo, a avaliação pode ser realizada com mais clareza, podendo ser feita de modo individual ou por grupo de trabalhadores que exercem uma mesma função. Assim é possível tomar decisões mais assertivas, examinando os dados de acordo com a natureza do serviço executado, uma vez que a doença ocupacional não surge de imediato e sim depois de repetidos esforços ao longo do tempo.

Perante as opções possíveis para realizar este monitoramento, cabe ao responsável pela utilização do sistema inteligente avaliar qual ação melhor se encaixa no ritmo de trabalho e as condições ambientais de cada setor, podendo-se adotar uma ou mais opções simultaneamente.

3.1 Requisitos

Devido à natureza de muitas indústrias, os trabalhadores não estão apenas expostos a ambientes quentes e úmidos, mas também a gases nocivos, sujeira e detritos, altas temperaturas, contato com equipamentos eletricamente carregados, materiais e imersão em água. Estas duras condições de trabalho apresentam um desafio para a operação de qualquer equipamento, incluindo sistemas portáteis de monitoramento. Portanto, é essencial elaborar um sistema capaz de atuar sob tais condições, e que atenda os seguintes requisitos:

- miniaturização do dispositivo, para que não interfira na execução das atividades rotineiras;
- o dispositivo requer robustez, para que suporte as condições adversas do ambiente laboral, e também o uso contínuo;
- comunicação sem fio, para não restringir o deslocamento do trabalhador dentro de uma área monitorada;
- acurácia aceitável, evitando interrupções desnecessárias no trabalho;

¹Norma Regulamentadora N° 17 (NR-17), estabelece parâmetros para permitir a adaptação das condições de trabalho às características psicofisiológicas dos trabalhadores. Além disso, os dispositivos desta regulamentação abordam características de prevenção a doenças na tentativa de garantir qualidade de vida no trabalho, saúde, bem estar, e especialmente segurança.




Figura 1: Mecanismo de monitoramento inteligente do trabalhador e controle de troca de atividade.

- resultados confiáveis, atingindo assim o propósito de prevenção de doenças;
- dar o *feedback* ao trabalhador sobre a análise dos dados, para que ele entenda os riscos envolvidos.

Mais detalhes sobre os requisitos são mencionados nas sessões subsequente.

3.2 Aquisição de dados

Para aquisição dos dados, propõe-se utilizar *smartwatches* ou *smartphones*, que são dispositivos acessíveis, de baixo custo, e que usualmente possuem sensores acelerômetros triaxiais, que tem a capacidade de captar com boa precisão valores de aceleração nos eixos x , y e z . O posicionamento do sensor precisa ser definido conforme a atividade desempenhada pelo trabalhador. A acomodação do sensor não pode atrapalhar a realização das atividades, porém isso pode influenciar na aquisição dos dados. Outro aspecto importante diz respeito à necessidade do uso de dispositivos de sensoriamento pequenos, dotados de comunicação sem fio. Estes permitem que os trabalhadores fiquem cientes dos perigos em tempo real para prevenir a exposição a riscos, sem atrapalhar os movimentos típicos realizados por eles no local de trabalho.

3.3 Pré processamento e aprendizagem de máquina

Os dados brutos gerados por sensores acelerômetros necessitam de tratamento apropriado e pré processamento antes de serem utilizados para monitoramento das atividades de trabalho. Um exemplo disso é a necessidade de dividir os dados referentes à atividade em janelas (podendo ser janela fixa ou deslizante) para se extrair amostras classificáveis. O tamanho da janela deve ser ajustado de modo que os dados sejam representativos.

Uma técnica possível de aplicação em casos de conjuntos de dados desbalanceados seria a Técnica de Sobreamostragem Sintética Minoritária (SMOTE) (Müller e Guido, 2018). O SMOTE é uma estratégia para aumento de amostras pela geração de dados sintéticos para a classe minoritária.

Os valores triaxiais que são captados pelo acelerômetro são transformados em dados estatísticos. Cada janela de dados é convertida em um conjunto de *features*, que devem ser selecionadas conforme o grau de importância para o modelo. Com o conjunto já pré processado, os dados são submetidos a treino e teste, na proporção de 70% e 30%, nessa ordem, conforme outros trabalhos (Müller e Guido, 2018; Martins, 2019; Grouios et al., 2023).

3.4 Definição de métricas e validação

Depois de se realizar a aprendizagem de máquina com um classificador específico, é possível determinar quais as melhores métricas de acordo com o modelo e o que se pretende avaliar. Cada métrica de avaliação tem sua singularidade que deve ser observada em relação ao modelo de classificação testado, considerando sempre qual seria o problema mais crítico para melhor definir a métrica. A matriz de confusão indica os erros e acertos do classificador comparando a predição com o real de cada atividade. Com esses dados é possível analisar quais os pontos mais críticos dentro dos erros apresentados para cada classe e auxiliar na avaliação do modelo de classificação.

A acurácia e o *f1 score* são exemplos de métricas muito usadas em RAH. A acurácia apresenta o desempenho do modelo através da relação entre o número de acertos e total de amostras, possibilitando uma visão geral do resultado. *F1 Score* representa a união entre a Precisão e *Recall*, podendo-se observar a relação de duas métricas em apenas um valor. A validação cruzada avalia a capacidade de generalização de um modelo, utilizando os dados de treino, que são divididos em blocos, onde cada bloco é testado individualmente. Enquanto um bloco é testado, os demais blocos são usados para treino.

4 Experimento usando simulação computacional

Para demonstrar a viabilidade da proposta, foi implementado um experimento computacional que utiliza um *dataset* de RAH disponível na literatura no trabalho de Zhang et al. (2019). Todo o código desenvolvido para realização dos experimentos está disponível em um repositório GitHub² de acesso público. Nesse experimento, foi realizada uma simulação do comportamento de um trabalhador por intermédio desses dados que são provenientes do setor de saneamento. O *dataset* aplicado neste experimento dispõe de atividades conforme a Tabela 1. Todas as atividades são descritas por amostras que contemplam os valores dos eixos x, y e z de um acelerômetro triaxial. A simulação utiliza a mesma estratégia de segmentação das janelas de cada atividade utilizada por Zhang et al. (2019).

Tabela 1: Atividades do *dataset* de Zhang et al. (2019).

Nº	Label	Legenda
0	bweep	varrer usando uma vassoura grande
1	clean	limpar
2	daily	atividades diárias (ex. sentar, fumar)
3	dump	despejar
4	run	correr
5	sweep	varrer
6	walk	caminhar

O *dataset* foi carregado para o ambiente *Google Colab*, contemplando as sete atividades citadas anteriormente. Os

dados passaram por um pré-processamento, onde foram extraídas um total de 8 *features*, que são: valor máximo, valor mínimo, binomial, media, mediana, variância, desvio padrão, e desvio médio absoluto.

Nos ensaios preliminares, observou-se problemas no aprendizado do classificador pelo fato do conjunto de dados estar desbalanceados e os resultados aquém do esperado. Como solução, foi aplicado o SMOTE para balancear os dados, deixando todas as classes com a mesma proporção, conforme apresentado na Fig. 2. Após o uso do SMOTE, os resultados das métricas apresentaram melhora significativa, pois havia uma tendência de erros para a atividade *Sweep*, que é a classe com maior número de dados naturais e consequentemente a que era melhor aprendida pelos classificadores. Havia um desempenho ruim para as classes minoritárias.

Os dados foram separados em conjunto de treino e teste, numa proporção respectiva de 70% e 30%. Foram escolhidos três classificadores distintos para as mesmas análises dos dados, com o propósito de avaliar qual apresentaria o melhor desempenho. Os classificadores usados foram: *K-Nearest Neighbor* (KNN), *Support-vector machine* (SVM) e *Logistic regression* (LR) (Müller e Guido, 2018; Zaki, 2020). O KNN é amplamente utilizado como classificador em RAH. Seu algoritmo tenta classificar cada amostra de um conjunto de dados, avaliando sua distância em relação aos vizinhos mais próximos. O SVM também é muito aplicado para RAH. Ele é um classificador que analisa os dados e reconhece padrões e a partir desta informação, separa os dados encontrando o *hiperplano* que melhor diferencia as classes. A LR é um classificador de fácil implementação. Ele explora os conceitos de estatística e probabilidade, medindo a relação entre as variáveis.

Os experimentos foram separados em duas fases. Na Fase 1, foi realizado o pré processamento dos dados, a aprendizagem de máquina e a aplicação das métricas propostas, com os três classificadores escolhidos. Por meio dos resultados, é possível definir qual deles apresenta o melhor desempenho para o conjunto de dados analisado. A Fase 2 avançou apenas com o classificador selecionado na Fase 1, com o objetivo de avaliar seu comportamento para detecção da troca de atividade, através de uma simulação com mudanças aleatórias de atividade.

4.1 Fase 1 - Uso dos classificadores para RAH

O conjunto de dados foi submetido a treino e teste para os três classificadores, na proporção definida de 70% e 30% respectivamente. Para o KNN, o valor de K foi definido após se realizar testes com valores entre 1 e 10, sendo que K=4 apresentou os melhores resultados. Logo após, algumas métricas de avaliação foram empregadas para determinar qual classificador apresentou o melhor desempenho para o *dataset* de estudo.

A matriz de confusão do KNN apresentou o menor número de erros, seguido do SVM e LR. Na Fig. 3, é possível observar que nos três classificadores há uma tendência de erro relacionada às atividades *bweep* (varrer com vassoura grande), *sweep* (varrer) e *clean* (limpar), mas deve-se levar em consideração que são atividades de grande similaridade. Apenas a matriz da LR apresenta números expressivos de erros, podendo-se concluir que este modelo não

²<https://github.com/MathheusAcacioR/collab-notebook-human-activity-recognition>




Figura 2: Quantitativo das atividades antes e depois da aplicação do SMOTE.

apresenta bons resultados para o conjunto de dados deste experimento.

Buscando comparar o desempenho dos modelos, as métricas de acurácia e *f1 score* estão expressas na Tabela 2. Em ambas as métricas, os melhores resultados foram para o KNN, após SVM, e por último a LR.

Tabela 2: Métricas e resultados por classificador.

MÉTRICA	KNN	SVM	LR
Acurácia	93,12%	89,21%	70,40%
F1 Score	93,13%	89,16%	69,91%

Ao implementar a validação cruzada, o conjunto de dados foi dividido em 5 blocos, onde todos os blocos foram testado individualmente. O desvio padrão foi calculado para o conjunto dos blocos. O procedimento se repetiu para cada classificador e os resultados estão descritos na Tabela 3. Na validação cruzada, o KNN apresentou um melhor desempenho em relação aos subconjuntos e o menor desvio padrão.

Tabela 3: Resultado da validação cruzada.

BLOCO	KNN	SVM	LR
1	89,01%	86,56%	68,40%
2	89,17%	88,27%	69,95%
3	89,01%	87,30%	68,81%
4	90,31%	87,87%	70,44%
5	88,26%	85,90%	68,54%
DesvPad	0,66%	0,86%	0,81%

4.2 Fase 2 - Avaliação de troca de atividade

Entre os três classificadores testados para este conjunto de dados, o RAH teve melhor desempenho com as análises feitas pelo algoritmo KNN. Assim, optou-se por analisar apenas esse classificador na Fase 2, avaliando seu desempenho especificamente em relação a detectar trocas de atividade em um intervalo *LT* pré definido.

Para isso, uma simulação computacional foi elaborada da seguinte forma. Existe um *LT* para cada tipo de atividade, que é previamente determinado por profissional do setor de segurança do trabalho. Em experiência profissional com trabalhadores do setor da construção civil, ao realizar uma atividade de carga e descarga manual, o tempo médio de execução contínua da atividade é de 10 minutos. Após esse tempo, é necessária uma pausa. Na atividade *Walk*, sabe-se que o tempo médio de duração de cada janela representa 3,5 segundos. Dentro de 10 minutos, temos 600 segundos. Ao dividir 600s por 3,5s obtém-se o resultado de 171 repetições, ou seja, dentro do tempo predeterminado de 10 minutos, cabem 171 repetições da mesma atividade no decorrer do *LT*. Portanto, a probabilidade de troca de atividade no tempo limite de sua execução corresponde a $P = 1/171 \approx 0,005$.

Por esse motivo, foi determinado que a probabilidade de chance para que houvesse mudança da atividade seria de 0,5%; e para permanência da mesma atividade, 99,5%.

Para esta simulação, foi convencionada a seguinte interpretação da matriz de confusão:

- **Verdadeiro Positivo (VP):** quando o classificador identifica a atividade atual como sendo mesma atividade anterior e, ao verificar a resposta, vê-se que a atividade




Figura 3: Matrizes de confusão obtidas da Fase 1.

realmente é a mesma;

- **Falso Positivo (FP):** quando o classificador identifica a atividade atual como igual à anterior e, ao verificar a resposta, vê-se que a atividade mudou;
- **Verdadeiro Negativo (VN):** quando o classificador identifica uma troca de atividade e, ao verificar a resposta, vê-se que a atividade realmente mudou;
- **Falso Negativo (FN):** quando o classificador identifica uma troca de atividade e, ao verificar a resposta, vê-se que a atividade é a mesma.

Após a definição de cada item, o classificador seleciona a primeira amostra de forma aleatória dentro do conjunto de dados. Depois é sorteado um valor entre 0 e 1. Esse valor sendo maior ou igual a 0,005, a atividade continua a mesma. Já o valor sendo menor que 0,005, a atividade muda de forma aleatória. A amostra já escolhida é retirada do conjunto de dados para que o algoritmo selecione preferencialmente amostras distintas. Quando acabam as amostras de uma atividade, todas as amostras já utilizadas voltam para o conjunto e a simulação prossegue. Todo o conjunto de dados é repetido por dez vezes em busca do resultado mais representativo.

Na Tabela 4, é apresentada a quantidade total de erros e acertos do classificador. Os resultados apontam uma acurácia de 85,36%.

Tabela 4: Resumo de erros e acertos na detecção da troca de atividade.

Percentual	99,50%	Mesma atividade
		VP: 22.344
		FN: 3.849
	0,50%	Troca de atividade
		VN: 122
	100%	FP: 5
		26.320

Para uma melhor avaliação do resultado, na matriz de confusão detalhada na Fig. 4, podemos ver quais atividades estão associadas ao maior número de erros. Nesses dados em questão, um volume mais expressivo de erros é associado à atividade *bweep*, classificada erroneamente em 274

vezes como *clean*, e à atividade *clean*, classificada 258 vezes como *bweep*. Por se tratarem de atividades bastante similares, pode-se dizer que atividade parecidas aumentam a probabilidade de erro na classificação. Especificamente para o caso que está sendo tratado, quando o modelo erra para uma atividade similar, não implica necessariamente em algo ruim, pois na verdade a necessidade de troca de atividade é voltada para alternância de atividades com outras tarefas que permitam variar as posturas, os grupos musculares utilizados, ou o ritmo de trabalho. Portanto, se o trabalhador mudar para uma atividade que seja similar à que estava sendo executada anteriormente, o risco de lesão permanece em alto nível.




Figura 4: Matriz de confusão obtida na Fase 2.

4.3 Desafios

Embora o uso das tecnologias 4.0 para monitoramento de atividades laborais e prevenção de doenças ocupacionais seja promissor, existem vários aspectos que precisam

ser tratados de forma apropriada. Até o momento, não há legislação sobre o uso dos dispositivos envolvendo o monitoramento de atividades laborais. Atualmente, os meios de proteção usados são insuficientes já que os números associados a acidentes de trabalho ainda são altos. Contudo há uma preocupação com a proteção dos dados dos trabalhadores, que são dados sigilosos e que podem ser compartilhados e acessados apenas por pessoal autorizado. O trabalhador precisa estar ciente de que está sendo monitorado e é fundamental que os dados sejam anonimizados. Empregado e empregador precisam entender o valor da tecnologia e os benefícios que ela pode proporcionar para que assim haja uma interação valiosa.

5 Conclusões e Trabalhos Futuros

Este trabalho apresentou uma proposta de monitoramento inteligente de atividades laborais, visando promover a saúde e segurança no trabalho. Os métodos de prevenção de doenças ocupacionais existentes são insuficientes e com o auxílio das tecnologias 4.0 é possível aprimorar os meios de cautela relacionados aos riscos no trabalho. O monitoramento das atividades do trabalhador pode prevenir o surgimento de doenças ocupacionais ou ajudar no seu controle, podendo evitar o agravamento delas. O experimento realizado até o momento tem mostrado resultados promissores. Ainda há desafios para a real aplicação na indústria, que envolvem cuidados com a privacidade do trabalhador, legislação, investimentos e outros.

Em relação aos trabalhos relacionados citados na Seção 2, a proposta que apresentamos se diferencia pelos seguintes itens:

- No trabalho de Low et al. (2019), o foco consiste em acompanhar a fadiga do sistema neuromuscular do trabalhador. Já no trabalho do autor Alberto et al. (2018), a proposta é obter a medida da atividade elétrica dos músculos e assim identificar características de fadiga para estabelecer a troca de atividade. Nossa proposta é fundamentada na NR 17 para a troca de atividade baseando no LT;
- Nos trabalhos de Vega-Barbas et al. (2019) e Ferraro et al. (2018) a aplicação está restrita a um ramo de atividade da indústria. Neste trabalho, a implementação pode ser feita na indústria como um todo desde que o funcionário exerça qualquer tipo de esforço físico, atividades repetitivas e/ou movimentos ergonômicos;
- A proposta dos autores Chander et al. (2020) e Jayasree e Kumari (2020) é fundamentada no correto reconhecimento da atividade e sua classificação para detecção de quedas. Nossa proposta não há necessidade de identificar a atividade com precisão, pois o propósito é mudar o tipo do esforço físico;
- No trabalho de Lind et al. (2020), o ponto central consiste no correto reconhecimento da atividade para alertar o trabalhador de riscos decorrentes da técnica de trabalho (atos inseguros). De forma prática, neste trabalho quando o algoritmo classifica uma atividade erroneamente, mas a atividade é similar a anterior, não consideramos como um problema, tendo em vista que o intuito é permitir variar os grupos musculares.

Para trabalhos futuros, será realizada a própria coleta de dados, utilizando *smartphone* ou *smartwatch*. A princípio a intenção é adquirir dados de trabalhadores autônomos que estejam dispostos a compartilhar as informações para fins de pesquisa. Busca-se analisar atividades distintas das que já foram apresentadas aqui, mas que também sejam rotineiras em âmbito laboral. Coletar dados posicionando o sensor em locais diferentes mostra-se essencial, sabendo que o posicionamento do sensor pode influenciar na coleta. Porém, é necessário avaliar de forma criteriosa, para que esse não venha a interferir de maneira negativa na execução do trabalho. Com os dados em mãos, a estimativa é que o sistema já criado possa ser aplicado ao novo dataset. Caso a aplicação não seja possível, espera-se que parte do processo seja similar ao que já foi realizado e que sirva de base para a análise dos novos dados.

Agradecimentos

Este projeto contou com recursos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), projeto nº 88887.604184/2021-00.

Referências

- Alberto, R., Draicchio, F., Varrecchia, T., Silvetti, A. e Iavicoli, S. (2018). Wearable monitoring devices for biomechanical risk assessment at work: Current status and future challenges—A systematic review, *International Journal of Environmental Research and Public Health* 15(9): 1–26. <https://doi.org/10.3390/ijerph15092001>.
- ANAMT, A. N. d. M. d. T. (2015). LER/DORT englobam cerca de 30 doenças. Disponível em: <https://www.anamt.org.br/portal/2015/03/06/lerdort-englobam-cerca-de-30-doencas/>.
- Awolusi, I., Nnaji, C., Marks, E. e Hallowell, M. (2019). Enhancing Construction Safety Monitoring through the Application of Internet of Things and Wearable Sensing Devices: A Review, *Computing in Civil Engineering 2019* pp. 105–113. <https://ascelibrary.org/doi/abs/10.1061/9780784482438.067>.
- Balli, S., Sağbaş, E. A. e Peker, M. (2019). Human activity recognition from smart watch sensor data using a hybrid of principal component analysis and random forest algorithm, *Measurement and Control (United Kingdom)* 52(1–2): 37–45. <https://doi.org/10.1177/0020294018813692>.
- Brasil (1991). LEI Nº 8.213, DE 24 DE JULHO DE 1991. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/18213cons.htm.
- Brasil (2020). Anuário Estatístico da Previdência Social. Disponível em: <https://www.gov.br/previdencia/pt-br/assuntos/previdencia-social/arquivos/versao-online-aeps-2020>.
- Brasil (2022). NR 17-ERGONOMIA. Disponível em: <https://www.gov.br/trabalho-e-emprego/pt-br/aceso-a-informacao/participacao-social/conselhos-e-orgao>

- s-colegiados/comissao-tripartite-partitaria-permanente/arquivos/normas-regulamentadoras/nr-17-atualizada-2022.pdf.
- Chander, H., Burch, R. F., Talegaonkar, P., Saucier, D., Luczak, T., Ball, J. E., Turner, A., Kodithuwakku Arachchige, S. N., Carroll, W., Smith, B. K., Knight, A. e Prabhu, R. K. (2020). Wearable stretch sensors for human movement monitoring and fall detection in ergonomics, *International Journal of Environmental Research and Public Health* 17(10): 1–18. <https://doi.org/10.3390/ijerph17103554>.
- Choi, B., Hwang, S. e Lee, S. H. (2017). What drives construction workers' acceptance of wearable technologies in the workplace?: Indoor localization and wearable health devices for occupational safety and health, *Automation in Construction* 84(July 2016): 31–41. <https://doi.org/10.1016/j.autcon.2017.08.005>.
- Chung, W. W. S., Tariq, S., Mohandes, S. R. e Zayed, T. (2020). IoT-based application for construction site safety monitoring, *International Journal of Construction Management* 0(0): 1–17. <https://doi.org/10.1080/15623599.2020.1847405>.
- Ferraro, V., Stepanovic, M. e Ferraris, S. (2017). Persuasive Technology as key to increase Working Health Condition. The Case study of a Wearable System to prevent Respiratory Disease, *Design Journal* 20(sup1): S2439–S2450. <https://doi.org/10.1080/14606925.2017.1352757>.
- Ferraro, V., Stepanovic, M. e Ferraris, S. (2018). Wearability and user experience through user engagement: The case study of a wearable device, *Advances in Intelligent Systems and Computing* 608: 125–135. https://doi.org/10.1007/978-3-319-60639-2_13.
- Gnoni, M. G., Bragatto, P. A., Milazzo, M. F. e Setola, R. (2020). Integrating IoT technologies for an “intelligent” safety management in the process industry, *Procedia Manufacturing* 42(2019): 511–515. <https://doi.org/10.1016/j.promfg.2020.02.040>.
- Grouios, G., Ziagkas, E., Loukovitis, A., Chatzinikolaou, K. e Koidou, E. (2023). Accelerometers in our pocket: Does smartphone accelerometer technology provide accurate data?, *Sensors* 23: 1–17. <https://doi.org/10.3390/s23010192>.
- Hugo Sefrian, P., Arthur Felipe Echs, L., Camila Maria, B., Cinthia Martins dos Santos, P., Eduardo Augusto, T., Edwin Vladimir Cardoza, G., Evandro Junior, R., Fernanda Aranha, S., Gislaine Camila Lapasini, L., Juliana Lopes de Souza, D., Luci Mercedes, D. M., Mario Henrique Bueno Moreira, C., Mário Paulo, C. e P., Marisa Fujiko, N., Nayara Rafaela de Mendonça, P., Regiane Cristina de, S., Renan, C., Ricardo Hoegen, B., Roberto, J. e Tatiana, I. (2019). *Segurança e Saúde do Trabalho na Indústria da Construção Civil*, Editora Scienza. Disponível em: https://abho.org.br/wp-content/uploads/2024/02/Seguranca_Saude_do_Trabalho_na_Industria_da_Construcao_Civil.pdf.
- Jayasree, V. e Kumari, M. N. (2020). IOT based smart helmet for construction workers, *2020 7th International Conference on Smart Structures and Systems, ICSSS 2020* pp. 1–5. <https://doi.org/10.1109/ICSSS49621.2020.9202138>.
- Jiang, Z., Bakker, O. J. e Bartolo, P. J. (2022). Critical review of industry 4.0 technologies' applications on occupational safety and health, *2022 8th International Conference on Control, Decision and Information Technologies, CoDIT 2022* pp. 1267–1272. <https://doi.org/10.1109/CoDIT55151.2022.9804010>.
- Kim, J., Campbell, A. S., de Ávila, B. E. F. e Wang, J. (2019). Wearable biosensors for healthcare monitoring, *Nature Biotechnology* 37(4): 389–406. <https://doi.org/10.1038/s41587-019-0045-y>.
- Lima, W. S., Souto, E., El-Khatib, K., Jalali, R. e Gama, J. (2019). Human activity recognition using inertial sensors in a smartphone: An overview, *Sensors (Switzerland)* 19(14): 14–16. <https://doi.org/10.3390/s19143213>.
- Lima, W. S. e Souto, E. J. P. (2020). *Reconhecimento de atividades humanas baseado na análise de fluxo contínuo de dados simbólicos*, PhD thesis. https://doi.org/10.5753/webmedia_estendido.2020.13054.
- Lind, C. M., Diaz-Olivares, J. A., Lindecrantz, K. e Eklund, J. (2020). A wearable sensor system for physical ergonomics interventions using haptic feedback, *Sensors (Switzerland)* 20(21): 1–25. <https://doi.org/10.3390/s20216010>.
- Low, J. X., Wei, Y., Chow, J. e Ali, I. F. (2019). ActSen – AI-enabled real-time IoT-Based ergonomic risk assessment system, *Proceedings - 2019 IEEE International Congress on Internet of Things, ICIOT 2019 - Part of the 2019 IEEE World Congress on Services* pp. 76–78. <https://doi.org/10.1109/ICIOT.2019.00024>.
- Martins, L. M. (2019). Activity Recording: um aplicativo para reconhecimento de atividade humana usando sensores de acelerômetro. Disponível em: <https://repositorio.ufu.br/handle/123456789/26685>.
- Müller, A. e Guido, S. (2018). *Introduction to Machine Learning with Python: A Guide for Data Scientists [en línea]*. United States Of América-Gravenstein Highway North,, Vol. 53, O'Reilly Media, Incorporated.
- Nnaji, C., Awolusi, I., Park, J. W. e Albert, A. (2021). Wearable sensing devices: Towards the development of a personalized system for construction safety and health risk mitigation, *Sensors (Switzerland)* 21(3): 1–25. <https://doi.org/10.3390/s21030682>.
- Nozaki, D., Okamoto, K., Mochida, T., Qi, X., Wen, Z., Myint, S. H., Tokuda, K., Sato, T. e Tamesue, K. (2018). AI Management System to Prevent Accidents in Construction Zones Using 4K Cameras Based on 5G Network Daichi, *2018 21st International Symposium on Wireless Personal Multimedia Communications (WPMC)* pp. 462–466. <https://doi.org/10.1109/WPMC.2018.8712896>.
- Olsen, T. L. e Tomlin, B. (2020). Manufacturing & Service Operations Management Industry 4.0 : Opportunities and Challenges for Operations Management Industry

- 4.0 : Opportunities and Challenges for Operations Management, *Manufacturing and Service Operations Management* **22**(1): 113–122. <https://doi.org/10.1287/msom.2019.0796>.
- Vega-Barbas, M., Diaz-Olivares, J. A., Lu, K., Forsman, M., Seoane, F. e Abtahi, F. (2019). P-ergonomics platform: Toward precise, pervasive, and personalized ergonomics using wearable sensors and edge computing, *Sensors (Switzerland)* **19**(5). <https://doi.org/10.3390/s19051225>.
- Wu, F., Wu, T. e Yuce, M. R. (2019). Design and implementation of a wearable sensor network system for iot-connected safety and health applications, *IEEE 5th World Forum on Internet of Things, WF-IoT 2019 - Conference Proceedings* pp. 87–90. <https://doi.org/10.1109/WF-IoT.2019.8767280>.
- Yeo, C. J., Yu, J. H. e Kang, Y. (2020). Quantifying the Effectiveness of IoT Technologies for Accident Prevention, *Journal of Management in Engineering* **36**(5): 04020054. [https://doi.org/10.1061/\(ASCE\)ME.1943-5479.0000825](https://doi.org/10.1061/(ASCE)ME.1943-5479.0000825).
- Zaki, Z. (2020). Logistic Regression Based Human Activities Recognition, *Journal of Mechanics of Continua and Mathematical Sciences* **15**(4). <https://doi.org/10.26782/jmcms.2020.04.00018>.
- Zhang, Y., Zhang, Z., Zhang, Y., Bao, J., Zhang, Y. e Deng, H. (2019). Human Activity Recognition Based on Motion Sensor Using U-Net, *IEEE Access* **7**: 75213–75226. <https://doi.org/10.1109/ACCESS.2019.2920969>.
- Zimmermann, L. (2019). *Elderly activity recognition using smartphones and wearable devices*, Master thesis, Universidade de São Paulo. <https://doi.org/10.11606/D.55.2019.tde-10062019-080049>.