



ENTAC 2024

XX ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO
Maceió, Brasil, 9 a 11 de outubro de 2024



Mapeamento de atributos utilizados em modelos de predição de acidentes na construção usando técnicas de ML

Mapping of attributes used in construction accidents prediction models using ML techniques

Mírian Caroline Farias Santos

Universidade Federal da Bahia (UFBA) | Salvador | Brasil | miriancfarias@gmail.com

Vinicius Fernandes Santos

UFBA | Salvador | Brasil | viniufernandes.eng@outlook.com

Roseneia Rodrigues Santos de Melo

UFBA | Salvador | Brasil | roseneia.engcivil@gmail.com

Dayana Bastos Costa

UFBA | Salvador | Brasil | dayanabcosta@ufba.br

Resumo

O baixo desempenho em saúde e segurança ocupacional enfrentado pela indústria da construção impacta o produto interno bruto dos países e traz perdas financeiras para empresas e trabalhadores. Neste contexto, vários modelos preditivos utilizando machine learning (ML) foram desenvolvidos utilizando dados históricos de acidentes de construção. No entanto, ainda não existe consenso sobre os tipos de atributos que devem ser inseridos nestes modelos para alcançar predições mais assertivas. Portanto, este artigo tem como objetivo apresentar e categorizar os atributos mais utilizados em modelos preditivos usando ML. Para isso, é realizada uma revisão sistemática visando identificar os principais artigos de modelos preditivos. Os resultados mostraram seis categorias principais de atributos que tiveram maior ocorrência, sendo aqueles relacionados ao trabalhador, à organização e à gestão da segurança. Portanto, este artigo pretende contribuir para a definição de quais tipos de dados relacionados a acidentes devem ser coletados para auxiliar na previsão de acidentes e, consequentemente, melhorar o desempenho de segurança.

Palavras-chave: Gestão da segurança. Acidentes. Aprendizado de máquina. Modelos preditivos.

Abstract

The low occupational health and safety performance faced by the construction industry impacts countries' gross domestic product and brings financial losses to companies and workers. In this context, several predictive models using machine learning (ML) have been developed using historical data on construction accidents. However, there is still no consensus on the types of attributes that should be input into these models to achieve more assertive predictions. Therefore, this paper aims to survey and categorize the most commonly used attributes in predictive models using ML. To this end, a systematic review aims to identify the main research of accident predictive models. The findings show six main categories of attributes; the most



frequent attributes were those related to workers, organization, and safety management. Thus, this paper aims to define what types of data related to accidents should be collected to assist in predicting accidents and consequently improving safety performance.

Keywords: Safety management. Accident. Machine Learning. Predictive models.

INTRODUÇÃO

A segurança no trabalho é de suma importância para o setor da construção civil, dado que é uma das áreas com os mais altos índices de acidentes laborais em todo o mundo, acarretando significativas perdas sociais e econômicas [1]. Em países em desenvolvimento, os trabalhadores da construção têm três a seis vezes mais chances de sofrer acidentes fatais do que em outras indústrias [2]. Segundo a Associação Nacional de Medicina do Trabalho, a taxa de mortalidade no trabalho no Brasil é de 5,21 mortes para cada 100 mil vínculos empregatícios. Na construção civil, a taxa chega a 11,76 casos para cada grupo de 100 mil [3].

Além dos prejuízos humanos e às famílias, os custos desses acidentes têm um grande impacto na economia e na produtividade do setor privado. A Organização Internacional do Trabalho (OIT) estima que essas ocorrências causam a perda aproximada de 4% do Produto Interno Bruto (PIB) global a cada ano [4].

Apesar dos avanços na gestão de segurança do trabalho, somado aos esforços do setor para reduzir o número de incidentes, existem muitos desafios a serem superados devido ao ambiente de trabalho altamente dinâmico e complexo [5; 6]. Construtoras de grande porte possuem centenas de projetos em andamento simultaneamente, o que pode dificultar a análise de dados e tomada de decisão mais assertiva por parte dos gestores [1]. Outro ponto a destacar é a subjetividade das avaliações das condições de segurança em canteiros de obras, baseada na maioria dos casos nos atendimentos de requisitos normativos [2, 5], dificultando a análise crítica e proposição de ações em tempo hábil [7; 6].

Nesse contexto, existe a necessidade de melhorar a capacidade dos gestores em gerenciar efetivamente dezenas ou centenas de trabalhadores e informá-los acerca dos riscos que enfrentam. Para isso, diversas tecnologias digitais vêm sendo adotadas a fim de melhorar a eficiência da gestão, reduzir o tempo de observação manual e aumentar a confiabilidade das informações [8].

Assim, as técnicas de aprendizado de máquina, em inglês Machine Learning (ML), impulsionadas por dados e metodologias de inteligência artificial interpretáveis, estão progressivamente suplantando os métodos estatísticos tradicionais. Estas técnicas estão sendo ativamente empregadas na identificação de variáveis que influenciam na ocorrência de acidentes [9]. Uma das estratégias utilizadas é o uso de dados históricos de acidentes de construção, os quais podem fornecer informações significativas para estimar acidentes futuros e potencialmente reduzir as suas graves consequências [1]. Entretanto, a OIT [4] discute que o principal desafio no domínio das estatísticas de segurança e saúde no trabalho seja a falta de disponibilidade de dados, já que registros administrativos nem sempre são mantidos seguindo diretrizes rigorosas para garantir a qualidade, validade e consistência da informação, e nem sempre são atualizados regularmente. Além disso, a grande variedade de dados numéricos e volumes de

documentos de diferentes projetos para serem analisados se tornam uma limitação diante dos recursos humanos disponíveis [1].

Sendo assim, apesar da literatura apresentar um arcabouço relevante sobre métodos para análise de acidentes de construção [10], a previsão de acidentes e a identificação das causas correspondentes estão sujeitas a melhorias. Uma dessas melhorias é relacionada a necessidade urgente de identificar e compreender os fatores que podem influenciar os incidentes fatais na construção, visando a geração de modelos preditivos e, posteriormente, o desenvolvimento de estratégias eficazes para prevenção de acidentes [11].

Além disso, como diferentes países podem ter diferentes resultados dependendo da categoria de conjuntos de dados disponíveis e conteúdo desses dados, uma análise de semelhanças e diferenças pode trazer um resultado enriquecedor, principalmente quando são adicionadas descrição textual da situação do acidente e informações das pessoas envolvidas [2].

Este artigo tem como objetivo identificar e categorizar os fatores que influenciam na ocorrência de acidentes na construção visando a construção de modelos preditivos. Este trabalho faz parte de uma tese de doutorado na temática de desenvolvimento e análise de modelos de predição de acidentes na construção civil.

Revisão da literatura

Com o advento da indústria 4.0, o de aprendizado de máquina têm ganhado destaque para a predição de acidentes de trabalho, visando minimizar as taxas de acidentes. Os dados usados são oriundos de diversas fontes, como base de dados históricos nacionais e internacionais, públicos e privados [1, 2, 12, 13], registros de segurança e relatórios de acidentes [10, 11,14], incluindo informações sobre condições climáticas, comportamento dos trabalhadores, condições do canteiro, equipamentos utilizados e características organizacionais.

Diante desse contexto, os algoritmos de ML processam e analisam esses dados para identificar padrões e anomalias que não seria facilmente perceptível por análises manuais, levando em consideração a dependência entre os fatores e as condições de risco com base em eventos passados. As saídas dos modelos são as mais diversas, por exemplo, risco baixo, médio ou alto [15], possibilidade de ocorrência de lesões graves e moderadas [9], parte do corpo lesionadas [16], fatal ou não-fatal [17].

Essas previsões permitem, com base nos dados de entrada, que as empresas implementem medidas preventivas, para melhorar à gestão da segurança [6; 17]. Por exemplo, uso de ML para desenvolver indicadores de segurança visando auxiliar na previsão e prevenção de acidentes [1,12]. Os modelos de ML podem ser aplicados para a previsão de situações potenciais de risco de acidentes fatais em canteiros de obras com base em dados históricos de acidentes [2], além de possibilitar a análise de fatores críticos e avaliação do impacto de diversas combinações de fatores na previsão da gravidade dos acidentes de construção [18].

A literatura também apresenta estudos que combinaram ML com sensores para avaliar riscos de acidentes. Por exemplo, dados de sinais fisiológicos obtidos de sensores vestíveis usados por trabalhadores da construção foram usados para avaliação de

riscos percebidos [15]. Assim como o desenvolvimento de protótipo de sistema para rastrear o peso de objetos pesados carregados por trabalhadores da construção civil, desenvolvendo calçados de segurança inteligentes com sensores FSR (*Force Sensitive Resistor*) [19].

A aplicação de ML pode ser uma solução eficaz para melhorar a segurança do trabalho na construção civil [1, 2, 12]. Nesse sentido, esse estudo buscou identificar o que tem sido desenvolvido sobre a aplicação de ML na gestão da segurança em canteiro de obras, destacando quais algoritmos foram mais utilizados, vantagens e limitações desses algoritmos e os atributos mais utilizados para desenvolver os modelos de ML.

MÉTODO DE PESQUISA

Esta pesquisa é centrada na Revisão Sistemática da Literatura (RSL), uma vez que busca identificar, avaliar e interpretar, estudos recentes relativo a uma determinada área de conhecimento, questão ou fenômeno de interesse.

As buscas foram efetuadas na base de dados Scopus, por sua vasta representatividade [21]. Como critérios de inclusão, foram considerados todos os períodos registrados nas bases de dados até 2023 e a combinação dos seguintes termos de pesquisa, a serem buscados no título, no resumo ou nas palavras-chave dos artigos: (TITLE-ABS-KEY (machine AND learning) AND TITLE-ABS-KEY (safety AND management) AND TITLE-ABS-KEY (construction)). O processo resultou em 30 artigos, sendo considerado apenas artigos de periódicos, na língua inglesa. Após a leitura dos resumos, foram excluídos das amostras os artigos que utilizam dados de imagens para geração de previsões, tendo em vista que este trabalho foca em dados numéricos e categóricos. Além disso, não foram considerados artigos que não estavam alinhados com a temática de modelos preditivos para gerenciamento da segurança com foco na prevenção ou avaliação de risco de acidentes em canteiros de obras. Ao final, foram analisados 13 artigos.

A análise dos dados envolveu quatro etapas: (i) Mapeamento dos atributos utilizados pelos modelos de predição que foram considerados relevantes para a segurança do trabalho, (ii) Categorização dos atributos, visando agrupar atributos de mesma natureza, (iii) Levantamento das características dos modelos preditivos identificados na literatura. Essas análises foram cruciais para identificar quais fatores são relevantes e como podem ser mensurados para uso em modelos preditivos futuros.

A quarta análise (iv) está centrada na identificação e categorização dos algoritmos mais utilizados para a predição de acidentes, além de suas respectivas aplicações, vantagens e limitações.

RESULTADOS

Após a leitura dos artigos e compatibilização dos dados, os 59 atributos mapeados foram classificados em seis categoriais, conforme a sua natureza. As categorias adotadas foram: atributos relacionados ao trabalhador (9), atributos relacionados à organização (12), atributos relacionados à tarefa (3), atributos relacionados ao

ambiente de trabalho (9), atributos relacionados à gestão da segurança (18) e atributos relacionados ao tempo e condições climáticas (8). Os Quadros 1 ao 6 apresentam a lista dos atributos e sua descrição.

Quadro 1: Atributos relacionados ao trabalhador

Atributos	Descrição	Referências
Idade	Faixa etária	[1, 9, 11, 14, 16, 17, 22]
Sexo	Masculino ou feminino	[2, 11, 14, 16, 17, 22]
Etnia	Etnia	[14]
Escolaridade	Nível de escolaridade	[13, 14, 16, 17, 22]
Qualificação profissional	Se o profissional é qualificado ou não	[9, 18]
Experiência de trabalho	Tempo de experiência do trabalhador na função	[2,9,14]
Salário	Faixa salarial ou valor equivalente a um dia de trabalho	[13, 17, 22]
Dias trabalhados	Dias de trabalhado do trabalhador	[16, 17, 22]

Fonte: Os autores.

Com base no Quadro 1, verifica-se que os atributos idade, gênero e escolaridade são os mais utilizados pelos modelos de predição analisados, passando a frente dos atributos referente à qualificação profissional e experiência do trabalhador. Sob a perspectiva organizacional, o Quadro 2 apresenta que o tipo de construção foi o atributo mais usado pelos modelos, seguido do tamanho da empresa e o tipo de mão de obra.

Quadro 2: Atributos relacionados à organização

Atributos	Descrição	Referências
Prazo	Se o projeto está em atraso ou não.	[12, 14, 18]
Tamanho da empresa	Pequeno, médio ou grande porte (quantidade de empregado)	[2, 9, 14, 16, 17]
Tipo de construção	Edificação, estrada, hidroelétrica, ferroviária, túneis, pontes, telecomunicações, entre outros	[1, 2, 11, 12, 13, 16, 17, 22]
Mão de obra	Se a mão de obra é tempo integral, parcial, temporário, por contrato (terceirizado).	[1, 9, 11, 18]
Turnos de trabalho	Trabalho noturno	[14, 16, 17]
Projeto	Projetos atrasados ou de baixa qualidade	[1, 18]
Planejamento	Cronograma do projeto, Planejamento incompleto e execução inadequada do que foi planejado	[1, 18]
Layout de canteiro	Arranjo inadequado dos procedimentos executivos	[18]
Contrato	Tipo de contrato	[1, 9, 12, 18]
Orçamento	Valor do projeto	[1, 12]
Controle da produção	Acompanhamento do percentual concluído / valor agregado	[1, 12]
Qualidade	Acompanhamento da qualidade dos serviços e não conformidades	[12]

Fonte: Os autores.

Conforme a análise apresentada no Quadro 2, os dados relacionados ao orçamento do projeto, planejamento e controle e qualidade, embora relevantes para a gestão da segurança, ainda são poucos usados em modelos de predição [1, 12, 18].

Com relação aos atributos relacionados à tarefa (Quadro 3), destacam-se os atributos partes do corpo lesionada e o tipo de lesão. Apesar desses dados serem comuns em registros de acidentes, eles tiveram uma menor incidência quando comparados as demais categorias, presente em apenas três artigos.

Quadro 3: Atributos relacionados à tarefa

Atributos	Descrição	Referências
Partes do corpo lesionadas	Membros superiores, membros inferiores, mãos, pés, cabeça	[9, 13]
Tipo de lesão	Infecções agudas, exposição a produtos químicos, exposição a condições extremas de temperatura, fratura, choque, entre outros	[13]
Sinais fisiológicos	Atividade eletrodérmica, fotopletismografia e temperatura da pele	[15]

Fonte: Os autores.

Conforme apresentado no Quadro 4, na categoria ambiente de trabalho, os atributos referentes à sistema construtivo, materiais e equipamentos foram os mais recorrentes, seguidos de plataforma de trabalho em altura e uso de guias e andaimes.

Quadro 4: Atributos relacionados ao ambiente de trabalho

Atributos	Descrição	Referências
Sistema construtivo/atividade	Sistema construtivo (escavação, fundação, estrutura de aço, instalações, concreto, telhado)	[10, 11, 16, 17]
Plataforma de Trabalho em altura	Se existe plataforma de trabalho em altura, e se está em boas condições (acima de 2,0 metros)	[1, 10, 11]
Materiais utilizados	Tipo de material, se o material está em boas condições e em quantidades adequadas	[13, 18, 22]
Equipamentos	Operação inadequada dos equipamentos e atraso na manutenção dos equipamentos	[10, 11, 14, 18]
Sinalização	Se há sinalização de segurança no canteiro e se é adequada	[18]
Gruas / andaimes	Se há presença de guias ou andaimes (posição inadequada ou com defeito)	[1, 10, 14]
Local do acidente	Cidade em que aconteceu	[2]
Tipo de acidente	Queda, choque, esmagamento	[2, 9]
Acessos	Existência de acessos seguros	[1]

Fonte: Os autores.

Sob a perspectiva de gestão da segurança, o Quadro 5 apresenta que os atributos mais usados na predição de acidentes foram gestão de segurança on-site, avaliação de risco, medidas de proteções individuais e condições de trabalho e proteções coletivas. Tais aspectos reafirmar a importância de práticas, procedimentos e políticas de segurança

para a prevenção de acidentes em ambientes laborais. Aspectos relacionados à saúde do trabalhador, comportamento e cultura de segurança também foram mapeados, apesar na menor incidência.

Quadro 5: Atributos relacionados à gestão da segurança

Atributos	Descrição	Referências
Departamento de saúde e segurança do trabalho	Se há ou não departamento de segurança do trabalho na empresa	[18]
Profissionais de segurança do trabalho	Se há profissionais de segurança e se esses profissionais são adequados	[18]
Supervisão de segurança	Se é eficiente ou não	[18]
Gestão de segurança on-site	Implementação de práticas, inspeções de segurança, procedimentos e políticas de segurança diretamente no ambiente onde as atividades laborais ocorrem	[1, 10, 11, 18]
Avaliação de Risco	Se há falhas em identificar os riscos de acidentes, horas de exposição ao risco, conteúdo da tarefa	[1, 9, 11, 12, 18]
Medidas prevenção de acidentes	Se há atrasado em tomar medidas de controle de segurança após identificar perigo	[18]
Alocação dos recursos para segurança	Se há adequada alocação de recursos físicos e financeiros para a segurança do trabalho	[18]
Medidas de proteção individual e condições de trabalho	Distribuição inadequada de Equipamento de proteção Individual (EPI), uso inadequado do EPI, proteções de segurança inadequadas e condições de trabalho severa, iluminação insuficiente ou inadequada	[1, 9, 10, 11, 14, 18]
Proteções Coletivas	Uso de proteções coletivas (projeção de materiais, isolamentos, proteção contra queda, guarda-corpos, proteção de partes perigosas de máquinas)	[1, 10, 11, 14]
Treinamento de segurança	Se há treinamento de segurança dos trabalhadores e se os treinamentos de segurança são adequados	[11, 14, 18]
Cultura de segurança	Se há falta de conscientização de segurança e se há falta de conhecimento de segurança	[18]
Comportamental	Ato inseguro, desvios e falta de atenção	[9, 10, 14]
Plano de emergência (intervenção)	Se há falha em propor medidas para conter ou minimizar os riscos após incidentes e se há falhas no plano de resgate em situações de emergência	[1, 18]
Relatórios e Comunicação de acidentes	Se há notificação de acidentes e se essas notificações são adequadas e analisadas	[9, 18, 22]
Primeiros socorros	Instalação de primeiros socorros no canteiro de obra	[1]
Dias de trabalho perdidos	Quantidade de dias de trabalho perdidos devido a ocorrência de acidentes	[9, 13]
Índice de acidentes da empresa	número de acidentes registrados pela empresa (histórico)	[17, 22]
Saúde do trabalhador	Fadiga, privação sono, depressão	[14]

Fonte: Os autores.

Com relação aos atributos relacionados ao tempo e às condições climáticas, o Quadro 6 aponta que o mês e o dia da semana foram os mais usados nos modelos de previsão. Os resultados também chamam atenção sobre o mapeamento das condições climáticas, que apesar da menor frequência, vêm ganhando destaque nos trabalhos de ergonomia e segurança devido a sua relação à ocorrência de acidentes.

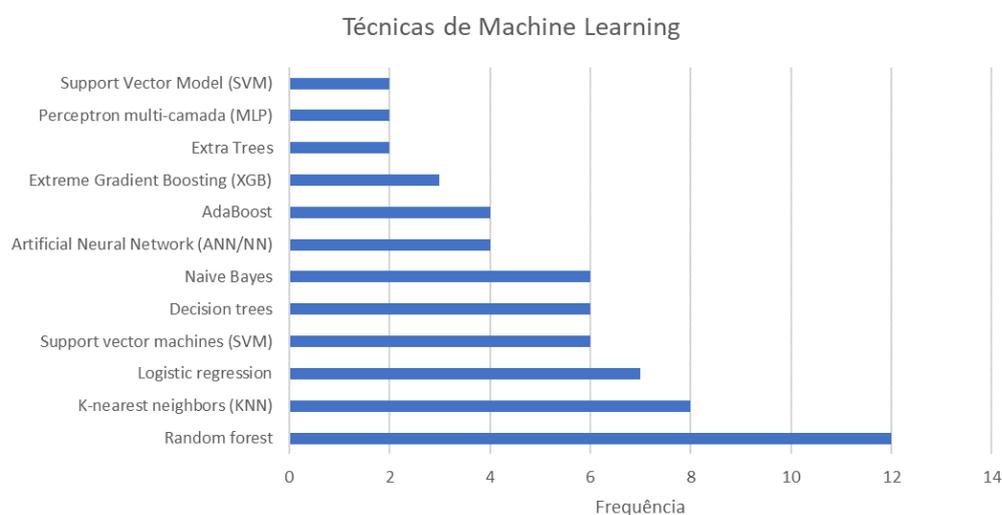
Quadro 6: Atributos relacionados ao tempo e condições climáticas

Atributos	Descrição	Referências
Ano	Ano em que ocorreu o acidente	[11, 16, 22]
Mês	Mês em que ocorreu o acidente	[2, 16, 17, 22]
Data	Dia do mês em que ocorreu o acidente	[16, 17, 22]
Dia	Dia da semana em que ocorreu o acidente	[2, 16, 17, 22]
Horário	Horário do dia em que ocorreu o acidente	[22]
Temperatura Média (°C/mês)	Temperatura do mês (máxima, mínima, média)	[16, 17]
Precipitação (mm/mês)	Quantidade de chuva do mês	[10, 16, 17]

Fonte: Os autores.

Ao investigar os principais algoritmos utilizados, destacam-se os algoritmos de *Random Forest* (12), *KNN* (8) e *Regressão logística* (7), seguidos de *Árvore de Decisão* (6), *SVM* (6) e *Naive Bayes* (6). No total, foram identificados o uso de 18 algoritmos, sendo apresentado na Figura 2 os mais relevantes.

Figura 1 - Algoritmos usados nos artigos



Percebe-se que os autores deram preferência aos algoritmos mais simples e fáceis de serem interpretados. *Random Forest* destaca-se por ser um algoritmo poderoso para lidar com previsão em dados de alta dimensionalidade e desequilibrados [18]. *KNN* destaca-se por sua simplicidade de ser manipulada e interpretada [1]. *Árvore de Decisão* também é um algoritmo fácil de ser interpretada [1,2,18,19] e com bom desempenho em dados de grandes dimensões [18]. A *Regressão Logística* é fácil de ser utilizada e interpretada [2,18]. Enquanto o *SVM* é um poderoso algoritmo para lidar com dados de alta dimensionalidade.

Algumas limitações a esses algoritmos foram identificadas. Por exemplo, Random Forest e Árvore de Decisão podem sofrer *overfitting* [18] e ter dificuldades com dados desbalanceados [1]. KNN, Regressão Logística e SVM apresentam dificuldades em lidar com muitas variáveis categóricas [2,18], além do KNN requerer alta capacidade computacional [1,18].

Com a análise dos dados, percebe-se que o uso das técnicas de ML para classificação binária é o mais comum, presente em oito artigos. A classificação de dados multivariados aparece em quatro estudos, enquanto a regressão logística aparece em apenas um. Dentre as aplicações, destacaram-se o uso de algoritmos para classificação de dados bivariados ou multivariados, especialmente para avaliar o impacto de diversos fatores na previsão de riscos de acidentes.

Os resultados da RSL revelaram tendência dos autores em desenvolver modelos preditivos com foco em previsão e prevenção de riscos. Isso mostra um esforço conjunto para antecipar e evitar acidentes que possam ocorrer durante a construção. No entanto, os atributos relacionados ao trabalhador e a organização foram os mais presentes nos artigos revisados. Os atributos relacionados ao clima emergem nas pesquisas mais recentes, assim como os relacionados à gestão da segurança, indicando uma oportunidade de aprimoramento do uso de ML na gestão da segurança, a fim de garantir que esses atributos sejam considerados como variáveis importantes nos modelos preditivos.

CONCLUSÃO

Com base nas análises, os resultados da revisão sistemática de literatura forneceram achados importantes no uso de técnicas de ML na previsão e avaliação de risco de acidentes na indústria da construção civil. Os atributos mais frequentes foram idade, gênero, escolaridade, tamanho da empresa, tipo de construção, avaliação de risco e medidas de proteção individual e condições de trabalho obra. A categoria de gestão da segurança apresentou a maior quantidade de atributos quando comparada as demais, no entanto, percebe-se uma falta de padronização dos dados e dificuldade de coleta das informações. Esta categoria é um importante vetor para avaliar a eficácia das ações de segurança e redução das taxas de acidentes.

Para futuros trabalhos destaca-se a necessidade de avaliar a importância dos atributos identificados para a predição de acidentes por meio de testes e simulações, além de explorar como esses atributos podem ser coletados no dia a dia do canteiro de obra visando alimentar modelos de predição para facilitar a tomada de decisão de gestores. Além disso, é importante considerar a disponibilidade e a abrangência das bases de dados nacionais e internacionais, a fim de garantir a inclusão de fatores importantes para o desenvolvimento de modelos preditivos eficazes.

AGRADECIMENTOS

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (Capes) e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão de bolsas.

REFERÊNCIAS

- [1] POH, C. Q. X.; UBEYNARAYANA, C. U.; GOH, Y. M. Safety leading indicators for construction sites: A machine learning approach. **Automation in Construction**, v. 93, p. 375–386, 1 set. 2018.
- [2] CHOI, J. et al. Machine learning predictive model based on national data for fatal accidents of construction workers. **Automation in Construction**, v. 110, 2020.
- [3] ANAMT - ASSOCIAÇÃO NACIONAL DE MEDICINA DO TRABALHO. Divulgadas as estatísticas de acidentes de trabalho para o ano de 2021. Disponível em: <<https://www.anamt.org.br/portal/2023/02/08/divulgadas-as-estatisticas-de-acidentes-de-trabalho-para-o-ano-de-2021/>>. Acesso em: 29 mar. 2023.
- [4] OIT - ORGANIZAÇÃO INTERNACIONAL DO TRABALHO. Série SmartLab de Trabalho Decente 2022: acidentes de trabalho e mortes acidentárias voltam a crescer em 2021. Disponível em: <<https://www.anamt.org.br/portal/2023/02/08/divulgadas-as-estatisticas-de-acidentes-de-trabalho-para-o-ano-de-2021/>>. Acesso em: 29 mar. 2023.
- [5] SAURIN, T. A. Safety inspections in construction sites: A systems thinking perspective. **Accident Analysis & Prevention**, v. 93, p. 240-250, 2016.
- [6] MELO, R. R. S.; COSTA, D. B. Integrating resilience engineering and UAS technology into construction safety planning and control. **Engineering, Construction and Architectural Management**, v. 26, n. 11, p. 2705-2722, 2019.
- [7] LIN, K. et al. A user-centered information and communication technology (ICT) tool to improve safety inspections. **Automation in construction**, v. 48, p. 53-63, 2014.
- [8] LIU, Y. et al. Computer Vision Technologies and Machine Learning Algorithms for Construction Safety Management: A Critical Review. [s.l: s.n.].
- [9] KANG, K.; KOO, C.; RYU, H. An interpretable machine learning approach for evaluating the feature importance affecting lost workdays at construction sites. **Journal of Building Engineering**, v. 53, p. 104534, 2022.
- [10] SHUANG, Q.; ZHANG, Z. Determining critical cause combination of fatality accidents on construction sites with machine learning techniques. **Buildings**, v. 13, n. 2, p. 345, 2023.
- [11] ZHU, J. et al. Developing predictive models of construction fatality characteristics using machine learning. **Safety science**, v. 164, p. 106149, 2023.
- [12] JAFARI, P. et al. Leading safety indicators: Application of machine learning for safety performance measurement. *In*: ISARC. Proceedings of the International Symposium on Automation and Robotics in Construction. IAARC Publications, 2019. p. 501-506.
- [13] KOC, K.; EKMEKCIOĞLU, Ö.; GURGUN, A. P. Integrating feature engineering, genetic algorithm and tree-based machine learning methods to predict the post-accident disability status of construction workers. **Automation in Construction**, v. 131, p. 103896, 2021.
- [14] ZERMANE, A. et al. Predicting fatal fall from heights accidents using random forest classification machine learning model. **Safety science**, v. 159, p. 106023, 2023.
- [15] LEE, G. et al. Assessment of construction workers' perceived risk using physiological data from wearable sensors: A machine learning approach. **Journal of Building Engineering**, v. 42, p. 102824, 2021.

- [16] KOC, K.; EKMEKCIOĞLU, Ö.; GURGUN, A. P. Determining susceptible body parts of construction workers due to occupational injuries using inclusive modelling. **Safety science**, v. 164, p. 106157, 2023.
- [17] KOC, K.; EKMEKCIOĞLU, Ö.; GURGUN, A. P. Developing a national data-driven construction safety management framework with interpretable fatal accident prediction. **Journal of Construction Engineering and Management**, v. 149, n. 4, p. 04023010, 2023b.
- [18] ZHU, R. et al. Application of machine learning techniques for predicting the consequences of construction accidents in China. **Process Safety and Environmental Protection**, v. 145, p. 293–302, 1 jan. 2021.
- [19] LEE, S. H.; SON, J. Development of a safety management system tracking the weight of heavy objects carried by construction workers using fsr sensors. **Applied Sciences**, v. 11, n. 4, p. 1–15, 2021.
- [20] SEONG, H.; SON, H.; KIM, C. A Comparative Study of Machine Learning Classification for Color-based Safety Vest Detection on Construction-Site Images. **KSCE Journal of Civil Engineering**, v. 22, n. 11, p. 4254–4262, 2018.
- [21] RADZI, A. R. et al. Relationship between digital twin and building information modeling: a systematic review and future directions. **Construction Innovation**, v. 24, n. 3, p. 811-829, 2024.
- [22] KOC, K.; EKMEKCIOĞLU, Ö.; GURGUN, A. P. Prediction of construction accident outcomes based on an imbalanced dataset through integrated resampling techniques and machine learning methods. **Engineering, Construction and Architectural Management**, v. 30, n. 9, p. 4486-4517, 2022.