CC BY ND

*Zrecenzowany artykuł naukowy*

DOI: 10.54215/BP.2025.4.7.Podgorski

# Przegląd zastosowania algorytmów uczenia maszynowego do oceny i monitorowania ryzyka zawodowego w czasie rzeczywistym

dr inż. Daniel Podgórski* (ORCID: 0000-0003-0483-3731)

Fot. Shade Lite/Bigstockphoto

Uczenie maszynowe (UM) to obszar sztucznej inteligencji dotyczący algorytmów, które mogą modyfikować swoje parametry na podstawie przetwarzanych danych i wykonywać zadania bez wyraźnych instrukcji. Rozwój systemów sztucznej inteligencji i technologii internetu rzeczy (IoT) powoduje, że algorytmy UM są coraz częściej wykorzystywane w różnych sektorach gospodarki, w tym do oceny i monitorowania ryzyka zawodowego. Zawarty w artykule przegląd literatury naukowej z tej dziedziny pozwolił na wskazanie sektorów i rodzajów środowisk pracy, w których te algorytmy są stosowane, a także na określenie danych wykorzystywanych do uczenia algorytmów UM oraz identyfikację najczęściej stosowanych metod. Przedstawiono również potencjał algorytmów UM do automatyzacji procesów identyfikacji zagrożeń i oceny ryzyka zawodowego w czasie rzeczywistym.

*Słowa kluczowe: uczenie maszynowe, ocena ryzyka zawodowego, czas rzeczywisty, sztuczna inteligencja*

**Overview of the use of machine learning algorithms for real-time occupational risk assessment and monitoring**

Machine learning (ML) is an area of artificial intelligence dealing with algorithms that can modify their parameters based on processed data and perform tasks without explicit instructions. The development of artificial intelligence systems and Internet of Things technologies is resulting in ML algorithms being increasingly used in various sectors of the economy, including occupational risk assessment and monitoring. This article provides a review of the scientific literature in this field, which has identified the sectors and types of work environments in which these algorithms are used, defined the data used to learn ML algorithms and identified the most commonly used methods. The potential of UM algorithms to automate hazard identification and occupational risk assessment processes in real time is also presented.

*Keywords: machine learning, occupational risk assessment, real time, artificial intelligence*

* Centralny Instytut Ochrony Pracy – Państwowy Instytut Badawczy, kontakt: dapod@ciop.pl.

## Wstęp

Obserwowany w ostatnich latach rozwój systemów sztucznej inteligencji powoduje coraz powszechniejsze wykorzystywanie algorytmów UM we wszystkich dziedzinach życia i gospodarki. Do coraz szerszego zastosowania tych algorytmów przyczynia się również rozwój technologii IoT, umożliwiających generowanie i zbieranie dużej ilości danych, które mogą być następnie analizowane metodami UM.

Duży postęp w wykorzystaniu sztucznej inteligencji, w tym algorytmów UM, dokonuje się również w obszarze bezpieczeństwa i higieny pracy. Przegląd literatury [1] dotyczący tego zagadnienia wskazuje, że algorytmy UM są stosowane m.in. do analizy i klasyfikowania wypadków przy pracy, wyszukiwania wzorców w przyczynach wypadków przy pracy oraz do monitorowania zagrożeń i przewidywania zdarzeń wypadkowych. Zastosowania UM w większości tych obszarów bazują na danych pozyskanych z okresów przed wykonywaniem analiz (tzw. danych historycznych), więc działania podejmowane w ich wyniku mogą być nieadekwatne do aktualnego stanu środowiska pracy. Jednakże postęp w rozwoju technologii IoT pozwala na wykorzystanie algorytmów UM do oceny wykrywania zagrożeń i oceny ryzyka zawodowego (ORZ) w czasie rzeczywistym, co jeszcze kilka lat temu nie było możliwe. Zaletą tego nowego podejścia jest możliwość wykrywania i monitorowania zagrożeń na stanowiskach pracy w sposób ciągły, a następnie – ograniczania ryzyka zawodowego związanego z tymi zagrożeniami bezpośrednio po ich wykryciu. Jest to korzystne zwłaszcza w przypadku dynamicznie zmieniających się środowisk pracy oraz tam, gdzie występują szczególnie szkodliwe lub niebezpieczne czynniki zagrażające zdrowiu i życiu pracowników.

Celem niniejszego artykułu jest przedstawienie przeglądu literatury naukowej z zakresu zastosowań algorytmów UM do ORZ w czasie rzeczywistym oraz zdiagnozowanie ich potencjału do automatyzacji procesów ORZ. Wykonany przegląd pozwoli przede wszystkim odpowiedzieć na następujące pytania badawcze:

- W jakich sektorach gospodarki są stosowane metody UM do identyfikacji zagrożeń i ORZ?
- Jakie zagrożenia są obejmowane działaniem UM w ORZ?
- Które metody UM są najczęściej stosowane do ORZ w czasie rzeczywistym?
- Jakiego rodzaju dane są wykorzystywane do uczenia algorytmów UM, a następnie przetwarzane w procesach ORZ w czasie rzeczywistym?

Wyniki przeglądu są adresowane do specjalistów i praktyków z obszaru bezpieczeństwa i higieny pracy w celu wzbogacenia ich wiedzy o możliwościach zastosowania narzędzi informatycznych z funkcją UM do identyfikacji zagrożeń i ORZ na stanowiskach pracy. Ponadto wyniki te mogą posłużyć pracownikom naukowym do ukierunkowania ich prac badawczych w zakresie wykorzystania technologii obliczeniowych w procesie ORZ.

## Kwerenda publikacji naukowych

Do wyszukania publikacji naukowych dotyczących zastosowania UM w ORZ wykorzystano bazy literatury naukowej – Science Direct, Web of Science i Scopus – oraz wyszukiwarkę Google Scholar. Na pierwszym etapie zastosowano następujące kombinacje słów kluczowych w języku angielskim: „occupational risk" AND „machine learning" AND „real time" („ryzyko zawodowe" AND „uczenie maszynowe" AND „czas rzeczywisty"). W wyniku tego wyszukiwania, przeprowadzonego w okresie od 13 do 16 stycznia 2025 r., uzyskano następujące liczby publikacji: Science Direct – 70, Web of Science – 34, Scopus – 50, Google Scholar – 178 (czyli łącznie 332 pozycje).

Następnie dokonano selekcji publikacji z zastosowaniem następujących kryteriów:

- napisana w języku angielskim;
- dotycząca problematyki bezpieczeństwa i higieny pracy;
- opisująca własne rozwiązanie autorów (wykluczenie publikacji przeglądowych);
- zawierająca identyfikację zastosowanych algorytmów UM;
- opisująca zastosowanie algorytmów UM do jednego lub kilku etapów procesu ORZ przebiegającego według normy PN-N-18002:2011 [2] (1. Zbieranie informacji potrzebnych do ORZ, 2. Identyfikacja zagrożeń, 3. Oszacowanie ryzyka zawodowego);
- dotycząca ORZ na podstawie danych pozyskanych w czasie rzeczywistym (wykluczenie publikacji opisujących ORZ na podstawie danych historycznych).

Po tej selekcji uzyskano łącznie 44 publikacje [3–46] spełniające wymienione kryteria (Science Direct – 7, Web of Science – 10, Scopus – 19, Google Scholar – 8). Na kolejnym etapie w każdej z tych publikacji wyszukano następujące informacje, które zapisano w arkuszu Excel:

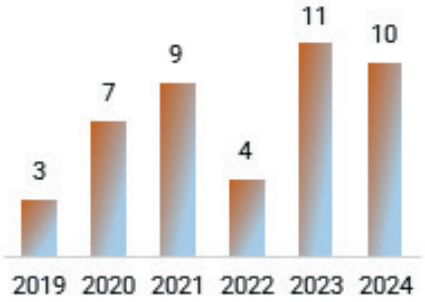


Rys. 1. Zestawienie liczby publikacji pod względem roku opublikowania
*Fig. 1. Summary of the number of publications by year of publication*

- tytuł publikacji;
- identyfikator DOI;
- rok opublikowania;
- kraj reprezentowany przez autora/autorów;
- sektor gospodarki lub cechy środowiska pracy;
- czynniki szkodliwe, niebezpieczne lub uciążliwe (w tym niebezpieczne sytuacje lub zachowania) objęte ORZ;
- rodzaj danych wejściowych przetwarzanych przez algorytmy UM;
- metody UM zastosowane w opisywanym rozwiązaniu ORZ.

## Ogólna charakterystyka publikacji naukowych wybranych do przeglądu

Zestawienie liczby analizowanych publikacji pod względem roku opublikowania przedstawiono na rys. 1. Widać na nim, że pierwsze doniesienia dotyczące zastosowania algorytmów UM do ORZ w czasie rzeczywistym pojawiły się sześć lat temu, po czym nastąpił szybki wzrost liczby publikacji w tej dziedzinie.

Następnie dokonano zestawienia liczby wybranych publikacji pod względem krajów, w których opracowano opisywane rozwiązania (rys. 2). Krajami wiodącymi w zakresie zastosowań UM do ORZ w czasie rzeczywistym okazały się Stany Zjednoczone, Włochy i Chiny (odpowiednio 11, 7 i 5 publikacji). Na uwagę zasługuje fakt, że wśród pozostałych krajów jest również Polska reprezentowana przez artykuł [23], który powstał z udziałem pracowników Centralnego Instytutu Ochrony Pracy – Państwowego Instytutu Badawczego w wyniku projektu międzynarodowego ASSIST-IoT, realizowanego w ramach europejskiego programu badawczego Horyzont 2020.

Kolejną cechą charakteryzującą analizowane rozwiązania był sektor gospodarki lub rodzaj środowiska pracy. Sektorem dominującym pod względem zastosowań UM do ORZ w czasie rzeczywistym jest

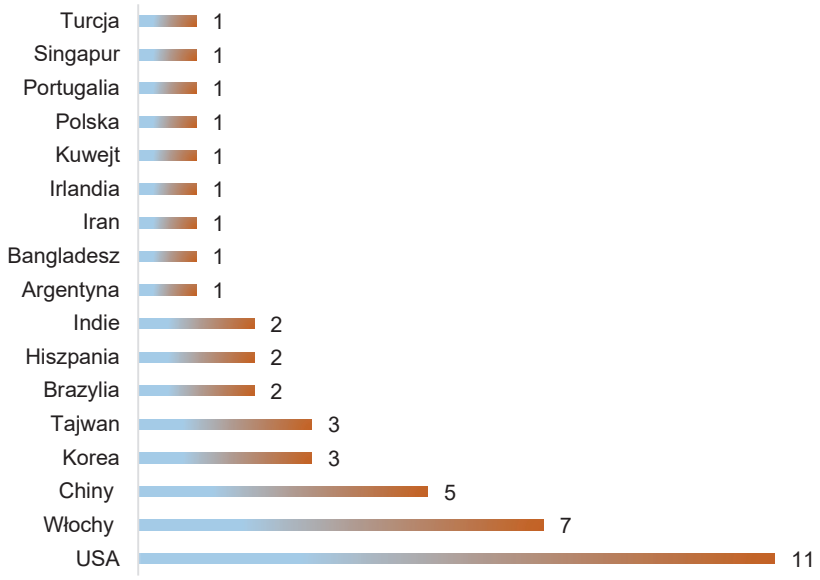


Rys. 2. Zestawienie liczby publikacji pod względem kraju reprezentowanego przez autora/autorów
*Fig. 2. Summary of the number of publications by country represented by the author/authors*

budownictwo, które wskazano w 20 publikacjach (45%). Do pozostałych sektorów tych zastosowań należą: rolnictwo (2), przemysł maszynowy (2), przemysł chemiczny (1), ochrona zdrowia (1) i pożarnictwo (1). W pozostałych publikacjach nie wskazano docelowego sektora implementacji UM, gdyż proponowane rozwiązania mogą być wykorzystywane w wielu sektorach gospodarki lub niezależnie od sektora. Najwięcej publikacji tego rodzaju dotyczyło prac transportowych (8) oraz wymuszonej pozycji ciała (5). Pozostałe rozwiązania dotyczyły gorącego środowiska pracy (2), starszych pracowników zagrożonych upadkiem (1) oraz obciążenia psychicznego pracowników (1).

## Zastosowanie algorytmów UM do ORZ

Analiza 44 wybranych publikacji wykazała, że do wspomagania ORZ w opisanych rozwiązaniach wykorzystano ponad 20 różnych rodzajów algorytmów UM. W niektórych rozwiązaniach stosowano jeden rodzaj algorytmów, a w innych – kilka, zwykle w celu sprawdzenia, które z nich najlepiej spełniają oczekiwane zadania.

Informacje o źródłach i rodzajach danych wejściowych oraz zastosowanych algorytmach UM przedstawiono w tabeli. Podzielono ją na osiem grup odpowiadających rodzajom czynników zagrożeń lub czynników uciążliwych, uwzględnianych w procesach ORZ wspomaganych przez UM. Nazwy algorytmów UM, użyte w analizowanej literaturze, pozostawiono w wersji angielskojęzycznej i w formie stosowanych w tej literaturze skrótów.

Z danych zawartych w tabeli wynika, że najczęściej stosowanymi algorytmami UM wspomagającymi procesy ORZ w czasie rzeczywistym są: konwolucyjne sieci neuronowe (CNN, 19 publikacji), maszyny wektorów nośnych (SVM, 11 publikacji), las losowy (RF, 10 publikacji) oraz metoda *k*-najbliższych sąsiadów (KNN, 8 publikacji).

## Ogólna charakterystyka najczęściej stosowanych algorytmów UM

**Konwolucyjne sieci neuronowe (CNN)** są szczególną klasą sztucznych sieci neuronowych, których najczęstszym zastosowaniem jest zaawansowane przetwarzanie obrazów. Powstanie tych sieci zostało zainspirowane procesami biologicznymi, gdyż połączenia między sztucznymi neuronami sieci odzwierciedlają organizację kory wzrokowej zwierząt. Algorytmy CNN pobierają obrazy wejściowe i klasyfikują je do określonych kategorii dzięki przypisaniu wag różnym kształtom, strukturom i obiektom. Sieci te uczą się, jakie cechy szczególne obrazu pomagają w jego klasyfikacji, i wykazują większą skuteczność w porównaniu z innymi algorytmami UM. Zalety CNN w tej dziedzinie zostały dostrzeżone przez wielu autorów analizowanych publikacji, gdyż 15 na 19 opisanych zastosowań CNN dotyczyło przetwarzania obrazów pracowników pozyskiwanych z kamer wideo [13, 16, 17, 29, 30, 37, 38–46]. Sieci CNN są również wykorzystywane do przetwarzania języka naturalnego oraz analizy sygnałów EEG (elektroencefalografii).

**Maszyny wektorów nośnych (SVM)** są rodzajem algorytmów uczenia nadzorowanego, wykorzystywanych do rozwiązywania zadań z zakresu klasyfikacji i regresji oraz wykrywania wartości odstających od analizowanych danych. Algorytmy SVM są przydatne zwłaszcza w rozwiązywaniu problemów klasyfikacji binarnej, czyli podziału elementów zbioru danych na dwie grupy. SVM dąży do znalezienia możliwie najlepszej linii lub granicy decyzyjnej, która oddziela punkty danych różnych klas danych. Granica ta stanowi hiperpłaszczyznę, która dzieli wielowymiarową przestrzeń cech. Celem jest maksymalizacja marginesu, który jest odległością między hiperpłaszczyzną a najbliższymi punktami danych każdej kategorii, umożliwiając w ten sposób rozróżnienie klas danych. Algorytmy SVM znajdują zastosowanie m.in. w klasyfikacji sygnałów pomiarowych oraz klasyfikacji i rozpoznawaniu obrazów. W przypadku analizowanych publikacji algorytmy te były najczęściej używane do analizy sygnałów pochodzących od czujników parametrów fizjologicznych i ruchów pracowników [6, 8, 14, 15, 20–22, 24, 31] oraz od czujników wykrywających stosowanie przez nich środków ochrony indywidualnej [7, 36].

**Las losowy (RF)** to metoda UM stosowana do klasyfikacji, regresji i innych zadań, która działa poprzez tworzenie wielu drzew decyzyjnych podczas uczenia, gdzie każde drzewo jest budowane na podstawie losowo wybranych podzbiorów danych. W przypadku zadań klasyfikacyjnych wynikiem RF jest np. klasa wybrana przez większość drzew. Z kolei w przypadku zadań regresji wynikiem RF jest np. średnia przewidywań drzew. Ta metoda jest znacznie tańsza i szybsza do trenowania w porównaniu ze sztucznymi sieciami neuronowymi, a jednocześnie oferuje dużą dokładność. Algorytmy RF są stosowane m.in. w badaniach genetycznych, medycynie oraz rozpoznawaniu obrazów poprzez klasyfikację obiektów i wzorców na zdjęciach. W przypadku analizowanych publikacji algorytmy RF były stosowane, podobnie jak jak SVM, do analizy parametrów fizjologicznych i ruchów pracowników [8, 15, 20–22, 24], a ponadto – do analizy sygnałów z czujników parametrów środowiska pracy [3, 4], czujników nacisku w obuwiu [9] oraz obrazów pozycji pracownika rejestrowanych przez kamery wideo [13].

**Metoda *k*-najbliższych sąsiadów (KNN)** jest obecnie jednym z najpopularniejszych algorytmów klasyfikacji i regresji stosowanych w dziedzinie UM. Jest to nieparametryczny,

Tabela. Zestawienie źródeł i rodzajów danych wejściowych, uwzględnianych w ORZ, oraz zastosowanych algorytmów UM
*Table. Summary of sources and types of input data taken into account in the occupational risk assessment and the machine learning algorithms used*

| Pozycja bibliografii | Źródło i rodzaj danych wejściowych | Algorytmy UM |
|---|---|---|
| **Zagrożenia chemiczne** | | |
| [3] | Czujnik dwutlenku węgla | Random Forest (RF) |
| [4] | Czujniki temperatury, wilgotności, dwutlenku węgla i gazów organicznych | RF |
| [5] | Czujniki tlenku węgla | Gradient Boosted Decision Tree |
| **Upadki, potknięcia, upadki z wysokości** | | |
| [6] | Elektroencefalografia | Support Vector Machine (SVM) |
| [7] | Czujniki połączenia systemu zabezpieczającego przed upadkiem z rusztowaniem | Naïve Bayes (NB), K-Nearest Neighbor (KNN), SVM |
| [8] | Czujniki rejestrujące ruchy pracowników (akcelerometry) | Logistic Regression (LR), SVM, RF, NB, KNN |
| **Czynniki mięśniowo-szkieletowe, przenoszenie ciężarów, pozycja przy pracy** | | |
| [9] | Czujniki nacisku w podeszwach obuwia | RF |
| [10] | Kamery rejestrujące pozycje i ruchy | RF |
| [11] | Akcelerometry rejestrujące ruchy na nadgarstku, klatce piersiowej i hełmie | Linear Regression (LR) |
| [12] | Inercyjne czujniki ruchu (akcelerometry) | DeepConvLSTM |
| [13] | Kamery rejestrujące pozycje i ruchy | Convolutional Neural Network (CNN) |
| [14] | Inercyjne czujniki ruchu (akcelerometry) | SVM |
| [15] | Inercyjny czujnik ruchu (akcelerometr) | RF, SVM |
| [16] | Kamery rejestrujące pozycje i ruchy, czujniki nacisku w podeszwach obuwia | CNN (Hourglass Network) |
| [17] | Smartfon rejestrujący pozycję przy pracy | CNN |
| [18] | Kamery rejestrujące ruchy części ciała | Multi-Layer Perceptron (MLP) |
| **Obciążenie termiczne, wysiłek fizyczny, zmęczenie** | | |
| [19] | Czujniki parametrów fizjologicznych | XGBoosted Trees |
| [20] | Czujnik częstości oddychania | KNN, SVM, RF, Artificial Neural Network (ANN) |
| [21] | Czujniki parametrów fizjologicznych, temperatury i wilgotności | RF, Xtreme Gradient Boosting, Support Vector Regression, MLP |
| [22] | Elektromiografia, czujniki częstości skurczów serca | RF, SVM, KNN |
| [23] | Smartwatch z czujnikiem częstości skurczów serca i akcelerometrem | MLP |
| [24] | Czujniki parametrów fizjologicznych | RF, ANN, SVM, KNN |
| **Niebezpieczne ruchy i zachowania pracowników** | | |
| [25] | Kamery rejestrujące zachowania pracowników | MLP |
| [26] | Kamery rejestrujące ruchy pracowników | CNN |
| [27] | Akcelerometr oraz czujniki temperatury, wilgotności, gazów, ciśnienia i oświetlenia | SVM, NB, CNN, Static Neural Network |
| [28] | Elektroencefalografia | CatBoost |
| [29] | Kamery rejestrujące ruchy pracowników | CNN |
| **Czynniki psychospołeczne (stres w pracy)** | | |
| [30] | Czujniki parametrów fizjologicznych | K-Means Clustering |
| [31] | Elektrokardiografia i rejestracja ruchów | NB, SVM, CNN, LR |
| [32] | T-shirt z czujnikami ECG (elektrokardiografia) | CNN |
| **Drgania mechaniczne (wibracje)** | | |
| [33] | Czujniki drgań (akcelerometry) na nadgarstkach | KNN |
| [34] | Czujniki drgań (akcelerometry) na nadgarstkach | KNN |
| [35] | Czujniki drgań (akcelerometry) w smartwatchu | Polynomial Classifier, KNN |
| **Monitorowanie stosowania środków ochrony indywidualnej (zagrożenia wypadkowe)** | | |
| [36] | Czujniki butów, hełmu i pasa bezpieczeństwa | SVM |
| [37] | Kamery rejestrujące sylwetki pracowników | CNN (YOLO v. 8) |
| [38] | Kamery rejestrujące sylwetki pracowników | CNN (YOLOX) |
| [39] | Kamery rejestrujące sylwetki pracowników | CNN (YOLACT) |
| [40] | Kamery rejestrujące sylwetki pracowników | CNN (YOLO v. 4) |
| [41] | Kamery rejestrujące sylwetki pracowników | CNN (YOLO, DenseNet) |
| [42] | Kamery rejestrujące sylwetki pracowników | CNN |
| [43] | Kamery rejestrujące sylwetki pracowników | CNN (Faster R-CNN) |
| [44] | Kamery rejestrujące sylwetki pracowników | CNN |
| [45] | Kamery rejestrujące sylwetki pracowników | CNN |
| [46] | Kamery rejestrujące sylwetki pracowników | CNN |

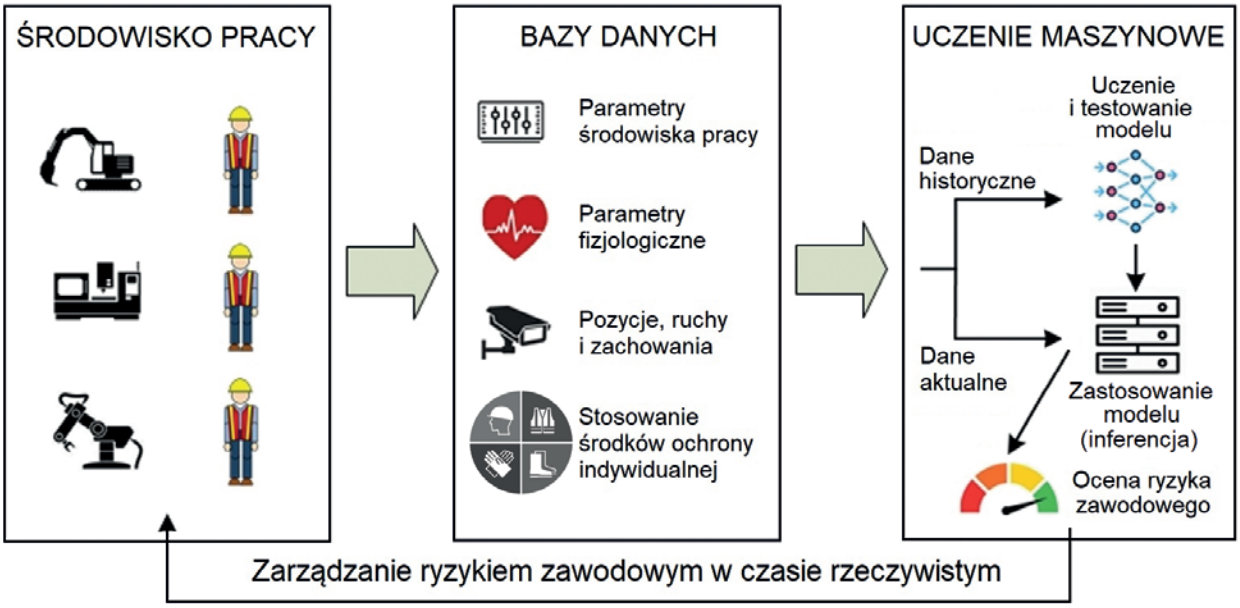


Rys. 3. Model konceptualny zastosowania algorytmów UM w procesie ORZ w czasie rzeczywistym (na podstawie [47])
*Fig. 3. Conceptual model of the application of UM algorithms in the real-time ORZ process (based on [47])*

nadzorowany algorytm, który wykorzystuje bliskość do klasyfikacji lub przewidywania grupowania poszczególnych punktów danych, czyli zakłada, że każdy punkt danych zbliżający się do siebie należy do tej samej klasy. Algorytm KNN polega na obliczaniu odległości między danymi wejściowymi a danymi w zbiorze treningowym, wyborze *k*-najbliższych sąsiadów danych wejściowych oraz przewidywaniu klasy lub wartości danych wejściowych na podstawie klasy większościowej lub średniej wartości sąsiadów. Metoda ta ma praktyczne zastosowanie m.in. w medycynie, analizach ekonomicznych, rozpoznawaniu tekstu czy przetwarzaniu obrazów. W przypadku literatury objętej przeglądem algorytmy KNN wykorzystano do analizy parametrów fizjologicznych i ruchów pracowników [8, 20, 22, 24], analizy danych z czujników drgań mechanicznych [33–35] oraz sygnałów stosowania środków ochrony indywidualnej [7].

## Konceptualizacja roli algorytmów UM w ORZ

Przedstawiona analiza publikacji dotyczących zastosowania algorytmów UM do oceny i monitorowania ryzyka zawodowego w czasie rzeczywistym wskazuje na następujące uzasadnienie i uwarunkowania ich stosowania:

- wydobywanie wzorców i zależności – w danych pomiarowych często występują złożone wzorce, które są trudne do zauważenia przez człowieka, a algorytmy UM mogą automatycznie wykrywać te wzorce nawet w przypadku dużych i złożonych zbiorów danych;
- zdolność do pracy z dużymi zbiorami danych – wiele systemów identyfikacji zagrożeń i monitorowania ryzyka zawodowego generuje ogromne ilości danych pomiarowych, które są zbyt duże i złożone, aby je analizować tradycyjnymi metodami;
- praca z szumami lub błędami pomiarowymi – w sytuacji gdy dane pomiarowe są obarczone szumem, błędami lub brakującymi danymi, tradycyjne metody statystyczne mogą nie być skuteczne, a algorytmy UM potrafią „nauczyć się", jak sobie radzić z niepełnymi lub szumowymi danymi;
- automatyzacja i szybkość – uczenie maszynowe może przyspieszyć proces analizy danych pomiarowych, a dzięki zastosowaniu odpowiednich algorytmów możliwe jest szybkie analizowanie nowych danych i generowanie wyników ORZ w czasie rzeczywistym;
- dokładność i precyzyjność – algorytmy UM, po odpowiednim wytrenowaniu, mogą oferować wyższą dokładność i precyzję w przewidywaniu lub klasyfikacji wyników na podstawie danych pomiarowych w porównaniu z klasycznymi metodami statystycznymi;
- adaptacyjność – w miarę zbierania nowych danych modele uczenia maszynowego mogą być aktualizowane i dostosowywane, co pozwala im lepiej radzić sobie z nowymi trendami czy nieoczekiwanymi zmianami w danych;
- predykcja i prognozowanie – algorytmy UM umożliwiają tworzenie modeli predykcyjnych, które na podstawie danych historycznych mogą przewidywać przyszłe wyniki lub trendy w zakresie zmian poziomu ryzyka zawodowego.

Biorąc powyższe pod uwagę, przedstawiony w artykule przegląd literatury naukowej pozwala na przedstawienie modelu konceptualnego funkcji algorytmów UM w procesie oceny i monitorowania ryzyka zawodowego w czasie rzeczywistym (rys. 3).

## Podsumowanie

Z przeglądu literatury naukowej dotyczącej zastosowania algorytmów UM do ORZ w czasie rzeczywistym wynika, że dziedzina ta zaczęła się rozwijać kilka lat temu i obejmuje obecnie kilkadziesiąt propozycji rozwiązań technicznych. Rozwiązania te są adresowane do różnych sektorów gospodarki oraz różnych środowisk pracy i rodzajów prac, a sektorem dominującym w tym zakresie jest budownictwo (pozostałe sektory to: rolnictwo, przemysł maszynowy, przemysł chemiczny, ochrona zdrowia i straż pożarna). W wielu przypadkach opracowane rozwiązania są uniwersalne i mogą być wykorzystane w odniesieniu do różnych środowisk pracy, niezależnie od sektora działalności.

Zastosowanie algorytmów UM do identyfikacji zagrożeń i ORZ w czasie rzeczywistym jest przydatne zwłaszcza w przypadku dużych i złożonych zbiorów danych pomiarowych, które wymagają wykrywania wzorców, klasyfikacji, prognozowania lub wykrywania anomalii.

Przegląd literatury pokazał, że do wspomagania procesów ORZ w opisywanych rozwiązaniach wykorzystuje się ponad 20 rodzajów algorytmów UM. Zestawienie tych algorytmów oraz źródeł danych wejściowych uwzględnianych w analizowanych rozwiązaniach pozwoliło podzielić te rozwiązania na następujące obszary:

- zagrożenia chemiczne;
- upadki, potknięcia i upadki z wysokości;
- czynniki mięśniowo-szkieletowe, przenoszenie ciężarów i pozycja przy pracy;
- obciążenia termiczne, wysiłek fizyczny i zmęczenie;
- niebezpieczne ruchy i zachowania pracowników;
- czynniki psychospołeczne (stres);
- drgania mechaniczne;
- monitorowanie stosowania środków ochrony indywidualnej.

Najczęściej stosowanymi algorytmami w tych obszarach są konwolucyjne sieci neuronowe, maszyny wektorów nośnych, las losowy oraz metoda *k*-najbliższych sąsiadów.

Biorąc pod uwagę dynamiczny postęp w rozwoju technologii internetu rzeczy i sztucznej inteligencji, można prognozować, że w najbliższej przyszłości potencjał algorytmów UM będzie coraz szerzej wykorzystywany do procesów ORZ w czasie rzeczywistym. Podstawową zaletą tego podejścia będzie wykrywanie i monitorowanie zagrożeń w środowisku pracy w sposób ciągły i zautomatyzowany, co pozwoli na ograniczanie związanego z nimi ryzyka zawodowego bezpośrednio po zdiagnozowaniu zagrożeń.

## BIBLIOGRAFIA


[1] Maheronnaghsh S. et al., *Machine learning in Occupational Safety and Health – a systematic review*, „International Journal of Occupational and Environmental Safety", 2023, 1: 14–32.

[2] PN-N-180022011. Systemy zarządzania bezpieczeństwem i higieną pracy. Ogólne wytyczne do oceny ryzyka zawodowego.

[3] Magoni M. et al. *Novel Chemoresistive Sensors for Indoor $CO_2$ Monitoring: Validation in an Operational Environment*, „ACS Sensors", 2024, 9(6): 2999–3008.

[4] Muraleedharan Jalajamony H.M., De S., Fernandez R.E., *NFC-Enabled Batteryless AI-Integrated Sensing Network for Smart PPE System*, „IEEE Sensors Journal", 2024, 24(16): 26914–26925.

[5] Patton N.A., *Novel Methods for Occupational and Non-Occupational Exposure Assessment for Improved Risk Assessment and Decision Making*, Johns Hopkins University, Baltimore 2021.

[6] Li J., Ouyang Y., Luo X., T*owards an EEG-Based Approach for Detecting Falls from Height Hazards Using Construction Workers' Physiological Signals*, Construction Research Congress, 2022.

[7] Khan M. et al., *IMU based Smart Safety Hook for Fall Prevention at Construction Sites*, IEEE Region 10 Symposium (TENSYMP), Jeju, Korea, 2021, s. 1–6.

[8] Kou J. et al., *Fall-risk assessment of aged workers using wearable inertial measurement units based on machine learning*, „Safety Science", 2024, 176: 1–14.

[9] O'Sullivan P. et al., *AI-Based Task Classification With Pressure Insoles for Occupational Safety*, „IEEE Access", 2024, 12: 21347–21357.

[10] Cobb B.S., Candan F., *Improving Workplace Safety in the Cargo Industry through Posture Monitoring using Mediapipe and Machine Learning*, International Conference on Innovations in Intelligent Systems and Applications (INISTA), 2023, s. 1–6.

[11] Low J.X. et al., *ActSen – AI-enabled Real-time IoT-based Ergonomic Risk Assessment System*, IEEE International Congress on Internet of Things (ICIOT), 2019, s. 76–78.

[12] Thomas B. et al., *Machine Learning for Detection and Risk Assessment of Lifting Action*, „IEEE Transactions on Human-Machine Systems", 2022, 52(6): 1196–1204.

[13] Massiris Fernández M., *Ergonomic risk assessment based on computer vision and machine learning*, „Computers & Industrial Engineering", 2020, 149: 1–11.

[14] Conforti I. et al., *Measuring Biomechanical Risk in Lifting Load Tasks through Wearable System and Machine-Learning Approach*, „Sensors", 2020, 20(6): 1–17.

[15] Hosseinian S.M. et al., *Static and Dynamic Work Activity Classification from a Single Accelerometer: Implications for Ergonomic Assessment of Manual Handling Tasks*, „IISE Transactions on Occupational Ergonomics and Human Factors", 2019, 7: 59–68.

[16] Yu J. et al., *Automatic Biomechanical Workload Estimation for Construction Workers by Computer Vision and Smart Insoles*, „Journal of Computing in Civil Engineering", 2019, 33(3): 1–28.

[17] Lee Y.-C., Lee C.-H., *SEE: A proactive strategy-centric and deep learning-based ergonomic risk assessment system for risky posture recognition*, „Advanced Engineering Informatics", 2022, 53, 1–14.

[18] Hosseini N., Arjmand N., *An artificial neural network for full-body posture prediction in dynamic lifting activities and effects of its prediction errors on model-estimated spinal loads*, „Journal of Biomechanics", 2024, 162: 2–11.

[19] Bustos D. et al., *Machine Learning Approach to Model Physical Fatigue during Incremental Exercise among Firefighters*, „Sensors", 2023, 23(1): 1–13.

[20] Sadat-Mohammadi M. et al., *Non-invasive physical demand assessment using wearable respiration sensor and random forest classifier*, „Journal of Building Engineering", 2024, 44: 1–10.

[21] Choi Y. et al., *A machine learning-based forecasting model for personal maximum allowable exposure time under extremely hot environments*, „Sustainable Cities and Society", 2024, 101: 1–17.

[22] Khan M. et al., *Developing Prediction Models for Monitoring Workers' Fatigue in Hot Conditions*, „Computing in Civil Engineering", 2023, s. 623–630.

[23] Sowiński P. et al., *Frugal Heart Rate Correction Method for Scalable Health and Safety Monitoring in Construction Sites*, „Sensors", 2023, 23(14): 6464.

[24] Shakerian S. et al., *Assessing occupational risk of heat stress at construction: A worker-centric wearable sensor-based approach*, „Safety Science", 2021, 142: 1–13.

[25] Irumva T. et al., *Agricultural Machinery Operator Monitoring System (Ag-OMS): A Machine Learning Approach for Real-Time Operator Safety Assessment*, „Journal of Agricultural Safety and Health", 2023, 29: 85–97.

[26] Bavaresco R. et al., *An ontology-based framework for worker's health reasoning enabled by machine learning*, „Computers & Industrial Engineering", 2024, 193: 1–16.

[27] Campero-Jurado I. et al., *Smart Helmet 5.0 for Industrial Internet of Things Using Artificial Intelligence*, „Sensors", 2020, 20(21): 6241.

[28] Jeon J.H., Cai H. *Classification of construction hazard related perceptions using: Wearable electroencephalogram and virtual reality*, „Automation in Construction", 2021, 132: 1–10.

[29] Wu H. et al., *Identifying Unsafe Behavior of Construction Workers: A Dynamic Approach Combining Skeleton Information and Spatiotemporal Features*, „Journal of Construction Engineering and Management", 2023, 149(11): 1–32.

[30] Ciccarelli M. et al., *Human work sustainability tool*, „Journal of Manufacturing Systems", 2022, 62(7):76–86.

[31] Bangani R.G., Menon V., Jovanov E., *Personalized Stress Monitoring AI System for Healthcare Workers*, IEEE International Conference on Bioinformatics and Biomedicine (BIBM), 2021, s. 2992–2997.

[32] Donati M. et al., *ECG-Based Stress Detection and Productivity Factors Monitoring: The Real-Time Production Factory System*, „Sensors", 2023, 23(12): 5502.

[33] Aiello G. et al., *Machine Learning approach towards real time assessment of hand-arm vibration risk*, „IFAC-PapersOnLine", 2021, 54(1): 1187–1192.

[34] Aiello G. et al., *Worker safety in agriculture 4.0: A new approach for mapping operator's vibration risk through Machine Learning activity recognition*, „Computers and Electronics in Agriculture", 2022, 193: 1–10.

[35] Sigcha L. et al., *Automatic Identification of Hand-Held Vibrating Tools through Commercial Smartwatches and Machine Learning*, [w:] P. Arezes et al., *Occupational and Environmental Safety and Health II. Studies in Systems, Decision and Control*, vol. 277, Springer, 2020, s. 481–489.

[36] Pisu A. et al., *Enhancing workplace safety: A flexible approach for personal protective equipment monitoring*, „Expert Systems with Applications", 2024, 238: 1–16.

[37] Yakubraj M. et al., *Monitoring Industrial Protection Gear Using Intelligent System*, 2nd International Conference on Networking and Communications (ICNWC), 2024, s. 1–6.

[38] Wang Z., Cai Z., Wu Y., *An improved YOLOX approach for low-light and small object detection: PPE on tunnel construction sites*, „Journal of Computational Design and Engineering", 2023, 10: 1158–1175.

[39] Lee Y.-R., *Deep learning-based framework for monitoring wearing personal protective equipment on construction sites*, „Journal of Computational Design and Engineering", 2023, 10(2): 1–13.

[40] Biswas S. et al., *Real-Time Construction Safety Gear Detection Using YOLOv4 with Darknet*, IEEE 17th International Conference on Application of Information and Communication Technologies (AICT), 2023, s. 1–6.

[41] Yu W. et al., *Real-time Identification of Worker's Personal Safety Equipment with Hybrid Machine Learning Techniques*, „International Journal of Machine Learning and Computing", 2022, 12(3): 79–84.

[42] Kamal R. et al., *Construction Safety Surveillance Using Machine Learning*, International Symposium on Networks, Computers and Communications (ISNCC), Montreal, Canada, 2020, s. 1–6.

[43] Yu W. et al., *Automatic Safety Monitoring of Construction Hazard Working Zone: A Semantic Segmentation based Deep Learning Approach*, Proceedings of the 7th International Conference on Automation and Logistics (ICAL), 2020, s. 54–59.

[44] Nath N.D. et al., *Deep learning for site safety: Real-time detection of personal protective equipment*, „Automation in Construction", 2020, 112: 1–20.

[45] Al-Khiami M.I., Elhadad M.M., *Enhancing Construction Site Safety Using AI: The Development of a Custom Yolov8 Model for PPE Compliance Detection*, European Conference on Computing in Construction, Chania, Crete, Greece, 2024, s. 1–8.

[46] Alves D.N.A. et al., *TinyPPE: Ensuring Workplace Safety Helmet Compliance with Tiny Machine Learning*, XIV Brazilian Symposium on Computing Systems Engineering (SBESC), 2024, s. 1–6.

[47] Tercan H., Meisen T., *Machine learning and deep learning based predictive quality in manufacturing: a systematic review*, „Journal of Intelligent Manufacturing", 2022, 33: 1879–1905.