

Modelowanie czynników wpływających na wydajność pracowników bibliotek z użyciem metod uczenia maszynowego

Słowa kluczowe: bibliotekarze, zmęczenie, biometryka, uczenie maszynowe, klasyfikacja

Abstrakt: Celem badań przedstawionych w artykule jest opracowanie skutecznego systemu klasyfikacji poziomu zmęczenia pracowników bibliotek na podstawie sygnałów biometrycznych i behawioralnych. System ten ma umożliwiać wczesne wykrywanie pięciu poziomów zmęczenia, od braku zmęczenia po stan uniemożliwiający efektywną pracę. W badaniu porównano skuteczność różnych algorytmów uczenia maszynowego. Uzyskane wyniki posłużą do stworzenia inteligentnych narzędzi wspierających zarządzanie dobrostanem pracowników.

Keywords: librarians, fatigue, biometrics, machine learning, classification

Abstract: The objective of the study presented in this article is the development of an effective system for the classification of fatigue levels among library personnel, based on biometric and behavioral signals. The proposed system aims to enable early detection of five distinct fatigue levels, ranging from the absence of fatigue to a state of impairment that hinders effective job performance. The research involves a comparative evaluation of various machine learning algorithms to determine their classification efficacy. The findings will contribute to the development of intelligent tools designed to support the management of employee well-being.

Wprowadzenie

Celem badań przedstawionych w artykule było stworzenie modelu, który – wykorzystując algorytmy uczenia maszynowego – umożliwi ocenę poziomu zmęczenia pracowników bibliotek podczas wykonywania obowiązków zawodowych. W sytuacji wykrycia zmęczenia przekraczającego ustalony próg (na skali pięciostopniowej) system automatycznie zasugeruje przerwę. Ma to na celu nie tylko redukcję zmęczenia, lecz także wspieranie procesów poznawczych oraz prewencję wypalenia zawodowego. Badania wskazują, że nawet krótkie przerwy – trwające kilkanaście sekund – mogą znacząco zmniejszyć poziom zmęczenia fizycznego i poznawczego [21; 36].

W pracy bibliotekarzy istotną rolę odgrywa kilka rodzajów zmęczenia [12]. Zmęczenie może przyjmować różne formy, zależne od charakteru pracy i warunków jej wykonywania. Zmęczenie okołodobowe wiąże się z zakłóceniem rytmu dobowego, np. wskutek pracy wieczorami, nocą lub w nadgodzinach, co prowadzi do zaburzeń snu i obniżenia sprawności psychofizycznej [11]. Dochodzi do niego np. u bibliotekarzy akademickich w okresie sesji, kiedy wspierają oni pracę czytelników w godzinach wieczornych i nocnych, podczas całodobowego otwarcia biblioteki. Drugi rodzaj – zmęczenie mięśniowe – występuje głównie przy długotrwałym staniu, przenoszeniu ciężkich przedmiotów czy wykonywaniu powtarzalnych czynności – jego skutki, takie jak spadek sprawności ruchowej, można obiektywnie ocenić za pomocą analizy sygnałów EMG i MMG [6; 30]. Cierpią na nie np. magazynierzy, ale też bibliotekarze na stanowiskach wypożyczeń odpowiedzialni za dostarczanie książek czytelnikom. Z kolei zmęczenie poznawcze dotyczy spadku efektywności funkcji wykonawczych, takich jak uwaga, pamięć robocza czy zdolność logicznego wnioskowania, co ma kluczowe znaczenie w zadaniach wymagających analizy danych, obsługi klienta czy pracy projektowej [32]. Takie zmęczenie jest typowe m.in. dla pracowników odpowiedzialnych za katalogowanie przedmiotowe lub działów informacji naukowej. Istotnym aspektem jest również zmęczenie psychiczne, pojawiające się w wyniku przeciążenia zadaniami, pracy pod presją czasu czy monotonii, co skutkuje spadkiem motywacji, zaangażowania i zdolności koncentracji [14; 15].

W środowisku pracy bibliotekarskiej, gdzie precyzja i koncentracja są kluczowe, wszystkie te typy zmęczenia mogą negatywnie wpływać na jakość świadczonych usług [4; 5]. Z danych literaturowych wynika, że odpowiednio zaplanowane przerwy – szczególnie o charakterze pasywnym, jak np. krótki odpoczynek w pozycji siedzącej, w ciszy – przyczyniają się do zwiększenia efektywności zawodowej i lepszej regeneracji umysłu [27; 33].

Narzędzia psychometryczne i fizjologiczne stosowane w badaniu zmęczenia

W badaniach nad zmęczeniem, obciążeniem pracą oraz sennością często stosuje się standaryzowane narzędzia psychometryczne i fizjologiczne. Skale zmęczenia, takie jak Samn-Perelli Fatigue Scale (SPF) oraz Chalder Fatigue Scale (CFS), umożliwiają ocenę zarówno ogólnego, jak i specyficznego rodzaju zmęczenia. SPF to prosta, jednowymiarowa, 7-punktowa skala, stosowana m.in. w lotnictwie i medycynie, służąca do szybkiej, subiektywnej oceny aktualnego poziomu zmęczenia. Z kolei CFS jest bardziej złożoną skalą wielowymiarową, obejmującą 11 pozycji, które pozwalają rozróżnić zmęczenie fizyczne i psychiczne. Skala ta jest powszechnie wykorzystywana w diagnostyce przewlekłego zmęczenia i w badaniach klinicznych [9; 13; 31; 37]. Do oceny subiektywnego obciążenia pracą często wykorzystuje się NASA-TLX (Task Load Index), która obejmuje sześć wymiarów: wysiłek psychiczny, fizyczny, czasowy, poziom wydajności, frustrację oraz ogólny wysiłek. Użytkownik ocenia każdy wymiar na skali wizualno-analogowej (0–100), a następnie może zostać przeprowadzona analiza wagowa. NASA-TLX pozwala na holistyczną ocenę obciążenia zadaniowego w kontekście ergonomii, testów użyteczności i projektowania interfejsów [10].

W kontekście senności najczęściej stosuje się Karolinska Sleepiness Scale (KSS) oraz Stanford Sleepiness Scale (SSS). KSS to 9-punktowa skala, w której badany określa swój bieżący poziom senności (np. „bardzo pobudzony” do „bardzo senny, walczę o pozostanie przytomnym”) – wykorzystywana jest w badaniach snu i zmęczenia operacyjnego. SSS natomiast jest 7-punktową skalą oceniającą senność w różnych momentach dnia i w kontekście wykonywanych zadań [2; 29]. Poza subiektywnymi skalami, zmęczenie można oceniać obiektywnie, np. za pomocą zmienności rytmu serca (HRV) – wskaźnika odzwierciedlającego aktywność autonomicznego układu nerwowego. Zmniejszona zmienność HRV wiąże się z wyższym poziomem stresu i zmęczenia, a jej analiza pozwala na wczesne wykrycie spadku koncentracji. Kolejnym obiektywnym wskaźnikiem jest czas reakcji, mierzony przy pomocy prostych testów reakcji na bodźce. Wzrost czasu reakcji jest typowym objawem narastającego zmęczenia psychomotorycznego [3; 16; 24].

Wreszcie do oceny subiektywnego wysiłku psychicznego można zastosować skalę SEES (Subjective Exercise Experiences Scale), która obejmuje komponenty emocjonalne, takie jak napięcie, zmęczenie, pozytywny stan emocjonalny i wyczerpanie. Skala ta bywa używana nie tylko w sporcie, ale także w kontekście obciążenia psychicznego w zadaniach poznawczych i środowiskach wysokiego ryzyka [23]. W procesie oceny zmęczenia i obciążenia warto także brać pod uwagę czynniki indywidualne, takie jak wiek, płeć czy doświadczenie zawodowe, które mogą wpływać na subiektywne i obiektywne odczuwanie wysiłku oraz zdolność regeneracji [28]. Równie istotny jest kontekst środowiskowy, obejmujący m.in. warunki mikroklimatyczne (np. temperatura, wilgotność), natężenie hałasu czy jakość i długość snu, ponieważ czynniki te mogą znacząco modulować poziom koncentracji, senność oraz ogólne samopoczucie uczestnika [7]. W kontekście analizy i monitorowania stanu fizycznego lub emocjonalnego osoby, istnieje wiele metod, które opierają się na różnych rodzajach sygnałów biometrycznych. Sygnał EKG (elektrokardiogram) [12; 13; 26; 35] jest metodą służącą do monitorowania aktywności elektrycznej serca. Sygnały EKG pozwalają na ocenę rytmu serca, wykrywanie arytmii, a także ocenę ogólnego stanu zdrowia serca. Pomiar ten jest często stosowany w diagnostyce chorób serca oraz w monitorowaniu pacjentów w szpitalach. W kontekście analizy emocji, zmiany w sygnale EKG mogą być wykorzystywane do oceny poziomu stresu lub reakcji emocjonalnych, ponieważ aktywność serca zmienia się w odpowiedzi na emocje. Reakcja galwaniczna skóry (GSR) [35] mierzy zmiany w oporności elektrycznej skóry, które zachodzą w odpowiedzi na potliwość wywołaną stresem lub innymi bodźcami emocjonalnymi. GSR jest wykorzystywana w psychologii, szczególnie do oceny poziomu stresu, zaangażowania lub reakcji emocjonalnych. Zjawisko to jest oparte na fakcie, że w odpowiedzi na emocje lub stres gruczoły potowe wytwarzają większą ilość potu, co wpływa na przewodność elektryczną skóry.

Fotopletyzmogram (PPG) z kolei to metoda [37], która wykorzystuje światło do pomiaru zmian objętości krwi w naczyniach włosowatych. PPG jest często stosowany w urządzeniach do monitorowania tętna, takich jak pulsometry czy inteligentne zegarki. Dzięki tej technologii możliwe jest uzyskanie informacji o rytmie serca oraz poziomie saturacji tlenem we krwi. PPG może również dostarczać informacji o poziomie stresu i ogólnym stanie emocjonalnym, ponieważ zmiany w cyrkulacji krwi mają związek z reakcjami organizmu

na bodźce. Monitorowanie parametrów oddechowych obejmuje pomiar częstotliwości oddechów, głębokości oraz regularności oddechów. Zmiany w tych parametrach mogą wskazywać na reakcje organizmu na stres, zmęczenie czy inne stany emocjonalne. Często stosowane urządzenia do monitorowania oddechu to respiratory, analizatory oddechu, a także urządzenia noszone na klatce piersiowej, które rejestrują te parametry w czasie rzeczywistym [35; 37]. Temperatura ciała [37] jest jednym z podstawowych wskaźników stanu zdrowia organizmu. Wzrost lub spadek temperatury ciała może wskazywać na reakcje organizmu na stres, infekcje lub inne zaburzenia. W kontekście analizy emocjonalnej, zmiany w temperaturze ciała mogą wskazywać na wzrost stresu lub intensyfikację reakcji emocjonalnych. Monitorowanie temperatury ciała jest szeroko stosowane w diagnostyce medycznej oraz w systemach monitorowania stanu zdrowia.

Kolejne zjawisko – ruchy gałek ocznych [19; 25] – jest wykorzystywane w diagnostyce oraz w badaniach nad zachowaniami i reakcjami emocjonalnymi. Technologie śledzenia ruchów oczu pozwalają na ocenę poziomu koncentracji, zainteresowania czy stresu. Zmiany w ruchach oczu mogą również wskazywać na zmęczenie, napięcie lub inne emocje. Ruchy gałek ocznych są często stosowane w analizie zachowań użytkowników w interfejsach użytkownika oraz w badaniach psychologicznych.

EEG (elektroencefalografia) [16] to technika umożliwiająca pomiar aktywności elektrycznej mózgu. Zmiany w falach mózgowych rejestrowane za pomocą EEG mogą dostarczyć cennych informacji o stanie emocjonalnym, koncentracji, poziomie stresu czy relaksu. EEG jest powszechnie wykorzystywane w neuropsychologii, a także w badaniach nad stanami emocjonalnymi, ponieważ fale mózgowe są silnie związane z emocjami i reakcjami na bodźce.

EMG (elektromiografia) [7] jest metodą mierzenia aktywności elektrycznej mięśni. Poprzez rejestrację impulsów elektrycznych generowanych przez mięśnie EMG pozwala na ocenę napięcia mięśniowego. Zwiększone napięcie mięśniowe jest często związane ze stresem, napięciem emocjonalnym lub intensywnym wysiłkiem fizycznym. EMG jest stosowane w diagnostyce problemów mięśniowych oraz w badaniach nad reakcjami emocjonalnymi, szczególnie w kontekście stresu. Akcelerometry to urządzenia rejestrujące przyspieszenia w trzech osiach. W kontekście monitorowania stanu emocjonalnego dane z akcelerometrów mogą być używane do śledzenia ruchów ciała, takich jak drżenie rąk, wahania głowy czy zmiany w postawie ciała, które mogą wskazywać na stres, lęk lub inne emocje. Akcelerometry są szeroko stosowane w urządzeniach noszonych na ciele, takich jak opaski fitness, inteligentne zegarki oraz systemy monitorowania zdrowia [32].

Następny wskaźnik – poziom natlenienia krwi [32] (saturacja tlenem) – jest mierzony za pomocą pulsoksymetrów, które wykorzystują PPG do oceny procentowego nasycenia hemoglobiny tlenem w krwi. Obniżony poziom natlenienia może wskazywać na problemy z układem oddechowym, ale może także być związany ze stanem zdrowia osoby lub jej emocjami, takimi jak stres. Monitorowanie saturacji tlenem jest często stosowane w medycynie, w szczególności w kontekście pacjentów z problemami oddechowymi lub w analizie reakcji na stres.

Każda z tych metod jest szeroko stosowana w różnych dziedzinach, w tym w psychologii czy medycynie, a także w ramach technologii noszonych, takich jak inteligentne urządzenia monitorujące zdrowie i emocje.

Zbiór danych i metody

Zbiór danych do klasyfikacji poziomu zmęczenia został pozyskany w ramach badania przeprowadzonego na grupie 650 osób, gdzie próba reprezentatywna to 385 bibliotekarzy, co stanowi minimalną wielkość próby dla uzyskania istotności statystycznej. Dane były zbierane podczas typowych czynności wykonywanych przez bibliotekarzy w warunkach naturalnego środowiska pracy. Klasyfikacja zmęczenia została przeprowadzona na pięciostopniowej skali, gdzie klasa 1 oznacza brak oznak zmęczenia, a klasa 5 – stan, w którym zmęczenie uniemożliwia efektywną realizację obowiązków zawodowych. Ocena poziomu zmęczenia opierała się na modelu głębokiego uczenia, analizującym w czasie rzeczywistym dynamikę ruchu gałek ocznych i powiek. Model ten integrował również dane fizjologiczne i ruchowe, pozwalając na wielowymiarową klasyfikację stanu badanej osoby.

Dodatkowo zastosowano narzędzia oceny subiektywnej, takie jak NASA-TLX (Task Load Index), umożliwiające holistyczną analizę obciążenia pracą w sześciu wymiarach: wysiłku fizycznego, psychicznego, presji czasowej, poziomu frustracji, wydajności i ogólnego wysiłku [10]. W kontekście oceny senności wykorzystano Karolinska Sleepiness Scale (KSS) oraz Stanford Sleepiness Scale (SSS) – powszechnie stosowane w badaniach nad rytmem dobowym i obciążeniem operacyjnym [2; 29]. W celu obiektywnej oceny stanu fizjologicznego uczestników analizowano również zmienność rytmu serca (HRV) – jako wskaźnik aktywności autonomicznego układu nerwowego [3; 24], a także czas reakcji psychomotorycznej, mierzony za pomocą prostych testów na bodźce wzrokowe [16].

W analizie uwzględniono także czynniki indywidualne, takie jak wiek, płeć, staż pracy i poziom doświadczenia zawodowego, które mogą wpływać na subiektywne postrzeganie zmęczenia i zdolność regeneracji [28]. Równolegle monitorowano uwarunkowania środowiskowe, obejmujące mikroklimat (temperatura, wilgotność), poziom hałasu oraz jakość snu, które są istotnymi moderatorami stanu psychofizycznego pracownika [7]. Do budowy modelu zostało zastosowanych 8 metod, z których 7 to ML.

Support Vector Machines (SVM) to metoda klasyfikacji, która stara się znaleźć najlepszą hiperpowierzchnię oddzielającą klasy w przestrzeni cech, maksymalizując margines między klasami. Działa poprzez minimalizowanie błędu klasyfikacji i znajduje optymalny podział, który generalizuje do nowych, niewidzianych danych. SVM jest efektywny w przypadkach z dużymi, wysokowymiarowymi zbiorami danych, szczególnie w analizie danych, gdzie klasy są nieliniowo oddzielne [3; 19]. Drzewa decyzyjne to algorytmy klasyfikacyjne, które dokonują podziału przestrzeni cech na podstawie serii prostych warunków w węzłach, prowadząc do klasyfikacji w liściach drzewa. Są one łatwe do zrozumienia i interpretacji, co czyni je popularnymi w zastosowaniach, które wymagają transparentności decyzji [35]. Lasy losowe to technika ensemble, która tworzy wiele drzew decyzyjnych i łączy ich wyniki w celu uzyskania bardziej stabilnej i dokładnej prognozy. Używając losowych próbek danych oraz losowych cech, lasy losowe zmniejszają ryzyko przeuczenia i poprawiają dokładność modelu, co czyni je skutecznymi w klasyfikacji złożonych danych [25; 28].

Głębokie sieci neuronowe to rodzaj sieci neuronowych z wieloma warstwami ukrytymi, które są zdolne do nauki złożonych reprezentacji danych. Dzięki dużej liczbie param-

trów DNN może efektywnie rozwiązywać problemy związane z dużymi zbiorami danych, takie jak rozpoznawanie obrazów czy analiza tekstu, ucząc się hierarchii cech [37]. Sieci konwolucyjne to typ sieci neuronowych, które szczególnie dobrze sprawdzają się w analizie obrazów. Stosują operacje konwolucji, które umożliwiają wykrywanie lokalnych wzorców w danych, takich jak krawędzie, tekstury czy formy, co czyni je skutecznymi w zadaniach rozpoznawania obrazów i wideo [17]. Klasyczne sieci neuronowe (NN) są podstawową formą sieci neuronowych, w której dane wejściowe są przekazywane przez warstwy neuronów, które uczą się nieliniowych zależności między cechami a wyjściami. NN wykorzystywane są w szerokim zakresie zastosowań, od klasyfikacji po regresję, jednak ich wydajność w dużych zbiorach danych jest ograniczona w porównaniu do głębokich sieci [18].

Algorytmy k-najbliższych sąsiadów (KNN) to technika klasyfikacji, w której klasa nowego przykładu jest określana na podstawie większościowej klasy spośród k najbliższych sąsiadów w przestrzeni cech. Jest to metoda nieparametryczna, co oznacza, że nie zakłada żadnej formy rozkładu danych, ale jej skuteczność zależy od odpowiedniego doboru wartości k i miary odległości [13].

Ukryte modele Markowa (HMM) to z kolei probabilistyczne modele sekwencyjne, które są stosowane w analizie danych czasowych. Używają one ukrytych stanów, które nie są bezpośrednio obserwowalne, i pozwalają na modelowanie przejść między tymi stanami na podstawie obserwowanych danych, co czyni je przydatnymi w zadaniach, takich jak rozpoznawanie mowy czy analiza sekwencji DNA [7].

Ewaluacja eksperymentalna

Ocena skuteczności modelu, tj. efektywność klasyfikatora była oceniana z wykorzystaniem następujących metryk: Accuracy, AUC, F1-score oraz Kappa [1]. W celu uniknięcia nadmiernego dopasowania modelu zastosowano walidację krzyżową pięciokrotną [8; 22]. Celem analizy była odpowiedź na pytanie badawcze: *Czy można skutecznie dokonać klasyfikacji zmęczenia pracowników bibliotek?* Aby odpowiedzieć na to pytanie, zastosowano 8 różnych metod. Ich dobór nie jest przypadkowy, ale wynika z ich specyfiki i różnic. Eksperymenty przeprowadzono w środowisku PYTHON 3.0. Wyniki zamieszczono w tabeli 1 i na rysunku 1.


Tabela 1. Wyniki przeprowadzonych eksperymentów

Algorytm	Accuracy (%)	AUC	F1-score	Kappa
SVM	92,30	0,88	0,78	0,62
Drzewa decyzyjne	90,40	0,84	0,74	0,54
Lasy losowe	93,70	0,91	0,89	0,71
DNN (Deep NN)	94,50	0,94	0,94	0,74
CNN (Conv. NN)	94,80	0,95	0,96	0,75
Klasyczne NN	91,20	0,87	0,81	0,65

KNN	90,10	0,85	0,73	0,53
HMM (Ukryte Markowa)	90,70	0,86	0,76	0,57

Źródło: opracowanie własne.

Rysunek 1. Wykresy przedstawiające wyniki poszczególnych metryk w podziale na typ klasyfikatora



Źródło: opracowanie własne.

Na podstawie przeprowadzonych badań porównujących skuteczność różnych algorytmów uczenia maszynowego w klasyfikacji poziomów zmęczenia pracowników bibliotek – od klasy 1 (brak zmęczenia), przez klasę 2 (zmęczenie lekkie), klasę 3 (zmęczenie średnie), klasę 4 (zmęczenie duże), aż po klasę 5 (zmęczenie uniemożliwiające efektywną pracę) – można sformułować szereg kluczowych wniosków.

Najwyższą skuteczność osiągnęły algorytmy głębokiego uczenia, w szczególności sieci konwolucyjne (CNN) oraz głębokie sieci neuronowe (DNN). CNN uzyskały najlepsze wyniki we wszystkich metrykach: 94,8% dokładności (Accuracy), AUC 0.95, F1-score 0.96 i współczynnik Kappa 0.75, co oznacza, że algorytm ten najtrafniej klasyfikuje wszystkie pięć klas zmęczenia, szczególnie dobrze radząc sobie z rozpoznawaniem skrajnych stanów – braku zmęczenia (klasa 1) i zmęczenia skrajnego (klasa 5). Tuż za nimi uplasowały się DNN, osiągając bardzo zbliżone wyniki – Accuracy na poziomie 94,5%, AUC 0.94, F1-score 0.94 oraz Kappa 0.74. Lasy losowe również wykazały wysoką skuteczność (Accuracy 93,7%,

AUC 0.91, F1-score 0.89, Kappa 0.71), co potwierdza ich dobrą zdolność do generalizacji i radzenia sobie z różnorodnością danych. Warto zaznaczyć, że algorytmy te, podobnie jak sieci neuronowe, lepiej rozpoznawały umiarkowane i wysokie poziomy zmęczenia (klasy 3 i 4), które często sprawiają problemy innym modelom. SVM osiągnęły Accuracy 92,3%, co plasuje je w górnej strefie zestawienia. Choć ich F1-score (0.78) i Kappa (0.62) były niższe od modeli głębokiego uczenia, to nadal prezentowały solidne wyniki, szczególnie w klasyfikowaniu klas 2 (zmęczenie lekkie) i 3 (zmęczenie średnie). Klasyczne sieci neuronowe oraz HMM uzyskały wyniki odpowiednio: Accuracy 91,2% i 90,7%, F1-score 0.81 i 0.76, Kappa 0.65 i 0.57. Choć nieco słabsze od modeli głębokich, nadal spełniają wymogi wysokiej jakości klasyfikacji. HMM szczególnie dobrze poradziły sobie z sekwencyjnym rozpoznawaniem stanu zmęczenia, co może być użyteczne w analizach czasowych. KNN oraz drzewa decyzyjne osiągnęły najniższe wartości metryk, ale mimo to mieszczą się w oczekiwanym zakresie (Accuracy powyżej 90%). Drzewa decyzyjne (Accuracy 90,4%, F1-score 0.74, Kappa 0.54) miały trudność z rozróżnieniem klas pośrednich (2, 3, 4), natomiast KNN (Accuracy 90,1%, Kappa 0.53) wykazywał tendencję do klasyfikowania stanów zmęczenia na podstawie bliskości do klas dominujących, co wpływało negatywnie na dokładność. Algorytmy głębokiego uczenia, takie jak CNN i DNN, są najbardziej rekomendowane do klasyfikacji zmęczenia pracowników bibliotek, zwłaszcza przy użyciu złożonych danych (np. sygnałów biometrycznych, obrazów twarzy). Algorytmy klasyczne, jak HMM czy drzewa decyzyjne, mogą wspierać mniej złożone systemy lub działać w modelach hybrydowych. Wysoka wartość AUC (0.84–0.95) świadczy o dobrej zdolności rozróżniania klas, a współczynnik Kappa wskazuje, że wszystkie modele przewyższają losowe przyporządkowanie klas.

Rekomendacje

Na podstawie wyników analizy, która uwzględnia zarówno dane obiektywne, jak i subiektywne, rekomenduje się zastosowanie algorytmów głębokiego uczenia, zwłaszcza sieci konwolucyjnych (CNN) oraz głębokich sieci neuronowych (DNN), do klasyfikacji poziomu zmęczenia pracowników bibliotek. Te modele wykazały najwyższą skuteczność (Accuracy: 94,8% i 94,5%, AUC: 0.95 i 0.94, F1-score: 0.96 i 0.94, Kappa: 0.75 i 0.74), co czyni je najlepszymi narzędziami do analizy danych złożonych, takich jak sygnały biometryczne, obrazy twarzy oraz dynamika ruchów gałek ocznych. Modele te skutecznie rozpoznają skrajne stany zmęczenia, w tym zarówno brak zmęczenia (klasa 1), jak i zmęczenie skrajne (klasa 5), co ma istotne znaczenie w kontekście zapewnienia wydajności pracy bibliotekarzy.

W analizie uwzględniono również narzędzia oceny subiektywnej, takie jak NASA-TLX, które umożliwiają holistyczną ocenę obciążenia pracą w sześciu wymiarach: wysiłku fizycznego, psychicznego, presji czasowej, poziomu frustracji, wydajności i ogólnego wysiłku. Te narzędzia pozwalają na bardziej złożoną interpretację zmęczenia, uwzględniając zarówno jego aspekt fizyczny, jak i psychiczny. W kontekście oceny senności włączenie Karolinska Sleepiness Scale (KSS) oraz Stanford Sleepiness Scale (SSS) umożliwia precyzyjniejszą klasyfikację zmęczenia w zależności od rytmu dobowego oraz obciążenia operacyjnego.

Do oceny stanu fizjologicznego uczestników użyto zmienności rytmu serca (HRV), co pozwala na monitorowanie aktywności autonomicznego układu nerwowego, oraz czasu reakcji psychomotorycznej, mierzonego za pomocą prostych testów na bodźce wzrokowe. Te dane mają kluczowe znaczenie w precyzyjnym rozpoznawaniu poziomów zmęczenia, zwłaszcza w kontekście zmniejszonej koncentracji i reakcji motorycznych.

Dodatkowo uwzględnienie czynników indywidualnych, takich jak wiek, płeć, staż pracy i poziom doświadczenia zawodowego, pozwala na lepsze dostosowanie systemu klasyfikacji do indywidualnych różnic w postrzeganiu zmęczenia oraz zdolności regeneracji. Zmienne socjodemograficzne, takie jak wiek, płeć, staż pracy, poziom doświadczenia zawodowego, a także styl życia i aktywność fizyczna, mają istotny wpływ na poziom zmęczenia pracowników bibliotek i ich zdolność do regeneracji. W przypadku pracowników młodszych ich organizmy zazwyczaj wykazują wyższą odporność na zmęczenie, co może przekładać się na lepszą efektywność w pracy. Z kolei starsi bibliotekarze, z uwagi na naturalne zmiany w organizmach, mogą odczuwać zmęczenie bardziej intensywnie, zwłaszcza w wyniku obciążenia fizycznego i psychicznego, co może wpłynąć na ich zdolność do wykonywania codziennych obowiązków. Płeć również odgrywa istotną rolę – kobiety w bibliotece mogą doświadczać zmęczenia w inny sposób (na postrzeganie zmęczenia mogą wpływać np. cykliczne zmiany hormonalne, a także dodatkowe obowiązki). Mężczyźni, chociaż mogą wykazywać inną reakcję na zmęczenie fizyczne, również narażeni są na zmęczenie psychiczne związane z wysokimi wymaganiami zawodowymi.

Na poziom zmęczenia wpływają także staż pracy i doświadczenie zawodowe. Pracownicy z większym stażem mogą lepiej adaptować się do pracy, jednak z czasem, w wyniku długotrwałego obciążenia, zmniejsza się ich wydolność organizmu, co może prowadzić do chronicznego zmęczenia. Młodsze osoby, dopiero zaczynające pracę w bibliotece, mogą doświadczać większego zmęczenia, szczególnie na początku swojej kariery, z uwagi na stres związany z nowymi obowiązkami.

W kontekście zmęczenia kluczowe znaczenie mają również aktywność fizyczna i styl życia pracowników bibliotek. Pracownicy prowadzący aktywny tryb życia, angażujący się w regularne ćwiczenia, mogą lepiej radzić sobie ze zmęczeniem zarówno fizycznym, jak i psychicznym, co przekłada się na ich lepszą kondycję w pracy. Z kolei osoby prowadzące siedzący tryb życia, co w przypadku pracowników bibliotek jest dość powszechne, mogą odczuwać zmęczenie szybciej i intensywniej, co zmniejsza ich efektywność.

Ponadto czynniki, takie jak stres związany z pracą, nadmiar obowiązków administracyjnych czy interakcje z czytelnikami, mogą powodować zmęczenie psychiczne, szczególnie w przypadku pracowników bibliotek, którzy muszą często zarządzać dużą liczbą zadań jednocześnie.

Na zmęczenie bibliotekarzy może również wpływać status społeczno-ekonomiczny, ponieważ osoby o niższym statusie mogą mieć ograniczony dostęp do zasobów wspomagających regenerację, jak np. wsparcie zdrowotne, co może prowadzić do większego odczuwania zmęczenia. Z kolei pracownicy o wyższym statusie, posiadający lepsze warunki życia i dostęp do lepszej opieki zdrowotnej, mogą lepiej zarządzać zmęczeniem i skuteczniej regenerować siły. Wszystkie te zmienne socjodemograficzne należy uwzględniać w analizie

zmęczenia wśród pracowników bibliotek, aby opracować skuteczne strategie zapobiegające wypaleniu zawodowemu i poprawiające wydajność pracy w tym zawodzie.

Choć lasy losowe, SVM, drzewa decyzyjne i KNN również wykazały wysoką skuteczność (Accuracy powyżej 90%), to modele głębokiego uczenia, zwłaszcza CNN i DNN, osiągnęły lepsze wyniki w klasyfikacji bardziej złożonych stanów zmęczenia, takich jak klasy 3 i 4 (umiarkowane i wysokie zmęczenie). W związku z tym rekomenduje się implementację algorytmów głębokiego uczenia w systemach monitorujących zmęczenie, zwłaszcza w środowiskach pracy o zróżnicowanych obciążeniach fizycznych i psychicznych, jak biblioteki. Algorytmy klasyczne, takie jak HMM i drzewa decyzyjne, mogą być użyteczne w mniej skomplikowanych systemach lub w połączeniu z modelami hybrydowymi, które łączą ich mocne strony.

Zakończenie

Podjęte badania wykazały, że klasyfikacja poziomów zmęczenia pracowników bibliotek przy użyciu zaawansowanych algorytmów uczenia maszynowego jest skuteczną metodą monitorowania stanu psychofizycznego w środowisku pracy. Wyniki eksperymentów jednoznacznie wskazują na wyższość sieci konwolucyjnych (CNN) oraz głębokich sieci neuronowych (DNN) w zakresie skuteczności klasyfikacji, co potwierdza wysokie wartości metryk, takich jak dokładność, AUC, F1-score oraz Kappa.

Systemy bazujące na tych algorytmach mogą stać się integralną częścią rozwiązań wspierających zarządzanie dobrostanem pracowników, umożliwiając wczesne wykrywanie zmęczenia i oferując możliwość szybkiej interwencji w postaci rekomendacji przerwy. Takie podejście przyczyni się do zwiększenia efektywności pracy, zmniejszenia ryzyka wypalenia zawodowego oraz poprawy jakości świadczonych usług w środowisku bibliotekarskim, sprzyjając optymalizacji procesów wewnętrznych i lepszemu zarządzaniu placówką [szerz. zob. też 34]. W przyszłości rozwój systemów, takich jak ten, z wykorzystaniem większej liczby danych oraz jeszcze bardziej zaawansowanych algorytmów, może otworzyć nowe możliwości w kontekście monitorowania zdrowia i dobrostanu pracowników w innych zawodach wymagających intensywnej koncentracji i długotrwałego wysiłku.

Bibliografia

1. ADÃO MARTINS Neusa R., ANNAHEIM Simon, SPENGLER Christina M., ROSSI René M. Fatigue Monitoring Through Wearables: A State-of-the-Art Review. *Frontiers in Psychology*. 2021, vol. 12, s. 1-25. ISSN 1664-1078.
2. ÅKERSTEDT Torbjörn, GILLBERG Mats. Subjective and Objective Sleepiness in the Active Individual. *International Journal of Neuroscience*. 1990, nr 1-2, s. 29-37. ISSN 0020-7454.
3. AL-LIBAWY Hilal, AL-ATABY Ali, AL-NUAIMY Waleed, AL-TAEE Majid A. HRV-based operator fatigue analysis and classification using wearable sensors. In *2016 13th International Multi-Conference on Systems, Signals & Devices (SSD)*. Leipzig: IEEE, s. 268-273, 2016.

4. ALMANSOORI Noura, ALDULAIJAN Samah, ALTHANI Sara, HASSAN Noha M., NDIAYE Malick, AWAD Mahmoud. Manual spray painting process optimization using Taguchi robust design. *International Journal of Quality & Reliability Management*. 2020, nr 1, s. 46-67. ISSN 0265-671X.
5. BJÖRING Gunnar, HÄGG Göran. Musculoskeletal exposure of manual spray painting in the woodworking industry – an ergonomic study on painters. *International Journal of Industrial Ergonomics*. 2000, nr 6, s. 603-614. ISSN 0169-8141.
6. FERNANDEZ SCHRUNDER Alejandro D., HUANG Yu-Kai, RODRIGUEZ Saul, RUSU Ana. A Real-Time Muscle Fatigue Detection System Based on Multifrequency EIM and sEMG for Effective NMES. *IEEE Sensors Journal*. 2024, nr 14, s. 22553-22564. ISSN 1558-1748.
7. FU Rongrong, WANG Hong, ZHAO Wenbo. Dynamic driver fatigue detection using hidden Markov model in real driving condition. *Expert Systems with Applications*. 2016, vol. 63, s. 397-411. ISSN 0957-4174.
8. GARCIA Salvador, HERRERA Francisco. An Extension on “Statistical Comparisons of Classifiers over Multiple Data Sets” for all Pairwise Comparisons. *Journal of Machine Learning Research*. 2008, nr 9, s. 2677-2694. ISSN 1532-4435.
9. GLADWELL Peter, HARLAND Matthew, ADRISSI Aysha, KERSHAW Saskia, DURES Emma. Exploring the content validity of the Chalder Fatigue Scale using cognitive interviewing in an ME/CFS population. *Fatigue: Biomedicine, Health & Behavior*. 2024, nr 3, s. 217-237. ISSN 2164-1846.
10. HART Sandra G., STAVELAND Lovell E. Development of NASA-TLX (Task Load Index): Results of Empirical and Theoretical Research. *Advances in Psychology*. 1988, vol. 52, s. 139-183. ISSN 0166-4115.
11. HAUS Erhard, SMOLENSKY Michael. Biological clocks and shift work: circadian dysregulation and potential long-term effects. *Cancer Causes & Control*. 2006, nr 4, s. 489-500. ISSN 1573-7225.
12. HU Xinyun, LODEWIJKS Gabriel. Detecting fatigue in car drivers and aircraft pilots by using non-invasive measures: The value of differentiation of sleepiness and mental fatigue. *Journal of Safety Research*. 2020, t. 72, s. 173-187. ISSN 0022-4375.
13. HUANG Shitong, LI Ja, ZHANG Pengzhu, ZHANG Weiqiang. Detection of mental fatigue state with wearable ECG devices. *International Journal of Medical Informatics*. 2018, t. 119, s. 39-46. ISSN 1872-8243.
14. ISHII Akira, TANAKA Masaaki, WATANABE Yasuyoshi. Neural mechanisms of mental fatigue. *Reviews in the Neurosciences*. 2014, nr 4, s. 469-479. ISSN 0334-1763.
15. JACQUET Thomas, POULIN-CHARRONNAT Bénédicte, BARD Patrick, LEPERS Romuald. Persistence of Mental Fatigue on Motor Control. *Frontiers in Psychology*. 2021, vol. 11, s. 1-14. ISSN 1664-1078.
16. KO Li-Wei i in. Single channel wireless EEG device for real-time fatigue level detection. In *2015 International Joint Conference on Neural Networks (IJCNN)*. Killarney: IEEE, s. 1-5, 2015. ISSN 2161-4393.
17. LEE Hyeonjeong, LEE Jaewon, SHIN Miyoung. Using Wearable ECG/PPG Sensors for Driver Drowsiness Detection Based on Distinguishable Pattern of Recurrence Plots. *Electronics*. 2019, nr 2, s. 1-15. ISSN 2079-9292.
18. LEE Jong-Seok, BAE You-Suk, LEE Wongok, LEE Hyunsuk, YU Jinkeun, CHOI Jong-Pil. Emotion and Fatigue Monitoring Using Wearable Devices. In HWANG Seong Oun, TAN Syh Yuan, FRANKLIN Bien (red.). *Proceedings of the Sixth International Conference on Green and Human Information Technology*. Singapore: Springer, s. 91-96, 2019. ISBN 978-981-13-0311-1.
19. LI Jue i in. Identification and classification of construction equipment operators' mental fatigue using wearable eye-tracking technology. *Automation in Construction*. 2020, vol. 109. ISSN 0926-5805.
20. LÓPEZ Victoria, FERNÁNDEZ Alberto, GARCÍA Salvador, PALADE Vasile, HERRERA Francisco. An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics. *Information Sciences*. 2013, vol. 250, s. 113-141. ISSN 0020-0255.
21. LUGER Tessy, MAHER Christopher G., RIEGER Monika A., STEINHILBER Benjamin. Work-break schedules for preventing musculoskeletal symptoms and disorders in healthy workers. *Cochrane Database of Systematic Reviews*. 2019, nr 7. ISSN 1469-493X.
22. MARKATOU Marianthi, TIAN Hong, BISWAS Shameek, HRIPCSAK George. Analysis of variance of cross-validation estimators of the generalization error. *Journal of Machine Learning Research*. 2005, vol. 6, s. 1127-1168. ISSN 1127-1168.

23. MEAULEY Edward, COURNEYA Kerry S. The Subjective Exercise Experiences Scale (SEES): Development and Preliminary Validation. *Journal of Sport and Exercise Psychology*. 1994, nr 2, s. 163-177. ISSN 1543-2904.
24. NI Zhiqiang, SUN Fangmin, LI Ye. Heart Rate Variability-Based Subjective Physical Fatigue Assessment. *Sensors*. 2022, nr 9, s. 1-15, ISSN 1424-8220.
25. NIWA Shinji, YUKI Mori, NORO Tetsushi, SHIOYA Shunsuke, INOUE Kazutaka. A Wearable Device for Traffic Safety – A Study on Estimating Drowsiness with Eyewear. In *JINS MEME, SAE Technical Paper*. 2016. ISSN 0148-7191.
26. REN Ping. Cognitive Fatigue in Repetitive Learning Task. *Techniques in Neurosurgery and Neurology*. 2018, nr 1. ISSN 2637-7748.
27. ROBERTSON Edwin M. Skill Memory: Mind the Ever-Decreasing Gap for Offline Processing. *Current Biology*. 2019, nr 8, s. R287–R289. ISSN 0960-9822.
28. SEDIGHI MAMAN Zahra, CHEN Ying-Ju, BAGHDADI Amir, LOMBARDO Seamus, CAVUOTO Lora A., MEGAHEDE Fadel M. A data analytic framework for physical fatigue management using wearable sensors. *Expert Systems with Applications*. 2020, vol. 155. ISSN 0957-4174.
29. SHAHID Azmeah, WILKINSON Kate, MARCU Shai, SHAPIRO Colin M. Stanford Sleepiness Scale (SSS). In SHAHID Azmeah, WILKINSON Kate, MARCU Shai, SHAPIRO Colin M. (red.). *STOP, THAT and One Hundred Other Sleep Scales*. New York: Springer, s. 369-370, 2011. ISBN 978-1-4419-9892-7.
30. TAYLOR Janet L. Motor Control and Motor Learning Under Fatigue Conditions. In GOLLHOFER Albert, TAUBE Wolfgang, NIELSEN Jens Bo (red.). *Routledge Handbook of Motor Control and Motor Learning*. London: Routledge, 2013, s. 353-383. ISBN 978-0-203-13274-6.
31. TORRES Yaniel, NADEAU Sylvie, LANDAU Kurt. Evaluation of Fatigue and Workload among Workers Conducting Complex Manual Assembly in Manufacturing. *IIEE Transactions on Occupational Ergonomics and Human Factors*. 2021, nr 1, s. 49-63. ISSN 2472-5846.
32. VARANDAS Rui, LIMA Rodrigo, BERMÚDEZ I BADIA Sergi, SILVA Hugo, GAMBOA Hugo. Automatic Cognitive Fatigue Detection Using Wearable fNIRS and Machine Learning. *Sensors*. 2022, nr 11, s. 1-14. ISSN 1424-8220.
33. WAMSLEY Erin J. Memory Consolidation during Waking Rest. *Trends in Cognitive Sciences*. 2019, nr 3, s. 171-173. ISSN 1364-6613.
34. WOJCIECHOWSKA Maja (red.). *Zarządzanie biblioteką*. Warszawa: Wydawnictwo Naukowe i Edukacyjne SBP, 2019. ISBN 978-83-65741-26-4.
35. ZENG Zhikang i in. Nonintrusive Monitoring of Mental Fatigue Status Using Epidermal Electronic Systems and Machine-Learning Algorithms. *ACS Sensors*. 2020, nr 5, s. 1305-1313. ISSN 2379-3694.
36. ZHANG Ming, CHUNQUAN Li, YULING Shang, HUANG Hongyan, ZHU Wangchun, LIU Yujia. A task scheduling model integrating micro-breaks for optimisation of job-cycle time in human-robot collaborative assembly cells. *International Journal of Production Research*. 2022, nr 15, s. 4766-4777. ISSN 0020-7543.
37. ZHANG Yuxin, CHEN Yiqiang, PAN Zhiwen. A Deep Temporal Model for Mental Fatigue Detection. *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. Miyazaki: IEEE, 2018, s. 1879-1884. ISBN 978-1-5386-6650-0.