

Kamil SKOWROŃSKI, Adam GAŁUSZKA
Politechnika Śląska

ZASTOSOWANIE ROZPOZNAWANIA EMOCJI ZA POMOCĄ SYGNAŁÓW BIOMEDYCZNYCH W ROBOTYCE SPOŁECZNEJ - PRZEGLĄD ROZWIĄZAŃ

Streszczenie. Praca ma na celu przegląd dostępnych zbiorów danych oraz algorytmów sztucznej inteligencji dla problemu rozpoznawania emocji za pomocą sygnałów biomedycznych. Przegląd uwzględnia praktyczne wymagania użycia rozwiązań w multimodalnym systemie analizy emocji robotów społecznych - łatwość w użytkowaniu urządzeń do gromadzenia danych biomedycznych oraz sposób kategoryzacji danych wg teorii Paula Ekmana.

APPLICATION OF EMOTION RECOGNITION USING BIOMEDICAL SIGNALS IN SOCIAL ROBOTICS - SOLUTIONS OVERVIEW

Summary. This work aims to review available datasets and artificial intelligence algorithms for the problem of emotion recognition using biomedical signals. The review takes into account the practical requirements for using solutions in a multimodal emotion analysis system for social robots - the ease of use of devices for collecting biomedical data and the method of categorizing data according to Paul Ekman's theory.

1. Wprowadzenie

Rozpoznawanie emocji, szczególnie w kontekście nauk technicznych, jest zadaniem subiektywnym. W bliskiej przyszłości na pewno nie będziemy w stanie prawidłowo rozpoznać emocji wyrażanej przez każdą osobę na świecie z powodu ludzkiego indywidualizmu. Jesteśmy jednak w stanie odnaleźć pewne wzorce w rozpoznawaniu emocji, które objawiają się u większości społeczeństwa. Nie jest to zadanie, które można wykonać na podstawie jednego rodzaju danych. Ludzie charakteryzują się różnymi sposobami komunikacji takimi jak: werbalna (komunikacja za pomocą słów) czy niewerbalna (gestykulacja, mimika czy ton wypowiedzi). Z tego powodu problem rozpoznawania ludzkich emocji powinien być traktowany jako problem wielomodalny [1]. Wyrażanie emocji przez człowieka to nie tylko efekty, które możemy usłyszeć czy zobaczyć. Emocje (zarówno te odbierane jak i wyrażane) wpływają na autonomiczny system nerwowy ludzkiego organizmu. Sygnały fizjologiczne takie jak zmienność rytmu zatokowego, reakcja skórno-galwaniczna, temperatura skóry czy respiracja pozwalają również na określenie stanu emocjonalnego człowieka [8]. Jednym z najbardziej dokładnych sposobów na określenie ludzkiej emocji jest badanie bioelektrycznej czynności mózgu za pomocą badania elektroencefalografii (*ang. Electroencephalography - EEG*). Wiele

prac porusza temat rozpoznawania emocji za pomocą badania EEG [4, 11, 3]. Praca ma na celu dokonanie przeglądu literatury, zbiorów danych oraz rozwiązań sztucznej inteligencji dla problemu rozpoznawania emocji z sygnałów biomedycznych. Przegląd ten ma podłoże praktyczne – planuje się skonstruować multimodalny system analizy stanu emocjonalnego człowieka na podstawie wizji, fonii oraz sygnałów biomedycznych. Z racji wykorzystania systemu jako elementu składowego wspomagającego komunikację człowiek-robot robotów społecznych, pomiar sygnałów fizjologicznych musi być praktyczny oraz jak najmniej inwazyjny. W związku z tym z porównania wyklucza się m. in. wykorzystanie EEG. Warto podkreślić, że prace o podobnej tematyce opisują rozwiązania sprzed kilkunastu lat a problem robotyki społecznej i rozpoznawania emocji jest dynamicznie rozwijającą się dziedziną.

2. Powiązane prace

2.1. Roboty społeczne

Robotyka społeczna to interdyscyplinarna dziedzina, w której psychologia i socjologia zbiegają się z robotyką. Robot społeczny może dostosowywać swoje zachowanie do nastroju użytkownika lub wyrażać związane z nim emocje, wzmacniając współpracę i synergię z użytkownikiem. Umożliwienie robotom wyczuwania i modelowania emocji poprawi ich wydajność w różnych zastosowaniach związanych z interakcją człowiek-robot (*ang. Human-Robot Interaction - HRI*) [5]. Dzięki algorytmom sztucznej inteligencji roboty społeczne są w stanie doskonale odwzorować ludzkie zachowania i zrozumieć co je wyzwała. W dzisiejszych czasach wchodzi do użytku komercyjnego pod wieloma postaciami – inteligentne czatboty, punkty pomocy w galeriach handlowych czy placówkach medycznych czy nawet w postaci towarzyszy dla dzieci i seniorów.

2.2. Interakcja człowiek-robot

Interakcja człowiek-robot to dziedzina zajmująca się projektowaniem, zrozumieniem i oceną systemów, w skład których wchodzi roboty a z którymi wchodzi w interakcję ludzie [13]. Dziedzina ta wpisuje się doskonale w obszar robotów społecznych, które dzięki lepszemu zrozumieniu ludzkich emocji mogą ciągle poprawić i doskonalić komunikację z ludźmi.

2.3. Sygnały biomedyczne

Sygnały te mogą dostarczać cennych informacji na temat stanu emocjonalnego człowieka [8]. Poniżej zaprezentowano sygnały fizjologiczne użyteczne dla problemu rozpoznawania emocji:

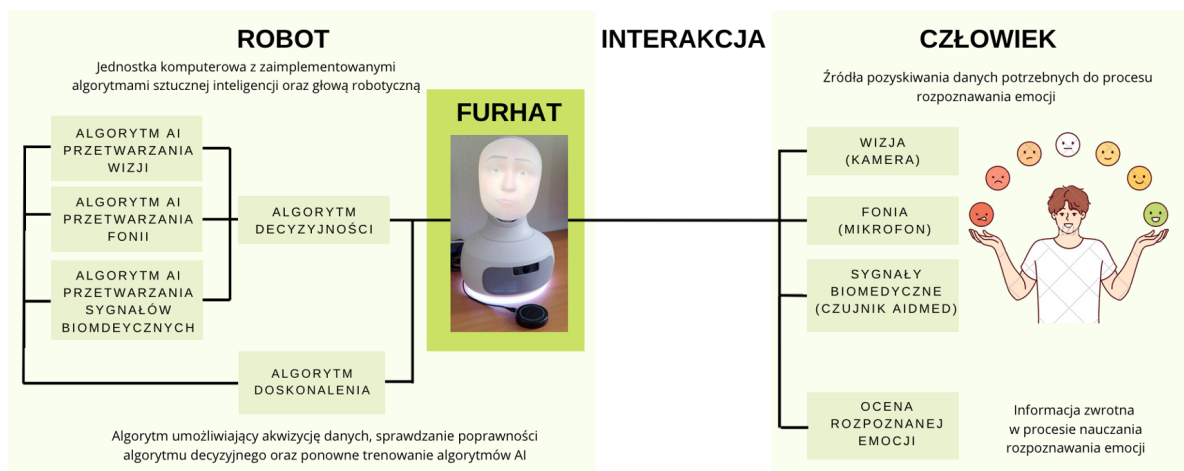
- Aktywność elektrodermalna - (*ang. Electrodermal activity - EDA*) – sygnał odpowiedzialny za oporność i przewodnictwo skóry. Mierzy się go poprzez zastosowanie dwóch elektrod do palca. Przewodnictwo skóry zmniejsza się w stanach relaksu, a zwiększa pod wpływem wysiłku. Z tym terminem związana jest galwaniczna odpowiedź skóry (*ang. Galvanic Skin Response - GSR*), która odnosi się do ogólnego zjawiska zmiany przewodności elektrycznej skóry. GSR to ogólny termin opisujący reakcję elektryczną skóry na bodźce emocjonalne, podczas gdy EDA jest terminem odnoszącym się do metod pomiarowych i analizy tych reakcji.

- Puls objętości krwi (*ang. Blood Volume Pulse - BVP*) to sygnał, który odzwierciedla zmiany w objętości krwi w naczyniach krwionośnych, zwykle wskutek skurczu i rozkurczu serca. Pomiar BVP jest często wykorzystywany w urządzeniach takich jak smartwatch, do monitorowania aktywności serca i obliczania wskaźników takich jak zmienność rytmu serca.
- Elektroencefalografia (*ang. Electroencephalography - EEG*) - może dokładnie określać emocje, ale ze względu na konfigurację i wrażliwość na zakłócenia, najlepiej sprawdza się w środowisku klinicznym. Analizy wykazały, że wartościowość i pobudzenie mogą być mierzone na podstawie specyficznych wzorców fal mózgowych, a różne emocje są związane z charakterystyczną aktywacją w różnych obszarach mózgu.
- Elektromiografia (*ang. Electromyography - EMG*) jest stosowana w badaniu klinicznym, ponieważ wymaga przyłączenia elektrod do skóry. Badanie to ma na celu ocenienie pobudliwości mięśni. EMG umożliwia jednak pomiar wartościowości w jednym wymiarze, co czyni je cennym uzupełnieniem dla innych jednowymiarowych sygnałów biomedycznych.
- Oddychanie (*ang. Respiration - RSP*) - aktywność klatki piersiowej, może być mierzona za pomocą oporowych przewodów, fotopletyzmoigrafii lub czujników ciśnieniowych z pianki. Zmniejszona częstotliwość oddechu wskazuje na stan spokoju i wyciszenia. Głębokie i szybkie oddychanie może oznaczać szczęście lub złość. Natomiast nieregularne wzorce oddechowe są oznaką negatywnej wartościowości i pobudzenia.
- Temperatura skóry (*ang. Skin Temperature - SKT*) – jest mierzona na czubku palca i wskazuje czy osoba jest zrelaksowana. Rozszerzone naczynia krwionośne oznaczają podwyższoną temperaturę podczas relaksacji lub obniżoną podczas stresu lub lęku, gdy naczynia się zwężają.
- Zmienność rytmu serca (*ang. Heart Rate Variability - HRV*) - sygnały biomedyczne związane z sercem dostarczają wielu informacji na temat systemu emocjonalnego człowieka. Mierzy się je za pomocą elektrokardiografii (Elektrokardiografia - EKG). Choć EKG jest trudne do używania na co dzień, jednak dzięki technice fotopletyzmoigrafii (*ang. photoplethysmogram - PPG*), szeroko stosowanej w opaskach nadgarstkowych, pozwala na mobilne monitorowanie tętna i wyliczanie HRV. Osiąganie wysokiej korelacji wyników z EKG (do 95%), czyni ją preferowaną metodą w ruchu i łatwą do zamontowania.

3. Architektura systemu

W celu bardziej dokładnego rozpoznawania emocji przez roboty społeczne została opracowana koncepcja multimodalnego systemu analizy emocji. System ten nie tylko pozwala na rozpoznawanie emocji za pomocą 3 kanałów informacyjnych (wizja, fonia, oraz sygnały biomedyczne) ale pozwala również na ciągłe doskonalenie się algorytmów sztucznej inteligencji dzięki informacji zwrotnej od użytkownika. System ten pozwoli w przyszłości na zbadanie użyteczności oraz przydatności poszczególnych kanałów informacyjnych oraz ich wpływu na rozpoznawanie emocji. Na obecną chwilę przygotowano są algorytmy uczenia głębokiego do rozpoznawania emocji na obrazach oraz zo-

stał opracowany algorytm analizy stanu emocjonalnego na podstawie polskich tekstów, który wraz z metodami ‘mowa na tekst’ (*ang. speech-to-text*) tworzy element składowy przetwarzania fonii. Warto nadmienić, że centralną część tego systemu zajmuje głowa robotyczna Furhat, która została zaprojektowana do interakcji z ludźmi w sposób naturalny i realistyczny, wykorzystując mimikę twarzy, gesty oraz mowę. Pełna koncepcja systemu zaprezentowana jest na rysunku 1.



Rys. 1. Koncepcja multimodalnego systemu analizy emocji

Skupiając się na przedstawionej koncepcji systemu analizy emocji oraz biorąc pod uwagę wymagania praktyczne, rozwiązanie musi spełniać określone wymagania:

- Sygnały, na których opiera się zbiór danych muszą być możliwe do zmierzenia za pomocą praktycznych urządzeń np. opaska na nadgarstek czy klatkę piersiową. Wyklucza się badania kliniczne jak np. badanie EEG. Dla podanej architektury planuje się wykorzystać bezprzewodowe certyfikowane urządzenia medyczne takie jak medyczny smartwatch lub urządzenie AIDMED. Rejestrator AIDMED ONE posiada moduły do pomiaru parametrów fizjologicznych, takie jak jednokanałowy moduł EKG z elektrodami silikonowymi, czujnik ciśnienia różnicowego, kontaktowy czujnik temperatury, czujnik ruchu inercyjnego oraz wbudowany mikrofon. Urządzenie mierzy również saturację krwi za pomocą bezprzewodowego pulsoksymetru.
- Kategorie opisanych danych muszą być zbliżone do klasycznej teorii Paula Ekmana - istnieje sześć podstawowych emocji: radość, smutek, wstręt, strach, zaskoczenie i złość [9].

4. Zbiory danych biomedycznych

Jednym z kluczowych elementów uczenia maszynowego jest zbiór danych. Na danych może zostać wytrenowany model a następnie oszacowana jego skuteczność. W przypadku sygnałów fizjologicznych liczba ogólnodostępnych zbiorów jest ograniczona z uwagi na trudność pozyskiwania tych danych i możliwość potencjalnego ich użycia. Dodatkową trudnością jest oznaczenie tych danych co wiąże się z udziałem eks-

pertów z dziedziny medycyny. Wyróżniamy następujące zbiory danych, które spełniają wymagania:

- Young Adult's Affective Data (YAAD) [6] - multimodalny zestaw danych pozyskany dzięki badaniu EKG oraz GSR uzyskanych od młodych dorosłych podczas oglądania emocjonujących filmów. Pozyskanie danych było możliwe dzięki urządzeniom Shimmer3 EKG i Shimmer3 GSR noszonych na klatce piersiowej i dłoni uczestników. Dane oznaczono dla siedmiu emocji i pięciu poziomów intensywności oraz dla wartościowości, pobudzenia i dominacji.
- The Continuously Annotated Signals of Emotion (CASE) [17] – zestaw danych uzyskany dzięki ciągłej, przeprowadzanej w czasie rzeczywistym anotacji emocji przeprowadzonej na 30 uczestnikach podczas oglądania stymulujących filmów. Uczestnik sam dokonywał oznaczenia danych za pomocą specjalnego joysticka. Dane zostały pozyskane z czujników EKG, RSP, PPG, GSR, EDA, SKT oraz EMG. Oznaczenie danych odbyło się pod kątem wymiarowości oraz 4 stanów emocjonalnych.
- Emognition [15] – zestaw danych opracowanych do rozpoznawania stanów emocjonalnych na podstawie sygnałów fizjologicznych i reakcji wizualnej. Dane zebrane na grupie 43 osób oglądających filmy wywołujące 9 emocji. Zarejestrowane sygnały biomedyczne dzięki następującym pomiarom - PPG, EEG, GSR, SKT. Dodatkowo nagrywano reakcje górnej części ciała. Dane były gromadzone za pomocą urządzeń: Muse 2 (dla badania EEG) oraz opasek nadgarstkowych Empatica E4 i Samsung Galaxy Watch. Uczestnicy badania dodatkowo dokonali samooceny pod kątem kategorii emocjonalnych i wymiarowych.
- Emotion, cognition, sleep, and multi-model physiological signals ECSMP dataset [10] – zbiór danych powstał podczas stanu spoczynku, indukcji emocji, regeneracji oraz zadań oceniających funkcje poznawcze. Ocena była dokonywana wg 6 podstawowych emocji, a funkcje poznawcze mierzono za pomocą automatycznego testu neuropsychologicznego. 89 przebadanych studentów musiało na koniec przeprowadzić samoocenę dotyczącą regulacji emocji, depresji, nastroju i jakości snu. Dane były zbierane na podstawie następujących sygnałów - EEG, EKG, PPG, EDA, SKT i danych z akcelerometru.
- AMIGOS [12] - Zestaw danych do badań multimodalnych nad reakcjami afektywnymi, cechami osobowości i nastrojem jednostek oraz grup. Warto podkreślić, że dane były zbierane zarówno indywidualnie jak i w grupach (wpływ emocjonalny grupy widzów). Przy zbieraniu danych użyto następujących sygnałów: EEG, EKG i GSR. Dodatkowo gromadzono materiały wideo twarzy badanych. Dane były oceniane zarówno pod kątem poziomów afektywnych jak i 6 podstawowych emocji.
- Physiological Dataset for Multimodal Emotion Recognition PhyMER [14] – zbiór danych zebrany na podstawie sygnałów EEG, EDA, BVP i SKT oraz dodatkowo cech osobowości 30 uczestników. Uczestnicy oglądali filmy wywołujące emocje, a następnie oznaczali swoje odczucia za pomocą narzędzia online. Dane były oceniane pod kątem wartościowości i pobudzenia jak i 6 podstawowych emocji.

5. Porównanie zbiorów danych

W tabeli 1 zostało przedstawione porównanie zbiorów danych pod kątem najważniejszych parametrów: sygnałów biomedycznych, kategorii opisowych, liczby próbek oraz rodzajów bodźców stymulujących. Porównanie zostało również uzupełnione o informację na temat dostępności tychże zbiorów.

Tabela 1

Porównanie zbiorów danych dla problemu rozpoznawania emocji za pomocą sygnałów fizjologicznych

Zbiór danych	Rok	Sygnały biomedyczne	Kategorie (emocje, wymiary)	Liczba próbek (osób)	Bodziec stymulujący	Dostępność
YAAD[6]	2022	EKG, GSR	Emocje: radość, smutek, strach, zaskoczenie, złość, wstręt i neutralność. Wymiary: wartościowość, pobudzenie, dominacja	25 15m/10k	filmy (21)	ogólnodostępny
CASE[17]	2019	EKG, RSP, PPG, GSR, EDA, SKT, EMG	Emocje: zabawne, nudne, relaksujące i przerażające. Wymiary: wartościowość, pobudzenie	30 15m/15k	filmy (11)	ogólnodostępny
Emognition [15]	2022	EEG, GSR, PPG, SKT	Emocje: rozbawienie, podziw, entuzjazm, sympatia, zaskoczenie, złość, wstręt, strach i smutek. Wymiary: wartościowość, pobudzenie, motywacja	43 22m/21k	filmy (11)	akademicki (dostępny po kontakcie z twórcami)
ECSMP [10]	2021	EEG, EKG, GSR, PPG, SKT	Emocje: neutralny, strach, smutek, radość, złość i wstręt.	89 32m/57k	filmy (6)	ogólnodostępny
AMIGOS [12]	2018	EEG, EKG, GSR	Emocje: neutralny, strach, złość, wstręt, smutek, szczęście i zaskoczenie. Wymiary: wartościowość, pobudzenie, dominacja, sympatia, znajomość.	40 27m/13k	filmy długie (16), krótkie (4)	ogólnodostępny
PhyMER [14]	2023	EEG, GSR, PPG, SKT	Emocje: złość, radość, smutek, zaskoczenie, neutralny, strach i wstręt. Wymiary: wartościowość, pobudzenie.	30 15m/15k	filmy (23)	akademicki (dostępny po kontakcie z twórcami)

m - mężczyźni, k - kobiety

6. Modele sztucznej inteligencji

Po porównaniu zbiorów danych dokonano przeglądu rozwiązań pod kątem algorytmów sztucznej inteligencji. W dalszym ciągu aktualne są wymagania zaprezentowane w rozdziale 3, szczególnie co do algorytmów opartych o kategorie emocji. Poniższy przegląd prezentuje rozwiązania oparte na wspomnianych zbiorach danych oraz tych mniej popularnych (jako forma porównania). Zaprezentowane również jedno rozwiązanie, które opierało się na kategoriach wymiarowości oraz rozwiązanie, które opisuje przejście z kategorii wymiarowości na emocje. Rozwiązania wybrane do porównania:

- Model uczenia maszynowego Extreme Gradient Boosting na podstawie zbioru PhyMER [14]. Twórcy przeprowadzili eksperymenty zależne i niezależne od podmiotu w celu porównania wydajności przy różnych kombinacjach cech. Zastosowano metodę walidacji krzyżowej 5-krotnej na zbiorze danych, który podzielono na zbiory treningowy i walidacyjny w stosunku 80:20. Ekstrakcja cech wyodrębniona została ręcznie. Dla tego zadania klasyfikacyjnego obejmującego siedem podstawowych emocji oraz predykcji wartości pobudzenia i wartościowości zastosowano klasyfikator i model regresji oparty na Extreme Gradient Boosting (XGBoost), znany ze swojej skuteczności w różnych zadaniach klasyfikacji i regresji.
- Klasyczne algorytmy uczenia maszynowego porównane na 3 zbiorach [2]. Dostępne publicznie zbiory danych, oparte na EEG, EKG i GSR, wykorzystano do trenowania modeli klasyfikatorów emocji przy użyciu technik uczenia maszynowego takich jak Las Losowy (*ang. Random Forest*), Maszyna Wektorów Nośnych (*ang. Support Vector Machine*), k Najbliższych Sąsiadów (*ang. k-Nearest Neighbors*) i Drzewo Decyzyjne (*ang. Decision Tree*).
- Algorytmy sztucznej inteligencji w oparciu o indywidualny zbiór danych [7]. Zaproponowane zostały modele rozpoznawania trzech emocji: rozbawienia, smutku i neutralnego stanu. Dla problemu rozpoznawania stanów emocjonalnych przetestowano metody klasyfikacji, w tym maszynę wektorów nośnych (*ang. Support Vector Machine - SVM*) oraz regresję wielomianową (*ang. Multinomial Regression - MN*). Przygotowano także modele zespołowe m.in. modele liniowe z regularizacją lasso i elastic-net (*ang. Lasso and Elastic-Net Regularized Generalized Linear Models - GLMNET*). Klasyfikatory te były trenowane i testowane na danych za pomocą algorytmu 10-krotnej walidacji krzyżowej, aby stworzyć subiektywne modele rozpoznawania emocji.
- Rozwiązanie z przejściem kategorii z podejścia wymiarowego na emocje HER [18]. Zaproponowana została metoda HRV Emotion Recognition (HER) z wykorzystaniem techniki kwantyzacji poziomu amplitudy (*ang. Amplitude Level Quantization - ALQ*) i analizy kwantyfikacji emocji (*ang. Emotion Quantification Analysis - EQA*). Dla tego modelu zostało również dokonane porównanie z innymi modelami sieci neuronowych: Równoległa Ulepszona Dwustopniowa w Pełni Konwolucyjna Sieć Neuronowa (*ang. Parallel Enhanced Two-Stage Fully Convolutional Neural Network – PETSFCNN*), hybrydowa sieć neuronowa łącząca rekurencję z konwolucją (*ang. Long Short-Term Memory Convolutional Neural Network - LSTM-CNN*) oraz model w oparciu o transformatę falkową (*ang. Wavelet Scattering - WAVE-SCATTER*).

- Porównanie klasycznych algorytmów uczenia maszynowego z sieciami neuronowymi w oparciu o kategorie wymiarowe [16]. W rozwiązaniu zastosowano podejście głębokiego uczenia z użyciem głębokiej konwolucyjnej sieci neuronowej na zbiorze danych AMIGOS. Porównano dokładność tego modelu z wynikami algorytmów: k Najbliższych Sąsiadów, Las Losowy, Liniowa Analiza Dyskryminacyjna (ang. *Linear Discriminant Analysis*), Liniowa Maszyna Wektorów Nośnych (ang. *Linear Support Vector*), Wielowarstwowy Perceptron (ang. *Multi-Layer Perception*) oraz Adaptacyjne Wzmacnianie (ang. *Adaptive Boosting*).

7. Porównanie rozwiązań

W tabeli 2 zostało przedstawione porównanie modeli klasyfikacyjnych dla problemu rozpoznawania emocji za pomocą sygnałów biomedycznych. Oprócz modeli zostały zestawione również ich dokładności oraz zbiory danych, na których bazowały prezentowane modele. W tabeli zostały użyte angielskie nazwy modeli w celu ujednolicenia - tłumaczenia zostały przedstawione w poprzednim rozdziale.

Tabela 2

Porównanie rozwiązań dla problemu rozpoznawania emocji za pomocą sygnałów fizjologicznych

Rozwiązanie / Rok	Zbiór danych (ewentualne kategorie)	Model klasyfikacyjny	Dokładność
[14] / 2023	PhyMER	Extreme Gradient Boosting	<u>73%</u>
[2] / 2023	YAAD	Random Forest (Ensemble Bagged Tree)	99.9%
		Random Forest (Ensemble RUSBoosted)	93.4%
		Support Vector Machine (Quadratic)	92.3%
		Support Vector Machine (Fine Gaussian)	99.5%
		Decision Tree (Medium Tree)	96.2%
	LUMED-2 (radość, smutek, strach, zaskoczenie, złość, wstręt i neutralność)	Random Forest (Ensemble Bagged Tree)	<u>100.0%</u>
		Support Vector Machine (Quadratic)	96.3%
		Decision Tree (Medium Tree)	<u>100%</u>
	SWELL (przeszkadzanie, bez stresu i presja czasu)	Random Forest (Ensemble Bagged Tree)	99.7%
		Support Vector Machine (Quadratic)	98%
		Decision Tree (Medium Tree)	99.2%
[7] / 2019	WŁASNY (rozbawienie, neutralność i smutek)	MN	57.0%
		SVML	57.0%
		GLMNET	<u>64.0%</u>
[18] / 2023	DREAMER (nastrój, pobudzenie i dominacja)	HER	<u>94.3%</u>
		PETSFCNN	32.6%
		LSTM-CNN	49.3%
		WAVE-SCATTER	33.8%
[16] / 2019	AMIGOS	Deep Convolutional Neural Network - indywidualna architektura	<u>74.5%</u>
		Nearest Neighbours	66.0%
		Liner Discriminant Analysis	67.5%
		Linear Support Vector	66.5%
		Multi-Layer Perception	65.25%
		Adaptive Boosting	65.25%
		Random Forest	62.25%

8. Wnioski

Przeprowadzony przegląd rozwiązań dla problemu rozpoznawania emocji za pomocą sygnałów fizjologicznych pozwala stwierdzić, że istnieją nowoczesne zbiory danych i algorytmy sztucznej inteligencji pomimo ograniczeń w koncepcji systemu. Odnosząc się do przedstawionych 6 zbiorów danych, widać, że badania z ostatnich lat przeprowadzane są na małej grupie osób, co w dalszym ciągu pozwala twierdzić, że istnieją braki w danych szczególnie w kontekście wieku czy chorób. Jednak zaprezentowane zbiory tworzą mocną bazę pod algorytmy sztucznej inteligencji do rozpoznawania emocji, nawet przy pomocy urządzeń, które nie wymagają klinicznego środowiska. Podsumowując przegląd 5 rozwiązań/algorytmów sztucznej inteligencji można stwierdzić, że większą dokładnością charakteryzują się modele sieci neuronowych co potwierdza dzisiejsze trendy w tworzeniu tych algorytmów. Można jednak zauważyć, że pomimo istnienia wielu zbiorów danych oznaczonych wg kategorii emocji, niewiele jest algorytmów, które podążają za tą kategoryzacją. Warto jednak zauważyć, że przedstawione wyniki prac są doskonałym zbiorem informacji podczas konstruowania systemów z robotami społecznymi.

W dalszym ciągu istnieje nisza w tej dziedzinie pozwalająca na dalsze badania. Przyszłościowe prace obejmują dostosowanie jednego z algorytmów sieci neuronowych do planowanej architektury systemu oraz przetestowanie jego działania w warunkach rzeczywistych. Planuje się również na podstawie przedstawionych zbiorów wytrenować model z największą dokładnością (rozwiązanie HER lub indywidualna sieć konwolucyjna) oraz porównać go z pozostałymi przedstawionymi algorytmami. Bardziej wymagającym zadaniem może być opracowanie własnego zbioru danych i architektury sieci neuronowej, które mogłyby się charakteryzować większą skutecznością.

PODZIĘKOWANIA

Prace Kamila Skowrońskiego wsparła Politechnika Śląska w Gliwicach poprzez dotację na utrzymanie i rozwój potencjału badawczego w roku 2024 dla młodych naukowców. Prace Adama Gałuszki wsparła częściowo Politechnika Śląska w Gliwicach poprzez dotację na utrzymanie i rozwój potencjału badawczego w roku 2024.

LITERATURA

1. Abdullah S. M. S. A., Ameen S. Y. A., Sadeeq M. A., Zeebaree S.: Multimodal emotion recognition using deep learning. *Journal of Applied Science and Technology Trends*, 2021, vol. 2(01), p. 73-79.
2. Alam A., Urooj S., Ansari A. Q.: Human emotion recognition models using machine learning techniques. In *2023 International Conference on Recent Advances in Electrical, Electronics & Digital Healthcare Technologies (REEDCON)* (p. 329-334). IEEE, 2023.
3. Alarcao S. M., Fonseca M. J.: Emotions recognition using EEG signals: A survey. *IEEE transactions on affective computing*, 2017, vol. 10(3), p. 374-393.
4. Bos D. O.: EEG-based emotion recognition. The influence of visual and auditory stimuli, 2006, vol. 56(3), p. 1-17.

5. Cavallo F., Semeraro F., Fiorini L., Magyar G., Sinčák P., Dario P.: Emotion modelling for social robotics applications: a review. *Journal of Bionic Engineering*, 2018, vol. 15, p. 185-203.
6. Dar M. N., Rahim A., Akram M. U., Khawaja S. G., Rahim A.: YAAD: young adult's affective data using wearable ECG and GSR sensors. In *2022 2nd International Conference on Digital Futures and Transformative Technologies (ICoDT2)* (p. 1-7), IEEE, 2022.
7. Domínguez-Jiménez J. A., Campo-Landines K. C., Martínez-Santos J. C., Delahoz E. J., Contreras-Ortiz S. H.: A machine learning model for emotion recognition from physiological signals. *Biomedical signal processing and control*, 2020, vol. 55, p. 101646.
8. Egger M., Ley M., Hanke S.: Emotion recognition from physiological signal analysis: A review. *Electronic Notes in Theoretical Computer Science*, 2019, vol. 343, p. 35-55.
9. Ekman P.: An argument for basic emotions. *Cognition & emotion*, 1992, vol. 6(3-4), p. 169-200.
10. Gao Z., Cui X., Wan W., Zheng W., Gu Z.: ECSMP: A dataset on emotion, cognition, sleep, and multi-model physiological signals. *Data in Brief*, 2021, vol. 39, p. 107660.
11. Jafari M., Shoeibi A., Khodatars M., Bagherzadeh S., Shalhaf A., García D. L., Acharya U. R.: Emotion recognition in EEG signals using deep learning methods: A review. *Computers in Biology and Medicine*, 2023, p. 107450.
12. Miranda-Correa J. A., Abadi M. K., Sebe N., Patras I.: Amigos: A dataset for affect, personality and mood research on individuals and groups. *IEEE transactions on affective computing*, 2018, vol. 12(2), p. 479-493.
13. Murphy R. R., Nomura T., Billard A., Burke J. L.: Human-robot interaction. *IEEE robotics & automation magazine*, 2010, vol. 17(2), p. 85-89.
14. Pant S., Yang H. J., Lim E., Kim S. H., Yoo S. B.: PhyMER: physiological dataset for multimodal emotion recognition with personality as a context. *IEEE Access*, 2023.
15. Saganowski S., Komoszyńska J., Behnke M., Perz B., Kunc D., Klich B., Kazienko P.: Emognition dataset: emotion recognition with self-reports, facial expressions, and physiology using wearables. *Scientific data*, 2022, vol. 9(1), p. 158.
16. Santamaria-Granados L., Munoz-Organero M., Ramirez-Gonzalez G., Abdulhay E., Arunkumar N. J. I. A.: Using deep convolutional neural network for emotion detection on a physiological signals dataset (AMIGOS). *IEEE Access*, 2018, vol. 7, p. 57-67.
17. Sharma K., Castellini C., Van Den Broek E. L., Albu-Schaeffer A., Schwenker F.: A dataset of continuous affect annotations and physiological signals for emotion analysis. *Scientific data*, 2019, vol. 6(1), p. 196.
18. Wang L., Hao J., Zhou, T. H.: ECG Multi-Emotion Recognition Based on Heart Rate Variability Signal Features Mining. *Sensors*, 2023, vol. 23(20), p. 8636.