


Wydział Inżynierii Biomedycznej Politechniki
Śląskiej



Streszczenie Rozprawy Doktorskiej
Rękawica ze zredukowaną liczbą czujników do
rozpoznawania liter Polskiego Języka Migowego

Autor:

mgr inż. Jakub Piskozub

Promotor:

prof. dr hab. inż. Paweł Strumiłło

Łódź, 2023

1. Wstęp

1.1. Cel pracy

Celem niniejszej rozprawy doktorskiej jest zbudowanie rękawicy sensorycznej wyposażonej w zestaw czujników przeznaczonych do badania możliwości jej wykorzystania w zastosowaniach rehabilitacyjno-diagnostycznych oraz rozpoznawania liter alfabetu Polskiego Języka Migowego (APJM). Za jej pomocą postanowiono zbadać możliwość redukcji liczby czujników w rękawicy do rozpoznawania liter APJM. Prace mają na celu analizę istniejących rozwiązań, opracowanie nowego, bardziej wydajnego i ergonomicznego modelu rękawicy danych oraz zastosowanie zaawansowanych technik uczenia maszynowego i głębokiego w celu poprawy skuteczności rozpoznawania gestów.

1.2. Teza i motywacja podjęcia badań

Oczywistym wyborem wśród urządzeń wspomagających osoby z niepełnosprawnością są technologie, które mogą wspomagać lub zastępować uszkodzony lub nieprawidłowo funkcjonujący organ. W przypadku osób głuchoniemych są to zazwyczaj aparaty słuchowe, implanty ślimakowe lub vocodery. Istnieją jednak przypadki, w których korzystanie z takiego systemu jest niemożliwe, niewystarczające lub nieakceptowane przez osobę niepełnosprawną. Z myślą o takich sytuacjach opracowano szereg technologii mających na celu poprawę jakości życia i bezpieczeństwa ich użytkowników. Należą do nich m.in. urządzenia, które pomagają osobom słabowidzącym i niewidomym w orientacji przestrzennej i dostępie do informacji wizualnej [1]. Technologia ostatnich dwóch dekad również znacząco przyczyniła się do poprawy jakości życia osób głuchoniemych [2]. Dzięki smartfonom takie osoby mogą w wystarczającym stopniu komunikować się z innymi, którzy nie znają języków migowych, a wraz z upowszechnieniem się połączeń wideo, łączyć się z tłumaczem języka migowego [3]. Nie jest jednak nieprawdopodobna sytuacja, że nie ma dostępu do telefonu, połączenia internetowego niezbędnego do wykonania połączenia z tłumaczem w ważnej sprawie lub że osoba posługująca się językiem migowym nie zna żadnego innego języka. W takiej sytuacji pomocny może być system oparty na rękawicy do transmisji danych, który przetłumaczy język migowy na mowę. Urządzenie, to ma swoją genezę w cybernetyce i istnieje w szerszej świadomości,

odkąd pojawiło się jako kontroler gier. Urządzenia śledzące ruchy dłoni, takie jak rękawica danych opracowana przez Sandina et al. [4] sprawia, że możliwe jest opracowanie takiego systemu. Rękawica umożliwia bezpośredni pomiar ruchów palców i jest zaprojektowana tak aby nie zakłócać naturalnych ruchów ręki. Ta cecha ma kluczowe znaczenie podczas śledzenia różnych gestów i języków migowych. W miarę dalszego odkrywania potencjału interakcji człowiek-komputer, urządzenia takie jak rękawica danych będą odgrywać kluczową rolę w wypełnianiu luki między światem fizycznym i wirtualnym, torując drogę dla bardziej zaawansowanych i intuicyjnych systemów sterowania.

Język migowy jest kluczowym narzędziem komunikacji dla osób niesłyszących i niedosłyszących. Rękawice do transmisji danych mogą potencjalnie ułatwić komunikację między tymi osobami a otoczeniem, ale ich rozmiar i liczba czujników mogą stanowić barierę dla ich szerszego upowszechnienia. Motywacją do podjęcia tej tematyki badań jest dążenie do poprawy jakości życia osób posługujących się językiem migowym, a także przyspieszenia rozwoju technologii wspierających taką komunikację.


Najważniejszym z wielu zastosowań rękawicy danych jako tłumacza języka migowego może być jej użycie w sytuacjach awaryjnych. Rękawica może okazać się nieoceniona dla służb ratowniczych, umożliwiając im skuteczniejszą komunikację z osobami niesłyszącymi lub niedosłyszącymi, które wymagają pomocy. Zapewniając tłumaczenie języka migowego w czasie rzeczywistym, można dzięki skutecznej reakcji w sytuacjach awaryjnych ratować życie. Przeszkodą w ich powszechnym stosowaniu jest jednak ich duży koszt i zawodność, związane bezpośrednio z ich złożoną konstrukcją, o czym wspominają ich potencjalni użytkownicy. Zmniejszenie liczby czujników wykorzystywanych do skutecznego rozpoznawania gestów w komunikacji w języku migowym przyczyni się do rozwiązania obu tych problemów. Zatem tezę poniższej pracy można sformułować następująco:

Możliwe jest skuteczne rozpoznawanie liter alfabetu Polskiego Języka Migowego za pomocą rękawicy sensorycznej o zmniejszonej liczbie czujników, co może uprościć budowę rękawicy i poprawić jej ergonomię.

2. Podstawy teoretyczne i techniczne

Jedną z części PSL jest alfabet migowy, znany również jako alfabet palcowy. Jest on używany głównie do artykułowania nazw własnych, nazw geograficznych, nazw

technicznych, imion i nazwisk oraz innych nazw, które nie mają własnego znaku w języku migowym. W praktyce alfabet palcowy ułatwia komunikację między osobami niesłyszącymi oraz między osobami niesłyszącymi i słyszącymi, które nie posługują się biegle językiem migowym. APJM jest również używany jako narzędzie edukacyjne dla osób uczących się języka migowego. Pomaga im zapamiętać gesty i litery, a także osiągnąć płynność w komunikacji. Warto zauważyć, że różne kraje mają różne wersje alfabetu palcowego, które odpowiadają literom języka. Alfabet palcowy PJM składa się z 36 znaków: 20 dynamicznych i 16 statycznych. Ciekawą cechą APJM jest to, że znaki diakrytyczne, takie jak "Ł" i "Ó", są dynamicznymi odpowiednikami znaków alfabetu łacińskiego. Pełny zestaw 36 liter APJM pokazano na rysunku 2.1.2.



Rys 2.1.2. Alfabet Polskiego Języka Migowego źródło: <http://alfabet-migowy.blogspot.com/2013/04/alfabet-migowy.html>

I chociaż ruchy rąk stanowią większość w gramatyce PJM, nie stanowią one jej całości. Równie ważne jak ułożenie dłoni podczas komunikacji są mimika twarzy i język ciała. Tak więc bez dodatkowego urządzenia, które śledzi i rozpoznaje w połączeniu z działaniem rękawicy te dwa pozostałe aspekty PJM, niemożliwe jest zbudowanie kompletnego

tłumacza. Należy zatem podkreślić, iż sama rękawica nigdy nie będzie samodzielnym tłumaczem języka migowego.

2.1. Data gloves: powiązane prace

W [5] Simoes Dias et al. przedstawiają rozwój i analizę systemu rozpoznawania wzorców dla alfabetu brazylijskiego języka migowego (Libras), opartego na rękawicy z czujnikami. Opracowana rękawica składa się z pięciu czujników ugięcia, akcelerometru, żyroskopu i dwóch czujników dotykowych.

Lee et al. przedstawiają projekt i implementację przenośnego rozwiązania do interpretacji słów Amerykańskiego Języka Migowego poprzez analizę wzorców ruchu palców i dłoni w oparciu o dane ruchu z 5 czujników inercyjnych [6]. Model rekurencyjnej sieci neuronowej z warstwą LSTM został dostrojony tak, aby osiągnąć najlepszą wydajność w klasyfikacji 27 gestów AJM opartych na słowach, ze średnią dokładnością przekraczającą 99%.

W [7] Pezzouli et al. przedstawiają proces tłumaczenia dynamicznych znaków za pomocą specjalnie zaprojektowanej rękawicy danych, zwanej Talking Hands. Przetestowano różne klasyfikatory, w szczególności lasy losowe i sieci neuronowe. Badanie pokazuje, że dobre rezultaty w rozpoznawaniu języka migowego można osiągnąć bez użycia zewnętrznej kamery, pozyskując wszystkie dane z rękawicy.

Odpowiedź na problem segmentacji strumienia danych zawierającego gesty została przedstawiona w [8]. W artykule przedstawiono system rozpoznawania języka migowego w czasie rzeczywistym, który wykorzystuje rękawicę sensoryczną opartą na 10 czujnikach piezorezystancyjnych natryskiwanych bezpośrednio na materiał rękawicy. Opracowany system rozpoznawania gestów miał na celu segmentację i rozpoznawanie 17 dynamicznych gestów w czasie rzeczywistym, niezależnie od liczby powtórzeń wykonywanego gestu w ciągu jednego pomiaru.

Badanie przeprowadzone przez Saggio et al. [9] opisuje użycie rękawicy wyposażonej w zestaw 10 czujników piezorezystancyjnych umieszczonych w kieszeniach z tkaniny i jeden czujnik inercyjny. Uzyskane dane zostały sklasyfikowane przy użyciu nieparametrycznego modelu łączącego klasyfikator k-NN z algorytmem DTW. Model wykazał dobrą dokładność klasyfikacji (96,6%).

W [10] Pławiak et al. opisali próbę analizy 22 gestów dłoni pochodzących z ogólnie przyjętej mowy ciała w celu ich identyfikacji. W eksperymencie wykorzystano dane ze specjalistycznej rękawicy (z dziesięcioma czujnikami), które zostały wstępnie przetworzone i przeanalizowane przy użyciu algorytmów uczenia maszynowego. Wyniki potwierdziły, że możliwe jest skuteczne i szybkie rozpoznawanie mowy ciała dłoni, a najlepszy klasyfikator osiągnął czułość na poziomie 98,32%.

Dziubich et al., autorzy [11], przeprowadzili badanie skuteczności klasyfikacji liter APJM przy użyciu rękawicy składającej się z 5 czujników ugięcia. W przeprowadzonych eksperymentach, które obejmowały testy klasyfikacji gestów statycznych i dynamicznych, klasyfikator ANN wypadł gorzej niż SVM. Wyniki dla obu klasyfikatorów można uznać za dobre, z rezultatami nie najgorszymi odpowiednio niż 87% i 82%. Klasyfikacja dynamicznych gestów wykazała, że wydajność metod DTW i Hidden Markov Models (HMM) była znacznie gorsza, i wyniosła odpowiednio 48% i 53%. Autorzy nie określili jednak, których gestów lub liter ostatecznie dotyczyło ich badanie. Wiadomo jedynie, że wykorzystano 25 różnych statycznych i dynamicznych gestów.

Obecnie, zgodnie z najlepszą wiedzą autora, jedyne badania nad rękawicą do rozpoznawania liter APJM zostały przeprowadzone przez Korzeniewską et al. opisane w artykule [12]. Artykuł opisuje proces opracowywania i testowania prototypu rękawicy do tłumaczenia języka migowego. Prototyp umożliwi użytkownikom wprowadzanie liter za pomocą urządzenia mobilnego lub komputera, zastępując klawiaturę, chociaż proces identyfikacji liter nie jest w pełni dokładny. Autorzy skupiają się również na wyzwaniach związanych z trwałością cienkich warstw przewodzących i długowiecznością czujników tektonicznych, takich jak Velostat, proponując ich wykorzystanie do produkcji czujników zgięcia palca. Analiza właściwości elektrycznych i dobór podłoży do produkcji czujników cienkowarstwowych umożliwiły stworzenie rękawicy, która została wykorzystana do sklasyfikowania ponad 500 próbek znaków ze wskaźnikiem skuteczności wynoszącym 86,5%.

3. Projekt rękawicy danych

Czujniki zostały przymocowane do powierzchni rękawicy za pomocą rzepu, który został przyklejony jedynie do końcówki czujnika. Jednocześnie, aby zapewnić stabilność ruchu

czujnika, zastosowano wydrukowane w 3D prowadnice, które również zostały przymocowane do rękawicy przy użyciu rzepu. To rozwiązanie pozwoliło czujnikowi poruszać się swobodnie, pozwalając na zgięcie wraz z palcem, jednocześnie utrzymując go w stabilnym położeniu, co eliminowało niepożądane ruchy. Co więcej, umożliwiło to dostosowanie pozycji czujnika do dłoni użytkownika.

Zastosowanie złączy FCL umożliwiło bezpieczne połączenie czujników i szybką ich wymianę w razie potrzeby. W przeciwieństwie do tradycyjnych izolowanych przewodów, w tej wersji rękawicy zastosowano przewodzącą nić wszytą w materiał. To pozwoliło na utworzenie połączeń, które nie wpływały znacząco na ruch czujnika i były niewyczuwalne dla użytkownika. Niestety, pojawił się problem tymczasowych zwarć między różnymi liniami sygnałowymi utworzonymi przez tę nić.

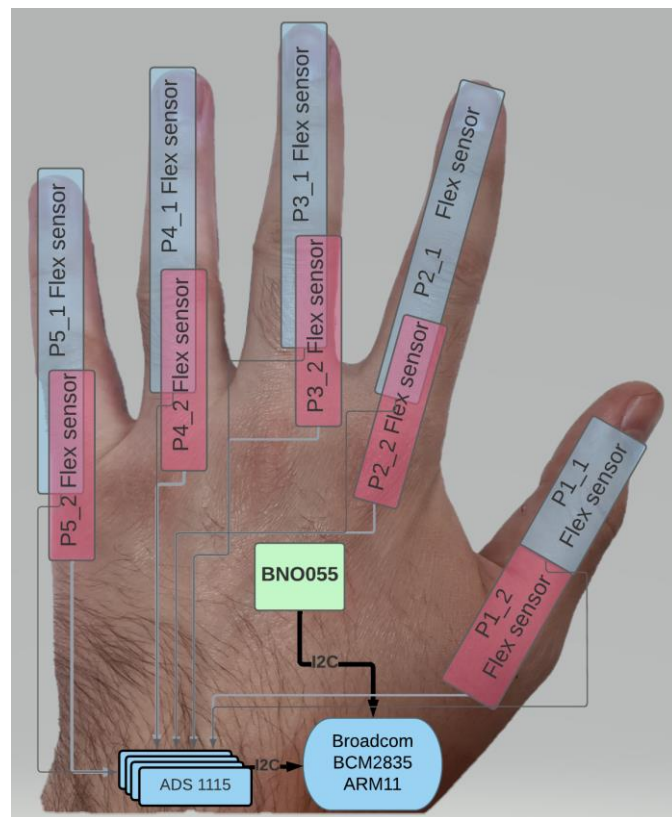
Próby rozwiązania tego problemu przy użyciu dostępnych na rynku preparatów izolujących, które nie ograniczałyby elastyczności nici, zakończyły się niepowodzeniem. Jednak udało się go złagodzić poprzez reorganizację tras poszczególnych linii w taki sposób, aby były jak najdalej od siebie, bez zbędnych luzów, co umożliwiło swobodny ruch czujnika.

3.1. Jednostka pomiarowo-kontrolna


W każdym etapie projektu, zastosowano czujniki ugięcia w układzie z drugim rezystorem, tworząc dzielnik napięcia, które było przesyłane na wejście przetwornika ADC. Wykorzystano przetworniki ADS1115, które są 16-bitowymi, czterokanałowymi przetwornikami analogowo-cyfrowymi firmy Texas Instruments, działającymi z prędkością 860 próbek na sekundę. Te przetworniki komunikowały się z jednostką sterującą rękawicą poprzez protokół I2C.

Oznaczenia czujników piezorezystancyjnych zastosowano konwencję: P[nr palca, na którym znajduje się czujnik]_[nr rzędu, w którym znajduje się czujnik], na przykład P2_1 to czujnik na drugim palcu w pierwszym rzędzie. Schemat blokowy najnowszej wersji,

wraz z ilustracyjnym układem i oznaczeniem różnych komponentów, został przedstawiony na rysunku 3.3.1.



Rys 3.3.1. Schemat blokowy urządzenia z ilustracyjnym rozmieszczeniem komponentów



Rys 3.3.2. Zdjęcie aktualnej wersji urządzenia

4. Metodologia badawcza

Najważniejszym etapem badań były prace nad rozpoznawaniem PAM na podstawie danych ze zbioru badawczego zarejestrowanego od 16 osób. Oceniono skuteczność rękawicy w pozyskiwaniu danych umożliwiających rozpoznawanie dynamicznych ruchów dłoni, które odpowiadają literom PAM. W tym celu zastosowano techniki uczenia głębokiego, które omówiono w dalszej części tej sekcji. Przeprowadzono również testy wybranych konfiguracji danych treningowych sieci neuronowej w celu określenia najbardziej wydajnej i skutecznej metody klasyfikacji danych.

4.1. Metoda pomiarów

W ramach przeprowadzonych badań zbierano pomiary podczas wykonywania przez uczestników gestów odpowiadających wszystkim literom APJM, zarówno dynamicznym, jak i statycznym. Dla ułatwienia zbierania danych przyjęto, że czas potrzebny na wykonanie każdego gestu wynosił 3 sekundy, co zostało ustalone na podstawie empirycznych obserwacji. To pozwoliło na zebranie 75 próbek danych od każdego z 10 czujników piezorezystancyjnych i 6 osi akcelerometru dla każdej litery alfabetu. Każdy uczestnik badania powtórzył każdy gest 10 razy. W wyniku tego etapu testów zebrano łącznie około 5800 sygnałów dla gestów APJM, co przekłada się na około 437 tysięcy pojedynczych próbek. Testy rękawicy danych zostały zatwierdzone przez Instytucjonalną Komisję Etyczną Politechniki Łódzkiej (nr 1/2021, data zatwierdzenia: 28 X 2021 r.).

4.2. Zastosowanie uczenia maszynowego i głębokiego do rozpoznawania liter APJM

Architektura sieci używanej do klasyfikacji danych została wybrana w badaniach skuteczności różnych konfiguracji sieci, w tym wykorzystanie zarówno warstw LSTM, jak i GRU, różnych rozmiarów warstw oraz funkcji aktywacji. Model sieci neuronowej zbudowany przy użyciu sekwencyjnego API z biblioteki Keras składa się z wielu warstw i funkcji aktywacji. Na wejście sieci podawane są dane treningowe.

Pierwszym etapem przetwarzania danych jest normalizacja wsadowa. Następnie dane przechodzą przez jednowymiarową warstwę konwolucji (Conv1D) z 64 filtrami, jądrem o rozmiarze 3 i funkcją aktywacji sigmoid. Po kolejnej normalizacji wsadowej dane kierowane są do bramkowanych jednostek rekurencyjnych (GRU), które wykorzystują funkcję aktywacji "selu" i regularyzację L2 ze współczynnikiem równym 0,03. Warstwa

GRU jest również wyposażona w mechanizm porzucania, z wartościami DP i RDP odpowiednio dla regularnego i rekurencyjnego porzucania. Ten proces jest powtarzany trzykrotnie. W ostatnim etapie, po normalizacji partii danych, dane są kierowane do warstwy gęstej (Dense) z 36 neuronami i funkcją aktywacji softmax, która służy do generacji wyników klasyfikacji.




Figure 4.5.1. Architektura sieci neuronowej (żółty - normalizacja wsadowa, czerwony - warstwa konwolucyjna, zielony - warstwa GRU, niebieski - warstwa gęsta)

5. Wyniki

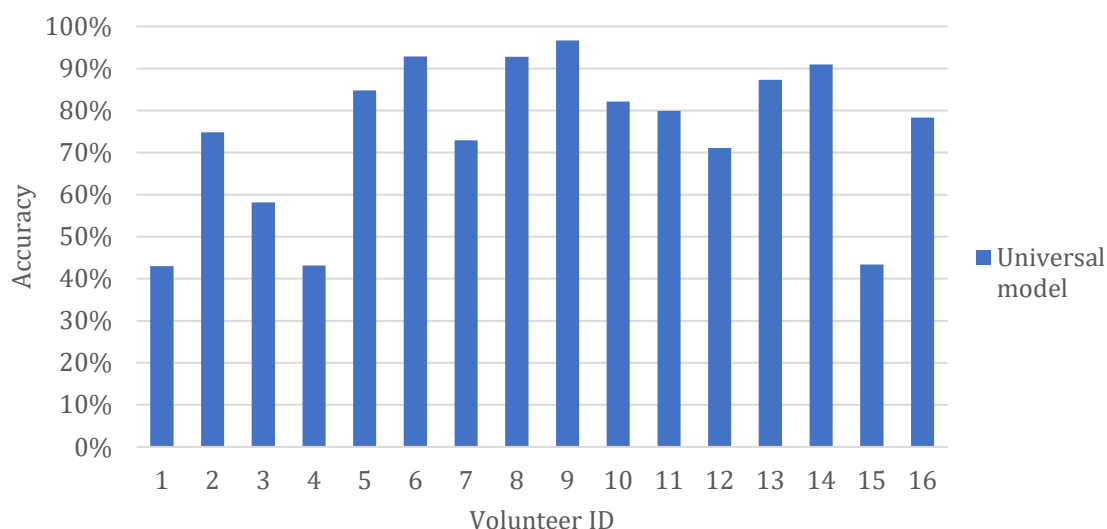
Rezultaty poprzednich etapów prac zostały opisane w dwóch publikacjach [13], [14].

Wydajność poszczególnych algorytmów klasyfikacji została oceniona na podstawie wartości trafności wyrażonej wzorem:

$$\text{Trafność} = \frac{\text{Ilość poprawnych klasyfikacji}}{\text{Całkowita ilość klasyfikacji}} \quad (1)$$

5.1. Wyniki klasyfikacji liter Polskiego Języka Migowego na podstawie zredukowanego wektora cech

Sieć wytrenowana na zbiorze składającym się z danych od wszystkich uczestników osiągnęła dokładność na poziomie 76%. Sieć osiągnęła najwyższą skuteczność po około 50 epokach trwających około 40 minut. Wynik został potwierdzony przez 5-krotną walidację krzyżową.



Ze względu na brak skutecznych metod oceny ważności cech w przypadku rekurencyjnych sieci neuronowych, zwłaszcza tych przeznaczonych do klasyfikacji danych szeregów czasowych, przeprowadzono obliczenia stosując metodę brute-force. Skuteczność nauki sieci neuronowej została poddana testom na różnych zestawach danych, obejmujących wszystkie możliwe kombinacje trzech z dziesięciu dostępnych czujników, a także dane z czujnika inercyjnego. Wyniki uzyskanych trafności, wraz z zestawami trzech czujników, na podstawie których te wyniki zostały osiągnięte, zostały przedstawione w tabeli 5.2.1.

Tab 5.2.1. 5 najskuteczniejszych tercetów cech do klasyfikacji alfabetu Polskiego Języka Migowego przy użyciu sieci neuronowej

Sensor			Trafność
P1_2	P3_1	P5_1	85,58%
P1_2	P3_1	P4_1	84,92%
P1_2	P2_2	P5_1	84,85%
P1_2	P4_2	P5_1	84,51%
P1_2	P3_1	P5_2	84,51%

5.2. Porównanie z powiązаныmi pracami

Porównanie opisanej wcześniej koncepcji z innymi jest utrudnione ze względu na brak alternatywnych rozwiązań redukcji wymiarów rękawic, które mogłyby być wykorzystane do rozpoznawania gestów języka migowego. W [15], gdzie autorzy dokonali przeglądu prac nt. rękawic danych do rozpoznawania ruchu dłoni, można znaleźć tylko 4 artykuły, które dotyczyły urządzeń, które działało poprawnie z mniej niż 5 czujnikami. Artykuły te dotyczyły jednak tylko podstawowych gestów lub ruchów. Ich listę zamieszczono w tabeli 5.3.1.

Tab 5.3.1. Artykuły opisujące urządzenia z mniej niż 5 czujnikami

Referencja	Ilość i rodzaj sensorów	Max. skuteczność
Gupta et al. (2020)	2 IMU	Tylko śledzenie ruchu przedramienia
Devnath et al. (2019)	2 IMU	Śledzenie tylko dwóch palców
Zhang et al. (2019)	4 czujniki nacisku	Testowanie podstawowych gestów
Huang et al. (2019)	2 IMU	Tylko śledzenie ruchu przedramienia

Konieczne jest również porównanie skuteczności algorytmów klasyfikacji opisanych w niniejszej pracy. Kilka prac dotyczących urządzeń, za pomocą których badano i klasyfikowano syntetycznie oddzielone dynamiczne gesty lub litery alfabetu migowego za pomocą sieci neuronowych, podsumowano wraz z liczbą czujników używanych w tej pracy w tabeli 5.3.2.

Tab 5.3.2. Porównanie z wynikami uzyskanymi w innych badaniach

Referencja	Ilość i rodzaj sensorów	Max. skuteczność
[5] Simoes Dias et al. (2022)	5 ugięcia + IMU sensor + 2 czujniki kontaktowe	96,15%
[6] Lee et al. (2020)	5 IMU sensor	99%
[7] Pezzuoli et al. (2021)	10 ugięcia + IMU sensor	99,7%
[8] Bae et al. (2021)	10 ugięcia + IMU sensor	94%
[9] Saggio et al. (2020)	10 ugięcia + IMU sensor	96,6%

Jak więc widać, koncepcja opisana w niniejszej pracy umożliwia osiągnięcie równie dobrych, jeśli nie lepszych wyników przy użyciu liczby czujników nawet kilkakrotnie mniejszej niż w przypadku porównywalnych rozwiązań.

6. Dyskusja i wnioski

6.1. Podsumowanie wyników badań

Wśród najlepszych wyników osiągniętych dla zbioru wszystkich liter oraz dla zbioru z rozszerzonymi odczytami od jednej osoby, wyróżnia się zestaw tercetów: 1_2, 3_1, 5_1 (oznaczone na niebiesko), jak to zaznaczono w tabeli 5.2.1. Wśród wyników eksperymentów dla różnych kombinacji dwóch czujników można również zidentyfikować powtarzający się zestaw dla obu zbiorów danych: P2_1, P3_2. Co jeszcze ważniejsze, wydajność klasyfikacji oparta na danych z tylko dwóch czujników piezorezystancyjnych i 6-osiowego czujnika inercyjnego pozwoliła uzyskać dokładność klasyfikacji na poziomie 99% w przypadku danych rozszerzonych i 82% w przypadku danych od wszystkich badanych razem. To potwierdza kolejną korzyść związaną z wykorzystaniem podejścia, które wykorzystuje dane tylko od jednej osoby do trenowania sieci.

Wnioski z przeprowadzonych badań potwierdzają główną tezę niniejszej pracy, tj. możliwość skutecznego rozpoznawania gestów liter alfabetu Polskiego Języka Migowego, przy użyciu jedynie trzech sensorów. To jest szczególnie ważne w kontekście dalszego rozwoju takich rękawic jako elementów systemów tłumaczenia języka migowego. Niedostatki w ergonomii i mała wydajność często stanowią podstawę do krytyki tej technologii. Dotychczas niewiele zespołów badawczych badało i testowało różne czujniki, zakładając, że potrzebnych jest co najmniej 5 z nich. Wyniki niniejszej pracy wskazują na możliwość znacznego zmniejszenia rozmiaru rękawic wykorzystywanych do rozpoznawania liter alfabetu Polskiego Języka Migowego.

6.2. Kontrybucja i wpływ uzyskanych rezultatów

Podsumowując uzyskane wyniki:

- Udowodniono, że możliwe jest skuteczne rozpoznawanie syntetycznie segmentowanych liter Polskiego Języka Migowego z wykorzystaniem danych z zaledwie trzech czujników piezorezystancyjnych z dokładnością nie gorszą niż 90%

Wyniki niniejszej pracy mogą stanowić wartościowy punkt odniesienia dla badaczy i ukierunkować prace na zmniejszenie rozmiaru rękawicy, która może stanowić kluczowy element systemów tłumaczenia języka migowego. Za najważniejsze osiągnięcie pracy można uznać potwierdzenie możliwości redukcji rozmiaru tych rękawic poprzez zmniejszenie liczby czujników. W ramach niniejszych badań wytrenowano sieć neuronową, wykorzystując tylko dane z trzech czujników zgięcia palców oraz dane z sześcioposiowego czujnika inercyjnego. Wyniki tych badań pozwalają nie tylko nie zmniejszyć skuteczności rozpoznawania gestów, ale mogą obniżyć koszty produkcji i poprawić ergonomię urządzenia.

Równie interesujące wyniki przyniósł eksperyment, w którym poprzez rozszerzenie danych od jednej osoby udało się osiągnąć większą skuteczność rozpoznawania gestów niż w przypadku trenowania klasyfikatorów na danych od wielu osób. Ten wynik sugeruje, że obszerne pomiary od dużej liczby osób niekoniecznie są wymagane do zbudowania uniwersalnego modelu. Krótka kalibracja przeprowadzona na jednej osobie wydaje się być wystarczająca, co znacznie upraszcza proces tworzenia efektywnych systemów rozpoznawania gestów

Wyniki niniejszych prac otwierają możliwość opracowania uniwersalnego modelu poprzez zastosowanie uczenia transferowego. Metoda ta polega na wykorzystaniu wcześniej wytrenowanych modeli sieci neuronowych i dostosowaniu ich do nowych danych, co pozwala oszczędzić zasoby obliczeniowe i czas obliczeń. Korzystając z danych pochodzących od wielu osób, można dostosować model do różnych stylów i idiosynkrazji

ruchów dłoni, co może przyczynić się do opracowania bardziej wszechstronnego i uniwersalnego systemu rozpoznawania gestów.

7. Bibliografia

- [1] "Assistive listening devices / Deaf and Hard of Hearing." Accessed: Jul. 14, 2023. [Online]. Available: <https://mn.gov/deaf-hard-of-hearing/assistive-technology/assistive-listening-devices/>
- [2] "Assistive Devices for People with Hearing or Speech Disorders | NIDCD." Accessed: Jul. 14, 2023. [Online]. Available: <https://www.nidcd.nih.gov/health/assistive-devices-people-hearing-voice-speech-or-language-disorders#4>
- [3] "Tłumacz Migam - Migam." Accessed: Jul. 14, 2023. [Online]. Available: <https://migam.org/tlumacz-migam/>
- [4] D. J. Sandin and T. A. DeFanti, "Sayre Glove - US NEA R60-34-163 Final Project Report." pp. 1–30, 1977.
- [5] T. Simoes Dias, J. J. A. M. Junior, and S. F. Pichorim, "An Instrumented Glove for Recognition of Brazilian Sign Language Alphabet," *IEEE Sens J*, vol. 22, no. 3, pp. 2518–2529, 2022, doi: 10.1109/JSEN.2021.3136790.
- [6] B. G. Lee, T. W. Chong, and W. Y. Chung, "Sensor Fusion of Motion-Based Sign Language Interpretation with Deep Learning," *Sensors 2020, Vol. 20, Page 6256*, vol. 20, no. 21, p. 6256, Nov. 2020, doi: 10.3390/S20216256.
- [7] F. Pezzuoli, D. Corona, and M. L. Corradini, "Recognition and Classification of Dynamic Hand Gestures by a Wearable Data-Glove," *SN Comput Sci*, vol. 2, no. 1, 2021, doi: 10.1007/s42979-020-00396-5.
- [8] M. Lee and J. Bae, "Deep Learning Based Real-Time Recognition of Dynamic Finger Gestures Using a Data Glove," *IEEE Access*, vol. 8, pp. 219923–219933, 2020, doi: 10.1109/ACCESS.2020.3039401.
- [9] G. Saggio, P. Cavallo, M. Ricci, V. Errico, J. Zea, and M. E. Benalcázar, "Sign language recognition using wearable electronics: Implementing K-nearest neighbors with dynamic time warping and convolutional neural network algorithms," *Sensors (Switzerland)*, vol. 20, no. 14, pp. 1–14, 2020, doi: 10.3390/s20143879.

- [10] P. Pławiak, T. Sońnicki, M. Niedźwiecki, Z. Tabor, and K. Rzecki, "Hand Body Language Gesture Recognition Based on Signals From Specialized Glove and Machine Learning Algorithms," *IEEE Trans Industr Inform*, vol. 12, no. 3, pp. 1104–1113, 2016, doi: 10.1109/TII.2016.2550528.
- [11] T. Dziubich and J. Szymański, "Automatic classification of Polish sign language words | Automatyczna klasyfikacja znaków Polskiego języka miganego," *Przegląd Elektrotechniczny*, vol. 90, no. 3, 2014, doi: 10.12915/pe.2014.03.43.
- [12] E. Korzeniewska, M. Kania, and R. Zawiślak, "Textronic Glove Translating Polish Sign Language," *Sensors*, vol. 22, no. 18, 2022, doi: 10.3390/s22186788.
- [13] J. PISKOZUB, "Rozpoznawanie gestów statycznych ręki za pomocą rękawicy sensorowej," *PRZEGLĄD ELEKTROTECHNICZNY*, vol. 1, no. 9, pp. 144–147, Sep. 2019, doi: 10.15199/48.2019.09.29.
- [14] J. Piskozub and P. Strumillo, "Reducing the Number of Sensors in the Data Glove for Recognition of Static Hand Gestures," *Applied Sciences*, vol. 12, no. 15, p. 7388, Jul. 2022, doi: 10.3390/app12157388.
- [15] Z. R. Saeed, Z. B. Zainol, B. B. Zaidan, and A. H. Alamoodi, "A Systematic Review on Systems-Based Sensory Gloves for Sign Language Pattern Recognition: An Update from 2017 to 2022," *IEEE Access*, pp. 1–1, 2022, doi: 10.1109/ACCESS.2022.3219430.