

Wprowadzenie do Sztucznej Inteligencji

Przegląd zastosowań metod SI oraz uczenia maszynowego w biometrii i w medycynie

Wykład (1 godz. wykł.)

prof. dr hab. inż. Bożena Kostek (p. 731)
LAF/KSM WETI

Wprowadzenie

- W niniejszym wykładzie przedstawione zostaną przykłady wykorzystania sztucznej inteligencji w praktycznych zastosowaniach: technologie inżynierii biomedycznej oraz biometria.
- Przykładem takiego zastosowania jest projekt PERFORM, zrealizowany w ramach międzynarodowego konsorcjum (kliniki uniwersytetów medycznych, uczelnie wyższe, ośrodki badawczo-rozwojowe i firmy)

Technologie inż. biomedycznej wykorzystujące SI

- Inteligentne buty wyposażone w czujniki
- Inteligentne maty do monitorowania snu, upadek z łóżka
- Inteligentna waga – ocena równowagi
- Czujniki, kamery, mikrofony, żyroskopy, itd. do monitorowania aktywności dziennej,
- Kaski EEG,
- Urządzenia do śledzenia ruchu gałek ocznych (*eye, gaze trackery* – do komunikacji z otoczeniem),
- Roboty wspomagające osoby niepełnosprawne (np. robot KOMPAI-3).

Technologie wykorzystujące SI – zastosowania w chorobach neurodegeneracyjnych

- Identyfikacja choroby
- Bezpieczeństwo pacjenta
- Rehabilitacja
- Zachowanie produktywności

Technologie wykorzystujące SI – zastosowania w chorobach neurodegeneracyjnych

- Możliwość przewidzenia wystąpienia choroby w ciągu najbliższych 5 lat;
- Nadzorowanie i monitorowanie pacjentów z zaburzeniami neurodegeneracyjnymi;
- Wspieranie lekarzy i zwiększenie ilości przeprowadzanych diagnoz, a tym samym zmniejszenie liczby występowanie zaawansowanych przypadków choroby;
- Skuteczne rozpoznanie choroby i przewidzenie dalszych rokowań w każdym stadium choroby;
- Analiza dużych zbiorów danych.

Technologie wykorzystujące SI – zastosowania w chorobach neurodegeneracyjnych

Choroba Alzheimerera

- Głównie badania PET i MRI
- Baza danych: The Alzheimer's disease Neuroimaging Initiative (ADNI)
- Używane algorytmy:
 - Splotowe sztuczne sieci neuronowe (CNN)
 - Głębokie sieci generatywne (Deep Belief Networks)
- Analiza rozmowy z pacjentem

Technologie wykorzystujące SI – zastosowania w chorobach neurodegeneracyjnych

Stwardnienie zanikowe boczne

- Interfejs do sterowania komputerem za pomocą mózgu (BCI)
- Próby przewidywania reakcji pacjentów na leki

Technologie wykorzystujące SI – zastosowania w chorobach układu nerwowego

Epilepsja

Do detekcji wykorzystuje się głównie sygnały EEG

Wykorzystywane algorytmy:

- Maszyny wektorów nośnych (SVM)
- Optymalizacja za pomocą roju cząstek (PSO)
- Algorytmy genetyczne (GA)
- Logika rozmyta (Fuzzy logic)

Technologie wykorzystujące SI – zastosowania w chorobach neurodegeneracyjnych

PERFORM: wieloczynnikowy system, służący do ciągłego monitorowania i oceny funkcji motorycznych osób z zaburzeniami neurodegeneracyjnymi

A so**P**histicat**E**d multi-pa**R**ametric system **FOR** the continuous effective assessment and **M**onitoring of motor status in **Parkinson's** disease and other neurodegenerative diseases progression and optimizing patients' quality of life

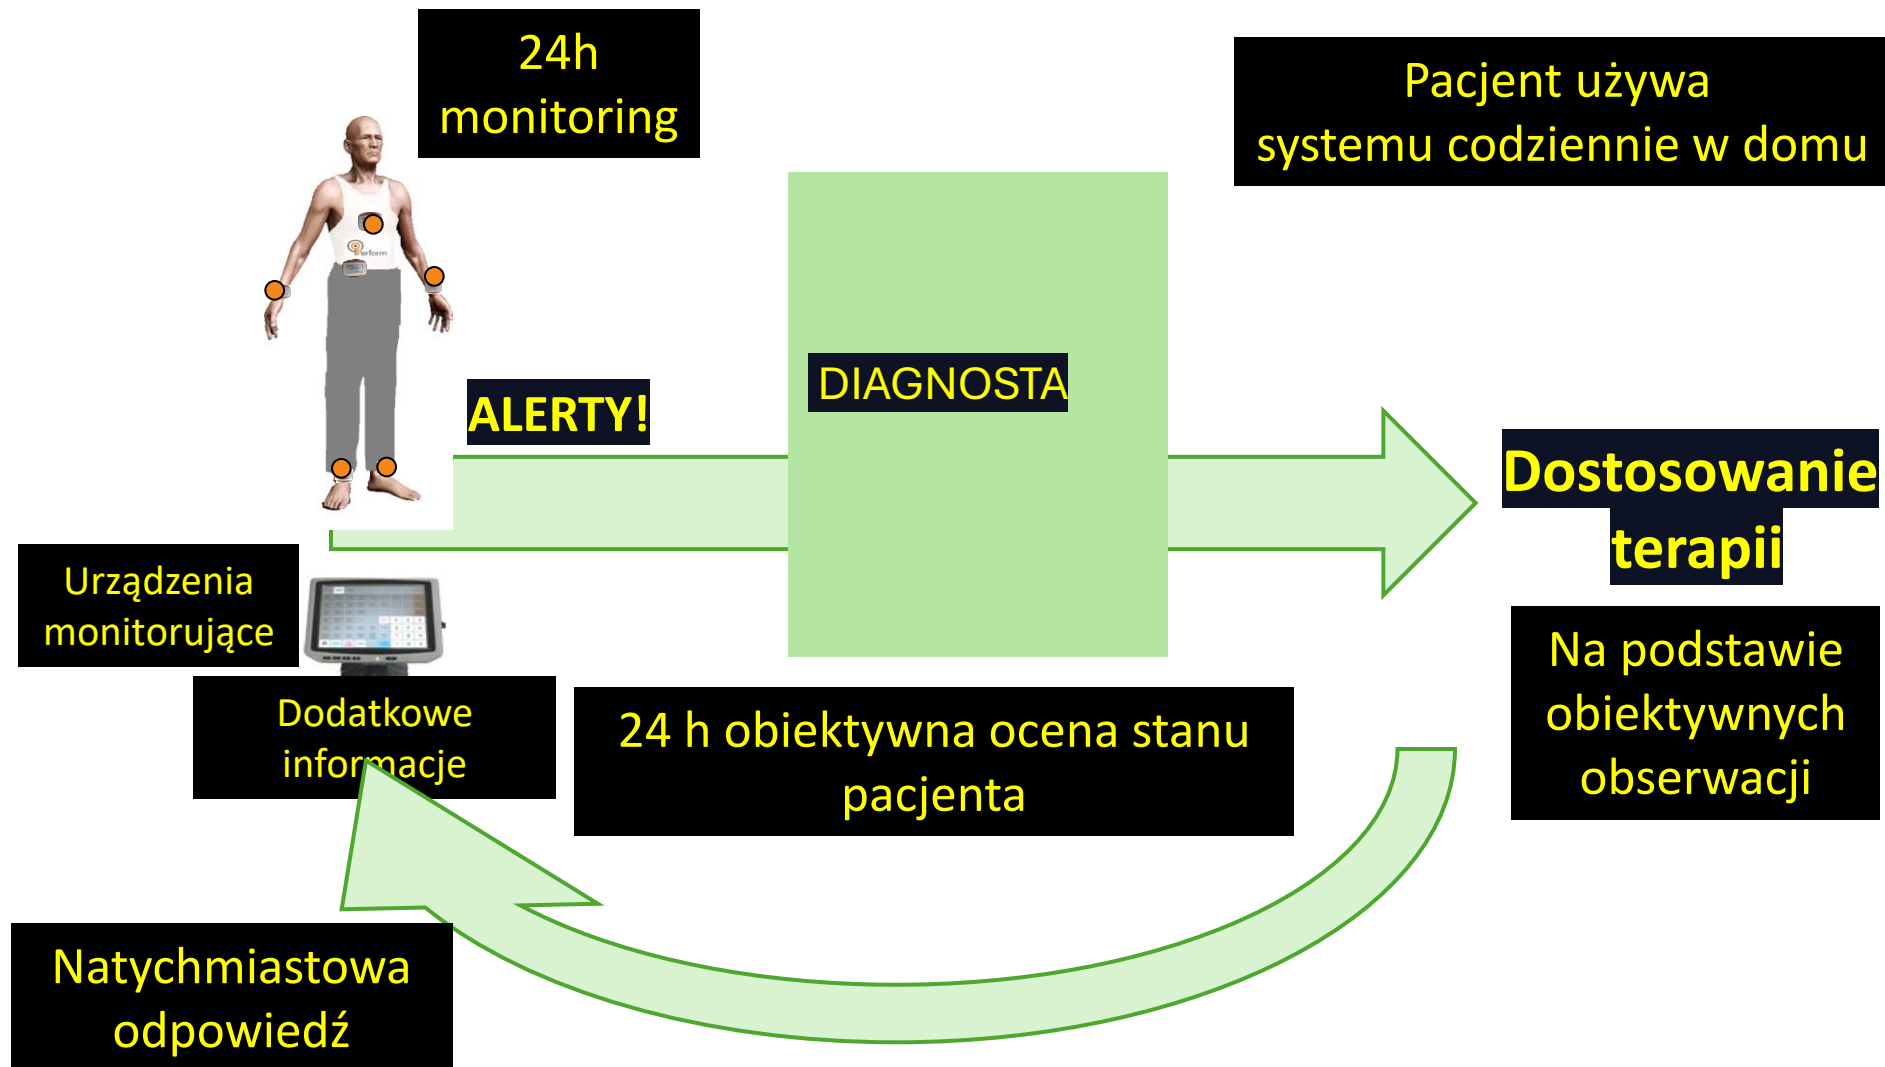
PERFORM - Wprowadzenie

- W wyniku realizacji projektu powstał system ciągłego, zdalnego monitorowania stanu motorycznego osób cierpiących na choroby zwyrodnieniowe układu nerwowego (w szczególności na chorobę Parkinsona).
- System umożliwia zdalne obserwowanie bieżącego stanu pacjentów oraz oceny poprawności i efektywności indywidualnie dobranego schematu ich leczenia, a także ewentualnej jego korekty.
- System ma możliwość łączenia własnych danych z danymi z innych źródeł, po to aby poszerzyć bazę wiedzy, a następnie wykorzystać ją jako wejściowy materiał informacyjny dla zestawu inteligentnych komputerowych narzędzi decyzyjnych.

PERFORM - CELE DO OSIĄGNIĘCIA

- Ciągły monitoring i ocena stanu pacjenta
- Detekcja symptomów przy użyciu pojedynczego zestawu czujników
- Wczesne wykrywanie postępów choroby i zmian stanu pacjenta
- Wspomaganie w leczeniu (prowadzeniu) pacjenta przy użyciu inteligentnych metod zdobywania wiedzy
- Prognoza przyszłego przebiegu choroby uzależniona od charakterystyki danego pacjenta

Cele medyczne – system PERFORM



Cele medyczne – system PERFORM

Krótkoterminowe

- 24h obiektywna ocena stanu pacjenta
- Rozpoznawanie stanu zakończenia działania ostatniej dawki lekarstwa
- Możliwość dostosowania terapii to przebiegu choroby charakterystycznego dla danego pacjenta
 - Harmonogram przyjmowania lekarstw
 - Harmonogram i kompozycja posiłków
- Rozpoznawanie zmian w reakcji pacjenta na terapię
- Natychmiastowy dostęp do ogólnej informacji o pacjencie
- Szybki dostęp do szczegółowych informacji o pacjencie

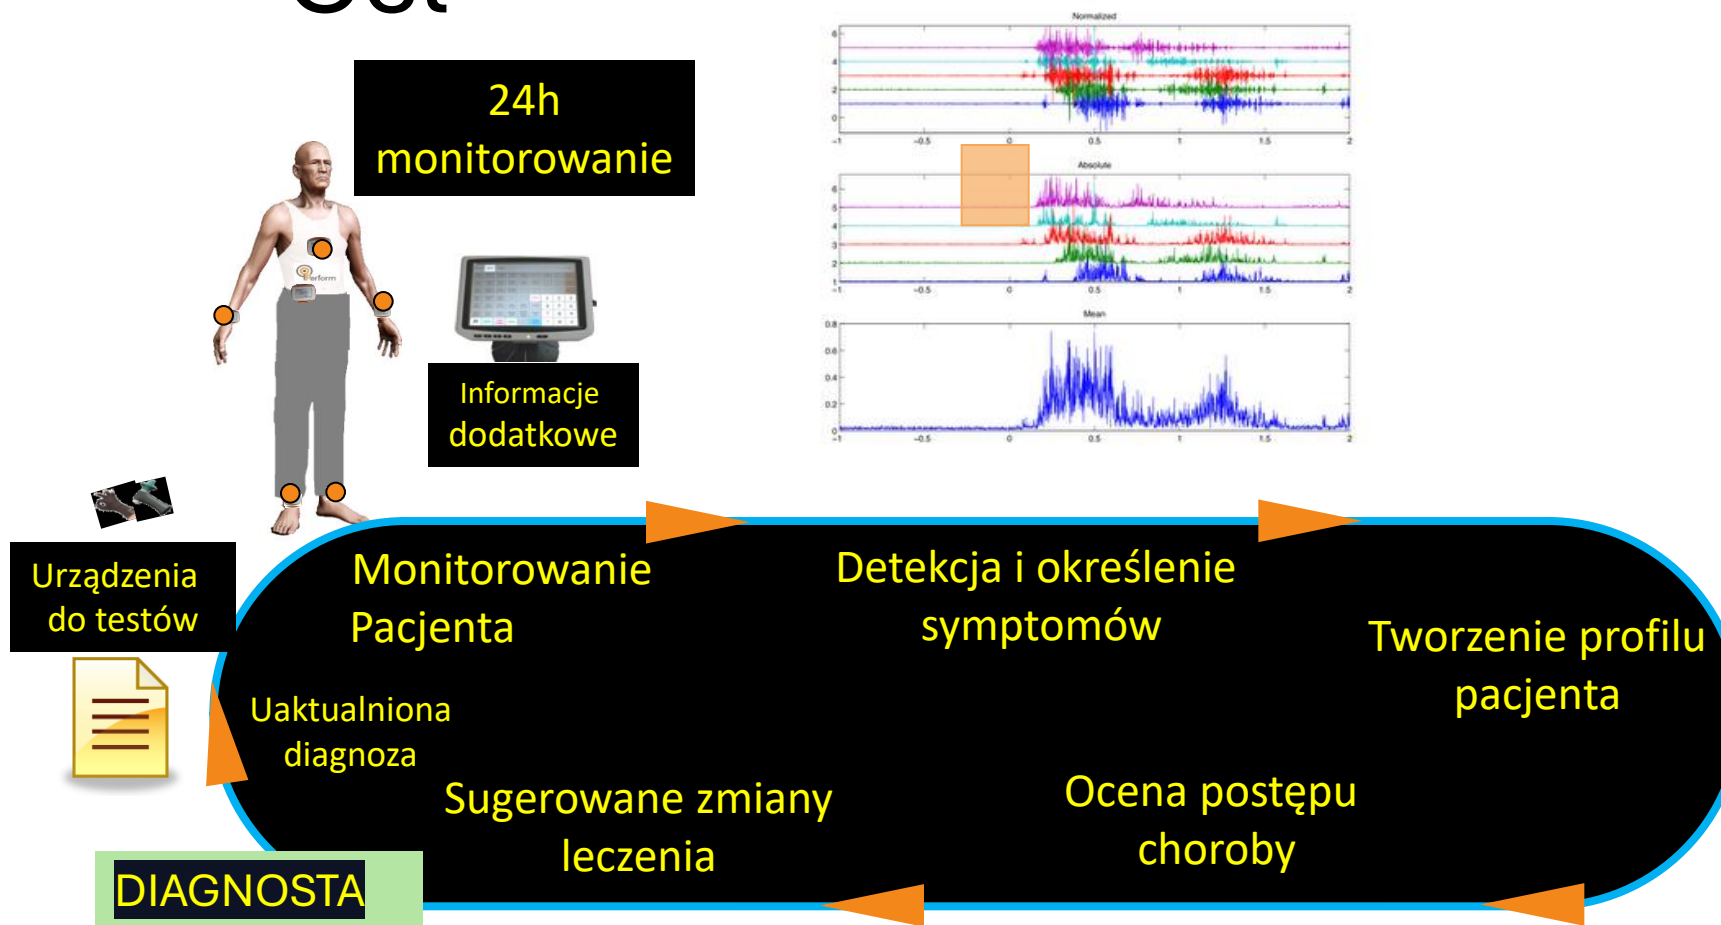
Cele medyczne – system PERFORM

Długoterminowe

- Obiektywna ocena terapii
- Obserwacja postępów symptomów choroby w czasie
- Rozpoznawanie zmian/reakcji pacjenta na zmianę terapii

Zaprojektowanie, wdrożenie i walidacja systemu wielo-sensorycznego, służącego do ciągłego monitorowania i oceny stanu motoryki ruchów osób z chorobami neurodegeneracyjnymi

Cel



Komputer osobisty (lub innego tego typu urządzenie) z odpowiednim oprogramowaniem (**LBU – Local Base Unit**). Sprzęt ten przekazuje dane do komputera jednostki opieki medycznej (**CHU – Central Hospital Unit**).

Cel

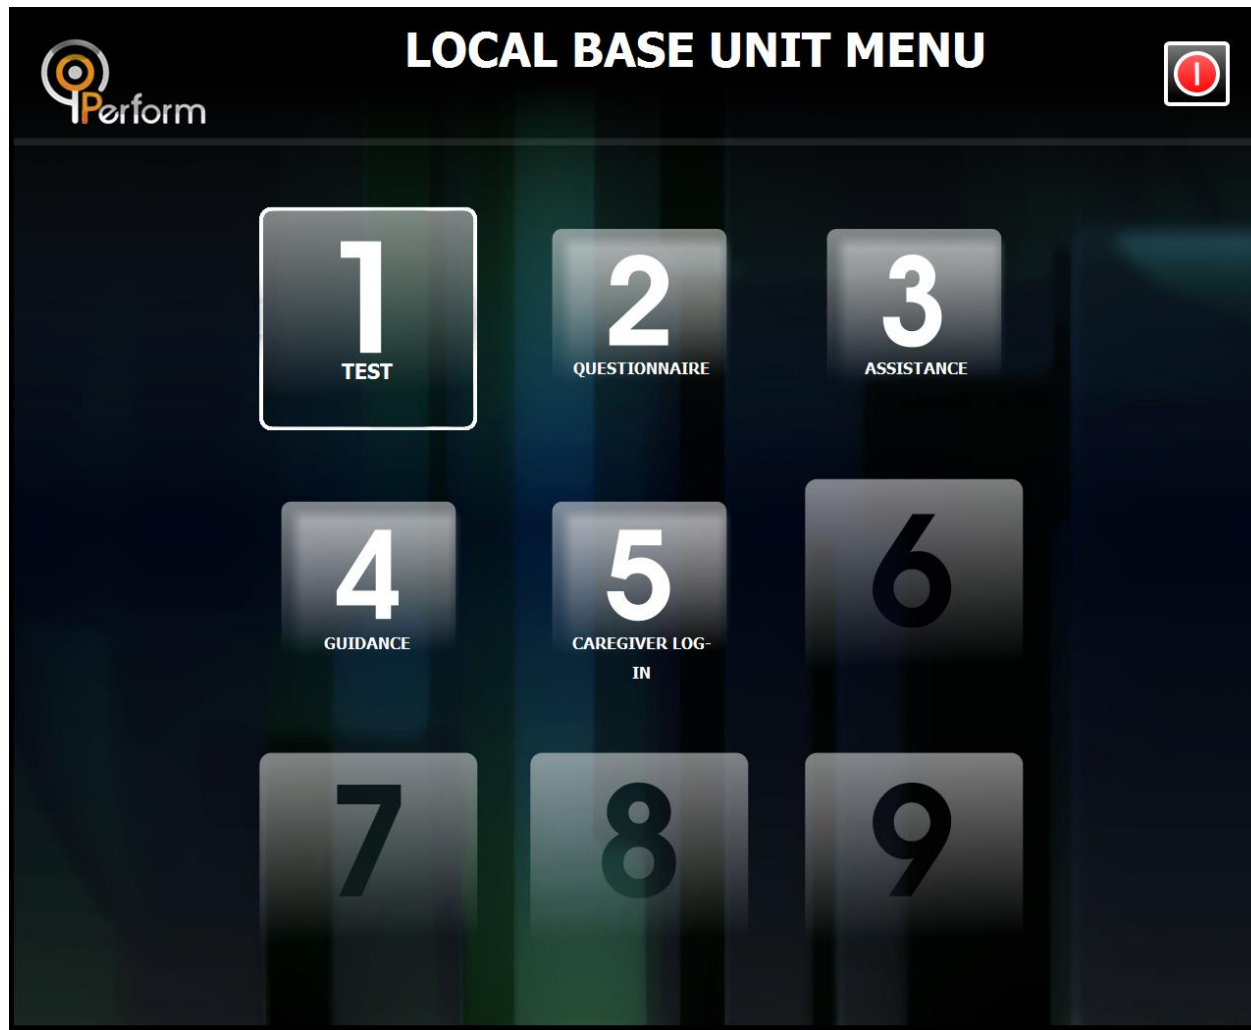
Komputer osobisty (lub innego tego typu urządzenie) z odpowiednim oprogramowaniem (**LBU – Local Base Unit**).

Koncepcja menu wykorzystująca schemat klawiatury typowych urządzeń takich jak: smartfon, pilot zdalnego sterowania do telewizora, itp.

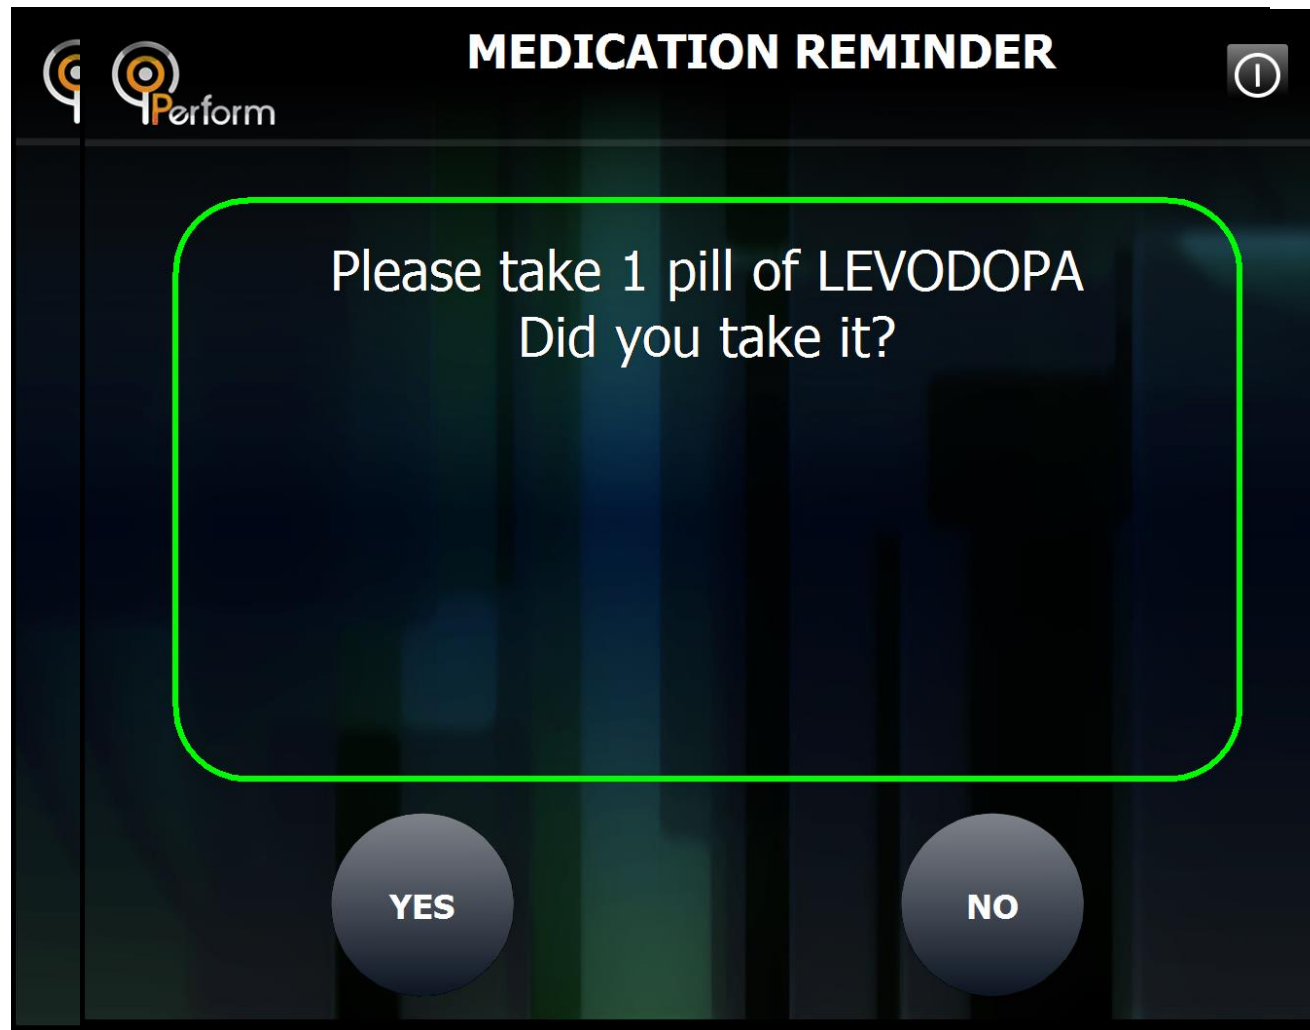
Duże, czytelne komunikaty (również odczytywane przez komputer – synteza mowy):

- interaktywny, graficzny harmonogram zażywania leków,
- Interaktywny, graficzny kwestionariusz posiłków,
- graficzne, interaktywne interfejsy ćwiczeń,
- automatyczna analiza obrazu z kamery komputera.

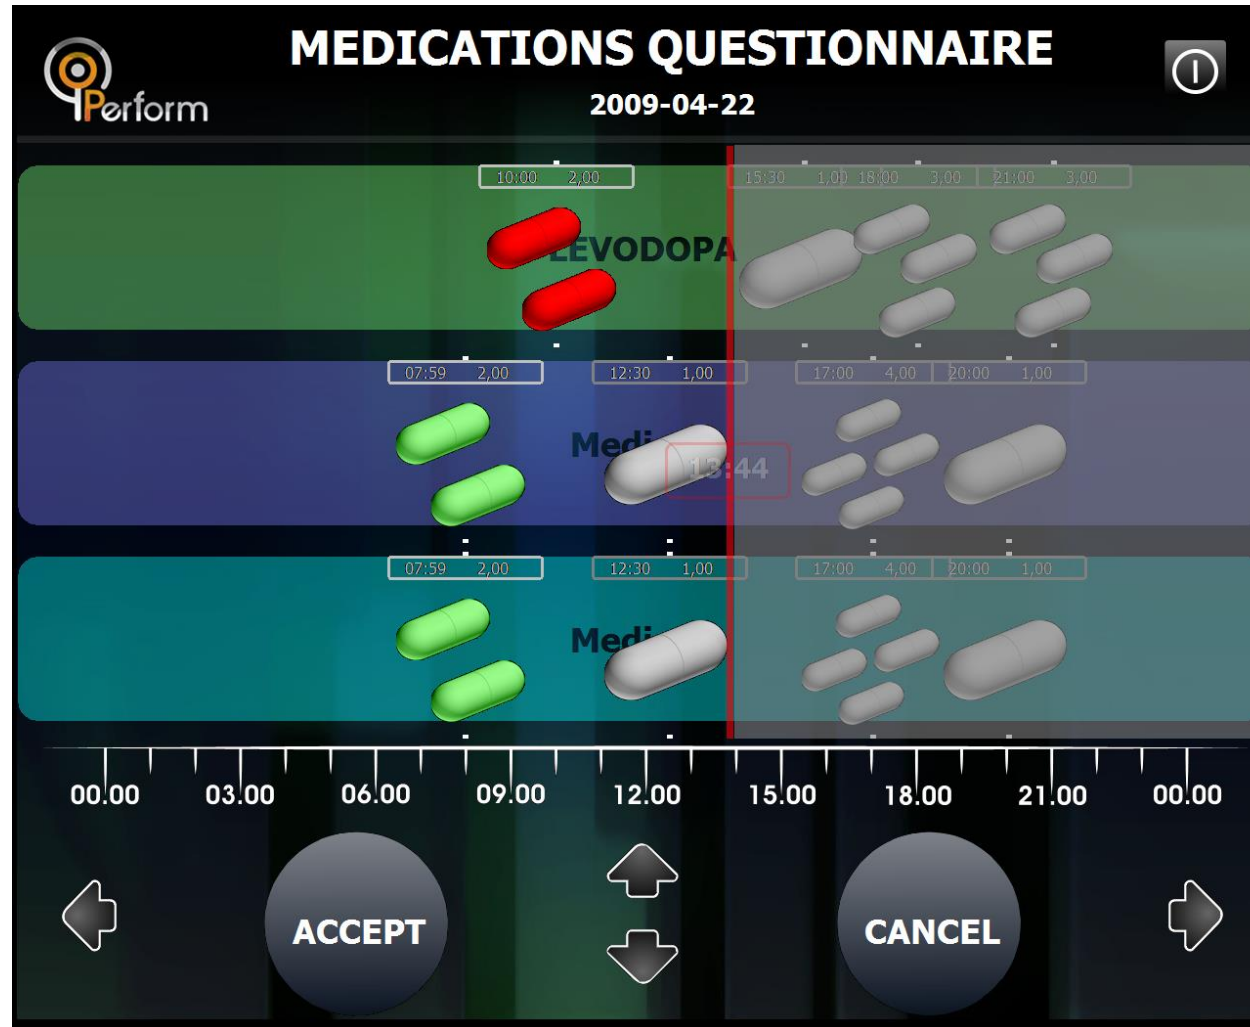
- Interfejsy multimodalne (interakcja pacjenta z systemem)



- Interfejsy multimodalne (interakcja pacjenta z systemem)



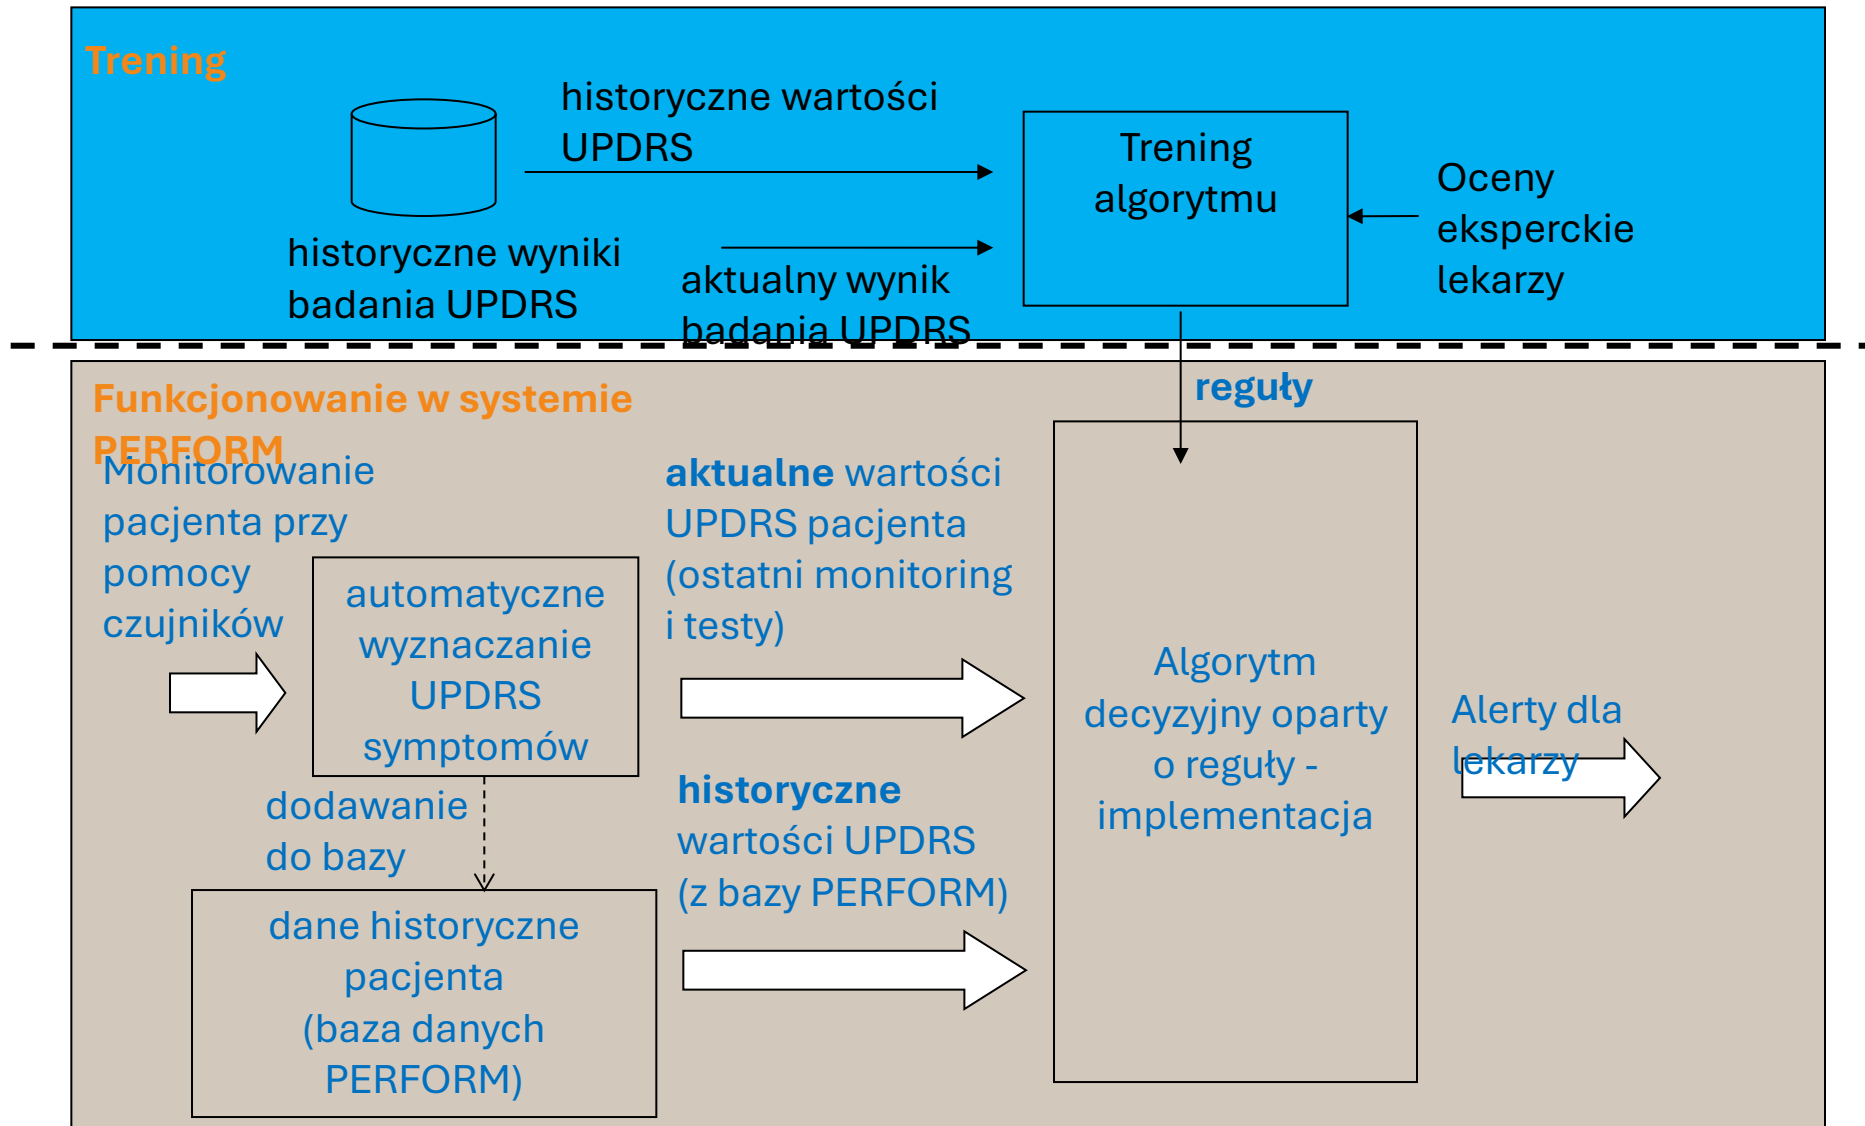
- Interfejsy multimodalne (interakcja pacjenta z systemem)



- Interfejsy multimodalne (interakcja pacjenta z systemem)

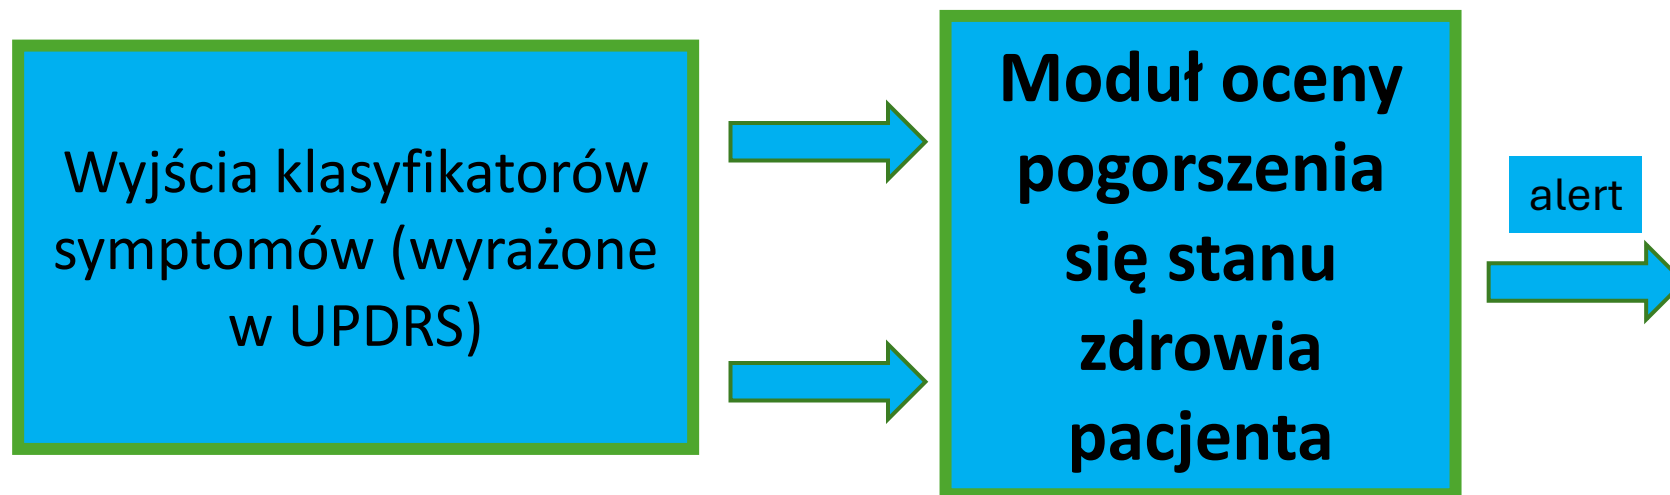


Trening i funkcjonowanie modułu



Ogólna zasada działania modułu

- **Moduł oceny pogorszenia się stanu zdrowia pacjenta** jest ostatnim elementem decyzyjnym systemu. Wejściami tego modułu są wyjścia pozostałych klasyfikatorów wyrażone w UPDRS (0-4). System PERFORM umożliwia wyznaczenie następujących wartości UPDRS: UPDRS 13, 14, 20, 21, 23, 24, 25, 28, 29, 31, 32, 39.
- Wyjściem modułu jest alert informujący o ewentualnym pogorszeniu się zdrowia pacjenta (wartości aktualne UPDRS są porównywalne z wartościami historycznymi zapisanymi w bazie danych projektu PERFORM).



Cel

Komputer osobisty (lub innego tego typu urządzenie) z odpowiednim oprogramowaniem (**LBU – Local Base Unit**).

Koncepcja menu wykorzystująca schemat klawiatury typowych urządzeń takich jak: smartfon, pilot zdalnego sterowania do telewizora, itp.

Duże, czytelne komunikaty (również odczytywane przez komputer – synteza mowy):

- interaktywny, graficzny harmonogram zażywania leków,
- Interaktywny, graficzny kwestionariusz posiłków,
- graficzne, interaktywne interfejsy ćwiczeń,
- automatyczna analiza obrazu z kamery komputera.

Zbiór reguł

- Wiedzę do wygenerowania reguł zebrano z kwestionariuszy lekarzy oceniających pary historycznych i aktualnych wartości UPDRS
- Do generacji reguł zastosowano metodę zbiorów przybliżonych. Metoda ta najlepiej nadaje się do obróbki danych takich kwestionariuszy, w których może wystąpić brak danych, sprzeczne dane, itp.

Przykład wygenerowanej reguły:

**jeśli ($\Delta UPDRS_{14} > 1$) i ($\Delta UPDRS_{23} > 2$) i ($\Delta UPDRS_{25} > 1$) i
($\Delta UPDRS_{31} > 2$) => OUT= alarm (alert wysokiego priorytetu)**

- Reguły wygenerowane w konkretnym przypadku są zaprezentowane lekarzowi do weryfikacji. Dzięki temu lekarz ma informację, które symptomy wpłynęły na decyzję systemu.

Założenia modułu sygnałowego

- Wartości UPDRS wybranych symptomów są automatycznie wyliczane podczas monitorowania pacjenta w domu (głównie symptomy motoryczne),
- Obliczane wartości są zapisywane w bazie danych. W każdym momencie istnieje możliwość dostępu do danych historycznych z dowolnego dnia i dla danego pacjenta,
- Moduł bada zmiany wartości UPDRS dla danego pacjenta i automatycznie wykrywa pogorszenie się stanu zdrowia pacjenta. W przypadku wykrycia takiego stanu zgłasza odpowiednie ostrzeżenie (ALERT).


Założenia modułu rejestracji sygnałów

- Każdy z pacjentów wykonywał następujące czynności: chodzenie po linii prostej z obrotem; podnoszenie obiektu odpowiednio ręką lewą, prawą oraz obiema rękami; podnoszenie lewej, prawej oraz obu rąk; siadanie i wstawanie z krzesła; kładzenie się i wstawanie z łóżka; stanie; siedzenie; leżenie.
- Każda aktywność wykonywana była w sekwencji łączącej aktywność dynamiczną z czynnością statyczną. Dla przykładu sekwencję chodu rejestrowano w sekwencji: stanie w miejscu, chodzenie z obrotem oraz zatrzymanie się.
- Każda sekwencja ruchu była powtarzana trzykrotnie. Podczas rejestracji sygnałów przyspieszenia rejestrowano także obraz wideo zsynchronizowany z sygnałami przyspieszenia.
- Nagrania wideo pozwalały na precyzyjne wyznaczenie początku i końca każdej z kategorii ruchowych.

Założenia modułu rejestracji sygnałów

- Sygnały przyspieszenia rejestrowano z wykorzystaniem dwóch rodzajów urządzeń wyposażonych w trójosiowe akcelerometry. Zbierany sygnał zapisywano na kartach *microSD* zintegrowanych z urządzeniami zapisu.
- Akcelerometry rozmieszczano na nadgarstkach, kostkach oraz klatce piersiowej osoby biorącej udział w testach. Rozmieszczenie urządzeń zostało dobrane w taki sposób, by pozwalało na detekcję jak największej liczby aktywności ruchowych oraz ocenę stanu pacjenta dokonywaną automatycznie przez algorytmy rozpoznające symptomy choroby.
- Podczas testów wykorzystywano urządzenia wyprodukowane przez firmę *Shimmer* oraz urządzenie zaprojektowane w ramach projektu *PERFORM*.
- Zakres przyspieszeń rejestrowanych przez akcelerometry zawierał się w przedziale ± 6 g, co w pełni pokrywa zakres przyspieszeń uzyskiwanych podczas typowych aktywności ruchowych ciała ludzkiego. Częstotliwość próbkowania sygnału wynosiła odpowiednio 51.2 Hz dla urządzenia *Shimmer* oraz 62.5 Hz dla systemu *PERFORM*.

Podczas rejestracji sygnałów uzyskiwano 15 niezależnych przebiegów sygnału przyspieszenia. Przykładowe przebiegi czasowe sygnałów dla aktywności chodu zamieszczono na rysunku poniżej.



Założenia modułu rejestracji sygnałów

Na wykresach sygnału odpowiadającego osi x można zaobserwować składową stałą równą przyspieszeniu ziemskiemu (1 g). Występowanie składowej stałej dla tej osi związane jest z orientacją osi akcelerometrów, które były ustawione w następujący sposób: oś x - wertykalnie, oś y - horyzontalnie i prostopadle do klatki piersiowej, oś z - wertykalnie i równoległe do klatki piersiowej.

Parametryzacja sygnałów przyspieszenia

- Dolnoprzepustowa filtracja sygnału przyspieszenia z częstotl. odcięcia równą 3 Hz daje najlepsze wyniki w eliminacji zakłóceń, jednocześnie nie usuwając istotnych w procesie klasyfikacji informacji związanych z częstotliwością ruchu. Przed analizą właściwą, wszystkie sygnały zostały poddane filtracji dolnoprzepustowej za pomocą filtra IIR.
- Parametryzacja sygnału wykonywana była w ramach czasowych zależnych od rodzaju aktywności. W przypadku rozpoznawania chodu zastosowano ramkę o długości 1250 ms przesuwaną z krokiem 625 ms, co odpowiadało 64 i 32 próbkom sygnału dla urządzeń *Shimmer* oraz 78 i 39 próbkom dla urządzeń opracowanych w ramach projektu *PERFORM*. Podczas parametryzacji sygnału wykorzystanej do klasyfikacji ruchu rąk zastosowano krótszą ramkę o długości 625 ms i kroku 320 ms.
- Zastosowanie krótszej ramki związane było z koniecznością wykrywania aktywności szybkozmiennych. Wszystkie parametry przed podaniem na wejście klasyfikatora były normalizowane do zakresu wartości $\langle -1, 1 \rangle$.

Parametryzacja sygnałów przyspieszenia

Parametry w dziedzinie czasu

W procesie parametryzacji wykorzystano typowe parametry opisujące właściwości statystyczne parametryzowanych sygnałów.

Jako pierwszy parametr przyjęto wartość średnią sygnału – parametr opisujący poziom przyspieszenia odpowiadający analizowanej ramce sygnału. Można zauważyć, że parametr ten przyjmuje wysokie wartości dla aktywności dynamicznych (np. chód, ruch rąk) i niskie w przypadku aktywności statycznych (np. siedzenia).

Wartość średnia, odchylenie standardowe sygnału przyspieszenia, kurtoza zostały wyznaczone w celu określenia dynamiki zmian sygnału przyspieszenia, współczynnik szczytu (ang. *crest factor*) oznacza stosunek maksymalnej wartości sygnału do wartości RMS. Parametr ten opisuje charakter impulsowy sygnału, wykorzystano również współczynnik korelacji.

Parametryzacja sygnałów przyspieszenia

Parametry w dziedzinie widma sygnału

Złożoność ruchu opisano za pomocą energii widmowej sygnału

Ocena okresowości ruchu opisywana jest przez entropię

Stosowane klasyfikatory

Klasyfikację sygnałów przyspieszenia wykonywano z wykorzystaniem dwóch zależnych od siebie klasyfikatorów, służących do rozpoznawania kategorii chód oraz do rozpoznawania ruchu rąk. Klasyfikatory zostały przygotowane w oparciu o algorytm sztucznych sieci neuronowych oraz maszynę wektorów nośnych (ang. SVM - *Support Vector Machine*)

Każdy algorytm został przetestowany z wykorzystaniem algorytmu walidacji krzyżowej oraz metody *leave-one-out*

Konfiguracja akcelerometrów	Rodzaj aktywności	SVM (C = 62.5, $\gamma=0.5$)		SVM grid-search		Sieć neuronowa	
		Skuteczność [%]	Odchylenie standardow	Skuteczność [%]	Odchylenie standardow	Skuteczność [%]	Odchylenie standardow
1 – lewa noga	Chód	95,63	7,34	96,34	5,89	97,27	17,82
	Brak	97,66	7,76	97,86	7,57	97,00	7,90
1 – prawa noga	Chód	95,06	17,65	94,93	18,69	94,86	17,97
	Brak	96,96	8,82	97,18	8,87	96,04	8,06
2 - nogi	Chód	96,71	13,27	97,51	10,91	98,00	5,73
	Brak	98,86	3,16	98,62	4,23	96,82	7,28
2 – prawa noga, klatka piersiowa	Chód	97,15	9,71	98,24	6,97	96,35	14,00
	Brak	96,67	9,48	97,75	7,08	95,88	9,73
3 – nogi, klatka piersiowa	Chód	98,82	2,03	<u>99,19</u>	<u>1,66</u>	85,49	20,82
	Brak	98,12	6,08	98,01	6,04	77,10	16,77
3 – lewa ręka, prawa noga, klatka piersiowa	Chód	97,02	6,74	98,01	4,96	91,02	13,63
	Brak	97,33	6,51	97,31	6,95	86,28	17,81
5 – nogi, ręce, klatka piersiowa	Chód	96,94	6,86	97,16	6,65	34,35	28,99
	Brak	<u>99,24</u>	<u>1,91</u>	98,36	3,71	83,89	19,60

Konfiguracja akcelerometrów	Rodzaj aktywności	SVM (C = 62.5, $\gamma=0.5$)		SVM grid-search		Sieć neuronowa	
		ć [%]	Skuteczność Standardow	ć [%]	Skuteczność standardowe	ć [%]	Skuteczność standardowe
1 – lewa noga	Chód	97,47	1,14	97,03	0,97	97,42	1,39
	Brak	98,39	0,88	98,31	0,86	98,30	0,76
1 – prawa noga	Chód	98,37	0,89	98,65	0,51	97,50	1,30
	Brak	99,09	0,54	99,01	0,71	98,58	0,76
2 - nogi	Chód	98,89	0,44	98,99	0,72	98,68	0,90
	Brak	99,53	0,41	99,50	0,46	98,55	0,79
2 – prawa noga, klatka piersiowa	Chód	98,62	1,07	99,14	0,46	98,66	0,67
	Brak	99,26	0,42	99,16	0,53	97,77	1,41
3 – nogi, klatka piersiowa	Chód	99,37	<u>0,37</u>	<u>99,69</u>	0,42	90,54	8,01
	Brak	<u>99,78</u>	<u>0,26</u>	99,69	0,29	89,10	12,95
3 – lewa ręka, prawa noga, klatka piersiowa	Chód	98,49	1,65	98,91	1,19	92,64	8,13
	Brak	99,36	0,34	99,35	0,31	85,04	19,11
5 – nogi, ręce, klatka piersiowa	Chód	98,38	2,35	98,99	1,29	38,51	16,23
	Brak	99,65	0,37	99,69	0,27	94,04	7,48

Konfiguracja akcelerometrów		Rodzaj aktywności	SVM (C=60 $\gamma=0.5$)			Sieć neuronowa		
			Skuteczność	Odchylenie standardowe	Błąd rzędu	Skuteczność	Odchylenie standardowe	Błąd rzędu
2 czujniki - nadgarstki rąk	Lewa		76,33	35,90	<u>1,43</u>	<u>81,56</u>	33,55	4,46
	Prawa		74,88	<u>35,31</u>	0,44	<u>77,85</u>	38,02	1,54
	Obie		<u>93,15</u>	<u>13,15</u>	<u>4,30</u>	90,89	18,69	5,36
	Brak		99,41	0,91	50,06	99,63	0,84	<u>38,70</u>
3 czujniki - nadgarstki rąk, klatka piersiowa	Lewa		70,41	35,74	1,76	77,22	<u>33,03</u>	6,68
	Prawa		71,50	37,75	<u>0,36</u>	74,95	39,96	2,37
	Obie		<u>90,40</u>	<u>15,96</u>	<u>4,64</u>	86,21	23,15	7,30
	Brak		<u>99,69</u>	<u>0,60</u>	61,23	98,92	3,15	<u>46,35</u>

Wnioski

- Analiza wyników skuteczności rozpoznawania kategorii chodu w zależności od metody testowania, konfiguracji akcelerometrów oraz rodzaju klasyfikatora pokazała, że najwyższą skuteczność przy możliwie niewielkiej liczbie czujników można uzyskać stosując klasyfikator SVM i analizując sygnały rejestrowane przez trzy akcelerometry (nogi, klatka piersiowa)
- Najlepsze rezultaty klasyfikacji ruchu rąk uzyskano, stosując sieć neuronową i analizując wyłącznie sygnały rejestrowane przez czujniki umieszczone na nadgarstkach rąk

KLASYFIKACJA SYGNAŁÓW EEG

- Drugim przykładem projektu jest badanie sygnałów EEG i ich analiza za pomocą SI (na podstawie: Browarczyk J, Kurowski A, Kostek B. Analyzing the Effectiveness of the Brain–Computer Interface for Task Discerning Based on Machine Learning. *Sensors*. 2020; 20(8):2403. <https://doi.org/10.3390/s20082403>)

KLASYFIKACJA SYGNAŁÓW EEG

Przegląd stanu wiedzy (klasyfikacja sygnałów EEG) na podstawie publikacji:
Browarczyk J, Kurowski A, Kostek B. Analyzing the Effectiveness of the Brain–
Computer Interface for Task Discerning Based on Machine Learning. *Sensors*.
2020; 20(8):2403. <https://doi.org/10.3390/s20082403>

EEG-Related Task	Literature Source	Algorithm	Dataset	Classification Effectiveness
event-related potential	[46]	SVM, SWLDA, BLDA, SBL, SBLaplace	two experimental datasets	the best approach - approximately up to 100%
fatigue	[7]	spatial-temporal convolutional neural network (ESTCNN)	experimental, local dataset	97.3%
stress	[47]	DNN and deep CNN	experimental, local dataset	86.62
emotion	[48]	CNN	DEAP [49]	99.72%
emotion	[50]	dynamical graph CNN (DGCNN)	SEED [51]	90.4%
emotion	[52]	RNN with LSTM (Recurrent Neural Networks / Long Short-Term Memory)	SSVEP (steady-state visually evoked potentials)	93.0%
temporal analysis	[50]	dynamical graph CNN (DGCNN)	DREAMER [53]	86.23%
sleep disturbance detection	[54]	CNN (no feature extraction)	[54]	93.55% to 98.10% depending on the number of classes
auditory stimulus classification	[55]	RNN	experimental, local dataset	83.2%
automated visual object categorization	[56]	RNN, CNN-based regressor	experimental, local dataset	83%

MI (Motor Imagery) EEG	[57]	CNN, transfer learning	[57]	two classes: 86.49%, three classes: 79.25%, four classes: 68.51%
epileptic seizure detection	[58]	Gated Recurrent Unit RNN	BUD [58]	98%
epileptic seizure detection	[59]	Neuro-fuzzy	Local (EEG database - Bonn University) [59]	~90%
epileptic seizure detection	[60]	CNNs/ LSTM	TUH EEG Seizure Corpus [61]/ Duke University Seizure Corpus	sensitivity: 0.3083; specificity: 0.9686
Behavioral Disorder (RBD)	[62]	Echo State Networks (ESNs)	experimental, local dataset (118 subjects)	85%
Alzheimer disease detection	[63]	multiple convolutional-subsampling	experimental, local dataset	80%
depression screening	[64]	CNN	experimental, local dataset (patients with Mild Cognitive Impairment and healthy control group)	left hemisphere: 93.5% right hemisphere: 96%
autism	[65]	bispectrum transform, ST Fourier Transform (STFT)/STFT at a bandwidth of total spectrum (STFT-BW)	experimental, local dataset (10 autism patients and 7 control subjects)	82.4%

ŹRÓDŁA ZWIĄZANE Z KLASYFIKACJĄ SYGNAŁÓW EEG

- **Źródła w tabelach:**

[7] Gao, Z.; Wang, X.; Yang, Y.; Mu, C.; Cai, Q.; Dang, W.; Zuo, S. EEG-based spatio-temporal convolutional neural network for driver fatigue evaluation. *IEEE Trans. Neural Netw. Learn. Syst.* 2019, 30, 2755–2763. [46] Zhang, Y.; Zhou, G.; Jin, J.; Zhao, Q.; Wang, X.; Cichocki, A. Sparse Bayesian Classification of EEG for Brain–Computer Interface. *IEEE Trans. Neural Netw. Learn. Syst.* 2016, 27, 2256–2267.

[47] Jebelli, H.; Khalili, M.M.; Lee, S. Mobile EEG-based workers stress recognition by applying deep neural network. In *Advances in Informatics and Computing in Civil and Construction Engineering*; Springer: Berlin/Heidelberg, Germany, 2019; pp. 173–180.

[48] Moon, S.-E.; Jang, S.; Lee, J.-S. Convolutional neural network approach for EEG-based emotion recognition using brain connectivity and its spatial information. In *Proceedings of the 2018 IEEE (ICASSP)*, Calgary, AB, Canada, 15–20 April 2018; pp. 2556–2560.

[49] DEAP Dataset. <https://www.eecs.qmul.ac.uk/mmv/datasets/deap/> (accessed on 11 April 2020).

ŹRÓDŁA ZWIĄZANE Z KLASYFIKACJĄ SYGNAŁÓW EEG

Źródła w tabelach:

[50] Song, T.; Zheng, W.; Song, P.; Cui, Z. EEG emotion recognition using dynamical graph convolutional neural networks. *IEEE Trans. A_ect. Comput.* 2019, 1.

[51] SEED Dataset. BCMI Resources. Available online: <http://bcmi.sjtu.edu.cn/resource.html> (accessed on 11 April 2020).

[52] Attia, M.; Hettiarachchi, I.; Hossny, M.; Nahavandi, S. A time domain classification of steady-state visual evoked potentials using deep recurrent-convolutional neural networks. In *Proceedings of the 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, Washington, DC, USA, 4–7 April 2018; pp. 766–769.

[53] Katsigiannis, S.; Ramzan, N. DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals from Wireless Low-cost Of-the-Shelf Devices. *IEEE J. Biomed. Heal. Inform.* 2018, 22, 98–107.

[54] Mousavi, Z.; Rezaii, T.Y.; Sheykhivand, S.; Farzamnia, A.; Razavi, S. Deep convolutional neural network for classification of sleep stages from single-channel EEG signals. *J. Neurosci. Methods* 2019, 324, 108312.

ŹRÓDŁA ZWIĄZANE Z KLASYFIKACJĄ SYGNAŁÓW EEG

Źródła w tabelach:

[62] Rufni, G.; Ibanez, D.; Castellano, M.; Dunne, S.; Soria-Frisch, A. EEG-driven RNN classification for prognosis of neurodegeneration in at-risk patients. In Proceedings of the International Conference on Artificial Neural Networks, Barcelona, Spain, 6–9 September 2016; Springer: Berlin/Heidelberg, Germany, 2016; pp. 306–313.

[63] Morabito, F.C.; Campolo, M.; Ieracitano, C.; Ebadi, J.M.; Bonanno, L.; Bramanti, A.; Desalvo, S.; Mammone, N.; Bramanti, P. Deep convolutional neural networks for classification of mild cognitive impaired and Alzheimer's disease patients from scalp EEG recordings. In Proceedings of the 2016 IEEE 2nd International Forum on Research and Technologies for Society and Industry Leveraging a better tomorrow (RTSI), Bologna, Italy, 7–9 September 2016; pp. 1–6.

[64] Acharya, U.R.; Oh, S.L.; Hagiwara, Y.; Tan, J.H.; Adeli, H.; Subha, D.P. Automated eeg-based screening of depression using deep convolutional neural network. *Methods Programs Biomed.* 2018, 161, 103–113.

[65] Sheikhani, A.; Behnam, H.; Mohammadi, M.R.; Nooroziyan, M. Analysis of EEG background activity in Autism disease patients with bispectrum and STFT measure. In Proceedings of the 11th Conference on 11th WSEAS International Conference on Communications, Madrid, Spain, 22–23 August 2007; pp. 318–322.

MATERIAŁY ŹRÓDŁOWE

- **UPDRS: <https://www.parkinsons.org.uk/professionals/resources/mds-unified-parkinsons-disease-rating-scale-mds-updrs>**
- *FOG (freezing of gait)* <https://pubmed.ncbi.nlm.nih.gov/10817956/>
- Baga D., Fotiadis D.I., Konitsiotis S., Maziewski P., Greenlaw R., Chaloglou D., Arrendondo M.T., Robledo M.G., Pastor M.A.: **PERFORM: Personalised Disease Management for Chronic Neurodegenerative Diseases: The Parkinson's Disease and Amyotrophic lateral Sclerosis Cases**, eChallenges e-2009 Conf., 21-23 October 2009, Istanbul, Turkey.
- Greenlaw R., Robledo M.G., Estrada J.J., Pansera M., Konitsiotis S., Baga D., Maziewski P., Pastor M.A., Papasava A., Chaloglou D., Zanichelli F.: **PERFORM: Building and mining electronic records of neurological patients being monitored in the home**, World Congress on Medical Physics and Biomedical Engineering, 7-12 September 2009, Munich, Germany.
- Kostek, B., Kaszuba, K., Zwan, P. *et al.* Automatic assessment of the motor state of the Parkinson's disease patient--a case study. *Diagn Pathol* **7**, 18 (2012). <https://doi.org/10.1186/1746-1596-7-18>

MATERIAŁY ŹRÓDŁOWE

- Kostek, B., Kupryjanow, A.. (2013). WYKORZYSTANIE SIECI NEURONOWYCH I METODY WEKTORÓW NOŚNYCH SVM W PROCESIE ROZPOZNAWANIA AKTYWNOŚCI RUCHOWEJ PACJENTÓW DOTKNIĘTYCH CHOROBA PARKINSONA. *W : Inżynieria Biomedyczna Podstawy I Zastosowania*, 239-261.
- Browarczyk J, Kurowski A, Kostek B. Analyzing the Effectiveness of the Brain–Computer Interface for Task Discerning Based on Machine Learning. *Sensors*. 2020; 20(8):2403.
<https://doi.org/10.3390/s20082403>

Dziękuję

Bożena Kostek