

Autoreferat

1. Imię i nazwisko.

Stanisław Saganowski

2. Posiadane dyplomy, stopnie naukowe lub artystyczne – z podaniem podmiotu nadającego stopień, roku ich uzyskania oraz tytułu rozprawy doktorskiej.

- **Doktor nauk technicznych w dyscyplinie Informatyka**

Stopień naukowy nadany dnia 27 lutego 2018 roku decyzją Rady Wydziału Informatyki i Zarządzania Politechniki Wrocławskiej (Załącznik 2).

Tytuł rozprawy: Group Evolution Prediction in Social Networks

Promotor: prof. dr hab. inż. Przemysław Kazienko

Rozprawa obroniona z wyróżnieniem.

- **Master's degree in Computer Science**

Program Double Diploma na uczelni Blekinge Institute of Technology (Karlskrona, Szwecja). Kierunek: Computer Science.

- **Magister inżynier na kierunku Informatyka**

Studia magisterskie na Wydziale Informatyki i Zarządzania Politechniki Wrocławskiej. Kierunek: Informatyka, specjalność: Multimedialne systemy informatyczne.

Praca magisterska zajęła 3 miejsce w XXVIII edycji ogólnopolskiego konkursu na najlepsze prace magisterskie z informatyki organizowanego przez Polskie Towarzystwo Informatyczne.

3. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych lub artystycznych.

- **Politechnika Wroclawska, Wydział Informatyki i Telekomunikacji, 2012 –**

- **Adiunkt badawczo-dydaktyczny: 2018 –**

- Post-doc: marzec – wrzesień 2018
- Asystent badawczo-dydaktyczny: 2012 - 2017

4. Omówienie osiągnięć, o których mowa w art. 219 ust. 1 pkt. 2 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz. U. z 2021 r. poz. 478 z późn. zm.). Omówienie to winno dotyczyć merytorycznego ujęcia przedmiotowych osiągnięć, jak i w sposób precyzyjny określać indywidualny wkład w ich powstanie, w przypadku, gdy dane osiągnięcie jest dziełem współautorskim, z uwzględnieniem możliwości wskazywania dorobku z okresu całej kariery zawodowej.

4.1 Charakter i zawartość osiągnięcia naukowego

W ramach niniejszego wniosku habilitacyjnego prezentowane jest osiągnięcie będące cyklem powiązanych publikacji naukowych zatytułowanym:

“Metody i modele do rozpoznawania emocji w życiu codziennym”

W skład cyklu wchodzi **12 prac** opublikowanych w międzynarodowych czasopismach naukowych (każda posiada współczynnik *Impact Factor* oraz jest indeksowana na liście *Ministerstwa Edukacji i Nauki - MEiN*) oraz w recenzowanych materiałach konferencyjnych (każda posiada współczynnik *Core* oraz jest indeksowana na liście *MEiN*). Prace zostały uszeregowane chronologicznie. Do określenia wkładu zastosowałem taksonomię *CRedit*¹ zaproponowaną przez wydawnictwo Elsevier. **W niemal wszystkich pracach mój wkład był wiodący.**

W skład osiągnięcia wchodzi następujące prace:

[O1] S. Saganowski, A. Dutkowiak, A. Dziadek, M. Dzieżyc, J. Komoszyńska, W. Michalska, A.G. Polak, M. Ujma, P. Kazienko. (2020). Emotion recognition using wearables: A systematic literature review-work-in-progress. In 2020 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops, EmotionAware Workshop) (pp. 1-6). IEEE.

Core: A*

Liczba punktów MEiN: 200

¹ <https://www.elsevier.com/authors/policies-and-guidelines/credit-author-statement>

Liczba cytowań: 40/23/7²

Szacowany udział: 50%

Mój wkład: konceptualizacja, metodologia (wybór SLR, sformułowanie hipotezy oraz kryteriów), oprogramowanie (przygotowanie narzędzi do współpracy), analiza formalna (systematyzacja gromadzonej wiedzy), badanie (przegląd artykułów, sformułowanie wniosków), opracowanie danych (wybór i pobranie artykułów, formatowanie), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami), administracja (podział pracy, planowanie, proces zgłoszenia i recenzji).

Szacowany udział współautorów: A.D. 3%, A.D. 3%, M.D. 5%, J.K. 7%, W.M. 7%, A.P. 5%, M.U. 5%, P.K. 15%

[O2] M. Dzieżyc, M. Gjoreski, P. Kazienko, **S. Saganowski**, M. Gams. (2020). Can we ditch feature engineering? End-to-end deep learning for affect recognition from physiological sensor data. *Sensors*, 20(22), 6535.

Impact Factor: 3.847

Liczba punktów MEiN: 100

Liczba cytowań: 19/14/10

Szacowany udział: 15%

Mój wkład: konceptualizacja, metodologia, pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja (opracowanie rysunków i tabel), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami).

Szacowany udział współautorów: M.D. 40%, M.G. 30%, P.K. 5%, M.G. 10%

[O3] **S. Saganowski**, P. Kazienko, M. Dzieżyc, P. Jakimów, J. Komoszyńska, W. Michalska, A. Dutkowiak, A.G. Polak, A. Dziadek, M. Ujma. (2020). Consumer wearables and affective computing for wellbeing support. In

² Google Scholar / Scopus / Web of Science

MobiQuitous 2020-17th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services (pp. 482-487)

Core: A
Liczba punktów MEiN: 140
Liczba cytowań: 15/7/0
Szacowany udział: 60%

Mój wkład: konceptualizacja, metodologia (przeglądu urządzeń oraz modelu maszynowego), walidacja, analiza formalna (systematyzacja gromadzonej wiedzy), badanie (przegląd urządzeń, sformułowanie wniosków), zasoby (gromadzenie danych), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja (opracowanie rysunków i tabel), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami), administracja (podział pracy, planowanie, proces zgłoszenia i recenzji, prezentacja).

Szacowany udział współautorów: P.K. 10%, M.D. 1%, P.J. 5%, J.K. 5%, W.M. 5%, A.D. 5%, A.P. 5%, A.D. 2%, M.U. 2%

[O4] M. Dzieżyc, J. Komoszyńska, **S. Saganowski**, M. Boruch, J. Dziwiński, K. Jabłońska, D. Kunc, P. Kazienko. (2021). How to catch them all? Enhanced data collection for emotion recognition in the field. In 2021 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops, EmotionAware Workshop) (pp. 348-351). IEEE.

Core: A*
Liczba punktów MEiN: 200
Liczba cytowań: 8/6/6
Szacowany udział: 40%

Mój wkład: konceptualizacja, metodologia, oprogramowanie (tworzenie systemu), walidacja, analiza formalna, badanie, zasoby (gromadzenie danych), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja

(opracowanie rysunków i tabel), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami), administracja (podział pracy, planowanie).

Szacowany udział współautorów: M.D. 15%, J.K. 20%, M.B. 5%, J.D. 5%, K.J. 5%, D.K. 5%, P.K. 15%

[O5] S. Saganowski, B. Perz, A.G. Polak, P. Kazienko. (2022). Emotion Recognition for Everyday Life Using Physiological Signals From Wearables: A Systematic Literature Review. IEEE Transactions on Affective Computing. Doi: 10.1109/TAFFC.2022.3176135

Impact Factor: 13.990

Liczba punktów MEiN: 140

Liczba cytowań: 5/2/0

Szacowany udział: 60%

Mój wkład: konceptualizacja, metodologia (wybór SLR, sformułowanie hipotezy oraz kryteriów), oprogramowanie (przygotowanie narzędzi do współpracy), analiza formalna (systematyzacja gromadzonej wiedzy), badanie (przegląd artykułów, sformułowanie wniosków), opracowanie danych (wybór i pobranie artykułów, formatowanie), pisanie tekstu (szkie i wersja końcowa, przegląd, poprawki), wizualizacja (opracowanie tabel, pierwsza wersja rysunków), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami), administracja (podział pracy, planowanie, proces zgłoszenia i recenzji).

Szacowany udział współautorów: B.P. 20%, A.P. 5%, P.K. 15%

[O6] S. Saganowski, J. Komoszyńska, M. Behnke, B. Perz, D. Kunc, B. Klich, Ł.D. Kaczmarek, P. Kazienko. (2022). Emognition dataset: emotion recognition with self-reports, facial expressions, and physiology using wearables. Scientific Data, 9(1), 1-11.

Impact Factor: 8.501

Liczba punktów MEiN: 140

Liczba cytowań: 2/2/2

Szacowany udział: 45%

Mój wkład: konceptualizacja, metodologia (opracowanie planu badania laboratoryjnego, w tym procedur, urządzeń i systemu), walidacja, analiza formalna (analizy sygnału i statystyczne), badanie (kierowanie badaniem laboratoryjnym), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja (opracowanie tabel i części rysunków), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami), administracja (podział pracy, planowanie, proces zgłoszenia i recenzji).

Szacowany udział współautorów: J.K. 15%, M.B. 15%, B.P. 8%, D.K. 5%, B.K. 2%, Ł.K. 5%, P.K. 5%

[O7] **S. Saganowski**. (2022). Bringing Emotion Recognition Out of the Lab into Real Life: Recent Advances in Sensors and Machine Learning. *Electronics*, 11(3), 496.

Impact Factor: 2.690

Liczba punktów MEiN: 100

Liczba cytowań: 11/8/7

Szacowany udział: 100%

[O8] **S. Saganowski**, D. Kunc, B. Perz, J. Komoszyńska, M. Behnke, P. Kazienko. (2022). The cold start problem and per-group personalization in real-life emotion recognition with wearables. In 2022 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops, WristSense Workshop) (pp. 812-817). IEEE. **Best Paper Award**.

Core: A*

Liczba punktów MEiN: 200

Liczba cytowań: 3/2/0

Szacowany udział: 45%

Mój wkład: konceptualizacja, metodologia (opracowanie scenariuszy), analiza formalna (analiza statystyczna), zasoby (pozyskanie danych), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja (opracowanie tabel i rysunków), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami), administracja (podział pracy, planowanie, proces zgłoszenia i recenzji, prezentacja).

Szacowany udział współautorów: D.K. 15%, B.P. 15%, J.K. 15%, M.B. 5%, P.K. 5%

- [O9] P. Miłkowski, **S. Saganowski**, M. Gruza, P. Kazienko, M. Piasecki, J. Kocoń. (2022). Multitask Personalized Recognition of Emotions Evoked by Textual Content. In 2022 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops, EmotionAware Workshop) (pp. 347-352). IEEE.

Core:	A*
Liczba punktów MEiN:	200
Liczba cytowań:	2/1/0
Szacowany udział:	30%

Mój wkład: metodologia (wielozadaniowość), walidacja, analiza formalna, pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja (opracowanie tabel i rysunku 2).

Szacowany udział współautorów: P.M. 30%, M.G. 3%, P.K. 4%, M.P. 3%, J.K. 30%

- [O10] A.G. Polak, B. Klich, **S. Saganowski**, M.A. Prucnal, P. Kazienko. (2022). Processing Photoplethysmograms Recorded by Smartwatches to Improve the Quality of Derived Pulse Rate Variability. *Sensors*, 22(18), 7047.

Impact Factor:	3.847
Liczba punktów MEiN:	100
Liczba cytowań:	0/0/0

Szacowany udział: 20%

Mój wkład: konceptualizacja, zasoby (pozyskanie danych), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami), administracja (podział pracy, planowanie).

Szacowany udział współautorów: A.P. 30%, B.K. 30%, M.P. 15%, P.K. 5%

[O11] M. Behnke, **S. Saganowski**, D. Kunc, P. Kazienko. (2022). Ethical Considerations and Checklist for Affective Research with Wearables. IEEE Transactions on Affective Computing. Doi: 10.1109/TAFFC.2022.3222524

Impact Factor: 13.990

Liczba punktów MEiN: 140

Liczba cytowań: 0/0/0

Szacowany udział: 30%

Mój wkład: konceptualizacja, metodologia (proces ankietyzacji), walidacja, analiza formalna, badanie (opracowanie ryzyk, rekomendacji i listy kontrolnej), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja (opracowanie tabel), zarządzanie (kierowanie pracami badawczymi, nadzór nad pracą i wynikami).

Szacowany udział współautorów: M.B. 35%, D.K. 30%, P.K. 5%

[O12] **S. Saganowski**, J. Miszczyk, D. Kunc, D. Lisouski, P. Kazienko. (2022) Lessons Learned from Developing Emotion Recognition System for Everyday Life. In 5th International SenSys+BuildSys Workshop on Data: Acquisition To Analysis (DATA) (DATA '22). W publikacji.

Core: A*

Liczba punktów MEiN: 200

Liczba cytowań: 0/0/0

Szacowany udział: 45%

Mój wkład: konceptualizacja, metodologia (nakreślenie przekazu artykułu, wytyczanie ścieżki rozwoju systemu), walidacja, badanie (kierowanie pracami nad systemem, nadzór nad wynikami), pisanie tekstu (szkic i wersja końcowa, przegląd, poprawki), zarządzanie (nadzór nad pracą i wynikami), administracja (podział pracy, planowanie, proces zgłoszenia i recenzji).

Szacowany udział współautorów: D.K. 20%, J.M. 20%, D.L. 10%, P.K. 5%

Tabela 1: Wskaźniki bibliometryczne publikacji wchodzących w skład osiągnięcia naukowego.

Łączna liczba publikacji w cyklu	12
Liczba publikacji czasopismowych	6
Liczba publikacji konferencyjnych	6
Suma współczynnika Impact Factor	46.865
Suma punktów MEiN	1860
Liczba cytowań (Google Scholar / Scopus / WoS)	105/65/32
Liczba cytowań bez autocytowań (Scopus / WoS)	35/18

4.2 Droga naukowa prowadząca do osiągnięcia naukowego

Moje badania naukowe w ramach pracy magisterskiej oraz przewodu doktorskiego koncentrowały się na analizie sieci społecznościowych, w szczególności na analizie ewolucji grup. Zaproponowałem nowatorskie metody do śledzenia (metoda GED) [Bró13] oraz predykcji (metoda GEP) [Sag15, **PO15**] ewolucji grup w sieciach społecznościowych. Metody są szeroko stosowane i cytowane – niemal 500 cytowań moich artykułów związanych z metodami, z czego ponad 200 cytowań dla pracy [Bró13]. Według przeglądu porównawczego [Hel7b] metody te należą do najlepszych w dziedzinie.

Po uzyskaniu stopnia naukowego doktora postanowiłem zmienić kierunek badań i zająłem się informatyką afektywną, szczególnie rozpoznawaniem emocji z fizjologii. Była to istotna zmiana wymagająca poznania nowej dziedziny – możliwości, aktualnych trendów, narzędzi, problemów, najważniejszych konferencji

i czasopism, a także zdobycia wiedzy interdyscyplinarnej. Wymagało to czasu oraz dużego dodatkowego zaangażowania. Aby zapewnić najwyższą jakość prowadzonych badań, pracowałem także nad nawiązaniem współpracy z wiodącymi naukowcami i zespołami w dziedzinie. Mimo niesprzyjających okoliczności (w latach 2019-2021 konferencje odbywały się wirtualnie a podróże służbowe były zawieszono) udało się nawiązać i rozpocząć współpracę z wiodącymi naukowcami i zespołami (sekcja 4.7.4).

4.3 Wprowadzenie i umotywowanie prac badawczych

W niniejszej sekcji pokrótce podsumowuję stan wiedzy w obszarze, którego dotyczy przedłożone osiągnięcie naukowe, aby umiejscowić je pośród zagadnień problemowych. Aby odróżnić znaczenie słowa “badania” w rozumieniu badań naukowych (ang. research) od czynności oznaczającej prowadzenie eksperymentu z udziałem ludzi (w języku polskim określanej jako badanie – ang. study), będę stosował terminologię “badania” mając na myśli badania naukowe, oraz “eksperyment” mając na myśli badanie z udziałem ludzi.

Informatyka afektywna

Informatyka afektywna to stosunkowo nowa, ale szybko rozwijająca się dziedzina badawcza łącząca informatykę z psychologią, biologią i kognitywistyką [Pic00]. Zajmuje się tworzeniem metod oraz narzędzi do rozpoznawania, analizy, interpretacji i symulacji stanów afektywnych, często w kontekście interakcji człowieka z komputerem (lub robotem lub smart-urządzeniem lub innym urządzeniem elektronicznym). Badania w obszarze informatyki afektywnej początkowo koncentrowały się na rozpoznawaniu emocji na podstawie wizualnego przetwarzania mimiki twarzy [KO58]. Innym popularnym kierunkiem badań było rozpoznawanie emocji z mowy [Kha19]. Wreszcie aspektem, który ostatnio staje się coraz popularniejszy, jest analiza stanów afektywnych z sygnałów fizjologicznych, np. aktywność fal mózgowych (elektroencefalografia – ang. electroencephalography, EEG) [Suh20], elektryczna aktywność układu sercowego (elektrokardiografia – ang. electrocardiography, ECG) [Nik18], optyczna aktywność układu sercowego (fotopletyzmografia – ang. photoplethysmography, PPG) [Dze20], reakcja elektrodermalna skóry (ang. electrodermal activity, EDA) [Dze20].

W swoich badaniach skupiam się na rozpoznawaniu emocji z sygnałów fizjologicznych, ponieważ dzisiejsza technologia pozwala na bezinwazyjne monitorowanie fizjologii w niemal każdych warunkach. Natomiast rozpoznawanie emocji z twarzy lub głosu jest ograniczone – m.in. wymaga widocznej twarzy lub emisji głosu [O7]. Osobie także łatwiej jest świadomie kontrolować mimikę twarzy i głos niż reakcje fizjologiczne.

Zastosowania

Rozpoznawanie emocji staje się bardzo ważnym kierunkiem naukowym, z licznymi zastosowaniami w życiu codziennym. Korporacje technologiczne rozbudowują swoje produkty o moduły rozpoznawania emocji, aby oferować lepszą jakość usług [Pan21, Ber19]. Gdy komputer rozumie emocje użytkownika możliwa jest lepsza interakcja i użyteczność [Set18], a wirtualni asystenci mogą lepiej reagować na potrzeby użytkownika [Nal19]. Interfejs, oferowane treści, rekomendacje wyników wyszukiwania, a także gry komputerowe, mogą być wzbogacone o kontekst emocjonalny użytkownika [Lis04, Lis06, Tka18, Nal19]. Wszechobecne wykrywanie emocji może pomóc w monitorowaniu naszego samopoczucia [Fer19, Hu18]. Ponadto rozpoznawanie emocji może pomóc w kontroli stresu, m.in. w celu zmniejszenia prawdopodobieństwa chorób układu krążenia [Sch18a]. Konteksty terapeutyczne zaproponowano w [Fen18, Pol17], gdzie dzieci z autyzmem można by nauczyć lepszego rozumienia swoich emocji. Rozpoznawanie afektu jest również proponowane jako kompleksowe narzędzie pomocy osobom z zaburzeniami związanymi z emocjami [He17a]. Inne zastosowania obejmują, np.: wykrywanie senności kierowcy i określenie obciążenia poznawczego [Nak18], dostosowywanie trudności treści lekcji [Mai19], czy wyrażania emocji za pomocą muzyki [Lu19].

Modele emocji

Powszechnie stosowane w nauce modele emocji zostały opracowane przez psychologów. Ich typowa taksonomia wyróżnia modele kategoryczne i wymiarowe, m.in. bardzo popularny 2-wymiarowy model pobudzenie–walencja (ang. arousal–valence). Do klasycznych modeli kategorycznych zaliczamy modele Friesena i Ekmana [Fri78] czy Plutchika [Plu80, Plu03]. Jednak psychologowie nadal nie są zgodni co do liczby podstawowych emocji [Ekm11, Sca11]. Obecnie Ekman wyróżnia kilkanaście podstawowych emocji [Ekm11]. Z kolei psychologowie z Berkley - Cowen i Keltner

w ostatnich latach w swoich wielkoskalowych badaniach identyfikowali od 13 do 27 różnych emocji w odpowiedzi na bodźce płynące z oglądania krótkich filmików i sztuki, słuchania muzyki lub różnych wyrazów twarzy [Cow17, Cow19, Cow20, Cow21].

Warto odnotować, że do tej pory nie powstał żaden model emocjonalny wykorzystujący fizjologię. Natomiast w ramach projektu finansowanego ze środków NCN, którego jestem współautorem i wykonawcą, powstanie pierwszy model emocjonalny oparty na fizjologii (prace nad modelem przewidziane są na drugą połowę 2023 roku). Prof. Keltner (University of Berkeley, CA, Stany Zjednoczone) wyraził gotowość konsultacji wyników uzyskanych z mapowania fizjologicznego modelu emocji.

Emocje i fizjologia

Główną motywacją rozpoznawania emocji na podstawie sygnałów fizjologicznych są naturalne, biologiczne korzenie emocji [Bar06]. Schlosberg już w 1954 stwierdził, że przewodnictwo elektryczne skóry jest dobrą miarą stopnia pobudzenia emocjonalnego [Sch54]. Levenson i in. w 1990 roku wykazali, że reakcja autonomicznego układu nerwowego (ANS) na dobrowolnie wywołaną emocję może być obserwowana za pomocą sygnałów fizjologicznych [Lev90]. W szczególności odkryli pewne powiązania między sześcioma podstawowymi emocjami a tętnem, temperaturą palców i przewodnictwem skóry. Uważali, że wynika to ze specyfiki funkcjonalnej ANS. W kolejnej pracy Levenson omawia ewolucyjne/funkcjonalistyczne teorie, w których emocje organizują aktywność autonomicznego układu nerwowego (ANS) i innych układów fizjologicznych [Lev14]. Kreibig dokonała przeglądu 134 publikacji, które opisują eksperymentalne badania wpływu emocjonalnego na obwodową odpowiedź fizjologiczną [Kre10]. Z jej analizy, wynika, że aż 16 odrębnych emocji jest skorelowanych z różnymi komponentami ANS [Kre10; Tab. 2]. Jednak nie przeprowadzono ani jednego eksperymentu (badania z udziałem ludzi), w którym analizowano by wszystkie 16 emocji jednocześnie. Co najwyżej siedem różnych kategorycznych emocji było rozważanych w problemie klasyfikacji wieloklasowej. Ponadto, wszystkie eksperymenty przeprowadzono w środowisku laboratoryjnym (niektóre imitowały warunki rzeczywiste), gdzie zakres emocji i kontekst ich występowania jest mniej bogaty niż w prawdziwym życiu.

Eksperymenty w życiu codziennym

Niedawny przegląd [Lar20] przedstawia wiele zalet danych zebranych w naturalnych warunkach. Są to między innymi (1) bardziej intensywne emocje; (2) naturalny kontekst emocji, bez obecności eksperymentatora i ograniczeń występujących w laboratorium; (3) możliwość długofalowego zbierania (dużej) ilości danych. Niestety z uwagi na trudność prowadzenia eksperymentów poza laboratorium, takich eksperymentów jest bardzo niewiele. Przegląd [Lar20] wskazuje jedynie siedem eksperymentów, które zostały przeprowadzone w życiu codziennym lub w warunkach symulujących życie codzienne do roku 2020. Tylko trzy eksperymenty były przeprowadzone na większej liczbie osób (było to 11, 19 oraz 40 osób). Żadna z prac opisujących eksperymenty nie oferuje dostępu do zebranego zbioru danych. W systematycznym przeglądzie literatury [O5], obejmującym prace opublikowane do marca 2021 roku, wskazuję jedynie cztery eksperymenty, które zostały przeprowadzone w pełni w życiu codziennym, z wykorzystaniem urządzeń wearables, i obejmowały więcej niż pięć osób. Są to: [Exl16, Ngu17, Sch19a, Kad20]. Żadna z prac nie oferuje dostępu do danych. Z kolei w pracy [O7] pokazuję, że technologia (sensory, metody przetwarzania sygnałów, architektury do głębokiego uczenia) jest gotowa na to, aby wykonywać eksperymenty w życiu codziennym. Właśnie dlatego **swoje badania koncentruję na rozpoznawaniu emocji z fizjologii w życiu codziennym [O1, O3, O4, O5, O7, O8, O10, O11, O12, PO13, PO14].**

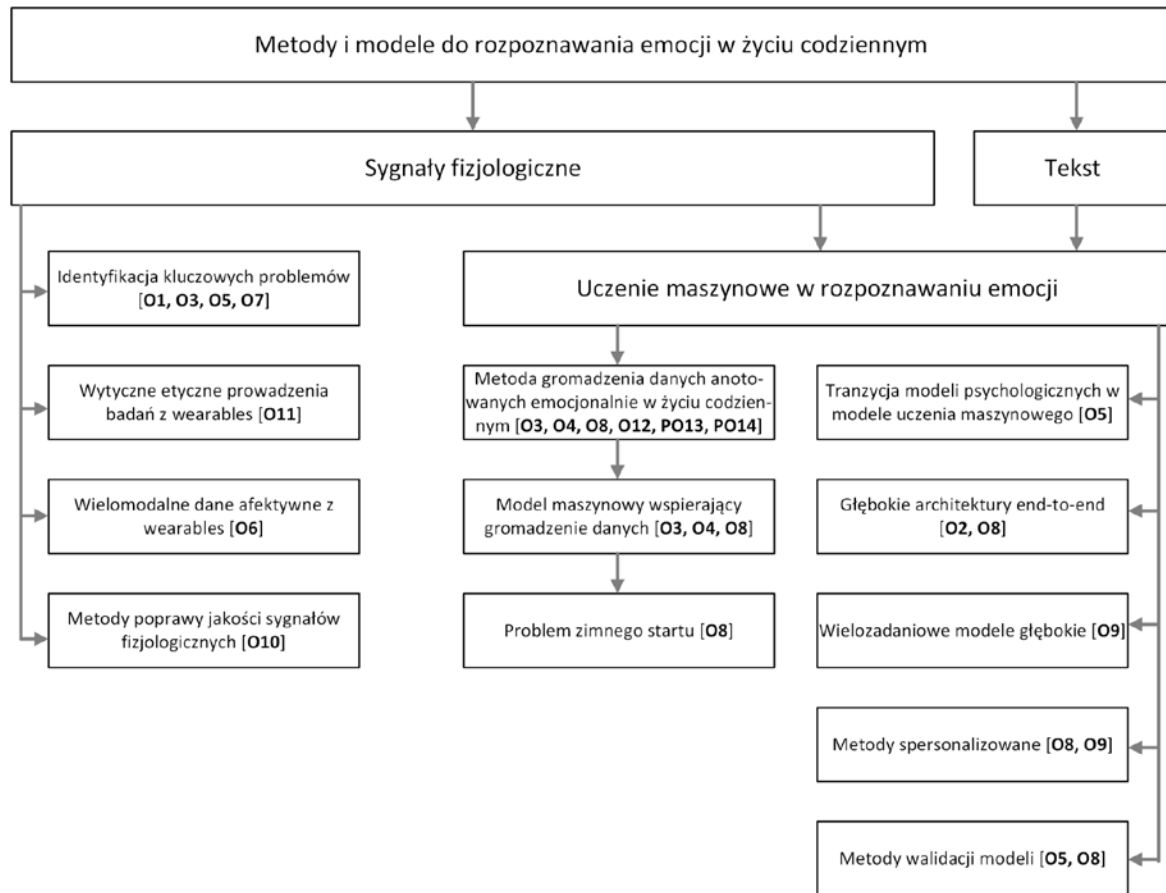
4.4 Cel prac badawczych związanych z osiągnięciem naukowym

Celem ogólnym prac badawczych nawiązujących do problemów przedstawionych w poprzednim punkcie było **opracowanie metod i modeli uczenia maszynowego służących do (1) rozpoznawania emocji w życiu codziennym z sygnałów fizjologicznych zgromadzonych za pomocą urządzeń do noszenia oraz (2) predykcji emocjonalnej percepcji tekstu.** Aby zrealizować cel ogólny zdefiniowałem następujące cele szczegółowe:

[C1] Zidentyfikowanie problemów w rozpoznawaniu emocji w życiu codziennym z sygnałów fizjologicznych, oraz krytyczna analiza istniejących rozwiązań.

- [C2] Opracowanie koncepcji, metod i technologicznych rozwiązań służących rozpoznawaniu emocji w życiu codziennym z sygnałów fizjologicznych z wykorzystaniem uczenia maszynowego.
- [C3] Opracowanie i analiza modelu uczenia maszynowego służącego do efektywniejszego gromadzenia danych anotowanych emocjami.
- [C4] Analiza problemu “zimnego startu” (problem zidentyfikowany w [C3] na początku eksperymentu) i jego rozwiązanie za pomocą odpowiedniego modelu uczenia maszynowego.
- [C5] Analiza personalizacji modelu maszynowego do rozpoznawania emocji.
- [C6] Analiza zastosowania głębokich metod uczenia maszynowego end-to-end do predykcji afektu w porównaniu do metod bazujących na wyodrębnionych cechach.
- [C7] Opracowanie metody poprawy jakości sygnałów fizjologicznych poprzez usunięcie zakłóceń o wysokiej częstotliwości, co ma istotne znaczenie dla jakości modeli wnioskujących.
- [C8] Zaplanowanie i zgromadzenie danych anotowanych emocjami w warunkach laboratoryjnych i w życiu codziennym ze wsparciem modeli uczenia maszynowego dostosowanych do działania na urządzeniach mobilnych.
- [C9] Opracowanie zasad etycznych chroniących uczestników eksperymentów oraz poprawiających jakość zbieranych danych dotyczących rozpoznawania emocji z sygnałów fizjologicznych, w tym także zasad związanych z modelami wnioskującymi.

4.5 Opis uzyskanych wyników oraz ich istotności/przydatności dla zdefiniowanych celów



Rysunek 1: Zagadnienia zrealizowane w osiągnięciu naukowym.

Identyfikacja kluczowych problemów

W latach 2019-2021 przeprowadziłem analizę korzystając z metodyki systematycznego przeglądu literatury w poszukiwaniu eksperymentów związanych z rozpoznawaniem emocji, w których wykorzystano urządzenia do noszenia (wearables). Celem przeglądu była odpowiedź na pytanie: czy rozpoznawanie emocji w życiu codziennym jest możliwe? Przegląd objął ponad 3000 prac naukowych, z których jedynie 34 wykorzystywało wearables oraz spełniło kryteria kwalifikujące je do dalszej analizy. Wyniki przeglądu zostały przedstawione w dwóch publikacjach – [O1] zawiera pierwszą wersję przeglądu i analizy, natomiast [O5] zawiera końcowe, znacznie obszerniejsze wyniki, krytyczne obserwacje i rozważania. W 2020 dokonałem także przeglądu urządzeń dostępnych na rynku, które mogą być wykorzystane w eksperymentach związanych z emocjami, stresem, jakością snu, medytacją lub

aktywnością fizyczną [O3]. Pod koniec roku 2021 powyższe przeglądy uzupełniłem o wskazanie sensorów, metod przetwarzania sygnałów oraz metod głębokiego uczenia, które pomagają w prowadzeniu eksperymentów w życiu codziennym [O7]. Wskazałem także kierunki badań kluczowe dla tego obszaru w nadchodzących latach.

Na podstawie przeprowadzonych przeglądów [O1, O3, O5, O7] zidentyfikowałem kluczowe problemy i wyzwania w temacie rozpoznawania emocji na podstawie sygnałów fizjologicznych w życiu codziennym.

Problemy bezpośrednio związane z uczeniem maszynowym:

- Badania nad rozpoznawaniem emocji są wciąż rzadko prowadzone z wykorzystaniem najnowszych modeli głębokiego uczenia. Jak wynika z przeglądu [O5] jedynie około 15% prac stosuje sieci neuronowe – około połowę stanowią wariacje architektury *Long Short-Term Memory* (LSTM), a resztę inne architektury głębokie. Nieliczne prace stosują mechanizm uwagi lub wstecznej propagacji [O5, O7].
- W większości (51%) badań rozważa się binarną klasyfikację lub proste modele klasyfikacji (np. *Support-Vector Machine* – SVM – 33%, *Linear Discriminant Analysis* – LDA – 7%). W zaledwie 19% badań wykorzystano więcej niż jeden model [O5].
- Jedynie około 7% prac w jakikolwiek sposób rozważa problem niezbalansowania klas, podczas gdy zjawisko to występuje w danych afektywnych bardzo często – na ogół ludzie znajdują się w stanie neutralnym, a silne emocje występują sporadycznie [O5, O7].
- W bardzo niewielu badaniach brano pod uwagę dostosowanie modelu klasyfikacyjnego i szerszą walidację: optymalizację hiper-parametrów (7%), konfigurację modeli (11%), selekcję cech (7%), walidację przez psychologów (7%), testy statystyczne (15%). W procesie walidacji zwykle nie analizuje się zdolności generalizujących i personalizujących modelu [O5].
- Tylko nieliczne prace badają temat personalizacji modeli wnioskujących [Kan19, Sch19a, Tay20, Tiz20], podczas gdy postrzeganie i przeżywanie emocji są bardzo subiektywnym i indywidualnym odczuciem. Co więcej, ludzie bardzo

różnią się od siebie pod kątem fizjologii, np. wartości tętna spoczynkowego [O1, O5, O7].

- Badania nad rozpoznawaniem emocji wykorzystują zwykle dane z niewielkiej próbki populacji – zazwyczaj około 30-40 osób [O5]. Niewielka ilość danych uniemożliwia efektywne uczenie głębokich modeli maszynowych oraz generalizację modeli.

Problemy pośrednio związane z uczeniem maszynowym:

- Absolutnie podstawową i oczywistą kwestią jest znacząca różnica między rozpoznawaniem emocji w warunkach laboratoryjnych i w warunkach naturalnych (w życiu codziennym). Niestety wielu naukowców oraz firm zdaje się ignorować tę różnicę i wdrażają do codziennego użytku rozwiązania opracowane z wykorzystaniem danych zebranych w laboratorium. Przekładając to na reguły tworzenia i wykorzystania modeli uczenia maszynowego – modele są uczone na danych spoza domeny, a następnie bez żadnego dostosowania stosowane w domenie. Mam nadzieję, że poprzez wyraźne wskazanie różnic pomiędzy tymi środowiskami (laboratorium i życie codzienne) [O5, Tab. 2] oraz szeroką dyskusję [O1, O5, O7], podniosę świadomość w tym aspekcie przynajmniej w środowisku naukowym.
- Bardzo niewiele eksperymentów jest wykonywanych w życiu codziennym. Do roku 2021 było to zaledwie kilka eksperymentów [Ex116, Ngu17, Sch19a, Kad20]. Zdecydowana większość eksperymentów odbywa się w ściśle kontrolowanych warunkach laboratoryjnych, uniemożliwiających przeniesienie opracowanych modeli do życia codziennego [O5]. W efekcie praktycznie nie istnieją zbiory danych zgromadzone w życiu codziennym. Jedyne dostępne zbiory to [Shu21], jednak sposób anotacji zdarzeń emocjonalnych wydaje się mało efektywny – uczestnicy każdego wieczoru mają przypomnieć sobie emocjonujące zdarzenia z danego dnia i ocenić je korzystając z formularza. Z kolei dostępne zbiory danych zgromadzone w warunkach laboratoryjnych często charakteryzują się małą intensywnością odczuwanych emocji oraz niewielką liczbą uczestników [O5, O7]. Taki stan rzeczy wpływa negatywnie na możliwość tworzenia zaawansowanych głębokich modeli maszynowego uczenia.

- Brak powszechnie przyjętego modelu emocji – 55% badań wykorzystywało własne modele emocjonalne. Często modele wymiarowe upraszczano do modeli kategoriowych (i stosowano klasyfikację binarną lub wieloklasową). Brakuje badań stosujących klasyfikację lub regresję z wieloma etykietami. Dotąd nie zaproponowano modelu emocjonalnego dedykowanego sygnałom fizjologicznym [O1, O5, O7].
- Jakość sygnału zależy od urządzenia i czujników: częstotliwości próbkowania, odporności na wstrząsy, odpowiedniego przylegania do ciała. Urządzenia do noszenia (wearables) są bardzo podatne na zakłócenia związane z ruchem użytkownika [O1, O3, O5, O7]. Niska jakość sygnału negatywnie wpływa na uczenie modeli maszynowych, ponieważ wprowadza szum do danych uczących, co może wpływać na zdolność modelu do rozróżniania klas.
- Sygnały fizjologiczne są anotowane wartościami afektywnymi poprzez proces samooceny osób badanych. Proces ten jest bardzo subiektywny, podatny na wpływ kultury i języka (czy różnica między “fascynacją” a “zachwytem” jest taka sama dla wszystkich?), a także zdeterminowany przez wykorzystywany model emocjonalny [O5, O7]. Bez zastosowania odpowiednich technik personalizacji, modele maszynowe nie będą w stanie uwzględnić subiektywnej anotacji danych.
- Analiza przeżywanych emocji zwykle pomija treść bodźców oraz szerszy kontekst zdarzenia [O1, O5].
- Brak powtarzalności badań naukowych: dane lub kod źródłowy opublikowano w zaledwie 5% artykułów [O5, O7].
- Zgoda komisji etycznej była uzyskana tylko w 19% analizowanych eksperymentów [O5].

Spośród zidentyfikowanych problemów, w mojej ocenie największy potencjał dla rozwoju dziedziny mają: (1) przeprowadzenie eksperymentów w życiu codziennym i zgromadzenie dużej ilości danych [PO13], oraz (2) utworzenie nienadzorowanych modeli emocjonalnych opartych o fizjologię. Oba te zagadnienia są przeze mnie aktualnie realizowane w ramach badań prowadzonych na uczelni University of Southern California (wyjazd naukowy finansowany przez Narodową Agencję Wymiany

Akademickiej, program im. Bekkera) oraz w ramach realizacji projektu badawczego pt. “Informatyka afektywna: głębokie uczenie w rozpoznawaniu emocji z sygnałów fizjologicznych” finansowanego przez Narodowe Centrum Nauki, program Opus (2020-24).

Prace [O1, O3, O5, O7] realizują cel szczegółowy [C1]. Usystematyzowanie wiedzy oraz identyfikacja kluczowych problemów w dziedzinie było bardzo istotne, ponieważ krytycznie oraz syntetycznie ujmuje aktualny stan wiedzy w obszarze, wskazując na możliwości istniejących metod i narzędzi, oraz wyznaczając potencjalne obiecujące kierunki badań. Ponadto, w pracach [O5] i [O7] przedstawiłem postulaty adresujące wiele z powyższych problemów, co bezpośrednio przyczynia się do rozwoju dziedziny:

- analiza wieloetykietowego podejścia do klasyfikacji emocji (rozważenie współwystępowania emocji);
- dalsza analiza nad generalizacją i personalizacją modeli maszynowych;
- opracowanie zasad i danych umożliwiających porównanie różnych metod (ang. benchmark);
- stosowanie standardowych metod walidacji, np. leave-one-subject-out (LOSO);
- stosowanie standardowych miar jakości, np. F-miara, ROC AUC, dokładność;
- stosowanie wspólnych modeli emocji, np. Ekman-Friesen [Fri78], Plutchik [Plu80], model wymiarowy pobudzenie–walencja;
- publikowanie danych i kodów źródłowych pozwalających na replikację badań;
- opracowanie metod pomiaru fizjologii, odpornych na zakłócenia wynikające z ruchu;
- opracowanie procedury walidacji jakości pomiaru fizjologii przez sensory.

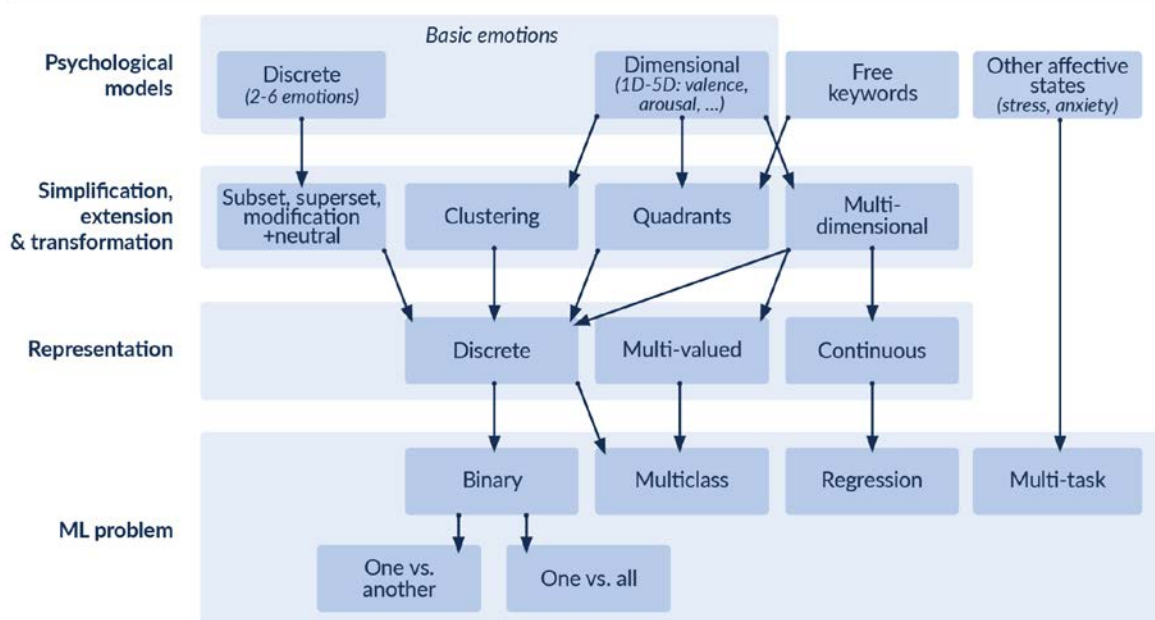
Tranzycja modeli psychologicznych w modele uczenia maszynowego

Prowadząc badania nad rozpoznawaniem emocji naukowcy zazwyczaj wybierają jeden z popularnych psychologicznych modeli emocji. Modele te zazwyczaj opisują skomplikowane relacje między różnymi emocjami, np. w trójwymiarowym diagramie Plutchik’a wymiar pionowy reprezentuje intensywność emocji, a koło poziome reprezentuje stopień podobieństwa emocji; emocje przeciwległe na kole są z kolei emocjami przeciwnymi. W oparciu o wybrany psychologiczny model emocji tworzone są ankiety samooceny, które wypełniają uczestnicy eksperymentów,

dostarczając tym samym anotowanych danych (ground truth). Dane te służą do uczenia modeli maszynowych i wnioskowania. Niestety pomiędzy wyborem psychologicznego modelu emocji a sformułowaniem problemu wnioskowania bardzo często następuje uproszczenie problemu prowadzące do utraty informacji, zwłaszcza zależności między emocjami. Przykładowo modele wielowymiarowe są często konwertowane na wartości dyskretne, np. za pomocą kwadrantów, które później są traktowane jako cztery niezależne klasy.

Zjawisko upraszczania modeli omawiam w pracy [O5], wskazując jak poważny i częsty jest to problem (Rysunek 2). W tejże pracy proponuję, aby psychologiczne modele wielowymiarowe prowadziły do problemu klasyfikacji wieloetykietowej (który praktycznie nie występuje w dotychczasowych badaniach nad emocjami). Prawdopodobnie jest to związane z potrzebą zgromadzenia znacznie obszerniejszego zbioru do uczenia. Z kolei psychologiczne modele dyskretne powinny prowadzić do problemu wieloklasowego lub wielozadaniowego, a nie do pojedynczych problemów binarnych/regresyjnych.

Transition of psychological models to ML problems



Rysunek 2: Tranzycja (upraszczanie) modeli psychologicznych w modele uczenia maszynowego. Źródło: [O5].

Zysk z zastosowania podejścia wielozadaniowego zaprezentowałem w pracy [O9]. W pracy porównuję trzy podejścia do predykcji wartości ośmiu emocji (czterech

pozytywnych – antycypacja, radość, zaskoczenie, zaufanie; i czterech negatywnych – obrzydzenie, smutek, strach, złość) oraz pobudzenia i walencji w odpowiedzi na konsumowaną treść tekstową (opinie i komentarze). Podejście jednozadaniowe zakłada, że wartości dla każdej emocji (skala 0-4), pobudzenia (skala 0-4) i walencji (skala od -3 do +3) są predykowane osobno. W podejściu częściowo wielozadaniowym, wartości są predykowane w grupach: emocje pozytywne (4 zadania), emocje negatywne (4 zadania), pobudzenie i walencja (2 zadania). Z kolei w podejściu wielozadaniowym wartości wszystkich emocji i obu wymiarów afektu są predykowane jednocześnie (10 zadań). Badania wykazały, że łączenie uczenia zadań w jednym modelu poprawia jakość predykcji. Podejście częściowo wielozadaniowe uzyskało średnio 4% – 6% poprawy (w zależności od modelu reprezentacji tekstu), a wielozadaniowe średnio 13% – 15% poprawy w odniesieniu do podejścia jednozadaniowego. Najbardziej prawdopodobną przyczyną istotnej poprawy jakości było wykorzystanie przez model maszynowy relacji między emocjami a walencją i pobudzeniem.

Powyższe badania są przydatne dla dziedziny, ponieważ ukazują zalety stosowania podejścia wielozadaniowego. Takie rozwiązanie można zastosować do większości badań związanych z afektem, ponieważ klasy/wymiary (zadania) w modelach dyskretnych/wielowymiarowych są bardzo często zależne lub wręcz skorelowane.

Metoda gromadzenia danych anotowanych afektem w życiu codziennym

Istniejące metody gromadzenia danych anotowanych afektem w życiu codziennym bazują najczęściej na wykorzystaniu samooceny generowanej w losowym momencie (ang. Ecological Momentary Assessment – EMA, lub także Experience Sampling Methods – ESM) [Sch18b]. Proponowano także wykorzystanie: (1) informacji zapisanych w kalendarzu (wydarzenia), (2) zdarzeń, które można rejestrować, np. otrzymana wiadomość SMS lub odebrany telefon, (3) cyklicznej samooceny, np. co godzinę, oraz (4) samooceny wywołanej przez uczestnika eksperymentu [Ex116]. Jednak metody te dostarczają niewielkiej ilości danych, a zebrane zdarzenia emocjonalne cechują się niską intensywnością [Sch18b, Shu21].

Aby rozwiązać ten problem, swoje badania skupiłem m.in. na opracowaniu metody do zbierania danych, bazującej na modelu uczenia maszynowego wykrywającym przeżywanie intensywnych emocji. Główne założenia metody zostały

zaprezentowane w pracy [O3]. Urządzenia do noszenia, np. smart-zegarek lub opaska na klatkę piersiową, rejestrują sygnały fizjologiczne (ECG, PPG, EDA, akcelerometr – ACC) osoby badanej, i poprzez technologię Bluetooth przesyłają je na smartfona w paczkach danych zawierających dwie minuty sygnałów. Na smartfonie sygnały są filtrowane, a następnie przetwarzane w celu obliczenia sygnałów pochodnych (np. tętno, ang. heart rate – HR) oraz ekstrakcji cech. Obliczone cechy są wejściem do modelu uczenia maszynowego (osadzonego na smartfonie), który w czasie rzeczywistym dokonuje wnioskowania czy w przesłanym oknie czasowym osoba doświadczyła intensywnej emocji. Jeżeli tak, generowana jest ankieta samooceny w celu anotacji próbki przez osobę badaną. Uczestnik eksperymentu może wypełnić ankietę w dowolnym momencie, jednak nie później niż w ciągu 15 minut od jej wygenerowania. Ma to zapewnić, że ankieta zostanie wypełniona krótko po zdarzeniu, ale jednocześnie pozostawia pewną dowolność osobie badanej, która może nie mieć możliwości wypełnienia ankiety natychmiast. Metoda generuje także losowe ankietę w celu umożliwienia określenia skuteczności działania modelu maszynowego (podobnie do testów A/B z wykorzystaniem placebo).

W pracy [O4] opisałem metodę dokładniej, w szczególności sposób obliczania cech dla modelu uczenia maszynowego. Z sygnałów PPG, EDA i ACC rejestrowanych smart-opaską Empatica E4 obliczanych jest 10 pochodnych sygnałów: tętno (HR) i jego odwrotność, czyli interwał między uderzeniami serca (ang. interbeat interval – IBI), zmienność rytmu serca (heart rate variability – HRV), toniczna i fazowa składowa EDA, wysokość i szerokość załamek fazowej składowej EDA, trzy wektory ACC, oraz zagregowany wektor ACC określający intensywność ruchu. Ze wszystkich sygnałów obliczane są cechy statystyczne i cechy w domenie częstotliwościowej. Dodatkowe cechy są tworzone z danych demograficznych (płeć, wiek) oraz czasowych (dzień tygodnia, pora dnia). Aby uchwycić różnicę w fizjologii przed wystąpieniem emocji i po niej, cechy liczone są osobno w dwóch 60-sekundowych oknach. Różnice między wartościami tożsamyh cech z obu okien są także wykorzystywane jako cechy. W rezultacie obliczanych jest niemal 900 cech. Wyniki klasyfikacji prezentowane w pracy [O4] są niższe niż w pracy [O3], ponieważ zastosowałem inny rodzaj walidacji – walidację niezależną od uczestnika (ang. leave-N-subjects-out).

Jednym z istotniejszych elementów metody jest właściwe zebranie danych anotowanych (ground truth) za pomocą ankiet samooceny. Naukowcy chcieliby bardzo

szczegółowego kwestionariusza przeprowadzanego możliwie często, aby gromadzić jak najwięcej danych zawierających dokładne informacje, np. o kontekście. Jednak zbyt obszerny i zbyt częsty kwestionariusz może prowadzić do irytacji uczestników, nierzetelnego wypełniania, lub wręcz pomijania go. Motywowany pracą [Eis20] przeprowadziłem eksperymenty w życiu codziennym mające na celu ustalenie odpowiedniej liczby ankiet w ciągu dnia [PO13] oraz walidujące wybrany zakres formularza – 16 pytań podzielonych na cztery kwadranty. Zgromadzone dane oraz ankiety opiniujące, wypełnione przez uczestników po eksperymencie, wskazują, że uczestnicy są w stanie wypełnić od trzech do sześciu ankiet dziennie. Obrany zakres ankiety był metodologicznie poprawny – rzetelność odpowiedzi mierzona miarą Cronbach’a dla wszystkich podskal przekraczała 0.72, a odpowiedzi w obrębie kwadrantów afektu (wysokie/niskie pobudzenie/walencja) były skorelowane. Jednak uczestnicy wyrazili opinię, że były uciążliwe obszerność ankiety i wielokrotne pytanie o ten sam kwadrant. Znalazło to także potwierdzenie w spadku liczby wypełnianych ankiet z biegiem eksperymentu. Aby rozwiązać ten problem, zaproponowałem znaczne uproszczenie ankiety samooceny. W nowej (i obecnej) wersji ankieta ma zaledwie trzy pytania i jedno pole tekstowe na ewentualne uwagi.

Metoda gromadzenia danych anotowanych afektem z nową, uproszczoną ankietą samooceny, została zwalidowana 12-tygodniowym eksperymentem w życiu codziennym [O8, PO14]. Praca [O8] skupia się na porównaniu różnych modeli maszynowych i strategiach ponownego uczenia modelu – te wyniki zostaną opisane w dalszej części autoreferatu. Praca [PO14] koncentruje się na określeniu skuteczności zaproponowanej metody gromadzenia danych. Aby umożliwić pomiar skuteczności, metoda zawiera mechanizm wywoływania ankiet w momentach losowych (EMA). W efekcie część ankiet jest wywoływana losowo, a część przez model wykrywający intensywne emocje. Uczestnicy eksperymentu są informowani, że ankiety będą wywoływane losowo, aby nie sugerowali się działaniem modelu. Ankiety wywołane losowo stanowią wartość referencyjną. Jeżeli ankiety wywołane przez model maszynowy zawierają procentowo więcej ankiet raportujących przeżywanie silnych emocji, uznajemy, że metoda oparta o model maszynowy ma wyższą skuteczność gromadzenia danych. Formalnie skuteczność określona jest następująco:

$$S = \frac{A_{em}}{A_{wy}}, \text{ gdzie:}$$

S to skuteczność rozważanej metody; A_{em} to liczba ankiet, w których zaraportowano przeżywanie intensywnych emocji; A_{wy} to łączna liczba ankiet wywołanych przez rozważaną metodę (model maszynowy lub losowo). W przeprowadzonych badaniach niespersonalizowany model maszynowy zapewnił o 21% więcej danych anotowanych afektem niż losowe wywoływanie ankiet (EMA). W przypadku modelu spersonalizowanego dla grupy uczestników zysk był jeszcze większy – do 38% danych więcej. Co istotne, wraz z długością eksperymentu model maszynowy poprawia swoją skuteczność, ponieważ stale zwiększa się ilość danych do uczenia. Według posiadanej przeze mnie wiedzy, jest to pierwsze na świecie rozwiązanie, dostarczające więcej anotowanych danych niż losowe próbkowanie (EMA).

Opisywana metoda została zaimplementowana jako system Emognition, składający się z aplikacji mobilnej na smartfona z systemem Android, aplikacji na smart-zegarek z systemem Tizen, oraz części serwerowej (technologia Google Firebase). W swoich badaniach stosuję ideę otwartej nauki, dlatego techniczne aspekty implementacji metody zostały opisane w [O12]. W szczególności: zastosowane technologie, integracja z urządzeniami wearables, przetwarzanie danych, a także napotkane problemy i sposoby ich rozwiązania.

Opracowanie i walidacja metody do gromadzenia danych anotowanych afektem w życiu codziennym realizuje cel szczegółowy [C2]. Opisanie metody oraz jej wyników [O3, O4, O8, O12, PO13, PO14] jest bardzo istotne dla dziedziny ponieważ otwiera możliwość prowadzenia długofalowych eksperymentów w życiu codziennym na szeroką skalę. W ostatnich miesiącach kilku naukowców z różnych krajów wyraziło chęć skorzystania z systemu Emognition w ich eksperymentach. Zainteresowanie metodą wykazała również duża firma technologiczna. Aktualnie trwają prace nad implementacją metody w taki sposób, aby możliwe było publiczne udostępnienie systemu, np. aplikacja do pobrania w sklepie Google Play oraz webowy panel administratora. W związku z przetwarzaniem danych wrażliwych (fizjologia, ankiety samooceny) i koniecznością ich składowania, stworzenie takiego systemu jest bardzo skomplikowanym zadaniem.

Model rozpoznający przeżywanie silnych emocji

Najważniejszym elementem metody gromadzenia danych anotowanych afektem jest model maszynowy dokonujący wnioskowania w czasie rzeczywistym. W ramach prac [O3, O4, O8] zbadałem różne modele (w tym różne architektury głębokie), różne (pod)zbiory cech wykorzystywanych do uczenia modelu, różne miary jakości wykorzystywane do strojenia modelu, a także różne metody walidacji modelu.

W początkowych badaniach [O3] wykorzystałem klasyczne modele drzewiaste (drzewo decyzyjne, lasy losowe) opakowane meta-klasyfikatorem AdaBoost w celu uzyskania zespołu klasyfikatorów. Do walidacji zastosowałem 5-krotną walidację krzyżową oraz F-miarę. Uzyskane wyniki były wysokie (F-miara równa 0.91), jednak w takiej konfiguracji (walidacja krzyżowa) nie można ocenić generalizujących właściwości modelu. Dlatego w kolejnych pracach najczęściej używałem technik walidacji uwydatniających skuteczność modelu pomiędzy uczestnikami (ang. cross-participant validation).

W pracy [O4] zastosowałem walidację leave-N-subjects-out. Model był trenowany na 12 osobach, a walidowany na trzech “nieznanych” osobach. Model maszynowy został dobrany automatycznie poprzez zastosowanie biblioteki auto-sklearn. Optymalizowaną metryką był obszar pod krzywą ROC (ang. ROC AUC), a najlepszym modelem okazał się zespół klasyfikatorów składający się z lasów losowych i ich wariacji (Extremely Randomized Trees Classifier), a także wzmocnionego gradientu (Gradient Boosting). Uzyskane wyniki oscylowały w okolicy wartości 0.57-0.59, które były wyższe od metod referencyjnych określonych jako predykcja klasy dominującej (ROC AUC = 0.5), klasyfikacja losowa (ROC AUC = 0.5), oraz klasyfikacja losowa stratyfikowana (ROC AUC = 0.534).

W późniejszych badaniach [O8] znacznie większą wagę przykładałem do metryki F-miary uzyskanej na klasie odpowiadającej przeżywaniu silnych emocji. Jest to lepszy wybór jeśli priorytetyzujemy wskazanie wszystkich przypadków prawdziwie pozytywnych (ang. true positive), a jednocześnie konsekwencje możliwych przypadków fałszywie pozytywnych nie są szkodliwe. W tym wypadku uczestnik eksperymentu zostanie poproszony o wypełnienie ankiety samooceny mimo iż nie przeżywa silnych emocji, co można uznać za mniej szkodliwe zdarzenie niż pominięcie wartościowego zdarzenia emocjonalnego. W pracy [O8] analizuję skuteczność modeli

uczonych w klasyczny sposób z wykorzystaniem cech (klasyfikatory AdaBoost, KNN, Random Forest, SVM i model głęboki MLP) oraz modeli end-to-end (Residual Network – ResNet, Fully Convolutional Network – FCN, FCN + Long Short-Term Memory) uczonych na surowych sygnałach. Najwyższą skuteczność wyrażoną F-miarą ważoną makro uzyskała architektura głęboka FCN – 0.63. W tej pracy badałem także czy wykorzystanie cech związanych z akcelerometrem poprawia działanie modelu, jednak testy statystyczne nie udzieliły jednoznacznej odpowiedzi na to pytanie.

Opracowanie modelu uczenia maszynowego predykującego przeżywanie intensywnych emocji (cel szczegółowy [C3]) było kluczowe do stworzenia skutecznej metody gromadzenia danych anotowanych afektem w życiu codziennym. Przeprowadzone analizy różnych klasyfikatorów i architektur są istotne dla dalszych prac nad rozwojem modelu.

Problem zimnego startu

Rozpoczynając gromadzenie danych z wykorzystaniem modelu maszynowego wykrywającego przeżywanie silnych emocji pojawia się pytanie skąd wziąć dane do treningu modelu. Taka sytuacja jest dobrze znana w obszarze systemów rekomendacyjnych, gdzie określa się ją mianem “problemu zimnego startu” (ang. the cold start problem). W pracy [O8] analizuję cztery strategie uczenia modelu na początku eksperymentu z nową grupą uczestników. Co istotne, eksperymenty zostały przeprowadzone w życiu codziennym. Rozważane strategie to: (S1) model wytrenowany na danych z poprzednich eksperymentów – jedyne możliwe rozwiązanie na samym początku eksperymentu, (S2) model bazujący na części danych z poprzednich eksperymentów i z aktualnego eksperymentu (w stosunku 1:1) – rozwiązanie możliwe po pewnym czasie od rozpoczęcia eksperymentu, (S3) model wytrenowany tylko na danych z aktualnego eksperymentu – wymaga odpowiedniej ilości danych, i (S4) model opracowany z wykorzystaniem wszystkich dostępnych danych z poprzednich eksperymentów i z aktualnego eksperymentu. Przeprowadzone analizy wykazały, że korzystne jest tworzenie modelu uwzględniającego dane z aktualnego eksperymentu. Modele opracowane w scenariuszach S2, S3 i S4 okazały się skuteczniejsze w wykrywaniu silnych emocji od modelu w S1 o odpowiednio 12%, 18% i 15%. Prawdopodobną przyczyną jest fakt, że modele w tych scenariuszach były trenowane na próbkach osób, które brały udział w eksperymencie, przez co modele były częściowo

personalizowane. Najbardziej skuteczny okazał się model w S3, uczony tylko na danych z aktualnego eksperymentu. Model ten został opracowany po dwóch tygodniach trwania eksperymentu. Co ciekawe, model trenowany na większej ilości danych (S4) uzyskał niższą skuteczność niż model w S3. Możliwym uzasadnieniem jest znacznie przeważająca ilość danych z poprzednich eksperymentów w S4, która zaszumia model dla uczestników aktualnego eksperymentu.

Badania nad “problemem zimnego startu” adresują cel szczegółowy [C4]. Wyniki są istotne dla prowadzenia eksperymentów wykorzystujących modele uczenia maszynowego do wywoływania ankiet samooceny. Wnioskiem płynącym z analiz w [O8] jest konieczność stopniowego przeuczania modelu wraz z biegiem eksperymentu.

Głębokie architektury end-to-end

Klasyczne uczenie modeli z wykorzystaniem cech wymaga wiedzy dziedzinowej na temat sygnałów fizjologicznych, aby wydobyć odpowiednie i informatywne cechy. Ponadto, wydobywanie cech jest kosztowne obliczeniowo i czasowo, zależne od sygnału (każdy sygnał wymaga dedykowanych metod), niestandardowe i niesystematyczne (liczba cech dla każdego sygnału może się różnić od kilku dla temperatury skóry do setek dla sygnału EEG). Aby obliczyć cechy, bardzo często konieczne jest zaawansowane wstępne przetwarzanie sygnału. Co więcej, duża liczba wyodrębnionych cech prowadzi do tak zwanej klątwy wymiarowości i wymaga etapów selekcji oraz redukcji cech, co z kolei może prowadzić do utraty informacji. Dlatego bardzo atrakcyjnym rozwiązaniem alternatywnym jest tworzenie modeli end-to-end. To podejście zakłada, że architektury głębokich sieci neuronowych są w stanie samodzielnie wydobyć niezbędne informacje z sygnałów, co znacznie zmniejsza złożoność procesu tworzenia modeli, ale także zwiększa szansę na wydobycie odpowiednich informacji, nieosiągalnych nawet dla ekspertów dziedzinowych.

Jako jeden z pierwszych w dziedzinie zastosowałem metody end-to-end do rozpoznawania afektu [O2]. W badaniach opisanych w pracy [O2] przeanalizowałem 10 różnych architektur end-to-end opartych na sieciach rezydualnych, konwolucyjnych, oraz rekurencyjnych. Dla trzech zbiorów danych, w których problem maszynowy polega na klasyfikacji próbek do czterech kwadrantów przestrzeni pobudzenie-walencja, modele end-to-end osiągnęły wyniki zbliżone do metod referencyjnych –

klasyfikacji losowej oraz klasyfikacji klasą dominującą. Dla zbioru danych WESAD, w którym problem to klasyfikacja 3-klasowa, modele end-to-end osiągnęły rezultaty znacząco lepsze od metod referencyjnych oraz porównywalne do modeli uczonych z wykorzystaniem cech. Najwyższą skuteczność klasyfikacji osiągnęła architektura FCN, zawierająca warstwy z największą liczbą filtrów. Może to oznaczać, że architektury end-to-end wymagają wielu wag (cech) aby uzyskać reprezentację sygnału. Niespodziewanie, sieci konwolucyjne okazały się lepsze od sieci rekurencyjnych (dedykowanych szeregom czasowym) we wszystkich rozważanych problemach. W badaniach wykorzystujących dane zebrane w życiu codziennym modele end-to-end osiągnęły nieznacznie lepszą skuteczność niż modele uczone z wykorzystaniem cech [O8]. Ponownie, najlepsza okazała się architektura oparta o sieć FCN.

Analiza zastosowania metod end-to-end (cel szczegółowy [C6]) wykazała, że osiągają one skuteczność zbliżoną do metod opartych o cechy. Główną korzyścią ze stosowania modeli end-to-end jest możliwość pominięcia etapu wydobywania cech. Jest to istotne dla otwarcia informatyki afektywnej na ekspertów uczenia maszynowego nieposiadających wiedzy dziedzinowej z zakresu fizjologii.

Metody spersonalizowane

Emocje są powszechne, jednak istnieje wiele czynników biologicznych, fizjologicznych, demograficznych, i innych, które sprawiają, że odczuwamy i przeżywamy emocje w różny sposób [Den16, Fer18]. Dlatego tak istotne jest spersonalizowane podejście do rozpoznawania emocji. W pracy [O9] analizuję różne strategie personalizacji w zadaniu rozpoznawania emocji wywołanych treścią tekstową (opinie i komentarze). Najprostszą strategią zakłada uwzględnienie w wektorze wejściowym unikalnego numeru przyporządkowanego danej osobie. Kolejną strategią dodaje do wektora wejściowego miarę mówiącą o tym na ile postrzeganie emocji przez daną osobę jest zbliżone z postrzeganiem przez ogół społeczeństwa. Wreszcie, najbardziej złożoną strategią uwzględnia miarę opisaną powyżej oraz podejście danej osoby do wcześniej skonsumowanych treści. Wszystkie strategie znacząco poprawiły skuteczność klasyfikacji w odniesieniu do metody niespersonalizowanej. W zależności od wybranego modelu językowego i strategii, skuteczność wyrażona współczynnikiem determinacji modelu (R^2) wzrosła od trzech do nawet pięciu razy w stosunku do wyniku bazowego.

W niektórych przypadkach personalizacja dla każdego uczestnika może nie być możliwa, np. z powodu niewystarczającej ilości danych. Taka sytuacja wystąpiła w badaniach opisanych w pracy [O8]. Problem zbyt małej ilości danych rozwiązałem proponując personalizację dla grupy uczestników. Częściowa personalizacja, tj. model wytrenowany na próbkach zgromadzonych od rozważanych uczestników i próbkach nienależących do uczestników (w stosunku 1:1), okazała się o 12% bardziej skuteczna niż podejście pozbawione personalizacji. Z kolei pełna personalizacja dla grupy, tj. model uczony tylko na próbkach pochodzących od rozważanych uczestników, poprawiła skuteczność klasyfikacji o 18%.

Skuteczność personalizacji dla grupy uczestników jest istotna, ponieważ brak możliwości personalizacji dla każdego uczestnika jest bardzo częstym problemem w eksperymentach afektywnych. Powyższe badania adresują cel szczegółowy [C5].

Metody walidacji modeli

Analiza zdolności personalizacji i generalizacji modeli maszynowych wymaga odpowiednich metod walidacji modeli. W literaturze zaprezentowano wiele metod walidacji modeli w problemie rozpoznawania emocji. W pracy [O5] zaproponowałem podział na następujące typy walidacji: (1) n -krotna walidacja krzyżowa wykorzystująca wszystkie próbki, (2) walidacja krzyżowa niezależna od stymulantu lub zadania (np. ang. leave- k -stimuli/tasks-out), (3) walidacja krzyżowa niezależna od uczestnika (np. ang. leave- k -subjects-out), (4) walidacja na przestrzeni czasu (np. hold-out). Typy walidacji wymienione w punktach 1 i 4 są przydatne do analizy dopasowania modelu do danej osoby lub zbioru danych. Z kolei pozostałe (niezależne od uczestnika, stymulantu lub zadania), pozwalają określić zdolności generalizacji modelu maszynowego.

W pracy [O3] stosuję 5-krotną walidację krzyżową. W pracy [O4] stosuję walidację niezależną od uczestnika, tj. leave-3-subjects-out. Natomiast w pracy [O8] wskazuję korzyści z dostosowania modelu do grupy uczestników i stosuję metodę walidacji zależną od uczestnika, tj. walidację na przestrzeni czasu (ang. hold-out). Dobór odpowiedniej metody walidacji jest istotny, ponieważ będzie ona uwydatniała konkretne zdolności modelu uczenia maszynowego.

Metody poprawy jakości sygnałów fizjologicznych

Kolejnym ważnym elementem rozpoznawania emocji w życiu codziennym jest umiejętność przetwarzania i poprawy jakości sygnałów fizjologicznych. W badaniach opisanych w pracy [O10] analizuję różne techniki poprawy jakości sygnału PPG zarejestrowanego przy pomocy smart-zegarka. Wyniki wskazują, że filtrowanie sygnałów PPG przy użyciu dyskretnej transformacji falkowej i jej odwrotności (DWT/IDWT) jest odpowiednie do usuwania wolnych składowych i szumu o wysokiej częstotliwości. Co więcej, główną korzyścią demodulacji amplitudy jest lepsze przygotowanie sygnału PPG do określenia częstotliwości rytmu serca i redukcja innych artefaktów. Przetwarzanie końcowe zastosowane do sygnału zmienności tętna (ang. Pulse Rate Variability – PRV) wskazuje, że korekcja wartości odstających oparta na lokalnych miarach statystycznych sygnałów i modelu autoregresyjnym jest ważna tylko wtedy, gdy PPG jest niskiej jakości i nie ma żadnego efektu przy dobrej jakości sygnału. Główny wniosek jest taki, że DWT/IDWT, a następnie demodulacja amplitudy, umożliwi właściwe przygotowanie sygnału PPG do późniejszego wykorzystania algorytmów ekstrakcji PRV, szczególnie w spoczynku. Badania te są obecnie kontynuowane, aby opracować metody i publicznie dostępne narzędzia do usuwania zakłóceń w sygnale zebranym w trakcie ruchu wykorzystując dodatkowe informacje, np. sygnał ACC.

W pracy [O7] wskazuję, że przetwarzanie i transformacja sygnałów mogą służyć nie tylko do redukcji zakłóceń, ale także do poprawy jakości sygnału (np. generacja brakujących próbek) i do obliczenia cech dla modeli maszynowych.

Opracowanie metody poprawy jakości sygnału (cel szczegółowy [C7]) jest istotne dla wnioskowania z fizjologii. Szczególnie, gdy do zbierania danych wykorzystuje się urządzenia do noszenia (wearables), które są bardzo podatne na zakłócenia sygnału.

Wielomodalne dane afektywne z urządzeń do noszenia (wearables)

Jednym z poważniejszych problemów w obszarze rozpoznawania emocji jest wciąż stosunkowo niewielka liczba publicznie dostępnych zbiorów danych. W ramach pracy [O6] stworzyłem zbiór danych anotowanych afektem. Jest to jeden z nielicznych zbiorów, które zostały zgromadzone z wykorzystaniem urządzeń do noszenia. Główne

zalety zbioru to (1) zastosowanie urządzeń do noszenia, (2) dostępność danych wielomodalnych – fizjologia (EEG, 2×PPG, HR, EDA, SKT, 3×ACC, 2×żyroskop) oraz nagrania wideo górnej części ciała, w tym wyrazu twarzy, (3) zastosowanie zarówno dyskretnych (dziewięć emocji) jak i wymiarowych (SAM - pobudzenie, walencja, motywacja) modeli emocji. Analizy wykazały, że stymulanty wzbudziły oczekiwane emocje a sygnały są dobrej jakości.

Zbiór danych [O6] umożliwia wiele kierunków badawczych, m.in.: (1) multimodalne podejście do rozpoznawania emocji (RE); (2) analizy pomiędzy RE z fizjologii i wyrazu twarzy; (3) analizy pomiędzy RE z EEG i PPG; (4) analizy pomiędzy RE z różnych sensorów – Empatica E4 oraz Samsung Galaxy Watch; (5) klasyfikacja emocji pozytywnych i negatywnych; (6) rozpoznawanie afektu – niskie vs. wysokie pobudzenie/walencja; (7) analizy pomiędzy dyskretnymi i wymiarowymi modelami emocji.

Gromadzenie i udostępnianie zbiorów danych (cel szczegółowy [C8]) jest istotne do osiągnięcia postępów w dziedzinie informatyki afektywnej. Aktualnie prowadzę badania, których efektem będzie wielomodalny zbiór danych zgromadzony w życiu codziennym obejmujący min. 300 osób. Po zakończeniu procesu zbierania i oczyszczania, dane zostaną udostępnione społeczności naukowej.

Etyka prowadzenia badań z wearables

Informatyka afektywna jest wciąż stosunkowo nowym obszarem, który wymaga zasad etycznych w wielu kwestiach. Zasady etyczne są ważne dla uczestników eksperymentów, ale także dla zapewnienia poprawności metodologicznej oraz wysokiej jakości prowadzonych badań naukowych (np. jakość sygnałów i modeli maszynowych). W pracy [O11] zaproponowałem zbiór zasad etycznych (ryzyka i rekomendacje) dla prowadzenia eksperymentów afektywnych z wykorzystaniem urządzeń do noszenia. Są to pierwsze rozważania etyczne koncentrujące się na urządzeniach typu wearables. Zidentyfikowałem 33 ryzyka i zaproponowałem do nich rekomendacje. Ryzyka odnoszące się do modeli maszynowego uczenia zwracają uwagę na stroniczość modeli przy niepoprawnym doborze próbek (np. niereprezentatywny dobór uczestników), problem deanonimizacji danych poprzez zastosowanie odwróconej inżynierii modelu maszynowego (np. maskowanie lub wnioskowanie z rozkładów), oraz możliwość

nadmiernej generalizacji modeli maszynowych stworzonych w oparciu o wąski zasób danych.

Aby zapewnić jak najwyższą kompletność i jakość proponowanych zasad, swoje propozycje skonsultowałem z ponad 30 naukowcami. W ogólności zaproponowane ryzyka i rekomendacje zostały przez nich zaaprobowane, a ich pojedyncze uwagi i sugestie zostały wdrożone. Ponadto, praca zawiera listę kontrolną, która ułatwia przygotowanie eksperymentów afektywnych z udziałem ludzi. Wypracowane zasady pomogą także komisjom do spraw etyki w procesie oceny wniosków.

Zaproponowane zasady etyczne (cel szczegółowy [C9]) są wartościowe dla uczestników eksperymentów, ponieważ chronią ich prywatność, zdrowie i samopoczucie. Chronią także naukowców prowadzących eksperymenty poprzez wskazanie pewnego rodzaju “zasad bezpieczeństwa”. Ponadto, mogą przyczynić się do poprawy jakości zbieranych danych, m.in. poprzez protokół poprawnego korzystania z urządzeń pomiarowych. W ramach kontynuacji rozważań i propozycji etycznych planuję organizację warsztatu poświęconego etyce na konferencji ACII 2023.

4.6 Podsumowanie osiągnięcia naukowego i uzyskanych wyników

W ramach osiągnięcia naukowego w dyscyplinie informatyka techniczna i telekomunikacja zaproponowałem **zestaw metod i modeli do rozpoznawania emocji w życiu codziennym**. Wkład naukowy wykazywanego dorobku można podsumować następująco:

- Identyfikacja problemów w rozpoznawaniu emocji w życiu codziennym z sygnałów fizjologicznych, systematyzacja wiedzy, oraz krytyczna analiza istniejących rozwiązań [O1, O3, O5, O7];
- Opracowanie koncepcji, metod i technologicznych rozwiązań służących rozpoznawaniu emocji w życiu codziennym z sygnałów fizjologicznych z wykorzystaniem uczenia maszynowego [O3, O4, O8, O10, O12, PO13, PO14];
- Opracowanie i analiza modelu uczenia maszynowego służącego do efektywniejszego gromadzenia danych anotowanych emocjami [O3, O4, O8];
- Analiza problemu “zimnego startu” (problem zidentyfikowany w [C3] na początku eksperymentu) i jego rozwiązanie za pomocą odpowiedniego modelu

uczenia maszynowego [O8]; badania zostały wyróżnione nagrodą “Best Paper Award”, WristSense’22 Workshop, PerCom’22 Conference;

- Analiza personalizacji modelu maszynowego do rozpoznawania emocji [O8, O9];
- Analiza zastosowania głębokich metod uczenia maszynowego end-to-end do predykcji afektu w porównaniu do metod bazujących na wyodrębnionych cechach [O2, O8];
- Opracowanie metody poprawy jakości sygnałów fizjologicznych poprzez usunięcie zakłóceń o wysokiej częstotliwości, co ma istotne znaczenie dla jakości modeli wnioskujących [O10];
- Zgromadzenie danych anotowanych emocjami w warunkach laboratoryjnych i w życiu codziennym ze wsparciem modeli uczenia maszynowego dostosowanych do działania na urządzeniach mobilnych [O4, O6, O8, PO14];
- Opracowanie zasad etycznych chroniących uczestników eksperymentów afektywnych oraz poprawiających jakość zbieranych danych dotyczących rozpoznawania emocji z sygnałów fizjologicznych, w tym także zasad związanych z modelami wnioskującymi [O11]

Pragnę podkreślić, że prowadzone przeze mnie badania zmierzały do umożliwienia prowadzenia eksperymentów afektywnych w ich naturalnym środowisku, tj. w życiu codziennym [O1, O3, O4, O5, O7, O8, O10, O11, O12, PO13, PO14].

Zaproponowana metoda gromadzenia danych anotowanych afektem została zwalidowana w dwóch badaniach przeprowadzonych w życiu codziennym, trwających łącznie ponad 14 tygodni i obejmujących niemal 30 osób [O8, PO13, PO14]. **Metoda okazała się skuteczniejsza od powszechnie stosowanej metody EMA (uznawanej za “state-of-the-art”).** Artykuł prezentujący walidację metody otrzymał nagrodę **Best Paper Award** na warsztacie WristSense ‘22. Aktualnie rozpoczęła się walidacja metody na znacznie większej populacji. W eksperymencie trwającym ponad rok weźmie udział 300 uczestników (badania są prowadzone w ramach grantu NCN Opus).

Informatyka afektywna jest złożonym obszarem leżącym na styku kilku dyscyplin, m.in.: informatyki (uczenie maszynowe), psychologii, inżynierii (przetwarzanie sygnałów), medycyny (fizjologia i kardiologia). Aby osiągnąć najwyższą jakość prowadzonych badań, w 2018 roku, wspólnie z prof. Przemysławem

Kazienką (Katedra Sztucznej Inteligencji, Politechnika Wrocławska) zawiązałem interdyscyplinarny zespół Emognition. Zespół składa się głównie z ekspertów uczenia maszynowego (mgr Bartosz Perz, mgr Dominika Kunc, mgr Joanna Komoszyńska – Katedra Sztucznej Inteligencji, Politechnika Wrocławska), ale także z psychologów (prof. Łukasz Kaczmarek i dr Maciej Behnke – Uniwersytet Adama Mickiewicza), oraz ekspertów w dziedzinie przetwarzania sygnałów (prof. Adam Polak, dr Monika Prucnal, mgr Bartłomiej Klich – Katedra Metrologii Elektronicznej i Fotonicznej, Politechnika Wrocławska). Wspólnie z prof. Kazienką kieruję pracami zespołu wyznaczając ścieżki badań, zapewniając opiekę naukową i analizując wyniki. Biorę także czynny udział w pozyskiwaniu projektów finansowanych ze środków krajowych i Unijnych, oraz nawiązuję współpracę naukową z zagranicznymi ośrodkami.

Literatura pomocnicza

[Ax53] Ax, A. F. (1953). The physiological differentiation between fear and anger in humans. *Psychosomatic medicine*, 15(5), 433-442.

[Bar06] Barrett, L. F. (2006). Are emotions natural kinds?. *Perspectives on psychological science*, 1(1), 28-58.

[Ber19] Bernal N. Amazon creates voice-activated device that recognises human emotions. *The Telegraph*, May 23, 2019.

[Bró13] Bródka P, Saganowski S, Kazienko P (2013) GED: the method for group evolution discovery in social networks. *Social Network Analysis and Mining*, 3(1), 1-14.

[Cow17] Cowen, A. S., & Keltner, D. (2017). Self-report captures 27 distinct categories of emotion bridged by continuous gradients. *Proceedings of the national academy of sciences*, 114(38), E7900-E7909.

[Cow19] Cowen, A. S., Elfenbein, H. A., Laukka, P., & Keltner, D. (2019). Mapping 24 emotions conveyed by brief human vocalization. *American Psychologist*, 74(6), 698.

[Cow20] Cowen, A. S., Fang, X., Sauter, D., & Keltner, D. (2020). What music makes us feel: At least 13 dimensions organize subjective experiences associated with music across different cultures. *Proceedings of the National Academy of Sciences*, 117(4), 1924-1934.

[Cow21] Cowen, A.S., Keltner, D., Schroff, F. *et al.* (2021) Sixteen facial expressions occur in similar contexts worldwide. *Nature* 589, 251–257. <https://doi.org/10.1038/s41586-020-3037-7>

- [Den16] Deng, Y., Chang, L., Yang, M., Huo, M., & Zhou, R. (2016). Gender differences in emotional response: Inconsistency between experience and expressivity. *PloS one*, 11(6), e0158666.
- [Dze20] Dzedzickis, A., Kaklauskas, A., & Bucinskas, V. (2020). Human emotion recognition: Review of sensors and methods. *Sensors*, 20(3), 592.
- [Eis20] Eisele, G., Vachon, H., Lafit, G., Kuppens, P., Houben, M., Myin-Germeys, I., & Viechtbauer, W. (2020). The effects of sampling frequency and questionnaire length on perceived burden, compliance, and careless responding in experience sampling data in a student population. *Assessment*, 29(2), 136-151.
- [Ekm11] Ekman, P., & Cordaro, D. (2011). What is meant by calling emotions basic. *Emotion review*, 3(4), 364-370.
- [Exl16] Exler, A., Schankin, A., Klebsattel, C., & Beigl, M. (2016, September). A wearable system for mood assessment considering smartphone features and data from mobile ECGs. In *Proceedings of the 2016 ACM international joint conference on pervasive and ubiquitous computing: Adjunct* (pp. 1153-1161).
- [Fel16] Feleky, A. (1916). The influence of the emotions on respiration. *Journal of Experimental Psychology*, 1(3), 218.
- [Fen18] Feng, H., Golshan, H. M., & Mahoor, M. H. (2018). A wavelet-based approach to emotion classification using EDA signals. *Expert Systems with Applications*, 112, 77-86.
- [Fer18] Fernández-Aguilar, L., Ricarte, J., Ros, L., & Latorre, J. M. (2018). Emotional differences in young and older adults: films as mood induction procedure. *Frontiers in psychology*, 9, 1110.
- [Fer19] Fernández-Aguilar, L., Martínez-Rodrigo, A., Moncho-Bogani, J., Fernández-Caballero, A., & Latorre, J. M. (2019, June). Emotion detection in aging adults through continuous monitoring of electrodermal activity and heart-rate variability. In *International Work-Conference on the Interplay Between Natural and Artificial Computation* (pp. 252-261). Springer, Cham.
- [Fri78] Friesen, E., & Ekman, P. (1978). Facial action coding system: a technique for the measurement of facial movement. *Palo Alto*, 3(2), 5.
- [He17a] He, C., Yao, Y. J., & Ye, X. S. (2017). An emotion recognition system based on physiological signals obtained by wearable sensors. In *Wearable sensors and robots* (pp. 15-25). Springer, Singapore.
- [He17b] He Z, Tajeuna EG, Wang S, Bouguessa M. (2017) A Comparative Study of Different Approaches for Tracking Communities in Evolving Social Networks. In: *Data Science and Advanced Analytics (DSAA)*, 2017 IEEE International Conference on. IEEE; 2017. p. 89-98.

- [Hu18] Hu, L., Yang, J., Chen, M., Qian, Y., & Rodrigues, J. J. (2018). SCAI-SVSC: Smart clothing for effective interaction with a sustainable vital sign collection. *Future Generation Computer Systems*, 86, 329-338.
- [Kad20] Kadoya, Y., Khan, M. S. R., Watanapongvanich, S., & Binnagan, P. (2020). Emotional status and productivity: Evidence from the special economic zone in Laos. *Sustainability*, 12(4), 1544.
- [Kam16] Kamdar, M. R., & Wu, M. J. (2016). PRISM: a data-driven platform for monitoring mental health. In *Biocomputing 2016: Proceedings of the Pacific Symposium* (pp. 333-344).
- [Kan19] Kanjo, E., Younis, E. M., & Ang, C. S. (2019). Deep learning analysis of mobile physiological, environmental and location sensor data for emotion detection. *Information Fusion*, 49, 46-56.
- [Kha19] Khalil, R. A., Jones, E., Babar, M. I., Jan, T., Zafar, M. H., & Alhussain, T. (2019). Speech emotion recognition using deep learning techniques: A review. *IEEE Access*, 7, 117327-117345.
- [Ko18] Ko, B. C. (2018). A brief review of facial emotion recognition based on visual information. *sensors*, 18(2), 401.
- [Kra13] Kragel, P. A., & LaBar, K. S. (2013). Multivariate pattern classification reveals autonomic and experiential representations of discrete emotions. *Emotion*, 13(4), 681.
- [Kre10] Kreibig, S. D. (2010). Autonomic nervous system activity in emotion: A review. *Biological psychology*, 84(3), 394-421.
- [Lar20] Larradet, F., Niewiadomski, R., Barresi, G., Caldwell, D. G., & Mattos, L. S. (2020). Toward emotion recognition from physiological signals in the wild: approaching the methodological issues in real-life data collection. *Frontiers in psychology*, 11, 1111.
- [Lev90] Levenson, R. W., Ekman, P., & Friesen, W. V. (1990). Voluntary facial action generates emotion-specific autonomic nervous system activity. *Psychophysiology*, 27(4), 363-384.
- [Lev14] Levenson, R. W. (2014). The autonomic nervous system and emotion. *Emotion review*, 6(2), 100-112.
- [Lis04] Lisetti, C. L., & Nasoz, F. (2004). Using noninvasive wearable computers to recognize human emotions from physiological signals. *EURASIP Journal on Advances in Signal Processing*, 2004(11), 1-16.
- [Lis06] Lisetti, C. L., & Nasoz, F. (2006, September). Categorizing autonomic nervous system (ans) emotional signals using bio-sensors for hri within the maui paradigm. In *ROMAN 2006-The 15th IEEE International Symposium on Robot and Human Interactive Communication* (pp. 277-284). IEEE.
- [Lu19] Lu, X., Liu, X., & Stolterman Bergqvist, E. (2019, May). " It sounds like she is sad" Introducing a Biosensing Prototype that Transforms Emotions into Real-time Music and Facilitates Social Interaction. In *Extended Abstracts of the 2019 CHI Conference on Human Factors in Computing Systems* (pp. 1-6).

- [Mai19] Maier, M., Elsner, D., Marouane, C., Zehnle, M., & Fuchs, C. (2019, May). DeepFlow: Detecting Optimal User Experience From Physiological Data Using Deep Neural Networks. In AAMAS (pp. 2108-2110).
- [Nak18] Nakisa, B., Rastgoo, M. N., Rakotonirainy, A., Maire, F., & Chandran, V. (2018). Long short term memory hyperparameter optimization for a neural network based emotion recognition framework. *IEEE Access*, 6, 49325-49338.
- [Nal19] Nalepa, G. J., Kutt, K., Giżycka, B., Jemiolo, P., & Bobek, S. (2019). Analysis and use of the emotional context with wearable devices for games and intelligent assistants. *Sensors*, 19(11), 2509.
- [Nik18] Nikolova, D., Petkova, P., Manolova, A., & Georgieva, P. (2018). ECG-based emotion recognition: Overview of methods and applications. ANNA'18; Advances in Neural Networks and Applications 2018, 1-5.
- [Ngu17] Nguyen, N. T., Nguyen, N. V., Tran, M. H. T., & Nguyen, B. T. (2017, October). A potential approach for emotion prediction using heart rate signals. In 2017 9th International Conference on Knowledge and Systems Engineering (KSE) (pp. 221-226). IEEE.
- [Pan21] Panda, R., Redinho, H., Gonçalves, C., Malheiro, R., & Paiva, R. P. (2021, July). How Does the Spotify API Compare to the Music Emotion Recognition State-of-the-Art?. In Proceedings of the 18th Sound and Music Computing Conference (SMC 2021) (pp. 238-245). Axa sas/SMC Network.
- [Pic00] Picard, R. W. (2000). Affective computing. MIT press.
- [Plu80] Plutchik, R. (1980). A general psychoevolutionary theory of emotion. In *Theories of emotion* (pp. 3-33). Academic press.
- [Plu03] Plutchik, R. (2003). *Emotions and life: Perspectives from psychology, biology, and evolution*. American Psychological Association.
- [Pol17] Pollreisz, D., & TaheriNejad, N. (2017, July). A simple algorithm for emotion recognition, using physiological signals of a smart watch. In 2017 39th annual international conference of the IEEE engineering in medicine and biology society (EMBC) (pp. 2353-2356). IEEE.
- [Sag15] Saganowski, S., Gliwa, B., Bródka, P., Zygmunt, A., Kazienko, P., & Koźlak, J. (2015). Predicting community evolution in social networks. *Entropy*, 17(5), 3053-3096.
- [Sca11] Scarantino, A., & Griffiths, P. (2011). Don't give up on basic emotions. *Emotion Review*, 3(4), 444-454.
- [Sch54] Schlosberg, H. (1954). Three dimensions of emotion. *Psychological review*, 61(2), 81.
- [Sch18a] Schmidt, P., Reiss, A., Dürichen, R., Marberger, C., & Van Laerhoven, K. (2018, October). Introducing WESAD, a multimodal dataset for wearable stress and affect detection. In Proceedings of the 20th ACM international conference on multimodal interaction (pp. 400-408).

- [Sch18b] Schmidt, P., Reiss, A., Dürichen, R., & Van Laerhoven, K. (2018, October). Labelling Affective States "in the Wild" Practical Guidelines and Lessons Learned. In Proceedings of the 2018 ACM International Joint Conference and 2018 International Symposium on Pervasive and Ubiquitous Computing and Wearable Computers (pp. 654-659).
- [Sch19a] Schmidt, P., Dürichen, R., Reiss, A., Van Laerhoven, K., & Plötz, T. (2019, September). Multi-target affect detection in the wild: an exploratory study. In Proceedings of the 23rd International Symposium on Wearable Computers (pp. 211-219).
- [Sch19b] Schmidt, P., Reiss, A., Dürichen, R., & Van Laerhoven, K. (2019). Wearable-based affect recognition—A review. *Sensors*, 19(19), 4079.
- [Set18] Setiawan, F., Khowaja, S. A., Prabono, A. G., Yahya, B. N., & Lee, S. L. (2018, July). A framework for real time emotion recognition based on human ans using pervasive device. In 2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC) (Vol. 1, pp. 805-806). IEEE.
- [Shu21] Shui, X., Zhang, M., Li, Z., Hu, X., Wang, F., & Zhang, D. (2021). A dataset of daily ambulatory psychological and physiological recording for emotion research. *Scientific Data*, 8(1), 1-12.
- [Sie18] Siegel, E. H., Sands, M. K., Van den Noortgate, W., Condon, P., Chang, Y., Dy, J., ... & Barrett, L. F. (2018). Emotion fingerprints or emotion populations? A meta-analytic investigation of autonomic features of emotion categories. *Psychological bulletin*, 144(4), 343.
- [Suh20] Suhaimi, N. S., Mountstephens, J., & Teo, J. (2020). EEG-based emotion recognition: A state-of-the-art review of current trends and opportunities. *Computational intelligence and neuroscience*, 2020.
- [Tay20] Taylor, S., Jaques, N., Nosakhare, E., Sano, A., & Picard, R. (2017). Personalized multitask learning for predicting tomorrow's mood, stress, and health. *IEEE Transactions on Affective Computing*, 11(2), 200-213.
- [Tiz20] Tizzano, G. R., Spezialetti, M., & Rossi, S. (2020, June). A deep learning approach for mood recognition from wearable data. In 2020 IEEE International Symposium on Medical Measurements and Applications (MeMeA) (pp. 1-5). IEEE.
- [Tka18] Tkalčić, M. (2018, September). Emotions and personality in recommender systems: Tutorial. In Proceedings of the 12th ACM Conference on Recommender Systems (pp. 535-536).

4.7 Pozostałe osiągnięcia naukowo-badawcze

4.7.1 Publikacje niezawarte w osiągnięciu naukowym

W niniejszym punkcie przedstawiam prace opublikowane po uzyskaniu stopnia doktora jednak niebędące częścią głównego osiągnięcia naukowego – cyklu publikacji. Jest to łącznie osiem prac: trzy artykuły w czasopismach z IF, cztery referaty na konferencjach międzynarodowych oraz jeden rozdział w monografii (zeszyty naukowe). Opublikowane prace podzieliłem na dwie sekcje: publikacje tematycznie związane z osiągnięciem naukowym oraz niezwiązane z nim. Natomiast pełny wykaz prac będący dorobkiem wnioskodawcy obejmującym także okres przed uzyskaniem stopnia doktora oraz inne wystąpienia konferencyjne przedstawiono w załączniku 4 do wniosku.

Publikacje tematycznie związane z osiągnięciem naukowym:

- [PO13]** S. Saganowski, M. Behnke, J. Komoszyńska, D. Kunc, B. Perz, P. Kazienko. (2021). A system for collecting emotionally annotated physiological signals in daily life using wearables. In 2021 9th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos (ACIIW) (pp. 1-3). IEEE.

Core: C, Punkty MEiN: 20, liczba cytowań: 6/5/1. Szacowany wkład własny: 30% (konceptualizacja, metodologia, walidacja, analiza formalna, badanie, przygotowanie tekstu (szkic i wersja końcowa, przegląd, poprawki), zarządzanie, administracja). Szacowany udział współautorów: M.B. 30%, J.K. 15%, D.K. 15%, B.P. 15%, P.K. 10%

- [PO14]** D. Kunc, J. Komoszyńska, B. Perz, P. Kazienko, S. Saganowski. (2022). Real-Life Validation of Emotion Detection System with Wearables. In International Work-Conference on the Interplay Between Natural and Artificial Computation (pp. 45-54). Springer, Cham.

Core: National, Punkty MEiN: 20, liczba cytowań: 0/0/0. Szacowany wkład własny: 15% (konceptualizacja, metodologia, walidacja, analiza formalna, badanie, przygotowanie tekstu (szkic i wersja końcowa, przegląd, poprawki),

zarządzanie, administracja). Szacowany udział współautorów: D.K. 34%, J.K. 23%, B.P. 23%, P.K. 5%

Publikacje niezwiązane tematycznie z osiągnięciem naukowym:

[PO15] S. Saganowski, P. Bródka, M. Koziarski, P. Kazienko. (2019). Analysis of group evolution prediction in complex networks. PloS one, 14(10), e0224194.

Impact Factor: 2.740, Punkty MEiN: 100, liczba cytowań: 12/9/7. Szacowany wkład własny: 70% (konceptualizacja, metodologia, oprogramowanie, walidacja, analiza formalna, badanie, zasoby, opracowanie danych, przygotowanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja, zarządzanie, administracja). Szacowany udział współautorów: P.B. 10%, M.K. 10%, P.K. 10%

[PO16] W. Liu, S. Saganowski, P. Kazienko, S.A. Cheong. (2019). Predicting the evolution of physics research from a complex network perspective. Entropy, 21(12), 1152.

Impact Factor: 2.494, Punkty MEiN: 100, liczba cytowań: 9/5/5. Szacowany wkład własny: 45% (konceptualizacja, metodologia, oprogramowanie, walidacja, analiza formalna, badanie, opracowanie danych, przygotowanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja, administracja). Szacowany udział współautorów: W.L. 30%, P.K. 5%, S.C. 20%

[PO17] H. Jegierski, S. Saganowski. (2020). An “outside the box” solution for imbalanced data classification. IEEE Access, 8, 125191-125209.

Impact Factor: 3.367, Punkty MEiN: 100, liczba cytowań: 10/7/6. Szacowany wkład własny: 50% (konceptualizacja, metodologia, walidacja, analiza formalna, badanie, zasoby, przygotowanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja, zarządzanie, administracja).

[PO18] S. Saganowski. (2020). A three-stage machine learning network security solution for public entities. In 2020 IEEE 19th International Conference on Trust, Security and Privacy in Computing and Communications (TrustCom) (pp. 1097-1104). IEEE.

Core: A, Punkty MEiN: 140, liczba cytowań: 0/0/0.

- [PO19] **S. Saganowski**, P. Kazienko. (2021). A Resource-Aware Method for Parallel D2D Data Streaming. In International Conference on Computational Collective Intelligence (pp. 696-707). Springer, Cham.

Core: B, Punkty MEiN: 20, liczba cytowań: 0/0/0. Szacowany wkład własny: 90% (konceptualizacja, metodologia, oprogramowanie walidacja, analiza formalna, badanie, zasoby, opracowanie danych, przygotowanie tekstu (szkic i wersja końcowa, przegląd, poprawki), wizualizacja, zarządzanie, administracja).

- [PO20] M. Duda, I. Józwiak, J. Maciejewski, **S. Saganowski**. (2018). Odporność algorytmów podpisywania dokumentów cyfrowych. Zeszyty Naukowe. Organizacja i Zarządzanie/Politechnika Śląska.

Punkty MEiN: 11, liczba cytowań: 0/0/0.

4.7.2 Opracowane zbiory danych oraz opublikowany kod źródłowy

Oprócz publikowania prac głównie w otwartym dostępie (open access), staram się opracowywać i udostępniać wykorzystane zbiory danych oraz kod pozwalający na reprodukcję wyników badań (w tym opracowane algorytmy). Na ogół wykorzystuję do tego platformy Harvard Dataverse (dane) oraz GitHub (kod).

Opracowane zbiory danych

- 1) Emognition Wearable Dataset 2020 [O6] – zbiór danych psychofizjologicznych zawierający anotacje emocjonalne – <https://doi.org/10.7910/DVN/R9WAF4>;
- 2) Kolekcja 28 zbiorów danych uzyskanych z przetworzenia siedmiu rzeczywistych sieci złożonych – opracowany do pracy [PO15]: <https://doi.org/10.7910/DVN/ONOFS7>;
- 3) Cybersecurity NER corpus 2019 – zbiór danych językowych zawierający anotacje tekstu oznaczeniami z domeny cyberbezpieczeństwa – opracowany do pracy [PO18]: <https://doi.org/10.7910/DVN/1TCFII>;

- 4) Kolekcja 25 zbiorów danych uzyskanych z przetworzenia trzech rzeczywistych sieci złożonych – opracowany do pracy [**Sag15**]: <https://doi.org/10.7910/DVN/TWULOX>.

Kod źródłowy algorytmów do celów reprodukowania wyników

- 1) Publikacja [**O2**]: <https://github.com/Emognition/dl-4-tsc.git>;
- 2) Publikacja [**O6**]:
<https://github.com/Emognition/Emognition-wearable-dataset-2020.git>;
- 3) Publikacja [**PO15**]:
<https://github.com/michalkoziarski/SocialNetworkFeatureRanking>;
- 4) Publikacja [**PO17**]: <https://github.com/HJegierski/DataEnrichment.git>.

4.7.3 Udział w projektach badawczych

Biorę lub brałem udział w dziesięciu wymienionych poniżej krajowych i międzynarodowych projektach badawczych finansowanych w drodze konkursów:

1. CLARIN – Common Language Resources and Technology Infrastructure

- finansowanie: Polska Agencja Rozwoju Przedsiębiorczości, Program Operacyjny Inteligentny Rozwój
- numer grantu: POIR.04.02.00-00C002/19
- okres realizacji: 2020–2023 (w realizacji)
- rola: **wykonawca**
- budżet projektu: 136.100.000 PLN

2. OMINO – Overcoming Multilevel Information Overload

- finansowanie: Unia Europejska, program Horyzont 2020 – H2020-MSCA-RISE
- okres realizacji: 2023–2027 (przyznany)
- rola: **wnioskodawca, wykonawca**
- budżet projektu: 1.550.200 EUR, budżet Politechniki Wrocławskiej 340.400 EUR

- pozostali główni beneficjenci i partnerzy projektu: Politechnika Warszawska (lider projektu), University of Wolverhampton (Wielka Brytania), Bar Ilan University (Izrael), Modul University Vienna (Austria), Rensselaer Polytechnic Institute (Stany Zjednoczone), Notre Dame University (Stany Zjednoczone), Nanyang Technological University (Singapur), National University Tokyo Institute of Technology (Japonia), University of New Hampshire (Stany Zjednoczone), University of Pittsburgh (Stany Zjednoczone)

3. TRANSFoRm – Translational Research and Patient Safety in Europe

- finansowanie: Unia Europejska, Siódmy Program Ramowy – FP7-ICT
- numer grantu: FP7-ICT-2011-7
- okres realizacji: 2011–2015 (zakończony)
- rola: **wykonawca**
- budżet projektu: 9.726.688 EUR, budżet Politechniki Wrocławskiej 2.823.652 PLN
- pozostali główni beneficjenci projektu: King’s College London (lider projektu, Wielka Brytania), Imperial College London (Wielka Brytania), University of Birmingham (Wielka Brytania), Trinity College Dublin (Irlandia), Karolinska Institute (Szwecja), NIVEL (Holandia)

4. ENGINE – European research centre of Network intelligence for INnovation Enhancement

- finansowanie: Unia Europejska, Siódmy Program Ramowy – FP7-REGPOT
- numer grantu: 316097
- okres realizacji: 2013–2016 (zakończony)
- rola: **wykonawca**
- budżet projektu: 4.731.186 EUR (w całości dla PWR)

5. RENOIR – Reverse EngiNeering of sOcial Information pRocessing

- finansowanie: Unia Europejska, program Horyzont 2020 – H2020-MSCA-RISE
- numer grantu: 691152
- okres realizacji: 2016–2019 (zakończony)
- rola: **wykonawca**

- budżet projektu: 1.314.000 EUR, budżet Politechniki Wrocławskiej 369.000 EUR
- pozostali główni beneficjenci i partnerzy projektu: Politechnika Warszawska (lider projektu), University of California, Davis (Stany Zjednoczone), Rensselaer Polytechnic Institute (Stany Zjednoczone), Carnegie Mellon University (Stany Zjednoczone), University of Technology Sydney (Australia), Notre Dame University (Stany Zjednoczone), Nanyang Technological University (Singapur)

6. RegSOC – Regionalne Centrum Bezpieczeństwa Cybernetycznego

- finansowanie: Narodowe Centrum Badań i Rozwoju
- okres realizacji: 2018–2021 (zakończony)
- rola: **wykonawca**
- pozostali główni beneficjenci i partnerzy projektu: Instytut Techniki Innowacyjnych EMAG, NASK Państwowy Instytut Badawczy

7. Informatyka afektywna: głębokie uczenie w rozpoznawaniu emocji z sygnałów fizjologicznych

- finansowanie: Narodowe Centrum Nauki – program OPUS
- numer grantu: 2020/37/B/ST6/03806
- okres realizacji: 2021–2025 (w realizacji)
- rola: **współautor, wykonawca**
- budżet projektu: 1.358.400 PLN

8. Metody uczenia maszynowego w sieciach złożonych

- finansowanie: Narodowe Centrum Nauki – program OPUS
- numer grantu: 2013/09/B/ST6/02317
- okres realizacji: 2014–2017 (zakończony)
- rola: **wykonawca**
- budżet projektu: 664.690 PLN

9. Modele, metody i algorytmy obliczeniowej nauki o sieciach

- finansowanie: Narodowe Centrum Nauki – program OPUS
- numer grantu: 2016/21/B/ST6/01463
- okres realizacji: 2017–2022 (zakończony)

- rola: **wykonawca**
- budżet projektu: 685.950 PLN

10. Eksploracja danych w złożonych, społecznych systemach sieciowych

- finansowanie: Ministerstwo Nauki i Szkolnictwa Wyższego
- numer grantu: N 516 510839
- okres realizacji: 2010–2013 (zakończony)
- rola: **wykonawca**
- budżet projektu: 375.100 PLN

Przed uzyskaniem stopnia doktora realizowałem projekty 3, 4, 8 i 10, po uzyskaniu stopnia doktora realizowałem projekty 1, 2, 6 i 7, natomiast projekty 5 i 9 – częściowo przed, częściowo po uzyskaniu stopnia doktora.

4.7.4 Współpraca międzynarodowa

Podejmowana przeze mnie współpraca międzynarodowa realizowana jest na kilku polach, głównie ma jednak charakter badawczy – poprzez wspólną pracę badawczą, projekty naukowe i publikacje. Poniżej wymieniłem wybrane instytucje międzynarodowe, z którymi jest lub było mi dane współpracować.

- 1) **Stanford University, Kalifornia, Stany Zjednoczone** – współpraca z Dr Nicholas Coles nad organizacją międzynarodowego konkursu *Emotion Phenomenology and Physiology Modeling Challenge*, wspólny wniosek o grant, wspólna organizacja warsztatu na konferencji ACII 2023;
- 2) **University of Southern California, Kalifornia, Stany Zjednoczone** – 14-miesięczny staż badawczy, wspólne badania w ramach wielu projektów z zespołem badawczym Signal Analysis and Interpretation Laboratory (SAIL) pod kierownictwem prof. Shrikanth Narayanan;
- 3) **Nanyang Technological University, Singapur** – trzy staże badawcze, wspólna publikacja, współpraca w ramach projektu RENOIR;
- 4) **University of California Davis, Kalifornia, Stany Zjednoczone** – staż badawczy, współpraca w ramach projektu RENOIR, wspólna publikacja,

wspólna realizacja projektu Mining Historic Realia: Automatic Generation of Historic Wine Pricing³ – zastosowanie OCR i uczenia maszynowego;

- 5) **University of Technology Sydney, Australia** – staż badawczy, wspólna organizacja warsztatu Workshop on Social Network Analysis in Applications (7 edycji), współpraca w ramach projektu RENOIR;
- 6) **Imperial College London, Londyn, Wielka Brytania** – wspólne publikacje, współpraca w ramach projektu TRANSFoRm;
- 7) **Uppsala University, Uppsala, Szwecja** – współpraca w ramach projektu ENGINE;
- 8) **King's College London, Londyn, Wielka Brytania** – wspólne publikacje, współpraca w ramach projektu TRANSFoRm;
- 9) **Karolinska Institutet, Szwecja** – wspólne publikacje, współpraca w ramach projektu TRANSFoRm;
- 10) **Trinity College Dublin, Irlandia** – wspólne publikacje, współpraca w ramach projektu TRANSFoRm;
- 11) **Rensselaer Polytechnic Institute, Troy, NY, Stany Zjednoczone** – współpraca w ramach projektów ENGINE oraz RENOIR;
- 12) **University of Notre Dame, Indiana, Stany Zjednoczone** – współpraca w ramach projektów RENOIR i ENGINE;
- 13) **University of Dundee, Szkocja** – współpraca w ramach projektu TRANSFoRm;

4.7.5 Nagrody i stypendia

Za działalność naukową otrzymałem następujące nagrody i stypendia (do 2017 roku – przed uzyskaniem stopnia doktora, od 2018 roku – po uzyskaniu stopnia doktora):

³ <https://datalab.ucdavis.edu/2019/08/27/extracting-wine-price-data-from-historical-catalogs>

- 1) **Stypendium Ministra Nauki i Szkolnictwa Wyższego dla wybitnych młodych naukowców** – przyznane w roku 2021 (współczynnik sukcesu 11%);
- 2) **Stypendium im. Mieczysława Bekkera przyznane przez Narodową Agencję Wymiany Akademickiej (NAWA)**, finansujące 14-miesięczny staż naukowy na uczelni University of Southern California – przyznane w roku 2022 (współczynnik sukcesu 31%), nr decyzji BPN/BEK/2021/1/00372/DEC/1;
- 3) Jestem laureatem programu **Primus Politechniki Wrocławskiej** za publikacje istotnie przyczyniające się do wzrostu punktacji dyscypliny naukowej (działanie pierwsze) – w latach **2020, 2021, 2022**;
- 4) Jestem laureatem programu **Secundus Politechniki Wrocławskiej** za publikacje istotnie przyczyniające się do wzrostu punktacji dyscypliny naukowej (działanie drugie) – w latach **2021, 2022**;
- 5) **Stypendium TOP 500 Innovators finansowane przez Ministerstwo Nauki i Szkolnictwa Wyższego**, finansujące 2-miesięczne szkolenie na University of Cambridge oraz University of Oxford – przyznane w roku 2015;
- 6) 3 miejsce (wyróżnienie) w XXVIII Ogólnopolskim Konkursie Polskiego Towarzystwa Informatycznego na najlepsze prace magisterskie z informatyki – przyznane w roku 2011;
- 7) Nagroda Jego Magnificencji Rektora Politechniki Wrocławskiej za uznane osiągnięcia naukowe – w roku akademickim 2013/2014;
- 8) Nagroda Dziekana Wydziału Informatyki i Zarządzania Politechniki Wrocławskiej za uznane osiągnięcia naukowe – w latach akademickich 2015/2016, 2014/2015, 2012/2013;
- 9) Stypendium naukowe w ramach projektu Młoda Kadra “Rozwój potencjału dydaktyczno-naukowego młodej kadry akademickiej Politechniki Wrocławskiej” – edycje IX (2013) oraz X (2014);

- 10) Stypendium projakościowe dla doktorantów – w latach 2011, 2012, 2013, 2014, 2015, 2016;
- 11) Stypendium dla najlepszych doktorantów – w latach akademickich 2011/2012, 2012/2013, 2015/2016;
- 12) Stypendium z własnego funduszu stypendialnego Politechniki Wrocławskiej – w latach akademickich 2014/2015, 2015/2016, 2016/2017;
- 13) Stypendium z dotacji na finansowanie działalności badawczej młodej kadry Politechniki Wrocławskiej – w roku akademickim 2015/2016;
- 14) Stypendium doktoranckie – w latach akademickich 2012/2013, 2013/2014, 2014/2015, 2015/2016, 2016/2017;

Dodatkowo, następujące artykuły konferencyjne uzyskały nagrodę **Best Paper Award**:

- 1) **S. Saganowski**, D. Kunc, B. Perz, J. Komoszyńska, M. Behnke, P. Kazienko: The cold start problem and per-group personalization in real-life emotion recognition with wearables. **WristSense 2022** - The Eighth Workshop on Sensing Systems and Applications Using Wrist Worn Smart Devices co-located with **PerCom 2022** - The 20th International Conference on Pervasive Computing and Communications, March 21-25, 2022, online, IEEE, 2022, pp. 812-817. (CORE A*)
- 2) P. Bródka, **S. Saganowski**, P. Kazienko: Tracking Group Evolution in Social Networks. **SocInfo'11**, The Third International Conference on Social Informatics, 6-8 October, 2011, Singapore, Lecture Notes in Computer Science LNCS 6984, Springer, 2011, pp. 316-319.

4.7.6 Podsumowanie dorobku wnioskodawcy

W tabeli 2 przedstawiłem podsumowanie mojego dorobku naukowego i relewantnych aktywności naukowych – tam, gdzie było to możliwe i zasadne, w rozbiciu na dorobek przed uzyskaniem stopnia doktora oraz po uzyskaniu stopnia doktora. Na rysunku 3 przedstawiłem wykaz kluczowych autorów w obszarze “Emotion; Emotion Recognition; Affective Computing” za lata 2019-

2022 według bazy Scopus. Jestem sklasyfikowany na 5 pozycji pod względem “Scholarly output” (stan na dzień 4 listopada 2022). Za lata 2017-2022 jestem sklasyfikowany na 12 pozycji. W tabeli 3 prezentuję istotność moich publikacji mierzoną miarą Field-Weighted Citation Impact w obszarze “Emotion; Emotion Recognition; Affective Computing” według bazy Scopus. Wartość większa niż 1.00 oznacza, że dokumenty są cytowane częściej niż oczekiwano. Mój łączny wynik dla tego obszaru to 5.66.

Tabela 2: Podsumowanie dorobku naukowego.

Wskaźnik	Przed doktoratem	Po doktoracie	Łącznie
Liczba publikacji	14	20	34
Liczba publikacji indeksowanych w WoS Core C.	10	14	24
Liczba artykułów w czasopismach z IF	2	9	11
Suma współczynnika Impact Factor	4.601	56.831	61.432
Suma punktów z wykazu MEiN	480	2371	2854
Liczba cytowań (Google Scholar / Scopus / WoS)			570/344/245
Liczba cytowań bez autocytowań wszystkich autorów (Scopus / WoS)			261/214
Liczba publikacji cytowanych w WoS Core Collection			21
Indeks Hirscha według Google Scholar / Scopus / WoS			11/9/7
Liczba realizowanych projektów badawczych			10
Liczba wykonanych recenzji artykułów			około 60
Liczba stażów badawczych (liczba różnych ośrodków)			9 (8)
Liczba zdobytych nagród i stypendiów (międzynarodowe)			35 (2)

Top 500 authors in this Topic, by Scholarly Output

Metric value: Low High

Author	Affiliation	Scholarly Output	Views Count	Field-Weighted Citation Impact	Citation Count
1. Affanni, A.	University of Udine	11	306	3.42	109
2. Mountstephens, James	Universiti Malaysia Sabah	10	436	0.27	34
3. Piras, Alessandro	University of Udine	10	266	3.53	90
4. Rinaldo, Roberto	University of Udine	10	266	3.53	90
5. Saganowski, Stanisław	Wrocław University of Science and Technology	10	236	5.66	65
6. Teo, Jason	Universiti Malaysia Sabah	10	436	0.27	34
7. Zontone, Pamela	University of Udine	10	266	3.53	90
8. Can, Yekta Said	Koc University	9	429	3.19	350
9. Ersoy, Cem	Bogazici University	9	469	3.56	362
10. Kazienko, Przemysław	Wrocław University of Science and Technology	9	203	5.72	58

Rysunek 3: Lista najważniejszych autorów dla obszaru “Emotion; Emotion Recognition; Affective Computing” za lata 2019-2022 według Scopus. Stan na dzień 4 listopada 2022.

Tabela 3: Istotność publikacji mierzona miarą Field-Weighted Citation Impact w obszarze zdefiniowanym przez Scopus jako “Emotion; Emotion Recognition; Affective Computing”. Wartość większa niż 1.00 oznacza, że dokumenty są cytowane częściej niż oczekiwano. Stan na dzień 4 listopada 2022.

Publikacja	Liczba cytowań	Field-Weighted Citation Impact ⁴ (Scopus)
O8	2	21.35
O1	23	10.63
O9	1	8.81
PO13	5	7.48
O4	6	6.28
O7	8	5.14
O3	7	2.08
O5	2	1.87
O2	14	1.73
O6	2	1.5
O10	0	–
O11	0	–
O12	0	–
PO14	0	–

⁴ Miara FWCT określa jak cytowane są publikacje w porównaniu z podobnymi publikacjami. Wartość większa niż 1.00 oznacza, że dokumenty są cytowane częściej niż oczekiwano. Więcej o metryce: https://service.elsevier.com/app/answers/detail/a_id/14894/supporthub/scopus/~what-is-field-weighted-citation-impact-%28fwi%29%3F/

5. Informacja o wykazywaniu się istotną aktywnością naukową albo artystyczną realizowaną w więcej niż jednej uczelni, instytucji naukowej lub instytucji kultury, w szczególności zagranicznej.

W tym punkcie – zgodnie z tytułem – wymieniłem ośrodki badawcze, w których prowadziłem działalność badawczą w ramach stażów naukowych. Natomiast wszystkie ośrodki międzynarodowe, z którymi współpracowałem lub współpracuję, wymieniłem w punkcie 4.7.4.

Dnia 1 lipca 2022 rozpocząłem **14-miesięczny staż naukowy na uczelni University of Southern California** (Los Angeles, Stany Zjednoczone). Staż jest realizowany w związku ze stypendium otrzymanym z Programu im. Mieczysława Bekkera finansowanym przez Narodową Agencję Wymiany Akademickiej (NAWA). Nr decyzji BPN/BEK/2021/1/00372/DEC/1.

W ramach stażu współpracuję z **prof. Shrikanth Narayanan** oraz jego zespołem Signal Analysis and Interpretation Laboratory (SAIL). Zespół badawczy SAIL jest jednym z wiodących zespołów na świecie zajmujących się przetwarzaniem sygnałów i informacji związanych z ludźmi (sygnały fizjologiczne, mowa). Plan mojej wizyty zakłada **badania innowacyjne** w obszarze informatyki afektywnej:

- 1) Opracowanie **nowego modelu emocjonalnego opartego o fizjologię**. Zastosowanie nienadzorowanego uczenia w celu identyfikacji stanów psychofizjologicznych występujących w życiu codziennym. Analiza cech różnicujących stany psychofizjologiczne. Analiza porównawcza z istniejącymi modelami.
- 2) Opracowanie **generalizujących oraz spersonalizowanych** modeli rozpoznawania emocji w **życiu codziennym**.
- 3) Analiza różnych **strategii fuzji modeli generalizujących i spersonalizowanych**, a także opracowanie metod walidacji modeli.

W momencie złożenia niniejszego wniosku (30 listopada 2022) wizyta jest w trakcie realizacji. Obecnie dobiegają końca prace związane z uczeniem reprezentacji sygnałów fizjologicznych z wykorzystaniem techniki self-supervised learning w ujęciu wielomodalnym. Stworzona reprezentacja zostanie wykorzystana do segmentacji przebiegów sygnałów fizjologicznych zgromadzonych w ciągu dnia.

W ramach realizacji projektów międzynarodowych opisanych w punkcie 4.7.3 miałem możliwość realizacji wizyt stażowych na kilku uczelniach będących partnerami projektów – łącznie było to niemal 12 miesięcy. Najsilniejsza współpraca wynikająca ze wspólnych zainteresowań badawczych miała miejsce z **dr Wenyuan Liu** oraz **prof. Siew Ann Cheong** z uczelni **Nanyang Technological University** (Singapur). W czasie trzech wizyt naukowych zajmowałem się adaptacją metod śledzenia i predykcji ewolucji grup w sieciach złożonych (metody GED i GEP) do obszaru metanauki (Science of Science). Stosując metody GED i GEP byłem w stanie śledzić i przewidywać kierunki rozwoju w obszarze fizyki, co może być szczególnie przydatne dla agencji finansujących badania naukowe. Efektem naszej współpracy jest publikacja [PO16].

Ponadto, w ramach projektu RENOIR odbyłem staże badawcze w dwóch innych ośrodkach badawczych, University of California Davis (Kalifornia, Stany Zjednoczone – Prof. Carl Stahmer i) oraz University of Technology Sydney (Australia – Prof. Katarzyna Musiał-Gabryś). Wizyty te pozwoliły skonsultować założenia i dokończyć pracę nad publikacją podsumowującą metody GED oraz GEP [PO15], oraz poszerzyły wachlarz moich umiejętności naukowych o, m.in., metody predykcji linków w sieciach złożonych, optyczne rozpoznawanie znaków (OCR), umiejętność posługiwania się językiem R, oraz inne metody, narzędzia i techniki w obszarach danologii (data science) i uczenia maszynowego.

Jednocześnie w tym punkcie należy wspomnieć o istotnej współpracy realizowanej z ośrodkiem krajowym. W ramach 3-letniej współpracy z **dr hab. Łukaszem Kaczmarkiem** oraz **dr Maciejem Behnke** z **Uniwersytetu im. Adama Mickiewicza w Poznaniu** udało się:

- 1) Przeprowadzić badanie psychofizjologiczne z wykorzystaniem urządzeń typu wearables [O6]. Uzyskany i opublikowany zbiór danych jest jednym z nielicznych, które wykorzystują urządzenia typu wearables do zarejestrowania fizjologii oznaczonej afektem.
- 2) Opracować wytyczne etyczne wskazujące sposób prowadzenia badań nad afektem z wykorzystaniem urządzeń typu wearables [O11]. Są to pierwsze na świecie wytyczne dotyczące wearables i afektu.

- 3) Opracować i zwalidować metodę służącą do zbierania danych fizjologicznych anotowanych afektem [**O8, PO13**].

Warto także podkreślić, że owocna współpraca ze wszystkimi powyższymi ośrodkami skutkuje także tym, że badacze z tych ośrodków chętnie dołączają do kolejnych inicjatyw badawczych, np. grantów, których jestem wnioskodawcą.

Podsumowanie stażów naukowych odbytych po uzyskaniu stopnia doktora:

- 1) **University of Southern California** (Los Angeles, Stany Zjednoczone), Prof. Shrikanth Narayanan, 07.2022 – 08.2023 (**14 miesięcy**) – wizyta naukowa w trakcie realizacji;
- 2) **Nanyang Technological University** (Singapur), Prof. Siew Ann Cheong, 09.2019 – 11.2019 (2 miesiące);
- 3) **University of Technology Sydney** (Australia), Prof. Katarzyna Musiał-Gabrys, 01.2019 – 02.2019 (1 miesiąc);
- 4) **University of California Davis** (Kalifornia, Stany Zjednoczone), Prof. Carl Stahmer, 08.2018 – 12.2018 (4 miesiące);
- 5) **Nanyang Technological University** (Singapur), Prof. Siew Ann Cheong, 04.2018 – 06.2018 (1 miesiąc).

6. Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę lub sztukę.

6.1. Opracowanie nowych kierunków studiów oraz kursów

- 1) **Brałem udział w opracowaniu programu studiów magisterskich** realizowanego na Wydziale Informatyki i Telekomunikacji Politechniki Wrocławskiej - kierunek *Sztuczna Inteligencja*⁵.
- 2) **Opracowałem następujące kursy dla II-go stopnia studiów na kierunku *Sztuczna inteligencja* w Politechnice Wrocławskiej:**
 - a. Informatyka afektywna;

⁵ Witryna kierunku *Sztuczna Inteligencja*: <https://studiuj.ai/>

- b. Personalizacja i systemy rekomendacyjne;
 - c. Wizualizacja danych i komunikowanie.
- 3) **Opracowałem kurs** *Techniki programowania na platformach mobilnych* dla II-go stopnia studiów na kierunku *Informatyka* we Wrocławskiej Wyższej Szkole Informatyki Stosowanej.

6.2. Opieka naukowa

- 1) Od 2018 roku **współprowadzę interdyscyplinarny zespół badawczy **Emognition****, zajmujący się rozpoznawaniem emocji w życiu codziennym z wykorzystaniem urządzeń typu wearables. Jestem odpowiedzialny za opiekę naukową, zarządzanie zespołem, pozyskiwanie projektów badawczych, wyznaczanie nowych kierunków badawczych oraz nawiązywanie współpracy (głównie międzynarodowej). Zespół obecnie liczy 13 osób specjalizujących się w uczeniu głębokim, przetwarzaniu sygnałów, psychologii, wytwarzaniu oprogramowania.
- 2) Jestem **promotorem pomocniczym dwojga doktorantów**, którzy realizują studia doktoranckie w Szkole Doktorskiej Politechniki Wrocławskiej w dyscyplinie *informatyka techniczna i telekomunikacja*:
- a. Bartosz Perz, 3 rok, tytuł rozprawy: *Personalizacja rozpoznawania emocji w życiu codziennym z sygnałów fizjologicznych zebranych przy użyciu urządzeń do noszenia*;
 - b. Dominika Kunc, 1 rok, tematyka rozprawy: *Reprezentacja sygnałów fizjologicznych zebranych w życiu codziennym z uwzględnieniem indywidualnej specyfiki ludzi oraz identyfikacja stanów fizjologicznych związanych z afektem w sposób nienadzorowany*.

Wsparłem oboje doktorantów **w pozyskaniu stypendiów z programu NAWA STER** na staże naukowe w **University of Southern California**. Wyjazdy odbędą się wiosną 2023 roku.

- 3) Byłem **promotorem 16 prac magisterskich oraz 24 prac inżynierskich** (łącznie 44 studentów) obronionych na Politechnice Wrocławskiej. Niemal wszystkie prace dotyczyły tematyki uczenia maszynowego, rozpoznawania

emocji, lub sieci złożonych. Byłem także promotorem pracy magisterskiej obronionej we Wrocławskiej Wyższej Szkole Informatyki Stosowanej. Zdecydowana większość prac została oceniona celująco lub bardzo dobrze.

- 4) Jestem **opiekunem pomocniczym koła naukowego *DaniE - Dane i Eksploracje***. Koło w minionych latach zrzeszało około dziesięciu studentów. W ramach prac koła powstało ponad dziesięć artykułów naukowych zaakceptowanych na najlepsze konferencje dziedzinowe (np. PerCom – Core A*). Koło regularnie pozyskuje środki z funduszy Politechniki Wrocławskiej, z których finansuje wyjazdy studentów na konferencje.
- 5) Byłem **mentorem naukowym trojga studentów** kierunku Sztuczna Inteligencja w ramach programu AI Tech finansowanego przez Kancelarię Prezesa Rady Ministrów.

6.3. Wykłady zaproszone na międzynarodowym forum

Po doktoracie wygłosiłem następujące wykłady zaproszone:

- 1) “*Group Evolution Prediction in complex networks*” – 8th International Young Scientists Conference in Computational Science, Heraklion, Grecja (czerwiec 2019) – wykład typu ‘keynote’ na zaproszenie organizatorów konferencji.
- 2) “*Group Evolution Prediction in complex networks*” – Conference on Complex Systems, Singapur (październik 2019).

Dodatkowo w ramach wizyt stażowych i krótkich wizyt badawczych, wyniki własnych badań prezentowałem w ramach seminariów wydziałowych lub seminariów poszczególnych grup badawczych na następujących uczelniach: **University of California Davis** (Davis, USA), **Nanyang Technological University** (Singapur), **University of Southern California** (Los Angeles, USA), **University of Technology** (Sydney, Australia).

6.4. Prowadzone kursy

- 1) Informatyka afektywna (II stopień, opracowanie, wykład i projekt)
- 2) Wizualizacja danych i komunikowanie (II stopień, opracowanie, wykład i projekt)

- 3) Systemy rekomendacyjne i personalizacja (II stopień, opracowanie, projekt)
- 4) Techniki programowania na platformach mobilnych (II stopień, opracowanie, wykład i laboratorium)
- 5) Projekt naukowo-wdrożeniowy (II stopień, projekt)
- 6) Systemy operacyjne (I stopień, laboratorium)
- 7) Teoria i inżynieria ruchu teleinformatycznego (I stopień, opracowanie, projekt)
- 8) Podstawy programowania (I stopień, laboratorium)
- 9) Zespołowe przedsięwzięcie inżynierskie (I stopień, opracowanie, projekt)
- 10) Architektura komputerów (I stopień, laboratorium)
- 11) Praca dyplomowa (prace inżynierskie i magisterskie, w języku polskim i angielskim)

6.5. Pozostałe osiągnięcia dydaktyczne, organizacyjne oraz popularyzujące naukę

- 1) Wygłosiłem **wykład popularnonaukowy** *“Czy znasz swoje emocje? Twój telefon zna! Rozpoznawanie emocji z wykorzystaniem smart-urządzeń.”* w ramach Dolnośląskiego Festiwalu Nauki 2020.
- 2) Jestem **recenzentem prac w Ogólnopolskim konkursie na najlepsze prace magisterskie z informatyki**⁶ organizowanym przez Polskie Towarzystwo Informatyczne.
- 3) **Jestem stypendystą programu Top 500 Innovators**, finansowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego. Celem programu było wzmocnienie kompetencji w zakresie innowacji, komercjalizacji i ochrony własności intelektualnej, oraz przedsiębiorczości i umiejętności miękkich niezbędnych do współpracy z gospodarką. W ramach programu w 2015 roku **odbyłem 2-miesięczne szkolenie w University of Cambridge i University of Oxford (Wielka Brytania).**

Należę do stowarzyszenia Top 500 Innovators pełniącego rolę doradcą przy Ministerstwie Edukacji i Nauki.

⁶ Witryna konkursu PTI na najlepsze prace mgr z informatyki: <https://kpm.pti.org.pl/>

- 4) W 2014 roku odbyłem szkolenie „Innowacyjny przedsiębiorca – od nauki do biznesu” współfinansowane ze środków Unii Europejskiej w ramach Europejskiego Funduszu Społecznego Człowiek – najlepsza inwestycja. W ramach szkolenia odbyłem 80 godzin zajęć dotyczących komercjalizacji, ochrony i oceny rynkowej wartości własności intelektualnej.

Po ukończeniu szkolenia założyłem **własną spółkę** pod nazwą **Mobilited** spółka z ograniczoną odpowiedzialnością. Spółka świadczy innowacyjne usługi z obszaru **sztucznej inteligencji, data science, platform mobilnych, wirtualnej rzeczywistości, oraz użyteczności interfejsów.**

7. **Oprócz kwestii wymienionych w pkt. 1-6, wnioskodawca może podać inne informacje, ważne z jego punktu widzenia, dotyczące jego kariery zawodowej.**

Wykaz wszystkich aktywności naukowych zawierający także poszerzone informacje dotyczące niektórych aktywności wymienionych w tym załączniku oraz rozbięcie na osiągnięcia przed i po uzyskaniu stopnia doktora znajduje się w załączniku 4 do wniosku.

.....
Sogomolki

(podpis wnioskodawcy)