

dr inż. Tomasz Krzeszowski
Katedra Informatyki i Automatyki
Wydział Elektrotechniki i Informatyki
Politechnika Rzeszowska
al. Powstańców Warszawy 12
35-959 Rzeszów

Rzeszów, 23 września 2023 r.

Załącznik 3

Autoreferat

Spis treści

1	Imię i nazwisko	3
2	Posiadane dyplomy, stopnie naukowe	3
3	Dotychczasowe zatrudnienie w jednostkach naukowych	3
4	Omówienie osiągnięć naukowych, 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.).	4
4.1	Tytuł osiągnięcia naukowego	4
4.2	Wykaz publikacji w zakresie osiągnięcia naukowego	4
4.3	Cel naukowy prac i uzyskane wyniki	8
4.3.1	Cel i zakres prac	8
4.3.2	Najważniejsze rezultaty badań	9
4.3.3	Modyfikacja algorytmu optymalizacji rojem cząstek	10
4.3.4	Śledzenie ruchu	14
4.3.5	Identyfikacja osób na podstawie chodu	25
4.3.6	Uczenie nadzorowane systemów rozmytych Takagi-Sugeno	28
4.4	Pozostałe osiągnięcia, 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.).	35
4.4.1	Monografia naukowa, zgodnie z art. 219 ust. 1. pkt 2a ustawy	35
4.4.2	Wykaz zrealizowanych oryginalnych osiągnięć projektowych, konstrukcyjnych, technologicznych lub artystycznych, zgodnie z art. 219 ust. 1. pkt 2c ustawy	35
4.5	Omówienie pozostałych osiągnięć naukowo-badawczych	36
5	Współpraca z innymi krajowymi i zagranicznymi ośrodkami badawczymi	37
6	Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę lub sztukę	38
6.1	Przygotowanie i prowadzenie zajęć dydaktycznych	38
6.2	Promotorstwo prac inżynierskich i magisterskich	38
6.3	Opieka naukowa nad studentami	39
7	Podsumowanie dorobku naukowego – zestawienie i wskaźniki bibliometryczne	39

1 Imię i nazwisko

Tomasz Krzeszowski

Profile naukowe:

- ResearcherID (Web of Science): <http://www.researcherid.com/rid/H-7717-2019>
- ORCID: <https://orcid.org/0000-0001-7359-4637>
- Scopus: <https://www.scopus.com/authid/detail.uri?authorId=36622971400>
- ResearchGate: <https://www.researchgate.net/profile/Tomasz-Krzeszowski>

2 Posiadane dyplomy, stopnie naukowe

- 2013 r. — doktor nauk technicznych w dyscyplinie informatyka, specjalność: wizja i grafika komputerowa
 - Temat rozprawy doktorskiej: *Śledzenie ruchu postaci ludzkiej w systemie wielokamerowym*
 - Miejsce i rok obrony: Politechnika Śląska w Gliwicach, Wydział Automatyki, Elektroniki i Informatyki, 2013 r.
 - Promotor: prof. dr hab. inż. Bogdan Kwolek – Akademia Górniczo-Hutnicza w Krakowie
 - Rozprawa została wyróżniona przez Radę Wydziału Automatyki, Elektroniki i Informatyki Politechniki Śląskiej
- Tytuł magistra inżyniera informatyki, specjalność: inżynieria systemów informatycznych
 - Temat pracy: *Przetwarzanie dźwięku w systemach multimedialnych*
 - Miejsce i rok obrony: Politechnika Rzeszowska, Wydział Elektrotechniki i Informatyki, 2009 r.
 - Promotor: prof. dr hab. inż. Bogdan Kwolek – Akademia Górniczo-Hutnicza w Krakowie (w chwili obrony Politechnika Rzeszowska)

3 Dotychczasowe zatrudnienie w jednostkach naukowych

- 10.2019 – obecnie: profesor uczelni, Wydział Elektrotechniki i Informatyki, Politechnika Rzeszowska
- 04.2021 – 12.2021: starszy specjalista naukowo-techniczny, Uniwersytet Rzeszowski (wykonawca w projekcie naukowym)

- 11.2013 – 09.2019: adiunkt, Wydział Elektrotechniki i Informatyki, Politechnika Rzeszowska
- 10.2009 – 09.2013: asystent, Wydział Elektrotechniki i Informatyki, Politechnika Rzeszowska
- 07.2009 – 03.2011: asystent naukowy w projekcie, Polsko-Japońska Wyższa Szkoła Technik Komputerowych

4 Omówienie osiągnięć naukowych, 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.).

4.1 Tytuł osiągnięcia naukowego

Osiągnięciem naukowym jest jednotematyczny cykl publikacji naukowych pt. *Rozwój i zastosowania algorytmów inteligencji roju*.

4.2 Wykaz publikacji w zakresie osiągnięcia naukowego

Osiągnięcie naukowe stanowią połączone tematycznie prace, dla których sumaryczny współczynnik Impact Factor, zgodnie z rokiem opublikowania, wynosi **IF = 27,12**. Sumaryczna liczba punktów według Ministerstwa Nauki i Szkolnictwa Wyższego (MNiSW) /Ministerstwa Edukacji i Nauki (MEiN) jest równa **785 pkt.** Wartości współczynników IF zaczerpnięto ze stron domowych wydawnictw. Liczbę punktów MNiSW/MEiN określono zgodnie z rokiem publikacji na podstawie wykazów czasopism opublikowanych na stronie Ministerstwa. W nawiasach podano procentowy wkład współautorów w opracowanie publikacji.

[A1] **T. Krzeszowski** (70%, autor korespondencyjny), K. Wiktorowicz (30%), *Evaluation of selected fuzzy particle swarm optimization algorithms*, Federated Conference on Computer Science and Information Systems 2016 (FedCSIS 2016), Gdansk, Poland, pp. 571-575, 2016, doi:10.15439/2016F206

MNiSW2016: **15 pkt.** (obecnie 20 pkt. - publikacja w recenzowanych materiałach konferencyjnych z konferencji umieszczonej na liście MEiN), indeksacja: Web of Science, Scopus

Mój wkład w powstanie tej publikacji szacuję na 70%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) implementację algorytmu MFPSO (Modified Fuzzy Particle Swarm Optimization) oraz algorytmów rozmytych innych autorów w środowisku Matlab, c) przeprowadzenie testów algorytmów z wykorzystaniem typowych funkcji testowych,

d) współudział przy opracowaniu koncepcji algorytmu MFPSO, e) współudział przy implementacji systemu Takagi-Sugeno w algorytmie MFPSO, f) współudział przy analizie wyników i ocenie algorytmów, g) współudział przy przygotowaniu tekstu artykułu, h) współudział przy korekcie artykułu, i) współudział przy przygotowaniu prezentacji, j) prezentację wyników pracy na konferencji, k) pełnienie roli autora korespondencyjnego.

- [A2] **T. Krzeszowski** (70%, autor korespondencyjny), K. Przednowek (15%), K. Wiktorowicz (10%), J. Iskra (5%), *Estimation of hurdle clearance parameters using a monocular human motion tracking method*, Computer Methods in Biomechanics and Biomedical Engineering, Taylor & Francis, vol. 19, no. 12, pp. 1319-1329, 2016, doi:10.1080/10255842.2016.1139092

IF2016: **1,909**, MNiSW2016: **25 pkt.** (obecnie 70 pkt.)

Mój wkład w powstanie tej publikacji szacuję na 70%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) opracowanie i implementację algorytmu śledzenia, c) przeprowadzenie testów algorytmu i opracowanie wyników śledzenia, d) współudział przy przygotowaniu koncepcji badań, e) współudział przy rejestracji danych wizyjnych, f) współudział przy przygotowaniu tekstu artykułu, g) współudział przy przygotowaniu odpowiedzi dla recenzentów oraz korekcie artykułu, h) pełnienie roli autora korespondencyjnego.

- [A3] K. Przednowek (45%), **T. Krzeszowski** (45%, autor korespondencyjny), K. H. Przednowek (5%), P. Lenik (5%), *A System for Analysing the Basketball Free Throw Trajectory Based on Particle Swarm Optimization*, Applied Sciences, vol. 8, iss. 11, p. 2090, 2018, doi:10.3390/app8112090

IF2018: **2,217**, MNiSW2018: **25 pkt.** (obecnie 100 pkt.)

Mój wkład w powstanie tej publikacji szacuję na 45%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) opracowanie oraz implementację algorytmu detekcji piłki, b) opracowanie oraz implementację algorytmu śledzenia piłki, c) przeprowadzenie testów opracowanego systemu na 200 sekwencjach wideo prezentujących rzuty wolne, d) współudział przy przygotowaniu koncepcji badań, e) współudział przy rejestracji danych wizyjnych, f) współudział przy analizie wyników, g) współudział przy przygotowaniu tekstu artykułu, h) współudział przy przygotowaniu odpowiedzi dla recenzentów oraz korekcie artykułu, i) pełnienie roli autora korespondencyjnego.

- [A4] **T. Krzeszowski** (60%, autor korespondencyjny), K. Wiktorowicz (40%), *Combined Regularized Discriminant Analysis and Swarm Intelligence Techniques for Gait Recognition*, Sensors 2020, vol. 20, iss. 23, p. 6794, 2020, doi:10.3390/S20236794

IF2020: **3,576**, MNiSW2020: **100 pkt.**

Mój wkład w powstanie tej publikacji szacuję na 60%; obejmował on wszystkie

etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) współudział przy opracowaniu koncepcji badań, c) przygotowanie danych do uczenia i testów modeli klasyfikacji, d) współudział przy opracowaniu algorytmu do identyfikacji osób, e) przygotowanie wizualizacji wyników, f) współudział przy opracowaniu i analizie wyników, g) współudział przy przygotowaniu tekstu artykułu, h) współudział przy przygotowaniu odpowiedzi dla recenzentów oraz korekcie artykułu, i) pełnienie roli autora korespondencyjnego.

- [A5] K. Wiktorowicz (60%), **T. Krzeszowski** (40%), *Training High-Order Takagi-Sugeno Fuzzy Systems Using Batch Least Squares and Particle Swarm Optimization*, International Journal of Fuzzy Systems, vol. 22, no. 1, pp. 22-34, 2020. doi:10.1007/s40815-019-00747-2

IF2020: **4,673**, MNiSW2020: **70 pkt.**

Mój wkład w powstanie tej publikacji szacuję na 40%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) opracowanie uczenia poprzedników reguł systemu rozmytego za pomocą optymalizacji rojem cząstek, c) opracowanie procedury projektowania systemów za pomocą optymalizacji rojem cząstek, d) współudział przy opracowaniu hybrydowej metody uczenia systemów rozmytych Takagi-Sugeno do aproksymacji funkcji, e) współudział przy opracowaniu funkcji celu dla uczenia poprzedników reguł za pomocą optymalizacji rojem cząstek, f) współudział przy opracowaniu eksperymentów, g) współudział przy opracowaniu i analizie wyników, h) współudział przy przygotowaniu tekstu artykułu, i) współudział przy przygotowaniu odpowiedzi dla recenzentów oraz korekcie artykułu.

- [A6] K. Wiktorowicz (50%), **T. Krzeszowski** (50%), *Approximation of two-variable functions using high-order Takagi-Sugeno fuzzy systems, sparse regressions, and metaheuristic optimization*, Soft Computing, vol. 24, no. 20, pp. 15113–15127, 2020. doi:10.1007/s00500-020-05238-3

IF2020: **3,643**, MNiSW2020: **70 pkt.**

Mój wkład w powstanie tej publikacji szacuję na 50%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) opracowanie uczenia poprzedników reguł systemu rozmytego za pomocą optymalizacji metaheurystycznych (optymalizacja rojem cząstek, algorytm genetyczny, algorytm symulowanego wyżarzania), c) współudział przy opracowaniu hybrydowej metody uczenia systemów rozmytych Takagi-Sugeno do aproksymacji funkcji, d) współudział przy opracowaniu funkcji celu dla uczenia poprzedników reguł za pomocą algorytmów metaheurystycznych, e) współudział przy opracowaniu procedury projektowania, f) współudział przy opracowaniu eksperymentów, g) współudział przy opracowaniu i analizie wyników, h) współudział przy przygotowaniu tekstu artykułu, i) współudział przy przygotowaniu odpowiedzi dla recenzentów oraz korekcie artykułu.

- [A7] **T. Krzeszowski** (50%, autor korespondencyjny), K. Wiktorowicz (50%), *Training Sparse Fuzzy Classifiers Using Metaheuristic Optimization*, IEEE International Conference on Fuzzy Systems 2021 (FUZZ-IEEE 2021), Luxembourg (Virtual Conference), pp 1-7, 11-14 lipca, 2021, doi:10.1109/FUZZ45933.2021.9494590

MEiN2021: **140 pkt.** (publikacja w recenzowanych materiałach konferencyjnych z konferencji umieszczonej na liście MEiN)

Mój wkład w powstanie tej publikacji szacuję na 50%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) opracowanie uczenia poprzedników reguł systemu rozmytego za pomocą metod optymalizacji metaheurystycznych do klasyfikacji, c) współudział przy opracowaniu algorytmu klasyfikacji, d) współudział przy opracowaniu procedury projektowania, e) przygotowanie skryptów do podziału danych, f) współudział przy opracowaniu i analizie wyników, g) współudział przy przygotowaniu tekstu artykułu, h) współudział przy korekcie artykułu, i) wykonanie prezentacji, j) prezentacja wyników pracy na konferencji, k) pełnienie roli autora korespondencyjnego.

- [A8] K. Wiktorowicz (55%), **T. Krzeszowski** (40%), K. Przednowek (5%), *Sparse Regressions and Particle Swarm Optimization in Training High-Order Takagi-Sugeno Fuzzy Systems*, Neural Computing and Applications, vol. 33, pp. 2705–2717, 2021. doi: 10.1007/s00521-020-05133-w

IF2021: **5,102**, MEiN2021: **100 pkt.**

Mój wkład w powstanie tej publikacji szacuję na 40%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) opracowanie uczenia poprzedników reguł systemu rozmytego za pomocą optymalizacji rojem cząstek, c) współudział przy opracowaniu hybrydowej metody uczenia systemów rozmytych Takagi-Sugeno do aproksymacji funkcji, d) współudział przy opracowaniu funkcji celu dla uczenia poprzedników reguł za pomocą optymalizacji rojem cząstek, e) współudział przy opracowaniu procedury projektowania, f) współudział przy opracowaniu eksperymentów, g) współudział przy opracowaniu i analizie wyników, h) współudział przy przygotowaniu tekstu artykułu, i) współudział przy przygotowaniu odpowiedzi dla recenzentów oraz korekcie artykułu.

- [A9] K. Wiktorowicz (70%), **T. Krzeszowski** (30%), *Identification of Time Series Models Using Sparse Takagi-Sugeno Fuzzy Systems with Reduced Structure*, Neural Computing and Applications, vol. 34, pp. 7473–7488, 2022. doi:10.1007/s00521-021-06843-5

IF2022: **6,0**, MEiN2022: **100 pkt.**

Mój wkład w powstanie tej publikacji szacuję na 30%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) wykonanie przeglądu literatury, b) opracowanie uczenia poprzedników reguł systemu rozmytego za pomocą opty-

malizacji rojem cząstek do identyfikacji szeregów czasowych, c) współudział przy opracowaniu hybrydowej metody uczenia systemów rozmytych Takagi-Sugeno do identyfikacji szeregów czasowych, d) współudział przy opracowaniu procedury projektowania, e) współudział przy przygotowaniu tekstu artykułu, f) współudział przy przygotowaniu odpowiedzi dla recenzentów oraz korekcie artykułu.

- [A10] **T. Krzeszowski** (70%, autor korespondencyjny), A. Świtoński (10%), M. Zieliński (5%), K. Wojciechowski (5%), J. Rosner (10%), *3D tracking of multiple drones based on Particle Swarm Optimization*, International Conference on Computational Science 2023 (ICCS 2023), Lecture Notes in Computer Science, vol 10476, Springer, Cham, Prague, Czech Republic, 03-05 lipca, 2023, doi:10.1007/978-3-031-36027-5_18

MEiN2023: **140 pkt.** (publikacja w recenzowanych materiałach konferencyjnych z konferencji umieszczonej na liście MEiN)

Mój wkład w powstanie tej publikacji szacuję na 70%; obejmował on wszystkie etapy przygotowania pracy, w szczególności: a) opracowanie koncepcji algorytmu śledzenia, b) implementację algorytmu śledzenia, c) opracowanie i implementację funkcji dopasowania, d) testy algorytmu, e) analizę wyników, f) współudział przy przygotowaniu przeglądu literatury, g) współudział przy przygotowaniu tekstu artykułu h) wykonanie prezentacji, i) prezentację wyników pracy na konferencji, j) pełnienie roli autora korespondencyjnego.

4.3 Cel naukowy prac i uzyskane wyniki

4.3.1 Cel i zakres prac

Głównym celem naukowym moich badań, przedstawionych w cyklu publikacji, był rozwój i zastosowanie algorytmów inteligencji roju, w szczególności algorytmu optymalizacji rojem cząstek (ang. Particle Swarm Optimization, PSO) do śledzenia ruchu, klasyfikacji i uczenia systemów rozmytych.

Algorytm PSO został opracowany przez Kennedy’ego i Eberharta [20] w 1995 roku. Od tego czasu powstały liczne modyfikacje PSO i wielokrotnie udowodniono jego przydatność w różnorodnych zastosowaniach, m.in. śledzeniu ruchu, optymalizacji parametrów klasyfikatorów, grupowaniu, projektowaniu regulatorów PID, czy planowaniu zadań. PSO jest nowoczesną metodą poszukiwania stochastycznego, czerpiącą z reguł zachowań społecznych w populacjach organizmów żywych. W technice tej wykorzystuje się rój cząstek w celu znalezienia optymalnego rozwiązania dla rozpatrywanego problemu.

W ramach prowadzonych badań zaproponowano modyfikację algorytmu PSO wykorzystującą system rozmyty [A1]. W zakresie śledzenia ruchu opracowano bezmarkerową metodę przechwytywania ruchu płotkarza oraz estymacji parametrów kroku płotkowego [A2], system do pomiaru i analizy parametrów rzutu wolnego w koszykówce wykorzystujący metody detekcji oraz śledzenia pozycji piłki [A3], a także algorytm śledzenia wielu dronów [A10]. W zakresie klasyfikacji opracowano metody hybrydowe [A4] oraz

metody wykorzystujące rozmyty system Takagi-Sugeno (T-S) [A7]. W zakresie uczenia systemów rozmytych opracowano sposób uczenia poprzedników reguł systemu rozmytego za pomocą algorytmu PSO [A5], [A6], [A7], [A8], [A9], opracowano hybrydowe metody uczenia systemów rozmytych T-S wysokiego rzędu [A5], [A9], zastosowano regresję rzadkie do uczenia systemów rozmytych T-S wysokiego rzędu z jednym [A8] i z dwoma wejściami [A6], [A9].

4.3.2 Najważniejsze rezultaty badań

Do najważniejszych elementów przeprowadzonych badań, które uważam, że mogą stanowić istotny wkład do dyscypliny informatyka techniczna i telekomunikacja, zaliczam:

- zaproponowanie modyfikacji algorytmu PSO z wykorzystaniem systemu rozmytego [A1];
- analizę porównawczą opracowanego algorytmu i wybranych rozmytych algorytmów PSO [A1];
- opracowanie bezmarkerowej metody przechwytywania ruchu płotkarza wykorzystującej PSO i obrazy z pojedynczej kamery [A2];
- opracowanie sposobu estymacji parametrów kroku płotkowego wykorzystującego bezmarkerowy system przechwytywania ruchu [A2];
- zastosowanie po raz pierwszy bezmarkerowych metod przechwytywania ruchu do estymacji parametrów kroku płotkowego [A2];
- opracowanie systemu do pomiaru i analizy parametrów rzutu wolnego w koszykówce [A3];
- opracowanie metody śledzenia piłki wykorzystującej PSO [A3];
- opracowanie sposobu detekcji położenia piłki do koszykówki i ponownej detekcji po zgubieniu przez algorytm śledzący [A3];
- opracowanie hybrydowej metody klasyfikacji wykorzystującej regularyzowaną analizę dyskryminacyjną (ang. *Regularized Discriminant Analysis*, RDA) i techniki inteligencji roju [A4];
- zastosowanie po raz pierwszy hybrydowej metody wykorzystującej RDA i algorytm PSO do identyfikacji osób na podstawie chodu [A4];
- zastosowanie po raz pierwszy hybrydowej metody wykorzystującej RDA i algorytm GWO (ang. *Grey Wolf Optimizer*) oraz metody wykorzystującej RDA i algorytm WOA (ang. *Whale Optimization Algorithm*) do klasyfikacji [A4];
- opracowanie sposobu uczenia poprzedników reguł systemu rozmytego za pomocą PSO [A5], [A6], [A7], [A8] i [A9];
- opracowanie hybrydowej metody uczenia systemów rozmytych T-S wysokiego rzędu z wykorzystaniem algorytmu PSO i wsadowej metody najmniejszych kwadratów [A5];

- zastosowanie po raz pierwszy metod wykorzystujących regresję rzadkie do uczenia systemów rozmytych T-S wysokiego rzędu z jednym wejściem [A8] i z dwoma wejściami [A6];
- zastosowanie opracowanych metod hybrydowych uczenia systemów rozmytych T-S do aproksymacji funkcji [A5], [A6] i [A8];
- opracowanie modelu klasyfikacji wykorzystującego rozmyty system T-S uczony przy pomocy metaheurystycznych algorytmów optymalizacji (PSO i inne) oraz regresji rzadkich [A7];
- opracowanie hybrydowej metody uczenia systemów rozmytych T-S wysokiego rzędu z wykorzystaniem technik optymalizacji (PSO i inne), regresji rzadkiej i etykiet reguł [A9];
- zastosowanie opracowanej metody hybrydowej do predykcji szeregów czasowych [A9];
- opracowanie algorytmu śledzenia wielu dronów wykorzystującego PSO i obrazy z systemu wielokamerowego [A10];
- zastosowanie po raz pierwszy techniki PSO do śledzenia wielu dronów [A10].

4.3.3 Modyfikacja algorytmu optymalizacji rojem cząstek

Algorytm optymalizacji rojem cząstek

W algorytmie PSO [8, 20] przestrzeń rozwiązań problemu jest przeszukiwana przy pomocy roju cząstek. Każda z cząstek jest rozmieszczana losowo w d -wymiarowej przestrzeni poszukiwań i reprezentuje hipotetyczne rozwiązanie problemu. Następnie cząstki eksplorują przestrzeń poszukiwań i oddziałują na siebie w celu znalezienia optymalnego rozwiązania. Każda i -ta cząstka zawiera pozycję $\mathbf{x}_i$, prędkość $\mathbf{v}_i$ oraz najlepszą pozycję znaną do tej pory $\mathbf{pbest}_i$. Ponadto cząstki mają dostęp do najlepszej globalnej pozycji, jaka została znaleziona przez dowolną cząstkę w roju $\mathbf{gbest}$. W podstawowej wersji algorytmu PSO [20] prędkość i położenie każdej cząstki w k -tej iteracji są aktualizowane za pomocą następujących równań:

$$\mathbf{v}_i^{k+1} = \omega \mathbf{v}_i^k + c_1 \mathbf{r}_1 (\mathbf{pbest}_i - \mathbf{x}_i^k) + c_2 \mathbf{r}_2 (\mathbf{gbest} - \mathbf{x}_i^k), \quad (1)$$

$$\mathbf{x}_i^{k+1} = \mathbf{x}_i^k + \mathbf{v}_i^{k+1}, \quad (2)$$

gdzie ω to waga inercji, $\mathbf{r}_1$ i $\mathbf{r}_2$ są liczbami losowymi z rozkładu jednorodnego w przedziale $(0, 1)$, zaś c_1 i c_2 to mnożniki wagowe, które powinny przyjmować wartości większe od zera. Cały algorytm można przedstawić w postaci następującego pseudokodu:

1. For each particle i
2. Initialize $\mathbf{x}_i^0, \mathbf{v}_i^0$
3. $\mathbf{pbest}_i = \mathbf{x}_i^0$
4. $\mathbf{gbest} = \arg \min_{\mathbf{x}_i^0} f(\mathbf{x}_i^0)$
5. For $k = 1, 2, \dots, K$

6. For each particle i
7. $\mathbf{v}_i^{k+1} = \omega \mathbf{v}_i^k + c_1 \mathbf{r}_1(\mathbf{pbest}_i - \mathbf{x}_i^k) + c_2 \mathbf{r}_2(\mathbf{gbest} - \mathbf{x}_i^k)$
8. $\mathbf{x}_i^{k+1} = \mathbf{x}_i^k + \mathbf{v}_i^{k+1}$
9. If $f(\mathbf{x}_i^{l+1}) < f(\mathbf{pbest}_i)$ then $\mathbf{pbest}_i = \mathbf{x}_i^{l+1}$
10. If $f(\mathbf{x}_i^{l+1}) < f(\mathbf{gbest})$ then $\mathbf{gbest} = \mathbf{x}_i^{l+1}$

Funkcja $f(\mathbf{x})$ to funkcja dopasowania (ang. *fitness function*) zwana również funkcją celu (ang. *objective function*). Funkcja ta określa w jakim stopniu dane rozwiązanie odpowiada poszukiwanemu rozwiązaniu problemu i umożliwia wybór najlepszej lokalnej pozycji cząstek ($\mathbf{pbest}_i$) i najlepszej globalnej pozycji w roju ($\mathbf{gbest}$).

Od czasu pierwszej publikacji omawiającej algorytm PSO powstały jego liczne modyfikacje [8, 12], w tym wersje wprowadzające elementy systemów rozmytych [2, 27, 29]. Podczas analizy wspomnianych publikacji narodziła się koncepcja udoskonalenia, która mogłaby poprawić działanie algorytmu PSO.

Zaproponowana modyfikacja algorytmu optymalizacji rojem cząstek

W pracy [A1] zaproponowano modyfikację algorytmu PSO wykorzystującą reguły rozmyte. Powstała metoda została nazwana Modified Fuzzy PSO (MFPSO). Idea koncepcji dla zaproponowanej modyfikacji narodziła się w wyniku analizy wcześniej opublikowanych prac omawiających rozmyte algorytmy optymalizacji roju cząstek [2, 27, 29].

Shi i Eberhart [29] udoskonaliли wcześniej wprowadzoną modyfikację algorytmu polegającą na zastosowaniu wagi inercji ω do stopniowego ograniczania wpływu prędkości cząstek z poprzedniej iteracji [12]. Współczynnik ten ma znaczący wpływ na działanie PSO, ponieważ równoważy zdolności roju do globalnej eksploracji i lokalnej eksploatacji. Autorzy pracy [29] doszli do wniosku, że lepsze wyniki można osiągnąć poprzez nieliniową zmianę współczynnika ω i zastosowali w tym celu rozmyty system wnioskujący. Ulepszenie algorytmu z publikacji [29] zostało zaproponowane przez Alfi i Fateh [2]. W ich metodzie, waga inercji jest obliczana dla każdej cząstki z osobna na podstawie jej aktualnego stanu. Jest to uzasadnione, ponieważ każda cząsteczka w roju znajduje się w innym miejscu przestrzeni problemu, a tym samym jej sytuacja może się diametralnie różnić od sytuacji innych cząstek. Inną koncepcję zaproponował Niknam [27], który zastosował system rozmyty nie tylko do zmiany ω , ale również współczynników c_1 i c_2 . Współczynniki te określają wpływ najlepszej pozycji znalezionej przez daną cząstkę $\mathbf{pbest}_i$ i najlepszej pozycji w roju $\mathbf{gbest}$ na prędkość cząstek. Na przykład, jeśli c_1 jest większe niż c_2 , wtedy cząstka ma tendencję do przemieszczania się w kierunku $\mathbf{pbest}_i$, a nie do najlepszej globalnej pozycji znalezionej przez rój.

Opracowany algorytm MFPSO [A1] łączy wcześniej przedstawione koncepcje opracowane przez autorów prac [2] i [27]. W algorytmie tym każda z cząstek ma własne współczynniki ω , c_1 i c_2 , które zmieniają się zgodnie z opisem lingwistycznym reprezentowanym przez reguły rozmyte. W ten sposób każdą z cząstek można traktować indywidualnie. Na przykład, jeśli cząstka znalazła nową lokalną najlepszą pozycję $\mathbf{pbest}_i$, to należy zmniejszyć wagę bezwładności ω i zwiększyć współczynniki c_1 i c_2 . Z drugiej strony, jeśli $\mathbf{pbest}_i$ nie zmienia się od dłuższego czasu, to lepszą strategią

byłoby prawdopodobnie zwiększenie ω i zmniejszenie c_1 i c_2 w celu poprawy zdolności eksploracji.

Rozważmy teraz rozmyty system Takagi-Sugeno z dwoma wejściami y_1 , y_2 i jednym wyjściem u . Dla wejścia y_1 zdefiniowano m trójkątnych zbiorów rozmytych A_i , których wierzchołki znajdują się w punktach p_i , gdzie $i = 1, \dots, m$. Analogicznie, dla wejścia y_2 , zdefiniowano n zbiorów rozmytych B_j z wierzchołkami w punktach q_j , gdzie $j = 1, \dots, n$. Współrzędne wierzchołków p_i i q_j są zapisane w formie wektorów $\mathbf{p} = [p_i] = [p_1, \dots, p_m]$ i $\mathbf{q} = [q_j] = [q_1, \dots, q_n]$. Wyjście systemu jest opisane przez $m \cdot n$ rozmytych reguł wnioskowania o następującej formie:

$$R_{ij} : \text{ IF } y_1 \in A_i \text{ AND } y_2 \in B_j, \text{ THEN } u = z_{ij}, \quad (3)$$

gdzie $z_{ij} \in \mathbb{R}$ jest następnikiem reguły R_{ij} . Reguły są zapisywane w postaci tabeli w następujący sposób:

$y_1 \backslash y_2$	B_1	B_2	$\dots$	B_{n-1}	B_n
A_1	z_{11}	z_{12}	$\dots$	$z_{1,n-1}$	z_{1n}
A_2	z_{21}	z_{22}	$\dots$	$z_{2,n-1}$	z_{2n}
$\vdots$	$\vdots$	$\vdots$	$\ddots$	$\vdots$	$\vdots$
A_{m-1}	$z_{m-1,1}$	$z_{m-1,2}$	$\dots$	$z_{m-1,n-1}$	$z_{m-1,n}$
A_m	z_{m1}	z_{m2}	$\dots$	$z_{m,n-1}$	z_{mn}

(4)

Wyjście u systemu T-S jest wyliczane jako średnia ważona z z_{ij} na podstawie równania

$$u = TS(y_1, y_2) = \frac{\sum_{i=1}^m \sum_{j=1}^n w_{ij}(y_1, y_2) z_{ij}}{\sum_{i=1}^m \sum_{j=1}^n w_{ij}(y_1, y_2)}, \quad (5)$$

gdzie

$$w_{ij}(y_1, y_2) = A_i(y_1) \cdot B_j(y_2) \quad (6)$$

oznacza stopień spełnienia reguły R_{ij} .

Zaproponowane rozwiązanie zakłada wyznaczenie współczynników ω , c_1 i c_2 dla każdej cząstki przy pomocy trzech systemów T-S:

$$\omega_i = TS(nf_i^k, nu_i^k) \quad (7)$$

$$(c_1)_i = TS(nf_i^k, nu_i^k) \quad (8)$$

$$(c_2)_i = TS(nf_i^k, nu_i^k) \quad (9)$$

Wejście nf_i^k jest zdefiniowane w następujący sposób [2]:

$$nf_i^k = \frac{fp_i^k - f_{min}}{fp_i^0 - f_{min}} \quad (10)$$

i $fp_i^k = f(\mathbf{pbest}_i^k)$, a nu_i^k wyznacza się z zależności

$$nu_i^k = \frac{u_i^k - u_{min}}{u_{max} - u_{min}}, \quad (11)$$

gdzie u_i^k to liczba iteracji bez zmiany najlepszej pozycji i -tej cząstki $\mathbf{pbest}_i$. Należy zauważyć, że w pracy [27], nu_i^k jest obliczane na podstawie najlepszej globalnej pozycji $\mathbf{gbest}$, natomiast w MFPSO nu_i^k jest obliczane na podstawie najlepszej lokalnej pozycji cząstki $\mathbf{pbest}_i$. Wierzchołki zbiorów rozmytych dla nf_i^k i nu_i^k zostały zdefiniowane jako $\mathbf{p} = [0,2, 0,45, 0,65, 0,9]$, $\mathbf{q} = [0,2, 0,45, 0,65, 0,9]$.

Reguły rozmyte dla ω są zdefiniowane w następujący sposób [27]

$nf_i^k \setminus nu_i^k$	B_1	B_2	B_3	B_4
A_1	PS	PM	PB	PB
A_2	PM	PM	PB	PR
A_3	PB	PB	PB	PR
A_4	PB	PB	PR	PR

(12)

W tabeli (12) $PS = 0,4$, $PM = 0,6$, $PB = 0,8$ i $PR = 1$. Reguły rozmyte dla c_1/c_2 są zdefiniowane jako [27]

$nf_i^k \setminus nu_i^k$	B_1	B_2	B_3	B_4
A_1	PR/PR	PB/PB	PB/PM	PB/PM
A_2	PB/PB	PM/PM	PM/PS	PS/PS
A_3	PB/PM	PM/PM	PS/PS	PS/PS
A_4	PM/PM	PM/PS	PS/PS	PS/PS

(13)

W (13) mamy $PS = 1,4$, $PM = 1,7$, $PB = 1,9$ i $PR = 2,2$. Dla przykładu, reguła R_{11} ma formę

$$\begin{aligned} R_{11} : & \text{IF } nf_i^k \in A_1 \text{ AND } nu_i^k \in B_1, \\ & \text{THEN } \omega = PS \text{ AND } c_1 = PR \text{ AND } c_2 = PR \end{aligned} \quad (14)$$

a reguła R_{44} ma formę

$$\begin{aligned} R_{44} : & \text{IF } nf_i^k \in A_4 \text{ AND } nu_i^k \in B_4, \\ & \text{THEN } \omega = PR \text{ AND } c_1 = PS \text{ AND } c_2 = PS \end{aligned} \quad (15)$$

Podobnie można interpretować pozostałe reguły.

Zaproponowany algorytm MFPSO został przetestowany na czterech powszechnie wykorzystywanych funkcjach testowych [29, 22] i porównany z pięcioma innymi wersjami PSO znanymi z literatury i omówionymi w pracy. Zastosowane funkcje testowe to Ackleya, Griewanka, Rastrigina i Rosenbrocka, natomiast wymiar problemu określono na $d = 10$ i $d = 30$.

Do oceny algorytmów zastosowano następujące miary:

- średnią wartość funkcji dopasowania uzyskaną przez algorytm (oznaczoną jako mfg),
- względny sukces (rs) [A1].

W celu porównania algorytmów przydzielano oceny za osiągnięcie określonych rezultatów. Oceny te zostały przypisane w taki sposób, aby najlepszy algorytm miał sześć punktów, a najgorszy jeden punkt. Po zsumowaniu ocen okazało się, że zaproponowany algorytm MFPSO okazał się najlepszy dla miary mfg , natomiast dla rs uzyskał przedostatni wynik. Należy jednak podkreślić, że w ocenie algorytmów optymalizacji najważniejszym kryterium jest uzyskana wartość funkcji dopasowania.

Opublikowano również pracę, która rozszerza eksperymenty przeprowadzone w ramach publikacji [A1]. Praca ta została opublikowana w materiałach konferencyjnych [C16]¹ i znajduje się na liście publikacji niewchodzących w skład głównego osiągnięcia naukowego.

4.3.4 Śledzenie ruchu

Badania opisane w tym rozdziale dotyczą opracowania metod śledzenia ruchu wykorzystujących algorytm optymalizacji rojem cząstek. Prace te są rozwinięciem badań prowadzonych w ramach doktoratu, które dotyczyły śledzenia ruchu postaci ludzkiej w środowisku wielokamerowym. Metody tego typu często nazywa się również bezmarkerowymi metodami przechwytywania ruchu (ang. *markerless motion capture*), w celu zaznaczenia głównej przewagi nad innymi rozwiązaniami umożliwiającymi przechwytywanie ruchu, które do działania wymagają założenia od kilku do kilkudziesięciu czujników lub specjalnych markerów.

Śledzenie ruchu płotkarza oraz estymacja parametrów kroku płotkowego

W pracy [A2] poruszono problem śledzenia ruchu człowieka na przykładzie zawodników pokonujących płotki w biegu na 110 m. Celem śledzenia ruchu postaci ludzkiej jest wyznaczenie aktualnej konfiguracji (zwanej również pozą) postaci ludzkiej, która jak najdokładniej odzwierciedla stan rzeczywisty. Należy zaznaczyć, że dokładne określenie pozy ciała człowieka na podstawie danych wizyjnych jest bardzo trudnym zadaniem [18]. Główne problemy to: ogromna przestrzeń poszukiwań, szumy występujące na obrazie, przesłonięcia poszczególnych części ciała oraz duża zmienność w wyglądzie śledzonych postaci i otoczeniu. W przypadku próby zastosowania systemów tego typu do estymacji pozy sportowców dochodzą dodatkowe trudności związane z dużą prędkością poruszania, a także z często występującymi pozami niemożliwymi do osiągnięcia przez osobę, która na co dzień nie trenuje danego sportu. Pomimo wymienionych problemów, ciągle trwają prace mające na celu udoskonalenie bezmarkerowych metody śledzenia ruchu


¹Publikacje z przedrostkiem „C” zamieszczono w Załączniku 4 w sekcji 2.1.

postaci ludzkiej. Dzieje się tak ponieważ metody te mają szereg zalet. Przede wszystkim nie wymagają noszenia specjalnego stroju, co jest bardzo istotne z punktu widzenia zastosowań w sporcie, gdzie istotna jest swoboda ruchu zawodników. Ponadto systemy są bardzo mobilne, kamery można zabrać właściwie w dowolne miejsce, a czas ustawienia i skonfigurowania systemu nie jest długi. Metody te są bardzo tanie w porównaniu do innych metod przechwytywania ruchu, koszt systemu sprowadza się do ceny zakupu kamer wizyjnych. Główną wadą jest mniejsza dokładność śledzenia w porównaniu do metod wykorzystujących pasywne i aktywne markery, czy czujniki.

Na podstawie dokonanej przeglądu literatury można zauważyć, że bezmarkerowe metody przechwytywania ruchu nie były wcześniej stosowane do estymacji parametrów kroku płotkowego i oceny techniki lekkoatletów. Najbliższa tematycznie praca naukowa została przygotowana przez Čoh [9] i dotyczyła zastosowania narzędzia APAS (*Ariel Performance Analysis System*) do przeprowadzenia analizy ruchu płotkarza podczas kroku płotkowego, jednak narzędzie to wymagało ręcznego zaznaczania segmentów szkieletu w kolejnych klatkach sekwencji. Z tego co mi wiadomo, do czasu opublikowania artykułu [A2], nie powstały również podobne rozwiązania umożliwiające śledzenie sportowców w innych dyscyplinach. Wynika to przede wszystkim ze stopnia zaawansowania prac nad metodami do śledzenia ruchu postaci ludzkich w oparciu o dane wizyjne. Pomimo wielu lat badań nad metodami tego typu, nadal większość prac dotyczy śledzenia podstawowych ruchów (chodzenie, bieganie, machanie rękami itp.), które są rejestrowane w warunkach laboratoryjnych [5, 18, 28, 30]. Dopiero w 2019 roku udostępniono bibliotekę OpenPose [7], co spowodowało wzrost zainteresowania badaniami mającymi na celu wykorzystanie wizyjnych metod estymacji konfiguracji postaci ludzkiej w zastosowaniach praktycznych.

W opracowanej metodzie śledzenia ruchu płotkarzy, wykorzystano metodę optymalizacji rojem cząstek oraz obrazy z jednej kamery. Zastosowanie tylko jednej kamery wprowadza dodatkową trudność ponieważ w takim przypadku trudniej oszacować odległości pomiędzy poszczególnymi częściami ciała, a także odległość od kamery. Do symulacji ruchu ludzkiego ciała oraz określenia pozy tj. pozycji i orientacji w przestrzeni oraz kątów pomiędzy segmentami modelu wykorzystano trójwymiarowy model postaci ludzkiej. Model ten jest oparty na kinematycznej strukturze drzewiastej składającej się z 11 segmentów reprezentowanych przez stożki ścięte [C26]. W proponowanym podejściu pozycja i -tej cząstki reprezentuje hipotetyczny stan (pozę) lekkoatlety. W algorytmach PSO używanych w śledzeniu ruchu człowieka inicjalizacja wszystkich cząstek w każdej klatce jest zwykle oparta na stanie (pozie) oszacowanym w czasie $t - 1$ (w poprzedniej klatce) [18][D4]². W proponowanej implementacji oprócz pozy z czasu $t - 1$ wykorzystywane są również cztery pozy pomocnicze, które są charakterystyczne dla wybranych punktów kluczowych kroku płotkowego (patrz P_2 , P_3 , P_4 i P_5 na rysunku 1). Oznacza to, że podczas inicjalizacji algorytmu używanych jest pięć pozycji, a każda z nich jest używana do inicjalizacji tej samej liczby cząstek. Podczas inicjalizacji nie jest wykorzystywana predefiniowana poza dla punktu P_1 , ponieważ jest ona bardzo podobna

²Publikacje z przedrostkiem „D” zamieszczono w Załączniku 4 w sekcji 2.1.



Rysunek 1: Punkty kluczowe w kroku płotkowym: P_1 — punkt w fazie przygotowania do odbicia, P_2 — punkt w fazie odbicia, P_3 — punkt w fazie lotu, P_4 — punkt w fazie lądowania, P_5 — punkt w fazie przygotowania do biegu

do pozy, z której algorytm rozpoczyna śledzenie (pozy w pierwszej klatce). Ta poza byłaby przydatna, w przypadku analizy sekwencji, w której lekkoatleta pokonywałby kilka płotków. Wprowadzona modyfikacja zwiększa prawdopodobieństwo poprawnego oszacowania pozy, gdy jedna z części ciała człowieka zostanie „zgubiona” przez algorytm (śledzenie nie powiodło się). Może to być spowodowane np. szybkim ruchem lub przesłonięciem.

Przy dostosowaniu algorytmu PSO do danego problemu kluczowe jest zdefiniowanie funkcji dopasowania, która pozwala określić, w jakim stopniu zaproponowane rozwiązanie odpowiada poszukiwanemu rozwiązaniu. W omawianym problemie funkcja dopasowania określa podobieństwo pomiędzy rzeczywistą i estymowaną pozą postaci ludzkiej. W zaproponowanej funkcji dopasowania wykorzystano obrazy z wydzieloną z obrazu sylwetką postaci ludzkiej oraz mapą odległości od krawędzi. Rysunek 2 przedstawia ideę obliczania funkcji dopasowania. Do wydzielenia sylwetki postaci ludzkiej (zob. rys. 2(c)) wykorzystano algorytm zaproponowany w pracy [37]. Drugi z obrazów wykorzystywanych w funkcji dopasowania, tj. mapa odległości od krawędzi (zob. rys. 2(e)), został wyznaczony na podstawie obrazu z wydzielonymi krawędziami (zob. rys. 2(b)), z którego usunięto krawędzie nienależące do śledzonej postaci (zob. rys. 2(d)). Następnie zrzutowane modele 3D (zob. rys. 2(g)) są porównywane z mapą odległości od krawędzi (zob. rys. 2(h)) i wydzieloną sylwetką (zob. rys. 2(i)).

Wartość funkcji dopasowania jest obliczana na podstawie równania:

$$f(\mathbf{x}) = 1 - (af_o(\mathbf{x}) + bf_e(\mathbf{x})), \quad (16)$$

gdzie $\mathbf{x}$ to poza postaci ludzkiej, a $a = 0,7$, $b = 0,3$ to współczynniki wagowe dobrane eksperymentalnie. Funkcja $f_o(\mathbf{x})$ definiuje stopień pokrycia pomiędzy wyrenderowanym modelem 3D i wydzieloną sylwetką, natomiast $f_e(\mathbf{x})$ jest wyznaczana poprzez porównanie krawędzi modelu 3D z obrazem zawierającym mapę odległości do najbliższej

krawędzi w pikselach.

Funkcja $f_o(\mathbf{x})$ jest zdefiniowana jako:

$$f_o(\mathbf{x}) = (1 - \alpha) \frac{\sum_p g(\mathbf{C}(p), \mathbf{R}(p))}{\sum_p u(\mathbf{C}(p))} + \alpha \frac{\sum_p g(\mathbf{C}(p), \mathbf{R}(p))}{\sum_p u(\mathbf{R}(p))}, \quad (17)$$


gdzie $\mathbf{C}$ to obraz z wyrenderowanym modelem 3D reprezentującym proponowane rozwiązanie, $\mathbf{R}$ to obraz referencyjny z wydzieloną sylwetką postaci ludzkiej (zob. rys. 2(c)), współczynnik α jest równy 0,5, a p to piksel obrazu. Funkcje $g(x, y)$ i $u(x)$ są zdefiniowane jako:

$$g(x, y) = \begin{cases} 1, & \text{if } x = y \text{ and } x \neq 0 \\ 0, & \text{otherwise} \end{cases}, \quad u(x) = \begin{cases} 1, & \text{if } x \neq 0 \\ 0, & \text{otherwise} \end{cases}. \quad (18)$$

Funkcja $f_e(\mathbf{x})$ jest zdefiniowana jako:

$$f_e(\mathbf{x}) = \frac{\sum_p \mathbf{C}_e(p) \cdot \mathbf{M}(p)}{\sum_p \mathbf{C}_e(p)}, \quad (19)$$

gdzie $\mathbf{C}_e$ to obraz binarny z wyrenderowanymi krawędziami modelu 3D, a $\mathbf{M}$ to mapa odległości od krawędzi (zob. rys. 2(e)), w której $\mathbf{M}(p) \in [0, 1]$. Wartość 0 oznacza, że piksel znajduje się poza mapą odległości, natomiast wartość 1, że piksel znajduje się na krawędzi.




Rysunek 2: Sposób wyznaczania funkcji dopasowania: (a) obraz wejściowy, (b) wydzielona krawędzie, (c) wydzielenie sylwetki, (d) krawędzie po operacji maskowania, (e) mapa odległości od krawędzi, (f) model 3D, (g) model 3D zrzutowany na obraz, (h) pokrycie modelu z mapą odległości od krawędzi, (i) pokrycie modelu z obrazem binarnym

Opracowany algorytm został przetestowany na 10 sekwencjach, na których zarejestrowano pokonywanie czwartego płotka w warunkach startowych biegu przez płotki na 110 m. W badaniach wzięło udział pięciu płotkarzy o różnym poziomie wytrenowania. Pośród zawodników znajdowali się czterokrotny wicemistrz Polski oraz dwukrotny młodzieżowy mistrz Polski. Po wyznaczeniu pozy śledzonej postaci dla kolejnych klatek, obliczono 21 parametrów geometrycznych (zob. rys. 1), które mogą zostać wykorzystane do oceny techniki pokonywania płotka przez zawodnika. Dobór parametrów został zrealizowany na podstawie przeglądu literatury [9] oraz w konsultacji z wieloletnim trenerem kadry narodowej w biegach przez płotki prof. dr. hab. Januszem Iskrą, który był członkiem zespołu badawczego. Wyniki śledzenia dla wybranej sekwencji przedstawiono na rysunku 3. Zrzutowany model 3D dość dobrze pasuje do sportowca na obrazie. Z przeprowadzonej analizy wynika, że algorytm zadowalająco wykrywa kończyny dolne, natomiast występują pewne problemy z oszacowaniem prawidłowej pozycji ramion. Problemy te wynikają głównie z przesłaniania niektórych części ciała i są niezwykle trudne do wyeliminowania przy użyciu obrazów z pojedynczej kamery.

Oprócz wizualnej oceny dokładności śledzenia obliczono również średni błąd bezwzględny (MAE) oraz średni błąd względny (MRE) dla wyznaczonych parametrów kroku płotkowego (zob. rys. 1). Dane odniesienia pozyskano poprzez ręczne dopasowanie modelu 3D do lekkoatletów na obrazach zawierających pięć punktów kluczowych dla analizy kroku płotkowego. Najmniejszy błąd dla parametrów odległościowych uzyskano dla parametru w_1 , dla którego błąd MRE wynosił 1% ($MAE = 25,8$ mm). Dla parametrów kątowych, najmniejszy błąd, równy 2,3% ($MAE = 2,9^\circ$), został uzyskany dla α_1 . Największy błąd zaobserwowano dla odległości pomiędzy środkiem ciężkości a stopą (x_4), jego wartość to $MRE = 139,2\%$ ($MAE = 100,9$ mm). Wartość błędu MRE może wydawać się duża, jednak jeśli wziąć pod uwagę wartość MAE i to, że śledzenie było realizowane w oparciu o dane z tylko jednej kamery, to w rzeczywistości tak nie jest. We wcześniejszych pracach [D4] uzyskiwano błąd na poziomie 50 mm analizując znacznie prostszy ruch (przejście przez scenę) i wykorzystując obrazy z czterech kamer. Dla pozostałych parametrów wartość MRE wynosiła 2,2% do 25,8%. Przygotowane oprogramowanie zostało zaimplementowane w języku C++. Do realizacji operacji na obrazach wykorzystano bibliotekę OpenCV.

Oprócz artykułu [A2], wstępne wyniki śledzenia opublikowano również w materiałach konferencyjnych i zaprezentowano na konferencjach międzynarodowych [C22],



Rysunek 3: Wyniki śledzenia dla jednej z sekwencji


[C26]. Ponadto w ramach kontynuacji badań zrealizowano śledzenie z wykorzystaniem urządzenia mobilnego [C15], a także w systemie wielokamerowym [C13], [C17].

Estymacja trajektorii lotu piłki i parametrów rzutu wolnego w koszykówce

W ramach publikacji [A3] opracowano metodę estymacji trajektorii lotu piłki i parametrów rzutu wolnego w koszykówce w oparciu o analizę obrazów z pojedynczej kamery. Ważną kwestią w sporcie jest analiza czynników, które wpływają na osiąganie najlepszych wyników sportowych. W każdej dyscyplinie sportu istnieją elementy, których wykonanie ma bezpośredni wpływ na końcowy wynik. Jednym z takich elementów w koszykówce jest rzut wolny, który jest bardzo ważny w tym sporcie. Analizując trajektorię lotu piłki oraz pewne parametry charakterystyczne można zbudować system, który będzie podpowiadał zawodnikowi co powinien poprawić w swoim rzucie, aby osiągnąć większą skuteczność. Prowadzone są prace badawcze mające na celu określenie, jakie parametry są najważniejsze podczas rzutu wolnego w koszykówce [3, 16]. Należy również wspomnieć o urządzeniach, które można wykorzystać do korekty techniki zawodników. Przykładem jest system *ShotLoc* [1] (*Hoops Innovation Ltd. LCC, Canada*), którego zadaniem jest optymalizacja położenia ręki gracza na piłce podczas rzutu wolnego. Z kolei *Noah Shooting System* [23] (*NOAH Basketball, Athens, Alabama, USA*), to system czasu rzeczywistego, który daje graczom natychmiastowe informacje o kącie lotu piłki i odległości do pierścienia kosza. Służy on do poprawy efektywności i budowania pamięci mięśniowej zawodników.

Głównym celem badań było opracowanie systemu do pomiaru i analiza wybranych parametrów trajektorii rzutów wolnych w koszykówce. System ten został oparty o algorytm PSO i dane wideo zarejestrowane przez pojedynczą kamerę. W ramach prac opracowano metody detekcji i śledzenia piłki, a także ponownej detekcji w przypadku zgubienia. Otrzymane wyniki śledzenia zostały porównane z wynikami uzyskanymi przez algorytm wykorzystujący filtr cząsteczkowy (ang. *Particle Filter*, PF) [11] zamiast PSO. Przeprowadzono również analizę wyestymowanych parametrów. Opracowany system został zaimplementowany z wykorzystaniem języka C++ i biblioteki OpenCV.

W zaproponowanym podejściu PSO został wykorzystany do śledzenia piłki na obrazie. Funkcja celu została zdefiniowana jako stosunek liczby pikseli w obiektach wydzielonych z tła, które znajdowały się w obrębie okręgu zdefiniowanego przez pozycję piłki i jej promień do liczby pikseli znajdujących się poza wspomnianym okręgiem. Do automatycznej detekcji piłki i redetekcji wykorzystano współczynnik cyrkularności oraz wielkość wydzielonego na obrazie obiektu. Ponadto wykorzystywano algorytm detekcji tła/pierwszego planu oraz metody morfologiczne. Wyestymowana trajektoria piłki została wykorzystana do obliczania parametrów rzutu wolnego. Następnie przeprowadzono analizę statystyczną rzutów chybianych i trafionych oraz wyznaczono zależności pomiędzy najważniejszymi parametrami. Opracowany algorytm detekcji i śledzenia piłki został przedstawiony w postaci schematu blokowego na rysunku 4, natomiast estymowane parametry zaprezentowano na rysunku 5. Na potrzeby estymacji parametrów na podstawie współrzędnych piłki na obrazie, opracowano procedurę kalibracji opartą




Rysunek 4: Schemat blokowy algorytmu detekcji i śledzenia piłki


o punkty charakterystyczne znajdujące się na boisku do koszykówki (linie, przecięcia linii, kosz, itp.). Ponadto założono, że piłka porusza się prostopadle do kamery, odległość piłki od kamery podczas lotu do kosza nie zmienia się, a zniekształcenia kamery są znikome. Przyjmując te założenia oraz biorąc pod uwagę odległości między punktami orientacyjnymi na obrazie, odpowiadającą im odległość w świecie rzeczywistym i pozycję piłki na obrazie, można oszacować parametry opisujące rzut wolny do kosza.

Opracowany system został przetestowany na 200 sekwencjach zawierających rzut wolny do kosza, nagranych przy pomocy kamery Basler Ace acA645-100gc. Rzuty były wykonywane przez 30 koszykarzy grających w II lidze koszykówki mężczyzn oraz zawodników Młodzieżowej Reprezentacji Polski. Przykładowe wyniki śledzenia zostały zaprezentowane na rysunku 6. W celu oceny opracowanego algorytmu śledzenia, dla 20 sekwencji wyznaczono dane odniesienia. Dane te zostały wyznaczone poprzez ręczne zaznaczenie pozycji piłki na poszczególnych klatkach sekwencji wideo. Algorytmy śledzące

(PSO i PF) zostały uruchomione po 10 razy dla każdej z sekwencji. Następnie w oparciu o dane odniesienia wyznaczono błędy $RMSE$. Testy zostały przeprowadzone dla pięciu konfiguracji algorytmów śledzących dobranych tak, aby liczba wywołań funkcji celu była taka sama. Dla większości konfiguracji algorytm PSO osiągnął znacznie lepsze wyniki, wyjątkiem była konfiguracja z najmniejszą liczbą cząstek, dla której błąd $RMSE$



Rysunek 5: Analizowane parametry rzutu wolnego w koszykówce; h_1 [m] – wysokość pomiędzy piłką i koszem, h_2 [m] – wysokość paraboli piłki, l_1 [m] – odległość pomiędzy pozycją piłki w pierwszej i drugiej fazie lotu, l_2 [m] – odległość pomiędzy pozycją piłki w drugiej i trzeciej fazie, v_1 [m/s] – prędkość piłki w pierwszej fazie, v_2 [m/s] – prędkość piłki w drugiej fazie, v_3 [m/s] – prędkość piłki w trzeciej fazie, α_1 [°] – kąt wznoszenia piłki w pierwszej fazie, α_2 [°] – kąt opadania piłki w drugiej fazie, α_3 [°] – kąt opadania piłki w trzeciej fazie



Rysunek 6: Śledzenie piłki w wybranych klatkach przykładowej sekwencji

algorytmu PF wynosił 9,89 pikseli, natomiast dla PSO błąd był równy 10,71 pikseli. Najlepsze wyniki ($RMSE = 5,82$ pikseli) osiągnął algorytm PSO dla konfiguracji 50 cząstek i 10 iteracji.

W ramach badań została również przeprowadzona analiza statystyczna wyznaczonych parametrów. Parametry zostały obliczone dla 200 sekwencji, które zawierały 155 rzutów zakończonych trafieniem oraz 45 rzutów nietrafionych. Do sprawdzenia istotności statystycznej parametrów pomiędzy trafionymi i nietrafionymi rzutami wykorzystano test t-Studenta. Przeprowadzona analiza wykazała, że dla parametrów h_1 , l_2 , α_2 i α_3 istnieje istotna statystycznie różnica pomiędzy rzutami trafionymi i nietrafionymi.

Zaproponowana metoda analizy trajektorii piłki w rzutach wolnych może być w praktyce wykorzystywana przez trenerów w procesie szkolenia jako narzędzie wspomagające trening rzutów wolnych w koszykówce. Trenerzy korzystający z tego systemu będą mogli monitorować trajektorię lotu piłki oraz parametry rzutu wolnego, co może pomóc przy korekcie rzutów wykonywanych przez zawodników i w rezultacie wspomóc wyuczenie prawidłowych nawyków motorycznych. System może również przyczynić się do wyeliminowania niektórych błędów technicznych wykonywanych przez zawodników. Zaprezentowaną w ramach prac badawczych ideę systemu skonsultowano z trenerem koszykówki. Oprócz artykułu [A3], wstępne wyniki śledzenia opublikowano również w materiałach konferencyjnych i zaprezentowano na konferencji międzynarodowej [C23].

Śledzenie wielu dronów

W publikacji [A10] przedstawiono metodę śledzenia wielu dronów w oparciu o analizę obrazów z systemu wielokamerowego. W ostatnim czasie znacznie wzrosło wykorzystanie dronów, określanych również jako bezzałogowe statki powietrzne (ang. *Unmanned Aerial Vehicles*, UAV), zarówno w zastosowaniach cywilnych, jak i wojskowych. Z tego też powodu wzrosło zainteresowanie badaczy różnego rodzaju zagadnieniami związanymi z dronami, w tym problemami śledzenia tych pojazdów latających. Rozwój metod śledzenia dronów napędzany jest głównie potrzebą opracowania skutecznych systemów wykrywania, identyfikacji i unieszkodliwiania dronów [19]. Są to przede wszystkim zastosowania militarne i związane z bezpieczeństwem. Istnieją jednak również inne zastosowania metod śledzenia dronów, m.in. gry wykorzystujące rzeczywistość rozszerzoną (ang. *Augmented Reality*, AR) [14].

Z przeprowadzonego przeglądu literatury wynika, że brakuje opublikowanych badań poświęconych problematyce śledzenia wielu dronów w przestrzeni trójwymiarowej. Ponadto nie znaleziono publikacji, w których mierzono dokładność śledzenia drona 3D. O ile mi wiadomo, również algorytm PSO nie był wcześniej używany do śledzenia dronów. W przypadku zastosowań powiązanych z dronami, PSO jest najczęściej wykorzystywany w kontrolerach lotu [34]. W ramach badań zaprezentowanych w pracy [A10] opracowano metodę śledzenia wielu dronów, która w procesie estymacji pozycji w trójwymiarowej przestrzeni wykorzystuje algorytm PSO oraz obrazy z systemu wielokamerowego.

Zaproponowana metoda śledzenia dronów opiera się na algorytmie PSO, danych z systemu wielokamerowego i metodach przetwarzania obrazu wykorzystywanych do

wydzielenia dronów z obrazu. Aby oszacować dokładną pozycję dronów w przestrzeni 3D, system wymaga co najmniej trzech kamer, rozmieszczonych wokół obszaru, po którym poruszają się drony. Strukturę wykorzystywanej w procesie śledzenia cząstki przedstawiono na rysunku 7. W funkcji dopasowania, w celu ekstrakcji sylwetek dronów, wykorzystano algorytm wykrywania tła/pierwszego planu zaproponowany przez Zivkovic i van der Heijden [37] i zaimplementowany w bibliotece OpenCV. Dodatkowo uzyskane w ten sposób obrazy poddawane są operacjom morfologicznym w celu usunięcia szumów i poprawy wydzielonych sylwetek. W kolejnym kroku hipotetyczne pozycje dronów, wygenerowane przez algorytm PSO są rzutowane do dwuwymiarowej przestrzeni obrazu, a następnie wyznaczane są prostokąty określające wielkość i pozycję dronów na obrazie z danej kamery. Mając prostokąty reprezentujące drony i sylwetki rzeczywistych dronów, oblicza się ich stopień pokrycia, a następnie wyliczana jest średnia wartość pokrycia dla wszystkich dronów na obrazie. Na koniec otrzymane wartości są uśredniane dla wszystkich kamer. Proces obliczania funkcji dopasowania dla kamery c można przedstawić przy pomocy równania:


$$f_c(\mathbf{x}) = \frac{1}{n} \sum_{d \in \mathbf{x}} g(\mathbf{I}_c(\text{box}_{c,d}))/\text{size}(\text{box}_{c,d}), \quad (20)$$

gdzie $\mathbf{I}_c$ to obraz z wydzielonym dronami na kamerze c , n to liczba śledzonych dronów, d to dron, którego pozycja jest zdefiniowana w cząstce $\mathbf{x}$ ($\mathbf{x}$ zawiera pozycje wszystkich dronów), $\text{box}_{c,d}$ to prostokąt definiujący drona d na obrazach z kamery c , a $\mathbf{I}_c(\text{box}_{c,d})$ jest częścią obrazu reprezentującą obszar zainteresowania określony przez $\text{box}_{c,d}$. Funkcja $g(\mathbf{I})$ jest zdefiniowana w następujący sposób:

$$g(\mathbf{I}) = \sum_p u(\mathbf{I}(p)), \quad u(x) = \begin{cases} 1, & \text{if } x > 0 \\ 0, & \text{otherwise} \end{cases}, \quad (21)$$

gdzie p jest pikselem na obrazie $\mathbf{I}$.

Opracowana metoda śledzenia wielu dronów została przetestowana na pięciu sekwencjach wideo z różną liczbą dronów. Wykorzystywany zbiór danych składał się z trzech sekwencji symulacyjnych (zawierających dwa, cztery lub 10 dronów) oraz dwóch sekwencji rzeczywistych (jeden dron). Jakość śledzenia oceniono, analizując zarówno obrazy prezentujące dokładność śledzenia, jak i tabele z uzyskanymi błędami śledzenia. Eksperymenty uwzględniały różne liczby cząstek i iteracji algorytmu PSO. Czas estymacji pozycji dronów dla pojedynczej klatki wynosił od 0,02 do 1 sekundy w zależności od konfiguracji algorytmu, liczby dronów i liczby kamer. Obliczenia wykonano



Rysunek 7: Struktura cząstki


na stacji roboczej wyposażonej w procesor Intel(R) Core(TM) i7-11800H oraz 64GB RAM. Implementacja zaproponowanej metody została zrealizowana w języku C++ z wykorzystaniem biblioteki OpenCV. Ponadto przygotowano skrypty pomocnicze (kalibracja kamer, odczyt danych z systemu przechwytywania ruchu, obliczenie i wizualizacja błędów) w języku Python.

Przykładowe wyniki śledzenia dla sekwencji symulacyjnych przedstawiono na rysunku 8, natomiast uzyskane błędy w tabeli 1. Tabela zawiera średnią wartość błędu $\bar{x}$ i odchylenie standardowe σ obliczone dla poszczególnych sekwencji. Wyniki zostały uśrednione dla 10 przebiegów algorytmu śledzącego. W zależności od konfiguracji algorytmu i sekwencji, uzyskany średni błąd śledzenia waha się od 0,078 m do 0,482 m. Zgodnie z oczekiwaniami najlepsze wyniki zostały uzyskane dla konfiguracji z największą liczbą cząstek (100) i iteracji (70). Najmniejszy błąd śledzenia wynoszący 0,078 m uzyskano dla sekwencji S2, w której śledzone były cztery drony. Najgorsze wyniki uzyskano dla sekwencji S3 (0,197–0,482 m), co wynika przede wszystkim z dużej liczby śledzonych dronów, których jest 10. W przypadku rzeczywistych sekwencji otrzymane błędy są zbliżone do uzyskanych dla sekwencji symulacyjnych i mieszczą się w przedziale od 0,101 do 0,124 m. Wydawać by się mogło, że dla pojedynczego drona błędy powinny być mniejsze, gdyż dla sekwencji symulacyjnych z dwoma i czterema dronami otrzymano błędy rzędu 0,08 m. Należy jednak zauważyć, że w przypadku sekwencji rzeczywistych występują dodatkowe błędy związane z niedokładnością systemu przechwytywania ruchu ³, błędami synchronizacji oraz błędami kalibracji.

Tabela 1: Błędy śledzenia uzyskane dla sekwencji S1, S2 i S3

l. cząst.	l. iter.	S1		S2		S3	
		$\bar{x}$ [m]	σ [m]	$\bar{x}$ [m]	σ [m]	$\bar{x}$ [m]	σ [m]
30	30	0,2525	0,3101	0,3567	0,5006	0,4676	0,3745
	50	0,1960	0,2177	0,2207	0,2586	0,3266	0,2463
	70	0,0857	0,0337	0,0965	0,1058	0,2670	0,2118
50	30	0,1419	0,1267	0,1972	0,2804	0,4823	0,3980
	50	0,1408	0,1261	0,1095	0,1293	0,2917	0,2212
	70	0,0859	0,0345	0,1065	0,1359	0,2267	0,1542
100	30	0,1413	0,1263	0,1804	0,2428	0,2970	0,2220
	50	0,1407	0,1261	0,0890	0,0925	0,2202	0,1686
	70	0,0859	0,0343	0,0784	0,0827	0,1972	0,1138

³W przypadku sekwencji rzeczywistych, do pozyskania pozycji dronów na scenie, wykorzystano system przechwytywania ruchu firmy Vicon.



Rysunek 8: Wyniki śledzenia dronów w wybranych klatkach sekwencji S3, liczba cząstek: 100, liczba iteracji: 70

4.3.5 Identyfikacja osób na podstawie chodu

Badania opisane w tym rozdziale dotyczą opracowania i zastosowania hybrydowych metod klasyfikacji do identyfikacji osób na podstawie chodu. Wyniki prac zostały przedstawione w artykule [A4]. Chód jest przejawem stylu poruszania się danej osoby, stąd jego rozpoznanie oznacza identyfikację osoby po jej sposobie chodzenia. Główne zalety zastosowania chodu w uwierzytelnianiu biometrycznym to: nieinwazyjność, możliwość zastosowania na odległość, trudność w ukryciu oraz brak konieczności współpracy rozpoznawanej osoby. Te zalety sprawiają, że jest to dobra cecha dla systemów nadzoru wizyjnego [24]. Wydajność rozpoznawania przez istniejące metody jest jednak ograniczona wpływem dużej liczby czynników towarzyszących wpływających zarówno na wygląd, jak i dynamikę chodu, np. zmienność obuwia i odzieży, zmienność punktu widzenia, zmiany w charakterystyce powierzchni, na której ruch występuje, noszenie toreb i bagaży, urazy wpływające na ruch itd. Są to powody, dla których rozpoznawanie chodu było intensywnie badane w ostatnich latach.

Z wykonanego przeglądu literatury wynika, że większość badań wykorzystująca podejście tradycyjne (tj. takie, w którym występuje wyraźne rozdzielenie deskryptorów chodu i stosowanych modeli klasyfikacji) poświęcona jest opracowywaniu deskryptorów chodu [10, 24, 35], a nie wprowadzaniu nowych metod klasyfikacji. W ramach zrealizowanych prac zaproponowano metody hybrydowe, które łączą techniki RDA [15] i inteligencji roju do rozpoznawania chodu. W proponowanym podejściu PSO, GWO [26] i WOA [25] są używane do dostrajania wag obserwacji i hiperparametrów modelu RDA. Z tego co mi wiadomo, algorytmy GWO i WOA nie były wcześniej wykorzystywane do tego celu, a algorytm PSO w połączeniu z RDA nie był stosowany do rozpoznawania chodu. Proponowane metody zostały przebadane na zbiorze danych zawierającym 414


cykli chodu należących do 32 różnych osób [C6]. Wspomniany zbiór danych został przygotowany i udostępniony społeczności naukowej w ramach prac, których byłem współautorem. Prace te dotyczyły zastosowania danych z bezmarkerowych systemów przechwytywania ruchu do rozpoznawania osób.

Budowanie modelu klasyfikacji obejmuje dwa główne etapy, są to trenowanie i testowanie. W tym celu baza danych sekwencji chodu jest podzielona na trzy zbiory: uczący, walidacyjny i testowy (zob. rys. 9). Należy zauważyć, że w pracy [C6] zdefiniowano tylko dwa zbiory: uczący i testowy. Jednak w proponowanym podejściu, ze względu na przeprowadzaną optymalizację parametrów klasyfikatora, z danych uczących wyodrębniony został dodatkowy zbiór walidacyjny. Zbiór danych walidacyjnych jest używany do oceny dopasowanego modelu podczas uczenia hiperparametrów modelu. Po zbudowaniu modelu zestaw testowy jest używany do testowania, to znaczy do przewidywania wyników klasyfikatora dla danych, które nigdy nie były używane w fazie uczenia. Trening modeli realizowany jest przy użyciu jednej z zaproponowanych metod hybrydowych, w której techniki inteligencji roju optymalizują wagi obserwacji i hiperparametry RDA. Podczas optymalizacji wykorzystywana jest następująca funkcja celu, wyrażona jako wartość błędu klasyfikacji:

$$\text{funkcja celu} = \frac{\text{liczba błędnie sklasyfikowanych próbek}}{\text{liczba wszystkich próbek}}, \quad (22)$$

gdzie próbki są brane ze zbioru walidacyjnego. Wartość funkcji celu jest minimalizowana z wykorzystaniem jednej z metod inteligencji roju tj. PSO, GWO lub WOA. Po zbudowaniu klasyfikatora RDA, jego skuteczność jest określana przy pomocy współczynnika CCR (ang. *Correct Classified Ratio*), który jest zdefiniowany jako stosunek prawidłowo sklasyfikowanych próbek do całkowitej liczby próbek w podzbiorze testowym.

Ideę integracji metod inteligencji roju z klasyfikatorem RDA zilustrowano na rysunku 10. Rysunek ten przedstawia w formie schematu blokowego główne etapy optymalizacji modelu RDA z wykorzystaniem algorytmów roju oraz metodę wyznaczania funkcji



Rysunek 9: Idea budowy modelu klasyfikacji RDA

celu. Zadaniem metod PSO, GWO i WOA jest dobór następujących parametrów RDA:


- $w_1, w_2, \dots, w_n$ — wagi obserwacji,
- δ — próg współczynnika liniowego,
- γ — parametr do regularyzacji macierzy kowariancji predyktorów,

gdzie n to liczba obserwacji w zbiorze uczącym. W celu wykonania optymalizacji, wagi obserwacji oraz hiperparametry (δ , γ) umieszcza się jako elementy wektora agenta (kandydata), który ma postać

$$\overline{[w_1 | w_2 | \dots | w_n | \delta | \gamma]} \quad (23)$$

Na początku algorytmu agenci podlegają inicjalizacji (zob. rys. 10). W kolejnym kroku obliczana jest wartość funkcji celu dla wszystkich agentów. Następnie sprawdzany jest warunek stopu, jeśli nie zostanie osiągnięty, agenci są aktualizowani i wyliczana jest wartość funkcji celu. Algorytm optymalizacji generuje wiele hipotetycznych rozwiązań (które są reprezentowane przez agentów), a najlepsze rozwiązanie jest wybierane w procesie optymalizacji. Operacje te są powtarzane aż do osiągnięcia warunku zatrzymania. W bloku funkcji celu, model RDA jest określany dla parametrów proponowanych przez agenta oraz danych uczących. Wynik tego modelu jest następnie obliczany na podstawie danych walidacyjnych, a wartość funkcji celu wyznaczana jest na podstawie wzoru (22). Po zakończeniu optymalizacji wyznaczone parametry klasyfikatora RDA znajdują się w wektorze agenta, który jest najlepszy w roju i są zwracane w bloku „Return the global best solution” (zob. rys. 10). Na podstawie tych parametrów obliczana jest wartość współczynnika CCR dla danych testowych.

W tabeli 2 przedstawiono wyniki klasyfikacji chodu dla trzech zaproponowanych metod (RDA-PSO, RDA-GWO i RDA-WOA), liniowej analizy dyskryminacyjnej (LDA)



Rysunek 10: Idea integracji metod wykorzystujących inteligencję roju z RDA

Tabela 2: Wyniki klasyfikacji - CCR [%]

Eksperyment	k NN [C6]	NB [C6]	SMO [C6]	MLP [C6]	LDA	RDA-PSO	RDA-GWO	RDA-WOA
1: Set #1	47,44	55,77	67,95	80,13	45,51	87,05	86,28	86,92
2: Set #2	37,93	56,90	63,79	75,86	79,31	85,34	84,48	84,48
3: Set #3	38,71	70,97	67,74	77,42	93,55	88,39	93,55	93,55
4: Set #4	56,92	79,69	84,31	89,85	91,99	95,07	95,39	95,09

oraz wybranych metod klasycznych (k -najbliższych sąsiadów (k NN), naiwny klasyfikator Bayes’a (NB), maszyna wektorów nośnych z minimalną optymalizacją sekwencyjną (SMO) i perceptron wielowarstwowy (MLP)). Zbiory, na których zostały przeprowadzone eksperymenty (Set #1–#4), różniły się pod względem liczby próbek w poszczególnych podzbiorach (treningowym, walidacyjnym i testowym), a także rodzajem tych próbek (zmienione ubranie, niesiony plecak itp.). Dokładny opis przeprowadzonych eksperymentów zamieszczono w publikacji [A4]. Analizując wyniki zaprezentowane w tabeli 2 można zauważyć, że w Eksperymentach 1 i 2 zaproponowana przez autorów metoda RDA-PSO ma najwyższy wskaźnik CCR. W Eksperymentach 3, który dotyczył ubrania z plecakiem, trzy z analizowanych metod (LDA, RDA-GWO, RDA-WOA) osiągnęły ten sam CCR na poziomie 94%. W ostatnim eksperymencie ponownie najlepsza okazała się metoda zaproponowana przez autorów, w tym przypadku łącząca RDA z GWO. Całość badań została zrealizowana w środowisku Matlab.

Zagadnieniami związanymi z rozpoznawaniem osób zajmowałem się również w ramach prac [C6], [C7], [C24], [C25], [D2], [D3] i [D11].

4.3.6 Uczenie nadzorowane systemów rozmytych Takagi-Sugeno

W ramach prac [A5], [A6], [A7], [A8] i [A9] prowadzono badania mające na celu opracowanie hybrydowych metod uczenia systemów rozmytych. W pracach tych mój główny wkład polegał na opracowaniu sposobu uczenia poprzedników reguł systemu rozmytego za pomocą optymalizacji metaheurystycznych (w tym algorytmu PSO). Ponadto jestem współautorem opracowanych metod hybrydowych do uczenia systemów rozmytych Takagi-Sugeno. W pracach [A5], [A6] i [A8] wspomniane metody zostały zastosowane do aproksymacji funkcji, w artykule [A7] do klasyfikacji, natomiast ostatnia z wymienionych publikacji [A9] poruszała problem predykcji szeregów czasowych.

Uczenie systemów rozmytych T-S odbywa się na podstawie par obserwacji wejście/wyjście. Proces ten składa się z dwóch głównych etapów: identyfikacji struktury i estymacji parametrów. Identyfikacja struktury polega zazwyczaj na określeniu liczby reguł rozmytych. Natomiast podczas estymacji parametrów wyznacza się parametry zbiorów rozmytych zdefiniowanych dla wejść systemu, a także współczynniki funkcji w następnikach reguł. Zadania te mogą być rozwiązywane z wykorzystaniem różnorodnych technik optymalizacji, takich jak np. metody metaheurystyczne, czy metoda najmniejszych kwadratów.

Uczenie hybrydowe z wykorzystaniem optymalizacji rojem cząstek i regularizowanej metody najmniejszych kwadratów

W ramach publikacji [A5] opracowano metodę uczenia hybrydowego dla systemu Takagi-Sugeno wysokiego rzędu. Metoda ta wykorzystuje algorytm optymalizacji rojem cząstek oraz regularizowaną metodę najmniejszych kwadratów. Na podstawie wykonanego przeglądu literatury można zauważyć, że dotąd stosowano tylko systemy rozmyte zerowego lub pierwszego rzędu. Z tego powodu zaproponowano zastosowanie wielomianów wysokiego rzędu w następnikach reguł. Zaletą takiego rozwiązania jest większa elastyczność w uczeniu systemów rozmytych, na przykład przy doborze liczby reguł. Ponadto, oprócz funkcji gaussowskich, wykorzystano funkcje trójkątne, które zamiast funkcji eksponencjalnej, używają prostych funkcji liniowych.

Należy podkreślić, że w spotykanych w literaturze metodach uczenia systemów rozmytych często stosuje się stałą liczbę reguł. Zazwyczaj dobór liczby reguł odbywa się za pomocą metod klasteryzacji, co wymaga dodatkowego mechanizmu w algorytmie uczenia. W zaproponowanym rozwiązaniu, liczba reguł dobierana jest za pomocą metody walidacji krzyżowej [4]. Ponadto, w publikacjach, w których do określenia parametrów systemu wykorzystywano regresję, nie stosowano regresji regularizowanych (z wyjątkiem pracy [6]). Z tego powodu, zaproponowano użycie regresji grzbietowej, która umożliwia rozważanie problemów źle uwarunkowanych, na przykład takich gdzie liczba obserwacji jest mała.

W pracy rozważono system rozmyty T-S z jednym wejściem x i jednym wyjściem y , który jest opisywany przez r rozmytych reguł wnioskowania z funkcjami wielomianowymi w następnikach reguł. Reguły mają następującą postać:

$$R_j : \text{IF } x \in A_j(x) \text{ THEN } y = w_{mj}x^m + \dots + w_{1j}x + w_{0j}. \quad (24)$$


Do wyznaczenia parametrów zbiorów A_j , tzn. położenia i kształtu, wykorzystano algorytm PSO, natomiast współczynniki wielomianów w następnikach reguł otrzymano przy pomocy regresji grzbietowej (ang. *ridge regression*) [17]. Ideę działania opracowanej metody, nazwanej PSO-BLS, przedstawiono na rysunku 11. Każda cząstka w roju zawiera hipotetyczne parametry poszukiwanych zbiorów. W kolejnych iteracjach algorytmu PSO, cząstki poruszają się w przestrzeni poszukiwań, generując nowe zbiory rozwiązań kandydujących. Najlepsze rozwiązanie uzyskuje się minimalizując funkcję celu określoną jako pierwiastek błędu średniokwadratowego [21, 32]:

$$\text{RMSE}_T = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}, \quad (25)$$

gdzie $y_i - \hat{y}_i$ jest błędem pomiędzy obserwacją a wynikiem modelu rozmytego.

W przypadku trójkątnych zbiorów rozmytych cząstka zawiera środki funkcji przynależności i ma następującą strukturę:

$$\overline{p_2 \mid p_3 \mid \dots \mid p_{r-2} \mid p_{r-1}} \quad (26)$$



Rysunek 11: Idea metody PSO-BLS

W zaproponowanym rozwiązaniu założono, że środki p_1 i p_r są znane i nie są wyznaczane przez PSO, dlatego liczba parametrów jest równa $r - 2$. W przypadku zbiorów gaussowskich, cząstki zawierają środki, tak jak w przypadku (26), oraz dodatkowo szerokości dla wszystkich funkcji przynależności:

$$\overline{p_2 \mid p_3 \mid \dots \mid p_{r-2} \mid p_{r-1} \mid \sigma_1 \mid \sigma_2 \mid \dots \mid \sigma_{r-2} \mid \sigma_r} \quad (27)$$

W tym przypadku, liczba optymalizowanych parametrów jest równa $2r - 2$.

W omawianej pracy najlepszy model T-S był wybierany za pomocą walidacji krzyżowej typu "wyrzucić-jeden" (ang. *leave-one-out cross-validation*, LOOCV) [4]. W metodzie tej liczba testów jest równa liczbie obserwacji i jedna para tworzy parę walidacyjną. Zdecydowano się wykorzystać LOOCV, ponieważ zbiór danych jest mały. Dla większych zbiorów, można użyć k -krotnej walidacji krzyżowej (ang. *k-fold cross-validation*). Jakość modelu rozmytego w metodzie LOOCV jest oceniana za pomocą pierwiastka średniej sumy kwadratów błędów.

Jako przykłady zastosowania uczenia hybrydowego systemu T-S rozważono pewne funkcje nieliniowe jednej zmiennej. Przykładowe wyniki, uzyskane w jednym z ekspery-

mentów, przedstawiono w tabelach 3 i 4. Uzyskane błędy zostały porównane z wynikami uzyskanymi przez metody zaczerpnięte z literatury. Przeprowadzona analiza wykazała, że zaproponowana metoda z gaussowskimi funkcjami przynależności ma najmniejszy błąd dopasowania (zob. tabela 3). W tabeli 4 zaprezentowano parametry modelu, który uzyskał najmniejszy błąd dopasowania.

Zastosowanie regresji rzadkich w uczeniu hybrydowym systemów rozmytych wysokiego rzędu

W artykule [A8] poruszono problem uczenia systemów T-S wysokiego rzędu z zastosowaniem optymalizacji rojem cząstek [12, 20] i regresji rzadkich [31]. Rozważono systemy o jednym wejściu i wyjściu z gaussowskimi zbiorami rozmytymi w poprzednikach reguł i wielomianami wysokiego rzędu w ich następnikach. Zaproponowana metoda uczenia może być stosowana w dwóch wariantach: bez optymalizacji lub z optymalizacją za pomocą PSO. W wariancie pierwszym zbiory rozmyte są znane, natomiast do wyznaczenia współczynników wielomianów wykorzystano zwykłą regresję najmniejszych kwadratów (ang. *Ordinary Least Squares* (OLS)), regresję grzbietową lub regresję rzad-

Tabela 3: Porównanie uzyskanych błędów dopasowania oraz liczby parametrów

Algorytm	RMSE _T	Poprzedniki	Następniki
LS-GRBFNFIS [32]	8,430e-02	—	—
LW-GRBFNFIS [32]	8,700e-03	—	—
PSO-RLSE [21]	5,290e-04	12	27
LW-GRBFNFIS [36]	3,320e-02	—	—
BLS (triang)	5,516e-02	—	27
BLS (gauss)	2,931e-02	—	27
PSO-BLS (triang)	1,098e-04	7	27
PSO-BLS (gauss)	9,072e-06	16	27

Tabela 4: Parametry modelu, który uzyskał najmniejszy błąd dopasowania w tabeli 3

Reguła	p	σ	w_2	w_1	w_0
R_1	-8,000	2,356	881,9	666,6	342,6
R_2	-5,906	1,485	5,720	1,948	0,6479
R_3	-5,767	2,446	-24350	14560	14270
R_4	-2,361	0,9911	166,3	51,78	15,92
R_5	0,5223	0,5000	-147,8	-88,37	-41,91
R_6	-0,3668	0,5536	-0,9968	-0,3998	-0,1548
R_7	-1,589	0,5000	-2,150e-10	-7,299e-11	-2,475e-11
R_8	10,59	3,996	-71,42	710,9	-7,621
R_9	12,00	7,829	92,41	-1231,1	2898

kie). W drugim z wymienionych wariantów zastosowano metodę hybrydową, w której PSO wyznacza zbiory rozmyte, natomiast OLS, regresja grzbietowa i regresje rzadkie wyznaczają wielomiany. Z tego co wiem, jest to pierwsze zastosowanie regresji rzadkich do uczenia systemów rozmytych.

Regresje zastosowane w pracy są rzadkie, oznacza to, że pewne współczynniki modelu rozmytego są równe zero. Taki model jest bardziej zwarty i prostszy w interpretacji. Dodatkową zaletą regresji rzadkich jest zapewnienie regularyzacji modelu, dzięki czemu metody te mogą być stosowane w problemach źle uwarunkowanych. Taka sytuacja może wystąpić wtedy, gdy liczba obserwacji jest mniejsza od liczby zmiennych. W zaproponowanym rozwiązaniu przebadano następujące regresje rzadkie:

- *forward selection* (FS) [31],
- *least angle regression* (LAR) [13, 31],
- *least absolute shrinkage and selection operator* (LASSO) [31, 33],
- *elastic net regression* (ENET) [31, 38].

W pracy najlepszy model wybierano za pomocą metody walidacyjnej z użyciem zaproponowanego wskaźnika jakości. Minimalizacja wskaźnika jakości umożliwia wybór modelu, w którym zachowany jest pewien kompromis pomiędzy jego dokładnością a rzadkością. Tabela 5 przedstawia przykładowy model wygenerowany przez algorytm PSO-ENET w jednym z eksperymentów. Przeprowadzone badania pokazały, że: a) wykorzystanie regresji rzadkich i optymalizacji rojem cząstek może zredukować błąd walidacyjny, b) zastosowanie regresji rzadkich może uprościć model poprzez wyzerowanie pewnych współczynników.

Kontynuacją pracy [A8] jest publikacja [A6], w której poruszono problem aproksymacji funkcji dwóch zmiennych. Do uczenia modeli rozmytych, oprócz algorytmu PSO, zastosowano także inne metody metaheurystyczne, takie jak algorytm genetyczny i symulowane wyżarzanie.

Tabela 5: Parametry układu rozmytego uzyskane przez PSO-ENET w eksperymencie 3

Reguła	p	σ	w_2	w_1	w_0
R_1	0	0,2139	0	14,51	-2,028
R_2	0,8145	0,1	0	0	126,3
R_3	0,0090	0,9261	-28,92	-33,44	0
R_4	0,7227	0,1	-81,64	0	0
R_5	0,8748	0,1	-108,1	0	0
R_6	0,7960	0,1356	0	0	0
R_7	0,6655	0,1225	17,93	0	-10,26
R_8	0,5463	0,2385	-19,69	0	30,78
R_9	1	0,1	32,53	0	32,71

Klasyfikacja z wykorzystaniem rozmytego system T-S uczonego przy pomocy metaheurystycznych algorytmów optymalizacji oraz regresji rzadkich

W publikacji [A7] zaprezentowano propozycję nowego modelu klasyfikacji nazwanego rzadkim klasyfikatorem rozmytym (ang. *Sparse Fuzzy Classifier*, SFC). Model ten wykorzystuje rzadki system rozmyty T-S ze zbiorami rozmytymi Gaussa w poprzednikach i wielomianami pierwszego rzędu w następnikach reguł rozmytych. Do wyznaczenia wejściowych zbiorów rozmytych, zastosowano metaheurystyczne metody optymalizacji (PSO, algorytm genetyczny (ang. *Genetic Algorithm*, GA), algorytm symulowanego wyżarzania (ang. *Simulated Annealing*, SA) lub algorytm wyszukiwania wzorca (ang. *Pattern Search*, PS)). Aby otrzymać współczynniki wielomianów w regułach rozmytych wykorzystano regresję rzadką ENET. Techniki optymalizacji operowały na wektorze zawierającym parametry Gaussowskich funkcji przynależności i modelu regresji:

$$\overline{p_1 \mid \dots \mid p_\rho \mid q_1 \mid \dots \mid q_\rho \mid \sigma_1 \mid \dots \mid \sigma_\rho \mid \delta_1 \mid \dots \mid \delta_\rho \mid \lambda} \quad (28)$$

gdzie $p_1, \dots, p_\rho, q_1, \dots, q_\rho$ to środki funkcji przynależności dla wejść, $\sigma_1, \dots, \sigma_\rho, \delta_1, \dots, \delta_\rho$ to szerokości tych funkcji, ρ jest liczbą zbiorów rozmytych, a λ to współczynnik regularyzacji. Zaproponowane modele klasyfikacji zostały przebadane na dwóch zbiorach danych znanych z literatury. Przykładowe wyniki uzyskane dla zbioru z kwiatami irysów przedstawiono w tabeli 6. Przeprowadzone eksperymenty potwierdziły użyteczność opracowanych metod do rozwiązywania problemów klasyfikacji. Metody SFC uzyskały lepsze wyniki niż klasyczne metody klasyfikacji, a zastosowanie regresji rzadkich spowodowało znaczne uproszczenie modeli rozmytych.

Predykcja szeregów czasowych z wykorzystaniem rozmytego system T-S uczonego przy pomocy metaheurystycznych algorytmów optymalizacji, regresji rzadkiej i etykiet reguł

Ostatnia z prac [A9], w której zastosowano opracowane metody uczenia systemów rozmytych, poruszała problem predykcji szeregów czasowych. W pracy tej do identyfikacji modelu rozmytego T-S wykorzystano algorytmy optymalizacji (PSO, GA, SA i PS), a także regresje rzadkie (ang. *Sparse Regression*, SR). Ponadto do części wprowadzono dodatkowy parametr nazwany „etykietą” (ang. *label*) reguły, który umożliwiał dezaktywację danej reguły. Wygenerowane modele zostały przebadane na reprezentatywnych zbiorach danych spotykanych w literaturze. Wyniki eksperymentów pokazują, że zastosowane metody mogą ulepszyć modele rozmyte poprzez zerowanie części ich współczynników i usunięcie niepotrzebnych reguł. Przykładowe rozwiązanie uzyskane w Eksperymentcie 1 przedstawiono w tabeli 7. W badaniu tym najlepsze wyniki uzyskał model PSO-SR. Analizując dane w tabeli można zauważyć, że reguły R_1 oraz R_4 zostają usunięte („etykieta” ma wartość 0), natomiast w przypadku pozostałych reguł duża część współczynników jest wyzerowana, co znacznie upraszcza model. Co więcej, we wszystkich przeprowadzonych eksperymentach zaproponowane metody poprawiły wynik uzyskany przez model referencyjny.

Tabela 6: Porównanie wyników klasyfikacji dla zbioru danych z kwiatami irysów i 10 krotnej walidacji krzyżowej; λ to współczynnik regularyzacji

Algorytm	λ	Błąd klasyfikacji	Rzadkość modelu	CCR [%]
Klasyfikatory nierozmyte				
DT	–	0,0600	–	94,00
NB	–	0,0467	–	95,33
KNN	–	0,0667	–	93,33
LDA	–	0,0467	–	95,33
SVM	–	0,0533	–	94,67
Klasyfikatory rozmyte				
ANFIS	–	0,0467	–	95,33
SFC-PSO	1,626	0,0333	0,6667	96,67
SFC-GA	3,578	0,0400	0,6333	96,00
SFC-SA	9,879	0,0467	0,6333	95,33
SFC-PS	1e–08	0,0467	0,5083	95,33

Najlepszy wynik CCR został pogrubiony.

Tabela 7: Parametry przykładowego systemu T–S uzyskane w Eksperymentcie 1; p , q , σ , δ to parametry funkcji przynależności zbiorów rozmytych, a v_1 , w_1 , c to współczynniki wielomianu

Reguła	Etykieta	p	σ	q	δ	v_1	w_1	c
PSO-SR								
R_1	0	–2,701	0,2357	45,68	3,783	0	0	0
R_2	1	–2,701	0,2357	48,04	4,076	0	1,070	0
R_3	1	–2,701	0,2357	60,50	3,844	0	1,051	0
R_4	0	–2,716	0,7576	45,68	3,783	0	0	0
R_5	1	–2,716	0,7576	48,04	4,076	0	1,354	0
R_6	1	–2,716	0,7576	60,50	3,844	0	1,014	0
R_7	1	–1,572	5,892	45,68	3,783	0	1,096	0
R_8	1	–1,572	5,892	48,04	4,076	–1,713	0,9763	0
R_9	1	–1,572	5,892	60,50	3,844	0	0,9883	0

4.4 Pozostałe osiągnięcia, 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.).

Liczba punktów MNiSW/MEiN za wymienione poniżej osiągnięcia wynosi 155 pkt.

4.4.1 Monografia naukowa, zgodnie z art. 219 ust. 1. pkt 2a ustawy

[B1] K. Przednowek (40%), **T. Krzeszowski** (30%), J. Iskra (20%), K. Wiktorowicz (10%), *Wspomaganie procesu treningowego w biegach przez płotki z wykorzystaniem modelowania komputerowego*, Wydawnictwo Uniwersytetu Rzeszowskiego, 2019

MNiSW2019: 80 pkt.

Mój wkład w powstanie tej publikacji szacuję na 30%; obejmował on wszystkie etapy przygotowania monografii, w szczególności: a) nadzór nad przygotowaniem rozdziału 3, b) przygotowanie opisu wizyjnych metod śledzenia, c) przygotowanie opisu inercyjnych systemów przechwytywania ruchu, d) przeprowadzenie eksperymentów zaprezentowanych w rozdziale 3, e) współudział przy rejestracji danych wizyjnych, f) współudział przy opracowaniu i analizie wyników, g) współudział przy redakcji i korekcie tekstu monografii.

W monografii zaprezentowano badania eksperymentalne zrealizowane w ramach grantu [B1]. Pierwsza część książki przedstawia ogólną charakterystykę biegów przez płotki. Drugi rozdział to opis metod modelowania matematycznego wraz z ich aplikacjami w procesie planowania obciążeń treningowych płotkarzy trenujących 110 m i 400 m przez płotki. Trzeci rozdział został poświęcony aplikacjom metod wizji komputerowej oraz nowoczesnym technikom opartym o czujniki bezwładnościowe w diagnozowaniu techniki w biegach przez płotki.

4.4.2 Wykaz zrealizowanych oryginalnych osiągnięć projektowych, konstrukcyjnych, technologicznych lub artystycznych, zgodnie z art. 219 ust. 1. pkt 2c ustawy

[B2] **T. Krzeszowski** (51%), K. Przednowek (49%), *Sposób estymacji cech somatycznych, wskaźników somatycznych, komponentów somatotypu, samego somatotypu oraz komponentów składu ciała z wykorzystaniem sensora głębi*, Zgłoszenie wynalazku nr P.434848 (29.07.2020 r.); patent przyznano 17.11.2021 r.; numeru publikacji opisu patentowego PL240075B1 (14.02.2022 r.)

MEiN2022: 75 pkt.

Mój wkład w opracowanie opatentowanego rozwiązania wynosi 51%; obejmował on wszystkie etapy przygotowania rozwiązania, w szczególności: a) współudział przy opracowaniu koncepcji systemu, b) wykonanie przeglądu stanu wiedzy,

- c) opracowanie i implementację metody segmentacji skanu 3D postaci ludzkiej,
- d) opracowanie i implementację metody estymacji cech i wskaźników somatycznych,
- e) współudział przy przygotowaniu opisu wynalazku.

Przedmiotem wynalazku jest system i metody do estymacji cech somatycznych, wskaźników somatycznych, komponentów somatotypu oraz komponentów składu ciała na podstawie danych z sensora głębi. W zaproponowanym rozwiązaniu cechy i wskaźniki somatyczne (wysokość, rozpiętość ramion, obwody) są wyznaczone bezpośrednio ze skanu 3D, natomiast do wyznaczenia masy ciała, komponentów składu ciała i komponentów somatotypu wykorzystano metody modelowania komputerowego w postaci modeli regresyjnych oraz metod uczenia maszynowego. Wskaźniki somatyczne (wskaźnik masy ciała (ang. *Body Mass Index*, BMI), wskaźnik otyłości ciała (ang. *Body Adiposity Index*, BAI) oraz wskaźnik powierzchni ciała (ang. *Body Surface Area*, BSA)) obliczane są na podstawie wzorów matematycznych wykorzystujących obliczone cechy somatyczne oraz wyestymowaną za pomocą modelu predykcyjnego masę ciała. Opracowane rozwiązanie może znaleźć zastosowanie w szpitalach, przychodniach, poradniach dietetycznych, szkołach (diagnozowanie otyłości), instytucjach kultury fizycznej (pomiar struktury ciała, mierzenie postępów w rozwoju masy mięśniowej i redukcji tkanki tłuszczowej). Obecnie wymienione parametry są wyznaczone przy pomocy wielu specjalistycznych urządzeń i przyrządów pomiarowych, co wymaga odpowiednio przeszkolonego personelu i jest czasochłonne. Opracowany wynalazek umożliwia automatyczny i szybki pomiar wielu parametrów. Wynalazek powstał jako wynik prac B+R zrealizowanych w ramach grantu [G4], w którym pełniłem rolę kierownika.

4.5 Omówienie pozostałych osiągnięć naukowo-badawczych

Przed uzyskaniem stopnia doktora zajmowałem się przede wszystkim zagadnieniami dotyczącymi śledzenia ruchu postaci ludzkiej [D1, D4-10, D12-13], zastosowaniem danych pozyskanych przy pomocy opracowanych metod przechwytywania ruchu do rozpoznawania osób [D2-3, D11], a także wykorzystaniem kart graficznych do przyspieszenia obliczeń [D1, D13]. Wyniki badań dotyczących śledzenia ruchu postaci ludzkich zostały przedstawione w pracy doktorskiej, która została obroniona z wyróżnieniem w czerwcu 2013 r. Moje późniejsze prace, które nie zostały omówione w ramach jednotematycznego cyklu publikacji [A1-10], dotyczyły metod autonomicznego lądowania dronów [C4, C12], rozwiązań umożliwiających estymację cech i wskaźników somatycznych oraz komponentów somatotypu i składu ciała na podstawie danych z sensora głębi [C1, B2], metod do generowania planów treningowych i predykcji wyników osiąganych przez lekkoatletów [C5, C8-10, C14, C19-20] oraz zbadania wpływu zmęczenia podczas wykonywania ćwiczeń fizycznych na częstotliwość mrugnięć oczu [C3].

5 Współpraca z innymi krajowymi i zagranicznymi ośrodkami badawczymi

W roku 2019 prowadziłem prace badawcze wspólnie z Profesorem Carlosem Tavares Calafate (Universitat Politècnica de València, Spain) oraz jego zespołem. Współpraca została nawiązana podczas mojego pobytu na Politechnice w Walencji w 2018 r. (wyjazd w ramach programu Erasmus dla pracowników uczelni). W wyniku wspólnych prac powstały dwie wysokopunktowane publikacje naukowe (artykuł [C4] oraz publikacja w materiałach konferencyjnych [C12]). Prace badawcze dotyczyły algorytmów umożliwiających autonomiczne lądowanie bezzałogowych pojazdów powietrznych (UAV) w oparciu o analizę danych z kamery pokładowej.

W latach 2009–2014 oraz 2017 – 2023 współpracowałem z naukowcami z Instytut Informatyki Politechniki Śląskiej w Gliwicach, Polsko-Japońskiej Akademii Technik Komputerowych oraz Akademii Górniczo-Hutniczej. W ramach prac powstało 16 publikacji, w tym sześć po doktoracie (trzy artykuły [C2], [C6], [C7] i trzy publikacje w materiałach konferencyjnych [A10], [C24], [C25]). Część prac została zrealizowana w ramach grantów badawczych [G1]⁴, [G7] oraz [G8], w których byłem zatrudniony jako wykonawca. Prowadzone badania dotyczyły metod śledzenia ruchu postaci ludzkiej oraz rozpoznawania osób na podstawie analizy chodu. Obecnie pracujemy nad algorytmami estymacji pozycji i orientacji pojazdów UAV w ramach grantu [G1]. W wyniku prowadzonych prac powstały dwie wysokopunktowane publikacje ([A10] oraz [C2]). W planach są kolejne trzy prace prezentujące wyniki grantu.

W okresie 2013–2023 uczestniczyłem w pracach badawczych prowadzonych we współpracy z pracownikami Uniwersytetu Rzeszowskiego i Politechniki Opolskiej. W wyniku współpracy powstało 22 prace naukowe (najważniejsze publikacje: [A2], [A3], [A8], [C1], [C5] i [B1]), część prac była realizowana w ramach grantu „Wspomaganie procesu treningowego w biegach przez płotki z wykorzystaniem modelowania komputerowego” [G5]. Badania te dotyczyły zastosowaniem metod uczenia maszynowego i wizji komputerowej do wspomagania pracy trenera. Większość prac badawczych była realizowana we współpracy z wieloletnim trenerem kadry lekkoatletycznej w biegach przez płotki prof. dr hab. Januszem Iskrą z Politechniki Opolskiej. Jako podsumowanie przeprowadzonych badań opublikowana została monografia naukowa [B1]. Ostatnie prace realizowane we współpracy z Uniwersytetem Rzeszowskim dotyczyły monitoringu osób starszych w celu detekcji upadków. Prace były prowadzone w ramach grantu B+R [G3]. W okresie realizacji prac byłem zatrudniony na Uniwersytecie Rzeszowskim jako wykonawca w projekcie naukowym na stanowisku starszy specjalista naukowo-techniczny.

⁴Listę projektów badawczych zamieszczono w Załączniku 4 i oznaczono przedrostkiem "G".

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

6.1 Przygotowanie i prowadzenie zajęć dydaktycznych

Jestem autorem programu nauczania przedmiotu „Uczenie maszynowe w języku Python”, a także współautorem programów nauczania dla przedmiotów „Roboty mobilne” oraz „Metody rozpoznawania obiektów i analizy ruchu”. Jestem również koordynatorem wspomnianych przedmiotów oraz prowadzę wykłady, laboratoria i zajęcia projektowe. Prowadzę także zajęcia dydaktyczne z następujących przedmiotów: „Algorytmy i struktury danych” (laboratoria), „Inżynieria oprogramowania” (laboratoria i projekty), „Bazy danych” (laboratoria i projekty), „Nowoczesne technologie programistyczne” (wykłady i laboratoria) oraz „Informatyka” (laboratoria). Ponadto w przeszłości prowadziłem następujące zajęcia dydaktyczne: „Programowanie funkcjonalne” (laboratoria), „Semantyka i weryfikacja programów” (laboratoria), „Programowanie w języku C” (laboratoria), „Komunikacja w sieciach mikrokomputerowych” (laboratoria), „Programowanie współbieżne i rozproszone” (laboratoria).

Prowadziłem również zajęcia w języku angielskim z przedmiotów: „Mobile Robotics” (semestr letni 2014/2015 oraz 2022/2023), „Programming in Python” (semestr letni 2020/2021) i „Machine learning in Python” (semestr letni 2022/2023) dla studentów z programu Erasmus.

W ramach projektów współfinansowanych przez Unię Europejską ze środków Europejskiego Funduszu społecznego opracowałem i prowadziłem kursy z zakresu programowania urządzeń mobilnych (szczegółowe informacje umieściłem w dokumencie prezentującym wykaz osiągnięć naukowych, sekcja 2.9).

W roku 2022 współtworzyłem nowy program studiów dla kierunku Informatyka na pierwszym i drugim stopniu.

6.2 Promotorstwo prac inżynierskich i magisterskich

Byłem promotorem 32 prac inżynierskich i 9 prac magisterskich na kierunkach Informatyka, Automatyka i robotyka oraz Inżynieria medyczna.

Promotorstwo prac inżynierskich:

- 18 na kierunku Informatyka,
- 13 na kierunku Automatyka i robotyka,
- 1 na kierunku Inżynieria medyczna.

Promotorstwo prac magisterskich:

- 7 na kierunku Informatyka,
- 2 na kierunku Automatyka i robotyka.

Prowadziłem również projekt inżynierski studenta z zagranicy w ramach programu Erasmus.

6.3 Opieka naukowa nad studentami

- Opieka nad studentami Koła Naukowego IT — 2013–2018 r.,
- Opieka nad dwoma stażystami z Turcji (program Erasmus+) — 2019 r.,
- Opieka nad studentami realizującymi pracę magisterską — 9 prac,
- Publikacje ze studentami (pogrubioną czcionką zaznaczono studentów):
 - T. Krzeszowski, A. Świtoński, **M. Zieliński**, K. Wojciechowski, J. Rosner, *3D tracking of multiple drones based on Particle Swarm Optimization*, International Conference on Computational Science 2023 (ICCS 2023), Lecture Notes in Computer Science, vol 10476, Springer, Cham, Prague, Czech Republic, 03-05 lipca, 2023, doi:10.1007/978-3-031-36027-5_18, MEiN2023: **140 pkt.**
 - **W. Lindenheim-Locher**, A. Świtoński, T. Krzeszowski, **G. Paleta**, **P. Hasi**, H. Josiński, M. Paszkuta, K. Wojciechowski, J. Rosner, *YOLOv5 Drone Detection Using Multimodal Data Registered by the Vicon System*, Sensors, 23(14), 6396, 2023 <https://doi.org/10.3390/s23146396>, IF2022: **3,9**, MEiN2023: **100 pkt.**
 - **J. Wubben**, F. Fabra, C. T. Calafate, T. Krzeszowski, J. M. Marquez-Barja, J. C. Cano, P. Manzoni, *Accurate landing of unmanned aerial vehicles using ground pattern recognition*, Electronics (Switzerland), vol. 8, iss. 12, p. 1532, 2019. doi:10.3390/electronics8121532, IF2019: **2.412**, MNiSW2019: **100 pkt.**
 - **J. Wubben**, F. Fabra, C. T. Calafate, T. Krzeszowski, J. M. Marquez-Barja, J. Cano, P. Manzoni, *A vision-based system for autonomous vertical landing of unmanned aerial vehicles*, in 2019 IEEE/ACM 23rd International Symposium on Distributed Simulation and Real Time Applications (DS-RT), 2019, pp. 1-7. doi:10.1109/DS-RT47707.2019.8958701, MNiSW2019: **70 pkt.**, indeksacja: Web of Science, Scopus
 - K. Przednowek, K. Wiktorowicz, T. Krzeszowski, **M. Tumidajewicz**, J. Iskra, *Mobile application for predictive modelling in hurdles race*, 2nd International Conference on Technology and Innovation in Sports, Health and Wellbeing (TISHW), Thessaloniki, Greece, pp. 1–7, 2018, MNiSW2018: **15 pkt.**, indeksacja: Web of Science, Scopus

7 Podsumowanie dorobku naukowego – zestawienie i wskaźniki bibliometryczne

Wyniki moich badań zostały opublikowane w 50 publikacjach, w tym 37 powstało po uzyskaniu stopnia doktora. Wśród nich znajdują się: artykuły w czasopismach z listy

JCR (15) [A2-6, A8-9, C1-2, C4-8, C10], artykuł w czasopiśmie indeksowanym w bazie Scopus [D11], publikacje w materiałach z konferencji międzynarodowych indeksowanych w WoS (19), np. [A1, A7, A10, C12, C14, C24-C25], monografia [B1] oraz jeden patent [B2]. Prace charakteryzują się współczynnikiem wpływu IF równym 48,115 i sumaryczną punktacją MNiSW/MEiN – 1801. Moje prace były cytowane 512 razy wg bazy Google Scholar, 364 (297 razy bez uwzględniania autocytowań) wg bazy Scopus i 281 (231 razy bez uwzględniania autocytowań) wg bazy WoS. Indeks Hirscha wynosi 14, 12 lub 11 wg odpowiednio bazy Google Scholar, Scopus i WoS. Podczas mojej pracy naukowej brałem udział w ośmiu grantach badawczych oraz badawczo-rozwojowych. W jednym z grantów pełniłem rolę kierownika [G4]. Ponadto brałem udział w czterech projektach związanych ze wzmocnieniem i rozwojem potencjału dydaktycznego WEiI PRz, współfinansowanych ze środków Europejskiego Funduszu Społecznego. Otrzymałem również stypendium dla doktorantów w ramach projektu „Podkarpacki fundusz stypendialny dla doktorantów”, który także był współfinansowany ze środków Europejskiego Funduszu Społecznego. Po uzyskaniu stopnia doktora wygłaszałem wykłady w ramach programu Erasmus oraz brałem aktywny udział w seminariach i konferencjach. W sumie wygłosiłem 10 referatów na konferencjach, w tym sześć po uzyskaniu stopnia doktora. W latach 2013-2023 wykonałem 78 recenzji: 47 dla 13 czasopism z listy JCR, sześć dla trzech czasopism spoza tej listy, a także 25 recenzji materiałów zgłoszonych na konferencje międzynarodowe oraz krajowe. Od 2021 r. pełnię rolę redaktora w czasopiśmie *Journal of Real-Time Image Processing* (Springer, IF2022: 3,0, MEiN2023: 70 pkt.) oraz pełniłem rolę członka komitetu dziewięciu konferencji międzynarodowych oraz dwóch krajowych. Ponadto dwa razy pełniłem rolę redaktora gościnnego wydania specjalnego w czasopiśmie *Sensors* (MDPI, IF2022: 3,9, MEiN2023: 100 pkt.). Od 2010 r. jestem członkiem zwyczajnym Towarzystwa Przetwarzania Obrazów. Otrzymałem pięć nagród Rektora Politechniki Rzeszowskiej (II i 4 × III stopnia za działalność naukową, w tym dwie nagrody indywidualne i trzy zespołowe; nagrody indywidualne otrzymałem po uzyskaniu stopnia doktora). Ponadto otrzymałem nagrodę za najlepszy poster na konferencji icSPORTS 2016. Syntetyczny wykaz prac, informacja o współpracy naukowej oraz popularyzacji nauki zostały przedstawione w Załączniku nr 4.

Literatura

- [1] ALEXANDER, M. J., AND HAYWARD-ELLIS, J. The effectiveness of the shotloc training tool on basketball free throw performance and technique. *International Journal of Kinesiology & Sports Science* 4, 2 (2016), 43–54.
- [2] ALFI, A., AND FATEH, M.-M. Intelligent identification and control using improved fuzzy particle swarm optimization. *Expert Systems with Applications* 38, 10 (2011), 12312–12317.

- [3] AMMAR, A., CHTOUROU, H., ABDELKARIM, O., PARISH, A., AND HOEKELMANN, A. Free throw shot in basketball: kinematic analysis of scored and missed shots during the learning process. *Sport Sciences for Health* 12, 1 (2016), 27–33.
- [4] ARLOT, S., AND CELISSE, A. A survey of cross-validation procedures for model selection. *Statistics Surveys* 4 (2010), 40–79.
- [5] BOUAZIZI, A., WIEDERER, J., KRESSEL, U., AND BELAGIANNIS, V. Self-supervised 3d human pose estimation with multiple-view geometry. In *2021 16th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2021)* (2021), pp. 1–8.
- [6] BOULKAIBET, I., BELARBI, K., BOUOUDEN, S., MARWALA, T., AND CHADLI, M. A new T-S fuzzy model predictive control for nonlinear processes. *Expert Systems with Applications* 88 (2017), 132–151.
- [7] CAO, Z., HIDALGO MARTINEZ, G., SIMON, T., WEI, S., AND SHEIKH, Y. A. Openpose: Realtime multi-person 2d pose estimation using part affinity fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2019).
- [8] CLERC, M., AND KENNEDY, J. The particle swarm - explosion, stability, and convergence in a multidimensional complex space. *IEEE Transactions on Evolutionary Computation* 6, 1 (2002), 58–73.
- [9] ČOCH, M. Biomechanical analysis of Colin Jackson’s hurdle clearance technique. *New Studies in Athletics* 1 (2003), 33–40.
- [10] DENG, M., WANG, C., CHENG, F., AND ZENG, W. Fusion of spatial-temporal and kinematic features for gait recognition with deterministic learning. *Pattern Recognition* 67 (2017), 186–200.
- [11] DOUCET, A., DE FREITAS, N., GORDON, N. J., ET AL. *Sequential Monte Carlo methods in practice*, vol. 1. Springer, 2001.
- [12] EBERHART, R. C., AND SHI, Y. Comparing inertia weights and constriction factors in particle swarm optimization. In *Evolutionary Computation, 2000. Proceedings of the 2000 Congress on* (2000), vol. 1, pp. 84–88.
- [13] EFRON, B., HASTIE, T., JOHNSTONE, I., TIBSHIRANI, R., ET AL. Least angle regression. *The Annals of Statistics* 32, 2 (2004), 407–499.
- [14] EICHHORN, C., JADID, A., PLECHER, D. A., WEBER, S., KLINKER, G., AND ITOH, Y. Catching the drone-A tangible augmented reality game in superhuman sports. *Adjunct Proceedings of the 2020 IEEE International Symposium on Mixed and Augmented Reality, ISMAR-Adjunct 2020* (2020), 24–29.

- [15] GUO, Y., HASTIE, T., AND TIBSHIRANI, R. Regularized linear discriminant analysis and its application in microarrays. *Biostatistics* 8, 1 (04 2006), 86–100.
- [16] HAMILTON, G. R., AND REINSCHMIDT, C. Optimal trajectory for the basketball free throw. *Journal of Sports Sciences* 15, 5 (1997), 491–504. PMID: 9386207.
- [17] HOERL, A. E., AND KENNARD, R. W. Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics* 12, 1 (1970), 55–67.
- [18] JOHN, V., TRUCCO, E., AND IVEKOVIC, S. Markerless human articulated tracking using hierarchical particle swarm optimisation. *Image and vision computing* 28, 11 (2010), 1530–1547.
- [19] JURN, Y. N., MAHMOOD, S. A., AND ALDHAIBANI, J. A. Anti-Drone System Based Different Technologies: Architecture, Threats and Challenges. *Proceedings - 2021 11th IEEE International Conference on Control System, Computing and Engineering, ICCSCE 2021*, August (2021), 114–119.
- [20] KENNEDY, J., AND EBERHART, R. Particle swarm optimization. In *Proc. of IEEE Int. Conf. on Neural Networks* (1995), vol. 4, IEEE Press, Piscataway, NJ, pp. 1942–1948.
- [21] LI, C., AND WU, T. Adaptive fuzzy approach to function approximation with PSO and RLSE. *Expert Systems with Applications* 38, 10 (2011), 13266–13273.
- [22] LIANG, J. J., SUGANTHAN, P. N., AND DEB, K. Novel composition test functions for numerical global optimization. In *Proceedings 2005 IEEE Swarm Intelligence Symposium, 2005. SIS 2005.* (June 2005), pp. 68–75.
- [23] MARTY, A., MCGHEE, R., AND EDWARDS, T. Trajectory detection and feedback system, Feb. 1 2007. US Patent App. 11/508,004.
- [24] MATOVSKI, D. S., NIXON, M. S., MAHMOODI, S., AND CARTER, J. N. The Effect of Time on Gait Recognition Performance. *IEEE Transactions on Information Forensics and Security* 7, 2 (2012), 543–552.
- [25] MIRJALILI, S., AND LEWIS, A. The whale optimization algorithm. *Advances in Engineering Software* 95 (2016), 51 – 67.
- [26] MIRJALILI, S., MIRJALILI, S. M., AND LEWIS, A. Grey Wolf Optimizer. *Advances in Engineering Software* 69 (2014), 46–61.
- [27] NIKNAM, T. A new fuzzy adaptive hybrid particle swarm optimization algorithm for non-linear, non-smooth and non-convex economic dispatch problem. *Applied Energy* 87, 1 (2010), 327–339.

- [28] SAINI, S., ZAKARIA, N., RAMBLI, D. R. A., AND SULAIMAN, S. Markerless human motion tracking using hierarchical multi-swarm cooperative particle swarm optimization. *PLoS One* 10, 5 (2015), e0127833.
- [29] SHI, Y., AND EBERHART, R. C. Fuzzy adaptive particle swarm optimization. In *Proceedings of the Congress on Evolutionary Computation* (2001), vol. 1, pp. 101–106.
- [30] SIGAL, L., AND BLACK, M. J. Humaneva: Synchronized video and motion capture dataset for evaluation of articulated human motion. *Technical Report CS-06-08, Brown University* (2006).
- [31] SJÖSTRAND, K., CLEMMENSEN, L., LARSEN, R., EINARSSON, G., AND ERSBØLL, B. SpaSM: A MATLAB toolbox for sparse statistical modeling. *Journal of Statistical Software, Articles* 84, 10 (2018), 1–37.
- [32] SUN, T. Y., TSAI, S. J., TSAI, C. H., HUO, C. L., AND LIU, C. C. Nonlinear function approximation based on least Wilcoxon Takagi-Sugeno fuzzy model. In *2008 Eighth International Conference on Intelligent Systems Design and Applications* (Nov 2008), vol. 1, pp. 312–317.
- [33] TIBSHIRANI, R. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)* (1996), 267–288.
- [34] TRAN, V. P., SANTOSO, F., AND GARRATT, M. A. Adaptive Trajectory Tracking for Quadrotor Systems in Unknown Wind Environments Using Particle Swarm Optimization-Based Strictly Negative Imaginary Controllers. *IEEE Transactions on Aerospace and Electronic Systems* 57, 3 (2021), 1742–1752.
- [35] YAM, C. Y. Y., NIXON, M. S., AND CARTER, J. N. Automated person recognition by walking and running via model-based approaches. *Pattern Recognition* 37, 5 (2004), 1057–1072.
- [36] YANG, Y.-K., SUN, T.-Y., HUO, C.-L., YU, Y.-H., LIU, C.-C., AND TSAI, C.-H. A novel self-constructing radial basis function neural-fuzzy system. *Applied Soft Computing* 13, 5 (2013), 2390 – 2404.
- [37] ZIVKOVIC, Z., AND VAN DER HEIJDEN, F. Efficient adaptive density estimation per image pixel for the task of background subtraction. *Pattern Recogn. Lett.* 27, 7 (May 2006), 773–780.
- [38] ZOU, H., AND HASTIE, T. Regularization and variable selection via the elastic net. *Journal of the Royal Statistical Society. Series B (Statistical Methodology)* 67, 2 (2005), 301–320.


 (podpis wnioskodawcy)