



Autoreferat

Spis treści

1. Posiadane dyplomy, stopnie naukowe	2
2. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych	2
3. Omówienie osiągnięć, o których mowa w art. 219 ust. 1 pkt. 2 ustawy	3
3.1. Główne osiągnięcie naukowe.....	5
3.1.1. Cele i hipotezy badawcze.....	8
3.1.2. Problemy ochrony grafów przed zagrożeniami	10
3.1.3. Podział cyklu publikacji na obszary tematyczne	16
3.1.4. Algorytmy metaheurystyczne	17
3.1.5. Algorytmy metaheurystyczne wykorzystujące modele uczenia maszynowego.....	26
3.1.6. Zastosowanie algorytmów metaheurystycznych do problemów rzeczywistych.....	48
3.1.7. Projekty badawcze powiązane tematycznie z cyklem publikacji	55
3.1.8. Podsumowanie głównego osiągnięcia naukowego	56
3.2. Prace badawcze oraz wynikające z nich publikacje w obszarze optymalizacji wielokryterialnej	60
3.3. Prace badawcze oraz wynikające z nich publikacje w obszarze optymalizacji logistyki i transportu	62
3.4. Prace badawcze oraz wynikające z nich publikacje w zakresie wizualizacji przestrzeni rozwiązań problemów optymalizacji.....	64
4. Informacja o wykazywaniu się istotną aktywnością naukową realizowaną w więcej niż jednej uczelni lub instytucji naukowej w szczególności zagranicznej.....	67
5. Informacja o osiągnięciach dydaktycznych, kształceniu kadry naukowej, organizacyjnych oraz popularyzujących naukę.....	70
6. Nagrody Rektora	71
7. Literatura	71

Imię i nazwisko

Krzysztof Michałak

1. Posiadane dyplomy, stopnie naukowe

- 2010 **Politechnika Wroclawska, Wydział Informatyki i Zarządzania**
Stopień naukowy: **doktor nauk technicznych** w dyscyplinie: **informatyka**
Temat rozprawy doktorskiej: "Mieszana metoda wyboru cech do zadania klasyfikacji".
Promotor: prof. dr hab. inż. Halina Kwaśnicka
Rozprawa została wyróżniona decyzją Rady Wydziału.
- 2001 **Politechnika Wroclawska, Wydział Informatyki i Zarządzania**
Tytuł zawodowy: **magister inżynier** w dyscyplinie: **informatyka**
Temat pracy magisterskiej: "Inteligentne metody poszukiwania liniowych kodów korekcyjnych".
Promotor: prof. dr hab. inż. Halina Kwaśnicka

2. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych

- 02.2012 – obecnie **Uniwersytet Ekonomiczny we Wrocławiu**
Katedra Technologii Informatycznych
Adiunkt
- 02.2011 – 01.2012 **Uniwersytet Ekonomiczny we Wrocławiu**
Katedra Technologii Informatycznych
Asystent
- 11.2013 – 08.2014 **Politechnika Wroclawska**
Praca w projekcie "Platforma optymalizacji procesów biznesowych w zintegrowanych systemach informatycznych" w ramach umów o dzieło i zlecenia.
- 10.2010 – 01.2011 **Politechnika Wroclawska**
Praca w projekcie „VISIBLE” w ramach umów o dzieło i zlecenia.

3. Omówienie osiągnięć, o których mowa w art. 219 ust. 1 pkt. 2 ustawy

W tym rozdziale zostały zaprezentowane osiągnięcia naukowe, o których mowa w art. 219 ust. 1 pkt. 2 ustawy.

Główne osiągnięcie naukowe:

Cykl publikacji (zgodnie z art. 219 ust. 1 pkt. 2 lit. b ustawy) zatytułowany „**Algorytmy metaheurystyczne dla problemów ochrony grafów przed zagrożeniami**”. Zgodnie z Art. 179, ust. 6, pkt. 2 ustawy "Przepisy wprowadzające ustawę - Prawo o szkolnictwie wyższym i nauce" (Dz.U.2018.1669 z późn. zm.) w ramach cyklu zostały uwzględnione także artykuły opublikowane w czasopismach naukowych lub recenzowanych materiałach z konferencji międzynarodowych, ujętych w wykazie sporządzonym zgodnie z przepisami wydanymi na podstawie art. 267 ust. 2 pkt 2 lit. b tej ustawy, przed dniem ogłoszenia tego wykazu.

W Tab.1 wymienione są publikacje wchodzące w skład cyklu wraz z danymi naukometrycznymi. Podpunkt 3.1.2 opisuje problematykę ochrony grafów przed zagrożeniami, zaś podpunkt 3.1.3 przedstawia podział głównego osiągnięcia (cyklu publikacji) na obszary tematyczne, które są dokładniej omówione w podpunktach 3.1.4-3.1.6. W podpunkcie 3.1.7 omówione są projekty badawcze powiązane tematycznie z głównym osiągnięciem naukowym (cyklem publikacji). Główne osiągnięcie naukowe jest podsumowane w podpunkcie 3.1.8.

Inne osiągnięcia naukowe:

1. Prace badawcze oraz wynikające z nich publikacje w obszarze optymalizacji wielokryterialnej (punkt 3.2).
2. Prace badawcze oraz wynikające z nich publikacje w obszarze optymalizacji logistyki i transportu (punkt 3.3).
3. Prace badawcze oraz wynikające z nich publikacje w zakresie wizualizacji przestrzeni rozwiązań w problemach optymalizacji (punkt 3.4).

Prezentowane osiągnięcia stanowią znaczny wkład w rozwój dyscypliny informatyka techniczna i telekomunikacja między innymi poprzez:

- **Opracowanie nowych algorytmów metaheurystycznych** oraz ich elementów (np. operatorów genetycznych) dla problemów ochrony grafów przed zagrożeniami.
- **Opracowanie podejścia do rozwiązywania problemów optymalizacji w zakresie ochrony grafów przed zagrożeniami z wykorzystaniem modeli uczenia maszynowego** do ukierunkowania przeszukiwania w algorytmach metaheurystycznych, między innymi poprzez ich użycie do sterowania operatorami genetycznymi, takimi jak operatory krzyżowania i mutacji.
- **Zaproponowanie i wykazanie skuteczności podejścia „wytrenuj raz, stosuj wielokrotnie”** (Rys. 6) dla problemów optymalizacji w zakresie ochrony grafów przed zagrożeniami polegającego na trenowaniu modeli uczenia maszynowego na małych instancjach problemów w taki sposób, aby można było wytrenowany model zastosować dla dużo większych instancji tego samego problemu.
- **Przeprowadzenie prac badawczych dla problemów optymalizacji dotyczących ochrony przed zagrożeniami w świecie rzeczywistym** (epidemie oraz upadłości podmiotów gospodarczych).
- **Przeprowadzenie analizy oraz ulepszenie działania algorytmu MOEA/D** – jednego z najpopularniejszych algorytmów ewolucyjnych dla optymalizacji wielokryterialnej a także **ulepszenia działania algorytmów przeszukiwania lokalnego** dla kombinatorycznych problemów optymalizacji.
- **Prace badawcze dotyczące problemu Inventory Routing Problem (IRP)**, w tym zaproponowane podejście wykorzystujące wiedzę dziedzinową do poprawy uzyskiwanych wyników. Zaproponowane zostało także nowe podejście wykorzystujące optymalizację ewolucyjną do generowania trudnych instancji tego problemu, przydatnych w badaniach nad algorytmami optymalizacji.
- **Zaproponowanie metody transformacji** z wysokowymiarowej przestrzeni wektorów binarnych, permutacji, itp. do niskowymiarowej przestrzeni euklidesowej, co ułatwia rysowanie wykresów, wizualizację populacji w algorytmach ewolucyjnych, itp.

O znaczeniu prezentowanych prac może również świadczyć fakt publikacji w wysoko punktowanych czasopismach oraz na wiodących konferencjach naukowych a także zrealizowanie badań dotyczących zastosowań dla problemów rzeczywistych we współpracy międzynarodowej.

3.1. Główne osiągnięcie naukowe

Głównym osiągnięciem naukowym prezentowanym w ramach niniejszego wniosku habilitacyjnego jest cykl powiązanych ze sobą tematycznie publikacji pod zbiorczym tytułem:

Algorytmy metaheurystyczne dla problemów ochrony grafów przed zagrożeniami

Prezentowane artykuły dotyczą przede wszystkim **opracowania nowych algorytmów metaheurystycznych oraz ich elementów** (np. operatorów genetycznych dla algorytmów ewolucyjnych). Część artykułów przedstawia wyniki prac badawczych przeprowadzonych na **danych rzeczywistych**.

W skład cyklu wchodzi, wymienione w Tab. 1, artykuły opublikowane w międzynarodowych czasopismach naukowych lub na wiodących konferencjach naukowych spełniające warunki art. 219 ust. 1 pkt. 2 lit. b ustawy „Prawo o szkolnictwie wyższym i nauce”. Zgodnie z Art. 179, ust. 6, pkt. 2 ustawy „Przepisy wprowadzające ustawę - Prawo o szkolnictwie wyższym i nauce” (Dz.U.2018.1669 z późn. zm.) w ramach cyklu zostały uwzględnione także artykuły opublikowane w czasopismach naukowych lub recenzowanych materiałach z konferencji międzynarodowych, ujętych w wykazie sporządzonym zgodnie z przepisami wydanymi na podstawie art. 267 ust. 2 pkt 2 lit. b tej ustawy, przed dniem ogłoszenia tego wykazu. Wszystkie artykuły wchodzące w skład cyklu zostały opracowane i opublikowane po uzyskaniu stopnia doktora.

Dla każdego z artykułów podano liczbę punktów MNiSW **według punktacji z roku publikacji oraz według wykazu z dnia 2024.01.05**, współczynnik wpływu (*Impact Factor*, IF) z roku wydania publikacji (lub w przypadku nowych publikacji najnowszy dostępny) oraz **liczbę cytowań (bez autocytowań)** na podstawie bazy Web of Science (WoS), Google Scholar (GS) i Scopus (SC). Dla konferencji podana została pozycja w rankingu CORE. **Łączny IF to 30.139**. Spośród publikacji konferencyjnych, osiem zostało opublikowanych na konferencjach mających pozycję w rankingach CORE (pięć – A, trzy zaś C). W przypadku publikacji wieloautorskich w tabeli podany jest mój szacowany udział procentowy. Udział merytoryczny opisany jest w oświadczeniach o współautorstwie. Wykaz zawarty w Tab. 1 podzielono na obszary tematyczne, które omówione są w podpunkcie 3.1.3.

Tab. 1. Artykuły opublikowane w międzynarodowych czasopismach naukowych lub na wiodących konferencjach naukowych wchodzące w skład głównego osiągnięcia naukowego (cyklu publikacji)

ID	Publikacja	Dane nauko- metryczne	Udział	Obszar temat.
A01 (*)	K. Michalak Auto-adaptation of Genetic Operators for Multi-objective Optimization in the Firefighter Problem Intelligent Data Engineering and Automated Learning - IDEAL 2014, Salamanca, Spain, LNCS, vol. 8669, pp. 484-491, Springer, 2014.	MNiSW ₂₀₁₄ : 10 MNiSW ₂₀₂₄ : 20 CORE₂₀₁₄: C WoS: 4 Google: 7 Scopus: 4	100%	Algorytmy metaheurystyczne
A02 (*)	K. Michalak The Sim-EA Algorithm with Operator Autoadaptation for the Multiobjective Firefighter Problem 15th European Conference, EvoCOP 2015, Copenhagen, Denmark, LNCS, vol. 9026, pp. 184-196, Springer, 2015.	MNiSW ₂₀₁₅ : 10 MNiSW ₂₀₂₄ : 70 WoS: 2 Google: 5 Scopus: 2	100%	
A03 (*)	K. Michalak Estimation of Distribution Algorithms for the Firefighter Problem Evolutionary Computation in Combinatorial Optimization 17th European Conference, EvoCOP 2017, Amsterdam, The Netherlands, LNCS, vol. 10197, pp. 108-123, Springer, 2017.	MNiSW ₂₀₁₇ : 15 MNiSW ₂₀₂₄ : 70 WoS: 1 Google: 3 Scopus: 2	100%	
A04 (*)	K. Michalak Simulation-based Crossover for the Firefighter Problem GECCO'17 Proceedings of the Genetic and Evolutionary Computation Conference, Berlin, Germany, pp. 601-608, ACM New York, NY, USA, 2017.	MNiSW ₂₀₁₇ : 15 MNiSW ₂₀₂₄ : 140 CORE2017: A WoS: 0 Google: 0 Scopus: 0	100%	
A05	K. Michalak ED-LS - A Heuristic Local Search for the Multiobjective Firefighter Problem Applied Soft Computing, vol. 59, pp. 389-404, Elsevier, 2017.	MNiSW ₂₀₁₇ : 40 MNiSW ₂₀₂₄ : 200 IF₂₀₁₇: 3.907 WoS: 6 Google: 9 Scopus: 7	100%	
A06	K. Michalak Solving the Parameterless Firefighter Problem using Multiobjective Evolutionary Algorithms GECCO '19 Proceedings of the Genetic and Evolutionary Computation Conference Companion, Prague, Czech Republic, ISBN: 978-1-4503-6748-6, pp. 1321-1328, ACM New York, NY, USA, 2019.	MNiSW ₂₀₁₉ : 140 MNiSW ₂₀₂₄ : 140 CORE2018: A WoS: 0 Google: 1 Scopus: 0	100%	
Dalszy ciąg tabeli na następnej stronie				

ID	Publikacja	Dane nauko- metryczne	Udział	Obszar temat.
Kontynuacja tabeli z poprzedniej strony				
A07 (*)	K. Michalak Knowledge-based Solution Construction for Evolutionary Minimization of Systemic Risk The 19th International Conference on Intelligent Data Engineering and Automated Learning, IDEAL 2018, Madrid, Spain, LNCS, vol. 11314, ISBN: 978-3-030-03492-4, pp. 58-68, Springer, 2018.	MNiSW ₂₀₁₈ : 15 MNiSW ₂₀₂₄ : 20 CORE2018: C WoS: 0 Google: 0 Scopus: 0	100%	Algorytmy metaheurystyczne wykorzystujące modele uczenia maszynowego
A08 (*)	K. Michalak Informed Mutation Operator using Machine Learning for Optimization in Epidemics Prevention GECCO '18 Proceedings of the Genetic and Evolutionary Computation Conference, Kyoto, Japan, ISBN: 978-1-4503-5618-3, pp. 1294-1301, ACM New York, NY, USA, 2018.	MNiSW ₂₀₁₈ : 15 MNiSW ₂₀₂₄ : 140 CORE2018: A WoS: 2 Google: 3 Scopus: 4	100%	
A09 (*)	K. Michalak Crossover Operator using Knowledge Transfer for the Firefighter Problem The 19th International Conference on Intelligent Data Engineering and Automated Learning, IDEAL 2018, Madrid, Spain, LNCS, vol. 11314, ISBN: 978-3-030-03492-4, pp. 305-316, Springer, 2018.	MNiSW ₂₀₁₈ : 15 MNiSW ₂₀₂₄ : 20 CORE2018: C WoS: 0 Google: 1 Scopus: 0	100%	
A10	K. Michalak Classifier-based evolutionary multiobjective optimization for the graph protection problem Applied Soft Computing, vol. 131, pp. 109721, Elsevier, 2022.	MNiSW ₂₀₂₁ : 200 MNiSW ₂₀₂₄ : 200 IF₂₀₂₂: 8.700 WoS: 0 Google: 0 Scopus: 0	100%	
A11	K. Michalak Evolutionary algorithm with a regression model for multiobjective minimization of systemic risk in financial systems Soft Computing, vol. 28, issue 5, pp. 3921-3939, Springer, 2023.	MNiSW ₂₀₂₃ : 70 MNiSW ₂₀₂₄ : 70 IF₂₀₂₂: 4.100 WoS: 0 Google: 0 Scopus: 0	100%	
A12	K. Michalak Surrogate-based Optimization for Reduction of Contagion Susceptibility in Financial Systems GECCO '19 Proceedings of the Genetic and Evolutionary Computation Conference, Prague, Czech Republic, ISBN: 978-1-4503-5618-3, pp. 1266-1274, ACM New York, NY, USA, 2019.	MNiSW ₂₀₁₉ : 140 MNiSW ₂₀₂₄ : 140 CORE2018: A WoS: 1 Google: 1 Scopus: 1	100%	
A13	K. Michalak Evolutionary Graph-Based V+E Optimization for Protection Against Epidemics Parallel Problem Solving from Nature - PPSN XVI. PPSN 2020, LNCS, vol. 12270, pp. 399-412, Springer, 2020.	MNiSW ₂₀₁₉ : 140 MNiSW ₂₀₂₄ : 140 CORE2020: A WoS: 0 Google: 3 Scopus: 0	100%	
Dalszy ciąg tabeli na następnej stronie				

ID	Publikacja	Dane nauko- metryczne	Udział	Obszar temat.
Kontynuacja tabeli z poprzedniej strony				
A14	M. Alexandre, T. Ch. Silva, K. Michalak, F. A. Rodrigues Does the default pecking order impact systemic risk? Evidence from Brazilian data European Journal of Operational Research, vol. 309, issue 3, pp. 1379-1391, Elsevier, 2023.	MNiSW ₂₀₂₃ : 140 MNiSW ₂₀₂₄ : 140 IF₂₀₂₂: 6.400 WoS: 0 Google: 1 Scopus: 0	20%	Zastosowania do problemów rzeczywistych
A15	K. Michalak, M. Giacobini The Influence of Uncertainties on Optimization of Vaccinations on a Network of Animal Movements Soft Computing, vol. 25, pp. 4907-4923, ISSN: 1432-7643, Springer, 2021.	MNiSW ₂₀₂₁ : 70 MNiSW ₂₀₂₄ : 70 IF₂₀₂₁: 3.732 WoS: 1 Google: 1 Scopus: 1	75%	
A16	M. Alexandre, K. Michalak, T. Ch. Silva, F. A. Rodrigues Efficiency-Stability Trade-off in Financial Systems: A multi-objective optimization approach Physica A: Statistical Mechanics and its Applications, vol. 629, pp. 129213, Elsevier, 2023.	MNiSW ₂₀₂₃ : 70 MNiSW ₂₀₂₄ : 70 IF₂₀₂₂: 3.300 WoS: 0 Google: 0 Scopus: 0	20%	

(*) Artykuły uwzględnione w cyklu zgodnie z Art. 179, ust. 6, pkt. 2 ustawy "Przepisy wprowadzające ustawę - Prawo o szkolnictwie wyższym i nauce" (Dz.U.2018.1669 z późn. zm.).

W dalszej części niniejszego rozdziału znajduje się omówienie merytoryczne przedmiotowego osiągnięcia.

3.1.1. Cele i hipotezy badawcze

Głównym celem badawczym przeprowadzonych prac badawczych było **opracowanie nowych metod metaheurystycznych** skutecznie rozwiązujących problemy optymalizacyjne występujące w zagadnieniach ochrony przed zagrożeniami takimi jak epidemie, upadłości firm, itp., których rozprzestrzenianie się może być modelowane za pomocą grafu reprezentującego powiązanie jednostek takich jak osoby, gospodarstwa, czy firmy (wierzchołki grafu) siecią kontaktów, transportów, czy relacji biznesowych (krawędzie grafu).

Szczegółowe cele badawcze wynikające z realizacji celu głównego przedstawia Tab. 2. Z realizacji wymienionych celów wynikają publikacje omówione dokładniej w podpunktach 3.1.4-3.1.6. Na podstawie wyników przedstawionych w tych publikacjach można stwierdzić, że **postawione hipotezy badawcze zostały zweryfikowane w sposób pozytywny** (podpunkt 3.1.8).

Tab. 2. Szczegółowe cele badawcze oraz hipotezy

Cele	Hipotezy badawcze	Artykuły
<p>[C01] Opracowanie nowych algorytmów metaheurystycznych lub ich elementów (np. operatorów genetycznych) pozwalających na uzyskiwanie lepszych wyników optymalizacji w zagadnieniach związanych z zapobieganiem rozprzeszczeniu się zagrożeń w grafach.</p>	<p>[H01] Nowe operatory genetyczne dla algorytmów ewolucyjnych, modele probabilistyczne dla algorytmów estymacji rozkładów oraz algorytmy przeszukiwania lokalnego umożliwią uzyskiwanie lepszych rozwiązań dla problemów ochrony grafów przed zagrożeniami.</p>	<p>A01-A06</p>
<p>[C02] Opracowanie metod optymalizacji wykorzystujących modele uczenia maszynowego do ukierunkowania przeszukiwania w algorytmach metaheurystycznych oraz jako modeli zastępczych dla problemów z kosztowną ewaluacją rozwiązań.</p>	<p>[H02] Modele uczenia maszynowego użyte do ukierunkowania przeszukiwania w algorytmach metaheurystycznych umożliwią uzyskiwanie lepszych rozwiązań dla problemów ochrony grafów przed zagrożeniami.</p> <p>[H03] Modele uczenia maszynowego przyczynią się do poprawienia wyników optymalizacji poprzez ich użycie do sterowania operatorami genetycznymi, takimi jak operatory krzyżowania i mutacji.</p>	<p>A07-A13</p>
<p>[C03] Zbadanie wpływu struktury powiązań między podmiotami gospodarczymi na poziom ryzyka systemowego.</p>	<p>[H04] Gęstość grafu wpływa na propagowanie się zagrożeń, przy czym, dla małych wstrząsów początkowych duża gęstość grafu zmniejsza ryzyko systemowe, zaś w przypadku dużych wstrząsów początkowych duża gęstość grafu zwiększa ryzyko systemowe.</p> <p>[H05] Wybór strategii zaspokajania dłużników przez poszczególne podmioty ma istotny wpływ na ryzyko systemowe.</p>	<p>A12,A14</p>
<p>[C04] Zbadanie przydatności opracowanych metod dla rzeczywistych problemów optymalizacji w zagadnieniach ochrony przed zagrożeniami takimi jak epidemie, upadłości firm, itp.</p>	<p>[H06] Zastosowanie opracowanych metod do zapobiegania epidemiom oraz minimalizacji ryzyka systemowego pozwoli na lepsze zrozumienie tych problemów.</p> <p>[H07] Zastosowanie opracowanych metod do zapobiegania epidemiom oraz minimalizacji ryzyka systemowego pozwoli na uzyskanie lepszych wyników optymalizacji.</p>	<p>A15,A16</p>

3.1.2. Problemy ochrony grafów przed zagrożeniami

Wiele systemów istniejących w świecie rzeczywistym może być przedstawionych w postaci **grafu** $G = \langle V, E \rangle$, w którym V to zbiór wierzchołków, a E to zbiór krawędzi. W przypadku niektórych systemów, krawędzie grafu mogą reprezentować fizyczne połączenia jak na przykład segmenty sieci komputerowej, drogi, linie kolejowe, a także, w przypadku infrastruktury technicznej, sieci przesyłowe, telekomunikacyjne, itp. Ten sam formalizm można wykorzystać do opisu różnego rodzaju kontaktów i relacji, niekoniecznie mających charakter trwałego połączenia fizycznego. Przykładowo, używając grafu można opisać sieć kontaktów powodujących rozprzestrzenianie się epidemii lub też powiązania biznesowe między podmiotami gospodarczymi.

W opisanych powyżej systemach może dochodzić do **rozprzestrzeniania się zagrożeń**, takich jak złośliwe oprogramowanie w sieciach teleinformatycznych, patogeny w populacjach ludzi i zwierząt, a także fale upadłości dotykające podmioty gospodarcze. Każde z tych zagrożeń powoduje znaczne straty finansowe oraz niekorzystne skutki społeczne. Przykładowo, średnie straty spowodowane jednym atakiem przy pomocy oprogramowania wymuszającego okup (ang. *ransomware*) w 2022 roku wyniosły 4,54 miliona USD [IBM Security 2022], zaś globalne straty spowodowane takimi atakami w roku 2021 są szacowane na 20 miliardów USD [Lubin 2022]. W trakcie pandemii COVID-19 stwierdzono, do kwietnia 2023 roku, ponad 764 miliony przypadków choroby oraz ponad 6,9 miliona ofiar śmiertelnych [WHO 2023]. Skutki ekonomiczne tej pandemii są trudniejsze do oszacowania, tym niemniej szacowana przez Międzynarodowy Fundusz Walutowy wartość skumulowanego spadku produkcji do roku 2024 spowodowanego pandemią COVID-19 w skali globalnej wynosi 13,8 biliona USD [Agarwal 2022].

Epizootie (epidemie wśród zwierząt) także wyrządzają poważne szkody. Przykładowo, epidemia pryszczycy w Wielkiej Brytanii w 2001 roku kosztowała życie ponad 6 milionów zwierząt oraz spowodowała straty w wysokości ponad 3 miliardów GBP w sektorze publicznym i ponad 5 miliardów GBP w sektorze prywatnym [Boum 2002]. W skali globalnej, roczne straty powodowane przez pryszczycę oszacowano na 6,5-21 miliardów USD w rejonach endemicznego występowania tej choroby oraz na ponad 1,5 miliarda USD skutkiem epidemii pojawiających się w krajach uznawanych za wolne od tej choroby [Knight-Jones 2013]. Kryzysy gospodarcze także wywołują poważne, negatywne skutki. Według Government Accountability Office, instytucji kontrolnej Kongresu Stanów Zjednoczonych, wartość skumulowanego spadku produkcji będącego skutkiem kryzysu finansowego z lat

2007-2009 szacowana jest na od kilku do nawet dziesięciu bilionów USD¹ [GAO 2013]. W świetle tych danych, naturalne jest poszukiwanie skutecznych sposobów zapobiegania rozprzestrzenianiu się opisanych powyżej zagrożeń.

Dla opisanych powyżej zagrożeń, możliwe jest zdefiniowanie (w oparciu o formalizm grafowy) problemów optymalizacji, w których funkcjami celu mogą być: liczba wierzchołków grafu dotkniętych danym zagrożeniem, koszt ochrony przed zagrożeniem, itp. Problemy optymalizacji określone w ten sposób mogą różnić się sposobem rozprzestrzeniania się zagrożenia, przestrzenią rozwiązań, ograniczeniami, a także występowaniem losowości lub niepełnej informacji co do warunków początkowych. Krótką charakterystykę przykładowych problemów optymalizacji związanych z ochroną grafów przed zagrożeniami zawiera Tab. 3. Są one zróżnicowane pod względem mechanizmu propagacji, sposobów zapobiegania zagrożeniu oraz typowej reprezentacji rozwiązań. Ponieważ głównym tematem niniejszego opracowania są algorytmy optymalizacji, przedstawione zestawienie ma jedynie charakter poglądowy. Szerszą dyskusję mechanizmów propagacji (nie tylko zagrożeń) w sieciach rzeczywistych można znaleźć w książce [Król 2015].

Tab. 3. Krótka charakterystyka przykładowych problemów optymalizacji związanych z ochroną grafów przed zagrożeniami

Problem	Mechanizm propagacji	Ochrona przed zagrożeniem	Typowa reprezentacja rozwiązań
Problem Gaszenia Pożarów (ang. <i>Firefighter Problem</i>)	Deterministyczny	Zabezpieczenie N_f wierzchołków grafu w danym kroku symulacji.	Permutacje $\Pi_{ V }$
Zapobieganie epidemiom	Probabilistyczny	Szczepienie (proaktywne lub reaktywne) wierzchołków grafu.	Ciągi binarne $\{0, 1\}^{ V }$
Zapobieganie upadłościom	Progowy	Ustalenie poziomu rezerw dla wierzchołków grafu.	Wektory rzeczywiste $\mathbb{R}^{ V }$

¹ „Research suggests that U.S. output losses associated with the 2007-2009 financial crisis could range from several trillion to over \$10 trillion” [GAO 2013]

Problem Gaszenia Pożarów

Problem Gaszenia Pożarów (ang. *Firefighter Problem*, *FFP*) jest to abstrakcyjny problem zdefiniowany przez Hartnella w 1995 roku [Hartnell 1995], w którym symulowane jest rozprzestrzenianie się pożaru, przy czym wierzchołki grafu mogą znajdować się w jednym z trzech stanów:

- ‘B’ – objęty ogniem (ang. *Burning*),
- ‘D’ – chroniony przez strażaków (ang. *Defended*)
- ‘U’ – nieobjęty ogniem i niechroniony (ang. *Untouched*).

W chwili początkowej $t = 0$, pewna liczba N_s wierzchołków w grafie jest w stanie ‘B’, a w kolejnych krokach symulacji $t = 1, 2, 3, \dots$ ogień **rozprzestrzenia się deterministycznie** wzdłuż krawędzi grafu od wierzchołków w stanie ‘B’ do wierzchołków w stanie ‘U’. W każdym kroku symulacji, możliwe jest zabezpieczenie ograniczonej liczby N_f wierzchołków grafu będących w stanie ‘U’, które od tego momentu pozostają w stanie ‘D’ do końca symulacji. Parametr N_f reprezentuje ograniczenie zasobów, których możemy użyć do zwalczania zagrożenia. Symulacja kończy się po skończonej liczbie kroków, w momencie, gdy nie ma już żadnych wierzchołków w stanie ‘U’ sąsiadujących z wierzchołkami w stanie ‘B’. Może się to zdarzyć w sytuacji, gdy część grafu objęta ogniem jest otoczona wierzchołkami w stanie ‘D’ lub gdy wszystkie niechronione wierzchołki są w stanie ‘B’. Pomimo, że w klasycznej wersji problemu FFP rozprzestrzenianie się ognia jest deterministyczne, możliwe jest także zdefiniowanie **niedeterministycznej wersji problemu** [Michalak 2016b]. Ponieważ w każdym kroku symulacji możliwe jest zabezpieczenie ograniczonej liczby N_f wierzchołków grafu, **reprezentacja rozwiązań** w tym problemie optymalizacji musi być określona w taki sposób, aby było możliwe ustalenie kolejności, w jakiej wierzchołki grafu mają być chronione w trakcie symulacji. Typową reprezentacją rozwiązań w problemie FFP są permutacje $|V|$ wierzchołków grafu. Dla danego rozwiązania (permutacji) $\pi \in \Pi_{|V|}$, w każdym kroku symulacji wybieranych jest N_f wierzchołków grafu, które są w stanie ‘U’ i znajdują się na początku permutacji π . Wierzchołki, które już są objęte ogniem nie są brane pod uwagę przy wyborze z permutacji π (Alg. 1). Oprócz reprezentacji w postaci permutacji, możliwe jest użycie także **innych sposobów reprezentacji rozwiązań dla problemu FFP**, na przykład w celu zmniejszenia przeszukiwanej przestrzeni rozwiązań [Hu 2015]. W tym artykule zastosowano reprezentację w postaci wektorów binarnych wskazujących, które wierzchołki grafu należy chronić, oraz procedurę dekodowania

rozwiązań, w ramach której podejmowana jest decyzja, w którym kroku symulacji ochronić dany wierzchołek. Reprezentacja umożliwiająca zakodowanie liczby wierzchołków N_f chronionych w każdym kroku symulacji pozwala zdefiniować bezparametrową wersję problemu FFP (ang. *Parameterless Firefighter Problem*) [A06]. Wielokryterialna optymalizacja dla bezparametrowej wersji problemu FFP pozwala zbadać zależność między liczbą wierzchołków grafu, które nie zostają zniszczone przez ogień w trakcie całej symulacji, a zasobami użytymi do ochrony przed ogniem (maksymalna liczba N_f wierzchołków chronionych w jednym kroku symulacji lub całkowita liczba wierzchołków chronionych podczas całej symulacji).

```

IN:
   $S_{in}$  – the state of the graph before firefighter assignment
   $\pi$  – a permutation that represents the solution
   $N_f$  – the number of graph nodes that become protected in each time step
   $N_p$  – the number of nodes in the graph
OUT:
   $S_{out}$  – the state of the graph after firefighter assignment
   $A$  – a set of nodes which became protected

 $S_{out} := S_{in}$ 
 $A := \emptyset$ 
 $k := 0$ 
for  $i := 1, \dots, N_p$  do
  if  $S_{out}[\pi[i]] = 'U'$  then
     $S_{out}[\pi[i]] := 'D'$ 
     $A := A \cup \{\pi[i]\}$ 
     $k := k + 1$ 
  end if
  if  $k \geq N_f$  then
    return  $S_{out}$ 
  end if
end for
return  $S_{out}$ 

```

Alg. 1. Wybór wierzchołków grafu do ochrony na podstawie permutacji π [A05, Alg. 1]

W klasycznej wersji problemu FFP, **funkcją celu**, którą maksymalizujemy, jest liczba wierzchołków grafu, do których w trakcie symulacji nie dotarł ogień (tzn. wierzchołków, które są w stanie różnym od 'B' na końcu symulacji) [Hartnell 1995]. Ewaluacja rozwiązania (permutacji) $\pi \in \Pi_{|V|}$ dla jednokryterialnego problemu FFP jest dokonywana przez przeprowadzenie symulacji rozprzestrzeniania się pożaru na grafie $G = \langle V, E \rangle$, a następnie policzenie wierzchołków nieobjętych pożarem:

$$f(\pi) = \{v \in V: s[v] \neq 'B'\}. \quad (1)$$

W przypadku problemu FFP ze zmiennym kosztem wierzchołków [A03], celem jest zmaksymalizowanie kosztu wierzchołków uratowanych przed ogniem, zaś w przypadku, gdy

do każdego wierzchołka przypisanych jest kilka różnych wartości kosztu otrzymujemy problem wielokryterialny, w którym celem jest jednoczesna maksymalizacja kilku różnych funkcji celu [A01]. Wielokryterialną wersję problemu FFP można traktować jako abstrakcję problemów, w których musimy brać pod uwagę wartość chronionych obiektów pod względem różnych kryteriów. W przypadku ochrony przeciwpożarowej można sobie wyobrazić ocenę wartości materialnej i kulturowej chronionych obiektów, a w przypadku ochrony infrastruktury utratę różnych rodzajów zasobów, na przykład mocy obliczeniowej i przestrzeni dyskowej w sieci komputerowej, zaś w przypadku infrastruktury technicznej - dostaw energii elektrycznej, wody i gazu.

Zapobieganie epidemiom

Ważnym z punktu widzenia praktycznego problemem, do którego można zastosować metody optymalizacji, jest **zapobieganie epidemiom**. Zastosowane metody optymalizacji różnią się w zależności od przyjętego sposobu modelowania epidemii. Dobrze znanym podejściem do modelowania epidemii są **modele przedziałowe** (ang. *comparmental models*) [Brauer 2008], w których populacja nie jest modelowana jako poszczególne jednostki (osoby, zwierzęta, farmy, itp.), tylko jako zestaw kilku przedziałów obrazujących stany, w których te jednostki mogą się znajdować. Najczęściej reprezentowane stany to 'S' (ang. *susceptible*) dla jednostek podatnych na zakażenie oraz 'I' (ang. *infected*) dla zakażonych. W oparciu o te dwa stany można zbudować dwa modele epidemiologiczne: SI - przydatny do opisu patogenów pozostających na zawsze w organizmie nosiciela (np. HIV) [Ghosh 2018; López 2007] oraz SIS – model w którym po przebyciu infekcji jednostki stają się ponownie podatne na chorobę czyli wracają do stanu 'S' [Kuhl 2021b]. Ten drugi model jest przydatny do badania takich chorób jak katar czy grypa, których przebycie nie daje trwałej odporności. W przypadku chorób, których przebycie daje trwałą odporność wprowadzany jest stan 'R' (ang. *recovered*) dla ozdrowiałych, który jest używany w modelu SIR [Kuhl 2021a]. Model ten jest przydatny w badaniach nad takimi chorobami jak na przykład odra [Bjørnstad 2002]. W zastosowaniu do zagadnienia zapobiegania epidemiom użyteczne są takie modele przedziałowe, w których reprezentowane są stany odpowiadające działaniom przeciwepidemicznym, na przykład 'V' (ang. *vaccinated*) – jednostki zaszczepione w modelu SVIR [Tornatore 2014] lub 'Q' (ang. *quarantined*) – jednostki poddane kwarantannie w modelu SIQR [Zhang 2022].

Oprócz modeli przedziałowych, epidemie mogą być opisywane za pomocą **sieci złożonych** [Pastor-Satorras 2015], w których wierzchołki reprezentują jednostki podatne na

działanie patogenu, takie jak na przykład ludzie, zwierzęta, miasta, farmy, itp. zaś krawędzie reprezentują kontakty powodujące rozprzestrzenianie się choroby. Rozprzestrzenianie się epidemii może być także badane przy pomocy **modeli osobniczych** (ang. *Individual-Based Models, IBM*). Praca przeglądowa [Willem 2017] systematyzuje 698 artykułów naukowych, w których **modele osobnicze zostały wykorzystane wraz z symulacjami do badania rozprzestrzeniania się chorób zakaźnych** (ibid. str. 4). Zaletą modeli symulacyjnych jest możliwość uwzględnienia bardzo wielu parametrów opisujących wierzchołki w grafie oraz symulowania złożonych interakcji, w tym indywidualnych zachowań, a także różnych sposobów powstrzymywania rozprzestrzeniania się choroby. Ponadto, dostępne w literaturze wyniki sugerują przewagę modeli symulacyjnych nad przedziałowymi w zastosowaniu do planowania strategii szczepień [Dalgic 2017].

Zapobieganie upadłościom firm

Fale upadłości przedsiębiorstw można postrzegać jako zjawisko podobne do rozprzestrzeniania się epidemii: podmioty gospodarcze zmagające się z problemami nie są w stanie wywiązywać się ze swoich zobowiązań wobec innych podmiotów, które same popadają w kłopoty (np. tracą płynność finansową) i nie są w stanie regulować swoich zobowiązań. W ten sposób, trudności finansowe, a w skrajnym przypadku upadłości, dotyczą coraz większej liczby przedsiębiorstw. Upadłości firm mogą być modelowane z użyciem grafu $G = \langle V, E \rangle$ poprzez zastosowanie **progowego mechanizmu propagacji** zaproponowanego przez Watts [Watts 2002] i wykorzystanego m.in. przez Burkholz i współautorów [Burkholz 2016]. Rozprzestrzenianie się upadłości jest modelowane w czasie dyskretnym. W każdym kroku symulacji wierzchołek grafu (podmiot gospodarczy) $v \in V$ może znajdować się w stanie stabilności finansowej (ang. *healthy*) $s_t[v] = 0$ lub w stanie upadłości (ang. *failed*) $s_t[v] = 1$. W stanie początkowym pewna liczba wierzchołków jest w stanie upadłości, a pozostałe są w stanie stabilności finansowej. Dla każdego wierzchołka $v \in V$ określony jest próg $\Theta_v \in [0, 1]$, który można zinterpretować jako poziom rezerw utworzonych przez firmę, pozwalających zachować płynność finansową, nawet w przypadku upadłości partnerów biznesowych firmy v . Oznaczając zbiór sąsiadów wierzchołka v przez $N_v = \{ u \in V : \langle u, v \rangle \in E \}$ możemy wyznaczyć narażenie (ang. *fragility*) wierzchołka v jako:

$$\varphi_t[v] = \frac{1}{|N_v|} \sum_{u \in N_v} s_t[u], \quad (2)$$

gdzie:

- N_v - zbiór sąsiadów wierzchołka v w grafie G ,
- $s_t[u]$ - stan wierzchołka u w czasie t (stan stabilności finansowej $s_t[v] = 0$ lub stan upadłości $s_t[u] = 1$).

Jeśli narażenie $\varphi_t[v]$ wierzchołka v przekracza próg Θ_v przedsiębiorstwo v ogłasza upadłość, to znaczy w kroku $t + 1$ stan wierzchołka v jest ustawiany na $s_{t+1}[v] = 1$ i wierzchołek v pozostaje w tym stanie do końca symulacji.

Ryzyko załamania całego systemu gospodarczego lub jego znacznej części nazywane jest **ryzykiem systemowym** i jest ono spowodowane opisanym powyżej przenoszeniem wstrząsów i zaburzeń z pewnej grupy podmiotów na cały system, co prowadzi do globalnych kryzysów. **Minimalizacja ryzyka systemowego** może być przeprowadzona przy pomocy różnych metod obliczeniowych. W przypadku modelowania ryzyka finansowego przy użyciu modeli przedziałowych znanych z epidemiologii, takich jak np. SIR problem ograniczenia rozmiaru kryzysów finansowych został sformułowany jako **problem sterowania optymalnego** [Kostylenko 2018]. Inni autorzy zastosowali model przedziałowy SEIR w połączeniu z siecią powiązań handlowych i inwestycyjnych, co pozwoliło użyć **znanych z epidemiologii strategii zwalczania epidemii do minimalizacji ryzyka systemowego** [Li 2023]. Możliwe jest także opracowanie modeli programowania matematycznego, na przykład dla problemu modyfikacji sieci powiązań między podmiotami (ang. *network rewiring*), który może być rozwiązany **metodą mieszanego programowania całkowitoliczbowego** (ang. *mixed-integer linear programming, MILP*) [Diem 2020]. Problem modyfikacji sieci powiązań w celu redukcji ryzyka systemowego jest także rozwiązywany w literaturze przy pomocy **algorytmów ewolucyjnych** [Guo 2017; Luk 2016].

3.1.3. Podział cyklu publikacji na obszary tematyczne

Prezentowany opis cyklu publikacji został podzielony na trzy obszary tematyczne, które są dokładniej omówione w podpunktach 3.1.4-3.1.6:

- **Algorytmy metaheurystyczne.** Prace w tym obszarze tematycznym służyły realizacji celu badawczego C01 (por. Tab. 2), a więc dotyczyły opracowania nowych algorytmów metaheurystycznych lub ich elementów (np. operatorów genetycznych dla algorytmów ewolucyjnych, metod przeszukiwania lokalnego, itp.) pozwalających na

uzyskiwanie lepszych wyników optymalizacji w zagadnieniach związanych z zapobieganiem rozprzestrzenianiu się zagrożeń w grafach.

- **Algorytmy metaheurystyczne wykorzystujące modele uczenia maszynowego.** Prace w tym obszarze tematycznym służyły realizacji celu badawczego C02 (por. Tab. 2), Algorytmy będące wynikiem tych prac wykorzystują modele uczenia maszynowego, które pozwalają na ukierunkowanie przeszukiwania w algorytmach metaheurystycznych np. poprzez zastosowanie operatorów genetycznych kierowanych przez model uczenia maszynowego (ang. *informed operators*). Innym zastosowanym podejściem jest użycie algorytmów metaheurystycznych do optymalizacji modelu uczenia maszynowego (np. sieci neuronowej), który jest następnie wykorzystywany do podejmowania decyzji dotyczących ochrony wierzchołków grafu.
- **Zastosowania do problemów rzeczywistych.** Prace w tym obszarze tematycznym służyły realizacji celów badawczych C03 i C04 (por. Tab. 2). Realizacja celu C04 służy sprawdzeniu skuteczności działania już opracowanych metod, natomiast realizacja celu C03 pozwala wskazać możliwie kierunki dalszych badań nad minimalizacją ryzyka systemowego. Przeprowadzone prace dotyczyły zbadania wpływu strategii zaspokajania dłużników przez poszczególne podmioty gospodarcze na ryzyko systemowe oraz opracowania metod optymalizacji dla zagadnień związanych z zapobieganiem rozprzestrzenianiu się epidemii oraz upadłości firm przy wykorzystaniu modelowania z użyciem grafów. Do przeprowadzenia badań wykorzystano dane rzeczywiste uzyskane dzięki współpracy z zespołami badawczymi z Uniwersytetu Turyńskiego oraz Uniwersytetu w São Paulo i Banku Centralnego Brazylii, a także wyniki projektu badawczego zrealizowanego podczas pobytu w Uniwersytecie Turyńskim w ramach Programu Bekkera finansowanego przez Narodową Agencję Wymiany Akademickiej (NAWA).

3.1.4. Algorytmy metaheurystyczne

Prace badawcze dotyczące algorytmów metaheurystycznych (opisane w artykułach [A01]-[A06]) były ukierunkowane na **opracowanie nowych i ulepszanie istniejących metod optymalizacji** dla problemów zapobiegania rozprzestrzenianiu się zagrożeń w grafach. Jako **problem testowy** wykorzystywany do porównywania działania różnych algorytmów został wybrany Problem Gaszenia Pożarów (ang. *Firefighter Problem*, FFP) opisany w podpunkcie

3.1.2. W problemie FFP rozprzestrzenianie się pożaru w grafie jest deterministyczne, więc ewaluacja danego rozwiązania daje zawsze taki sam wynik, co jest korzystne przy eksperymentalnym porównywaniu działania różnych metod, ponieważ wyeliminowany jest wpływ losowego przebiegu symulacji na otrzymywane wyniki. Ponadto, nie ma potrzeby wykonywania wielu symulacji dla tego samego rozwiązania w celu uśrednienia wyników, co zmniejsza koszt obliczeniowy eksperymentów. Dla klasycznej (jednokryterialnej) wersji problemu FFP zostały opracowane algorytmy estymacji rozkładów prawdopodobieństwa [A03]. Wadą klasycznej wersji problemu FFP jest konieczność odgórnego ustalenia wartości parametru N_t , a także uwzględnienie tylko jednego kryterium, podczas gdy rozwiązywanie rzeczywistych problemów optymalizacji najczęściej wymaga uwzględnienia wielu, często sprzecznych, wymagań. W artykułach wchodzących w skład prezentowanego cyklu publikacji zaproponowane zostały **zmodyfikowane wersje problemu FFP**, które nie mają powyższych wad: wersja wielokryterialna oraz wersja bezparametrowa.


[A03] W artykule [A03] został zaproponowany **nowy model probabilistyczny S-P (ang. State-Position) dla algorytmów EDA** dla jednokryterialnej wersji problemu FFP reprezentujący zależność między stanem S grafu w danym kroku symulacji, wierzchołkiem v , który został ochroniony oraz średnią ewaluacją rozwiązania e uzyskaną dla rozwiązań, dla których wierzchołek v został ochroniony w momencie, gdy stan grafu był równy S . Stan grafu składa się ze stanu wszystkich wierzchołków grafu w danym kroku symulacji, tzn. $S \in L^{|V|}$, gdzie $L = \{ 'B', 'D', 'U' \}$. Model probabilistyczny M to lista trójek:

$$M = [\langle S_1, v_1, e_1 \rangle, \langle S_2, v_2, e_2 \rangle, \dots, \langle S_n, v_n, e_n \rangle], \quad (3)$$

gdzie: $S_i \in L^{|V|}$, $v_i \in V$, $e_i \in \mathbb{R}$.

W artykule [A03], **oprócz modelu S-P** zostały przetestowane: algorytm EDA wykorzystujący Model Mallowsa [Ceberio 2011], algorytm EDA wykorzystujący Uogólniony Model Mallowsa [Ceberio 2014], algorytm EH-PBIL, algorytm mrówkowy (ACO), algorytm ewolucyjny (EA) oraz algorytm przeszukiwania lokalnego ze zmiennym sąsiedztwem (VNS) [Hu 2015]. Metody wymienione powyżej zostały porównane w testach wykonanych dla instancji problemu FFP zdefiniowanych w oparciu o grafy Erdősa-Rényiego liczące 500, 750, 1000, 1250, 1500, 1750, 2000, 2250, 2500 oraz 5000 wierzchołków. Algorytm EDA wykorzystujący model S-P zaproponowany w artykule [A03] osiągnął najlepsze rezultaty spośród testowanych metod dla grafów o 1000 i więcej wierzchołków. Dla 500 i 750

wierzchołków najlepsze wyniki uzyskano przy pomocy algorytmu VNS. Rys. 1 przedstawia, pochodzące z artykułu [A03], wyniki optymalizacji dla grafów o 2500 wierzchołkach względem czasu wykonania programu przeprowadzającego optymalizację (większe wartości oznaczają lepsze wyniki). Algorytm EDA wykorzystujący model S-P zaproponowany w artykule [A03] uzyskuje lepsze wyniki optymalizacji dla czasów wykonania 100 sekund i więcej. Dla krótszych czasów wykonania inne algorytmy mogą dawać porównywalne lub lepsze wyniki, co można wytłumaczyć dużą złożonością procesu budowania modelu probabilistycznego. Algorytm EDA wykorzystujący model S-P charakteryzuje się szybkim ulepszaniem znalezionych rozwiązań. Porównywalne przyrosty osiągnął jedynie algorytm VNS, jednak daje on gorsze wyniki co do wartości bezwzględnych.



Rys. 1. Wyniki optymalizacji dla grafów o 2500 wierzchołkach (większe wartości oznaczają lepsze wyniki) [A03, Fig. 1].

[A01] W artykule [A01] klasyczny problem FFP został uogólniony do **wersji wielokryterialnej** poprzez przypisanie m różnych wartości $v_i(v)$, $i = 1, \dots, m$ do każdego z wierzchołków $v \in V$ w grafie G . Ewaluacja rozwiązania (permutacji) $\pi \in \Pi_{|V|}$ dla tak zdefiniowanej wersji wielokryterialnej jest przeprowadzana poprzez wykonanie symulacji rozprzestrzeniania się pożaru zgodnie z opisem w podpunkcie 3.1.2, a następnie wyliczenie wartości m funkcji celu:

$$f_i(\pi) = \sum_{v \in V: s[v] \neq 'B'} v_i(v), \quad (4)$$

dla $i = 1, \dots, m$,

gdzie: $s[v]$ oznacza stan wierzchołka v po zakończeniu symulacji: 'B' – objęty ogniem (ang. *Burning*), 'D' – chroniony przez strażaków (ang. *Defended*) lub 'U' – nieobjęty ogniem i niechroniony (ang. *Untouched*).

Tak zdefiniowany problem pozwala optymalizować rozwiązania z uwzględnieniem wielu kryteriów, np. wartości materialnej i kulturowej w przypadku pożarów, dostępności różnego rodzaju zasobów w przypadku infrastruktury, itp. Zdefiniowaną powyżej wielokryterialną wersję problemu FFP wykorzystano do badań nad metodami optymalizacji wielokryterialnej w artykułach [A01], [A02], [A04] oraz [A05]. W artykule [A01], oprócz zdefiniowania wielokryterialnej wersji problemu FFP, został użyty **mechanizm autoadaptacji**, który wybiera jeden z kilku operatorów genetycznych z prawdopodobieństwem zależnym od skuteczności działania danego operatora.

[A02] W artykule [A02] opracowany wcześniej **algorytm wielopopulacyjny** Sim-EA [Michalak 2014b] został dostosowany do rozwiązywania wielokryterialnej wersji problemu FFP oraz wyposażony w mechanizm autoadaptacyjny do wyboru operatorów genetycznych pochodzący z artykułu [A01]. W algorytmie Sim-EA, populacja podzielona jest na N_{sub} podpopulacji, między którymi przeprowadzana jest migracja rozwiązań kontrolowana przez wskaźniki podobieństwa $S_{i,j}$, gdzie i oraz j są numerami podpopulacji. W artykule [A02] algorytm Sim-EA jest zastosowany do rozwiązywania wielokryterialnego problemu optymalizacji, więc podpopulacje są przypisane do wektorów wagowych używanych do dekompozycji metodą sumy ważonej:

$$\lambda^{(j)} = \left[\frac{j}{H}, \frac{H-j}{H} \right], \quad (5)$$

gdzie:

$$j = 0, \dots, H,$$

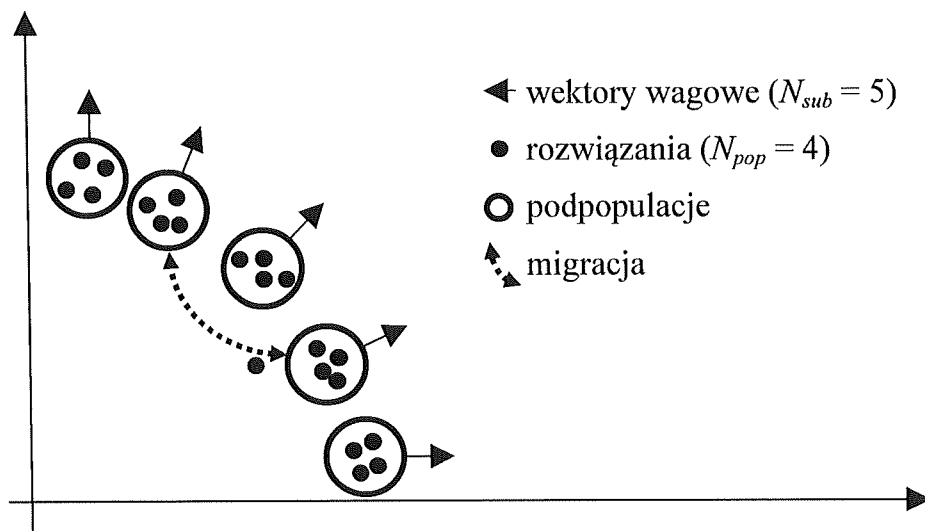
$$H = N_{\text{sub}} - 1,$$

N_{sub} – liczba podpopulacji w algorytmie Sim-EA,

zaś mechanizm migracji między podpopulacjami wykorzystuje wskaźnik podobieństwa obliczany jako iloczyn skalarny wektorów wagowych:

$$S_{i,j} = \lambda^{(i)} \cdot \lambda^{(j)}, \quad (6)$$

gdzie i oraz j są numerami podpopulacji w algorytmie Sim-EA. Ogólny schemat działania algorytmu Sim-EA dla problemu wielokryterialnego jest pokazany na Rys 2.



Rys 2. Działanie algorytmu Sim-EA [A02, Fig. 1].

W eksperymentach opisanych w artykule [A02], **algorytm Sim-EA uzyskał lepsze wyniki niż algorytm MOEA/D** [Li 2009; Zhang 2007], nawet w sytuacji, gdy ten drugi był uruchomiony dłużej.

[A04] W artykule [A04] został zaproponowany **operator krzyżowania SimX wykorzystujący symulacje wyspecjalizowany dla problemu FFP**. Operator SimX korzysta z dwóch wskaźników, które można wyliczyć dla każdego wierzchołka $v \in V$ w aktualnym stanie grafu S_t . Wskaźnik $W(S_t, v)$ to liczba kroków symulacji potrzebnych, aby ogień dotarł do wierzchołka v z wierzchołków objętych ogniem ('B') w stanie S_t . Wartość tego wskaźnika jest równa najmniejszej długości ścieżki łączącej jakikolwiek wierzchołek objęty ogniem ('B') w stanie S_t oraz wierzchołek v . Wskaźnik $D(S_t, v)$ to liczba krawędzi łączących wierzchołek v z wierzchołkami będącymi w stanie 'U'. Przy wyborze wierzchołków, które należy objąć ochroną preferowane są wierzchołki z niską wartością wskaźnika $W(S_t, v)$, a więc położone blisko ognia oraz te z wysoką wartością wskaźnika $D(S_t, v)$, a więc takie, z których ogień może się rozprzestrzenić na wiele wierzchołków w stanie 'U'. Operator SimX generuje rozwiązanie potomne (permutację) O na podstawie dwóch rozwiązań (permutacji) rodzicielskich R_1 i R_2 , przeprowadzając symulację rozprzestrzeniania się ognia od stanu początkowego S_0 . W każdym kroku symulacji, N_f wierzchołków grafu, które mają być chronione, jest wybieranych spośród wierzchołków znajdujących się na początkowych

miejscach w osobnikach (permutacjach) rodzicielskich R_1 i R_2 , przy czym preferowane są wierzchołki o niższych wartościach wskaźnika W , a w przypadku takich samych wartości wskaźnika W , te o wyższych wartościach wskaźnika D . Jeśli oba wskaźniki mają takie same wartości dla wierzchołków znajdujących się na początkowych miejscach w osobnikach (permutacjach) rodzicielskich R_1 i R_2 , to jeden z tych wierzchołków wybierany jest losowo. Do testowania operatora SimX użyty został algorytm Sim-EA [A02] stosujący operator krzyżowania SimX oraz 10 innych operatorów krzyżowania używanych dla permutacji. Operator SimX osiągnął najlepsze współczynniki sukcesu (ang. *success rate*) spośród użytych operatorów krzyżowania przy wysokim poziomie istotności statystycznej [A04, Tab. 1].

Prace nad algorytmami optymalizacji dla problemu FFP pozwoliły stwierdzić **skuteczność dwóch heurystyk wyboru wierzchołków grafu istotnych dla rozwiązywanego problemu**. Skutecznie działający operator krzyżowania SimX [A04] został opracowany przy wykorzystaniu dwóch wskaźników: liczby kroków symulacji potrzebnych, aby ogień dotarł do wierzchołka v z wierzchołków objętych ogniem ('B') w stanie S_t oraz liczby krawędzi łączących wierzchołek v z wierzchołkami będącymi w stanie 'U'. W artykule dotyczącym niedeterministycznej wersji problemu FFP [Michalak 2016b] dobre rozwiązania tego problemu optymalizacji udawało się znaleźć, chroniąc priorytetowo wierzchołki grafu o wysokim rzędzie (liczbie incydentnych krawędzi) oraz stosując heurystykę wykorzystującą minimalną długość ścieżki łączącej dany wierzchołek v z jakimkolwiek wierzchołkiem w stanie 'B'.

[A05] W artykule [A05] powyższe obserwacje zostały użyte do opracowania **algorytmu przeszukiwania lokalnego (ang. *local search*) ED-LS** pozwalającego uzyskiwać dobre rozwiązania dla wielokryterialnego problemu FFP przy jednoczesnym znacznym zmniejszeniu (do kilku procent) liczności sąsiedztwa przeszukiwanego przez algorytm. Metoda przeszukiwania lokalnego ED-LS **znacząco zmniejsza licznosc sąsiedztwa $N_{ED-LS}(\pi)$** rozwiązania π w porównaniu z sąsiedztwem $N(\pi)$ zawierającym wszystkie permutacje otrzymywane z π poprzez zamianę pary elementów miejscami. **Uzyskiwane wyniki są lepsze niż w przypadku metod porównawczych:** przeszukiwania sąsiedztwa $N(\pi)$ zawierającego wszystkie permutacje otrzymywane z π poprzez zamianę pary elementów miejscami, przeszukiwania sąsiedztwa o takiej samej liczności jak $N_{ED-LS}(\pi)$, wygenerowanego poprzez wykonanie losowych transpozycji oraz algorytmu ewolucyjnego bez przeszukiwania lokalnego. Oznacza to, że zastosowane wskaźniki $E(S_t, v)$ oraz $D(S_t, v)$

pozwalają poprawić uporządkowanie elementów permutacji π pod kątem uzyskania dobrych rozwiązań dla problemu FFP.

[A06] Podczas przeprowadzania badań opisanych w artykułach [A01]-[A05] dał się zaobserwować duży wpływ parametru N_f na uzyskiwane wyniki. Parametr ten określa liczbę wierzchołków grafu, które można ochronić w jednym kroku symulacji, a więc reprezentuje ograniczenie zasobów, których możemy użyć do zwalczania zagrożenia. Wybrana wartość parametru N_f ma bardzo duży wpływ na liczbę wierzchołków grafu, które można uratować. Przykładowo, jeśli wartość ta jest wystarczająco duża, żeby odciąć wierzchołki objęte ogniem na samym początku symulacji, to możliwe jest uratowanie znacznej części grafu. Z drugiej strony, dla ustalonej wartości parametru N_f , liczba wierzchołków grafu, które zostają ogarnięte przez pożar, zależy w dużym stopniu od struktury połączeń w grafie. Biorąc powyższe pod uwagę, w artykule [A06] została zaproponowana **bezparametrowa wersja problemu FFP**, w której liczba wierzchołków grafu chronionych w jednym kroku symulacji nie jest określona przez odgórnie określony parametr N_f , ale jest zakodowana w generowanych przez algorytm optymalizacji rozwiązaniach, poprzez wykorzystanie odpowiedniej reprezentacji tych rozwiązań. Dzięki takiemu podejściu, algorytm optymalizacji może dobrać liczbę chronionych wierzchołków do stopnia trudności instancji problemu. Każde rozwiązanie jest oceniane pod względem trzech kryteriów:

- f_1 – liczba wierzchołków objętych pożarem podczas symulacji,
- f_2 – maksymalna liczba wierzchołków chronionych w jednym kroku symulacji,
- f_3 – liczba wierzchołków chronionych w całej symulacji.

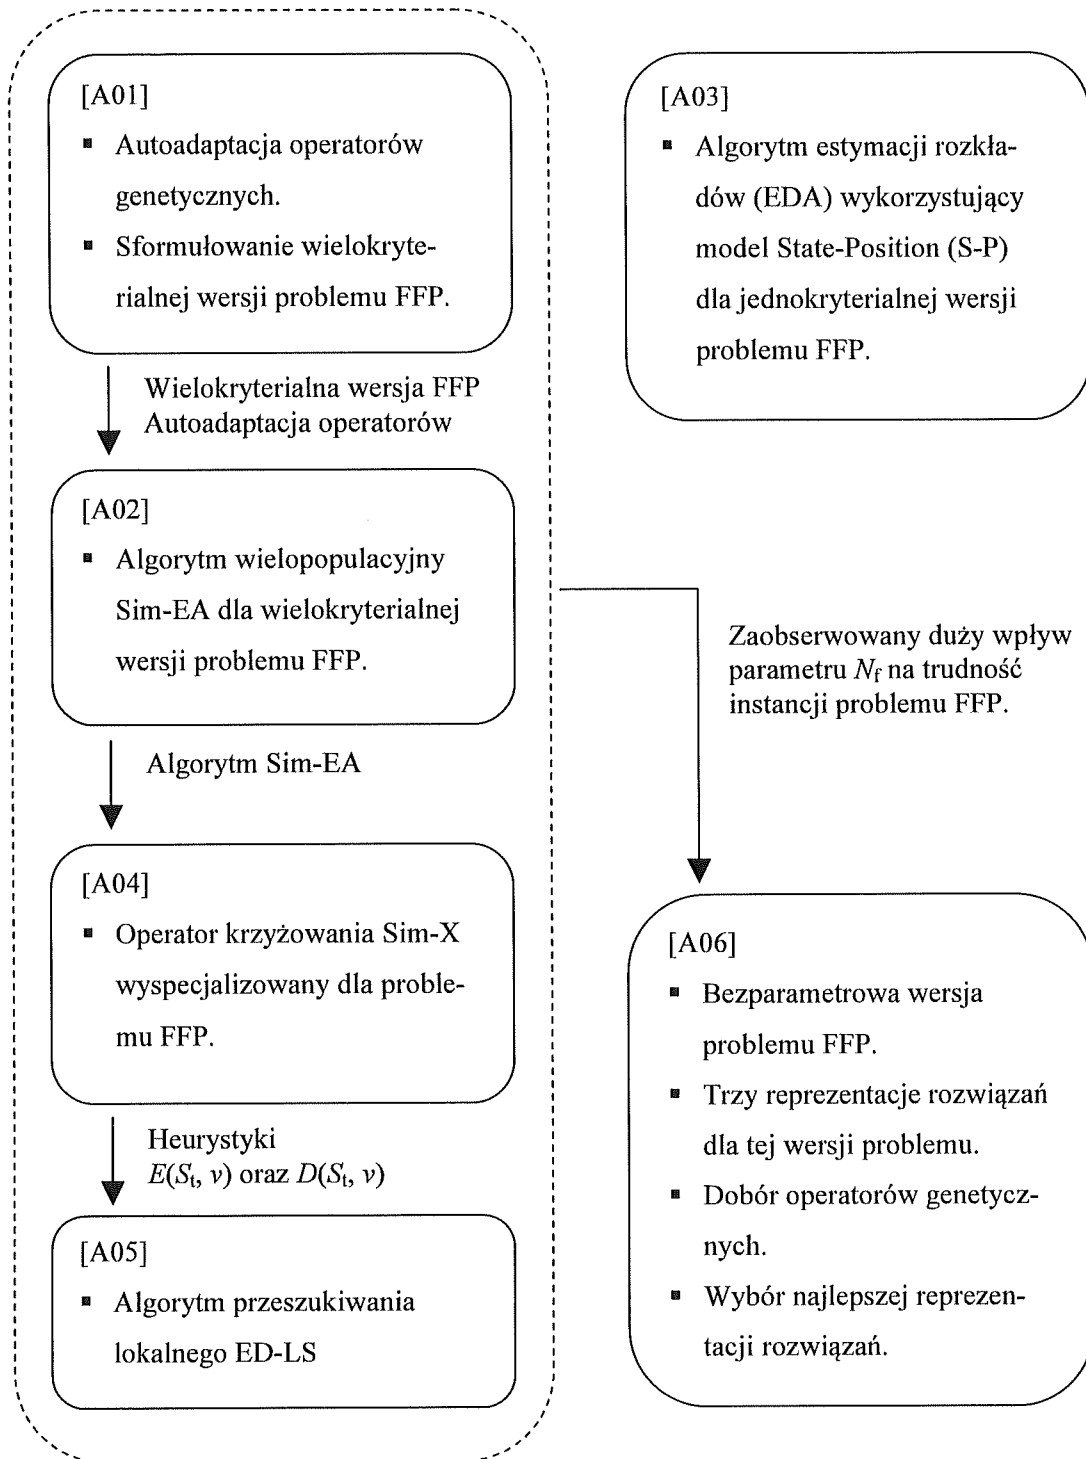
W omawianym artykule zostały zaproponowane trzy sposoby reprezentacji rozwiązań dla problemu FFP wraz z operatorami genetycznymi dostosowanymi do tych reprezentacji. Przeprowadzone eksperymenty miały na celu **dobór operatorów genetycznych dla każdej z reprezentacji** oraz porównanie skuteczności działania algorytmów ewolucyjnych korzystających z zaproponowanych reprezentacji. **Najlepsze wyniki optymalizacji** zarówno dla dwu-, jak i trzykryterialnej bezparametrowej wersji problemu FFP **zostały uzyskane przy użyciu reprezentacji N+P**, w której permutacja (P) jest dekodowana tak samo jak w klasycznej wersji problemu FFP, ale parametr N_f nie jest ustalony dla danej instancji problemu, tylko jest przechowywany jako liczba (N) w ramach genotypu.

Najważniejsze wyniki prac nad algorytmami metaheurystycznymi dla problemów zapobiegania rozprzestrzenianiu się zagrożeń w grafach to:

- Opracowanie, dla jednokryterialnej wersji problemu FFP, **algorytmu estymacji rozkładów (EDA)** wykorzystującego wyspecjalizowany dla tego problemu model S-P, który w przeprowadzonych eksperymentach okazał się lepszy od wielu innych metod optymalizacji [A03].
- Sformułowanie **dwóch nowych wersji problemu FFP**: wielokryterialnej [A01] oraz bezparametrowej [A06], która eliminuje problem wyboru wartości parametru N_f .
- Przeprowadzenie badań nad zastosowaniem **mechanizmu autoadaptacji** operatorów genetycznych dla wielokryterialnej wersji problemu FFP [A01].
- Przystosowanie **wielopopulacyjnego algorytmu Sim-EA z migracją opartą na podobieństwie podproblemów** do rozwiązywania wielokryterialnej wersji problemu FFP [A02]. Algorytm Sim-EA uzyskał lepsze wyniki niż algorytm MOEA/D, nawet w sytuacji, gdy ten drugi był uruchomiony dłużej.
- Zaproponowanie **operatora krzyżowania SimX wykorzystującego symulację** wyspecjalizowanego dla problemu FFP [A04]. Operator SimX osiągnął najlepsze współczynniki sukcesu (ang. *success rate*) spośród użytych operatorów krzyżowania przy wysokim poziomie istotności statystycznej. Wyniki uzyskane przez algorytm używający 10 operatorów krzyżowania oraz operator SimX są lepsze niż bez wykorzystania operatora SimX.
- Zaproponowanie **metody przeszukiwania lokalnego ED-LS dla problemu FFP** [A05], która dzięki zmniejszeniu przeszukiwanego sąsiedztwa pozwala uzyskać lepsze wyniki optymalizacji przy ustalonym koszcie obliczeniowym.
- Zaproponowanie **trzech reprezentacji rozwiązań** dla bezparametrowej wersji problemu FFP [A06] i przeprowadzenie badań mających na celu **dobór operatorów genetycznych dla każdej z reprezentacji** oraz porównanie skuteczności działania algorytmów ewolucyjnych korzystających z zaproponowanych reprezentacji.

Zależności między streszczonymi powyżej artykułami przedstawia Rys. 3. Dla każdego artykułu wskazane zostały najważniejsze zagadnienia w nim omawiane. Strzałki przedstawiają zależności między artykułami, takie jak wykorzystanie elementów

opracowanych w jednym artykule w innych, wnioski wpływające na sformułowanie tematu kolejnych prac badawczych, itp.



Rys. 3. Zależności między artykułami dotyczącymi algorytmów metaheurystycznych dla problemów zapobiegania rozprzestrzenianiu się zagrożeń w grafach

Podsumowując, przeprowadzenie opisanych w tym punkcie prac badawczych pozwoliło na **zrealizowanie celu szczegółowego C01**, czyli opracowanie nowych algorytmów metaheurystycznych lub ich elementów (np. operatorów genetycznych) pozwalających na uzyskiwanie lepszych wyników optymalizacji w zagadnieniach związanych z zapobieganiem rozprzestrzenianiu się zagrożeń w grafach. Otrzymane rezultaty wykazują uzyskiwanie, dzięki zaproponowanym metodom, lepszych rozwiązań dla problemów ochrony grafów przed zagrożeniami, co pozwala potwierdzić hipotezę badawczą H01.

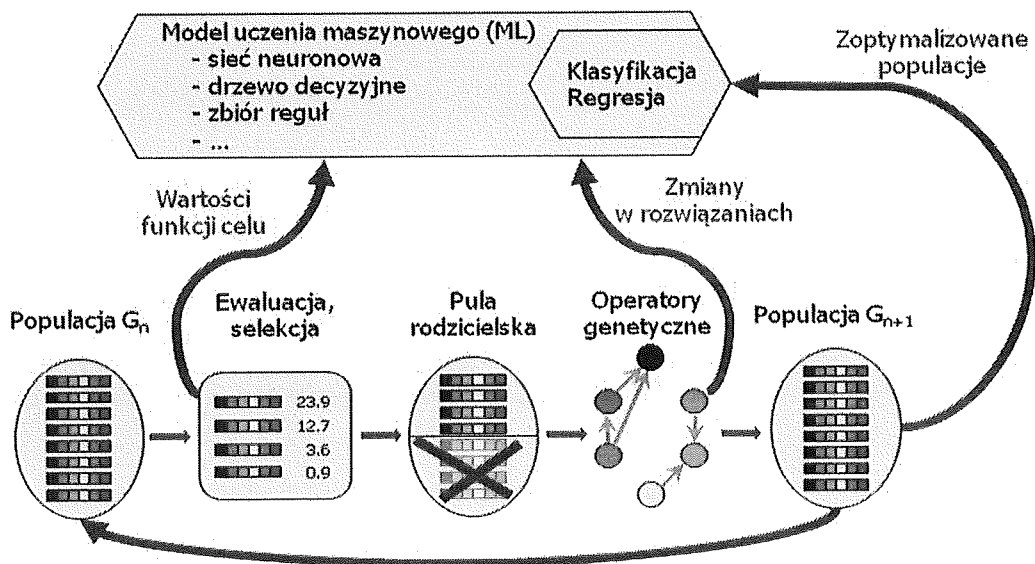
3.1.5. Algorytmy metaheurystyczne wykorzystujące modele uczenia maszynowego

Celem prac przeprowadzonych w tym obszarze badawczym i opisanych w artykułach [A07]-[A13] było **zastosowanie modeli uczenia maszynowego (ML) do wspomaganie optymalizacji w problemach ochrony grafów przed zagrożeniami**. Trudności, jakie występują przy próbach zastosowania modeli uczenia maszynowego w podobny sposób jak modeli probabilistycznych w algorytmach estymacji rozkładów (EDA), to znaczy do generowania całych rozwiązań, są następujące:

- **Brak możliwości zastosowania wielu typów modeli uczenia maszynowego do generowania całych rozwiązań** dla problemów ochrony grafów. Znaczna część modeli uczenia maszynowego jest przystosowana do generowania wyników w postaci pojedynczych, dyskretnych decyzji (np. klasyfikacji) albo odpowiedzi liczbowych (modele regresji). Współcześnie stosowane modele generujące złożone dane wyjściowe takie jak obrazy czy teksty, to w praktyce wyłącznie wielowarstwowe sieci neuronowe o miliardach parametrów, których wytrenowanie wymaga bardzo dużych zbiorów uczących oraz znacznych zasobów obliczeniowych. Zastosowanie prostszych, szybszych w trenowaniu, a co najważniejsze interpretowalnych modeli takich jak drzewa decyzyjne czy reguły nie wydaje się możliwe, jeśli chcielibyśmy generować całe rozwiązania dla problemów ochrony grafów.
- **Duża wielkość modelu**, który hipotetycznie mógłby działać dla tak dużych i złożonych problemów, a co za tym idzie bardzo wysoki koszt obliczeniowy wytrenowania takiego modelu.


- **Konieczność przygotowania bardzo dużej próbki uczącej** dla problemów grafowych, dla których ewaluacja rozwiązania wymaga przeprowadzenia kosztownych obliczeniowo symulacji.
- **Trudność w generalizacji uzyskanych wyników** dla instancji problemu o różnej wielkości (np. różnej liczbie wierzchołków grafu).

Z powyższych względów, w omawianych pracach przyjęte zostało podejście, w którym model uczenia maszynowego jest trenowany pod kątem modyfikacji istniejących rozwiązań lub też pozwala skonstruować nowe rozwiązanie stopniowo, poprzez generowanie poszczególnych elementów genotypu. Informacje potrzebne do skonstruowania próbki uczącej mogą pochodzić z ewaluacji rozwiązań, analizy zoptymalizowanych rozwiązań znalezionych przez algorytm ewolucyjny lub też mogą być zbierane podczas działania algorytmu (Rys. 4). Szczególnie istotnym źródłem informacji jest analiza zmian w rozwiązaniach wprowadzanych przez operatory genetyczne podczas działania algorytmu. Przykładowo, zmiana wartości elementów genotypu przez operator mutacji lub procedurę przeszukiwania lokalnego pozwala zaobserwować, jakie zmiany w genotypie przekładają się na poprawę uzyskiwanych rozwiązań. W przypadku reprezentacji permutacyjnej (np. dla problemu FFP), zmiana wartości funkcji celu wynikająca z zamiany elementów permutacji miejscami dostarcza informacji o pożądanej kolejności elementów w permutacji.

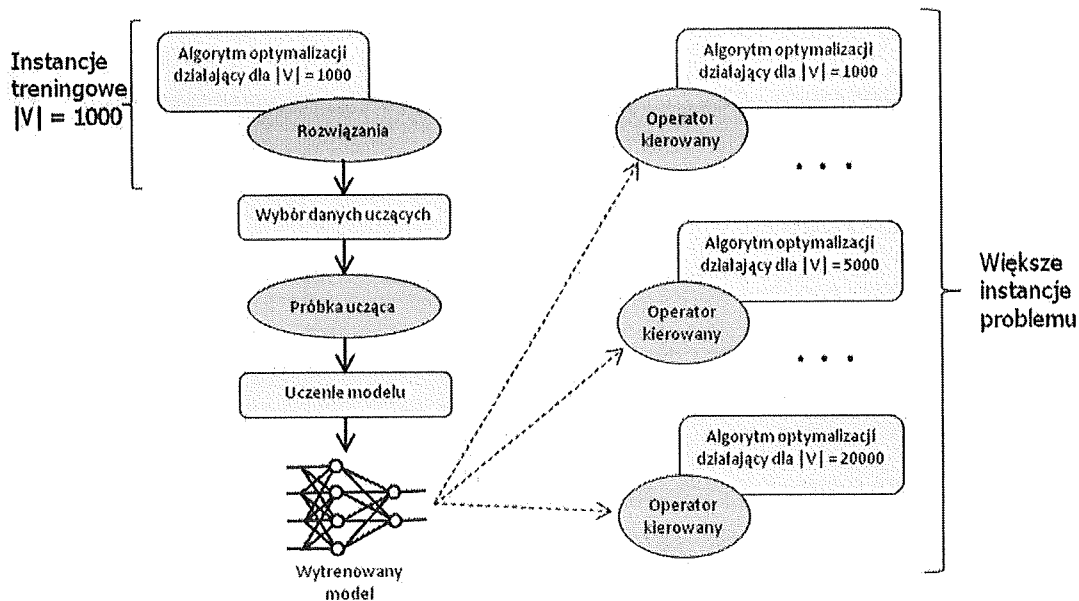


Rys. 4. Pozyskiwanie informacji potrzebnych do wytrenowania modelu uczenia maszynowego
 [źródło: raport końcowy z realizacji projektu NCN 2015/19/D/HS4/02574, Rys. 2]

Po wytrenowaniu, model uczenia maszynowego może być użyty na kilka różnych sposobów do wspomaganie działania algorytmu ewolucyjnego (Rys. 5). Populacja początkowa może być zainicjowana z użyciem modelu, co pozwala rozpocząć pracę algorytmu od relatywnie dobrych rozwiązań początkowych. W przypadku problemów ochrony grafu przed zagrożeniami, można użyć modelu uczenia maszynowego jako modelu zastępczego (ang. *surrogate model*) zamiast kosztownych symulacji w celu zmniejszenia kosztu obliczeniowego ewaluacji rozwiązań. Informacje generowane przez model mogą być użyte wraz z kierowanymi operatorami genetycznymi (ang. *informed operators*) w celu uzyskania lepszych rozwiązań. Przykładowo, model uczenia maszynowego może ukierunkować operator krzyżowania w taki sposób, żeby generował on lepsze rozwiązania potomne na podstawie rozwiązań rodzicielskich. Trenowanie modelu może być kosztowne obliczeniowo, nawet dla stosunkowo prostych modeli uczenia maszynowego. Aby zmniejszyć wpływ tych obliczeń na koszt optymalizacji można uczyć model na danych uzyskanych na podstawie działania algorytmu dla mniejszych instancji danego problemu, a następnie próbować zastosować już wytrenowany model przy rozwiązywaniu innych, często większych, instancji problemu zgodnie z zasadą „wytrenuj raz, stosuj wielokrotnie” (Rys. 6).



Rys. 5. Użycie modelu uczenia maszynowego do wspomaganie działania algorytmu ewolucyjnego
 [źródło: raport końcowy z realizacji projektu NCN 2015/19/D/H54/02574, Rys. 3]



Rys. 6. Użycie modelu uczenia maszynowego zgodnie z zasadą „wytrenuj raz, stosuj wielokrotnie” [A08, Fig. 1]

W przypadku problemów ochrony grafów przed zagrożeniami, w których decyzje dla poszczególnych wierzchołków grafu mają charakter *tak/nie* (np. szczepienia), modele uczenia maszynowego mogą być użyte w celu podejmowania decyzji, które wierzchołki grafu mają być chronione, a które nie. W takim przypadku można wykorzystać modele klasyfikacji zwracające jedną z dwóch klas: *chronić* lub *nie chronić*. Modele klasyfikacji można też wykorzystać dla problemów, w których istotna jest kolejność chronienia wierzchołków grafu (np. FFP). W takim przypadku model może generować decyzje dla par wierzchołków (elementów permutacji): *zamienić miejscami* lub *nie zamieniać*. W przypadku problemów, takich jak problem ochrony przed upadłościami, w którym do każdego wierzchołka grafu $v \in V$, przypisany jest poziom rezerw Θ_v (liczba rzeczywista z przedziału $[0, 1]$) zamiast modelu klasyfikacji może być użyty model regresji generujący sugerowane dla poszczególnych wierzchołków wartości Θ_v . Atrybuty wejściowe dla modelu uczenia maszynowego to różnego rodzaju miary grafowe przypisane do wierzchołka v w grafie $G = \langle V, E \rangle$ takie jak:

- **Stopień wierzchołka** – liczba krawędzi incydentnych z wierzchołkiem v . Może być też stosowana miara będąca rzędem wierzchołka znormalizowanym przez podzielenie przez $|V| - 1$, co umożliwia generalizację dla grafów o różnej wielkości.

- **Bliskość** (ang. *closeness centrality*) – odwrotność średniej długości najkrótszych ścieżek łączących v z wszystkimi innymi wierzchołkami w grafie:

$$(|V| - 1) \frac{1}{\sum_{w \neq v} d_{\min}(v, w)}, \quad (7)$$

gdzie $d_{\min}(v, w)$ jest długością najkrótszej ścieżki łączącej wierzchołki v i w .

- **Pośrednictwo** (ang. *betweenness centrality*) – miara określająca, jak często najkrótsze ścieżki łączące inne wierzchołki przechodzą przez wierzchołek v :

$$\frac{1}{(|V|-1)(|V|-2)} \sum_{s \neq v \neq t} \frac{\sigma(s, t | v)}{\sigma(s, t)}, \quad (8)$$

gdzie $\sigma(s, t)$ to liczba najkrótszych ścieżek łączących wierzchołki s i t ,

zaś $\sigma(s, t | v)$ to liczba najkrótszych ścieżek łączących wierzchołki s i t i przechodzących przez v .

- **Lokalny współczynnik grupowania** (ang. *local clustering coefficient*) – liczba krawędzi łączących wierzchołki sąsiadujące z v , podzielona przez liczbę krawędzi w grafie pełnym który powstałby z połączenia ze sobą wszystkich sąsiadów wierzchołka v :

$$\frac{| \{ (u, w) \in E : u, w \in N_v \} |}{k_v(k_v - 1)}, \quad (9)$$

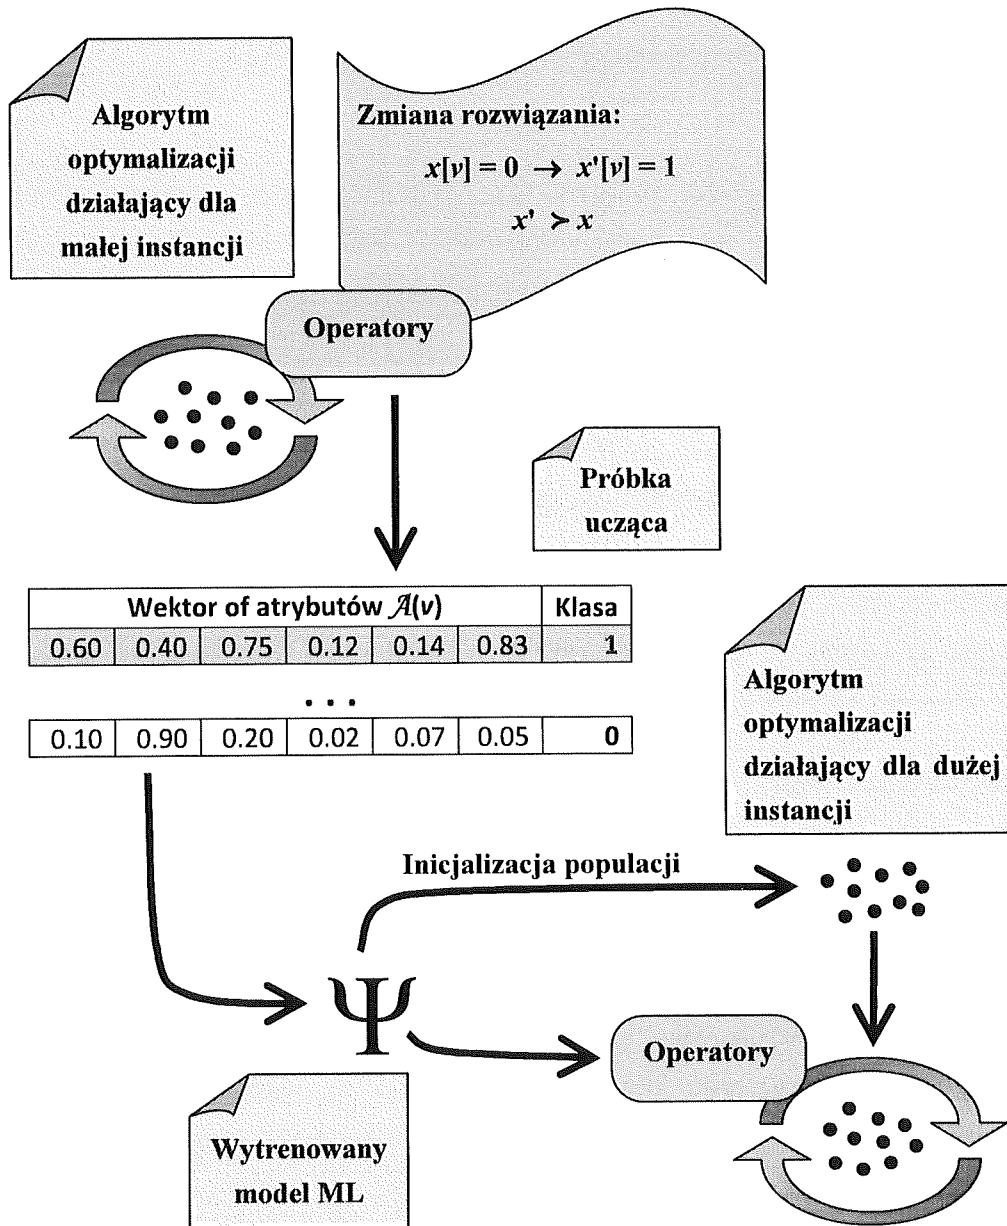
gdzie:

$N_v = \{ u \in V : \langle u, v \rangle \in E \vee \langle v, u \rangle \in E \}$ – zbiór wierzchołków będących sąsiadami wierzchołka v ,

$k_v = |N_v|$ – stopień wierzchołka v .

Warto zwrócić uwagę, że **wymienione powyżej atrybuty mogą być obliczone jednokrotnie dla danej instancji problemu**, w oparciu o graf $G = \langle V, E \rangle$. Innym rodzajem atrybutów, które mogą być łatwo wyznaczone dla wierzchołka v , są atrybuty określające, w jakim odsetku symulacji wykonywanych w celu ewaluacji rozwiązań wierzchołek v zostaje opanowany przez zagrożenie (ogień, infekcję, upadłość, itp.). Jeśli ochrona grafu ma charakter reakcyjny, a nie prewencyjny (np. szczepienia w przypadku już istniejącej epidemii a nie przed jej wystąpieniem, albo problem FFP), to istotne mogą być atrybuty określające odległość wierzchołka v od zagrożenia, wyrażoną np. jako długość najkrótszej ścieżki łączącej v z jakimkolwiek wierzchołkiem objętym zagrożeniem. Próbką ucząca używana do

trenowania modelu uczenia maszynowego może być zbudowana w oparciu o zmiany jakie są wprowadzane w rozwiązaniach podczas działania algorytmu ewolucyjnego rozwiązującego małą instancję problemu (Rys. 7).



Rys. 7. Trenowanie i użycie modelu uczenia maszynowego [A10, Fig. 2]

Przykładowo, jeśli procedura przeszukiwania lokalnego modyfikuje rozwiązanie $x \in \{0, 1\}^M$ w taki sposób, że w istniejącym rozwiązaniu x jest $x[v] = 0$, a w nowym, lepszym rozwiązaniu x' jest $x'[v] = 1$, to dodawany jest element próbki uczącej składający się z

wektora atrybutów \mathcal{A} wierzchołka v oraz nowej wartości genotypu $x'[v]$, która jest traktowana jako wartość, którą powinien przewidzieć model uczenia maszynowego:

$$\langle \mathcal{A}[v], x'[v] \rangle. \quad (10)$$

Po zgromadzeniu w próbce uczącej wielu par postaci (10), model uczenia maszynowego jest trenowany tak, żeby na podstawie wektora atrybutów $\mathcal{A}[v]$ podanego na wejściu przewidywał decyzję *chronić* lub *nie chronić* dla wierzchołka v reprezentowaną jako wartość $x'[v]$ równa 0 bądź 1. Analogicznie można utworzyć próbkę uczącą dla problemów, w których do wierzchołków grafu przypisywane są wartości liczbowe, w przypadku których można wytrenować modele regresji oraz dla problemów, dla których rozwiązania reprezentowane są w postaci permutacji (np. FFP). W tym ostatnim przypadku, informacje zawarte w próbce uczącej, to atrybuty dwóch wierzchołków v_1 i v_2 , zaś klasa określa, czy wierzchołek v_1 powinien poprzedzać v_2 w permutacji (klasa 0), czy na odwrót (klasa 1). Taka próbka ucząca może być utworzona na podstawie informacji pochodzących z działania np. procedury przeszukiwania lokalnego wykonującej transpozycje elementów permutacji (Rys. 8).

W artykułach [A07]-[A13] zaproponowane zostały metody rozwiązywania problemów ochrony grafów wykorzystujące opisane powyżej podejście do usprawnienia działania różnych aspektów działania algorytmów ewolucyjnych.

[A07] W artykule [A07] rozważany jest **problem ochrony grafu przed ryzykiem systemowym**. Rozwiązania tego problemu to wektory binarne ze zbioru $\{0,1\}^{|V|}$ z ograniczeniem pozwalającym ochronić co najwyżej N_t wierzchołków grafu (11). Ograniczenie to reprezentuje maksymalny całkowity koszt, jaki jesteśmy skłonni ponieść w celu ochrony systemu.

$$\forall_{x \in \{0,1\}^{|V|}} \sum_{i=1}^{|V|} x_i \leq N_t, \quad (11)$$

Informacje pochodzące z rozwiązań zoptymalizowanych dla $|V| = 1000$ są użyte do wygenerowania reguł w postaci:

$$\text{warunek}_1 \text{ and } \text{warunek}_2 \text{ and } \dots \text{ and } \text{warunek}_n \Rightarrow \text{decyzja} \quad (12)$$

w których każdy *warunek* łączy jeden z atrybutów z wektora $\mathcal{A}[v]$ z wartością liczbową przy pomocy operatorów porównania (\leq , $>$, $=$, itd.), a *decyzja* dla wierzchołka v to *chronić* lub *nie*

chronić. Otrzymane reguły pomagają w **wygenerowaniu populacji początkowej** dla algorytmów optymalizacji działających dla $|V| = 1000, \dots, 3000$. Rozwiązania w populacji początkowej są generowane jako losowe wektory binarne, następnie modyfikowane w oparciu o decyzje zwracane przez reguły. Aby uniknąć nadmiernego zmniejszenia różnorodności populacji, modyfikacja każdego rozwiązania w populacji początkowej jest wykonywana z prawdopodobieństwem $P_{\text{mod}/s}$, zaś każdego elementu (bitu) w genotypie z prawdopodobieństwem $P_{\text{mod}/p}$. Eksperymenty opisane w artykule [A07] wykazały, że najlepsze wartości dla tych parametrów to $P_{\text{mod}/s} = 0.8$ oraz $P_{\text{mod}/p} = 0.8$. Są to więc wartości zapewniające uwzględnienie wiedzy zawartej w regułach dla wielu rozwiązań, ale pozwalające części populacji pozostać niezmodyfikowanej.

[A08] W artykule [A08] rozważany jest **problem optymalizacji szczepień**, w którym rozwiązaniami są wektory binarne ze zbioru $\{0, 1\}^{|V|}$ reprezentujące decyzje *szczepić* lub *nie szczepić* dla poszczególnych wierzchołków grafu. Ewaluacja rozwiązania $x \in \{0, 1\}^{|V|}$ jest wyznaczana jako koszt ważony $f(x) = C_v f_v + C_i f_i$ wyliczany na podstawie liczby zaszczepionych wierzchołków $f_v(x) = \sum_{i=1}^{|V|} x_i$ oraz f_i – liczby zainfekowanych wierzchołków podczas symulacji wykorzystujących rozwiązanie x do aplikowania szczepień. Współczynniki C_v oraz C_i oznaczają, odpowiednio, koszt zaszczepienia wierzchołka oraz koszt wynikający z jego zainfekowania (w artykule przyjęto $C_v = 1$ oraz $C_i = 10$). Agregacja dwóch funkcji celu przy pomocy sumy ważonej pozwala jednoznacznie określić, że rozwiązanie x_1 jest lepsze niż x_2 jeśli $f(x_1) < f(x_2)$, co nie zawsze jest możliwe dla problemów wielokryterialnych. Możliwość uporządkowania rozwiązań pod względem ich jakości jest pomocna przy generowaniu danych uczących używanych do trenowania modelu uczenia maszynowego.

Model uczenia maszynowego (perceptron wielowarstwowy [Vang-Mata 2020]) służy w artykule [A08] do **kierowania operatorem mutacji**. Dla danego rozwiązania $x \in \{0, 1\}^{|V|}$ kierowany operator mutacji modyfikuje tylko elementy z podzbioru M wybranego przy użyciu decyzji generowanych przez model. Dane do trenowania sieci neuronowej uzyskiwane są poprzez zastosowanie dodatkowej procedury po zakończeniu każdej generacji algorytmu ewolucyjnego działającego dla $|V| = 1000$ [A08, Alg. 1]. Procedura ta, dla każdego rozwiązania x z populacji, wybiera losowo jeden element p_0 wektora x równy 0 i zamienia jego wartość na 1. Oznacza to zmianę decyzji dla wierzchołka grafu p_0 z *nie szczepić* na *szczepić*. Jeśli powoduje to poprawienie rozwiązania x pod względem kosztu f , to do próbki uczącej dodawana jest para $\langle \mathcal{A}[p_0], 1 \rangle$, w której $\mathcal{A}[p_0]$ jest wektorem atrybutów (m.in. miar

grafowych) przypisanych do wierzchołka p_0 . Analogicznie, z rozwiązania x wybierany jest jeden element p_1 równy 1, którego wartość zamieniana jest na 0. Jeśli uzyskiwana jest poprawa rozwiązania, to do próbki uczącej dodawany jest para $\langle \mathcal{A}[p_1], 0 \rangle$. Po zakończeniu działania algorytmu ewolucyjnego, zebrana próbka ucząca jest używana do wytrenowania sieci neuronowej metodą skalowanych gradientów sprzężonych (ang. *Scaled Conjugate Gradient*, SCG) [Ariana 2023]. Użyta sieć neuronowa ma tyle wejść, ile jest atrybutów wejściowych (elementów w wektorze \mathcal{A}) oraz dwa wyjścia o_1 i o_2 reprezentujące możliwe klasyfikacje wierzchołków grafu: 0 = *nie szczepić* oraz 1 = *szczepić*. Użycie sieci neuronowej [A08, Alg. 2] w operatorze mutacji działającym dla rozwiązania $x \in \{0, 1\}^{|V|}$ polega na podaniu na wejściu sieci neuronowej wektora atrybutów $\mathcal{A}[i]$ kolejno dla każdego i -tego wierzchołka grafu oraz podjęciu decyzji, czy element rozwiązania $x[i]$ powinien być poddany mutacji czy nie, na podstawie wartości $x[i]$ oraz wyjść sieci neuronowej o_1 i o_2 . W trybie **deterministycznym** indeks i jest dodawany do zbioru M zawsze, gdy decyzja wygenerowana przez sieć neuronową jest inna niż wartość elementu $x[i]$ (to znaczy, gdy $x[i] = 0$ oraz $o_2 > o_1$, lub $x[i] = 1$ oraz $o_2 < o_1$). W trybie **probabilistycznym** prawdopodobieństwo $P_{add}(i)$ dodania indeksu i do zbioru M jest proporcjonalne do znormalizowanej wartości wyjścia reprezentującego wartość „przeciwną” do $x[i]$:

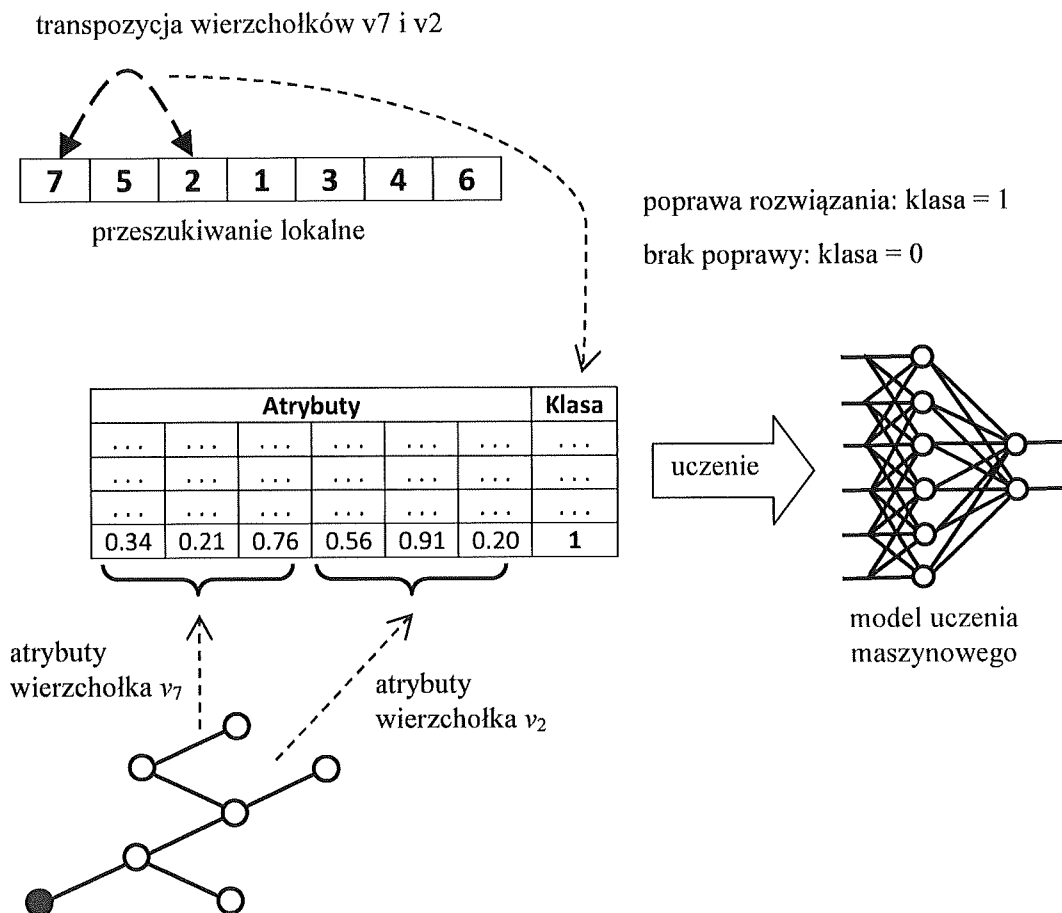
$$P_{add}(i) = \begin{cases} \frac{o_2}{(o_1 + o_2)} & \text{dla } x[i] = 0 \\ \frac{o_1}{(o_1 + o_2)} & \text{dla } x[i] = 1 \end{cases} \quad (13)$$

Operator mutacji losowo odwraca (zamienia z 0 na 1 lub na odwrót) wartości tych elementów (bitów), których indeksy są w zbiorze M .

Optymalizacja z wykorzystaniem zaproponowanego operatora mutacji daje lepsze wyniki niż z klasycznym operatorem mutacji bitowej (ang. *bit-flip mutation*), która dokonuje modyfikacji wszystkich elementów rozwiązania x z jednakowym prawdopodobieństwem. W artykule [A08] użycie sieci neuronowej wytrenowanej w oparciu o dane zebrane dla $|V| = 1000$ pozwoliło poprawić wyniki optymalizacji nawet dla $|V| = 20000$. Sieci neuronowe wybrane pod kątem wysokiej kompletności (ang. *recall*) klasyfikacji pozwoliły uzyskać najlepsze wyniki. Oznacza to, że, w przypadku omawianego problemu, istotniejsze jest zidentyfikowanie możliwie wielu wierzchołków wymagających zaszczepienia, niż unikanie zaszczepienia zbyt wielu wierzchołków. W większości przypadków, metoda wykorzystująca operator mutacji kierowany siecią neuronową działała *szybciej* niż bez tego operatora. Ten

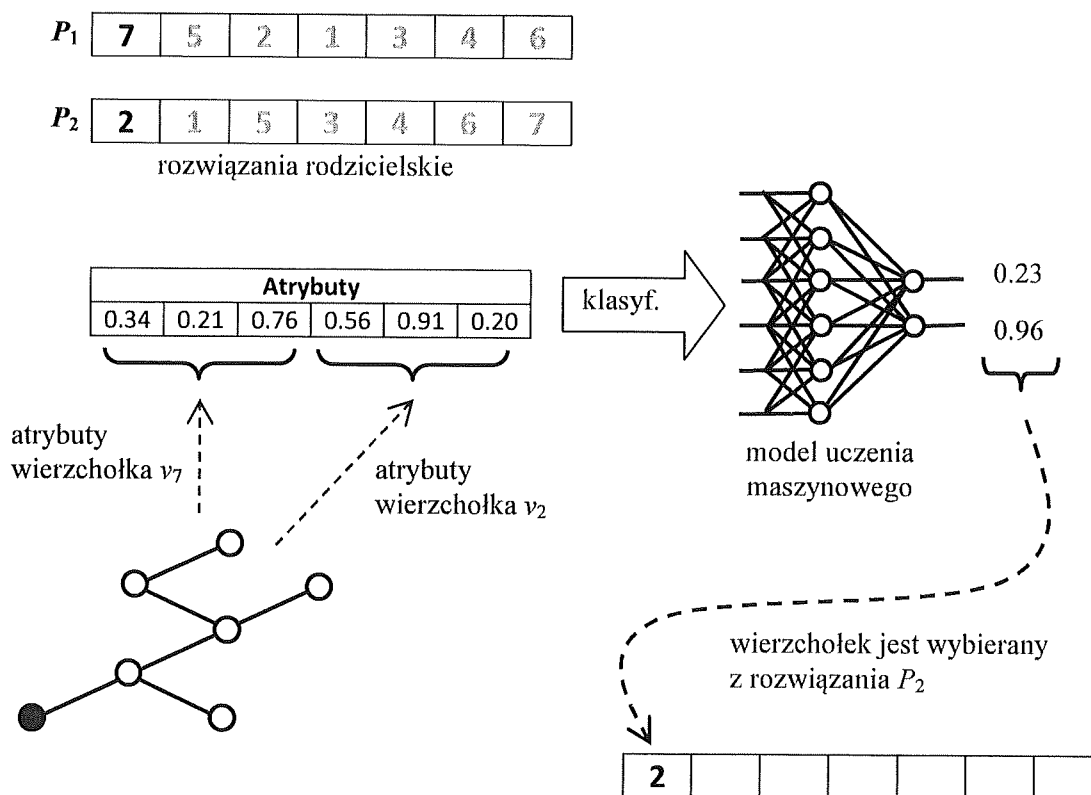
z pozoru paradoksalny wynik jest efektem tego, że w przypadku lepiej zoptymalizowanych rozwiązań epidemia wygasa szybciej, a więc symulacje przebiegu epidemii trwają krócej.

[A09] W artykule [A09] rozważany jest jednokryterialny **Problem Gaszenia Pożarów** (ang. Firefighter Problem, FFP) opisany w podpunkcie 3.1.2, w którym funkcją celu (maksymalizowaną) jest liczba wierzchołków grafu nieobjętych ogniem (1). W artykule [A09] dla tego problemu został zaproponowany **operator krzyżowania kierowany siecią neuronową**. Ponieważ w omawianym problemie rozwiązaniami są permutacje, sieć neuronowa używana jest jako klasyfikator, który dla danych dwóch wierzchołków grafu decyduje, w jakiej kolejności powinny być użyte w generowanym przez operator krzyżowania rozwiązaniu potomnym. Dane uczące są zbierane przez operator przeszukiwania lokalnego, który przeszukuje otoczenie rozwiązania (permutacji) $\pi \in \Pi_{|V|}$ znalezione przez algorytm ewolucyjny, dokonując zamiany miejscami (transpozycji) elementów tej permutacji (Rys. 8).



Rys. 8. Trenowanie modelu uczenia maszynowego dla problemu FFP [A09, Fig. 1]

Każdy element próbki uczącej zawiera atrybuty $\mathcal{A}[v_1]$ oraz $\mathcal{A}[v_2]$ odpowiednio dla wierzchołka v_1 (znajdującego się wcześniej w permutacji π) oraz wierzchołka v_2 (występującego później w tej permutacji). Klasa odpowiadająca w próbce uczącej wektorowi atrybutów wejściowych $\langle \mathcal{A}[v_1], \mathcal{A}[v_2] \rangle$ jest równa 1, jeśli zamiana v_1 i v_2 miejscami pozwoliła poprawić rozwiązanie π lub 0 w przeciwnym przypadku. Zaproponowany w artykule [A09] operator krzyżowania generuje rozwiązanie potomne S na podstawie dwóch rozwiązań rodzicielskich P_1 i P_2 . Rozwiązanie S jest generowane w $|V|$ przebiegach pętli, z których każdy powoduje dodanie jednego elementu do S [A09, Alg. 1]. W każdym przebiegu pętli, z rozwiązania P_1 wybierany jest pierwszy wierzchołek v_1 , który jeszcze nie znajduje się w S oraz, analogicznie, wierzchołek v_2 z P_2 . Na wejście sieci neuronowej podawany jest wektor atrybutów $\langle \mathcal{A}[v_1], \mathcal{A}[v_2] \rangle$. Jeśli wyjście sieci odpowiadające klasie 0 ma większą wartość niż wyjście odpowiadające klasie 1, to do S jest dodawany wierzchołek v_1 , a w przeciwnym przypadku wierzchołek v_2 (Rys. 9). W artykule [A09] użycie sieci neuronowej wytrenowanej w oparciu o dane zebrane dla $|V| = 1000$ pozwoliło poprawić wyniki optymalizacji nawet dla $|V| = 10000$.



Rys. 9. Użycie modelu uczenia maszynowego w operatorze krzyżowania dla problemu FFP [A09, Fig. 2]

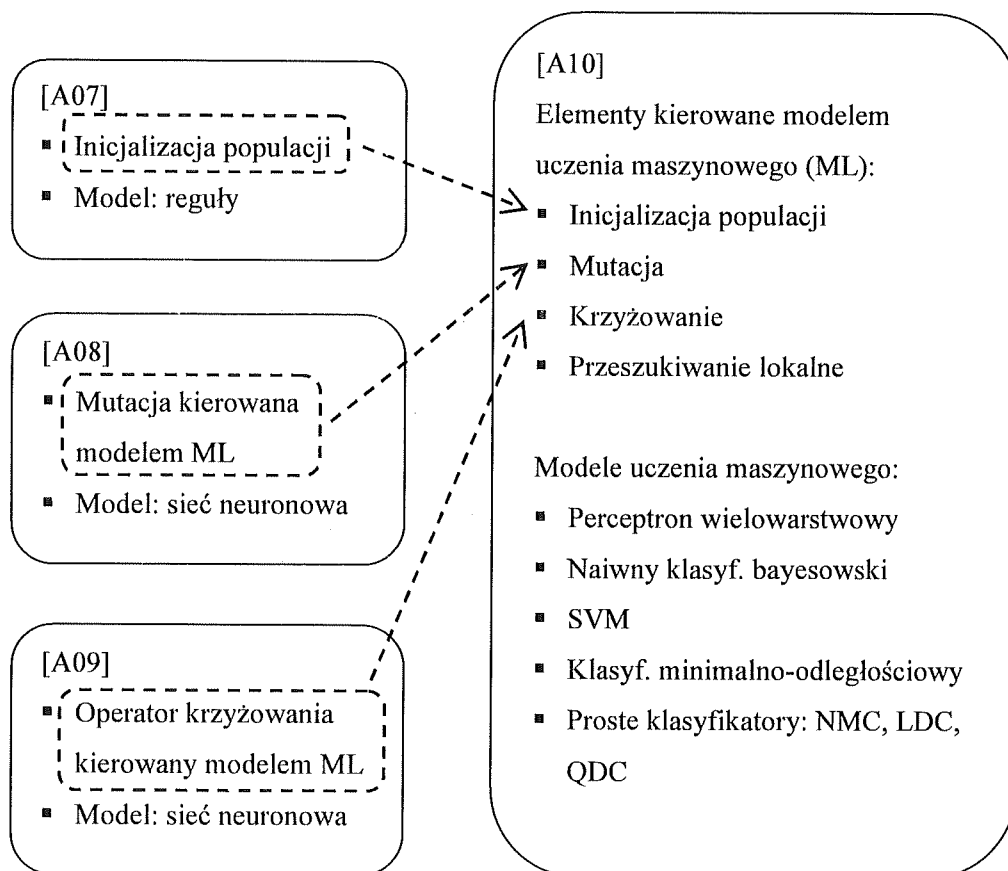
[A10] W artykule [A10], zaproponowane w artykułach [A07-A09] mechanizmy wspomagania optymalizacji przy pomocy modeli uczenia maszynowego zostały wykorzystane dla **problemu optymalizacji szczepień**, w którym rozwiązaniami są wektory binarne ze zbioru $\{0, 1\}^{|V|}$, reprezentujące decyzje *szczepić* lub *nie szczepić* dla poszczególnych wierzchołków grafu. Rys. 10 przedstawia zależności między artykułami dotyczącymi użycia modeli uczenia maszynowego. Problem optymalizacji rozważany w artykule [A10] jest problemem wielokryterialnym, w którym minimalizowane są dwie funkcje celu: liczba zaszczepionych wierzchołków $f_1(x) = \sum_{i=1}^{|V|} x_i$ oraz f_2 - liczba zainfekowanych wierzchołków podczas symulacji wykorzystujących rozwiązanie x do aplikowania szczepień. Zbieranie danych uczących wymaga określenia, czy nowe rozwiązanie znalezione przez algorytm ewolucyjny jest lepsze niż poprzednie, co w przypadku problemów wielokryterialnych nie zawsze jest możliwe. Z tego powodu, w artykule [A10] do generowania danych uczących został użyty algorytm MOEA/D [Li 2009; Zhang 2007], w którym przy pomocy wektorów wagowych wykonywana jest dekompozycja problemu wielokryterialnego na wiele problemów jednokryterialnych. Ponieważ w algorytmie MOEA/D każde rozwiązanie x w populacji ma przypisany pewien wektor wagowy λ , możliwe jest określenie, czy nowe rozwiązanie x' jest lepsze niż x poprzez zagregowanie wartości funkcji celu przy pomocy wektora wagowego λ . Aby model uczenia maszynowego mógł działać dla problemu wielokryterialnego, do wektora atrybutów dołączane są wartości współrzędnych wektora wagowego λ . W ten sposób, model uczenia maszynowego może generować inne odpowiedzi, jeśli celem jest optymalizacja tylko pierwszego kryterium (wektor wagowy $\lambda = [1, 0]$), inne jeśli celem jest optymalizacja tylko drugiego kryterium (wektor wagowy $\lambda = [0, 1]$), a jeszcze inne, jeśli celem jest optymalizacja pewnej kombinacji kryteriów (np. $\lambda = [0.5, 0.5]$).

W artykule [A10] model uczenia maszynowego został wykorzystany do kierowania kilkoma elementami algorytmu ewolucyjnego: inicjalizacją populacji, krzyżowaniem, mutacją oraz procedurą przeszukiwania lokalnego. Ponieważ dla omawianego problemu używana jest reprezentacja rozwiązań w postaci wektorów binarnych, jako modele uczenia maszynowego przetestowano następujące klasyfikatory:

- Perceptron wielowarstwowy [Vang-Mata 2020] z $N_{\text{hid}} = 5, 10, 15, 20$ neuronów w warstwie ukrytej.

- Naiwny klasyfikator bayesowski (ang. *Naïve Bayes classifier*) [Webb 2010] wykorzystujący modelowanie rozkładów prawdopodobieństwa metodą nieparametryczną oraz parametryczną dla rozkładu normalnego.
- Maszynę wektorów wspierających (ang. *Support Vector Machine, SVM*) [Steinwart 2008] z kilkoma różnymi funkcjami jądra.
- Klasyfikator minimalno-odległościowy [Mondal 2016] wykorzystujący odległość euklidesową, Manhattan oraz Czebyszewa.
- Trzy proste klasyfikatory [Tharwat 2016]: NMC, LDC i QDC.

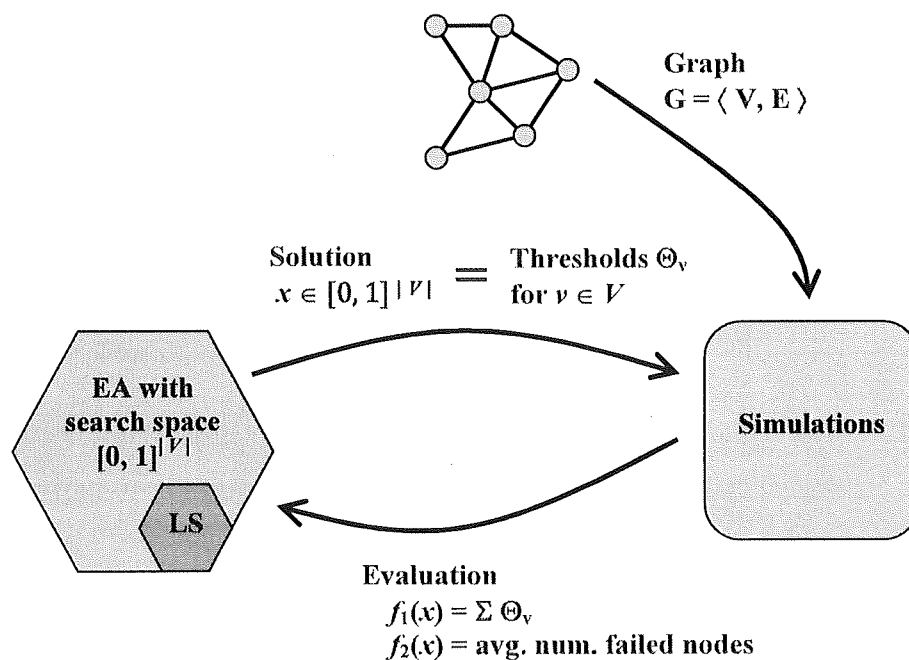
W przeprowadzonych badaniach, najlepszą dokładność klasyfikacji uzyskała sieć neuronowa (perceptron wielowarstwowy z $N_{hid} = 20$ neuronów w warstwie ukrytej). Użycie takiej sieci neuronowej wytrenowanej w oparciu o dane zebrane dla $|V| = 1000$ pozwoliło poprawić wyniki optymalizacji nawet dla $|V| = 20000$.



Rys. 10. Zależności między artykułami dotyczącymi użycia modeli uczenia maszynowego do wspomaganie algorytmów optymalizacji

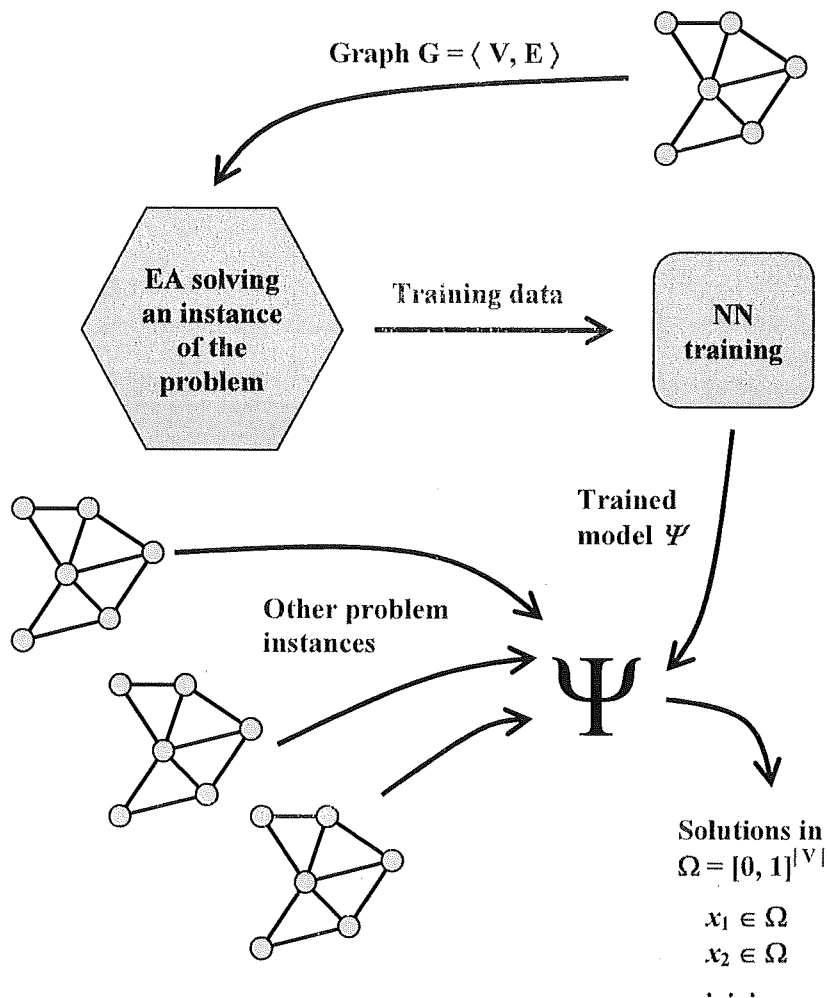
[A11] W artykule [A11] opisane zostały badania dotyczące wykorzystania modeli uczenia maszynowego dla **dwukryterialnej wersji problemu zapobiegania upadłościom firm**. W tym problemie optymalizacji, dla każdego wierzchołka $v \in V$ określony jest próg $\Theta_v \in [0, 1]$, który można zinterpretować jako poziom rezerw utworzonych przez firmę v pozwalających zachować płynność finansową, nawet w przypadku upadłości partnerów biznesowych tej firmy. Ponieważ próg Θ_v może przyjmować wartości będące liczbami rzeczywistymi, w artykule [A11] zostały wykorzystane modele regresji generujące sugerowane wartości Θ_v dla $v \in V$. Podobnie jak w przypadku klasyfikatorów zastosowanych w poprzednich artykułach, jako atrybuty wejściowe dla modeli regresji zostały użyte atrybuty wierzchołków grafu (stopień, bliskość, pośrednictwo, itd.). W artykule [A11] zostały porównane trzy podejścia do dwukryterialnej wersji problemu zapobiegania upadłościom:

1. **Optymalizacja progów Θ_v przy użyciu algorytmu ewolucyjnego**, w którym rozwiązaniem jest wektor $x \in [0, 1]^{|V|}$ zawierający wartości progów dla wszystkich wierzchołków grafu (Rys. 11). Ewaluacja rozwiązania polega na przeprowadzeniu symulacji rozprzestrzeniania się upadłości firm, w której progi (wartości rezerw) są przypisane do wierzchołków grafu (firm) zgodnie z wartościami w wektorze x .



Rys. 11. Optymalizacja progów Θ_v przy użyciu algorytmu ewolucyjnego. Każde rozwiązanie w populacji to wektor $x \in [0, 1]^{|V|}$ zawierający wartości progów dla wszystkich wierzchołków grafu [A11, Fig. 1].

2. **Generowanie rozwiązań za pomocą modelu uczenia maszynowego** trenowanego w oparciu o dane uczące zebrane podczas rozwiązywania wybranych instancji problemu optymalizacji (Rys. 12).



Rys. 12. Generowanie rozwiązań za pomocą modelu uczenia maszynowego trenowanego w oparciu o dane uczące wygenerowane przez algorytm ewolucyjny rozwiązujący wybrane instancje problemu optymalizacji. [A11, Fig. 2].

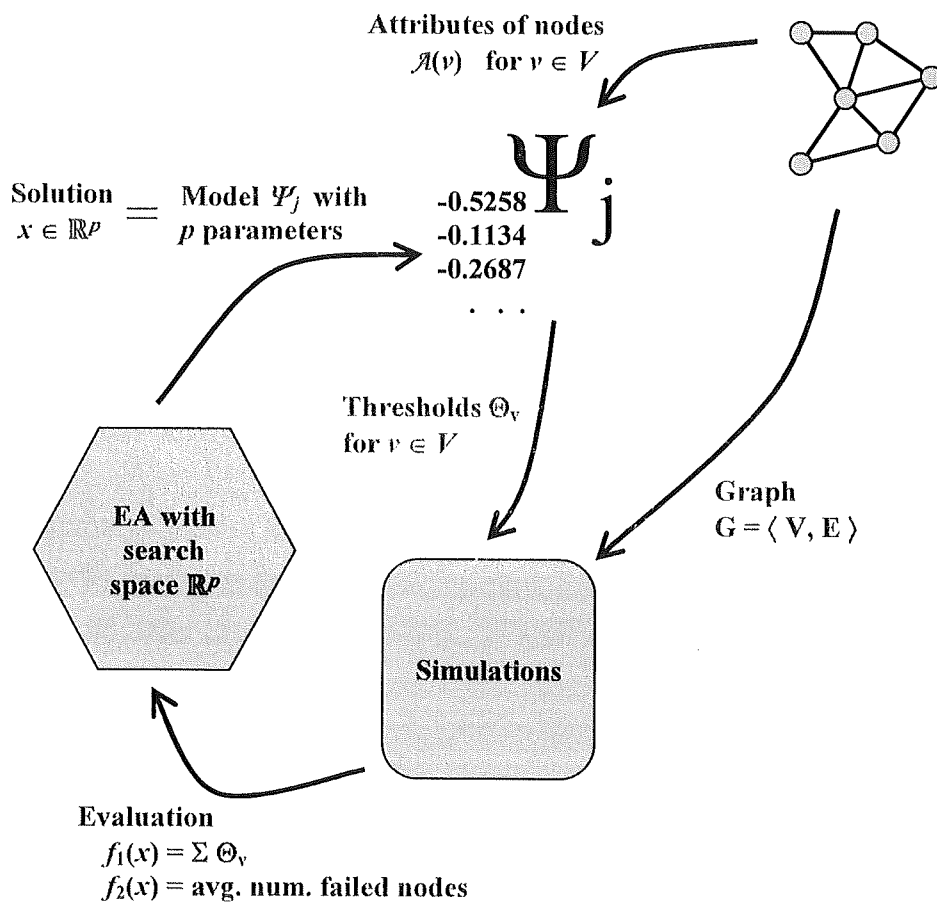
Dane uczące są generowane przez algorytm MOEA/D, wykorzystujący zbiór wektorów wagowych $\lambda^{(j)}$, $j = 1, \dots, N_{\text{pop}}$ (gdzie N_{pop} jest rozmiarem populacji) do dekompozycji wielokryterialnego problemu optymalizacji na N_{pop} problemów jednokryterialnych. Model uczenia maszynowego składa się z N_{pop} sieci neuronowych: $\Psi = \{ \Psi_j : j = 1, \dots, N_{\text{pop}} \}$. Dla każdej sieci Ψ_j zbierana jest osobna próbka ucząca S_j . Jeśli, podczas działania algorytmu MOEA/D, istniejące rozwiązanie x przypisane do pewnego wektora wagowego $\lambda^{(j)}$ jest zastępowane przez poprawione rozwiązanie x' ,

to do próbki uczącej S_j , dla każdego wierzchołka v dla którego $x[v] \neq x'[v]$, dodawana jest para $\langle \mathcal{A}[v], x'[v] \rangle$. Pary $\langle \mathcal{A}[v], x'[v] \rangle$ reprezentują sytuacje, gdy zmiana progu Θ_v przypisanego do wierzchołka v opisanego wektorem atrybutów $\mathcal{A}[v]$ z wartości $x[v]$ na wartość $x'[v]$ pozwoliła poprawić rozwiązanie względem funkcji celu zagregowanych przy pomocy wektora wagowego $\lambda^{(i)}$. Jest to informacja dla modelu uczenia maszynowego Ψ_j , pokazująca, że dla atrybutów $\mathcal{A}[v]$ odpowiednią wartością wyjściową jest $x'[v]$. Sieć neuronowa Ψ_j jest trenowana w poparciu o próbkę uczącą S_j metodą skalowanych gradientów sprzężonych (ang. *Scaled Conjugate Gradient*, SCG) [Ariana 2023]. Wytrenowany model $\Psi = \{ \Psi_j : j = 1, \dots, N_{\text{pop}} \}$ pozwala wygenerować N_{pop} rozwiązań dla nowej instancji problemu optymalizacji. W celu wygenerowania rozwiązania x_j , dla każdego wierzchołka grafu $v \in V$ wektor atrybutów $\mathcal{A}[v]$ jest podawany na wejście sieci neuronowej Ψ_j . Otrzymane wyjście jest przyjmowane jako wartość elementu rozwiązania $x_j[v] = \Psi_j(\mathcal{A}[v])$. W ten sposób, jedna sieć neuronowa Ψ_j generuje jedno rozwiązanie $x_j \in [0, 1]^{|V|}$ zaś cały model $\Psi = \{ \Psi_j : j = 1, \dots, N_{\text{pop}} \}$ generuje populację składającą się z N_{pop} rozwiązań. Ponieważ każda sieć neuronowa Ψ_j została wytrenowana w oparciu o dane uczące reprezentujące zmiany poprawiające rozwiązania dla wektora wagowego $\lambda^{(i)}$, można oczekiwać, że rozwiązanie x_j także będzie dobrym rozwiązaniem dla tego samego wektora wagowego $\lambda^{(i)}$.

3. **Ewolucyjna optymalizacja wag sieci neuronowych.** W tym podejściu algorytm ewolucyjny optymalizuje populację N_{pop} wektorów liczb rzeczywistych ze zbioru \mathbb{R}^p , gdzie p jest liczbą parametrów modelu uczenia maszynowego (wag sieci neuronowej). Każde rozwiązanie w populacji reprezentuje wagi dla jednej sieci neuronowej $\Psi_j, j = 1, \dots, N_{\text{pop}}$. Sieć neuronowa Ψ_j jest używana do wygenerowania rozwiązania $x_j \in [0, 1]^{|V|}$, tak jak to zostało opisane w poprzednim punkcie, tzn. poprzez podanie na wejściu wektorów atrybutów dla poszczególnych wierzchołków grafu:

$$\forall v \in V : x_j[v] = \Psi_j(\mathcal{A}[v]). \quad (14)$$

W ten sposób populacja N_{pop} wektorów liczb rzeczywistych przetwarzanych przez algorytm ewolucyjny (traktowanych jako wagi sieci neuronowych) jest używana do otrzymania N_{pop} rozwiązań dla problemu optymalizacji (Rys. 13).




Rys. 13. Ewolucyjna optymalizacja wag sieci neuronowych. Rozwiązanie $x_j \in \mathbb{R}^p$ zawiera p wag dla sieci neuronowej Ψ_j [A11, Fig. 3].

W artykule [A11] wymienione powyżej trzy podejścia zostały porównane w zastosowaniu do rozwiązywania dwukryterialnej wersji problemu zapobiegania upadłościom firm. Najlepsze wyniki zostały uzyskane metodą ewolucyjnej optymalizacji wag sieci neuronowych opisaną w punkcie 3. powyżej. Zaletą tej metody jest nie tylko możliwość uzyskania dobrych wyników optymalizacji, ale także to, że sieci neuronowe mogą być użyte dla innych instancji problemu niż te, dla których zostały zoptymalizowane. Ponieważ eksperymenty opisane w artykule [A11] zostały przeprowadzone dla instancji problemu zdefiniowanych w oparciu o grafy REDS [Antonioni 2014], których struktura zależy od trzech parametrów (R , E oraz S), możliwe było zbadanie skuteczności działania sieci zoptymalizowanych dla pewnych wartości parametrów R , E oraz S dla grafów o innych wartościach tych parametrów. Wpływ parametru R (określającego maksymalną długość

krawędzi grafu) na skuteczność działania zoptymalizowanych sieci okazał się większy niż wpływ parametrów E oraz S.

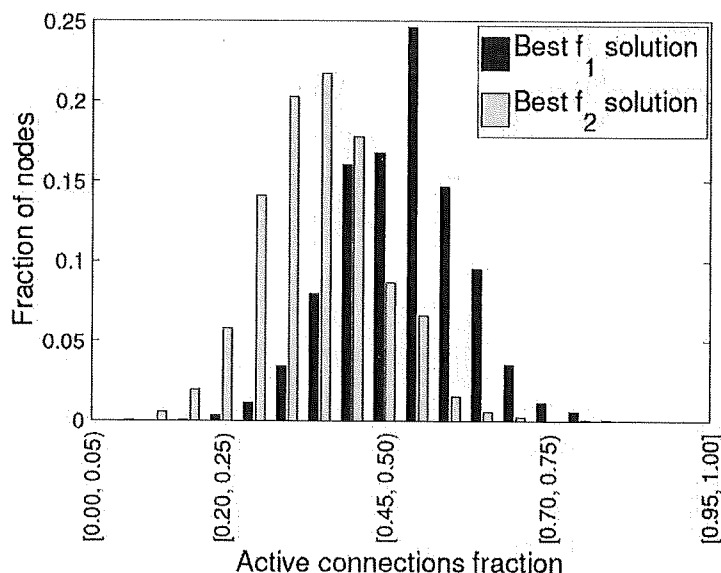
[A12] W artykule [A12] zbadane zostało **użycie modelu uczenia maszynowego jako modelu zastępczego** (ang. *surrogate model*) zamiast symulacji do ewaluacji rozwiązań na podstawie informacji o gęstości połączeń w grafie. Inspiracją dla takiego zastosowania modelu uczenia maszynowego były zarówno prezentowane w literaturze badania dotyczące wpływu gęstości połączeń grafu na rozprzestrzenianie się zagrożeń (m.in. [Ladley 2013]), jak i zrealizowane eksperymenty, prowadzące do podobnych wniosków. Przykładowo, w przypadku rozprzestrzeniania się upadłości firm, można zaobserwować, że zmiana gęstości połączeń w grafie wpływa na liczbę upadłości firm, przy czym najkorzystniejsza gęstość połączeń w grafie jest różna, w zależności od wielkości początkowego wstrząsu (liczby upadłości na początku symulacji). W modelu, w którym krawędzie grafu (relacje biznesowe) mogą być „aktywne” lub „nieaktywne”, optymalny odsetek „aktywnych” krawędzi zależy od wielkości początkowego wstrząsu w sposób przedstawiony na Rys. 14.



Rys. 14. Optymalny odsetek „aktywnych” krawędzi, dla którego uzyskiwana jest najmniejsza liczba upadłości dla danej wielkości początkowego wstrząsu [A12, Fig. 2].

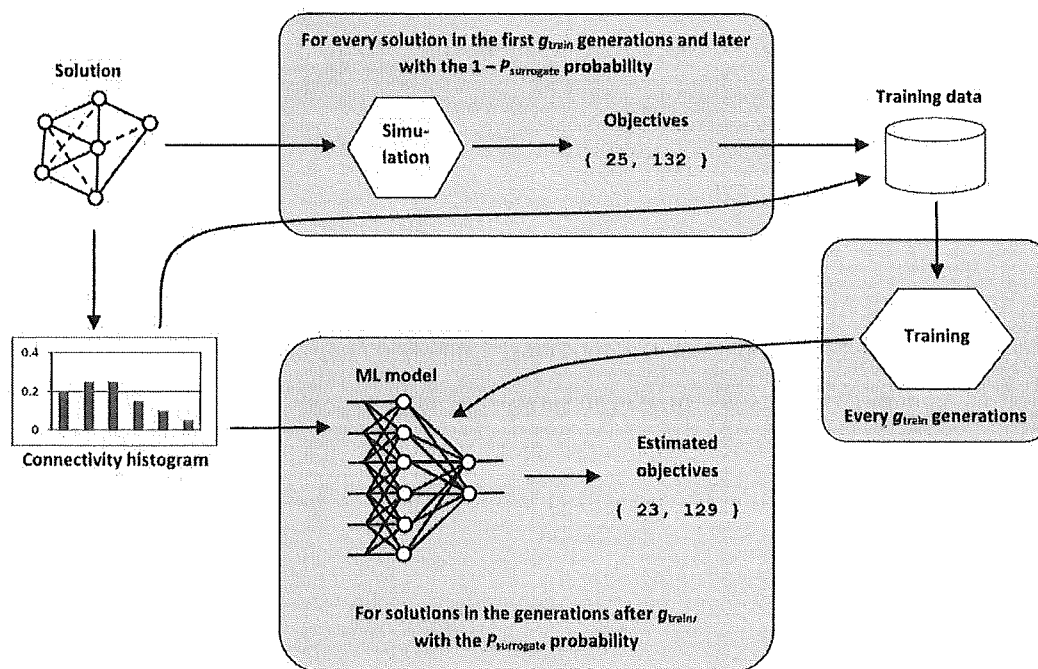
Jak widać, dla małych początkowych wstrząsów (niewielu firm w stanie upadłości na początku symulacji), duża liczba połączeń w grafie ogranicza rozmiar kryzysu, co tłumaczone jest efektem współdzielenia ryzyka (ang. *risk sharing*) [Ladley 2013]. W przypadku dużych

wstrząsów początkowych, duża liczba „aktywnych” połączeń w grafie zwiększa rozmiar kryzysu, co wynika z wpływu upadających firm na znaczną część rynku. Przy dużym początkowym wstrząsie, utrzymywanie relacji z wieloma firmami nie zapobiega utracie płynności finansowej, ponieważ wielu kontrahentów jednocześnie ma problemy finansowe. W artykule [A12] rozważany jest dwukryterialny problem zapobiegania upadłościom firm, w którym przestrzenią rozwiązań jest $\{0, 1\}^{2|E|}$, a rozwiązania (wektory binarne) określają, które (skierowane) krawędzie grafu są „aktywne”, co odpowiada utrzymywaniu relacji biznesowych między firmami. Funkcje celu f_1 i f_2 są wyliczane poprzez przeprowadzenie symulacji kryzysu finansowego dla dwóch różnych wielkości początkowego wstrząsu (liczby firm w stanie upadłości na początku symulacji): S_{small} i S_{large} . Ponieważ ewaluacja rozwiązań przy pomocy symulacji jest kosztowna, został wykorzystany **model zastępczy** (perceptron wielowarstwowy [Vang-Mata 2020]), który jako dane wejściowe wykorzystuje histogram H , określający, jaki odsetek wierzchołków grafu ma „aktywny” dany procent incydenentnych z nim krawędzi (Rys. 15). Przykładowo, jeśli węzeł ma „aktywne” dwie krawędzie z dziesięciu, to jest przypisany do przedziału $[0.20, 0.25)$. Ponieważ na Rys. 15 widoczna jest różnica w gęstości połączeń w grafach, dla których uzyskano najlepsze wartości kryteriów f_1 (fioletowy) i f_2 (żółty), można przypuszczać, że znajomość histogramu H może służyć do przewidzenia, jakie wartości funkcji celu zostaną uzyskane.



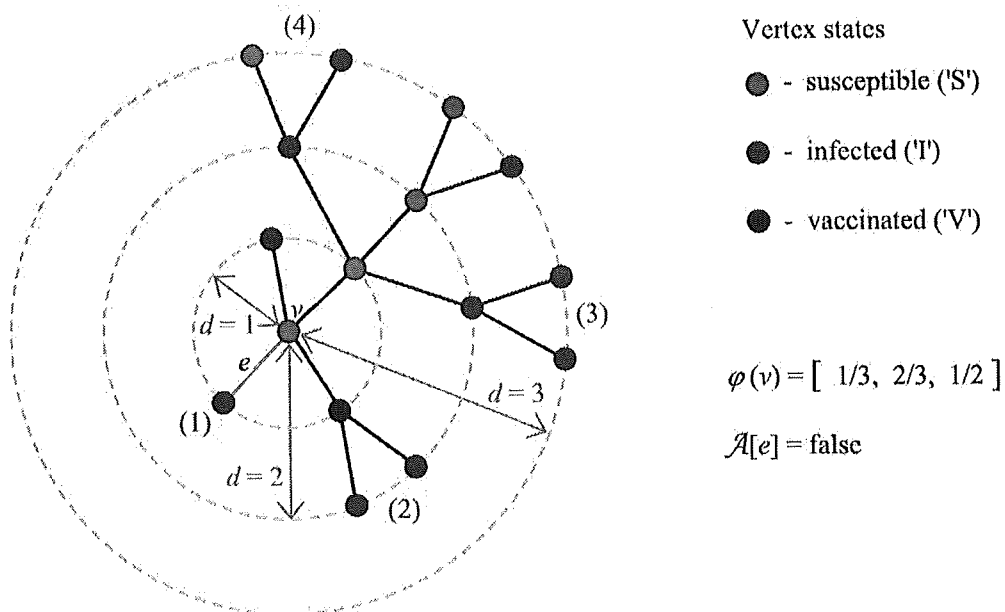
Rys. 15. Przykładowe histogramy H dla dwóch rozwiązań, które uzyskały najlepsze wartości kryteriów f_1 (fioletowy) i f_2 (żółty) dla grafów z $|V| = 5000$ wierzchołkami [A12, Fig. 3].

Metoda zaproponowana w artykule [A12] wykonuje ewaluację rozwiązań przy pomocy symulacji w czasie pierwszych g_{train} generacji algorytmu ewolucyjnego (Rys. 16). Uzyskane rozwiązania i ich ewaluacje służą do zbudowania próbki uczącej zawierającej, dla każdego rozwiązania $x \in \{0, 1\}^{2|E|}$, histogram $H(x)$ i uzyskane wartości funkcji celu $f_1(x)$ i $f_2(x)$. Zgromadzone dane uczące są używane do aktualizacji modelu uczenia maszynowego co g_{train} generacji algorytmu ewolucyjnego. W czasie pracy algorytmu (oprócz pierwszych g_{train} generacji, kiedy model uczenia maszynowego jeszcze nie jest wytrenowany), ewaluacja jest wykonywana z prawdopodobieństwem $P_{\text{surrogate}}$ za pomocą modelu, który po podaniu na wejściu histogramu $H(x)$ dla danego rozwiązania $x \in \{0, 1\}^{2|E|}$ zwraca przewidywane wartości funkcji celu $f_1(x)$ i $f_2(x)$. W eksperymentach przeprowadzonych dla grafów z $|V| = 200, \dots, 5000$ wierzchołkami, zaproponowana metoda została porównana z algorytmem, który wszystkie ewaluacje rozwiązań przeprowadzał przy pomocy symulacji. W przeprowadzonych testach, kryterium stopu stanowił czas uruchomienia programu, co miało na celu uwzględnienie w analizie porównawczej czasu potrzebnego na wytrenowanie i użycie modelu uczenia maszynowego. Zaproponowana metoda wykorzystująca model zastępczy osiągnęła lepsze wyniki optymalizacji niż metoda porównawcza dla wszystkich wielkości grafu.



Rys. 16. Działanie metody optymalizacji wykorzystującej model uczenia maszynowego jako model zastępczy do ewaluacji rozwiązań [A12, Fig. 4].

[A13] W artykule [A13] opisane zostały badania nad wykorzystaniem modeli uczenia maszynowego do generowania **decyzi pozwalających ograniczyć rozprzestrzenianie się epidemii**. Zastosowane podejście zawiera pewne elementy podobne do wykorzystanych w artykułach [A11] i [A12] dla problemu rozprzestrzeniania się upadłości. Algorytm ewolucyjny optymalizuje model uczenia maszynowego (podobnie jak w artykule [A11]), który dla każdego wierzchołka grafu może podjąć jedną z decyzji: *nie chronić*, *szczepić*, *izolować (25%)*, *izolować (50%)*, *izolować (75%)*, *izolować (100%)*. Podane wartości procentowe określają, jaką część kontaktów (krawędzi incydentnych z danym wierzchołkiem) należy usunąć w ramach izolacji wierzchołka. W przypadku izolacji, rozprzestrzenianie się zagrożenia jest ograniczane przez „dezaktywację” krawędzi grafu, podobnie jak w modelu rozważanym w artykule [A12]. W eksperymentach zostały użyte dwa modele uczenia maszynowego: oparty na regułach oraz sieć neuronowa. Wektor atrybutów $\varphi(v)$ podawany na wejście modelu zawiera wartości określające, jaka część wierzchołków znajdujących się w odległości 1, ..., h krawędzi od wierzchołka v jest zainfekowanych. Przykładowo, w sytuacji pokazanej na Rys. 17, aktywne krawędzie grafu łączą wierzchołek v z trzema innymi, które są w stanach ‘S’, ‘I’ oraz ‘R’, w związku z czym $\varphi(v)[1] = 1/3$. Czwarty wierzchołek, oznaczony na rysunku przez (1), jest połączony z v nieaktywną krawędzią e i dlatego nie jest liczony. W odległości $d = 2$ od wierzchołka v znajduje się jeden wierzchołek w stanie ‘S’ i dwa wierzchołki w stanie ‘I’, więc $\varphi(v)[2] = 2/3$. Dwa wierzchołki oznaczone na rysunku przez (2) są oddzielone od v zaszczepionym wierzchołkiem, więc nie są liczone. W odległości $d = 3$ od wierzchołka v znajdują się dwie pary wierzchołków oznaczone (3) i (4), które nie są liczone, ponieważ są odseparowane od v przez zainfekowane wierzchołki. W związku z tym, uwzględniane są jedynie dwa wierzchołki: jeden w stanie ‘S’ a drugi ‘I’, więc $\varphi(v)[3] = 1/2$.



Rys. 17. Przykład wyznaczenia wektora atrybutów $\varphi(v)$ dla $h = 3$ [A13, Fig. 1].

Eksperymenty opisane w artykule [A13] pokazały, że model oparty na regułach pozwala lepiej niż sieć neuronowa chronić graf poprzez decyzje o szczepieniu lub izolacji.

Podsumowując, przeprowadzenie opisanych w tym punkcie prac badawczych pozwoliło na **zrealizowanie celu szczegółowego C02**, czyli opracowanie metod optymalizacji wykorzystujących modele uczenia maszynowego do ukierunkowania przeszukiwania w algorytmach metaheurystycznych oraz jako modeli zastępczych dla problemów z kosztowną ewaluacją rozwiązań. Uzyskane wyniki pokazują, że, zgodnie z hipotezą badawczą H02, wykorzystanie modeli uczenia maszynowego do ukierunkowania przeszukiwania w algorytmach metaheurystycznych umożliwia uzyskiwanie lepszych rozwiązań dla problemów ochrony grafów przed zagrożeniami. Ponadto, opisana w artykułach [A07-A10], analiza działania elementów algorytmów ewolucyjnych, takich jak operatory krzyżowania i mutacji wykorzystujące modele uczenia maszynowego, potwierdza hipotezę H03.

3.1.6. Zastosowanie algorytmów metaheurystycznych do problemów rzeczywistych

Oprócz prac badawczych w zakresie opracowania algorytmów optymalizacji dla problemów ochrony grafów przed zagrożeniami, zostały zrealizowane badania w zakresie zastosowania metaheurystycznych metod optymalizacji w dwóch obszarach tematycznych: zapobiegania epidemiom oraz minimalizacji ryzyka systemowego w odniesieniu do upadłości instytucji finansowych. Prace opisane w artykułach [A14]-[A16] zostały przeprowadzone we współpracy z zespołami badawczymi Uniwersytetu Turyńskiego oraz Banku Centralnego Brazylii, przy wykorzystaniu danych rzeczywistych zebranych przez te zespoły.

[A14] Gdy podmiot gospodarczy ma problemy z płynnością finansową, nie jest w stanie uregulować należności wobec wierzycieli, którzy z tego powodu mogą nie być w stanie uregulować należności wobec swoich wierzycieli. Rozprzestrzenianie się problemów finansowych (a w konsekwencji upadłości firm) może być opisane przy pomocy modelu progowego, który został wykorzystany m.in. w artykułach [A11] i [A12]. W artykule [A12] pokazana została zależność między wielkością początkowego kryzysu (liczbą firm w stanie upadłości na początku symulacji), gęstością grafu (odsetkiem „aktywnych” krawędzi reprezentujących relacje biznesowe) oraz liczbą upadłości firm w trakcie symulacji (Rys. 14). W modelu progowym, dany węzeł grafu v (reprezentujący firmę) przechodzi ze stanu płynności finansowej od razu w stan upadłości, co jest rozumiane jako całkowite zaprzestanie spłacania wierzytelności. W bardziej realistycznym scenariuszu, w razie wystąpienia problemów finansowych, firma może spłacać część zobowiązań. Regulacje prawne mogą wymagać określonego sposobu postępowania w przypadku zaspokajania wierzycieli, na przykład określać kategorie należności i kolejność ich zaspokajania lub wymagać proporcjonalnego (pro-rata) zaspokajania wierzycieli. Tym niemniej, zjawisko selektywnej spłaty zobowiązań występuje w świecie rzeczywistym i jest szeroko opisywane w literaturze. Przykładowo, włoskie firmy opóźniają spłacanie kredytów w przypadku banków znajdujących się w gorszej kondycji finansowej [Schiantarelli 2020], przy czym opóźnienia mogą występować, nawet jeśli kredytobiorca jest w stanie na bieżąco spłacać swoje zobowiązania. Osoby fizyczne mogą zwlekać ze spłatą kredytu hipotecznego, a spłacać inne kredyty lub na odwrót [Saengchote 2022]. **W artykule [A14] został zbadany wpływ preferencji dotyczących kolejności spłacania zobowiązań wobec wierzycieli (ang. *default pecking order*, DPO) na ryzyko systemowe.** Generalnie, dłużnicy są mniej skłonni spłacać

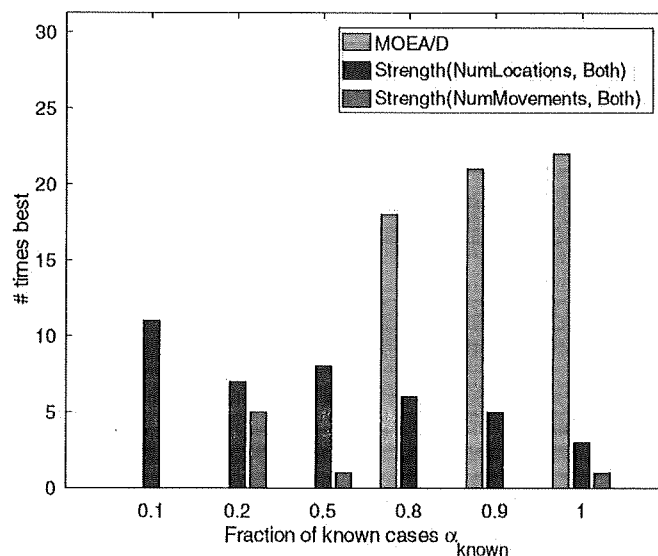
swoje należności wobec wierzycieli, których oceniają jako „słabszych”. W omawianym artykule zasymulowane zostało spłacanie należności przez kredytobiorcę v wobec wierzycieli uporządkowanych według kilku kryteriów: kapitału, proporcji kapitału własnego do aktywów (ang. *equity-to-asset ratio*), liczby kredytobiorców (reprezentowanej jako liczba krawędzi wychodzących z wierzchołka grafu reprezentującego wierzyciela) oraz wartości kredytu udzielonego kredytobiorcy v przez danego wierzyciela. Jako scenariusze porównawcze przyjęto losowe uporządkowanie wierzycieli oraz spłaty proporcjonalne. Do wykonania eksperymentów wykorzystano dane opisujące sieć powiązań międzybankowych (kredytów, udziałów, operacji walutowych, itp.) oraz kredytów udzielanych firmom z innych sektorów gospodarki przez banki. Z przeprowadzonych badań wynika, że zaspokajanie wierzycieli w kolejności (nawet losowej) zwiększa ryzyko systemowe w porównaniu ze spłacaniem proporcjonalnym. **Preferencyjne zaspokajanie silniejszych wierzycieli zwiększa ryzyko systemowe jeszcze bardziej.** W takim przypadku, większa gęstość grafu jest niekorzystna – więcej połączeń sprzyja propagacji upadłości zamiast umożliwiać współdzielenie ryzyka. Ponadto, względne zwiększenie ryzyka systemowego jest bardziej widoczne, jeśli początkowy wstrząs jest mniejszy. Ważnym wnioskiem z przeprowadzonych badań jest **konieczność uwzględniania strategii zaspokajania wierzycieli przez podmioty działające na rynku przy ocenie ryzyka systemowego.** Nieuwzględnienie wpływu takich strategii może prowadzić do znacznego zaniżenia prognozowanego poziomu ryzyka. Podobnie jak wcześniejsze publikacje, takie jak [Ladley 2013] i [A12], artykuł [A14] pokazuje zależność między gęstością grafu oraz wielkością początkowego kryzysu a propagowaniem się zagrożeń. Wyniki badań przedstawione w artykule [A14] pokazują dodatkowo istotny wpływ strategii zaspokajania wierzycieli na zależność między gęstością grafu a ryzykiem systemowym.

[A15] W artykule [A15] opisane zostały badania dotyczące **optymalizacji ewolucyjnej w zastosowaniu do zapobiegania epidemiom chorób zwierząt hodowlanych.** W badaniach zostały uwzględnione następujące aspekty występujące w rzeczywistych zagadnieniach związanych z zapobieganiem epidemiom:

- Symulacje rozprzestrzeniania się choroby były przeprowadzane przy wykorzystaniu **zbioru danych opisujących faktyczne transporty zwierząt w Piemontcie w roku 2017.**

- Zbadany został **wpływ nieprecyzyjnej wiedzy na wyniki optymalizacji**. Przyjęto, że nie wszystkie przypadki choroby zostały zdiagnozowane na początku symulowanej epidemii, a jedynie pewna część α_{known} , oraz, że faktyczny graf reprezentujący transporty zwierząt różni się od tego, dla którego przeprowadzana jest optymalizacja, ponieważ pewna liczba par krawędzi α_{rewire} została zmodyfikowana poprzez zastąpienie krawędzi $\langle v_1, v_2 \rangle$ i $\langle v_3, v_4 \rangle$ krawędziami $\langle v_1, v_4 \rangle$ i $\langle v_3, v_2 \rangle$. Opisane powyżej dwie modyfikacje pozwalają zasymulować niepewność w ocenie sytuacji epidemiologicznej występującą w zastosowaniach do problemów rzeczywistych.
- **Optymalizacja ewolucyjna została porównana ze znanymi z epidemiologii strategiami planowania szczepień**. W omawianym artykule użyte zostały strategie oparte na liczbie krawędzi grafu (wchodzących, wychodzących oraz ogółem), co w omawianym problemie przekłada się na liczbę transportów mogących być przyczyną przenoszenia choroby, a także strategię opartą na wielkości gospodarstwa.

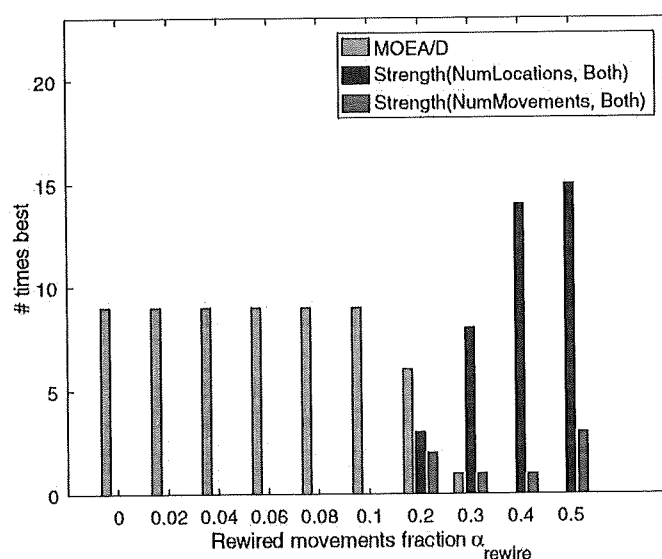
Wpływ znajomości przypadków choroby na skuteczność porównywanych metod (optymalizacji oraz znanych z epidemiologii strategii planowania szczepień) jest widoczny dzięki porównaniu liczby testów, w których każda z metod dała lepsze wyniki w zależności od parametru α_{known} (Rys. 18). Jeśli większość przypadków choroby jest znana ($\alpha_{\text{known}} \geq 0.8$), optymalizacja ewolucyjna daje lepsze wyniki. W przeciwnym razie, skuteczniejsze są strategie planowania szczepień.



Rys. 18. Liczba testów, w których porównywane metody dały lepsze wyniki, w zależności od wartości parametru α_{known} [A15, Fig. 3].

Wpływ ograniczonej wiedzy na temat sieci transportów na skuteczność porównywanych metod jest widoczny dzięki porównaniu liczby testów, w których każda z metod dała lepsze wyniki w zależności od parametru α_{rewire} (Rys. 19). W przypadku niewielkich modyfikacji grafu ($\alpha_{\text{rewire}} < 0.3$), optymalizacja ewolucyjna daje lepsze wyniki. W przeciwnym razie, skuteczniejsze są strategie planowania szczepień, choć należy wziąć pod uwagę, że sposób modyfikacji grafu użyty w badaniach (modyfikacja par krawędzi łączących cztery wierzchołki grafu) faworyzuje przyjęte strategie, które są oparte na parametrach transportów wchodzących i wychodzących z danego wierzchołka, które nie ulegają zmianie przy użytych modyfikacjach grafu. W przypadku innego rodzaju modyfikacji sieci transportów, efekty mogłyby być mniej korzystne dla przyjętych strategii planowania szczepień.

W opisywanym artykule zaproponowany został także mechanizm uzupełniania brakującej wiedzy dotyczącej przypadków choroby, poprzez wygenerowanie dodatkowych, losowych przypadków choroby na początku symulowanej epidemii. Zaproponowany mechanizm pozwala poprawić skuteczność optymalizacji ewolucyjnej, jednak powinien być stosowany ostrożnie, gdyż wygenerowanie nadmiernej liczby sztucznych przypadków choroby pogarsza wyniki optymalizacji.



Rys. 19. Liczba testów, w których porównywane metody dały lepsze wyniki, w zależności od wartości parametru α_{rewire} [A15, Fig. 4].

Podsumowując, przeprowadzone badania pokazały, że zarówno optymalizacja ewolucyjna, jak i zastosowanie znanych z epidemiologii strategii planowania szczepień może przynosić korzyści, w zależności od tego, jak bardzo precyzyjna wiedza dotycząca

przypadków choroby oraz transportów zwierząt jest dostępna. Jeśli większość przypadków choroby jest wykrywana oraz wiedza dotycząca transportów zwierząt nie jest obciążona znaczną niepewnością, to optymalizacja ewolucyjna daje dobre wyniki. Jeśli jednak znaczna liczba przypadków choroby nie jest znana ($\alpha_{\text{known}} < 0.8$) lub występują duże różnice między faktyczną a symulowaną siecią transportów ($\alpha_{\text{rewire}} \geq 0.3$), zastosowanie strategii planowania szczepień może dać lepsze wyniki niż optymalizacja ewolucyjna. Warto jednak podkreślić, że w przypadku zwierząt hodowlanych dokładność gromadzonych danych jest znacznie większa niż w przypadku ludzi. W szczególności, w Unii Europejskiej istnieje obowiązek rejestracji transportów zwierząt hodowlanych, co pozwala z dużą dokładnością odtworzyć sieć kontaktów mogących być przyczyną przenoszenia się chorób.

[A16] W artykule [A16] przedstawione zostały wyniki badań nad **wykorzystaniem optymalizacji wielokryterialnej do poprawy efektywności i stabilności systemu finansowego**. Zmienną decyzyjną w rozważanym problemie jest jeden z wymogów kapitałowych: współczynnik wartości netto do wartości aktywów międzybankowych. Rozważane są dwa scenariusze: heterogeniczny, w którym wartość x_i wymienionego powyżej współczynnika może być różna dla poszczególnych banków, oraz homogeniczny, w którym wszystkie wartości x_i są równe. Scenariusz homogeniczny odpowiada sytuacji, w której regulacje prawne określają jedną wartość współczynnika dla całego rynku międzybankowego. Relacje między bankami są modelowane w postaci grafu $G = \langle V, E \rangle$, w którym wierzchołkami są banki, zaś krawędź łącząca wierzchołki v_i oraz v_j o wadze L_{ij} oznacza, że i -ty bank udzielił j -temu bankowi pożyczki o wartości L_{ij} . Dla i -tego banku wartość jego aktywów na rynku międzybankowym L_i jest równa sumie wartości udzielonych przez niego pożyczek: $L_i = \sum_{j=1, \dots, |V|} L_{ij}$. Minimalna wartość netto i -tego banku, którą powinien on mieć, żeby spełnić wymogi kapitałowe jest wyliczana jako $NW_i = x_i L_i$. Wartość $x_i = NW_i / L_i$ reprezentuje poziom rezerw dla i -tego banku. W związku z tym, mniejsze wartości x_i przekładają się na większą efektywność (mniejsza część kapitału stanowi rezerwę), zaś większe wartości x_i przekładają się na większą stabilność (mniejsze ryzyko utraty płynności finansowej). Dla rozwiązania $x \in [0, 1]^{|V|}$ wartość funkcji celu f_1 jest wyliczana jako:

$$f_1(x) = \frac{\sum_{i=1}^{|V|} NW_i}{\sum_{i=1}^{|V|} L_i}. \quad (15)$$

Wartość funkcji celu f_2 jest uzyskiwana poprzez wykonanie symulacji rozprzestrzeniania się upadłości z progowym mechanizmem propagacji. Dla $t = 1$, pewna

część ζ banków znajduje się w stanie upadłości. Zbiór tych banków oznaczamy przez $\beta(1)$. Dla każdego banku v_i nie będącego w stanie upadłości sprawdzany jest warunek:

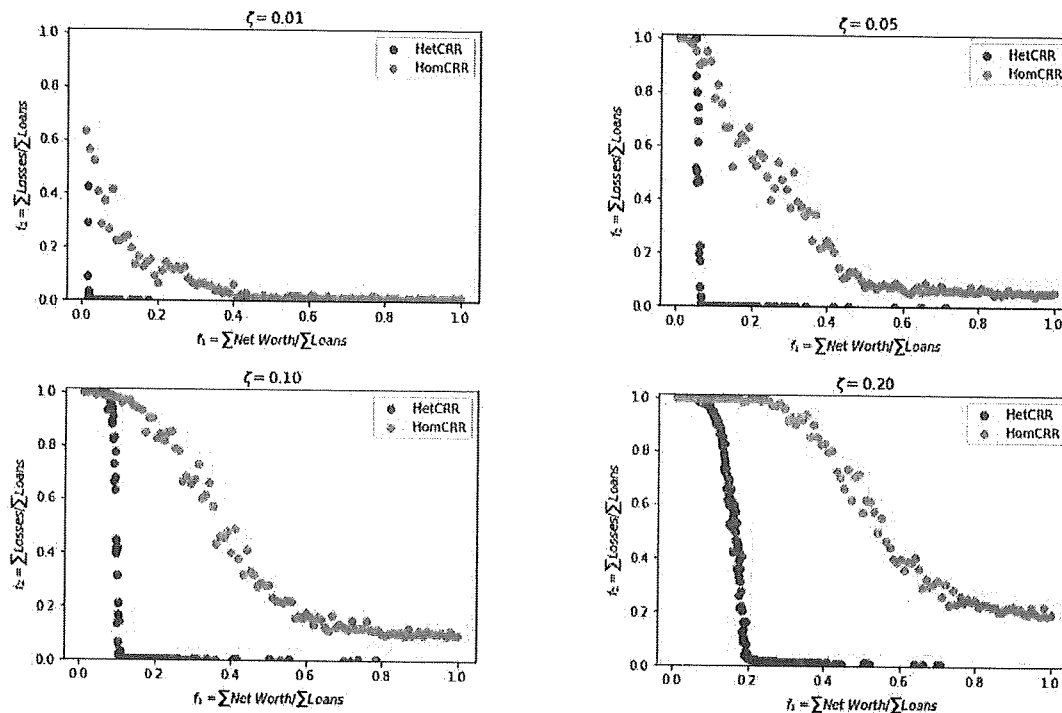
$$\sum_{j \in \beta(t)} L_{ij} \geq NW_i, \quad (16)$$

gdzie $t = 1$. Jeśli warunek (16) jest spełniony, bank v_i przechodzi w stan upadłości, tzn. jest dodawany do zbioru $\beta(2)$. W kolejnych krokach symulacji $t = 2, 3, \dots$ warunek (16) jest sprawdzany dla odpowiedniego $\beta(t)$, co może prowadzić do upadłości kolejnych banków. Po skończonej liczbie T kroków symulacji, fala upadłości zatrzymuje się w momencie, gdy dla żadnego banku warunek (16) nie jest spełniony lub wszystkie banki znajdują się w stanie upadłości. Wartość funkcji celu f_2 jest wówczas wyliczana jako:

$$f_2(x) = \frac{\sum_{i=1}^{|\mathcal{V}|} \sum_{t=1}^T \sum_{j \in \beta(t)} L_{ij}}{\sum_{i=1}^{|\mathcal{V}|} L_i}, \quad (17)$$

czyli jako straty skumulowane w czasie całej symulacji w proporcji do wartości całego rynku (wszystkich pożyczek udzielonych przez banki).

W eksperymentach opisanych w artykule [A16], porównana została skuteczność wprowadzenia regulacji dla całego rynku (scenariusz homogeniczny, w którym wszystkie wartości x_i są takie same) oraz skuteczność regulacji na poziomie każdego banku (scenariusz heterogeniczny, w którym wartości x_i mogą być różne i są one dobierane przez algorytm optymalizacji). Ponieważ omawiany problem jest problemem optymalizacji dwukryterialnej, rozwiązania osiągające różne wartości funkcji celu f_1 i f_2 formują front Pareto. W przypadku scenariusza homogenicznego, front Pareto jest generowany poprzez ustalenie wartości $f_1 = 0.01, \dots, 1$ z przyrostem 0.01. Dla ustalonej wartości f_1 wykonywana jest symulacja fali upadłości rozpoczynającej się od upadłości ζ banków. W tym scenariuszu przyjmowane jest $\forall i = 1, \dots, |\mathcal{V}| x_i = f_1$. Po zakończeniu symulacji, wartość kryterium f_2 jest wyliczana zgodnie ze wzorem (17). W przypadku scenariusza heterogenicznego, wykonywana jest optymalizacja wielokryterialna w przestrzeni poszukiwań $\Omega = [0, 1]^{|\mathcal{V}|}$. Ewaluacja każdego rozwiązania $x \in [0, 1]^{|\mathcal{V}|}$ jest wykonywana przy pomocy symulacji, zgodnie z opisem powyżej, a funkcje celu f_1 i f_2 są wyliczane odpowiednio ze wzorów (15) i (17). W artykule [A16] zostały omówione eksperymenty przeprowadzone na danych rzeczywistych opisujących rynek międzybankowy w Brazylii. Fronty Pareto uzyskane w obydwu scenariuszach: homogenicznym (HomCRR) oraz heterogenicznym (HetCRR) dla kilku różnych wielkości początkowego kryzysu ($\zeta = 0.01, 0.05, 0.10, 0.20$) pokazuje Rys. 20.



Rys. 20. Fronty Pareto uzyskane w obydwu scenariuszach: homogenicznym (HomCRR) oraz heterogenicznym (HetCRR) dla kilku różnych wielkości początkowego kryzysu ($\zeta = 0.01, 0.05, 0.10, 0.20$) [A16, Fig. 2]

Wyraźnie widoczna jest bardzo duża przewaga rozwiązań uzyskiwanych w scenariuszu heterogenicznym. Pozwalają one uzyskać znacznie niższy poziom strat wynikających z kryzysu (f_2) przy danym sumarycznym poziomie rezerw (f_1). W scenariuszu heterogenicznym bardziej wyraźny jest też spadek wielkości strat (Rys. 20 na osiach pionowych) po przekroczeniu pewnego krytycznego poziomu rezerw (Rys. 20 na osiach poziomych). Jest to efekt podobny do efektu odporności zbiorowej (ang. *herd immunity*) obserwowanego w przypadku zapobiegania epidemiom.

Podsumowując, przeprowadzenie opisanych w tym punkcie prac badawczych pozwoliło na **zrealizowanie celu szczegółowego C03**, czyli zbadanie wpływu struktury powiązań między podmiotami gospodarczymi na poziom ryzyka systemowego oraz **zrealizowanie celu szczegółowego C04**, czyli zbadanie przydatności opracowanych metod dla rzeczywistych problemów optymalizacji w zagadnieniach ochrony przed zagrożeniami takimi jak epidemie, upadłości firm, itp. Wyniki badań przedstawione w artykule [A14] wskazują na istotny wpływ zarówno gęstości grafu jak i strategii zaspokajania dłużników przez poszczególne podmioty na ryzyko systemowe, co potwierdza prawdziwość hipotez H04 i H05. Zgodnie z hipotezą H06, badania opisane w artykule [A15] pozwoliły lepiej zrozumieć wpływ niekompletnej

wiedzy o przebiegu epidemii na uzyskiwane wyniki optymalizacji. Zastosowanie opracowanych metod do zapobiegania epidemiom oraz minimalizacji ryzyka systemowego pozwoliło na uzyskanie lepszych wyników optymalizacji oraz lepsze zrozumienie tych problemów, co potwierdza hipotezę badawczą H07.

3.1.7. Projekty badawcze powiązane tematycznie z cyklem publikacji

Część wymienionych powyżej prac została zrealizowana w powiązaniu z projektami badawczymi finansowanymi przez NCN i NAWA. W ramach projektu NCN pt. „**Modele i metody wykorzystania wiedzy dziedzinowej w algorytmach metaheurystycznych dla problemów optymalizacji w świecie rzeczywistym**” prowadzone były prace nad usprawnieniem działania metod optymalizacji poprzez wykorzystanie wiedzy dziedzinowej. W ramach projektu opracowane zostały m.in. metody pozyskiwania (Rys. 4) i wykorzystania informacji (Rys. 5) podczas rozwiązywania problemów przez algorytmy ewolucyjne. Zostało także opracowane podejście do wykorzystania modeli uczenia maszynowego zgodnie z zasadą „wytrenuj raz, stosuj wielokrotnie” (Rys. 6). Prace badawcze przedstawione w publikacjach omawianych podpunkcie 0 zostały przeprowadzone w ramach projektu NCN.

W ramach Programu Bekkera (NAWA), został sfinansowany pobyt w Department of Veterinary Sciences, Data Analysis and Modeling Unit w Uniwersytecie Turyńskim. Podczas pobytu został zrealizowany projekt badawczy pt. „**Optimization of Epidemics Control in Dynamic Complex Networks**”. Dotyczył on wykorzystania metod optymalizacji do zapobiegania epidemiom chorób zwierzęcych rozprzestrzeniających się poprzez transporty zwierząt hodowlanych. Prace badawcze dotyczyły optymalizacji dla danych rzeczywistych z uwzględnieniem niekompletnej wiedzy dotyczącej sieci transportów i występowania przypadków choroby. Wyniki tych badań zostały opublikowane w artykułach [Michalak 2020] oraz [A15].

Obliczenia będące podstawą publikacji wchodzących w skład cyklu publikacji przedstawionego w tym autoreferacie wykonano na komputerach Wrocławskiego Centrum Sieciowo-Superkomputerowego (<http://www.wcss.pl>), grant obliczeniowy Nr 407.

3.1.8. Podsumowanie głównego osiągnięcia naukowego

Głównym osiągnięciem naukowym jest cykl publikacji przedstawiających wyniki prac badawczych mających na celu **opracowanie algorytmów metaheurystycznych dla problemów ochrony grafów przed zagrożeniami**. Artykuły [A01]-[A06] dotyczą opracowania algorytmów metaheurystycznych lub ich elementów (operatorów genetycznych, procedur przeszukiwania lokalnego, itp.), które pozwalają skuteczniej rozwiązywać badane problemy optymalizacji. Artykuły [A07]-[A13] dotyczą wykorzystania modeli uczenia maszynowego w celu usprawnienia algorytmów metaheurystycznych w zastosowaniu do problemów grafowych. W zagadnieniach ochrony grafów przed zagrożeniami rozwiązanie problemu optymalizacji najczęściej składa się z decyzji podejmowanych dla wierzchołków lub krawędzi grafu, takich jak szczepienia wierzchołków lub izolacja czyli dezaktywacja krawędzi (w przypadku epidemii) albo gromadzenie rezerw lub aktywacja/dezaktywacja kontaktów biznesowych (w przypadku problemu ochrony przed upadłościami). Pozwala to na zastosowanie modeli uczenia maszynowego (klasyfikacji lub regresji) do generowania takich decyzji w oparciu o różnego rodzaju atrybuty, takie jak np. miary grafowe: stopień wierzchołka, bliskość (ang. *closeness*), pośrednictwo (ang. *betweenness*) itp. Opracowane metody pozwalają trenować modele uczenia maszynowego na mniejszych instancjach problemu (np. dla 1000 wierzchołków), a następnie stosować wytrenowane modele dla większych instancji (nawet dla 10 000 wierzchołków). Jest to ważne, ponieważ problemy optymalizacji dla grafów cechują się dużą złożonością obliczeniową. Artykuły [A14]-[A16] przedstawiają **wyniki badań dla problemów rzeczywistych**: zapobiegania rozprzestrzenianiu się chorób wśród zwierząt hodowlanych oraz minimalizacji ryzyka systemowego dla rynku międzybankowego. Dane wykorzystane w artykule [A15] zostały dostarczone przez zespół Data Analysis and Modeling Unit z Uniwersytetu Turyńskiego i na ich podstawie przeprowadzone zostały badania nad zastosowaniem algorytmów metaheurystycznych do zapobiegania epidemiom chorób zwierząt hodowlanych w świecie rzeczywistym. Prace badawcze opisane w tej publikacji zostały zrealizowane podczas pobytu w Uniwersytecie Turyńskim sfinansowanego przez NAWA w ramach Programu Bekkera. **Badania nad zapobieganiem epidemiom chorób zwierząt hodowlanych mają istotne znaczenie dla gospodarki** ze względu na duże koszty zwalczania chorób, straty wśród zwierząt oraz negatywne skutki dla biznesu (straty wywoływane koniecznością uboju zwierząt, problemy wynikające z izolacji gospodarstw, itp.). Jak już wspomniano

w podpunkcie 3.1.2, skutkiem samych tylko epidemii przyszczyły są straty ekonomiczne liczone w miliardach USD oraz śmierć milionów zwierząt [Boum 2002; Knight-Jones 2013].

Dane wykorzystane w publikacjach [A14] oraz [A16] zostały zebrane przez badaczy z Uniwersytetu w São Paulo oraz Banku Centralnego Brazylii. Na ich podstawie przeprowadzone zostały badania nad stabilnością systemów finansowych oraz zastosowaniem algorytmów metaheurystycznych do minimalizacji ryzyka systemowego. **Zrozumienie czynników wpływających na podatność systemu finansowego na kryzysy oraz wielkość tych kryzysów ma istotne znaczenie praktyczne.** Przykładowo, skutkiem kryzysu finansowego z lat 2007-2009 był spadek produkcji szacowanych przez Government Accountability Office na od kilku do nawet dziesięciu bilionów USD² [GAO 2013]. Z tego względu zrozumienie zależności takich jak np. wpływ strategii obsługi zadłużenia (ang. *pecking order*) przez firmy na stabilność całego rynku jest nie tylko interesujące pod względem naukowym, ale **może też mieć wpływ na kształtowanie regulacji prawnych** zwłaszcza dla tak silnie kontrolowanych rynków jak rynek międzybankowy.

Na podstawie uzyskanych wyników można stwierdzić, że **postawione hipotezy badawcze zostały zweryfikowane w sposób pozytywny:**

[H01] Nowe operatory genetyczne dla algorytmów ewolucyjnych, modele probabilistyczne dla algorytmów estymacji rozkładów oraz algorytmy przeszukiwania lokalnego umożliwiają uzyskiwanie lepszych rozwiązań dla problemów ochrony grafów przed zagrożeniami.

Zarówno operator Sim-X [A04], model probabilistyczny S-P [A03], jak i algorytm przeszukiwania lokalnego ED-LS pozwoliły uzyskać lepsze wyniki optymalizacji niż metody porównawcze. Także przystosowanie algorytmu Sim-EA [Michalak 2014b] do wielokryterialnego Problemu Gaszenia Pożarów opisane w artykule [A02] pozwoliło poprawić uzyskiwane wyniki optymalizacji.

[H02] Modele uczenia maszynowego użyte do ukierunkowania przeszukiwania w algorytmach metaheurystycznych umożliwiają uzyskiwanie lepszych rozwiązań dla problemów ochrony grafów przed zagrożeniami.

Opisane w artykule [A10] badania dotyczyły wykorzystania modeli uczenia maszynowego do kierowania kilkoma elementami algorytmu ewolucyjnego: inicjalizacją

² „Research suggests that U.S. output losses associated with the 2007-2009 financial crisis could range from several trillion to over \$10 trillion” [GAO 2013]

populacji, krzyżowaniem, mutacją oraz procedurą przeszukiwania lokalnego. Użycie sieci neuronowej wytrenowanej w oparciu o dane zebrane dla $|V| = 1000$ wierzchołków grafu pozwoliło poprawić wyniki dla problemu optymalizacji szczepień nawet dla $|V| = 20000$. W artykule [A11] opisane zostały badania dotyczące wykorzystania modeli uczenia maszynowego dla dwukryterialnej wersji problemu zapobiegania upadłościom firm. Najlepsze wyniki zostały uzyskane, gdy algorytm ewolucyjny wykorzystano do optymalizacji wag sieci neuronowych, które następnie zostały użyte do wygenerowania rozwiązań dla problemu optymalizacji.

[H03] Modele uczenia maszynowego przyczyniają się do poprawienia wyników optymalizacji poprzez ich użycie do sterowania operatorami genetycznymi, takimi jak operatory krzyżowania i mutacji

W artykułach [A07]-[A09] opisane zostały wyniki prac badawczych dotyczących wykorzystania modeli uczenia maszynowego do usprawnienia działania poszczególnych elementów algorytmów ewolucyjnych: inicjalizacji populacji [A07], mutacji [A08] oraz krzyżowania [A09]. Uzyskane wyniki potwierdzają, że użycie modeli uczenia maszynowego do sterowania operatorami genetycznymi pozwala poprawić wyniki optymalizacji.

[H04] Gęstość grafu wpływa na propagowanie się zagrożeń, przy czym, dla małych wstrząsów początkowych duża gęstość grafu zmniejsza ryzyko systemowe, zaś w przypadku dużych wstrząsów początkowych duża gęstość grafu zwiększa ryzyko systemowe.

Badania opisane w artykule [A12] wykazały, że dla małych wstrząsów początkowych (niewielu firm w stanie upadłości na początku symulacji), korzystniejsza, z punktu widzenia ograniczania ryzyka systemowego, jest duża liczba połączeń w grafie, zaś w przypadku dużych wstrząsów początkowych, korzystniejsza jest mniejsza liczba połączeń w grafie (Rys. 14). W przypadku progowego mechanizmu propagacji upadłości (str. 15), duża gęstość grafu powoduje, że narażenie (ang. *fragility*) wierzchołków grafu (2) dla małego wstrząsu początkowego jest niskie, co zapobiega rozprzestrzenianiu się upadłości. Jest to efekt znany jako współdzielenie ryzyka (ang. *risk sharing*). W przypadku dużego wstrząsu początkowego, jest wystarczająco dużo podmiotów w stanie upadłości dla $t = 0$, żeby narażenie sąsiednich wierzchołków grafu przekroczyło próg θ , co powoduje ich przejście w stan upadłości dla $t = 1$. Duża liczba krawędzi grafu sprzyja propagacji wstrząsu (ang. *shock propagation*). Podobne wnioski wysnuto na podstawie badań przeprowadzonych na danych rzeczywistych, opisanych w artykule [A14]. Wnioski z artykułów [A12] i [A14] pokazują możliwy kierunek

dalszych badań – optymalizację struktury powiązań biznesowych pod kątem redukcji ryzyka systemowego. Tego rodzaju podejście mogłoby być zastosowane w przypadku rynków silnie regulowanych (np. rynku międzybankowego).

[H05] Wybór strategii zaspokajania dłużników przez poszczególne podmioty ma istotny wpływ na ryzyko systemowe.

W artykule [A14] został zbadany wpływ preferencji dotyczących kolejności spłacania zobowiązań wobec wierzycieli (ang. *default pecking order*, DPO) na ryzyko systemowe. Otrzymane wyniki pokazały, że działania ukierunkowane na zmniejszenie ryzyka systemowego mogą dotyczyć nie tylko optymalizacji poziomu rezerw lub sieci kontaktów biznesowych, ale także preferencji dotyczących kolejności spłacania zobowiązań wobec wierzycieli.

[H06] Zastosowanie opracowanych metod do zapobiegania epidemiom oraz minimalizacji ryzyka systemowego pozwoli na lepsze zrozumienie tych problemów.

Badania opisane w artykule [A15] pozwoliły lepiej zrozumieć wpływ niekompletnej wiedzy o przebiegu epidemii na uzyskiwane wyniki optymalizacji. Otrzymane rezultaty pokazały, że zarówno optymalizacja ewolucyjna, jak i zastosowanie znanych z epidemiologii strategii planowania szczepień może przynosić korzyści, w zależności od tego, jak bardzo precyzyjna wiedza dotycząca przypadków choroby oraz transportów zwierząt jest dostępna.

[H07] Zastosowanie opracowanych metod do zapobiegania epidemiom oraz minimalizacji ryzyka systemowego pozwala na uzyskanie lepszych wyników optymalizacji.

W artykule [A16] przedstawione zostały wyniki badań nad wykorzystaniem algorytmów optymalizacji wielokryterialnej do poprawy efektywności i stabilności systemu finansowego. W eksperymentach porównana została skuteczność wprowadzenia regulacji dla całego rynku (scenariusz homogeniczny) oraz skuteczność regulacji na poziomie każdego banku (scenariusz heterogeniczny wykorzystujący optymalizację wielokryterialną). Zaobserwowano znaczną przewagę rozwiązań uzyskiwanych w scenariuszu heterogenicznym, co wskazuje na zasadność wprowadzania regulacji oraz wykorzystania metod optymalizacji wielokryterialnej do zrealizowania scenariusza heterogenicznego. Ponadto, zaobserwowano efekt podobny do znanego z epidemiologii efektu odporności zbiorowej (ang. *herd immunity*), co wskazuje na podobieństwo zagadnień zwalczania epidemii i minimalizacji ryzyka systemowego.

3.2. Prace badawcze oraz wynikające z nich publikacje w obszarze optymalizacji wielokryterialnej

Prace badawcze w tym obszarze dotyczyły opracowania nowych oraz usprawnienia istniejących algorytmów metaheurystycznych dla optymalizacji wielokryterialnej, a także analizy działania tego rodzaju metod. Jedną z istotniejszych publikacji w tym zakresie jest [Michalak 2014a], w której został zbadany **wpływ sąsiedztwa rozwiązań w algorytmie MOEA/D na (a)symetrię jego działania**. Przeprowadzone eksperymenty pokazały, że użycie sąsiedztwa z parzystą liczbą rozwiązań (co jest bardzo często dokonywanym wyborem w wielu publikacjach) prowadzi do istotnej statystycznie asymetrii w uzyskiwanych frontach Pareto nawet dla specjalnie opracowanego problemu optymalizacji, charakteryzującego się idealną symetrią. Wynik ten jest istotny dla zastosowań algorytmu MOEA/D, który jest jednym z najpopularniejszych algorytmów ewolucyjnych dla optymalizacji wielokryterialnej (według Google Scholar 8702 cytowania dla artykułu [Zhang 2007] oraz 2635 cytowań dla artykułu [Li 2009], stan na koniec kwietnia 2024 roku). Otrzymane wyniki stały się inspiracją dla zrealizowania prac badawczych mających na celu wykorzystanie kierunkowania presji selekcyjnej w algorytmie MOEA/D w taki sposób, aby poprawić uzyskiwane rozwiązania [Michalak 2015c]. Zaproponowana metoda wynika ze spostrzeżenia, że sąsiedztwo rozwiązań znajdujących się na skraju frontu Pareto składa się z wektorów kierunkowych, które, średnio rzecz biorąc, są skierowane ku środkowej części tego frontu, co ogranicza zdolność algorytmu do jego rozszerzania. W omawianym artykule zostały zaproponowane sposoby ukierunkowania presji selekcyjnej ku zewnętrznej części frontu Pareto, co pozwala poprawić wyniki optymalizacji. W publikacji [Michalak 2017] zaproponowane zostało podejście, w którym prawdopodobieństwo wyboru rozwiązania z sąsiedztwa używanego w algorytmie MOEA/D ma rozkład normalny zamiast rozkładu jednostajnego stosowanego w klasycznej wersji algorytmu MOEA/D. Opracowana metoda pozwoliła poprawić wyniki optymalizacji dla dwukryterialnej wersji problemu TSP. Dwie inne publikacje [Michalak 2015b; Michalak 2016a] dotyczyły **ulepszenia działania algorytmów przeszukiwania lokalnego** (ang. *local search*). Zaproponowany w publikacji [Michalak 2016a] algorytm przeszukiwania lokalnego DirLS wykorzystuje kryterium akceptacji rozwiązań oparte na agregacji funkcji celu metodą sumy ważonej. Algorytm DirLS przechowuje pary $\langle pos, dir \rangle$, w których zapamiętywany jest kierunek (wektor wagowy dir), który pozwolił poprawić istniejące rozwiązanie x dla danej pozycji (wektora funkcji celu $pos = F(x)$). W kolejnych przeszukiwaniach dla rozwiązania y znajdującego się na pozycji


$pos = F(y)$ jako wektor wagowy dla procedury przeszukiwania lokalnego wybierany jest wektor będący średnią z N_{dir} wektorów dla pozycji najbliższych pozycji pos . Algorytm DirLS pozwolił uzyskać lepsze wyniki optymalizacji dla problemów TSP i QAP niż metody porównawcze: DLS (wykorzystujący ustalone wektory wagowe) oraz PLS (wykorzystujący kryterium dominacji w sensie Pareto). Rozważane w omawianej publikacji algorytmy przeszukiwania lokalnego PLS, DLS oraz DirLS zostały następnie użyte w badaniach opisanych w publikacji [A05]. W drugiej publikacji dotyczącej metod przeszukiwania lokalnego [Michalak 2015b] została zaproponowana metoda, w której podczas przeszukiwania lokalnego wokół rozwiązania x wykorzystywany jest lokalny punkt odniesienia $u(x) \in \mathbb{R}^m$, w którym współrzędne $u(x)_i, i = 1, \dots, m$ są wyznaczone jako:

$$u(x)_i = \max\{f_i(x') : x' \in P \setminus \{x\} \wedge f_i(x') < f_i(x)\}, \quad (18)$$

gdzie:

- x – rozwiązanie, wokół którego wykonywane jest przeszukiwanie lokalne,
- P – populacja rozwiązań w algorytmie ewolucyjnym,
- m – liczba funkcji celu w problemie optymalizacji,
- $f_i(\cdot)$ – wartość i -tej funkcji celu.

Wartość współrzędnej $u(x)_i$ jest największą wartością występującą w populacji, która jest mniejsza niż wartość funkcji celu $f_i(x)$. Ponieważ rozważany jest wielokryterialny problem TSP, w którym wszystkie funkcje celu są minimalizowane, lokalny punkt odniesienia określony równaniem (18) składa się ze współrzędnych odpowiadających istniejącym w populacji rozwiązaniom, które w przestrzeni kryteriów są najbliżej punktu x i jednocześnie poprawiają wartości kryteriów dla rozwiązania x (Rys. 21).



Rys. 21. Wyznaczanie lokalnego punktu odniesienia dla rozwiązania x (funkcje celu f_1 i f_2 są minimalizowane)

Inne prace w zakresie metod optymalizacji wielokryterialnej dotyczyły wykorzystania dodatkowej populacji (archiwum przechowującego najlepsze dotąd znalezione rozwiązania) [Michalak 2015a], oraz losowo generowanych rozwiązań (imigrantów) w celu zwiększenia różnorodności w populacji [Michalak 2021a], co pozwoliło poprawić wyniki optymalizacji dla wielokryterialnego problemu TSP.

3.3. Prace badawcze oraz wynikające z nich publikacje w obszarze optymalizacji logistyki i transportu

Prace badawcze w tym obszarze były związane z realizacją projektu NCN pt. „Modele i metody wykorzystania wiedzy dziedzinowej w algorytmach metaheurystycznych dla problemów optymalizacji w świecie rzeczywistym” i miały na celu opracowanie metod optymalizacji, pozwalających na wykorzystanie wiedzy praktyków lub innych źródeł informacji w celu poprawienia wyników optymalizacji dla problemów dotyczących logistyki i transportu. Jako problem optymalizacyjny wybrano problem wyznaczania tras przepływu zapasów (ang. *Inventory Routing Problem*, IRP), ponieważ jest on uogólnieniem prostszych problemów marszrutyzacji oraz uwzględnia zarówno optymalizację transportu, jak i składowania towarów, co pozwala na zastosowanie w praktyce. W artykule [Lipinski 2018] opracowany został **algorytm ewolucyjny dla problemu IRP wykorzystujący znane z praktyki sposoby modyfikacji rozwiązań** w operatorach genetycznych (krzyżowania i mutacji) dla problemu IRP. Podczas inicjowania populacji, wykorzystywany jest, stosowany przez praktyków, sposób konstrukcji rozwiązań w celu uzyskania rozwiązania bazowego. Populacja początkowa składa się z rozwiązania bazowego oraz jego zmutowanych kopii. Ponieważ problem IRP zawiera liczne ograniczenia, które utrudniają znalezienie rozwiązań dopuszczalnych, w artykule [Michalak 2021b] opracowane zostało podejście zapobiegające łamaniu ograniczeń przez rozwiązania obecne w populacji przetwarzanej przez algorytm ewolucyjny. W omawianym artykule zaproponowane zostały operatory genetyczne (krzyżowania i mutacji) zapewniające generowanie wyłącznie rozwiązań dopuszczalnych. Algorytm ewolucyjny pracujący w oparciu o rozwiązania dopuszczalne został porównany z algorytmem Infeasibility Driven Evolutionary Algorithm (IDEA) [Ray 2009], w którym część populacji zawiera rozwiązania niedopuszczalne, mechanizm selekcji preferuje rozwiązania dopuszczalne, a wśród niedopuszczalnych te, które łamią ograniczenia w najmniejszym stopniu. Uzyskane wyniki pokazały, że algorytm ewolucyjny pracujący

w oparciu o rozwiązania dopuszczalne daje znacznie lepsze wyniki niż algorytm IDEA, co pozwala stwierdzić, że **opracowanie operatorów zapewniających dopuszczalność rozwiązań jest ważne dla skutecznego rozwiązywania problemu IRP.**

Celem projektu NCN było opracowanie metod optymalizacji opartych na wiedzy. Jednym z badanych podejść było wykorzystanie informacji pozyskanych przy rozwiązywaniu wybranych instancji problemu optymalizacji w celu usprawnienia optymalizacji dla innych instancji tego samego problemu. Dla problemów grafowych zostały opracowane algorytmy wykorzystujące modele uczenia maszynowego, trenowane w oparciu o dane uczące pozyskane podczas rozwiązywania problemu optymalizacji na mniejszych grafach, które następnie można wykorzystać podczas rozwiązywania problemu optymalizacji na większych grafach (podpunkt 0). Dla problemu IRP zostały opracowane także inne metody wykorzystujące wiedzę dziedzinową lub informacje pozyskane w trakcie rozwiązywania instancji danego problemu. W artykule [Lipinski 2019] opracowane zostało **podejście wykorzystujące sieci optimów lokalnych (ang. *Local Optima Networks*, LON) dla problemu IRP.** Problem IRP wymaga zaplanowania tras dla danego horyzontu czasowego (liczby dni H), przy czym trasa dla każdego dnia przebiega przez wybrany podzbiór spośród n lokalizacji zdefiniowanych dla danej instancji problemu IRP. W związku z tym, zaproponowana została metoda, która wykorzystuje sieć optimów lokalnych dla problemu TSP wymagającego odwiedzenia wszystkich n lokalizacji do rozwiązywania pod-problemu TSP (wymagającego zazwyczaj odwiedzenia $n' < n$ lokalizacji) dla każdego z H dni. W omawianym artykule zaproponowano zastosowanie metody symulowanego wyżarzania (ang. *Simulated Annealing*, SA), w którym modyfikacje rozwiązań są dokonywane przy pomocy informacji pochodzącej z sieci optimów lokalnych (SA-LON) dla problemu TSP dla n lokalizacji. Otrzymane wyniki pokazały, że zaproponowana metoda SA-LON działa lepiej niż klasyczny algorytm symulowanego wyżarzania SA oraz może być wykorzystana jako element algorytmu ewolucyjnego rozwiązującego problem IRP. W artykule [Michalak 2023d] zaprezentowana została metoda **wykorzystania dodatkowej wiedzy w algorytmie ewolucyjnym rozwiązującym problem IRP.** Źródłem dodatkowej wiedzy może być znane dobre rozwiązanie problemu albo interakcja z użytkownikiem. Poprawę uzyskiwanych rozwiązań można zaobserwować nawet jeśli interakcja z użytkownikiem sprowadza się do jednej sesji podczas całego działania algorytmu, w czasie której użytkownik podaje dziesięć przykładowych rozwiązań danej instancji problemu.

Oprócz prac ukierunkowanych na rozwiązywanie problemu IRP, zostały także podjęte badania mające na celu wygenerowanie trudnych instancji tego problemu, co zostało podyktowane obserwacją, że znane z literatury instancje problemu IRP są niejednokrotnie zbyt proste dla komercyjnych narzędzi optymalizacyjnych. W artykule [Michalak 2021c] omówiono **ewolucyjną metodę generowania trudnych instancji problemu IRP**. W opisywanej metodzie wykorzystywany jest algorytm ewolucyjny, w którym **rozwiązaniami** są wektory liczbowe opisujące **instancje** problemu IRP, populacja początkowa jest konstruowana na podstawie znanych z literatury instancji problemu, zaś funkcją celu (maksymalizowaną) jest czas rozwiązywania danej instancji przez oprogramowanie komercyjne (np. CPLEX albo Gurobi). Dla trudnych instancji problemu IRP wygenerowanych zaproponowaną metodą **czas rozwiązywania przez oprogramowanie komercyjne jest od kilkudziesięciu, do stu tysięcy razy dłuższy niż w przypadku instancji znanych z literatury**, które zostały użyte do zainicjowania początkowej populacji w algorytmie ewolucyjnym. Zaproponowana metoda jest więc bardzo skuteczna w generowaniu trudnych instancji problemu IRP. Wygenerowane instancje są użyteczne w testowaniu algorytmów optymalizacji rozwiązujących problem IRP, ponieważ pozwalają lepiej zróżnicować testowane algorytmy niż w przypadku testów na instancjach dostępnych w literaturze.

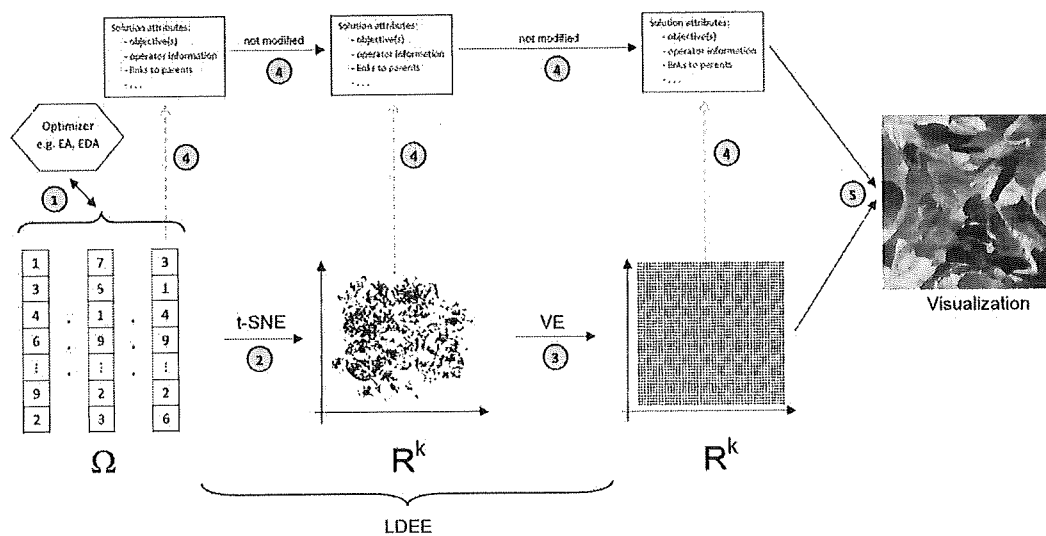
3.4. Prace badawcze oraz wynikające z nich publikacje w zakresie wizualizacji przestrzeni rozwiązań problemów optymalizacji

Opracowane podejście do wizualizacji przestrzeni rozwiązań problemów optymalizacji [Michalak 2019] umożliwia transformację danego zbioru rozwiązań z wysokowymiarowej przestrzeni wektorów binarnych, permutacji, itp. do niskowymiarowej przestrzeni euklidesowej, co ułatwia rysowanie wykresów, wizualizację populacji w algorytmach ewolucyjnych, itp. Założeniem opracowanej metody jest możliwie dokładne odwzorowanie odległości, co oznacza, że rozwiązania położone blisko siebie pod względem przyjętej metryki w przestrzeni rozwiązań Ω powinny być transformowane na punkty położone blisko siebie pod względem odległości euklidesowej w \mathbb{R}^2 . Rozwiązania wygenerowane przez algorytm ewolucyjny (Rys. 22, (1)) są transformowane do przestrzeni \mathbb{R}^2 przy pomocy metody t-distributed Stochastic Neighbor Embedding (Rys. 22, (2)), która transformuje rozwiązania położone blisko siebie w przestrzeni Ω na punkty położone blisko siebie w \mathbb{R}^2 . Jeśli pożądane jest uzyskanie równomiernego układu punktów (np. w celu wykonania


wykresu), wykonywana jest kolejna transformacja przy pomocy zaproponowanego w omawianej publikacji algorytmu Vacuum Embedding (Rys. 22, (3)). Atrybuty rozwiązań, takie jak wartości funkcji celu, ograniczenia, itp. są przypisywane w niezmięnionej formie punktom w \mathbb{R}^2 (Rys. 22, (4)), co umożliwia ich wykorzystanie do wizualizacji (Rys. 22, (5)).

Transformacja do niskowymiarowej przestrzeni euklidesowej umożliwia pokazanie rozwiązań znalezionych w trakcie wielu kolejnych uruchomień algorytmu ewolucyjnego (Rys. 23) oraz pokazanie przebiegu wybranego uruchomienia. Podobnie, można wizualizować przebieg optymalizacji dla pojedynczego uruchomienia algorytmu optymalizacji. W przypadku wizualizacji dwuwymiarowej (Rys. 24), wartości funkcji celu mogą być zaznaczone różnymi kolorami, zaś w przypadku wizualizacji trójwymiarowej (Rys. 25) dwie współrzędne pochodzą z transformacji metodą LDEE, zaś trzecią współrzędną jest wartość funkcji celu.


Na zaproszenie ze strony redakcji, metoda LDEE oraz przykładowe zastosowania zostały przedstawione w artykule opublikowanym w SIGEVolution – newsletterze ACM Special Interest Group on Genetic and Evolutionary Computation [Michalak 2023a]. W artykule [Thomson 2023] metoda LDEE została użyta do zwizualizowania przestrzeni rozwiązań dla problemu optymalizacji architektury sieci neuronowej (ang. *Neural Architecture Search, NAS*).




Rys. 22. Działanie metody Low-Dimensional Euclidean Embedding (LDEE) [Michalak 2019, Fig. 1]



Rys. 23. Wizualizacja rozwiązań problemu FFP dla $|V| = 100$ znalezionych w trakcie jednego uruchomienia algorytmu ewolucyjnego (kolorowe) w przestrzeni utworzone rozwiązań znalezionych w trakcie 30 uruchomień (szare). Kolor punktów zmienia się w zależności od numeru pokolenia od 1 do 250 w algorytmie ewolucyjnym (żółte – pokolenia początkowe, niebieskie – pokolenia końcowe).



Rys. 24. Dwuwymiarowa wizualizacja rozwiązań dla problemu Four Peaks Problem (4PP) znalezionych przez algorytm ewolucyjny uruchomiony przez 250 pokoleń. Kolorem niebieskim zaznaczone są rozwiązania o niskich wartościach funkcji celu a kolorem czerwonym o wysokich wartościach funkcji celu. Liczby oznaczają przybliżone położenie populacji w odpowiednich pokoleniach. Białe punkty pokazują położenie rozwiązań w pokoleniu 110. Strzałka wskazuje pierwsze rozwiązanie, które uzyskało premię REWARD = 100. [Michalak 2019, Fig. 5]



Rys. 25. Trójwymiarowa wizualizacja rozwiązań dla problemu Four Peaks Problem (4PP) znalezionych przez algorytm ewolucyjny uruchomiony przez 250 pokoleń. Białe znaczniki pokazują położenie rozwiązań w pokoleniu 110. Znacznik czerwony pokazuje pierwsze rozwiązanie, które uzyskało premię REWARD = 100.
[<https://krzysztof-michalak.pl/research/idee/index.html>]

4. Informacja o wykazywaniu się istotną aktywnością naukową realizowaną w więcej niż jednej uczelni lub instytucji naukowej w szczególności zagranicznej

Niektóre prace badawcze związane z tematyką głównego osiągnięcia naukowego zostały zrealizowane w ramach pobytów w zagranicznych ośrodkach goszczących.

W ramach akcji COST IC1404 zrealizowany został **pobyt w Institute for Biocomputation and Physics of Complex Systems (BIFI), Universidad de Zaragoza w Saragossie w Hiszpanii** w okresie od 2016-11-07 do 2016-12-06. Tematem prac badawczych było modelowanie wiedzy dziedzinowej w zastosowaniu do optymalizacji w problemach zapobiegania zagrożeniom w sieciach wielowarstwowych (ang. *Modelling domain-specific knowledge for optimizing threat prevention in multiplex networks*). Celem przedsięwzięcia było połączenie mojej wiedzy w zakresie optymalizacji z pracami badawczymi prowadzonymi w BIFI, które dotyczą modelowania systemów złożonych, między innymi przy pomocy sieci wielowarstwowych, a także z tematyką akcji COST

IC1404, czyli modelowaniem systemów cyberfizycznych („Multi-Paradigm Modelling for Cyber-Physical Systems”). W tym kontekście, modelowanie przy pomocy sieci wielowarstwowych ma zastosowanie między innymi do infrastruktury komunalnej, a w szczególności do rozwiązań typu „inteligentne miasto” (ang. *smart city*). Wzajemne powiązania wielu systemów, takich jak sieć energetyczna, systemy transmisji danych i sterowania, komunikacja miejska, itp. powodują, że uszkodzenia niektórych z tych systemów mogą przenosić się na inne systemy potęgując skutki awarii. Główne zadania zrealizowane podczas pobytu to:

1. **Zidentyfikowanie występujących w świecie rzeczywistym systemów mających strukturę sieci złożonych**, w których zastosowanie może mieć zapobieganie rozprzestrzenianiu się zagrożeń. Jednym z przykładów takich systemów są systemy informatyczne złożone z wielu powiązanych ze sobą usług sieciowych (ang. *Web Services*) [Eshuis 2015]. Awaryjne uszkodzenie niektórych usług powodują niemożność uruchomienia kolejnych, co może prowadzić do unieruchomienia całego systemu. Innym przykładem jest wspomniana powyżej infrastruktura komunalna, która może osiągać bardzo duży poziom złożoności. Przykładowo, w artykule [Robson 2015] opisana jest hierarchia 31 sieci (w tym 6 sieci powiązań lotniczych, 2 sieci energetyczne, 13 sieci kolejowych, 5 sieci drogowych, 4 sieci rzeczne oraz 1 sieć telekomunikacyjna).
2. **Zaproponowanie modelu** pozwalającego opisać system cyberfizyczny o strukturze wielowarstwowej z uwzględnieniem różnych typów węzłów sieci, ich atrybutów oraz sposobów funkcjonowania i reakcji na awarie, które są istotne z punktu widzenia modelowania rozprzestrzeniania się zagrożeń w takiej sieci.
3. **Zidentyfikowanie kilku typowych scenariuszy**, w których występują zjawiska znane z sieci złożonych (np. zmiana zachowania całego systemu mająca charakter przejścia fazowego, podatność na katastrofalne awarie, itp.), dla których można zastosować optymalizację w celu zapobieżenia rozprzestrzenianiu się zagrożeń.
4. **Opracowanie metod optymalizacji** dla scenariuszy opisanych w poprzednim punkcie oraz wykonanie eksperymentów, w których można zaobserwować wpływ optymalizacji na wrażliwość systemu na awarie, itp.

Raport z realizacji projektu jest dostępny pod adresem: http://msdl.uantwerpen.be/hosted/mpm4cps/STSM/reports/material/STSM_MichalakKrzysztof_Report.pdf

W ramach Programu Bekkera zrealizowany został projekt PPN/BEK/2018/1/00430 „Optimization of Epidemics Control in Dynamic Complex Networks” (lista beneficjentów programu dostępna pod adresem: <https://nawa.gov.pl/images/Bekker/bekker-nowa-lista/Bekker-lista-beneficjentow-2018.pdf>). Został on wykonany podczas **pobytu w Data Analysis and Modeling Unit (DAMU) na wydziale weterynarii Uniwersytetu Turyńskiego** w okresie od 2019-08-01 do 2020-02-29. Celem projektu było opracowanie metod optymalizacji dla problemu zwalczania epidemii chorób zwierzęcych przenoszonych poprzez transporty zwierząt hodowlanych. Do wykonania symulacji rozprzestrzeniania się choroby wykorzystany został **zbiór danych opisujących faktyczne transporty zwierząt w Piemontie w roku 2017**. W celu odzwierciedlenia nieprecyzyjnej wiedzy występującej w rzeczywistych zastosowaniach **przyjęto, że nie wszystkie przypadki choroby zostały zdiagnozowane na początku symulowanej epidemii** a jedynie pewna część α_{known} , oraz, że **faktyczny graf reprezentujący transporty zwierząt różni się od tego, dla którego przeprowadzana jest optymalizacja**, ponieważ pewna liczba par krawędzi α_{rewire} została zmodyfikowana poprzez zastąpienie krawędzi $\langle v_1, v_2 \rangle$ i $\langle v_3, v_4 \rangle$ krawędziami $\langle v_1, v_4 \rangle$ i $\langle v_3, v_2 \rangle$. Wynikiem badań przeprowadzonych podczas pobytu w Turynie są dwa artykuły naukowe. Artykuł [Michalak 2020] przedstawia analizę wpływu niezdiagnozowanych przypadków choroby na skuteczność działania metod optymalizacji. Badania przedstawione w artykule [A15] zawierają analizę wpływu niezdiagnozowanych przypadków choroby jak również wpływu różnic między faktycznym grafem (siecią transportów) a grafem użytym do optymalizacji. Prace rozpoczęte w ramach Programu Bekkera są kontynuowane, między innymi pod kątem zastosowania ewolucyjnych sieci neuronowych do przewidywania transportów zwierząt [Michalak 2023c] oraz zapobiegania epidemiom [Michalak 2023b].

Warto podkreślić, że nawiązana w związku z realizacją projektu w Programie Bekkera **współpraca z zespołem DAMU z Uniwersytetu Turyńskiego nie ogranicza się jedynie do prac badawczych dotyczących metod optymalizacji dla zapobiegania epidemiom**. W ramach tej współpracy, zostały także zrealizowane badania w zakresie uczenia maszynowego dotyczące klasyfikacji dla zbiorów danych cechujących się nierównowagą klas [Tarekegn 2021] oraz grupowania (ang. *clustering*) [Tarekegn 2020], a w czerwcu 2019 na Uniwersytecie Ekonomicznym we Wrocławiu gościliśmy Adane Tarekegn z zespołu DAMU z Uniwersytetu Turyńskiego.

5. Informacja o osiągnięciach dydaktycznych, kształceniu kadry naukowej, organizacyjnych oraz popularyzujących naukę

Wśród moich osiągnięć dydaktycznych warto wymienić **przedmioty prowadzone w języku angielskim:**

1. Przedmioty **Information Technologies** (laboratorium), **Introduction to Computer Science** (wykład+ćwiczenia) oraz **Business Programming** (wykład+laboratorium) dla studentów pierwszego roku pierwszego stopnia na kierunku Business Informatics.
2. Przedmiot **Mining of Financial Databases** (prowadzony w zależności od edycji kursu w formie wykład+laboratorium lub samo laboratorium) dla studentów drugiego roku drugiego stopnia na kierunku Finance.
3. Przedmiot **Bioinspired and Soft-Computing Methods in Data Analysis and Optimization**, będący moim autorskim kursem wykładowym, dla studentów drugiego roku drugiego stopnia na kierunku Informatyka w biznesie. Tematem kursu jest wykorzystanie metod metaheurystycznych, a w szczególności algorytmów ewolucyjnych do rozwiązywania różnorodnych problemów optymalizacji, poczynając od typowych jednokryterialnych problemów rzeczywistoliczbowych i kombinatorycznych, aż do zastosowań w optymalizacji wielokryterialnej, grafowej, itp. Przy opracowywaniu materiałów dla studentów do wizualizacji przestrzeni rozwiązań problemów optymalizacji zastosowano między innymi metodę LDEE, opisaną w punkcie 3.4.

W latach 2018-2023 pełniłem **funkcję promotora pomocniczego w przewodzie doktorskim** mgr Magdaleny Żabickiej-Włodarczyk na temat: **Big Data i zaawansowana analityka biznesowa w zarządzaniu relacjami z klientami w przedsiębiorstwach handlu detalicznego** (praca obroniona 2023-02-21, stopień nadany 2023-04-20³).

³ <https://wir.ue.wroc.pl/info/phd/UEWRd9f68171e71348eca9b68061107ec866&lang=pl>

6. Nagrody Rektora

W latach 2014-2023 otrzymałem 12 nagród Rektora Uniwersytetu Ekonomicznego we Wrocławiu za osiągnięcia naukowo-badawcze oraz za osiągnięcia w kształceniu lub wychowywaniu studentów lub kształceniu doktorantów (Tab. 4).

Tab. 4. Nagrody Rektora

Rok	Nagroda stopnia	Za osiągnięcia
2014	II	Naukowo-badawcze
2015	I	Naukowo-badawcze
2016	I	Naukowo-badawcze
2017	I	Naukowo-badawcze
2018	I	Naukowo-badawcze
2019	I	Naukowo-badawcze
2020	I	Naukowo-badawcze
2021	II	Naukowo-badawcze
2022	I	Naukowe
	III	Kształcenie lub wychowywanie studentów lub kształcenie doktorantów
2023	II	Naukowe
	II	Kształcenie lub wychowywanie studentów lub kształcenie doktorantów

7. Literatura

[Agarwal 2022] R. Agarwal, J. Farrar, G. Gopinath, R. Hatchett, P. Sands. *A Global Strategy to Manage the Long-Term Risks of COVID-19*. IMF Working Paper WP/22/68, International Monetary Fund, 2022.

[Antonioni 2014] A. Antonioni, S. Bullock, M. Tomassini. *REDS: An energy-constrained spatial social network model*. In H. Lipson, H. Sayama, J. Rieffel, S. Risi, R. Doursat, eds., *ALIFE 14: The Fourteenth International Conference on the Synthesis and Simulation of Living Systems*, pp. 368-375. MIT Press, 2014.

[Ariana 2023] A. A. G. B. Ariana, I. A. Wisky, N. L. W. S. R. Ginantra, M. R. Firmansyah, G. S. A. Daengs. *Performance analysis of scaled conjugate gradient (SCG) algorithm on computing problems*. AIP Conference Proceedings, vol. 2798, no. 1, page 020060, 2023.

[Bjørnstad 2002] O. N. Bjørnstad, B. F. Finkenstädt, B. T. Grenfell. *Dynamics of measles epidemics: Estimating scaling of transmission rates using a time series SIR model*. *Ecological Monographs*, vol. 72, no. 2, pp. 169-184, 2002.

- [Boum 2002] J. Boum. *The 2001 Outbreak of Foot and Mouth Disease*. Report by the comptroller and auditor general, National Audit Office, 2002.
- [Brauer 2008] F. Brauer. *Compartmental Models in Epidemiology*. In F. Brauer, P. van den Driessche, J. Wu, eds., *Mathematical Epidemiology*, pp. 19-79. Springer Berlin Heidelberg, Berlin, Heidelberg, 2008.
- [Burkholz 2016] R. Burkholz, M. Leduc, A. Garas, F. Schweitzer. *Systemic risk in multiplex networks with asymmetric coupling and threshold feedback*. *Physica D*, vol. 323-324, pp. 64-72, 2016.
- [Ceberio 2011] J. Ceberio, A. Mendiburu, J. A. Lozano. *Introducing the Mallows Model on Estimation of Distribution Algorithms*. In B.-L. Lu, L. Zhang, J. Kwok, eds., *Neural Information Processing*, volume 7063 of *Lecture Notes in Computer Science*, pp. 461-470. Springer Berlin Heidelberg, 2011.
- [Ceberio 2014] J. Ceberio, E. Irurozki, A. Mendiburu, J. A. Lozano. *A Distance-Based Ranking Model Estimation of Distribution Algorithm for the Flowshop Scheduling Problem*. *IEEE Transactions on Evolutionary Computation*, vol. 2, no. 18, pp. 286-300, 2014.
- [Dalgıç 2017] Ö. O. Dalgıç, O. Y. Özaltn, W. A. Ciccotelli, F. S. Erenay. *Deriving effective vaccine allocation strategies for pandemic influenza: Comparison of an agent-based simulation and a compartmental model*. *PLOS ONE*, vol. 12, no. 2, pp. 1-19, 2017.
- [Diem 2020] C. Diem, A. Pichler, S. Thurner. *What is the minimal systemic risk in financial exposure networks?* *Journal of Economic Dynamics and Control*, vol. 116, page 103900, 2020.
- [Eshuis 2015] R. Eshuis, A. Norta, O. Kopp, E. Pitkänen. *Service Outsourcing with Process Views*. *IEEE Transactions on Services Computing*, vol. 8, no. 1, pp. 136-154, 2015.
- [GAO 2013] *Financial Regulatory Reform: Financial Crisis Losses and Potential Impacts of the Dodd-Frank Act*. Report to Congressional Requesters GAO-13-180, U.S. Government Accountability Office, 2013.
- [Ghosh 2018] I. Ghosh, P. K. Tiwari, S. Samanta, I. M. Elmojtaba, N. Al-Salti, J. Chattopadhyay. *A simple SI-type model for HIV/AIDS with media and self-imposed psychological fear*. *Mathematical Biosciences*, vol. 306, pp. 160-169, 2018.
- [Guo 2017] W. Guo, K. Y. Szeto. *Minimization of Systemic Risk for Directed Network Using Genetic Algorithm*. In G. Squillero, K. Sim, eds., *Applications of Evolutionary Computation*, pp. 3-16, Cham, 2017. Springer International Publishing.
- [Hartnell 1995] B. Hartnell. *Firefighter! An application of domination*. In 20th Conference on Numerical Mathematics and Computing, 1995.
- [Hu 2015] B. Hu, A. Windbichler, G. R. Raidl. *A New Solution Representation for the Firefighter Problem*. In G. Ochoa, F. Chicano, eds., *Evolutionary Computation in Combinatorial Optimization*, volume 9026 of *LNCS*, pp. 25-35. Springer, 2015.
- [IBM Security 2022] IBM Security. *Cost of a Data Breach Report 2022*. <https://www.ibm.com/downloads/cas/3R8N1DZJ>, 2022. Online: accessed 2023.04.30.

- [Knight-Jones 2013]** T. Knight-Jones, J. Rushton. *The economic impacts of foot and mouth disease - What are they, how big are they and where do they occur?* Preventive Veterinary Medicine, vol. 112, no. 3, pp. 161-173, 2013.
- [Kostylenko 2018]** O. Kostylenko, H. S. Rodrigues, D. F. M. Torres. *Banking Risk as an Epidemiological Model: An Optimal Control Approach*. In A. I. F. Vaz, J. P. Almeida, J. F. Oliveira, A. A. Pinto, eds., Operational Research, pp. 165-176, Cham, 2018. Springer International Publishing.
- [Król 2015]** D. Król, D. Fay, B. Gabrys. Propagation phenomena in real world networks, volume 85 of *Intelligent Systems Reference Library*. Springer, 2015.
- [Kuhl 2021a]** E. Kuhl. The classical SIR model. In *Computational Epidemiology: Data-Driven Modeling of COVID-19*, pp. 41-59. Springer International Publishing, Cham, 2021.
- [Kuhl 2021b]** E. Kuhl. The classical SIS model. In *Computational Epidemiology: Data-Driven Modeling of COVID-19*, pp. 33-40. Springer International Publishing, Cham, 2021.
- [Ladley 2013]** D. Ladley. *Contagion and risk-sharing on the inter-bank market*. Journal of Economic Dynamics and Control, vol. 37, no. 7, pp. 1384-1400, 2013.
- [Li 2009]** H. Li, Q. Zhang. *Multiobjective optimization problems with complicated Pareto sets, MOEA/D and NSGA-II*. IEEE Trans. Evol. Comput., vol. 13, no. 2, pp. 284-302, 2009.
- [Li 2023]** J. Li, S. Li. *Immunization of systemic risk in trade-investment networks*. Physica A: Statistical Mechanics and its Applications, vol. 611, page 128440, 2023.
- [Lipinski 2018]** P. Lipinski, K. Michalak. *An Evolutionary Algorithm with Practitioner's-Knowledge-Based Operators for the Inventory Routing Problem*. In A. Liefooghe, M. López-Ibáñez, eds., Evolutionary Computation in Combinatorial Optimization, pp. 146-157, Cham, 2018. Springer International Publishing.
- [Lipinski 2019]** P. Lipinski, K. Michalak. *Deriving Knowledge from Local Optima Networks for Evolutionary Optimization in Inventory Routing Problem*. In Proceedings of the Genetic and Evolutionary Computation Conference Companion, GECCO '19, pp. 1551-1558, New York, NY, USA, 2019. ACM.
- [López 2007]** R. López, Y. Kuang, A. Tridane. *A simple SI model with two age groups and its application to US HIV epidemics: To treat or not to treat?* Journal of Biological Systems, vol. 15, no. 2, pp. 169-184, 2007.
- [Lubin 2022]** A. Lubin. *The Law and Politics of Ransomware*. Vanderbilt Journal of Transnational Law, vol. 55, page 1177, 2022. Indiana Legal Studies Research Paper No. 494.
- [Luk 2016]** P. W.-H. Luk, G. C. Lui, K. Y. Szeto. *Optimization of systemic stability of directed network using genetic algorithm*. In 2016 IEEE/ACIS 15th International Conference on Computer and Information Science (ICIS), pp. 1-6, 2016.
- [Michalak 2014a]** K. Michalak. *The effects of asymmetric neighborhood assignment in the MOEA/D algorithm*. Applied Soft Computing, vol. 25, pp. 97-106, 2014.

- [Michalak 2014b] K. Michalak. Sim-EA: An Evolutionary Algorithm Based on Problem Similarity. In E. Corchado, J. A. Lozano, H. Quintián, H. Yin, eds., *Intelligent Data Engineering and Automated Learning - IDEAL 2014*, volume 8669 of LNCS, pp. 191-198. Springer, 2014.
- [Michalak 2015a] K. Michalak. *Improving the NSGA-II Performance with an External Population*. In K. Jackowski, R. Burduk, K. Walkowiak, M. Wozniak, H. Yin, eds., *Intelligent Data Engineering and Automated Learning - IDEAL 2015*, pp. 273-280, Cham, 2015. Springer International Publishing.
- [Michalak 2015b] K. Michalak. *Local Search Based on a Local Utopia Point for the Multiobjective Travelling Salesman Problem*. In K. Jackowski, R. Burduk, K. Walkowiak, M. Wozniak, H. Yin, eds., *Intelligent Data Engineering and Automated Learning - IDEAL 2015 - 16th International Conference Wroclaw, Poland, October 14-16, 2015*, Proceedings, volume 9375 of *Lecture Notes in Computer Science*, pp. 281-289. Springer, 2015.
- [Michalak 2015c] K. Michalak. *Using an outward selective pressure for improving the search quality of the MOEA/D algorithm*. *Computational Optimization and Applications*, vol. 61, no. 3, pp. 571-607, 2015.
- [Michalak 2016a] K. Michalak. *Evolutionary algorithm with a directional local search for multiobjective optimization in combinatorial problems*. *Optimization Methods and Software*, vol. 31, no. 2, pp. 392-404, 2016.
- [Michalak 2016b] K. Michalak, J. D. Knowles. *Simheuristics for the Multiobjective Nondeterministic Firefighter Problem in a Time-Constrained Setting*. In G. Squillero, P. Burelli, eds., *Applications of Evolutionary Computation: 19th European Conference, EvoApplications 2016, Porto, Portugal, March 30 - April 1, 2016*, Proceedings, Part II, pp. 248-265. Springer International Publishing, 2016.
- [Michalak 2017] K. Michalak. *The MOEA/D Algorithm with Gaussian Neighbourhoods for the Multiobjective Travelling Salesman Problem*. In *Proceedings of the Genetic and Evolutionary Computation Conference Companion, GECCO '17*, pp. 155-156, New York, NY, USA, 2017. ACM.
- [Michalak 2019] K. Michalak. *Low-Dimensional Euclidean Embedding for Visualization of Search Spaces in Combinatorial Optimization*. *IEEE Transactions on Evolutionary Computation*, vol. 23, no. 2, pp. 232-246, 2019.
- [Michalak 2020] K. Michalak. *Multiobjective Optimization of a Targeted Vaccination Scheme in the Presence of Non-diagnosed Cases*. In P. A. Castillo, J. L. Jiménez Laredo, F. Fernández de Vega, eds., *Applications of Evolutionary Computation*, pp. 307-322, Cham, 2020. Springer International Publishing.
- [Michalak 2021a] K. Michalak. *Evolutionary Algorithm Using Random Immigrants for the Multiobjective Travelling Salesman Problem*. *Procedia Computer Science*, vol. 192, pp. 1461-1470, 2021. *Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 25th International Conference KES2021*.
- [Michalak 2021b] K. Michalak. *Feasibility-Preserving Genetic Operators for Hybrid Algorithms using TSP solvers for the Inventory Routing Problem*. *Procedia Computer Science*, vol. 192, pp. 1451-1460, 2021. *Knowledge-Based and Intelligent Information & Engineering Systems: Proceedings of the 25th International Conference KES2021*.

- [Michalak 2021c]** K. Michalak. *Generating Hard Inventory Routing Problem Instances Using Evolutionary Algorithms*. In Proceedings of the Genetic and Evolutionary Computation Conference, GECCO '21, pp. 243-251, New York, NY, USA, 2021. Association for Computing Machinery.
- [Michalak 2023a]** K. Michalak. *Visualizing Combinatorial Search Spaces with Low-Dimensional Euclidean Embedding*. SIGEVolution, vol. 15, no. 4, 2023.
- [Michalak 2023b]** K. Michalak, M. Giacobini. *Evolutionary Neural Networks for Livestock Disease Prevention*. In Proceedings of the Companion Conference on Genetic and Evolutionary Computation, GECCO '23 Companion, pp. 395-398, New York, NY, USA, 2023. Association for Computing Machinery.
- [Michalak 2023c]** K. Michalak, M. Giacobini. *Multiobjective Optimization of Evolutionary Neural Networks for Animal Trade Movements Prediction*. In M. Emmerich, A. Deutz, H. Wang, A. V. Kononova, B. Naujoks, K. Li, K. Miettinen, I. Yevseyeva, eds., *Evolutionary Multi-Criterion Optimization*, pp. 532-545, Cham, 2023. Springer Nature Switzerland.
- [Michalak 2023d]** K. Michalak, P. Lipinski. *Knowledge-based optimization algorithm for the inventory routing problem*. *Soft Computing*, vol. 27, no. 22, pp. 16959-16981, 2023.
- [Mondal 2016]** S. Mondal, S. Bag. *Face Recognition Using PCA and Minimum Distance Classifier*. In S. C. Satapathy, V. Bhateja, S. K. Udgata, P. K. Pattnaik, eds., *Proceedings of the 5th International Conference on Frontiers in Intelligent Computing: Theory and Applications - FICTA 2016, Bhubaneswar, Odisha, India, Volume 1, volume 515 of Advances in Intelligent Systems and Computing*, pp. 397-405. Springer, 2016.
- [Pastor-Satorras 2015]** R. Pastor-Satorras, C. Castellano, P. Van Mieghem, A. Vespignani. *Epidemic processes in complex networks*. *Reviews of Modern Physics*, vol. 87, pp. 925-979, 2015.
- [Ray 2009]** T. Ray, H. K. Singh, A. Isaacs, W. Smith. *Infeasibility Driven Evolutionary Algorithm for Constrained Optimization*. In E. Mezura-Montes, ed., *Constraint-Handling in Evolutionary Optimization*, pp. 145-165. Springer Berlin Heidelberg, Berlin, Heidelberg, 2009.
- [Robson 2015]** C. Robson, S. Barr, P. James, A. Ford. *Resilience of Hierarchical Critical Infrastructure Networks*. In T. Dolan, B. Collins, eds., *International Symposium for Next Generation Infrastructure Conference Proceedings: 30 September - 1 October 2014*, pp. 17-22. University College London, 2015.
- [Saengchote 2022]** K. Saengchote, K. Samphantharak. *Banking relationship and default priority in consumer credit: Evidence from Thai microdata*. *Emerging Markets Review*, vol. 52, page 100904, 2022.
- [Schiantarelli 2020]** F. Schiantarelli, M. Stacchini, P. E. Strahan. *Bank Quality, Judicial Efficiency, and Loan Repayment Delays in Italy*. *The Journal of Finance*, vol. 75, no. 4, pp. 2139-2178, 2020.
- [Steinwart 2008]** I. Steinwart, A. Christmann. *Support Vector Machines*. *Information Science and Statistics*. Springer New York, New York, NY, 2008.
- [Tarekegn 2020]** A. N. Tarekegn, K. Michalak, M. Giacobini. *Cross-Validation Approach to Evaluate Clustering Algorithms: An Experimental Study Using Multi-Label Datasets*. *SN Computer Science*, vol. 1, no. 5, page 263, 2020.

- [Tarekegn 2021] A. N. Tarekegn, M. Giacobini, K. Michalak. *A review of methods for imbalanced multi-label classification*. Pattern Recognition, vol. 118, page 107965, 2021.
- [Tharwat 2016] A. Tharwat. *Linear vs. quadratic discriminant analysis classifier: a tutorial*. International Journal of Applied Pattern Recognition, vol. 3, 2016.
- [Thomson 2023] S. L. Thomson, G. Ochoa, N. Veerapen, K. Michalak. *Channel Configuration for Neural Architecture: Insights from the Search Space*. In Proceedings of the Genetic and Evolutionary Computation Conference, GECCO '23, pp. 1267-1275, New York, NY, USA, 2023. Association for Computing Machinery.
- [Tornatore 2014] E. Tornatore, P. Vetro, S. M. Buccellato. *SIVR epidemic model with stochastic perturbation*. Neural Computing and Applications, vol. 24, no. 2, pp. 309-315, 2014.
- [Vang-Mata 2020] R. Vang-Mata. *Multilayer perceptrons: theory and applications*. Computer science, technology and applications. Nova Science Publishers, New York, 2020.
- [Watts 2002] D. J. Watts. *A simple model of global cascades on random networks*. Proceedings of the National Academy of Sciences, vol. 99, no. 9, pp. 5766-5771, 2002.
- [Webb 2010] G. I. Webb. *Naïve Bayes*. In C. Sammut, G. I. Webb, eds., Encyclopedia of Machine Learning, pp. 713-714. Springer US, Boston, MA, 2010.
- [WHO 2023] WHO. *WHO Coronavirus (COVID-19) Dashboard*. <https://covid19.who.int/?mapFilter=cases>, 2023. Online: accessed 2023.04.24.
- [Willem 2017] L. Willem, F. Verelst, J. Bilcke, N. Hens, P. Beutels. *Lessons from a decade of individual-based models for infectious disease transmission: a systematic review (2006-2015)*. BMC Infectious Diseases, vol. 17, page 612, 2017.
- [Zhang 2007] Q. Zhang, H. Li. *MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition*. IEEE Transactions on Evolutionary Computation, vol. 11, no. 6, pp. 712-731, 2007.
- [Zhang 2022] G. Zhang, Z. Li, A. Din. *A stochastic SIQR epidemic model with Lévy jumps and three-time delays*. Applied Mathematics and Computation, vol. 431, page 127329, 2022.



.....
(podpis wnioskodawcy)