

AUTOREFERAT

dr inż. Anna Bryniarska

Politechnika Opolska
Wydział Informatyki
Katedra Systemów Informatycznych i Sterowania

Opole, 2025

Spis treści

1	Dane osobowe	3
2	Posiadane dyplomy, stopnie naukowe	4
3	Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych lub artystycznych	5
4	Omówienie osiągnięć naukowych	6
4.1	Rodzaj i tytuł głównego osiągnięcia naukowego	6
4.2	Cykl publikacji	6
4.3	Omówienie celu naukowego wykazanych powyżej prac i osiągniętych wyników wraz z omówieniem ich wykorzystania	8
4.3.1	Wprowadzenie	9
4.3.2	Podstawowe pojęcia	10
4.3.3	Reprezentacja wiedzy w sieci semantycznej	13
4.3.4	Autorska logika wyszukiwania informacji	18
4.3.5	Rozszerzenia strukturalne i granularne logiki IRL	26
4.3.6	Zastosowania granulacji informacji w IRL	35
4.3.7	Autorskie osiągnięcia w zakresie niepewnego wyszukiwania wiedzy i granulacji	46
4.3.8	Podsumowanie	47
4.4	Wybrane publikacje spoza cyklu	47
4.5	Inne istotne osiągnięcia naukowe	49
4.5.1	Granty naukowe	49
4.5.2	Staże naukowe	50
4.5.3	Działalność recenzencka	50
4.5.4	Działalność ekspercka	50
4.6	Dane naukometryczne	51
5	Informacja o wykazywaniu się istotną aktywnością naukową realizowaną w więcej niż jednej instytucji	52

6	Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę	53
6.1	Osiągnięcia dydaktyczne	53
6.2	Osiągnięcia organizacyjne	55
6.3	Aktywność popularyzująca i upowszechniająca naukę	55
7	Inne informacje ważne z punktu widzenia wnioskodawcy	57

1. Dane osobowe

Imię i nazwisko:

dr inż. Anna Bryniarska

Profile naukowe:

- Web of Science: [F-9993-2018](#)
- ORCID: [0000-0002-3839-459X](#)
- SCOPUS: [55913254800](#)
- ResearchGate: [Anna Bryniarska](#)
- Semantic Scholar: [Anna Bryniarska 2778887](#)

2. Posiadane dyplomy, stopnie naukowe

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

Doktor nauk technicznych w dyscyplinie automatyka i robotyka

Politechnika Opolska, Wydział Elektrotechniki, Automatyki i Informatyki

Data uzyskania stopnia: 11 grudnia 2014 r.

Temat rozprawy doktorskiej: *Inteligentne wyszukiwanie wiedzy diagnostycznej wykorzystujące rozmytą logikę opisową na przykładzie wybranej klasy obiektów diagnozowanych.*

Promotor: dr hab. inż. Anna Walaszek-Babiszewska, prof. PO

Magister inżynier nauk technicznych w dyscyplinie informatyka

Specjalność: sieci komputerowe i systemy baz danych

Politechnika Opolska, Wydział Elektrotechniki, Automatyki i Informatyki

Data uzyskania dyplomu: czerwiec 2010 r.

Temat pracy magisterskiej: *Program edukacyjny do nauki geometrii przestrzennej.*

Promotor: dr inż. Waldemar Pokuta

3. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych lub artystycznych

- 10.2014 - 09.2015 - asystent, pracownik naukowo-dydaktyczny na **Uniwersytecie Opolskim**, Wydział Matematyki, Fizyki i Informatyki, Instytut Informatyki.
- 10.2015 - 09.2016 - adiunkt, pracownik naukowo-dydaktyczny na **Politechnice Opolskiej**, Wydział Elektrotechniki, Automatyki i Informatyki, Katedra Systemów Sterowania i Systemów Decyzyjnych.
- 10.2016 - 09.2020 - adiunkt, pracownik naukowo-dydaktyczny na **Politechnice Opolskiej**, Wydział Elektrotechniki, Automatyki i Informatyki, Instytut Informatyki.
- 10.2020 - 05.2025 - adiunkt, pracownik naukowo-dydaktyczny na **Politechnice Opolskiej**, Wydział Elektrotechniki, Automatyki i Informatyki, Katedra Informatyki.
- 05.2025 - obecnie - adiunkt, pracownik naukowo-dydaktyczny na **Politechnice Opolskiej**, Wydział Informatyki, Katedra Systemów Informatycznych i Sterowania.

4. Omówienie osiągnięć naukowych

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

4.1. Rodzaj i tytuł głównego osiągnięcia naukowego

Cykl powiązanych tematycznie artykułów naukowych opublikowanych w czasopismach naukowych lub recenzowanych materiałach z konferencji międzynarodowych, które w roku opublikowania artykułu w ostatecznej formie były ujęte w wykazie czasopism naukowych, sporządzonym zgodnie z przepisami wydanymi na podstawie art. 267 ust. 2 pkt 2 lit. b ustawy.

Temat głównego osiągnięcia naukowego:

Granulacja i wyszukiwanie wiedzy rozmytej w sieciach semantycznych.

4.2. Cykl publikacji

W prezentowanym cyklu uwzględniono wyłącznie publikacje, w których habilitantka wniosła wiodący wkład merytoryczny. Przy nazwisku habilitantki podano procentowy udział w poszczególnych publikacjach.

- **[P1]** Bryniarska, A. [100%]: *Certain Information Granule System as a Result of Sets Approximation by Fuzzy Context*, *International Journal of Approximate Reasoning*, 111, Elsevier, s. 1-20, 2019. DOI: [10.1016/j.ijar.2019.04.012](https://doi.org/10.1016/j.ijar.2019.04.012).
Punktacja ministerialna: 140 pkt; liczba cytowań (Scopus): 8.
- **[P2]** Bryniarska, A. [100%]: *Mathematical Models of Diagnostic Information Granules Generated by Scaling Intuitionistic Fuzzy Sets*, *Applied Sciences*, 2022, 12(5),

2597. DOI: [10.3390/app12052597](https://doi.org/10.3390/app12052597).

Punktacja ministerialna: 100 pkt; liczba cytowań (Scopus): 4.

- **[P3]** Bryniarska, A. [100%]: *The Auto-Diagnosis of Granulation of Information Retrieval on the Web, Algorithms*, 2020, 13, 264. DOI: [10.3390/a13100264](https://doi.org/10.3390/a13100264).

Punktacja ministerialna: 40 pkt; liczba cytowań (Scopus): 2.

- **[P4]** Bryniarska, A. [100%]: *The n -Pythagorean Fuzzy Sets, Symmetry*, 2020, 12, 1772. DOI: [10.3390/sym12111772](https://doi.org/10.3390/sym12111772).

Punktacja ministerialna: 70 pkt; liczba cytowań (Scopus): 11.

- **[P5]** Bryniarski, E.; Bryniarska, A. [50%]: *Rough Search of Vague Knowledge*, w: *Thriving Rough Sets, Studies in Computational Intelligence*, t. 708, red. G. Wang, A. Skowron, Y. Yao, D. Ślęzak, L. Polkowski, Springer, 2017, s. 283-309.

Liczba cytowań (Scopus): 5.

- **[P6]** Bryniarska, A. [100%]: *Autodiagnosis of Information Retrieval on the Web as a Simulation of Selected Processes of Consciousness in the Human Brain*, w: *Biomedical Engineering and Neuroscience*, red. W. P. Huneck, S. Paszkiel, *Advances in Intelligent Systems and Computing*, t. 720, Springer, 2018, s. 111-120.

Liczba cytowań (Scopus): 5.

- **[P7]** Bryniarska, A. [100%]: *Granulation of Technological Diagnosis in the Algebra of the n -Pythagorean Fuzzy Sets, AINA 2021*, w: *Lecture Notes in Networks and Systems*, t. 226, Springer, 2021, s. 358-369. DOI: [10.1007/978-3-030-75075-6](https://doi.org/10.1007/978-3-030-75075-6).

Punktacja ministerialna: 70 pkt.

- **[P8]** Bryniarska, A. [100%]: *Information Granule System Induced by a Perceptual System, Proceedings of the Federated Conference on Computer Science and Information Systems (FedCSIS 2019)*, Lipsk, 2019, s. 19-27. DOI: [10.15439/2019F147](https://doi.org/10.15439/2019F147).

- **[P9]** Bryniarska, A. [100%]: *An Uncertain Diagnostic System of Constructional and Technological Preferences, Proceedings of the 21st International Conference on Methods and Models in Automation and Robotics (MMAR 2016)*, Międzyzdroje, 29.08-1.09.2016, s. 256-260.

- **[P10]** Bryniarska, A. [100%]: *A Data Granulation Model for Searching Knowledge about Diagnosed Objects*, w: *Trends in Advanced Intelligent Control, Optimization and Automation (Proceedings of KKA 2017)*, *Advances in Intelligent Systems and Computing*, t. 577, Springer, 2017, s. 681-690.

- [P11] Bryniarska, A. [100%]: *The Model of Possible Web Data Retrieval, Proceedings of the 2nd IEEE International Conference on Cybernetics (CYBCONF 2015)*, Gdynia, 24-26 czerwca 2015, s. 348-353.
Liczba cytowań (Scopus): 5.
- [P12] Bryniarska, A. [100%]: *Fuzzy Granular Calculations for the Semantic Web Using Some Mathematical Morphology Methods*, w: R. Matousek (red.), *Recent Advances in Soft Computing (MENDEL 2017)*, Springer, 2018, s. 233-244. DOI: [10.1007/978-3-319-97888-8_20](https://doi.org/10.1007/978-3-319-97888-8_20).
- [P13] Bryniarska, A. [80%]; Pokuta, W.: *Ontology-Based Knowledge Representation in the IoT Cybersecurity System*, *Semantic Web Journal*, IOS Press, ISSN: 1570-0844, 2025, w druku.
Punktacja ministerialna: 140 pkt.

4.3. Omówienie celu naukowego wykazanych powyżej prac i osiągniętych wyników wraz z omówieniem ich wykorzystania

Cele naukowo-badawcze habilitantki, od rozpoczęcia aktywności naukowej na Politechnice Opolskiej, dotyczyły możliwości zastosowania sieci semantycznych (ang. *Semantic Web*) oraz wyszukiwania wiedzy, w szczególności niepewnej, w tych sieciach. Wiedza niepewna i niejasna w sieci semantycznej została opisana za pomocą logiki rozmytej (ang. *Fuzzy Logic*), natomiast badania ukierunkowały się w stronę granulacji (ang. *Granulation*) wiedzy w sieciach semantycznych w celu jej szybszego przeszukiwania. Rozważania teoretyczne prezentowane przez habilitantkę w publikacjach naukowych zostały zaimplementowane w ramach projektu „System oceniający i monitorujący poziom cyberbezpieczeństwa urządzeń IoE/IoT obywateli Rzeczypospolitej Polskiej” do analizy poziomu cyberbezpieczeństwa obywateli Polski, gdzie habilitantka była zatrudniona jako specjalistka od sztucznej inteligencji i sieci semantycznych. W ramach badań powstał niezależny moduł naukowy, który wykorzystuje sieć semantyczną do opisu i analizy danych zebranych w systemie.

Habilitantka rozpoczęła badania nad sieciami semantycznymi już w ramach pracy naukowo-badawczej prowadzonej podczas studiów doktoranckich. W tym okresie powstała koncepcja *logiki wyszukiwania informacji IRL* (ang. *Information Retrieval Logic*, skr. IRL) [7]. Logika wyszukiwania informacji pozwala na wyszukiwanie wiedzy w sieci semantycznej opisanej za pomocą rozmytej logiki opisowej (ang. *Fuzzy Description Logic*, fuzzyDL) [26]. Następnie badania zostały rozwinięte i rozszerzone w kolejnych etapach pracy naukowej.

Poniżej przedstawiono aparat teoretyczny utworzony i rozwijany przez habilitantkę w kolejnych publikacjach.

Prace zaprezentowane w cyklu powiązanych tematycznie publikacji wpisują się w dziedzinę nauk technicznych oraz nurt badań nad sztuczną inteligencją.

4.3.1 Wprowadzenie

Od początku istnienia Internetu możliwa jest szybka wymiana informacji za pomocą stron WWW wskazywanych przez adresy URL. Obecnie jednak obserwuje się nadmiar dostępnych treści, wśród których obok informacji wartościowych pojawiają się również treści nieprawdziwe. Analiza źródeł internetowych stała się więc ważną umiejętnością, a jeszcze większym wyzwaniem jest umożliwienie takiej analizy maszynom, które powinny potrafić wnioskować na podstawie danych dostępnych w sieci.

Odpowiedzią na problem „rozumienia” danych przez maszyny jest tworzenie sieci semantycznej, w której zapisywane są znaczenia pojęć oraz relacje między nimi. Dzięki temu agent komputerowy może analizować powiązania pojęć w sposób zbliżony do ludzkiego i wyciągać wnioski na podstawie odwzorowanych zależności.

Przykładowo, ciągi znaków „kot” i „pies” na stronie WWW są dla maszyny neutralne. W sieci semantycznej można jednak powiązać je z pojęciem „zwierzę domowe”, a następnie „zwierzę”. W efekcie agent komputerowy, otrzymując polecenie wyszukania zwierząt, potrafi stwierdzić, że oba napisy oznaczają nazwy zwierząt, natomiast np. „stół” nie należy do tej kategorii.

Wprowadzenie sieci semantycznej umożliwia zatem tworzenie agentów zdolnych do wyszukiwania wiedzy, co stanowi główną motywację prowadzonych badań. Warto przy tym zauważyć, że sieci semantyczne oraz współczesne modele językowe pełnią odmienne funkcje: modele generatywne AI odpowiadają na pytania w języku naturalnym, lecz ich działanie jest w dużej mierze nietransparentne, natomiast sieci semantyczne zapewniają pełną jawność i interpretowalność relacji, które stanowią podstawę wnioskowania. Dzięki temu mogą stanowić alternatywę lub uzupełnienie modeli językowych w zastosowaniach wymagających wyjaśnialności.

Przedmiotem badań habilitantki jest wyszukiwanie wiedzy niepewnej, niejasnej i niekompletnej w sieciach semantycznych. W celu skrócenia czasu wyszukiwania zaproponowano *granulację danych*, polegającą na grupowaniu informacji w granule, co zmniejsza liczbę elementów analizowanych podczas zapytań. Koncepcja ta nawiązuje do granulacji informacji w logice rozmytej (ang. *fuzzy granules*) [18].

Sieć semantyczna (ang. Semantic Web), zapoczątkowana przez Tim Bernersa-Lee [4], zakłada opisywanie wiedzy w sposób zrozumiały dla maszyn. Ontologie zapisane w OWL, RDF czy RDF Schema określają znaczenie danych i sposób ich interpretacji, umożliwiając automatyczne wnioskowanie. Semantic Web opiera się na założeniach teorii *semantic network*, a różni się od niej przede wszystkim zgodnością ze standardami Internetu.

System danych (ang. Data System, DS) definiuje strukturę sieci semantycznej i jej elementy, przetwarzając encje świata rzeczywistego na zbiory danych. Dane traktowane są jako wartości atrybutów lub elementy domen relacji, tworząc egzemplarze danych interpretowane przez agenta. DS obejmuje zbiory obiektów, egzemplarzy, danych, agentów, typów oraz relacji reprezentowania wiedzy i jej przetwarzania, w tym krotki wieloargumentowe, które umożliwiają tworzenie złożonych sieci semantycznych do przechowywania i przetwarzania wiedzy.

4.3.2 Podstawowe pojęcia

Zgodnie z definicją, **sieć semantyczna** to konceptualna struktura sieci utworzona w sposób czytelny dla maszyn [3]. Sieć semantyczna najczęściej przedstawiana jest za pomocą indeksowanego, skierowanego grafu. Ogólnie, wierzchołki (węzły) opisują tak zwane *koncepty*. Koncept to pojęcie odpowiadające klasie obiektów ze świata rzeczywistego. Natomiast krawędzie w grafie opisują role, jakie występują pomiędzy konceptami. Utworzona sieć semantyczna wraz ze wszystkimi jej elementami nazywana jest *ontologią*. Ontologia to wyraźna, czytelna maszynowo specyfikacja wspólnej konceptualizacji [27].

Dla systemu danych DS określamy elementy sieci semantycznej:

Koncept. Dla danej d w sieci semantycznej tworzony jest koncept C , który opisuje pewną klasę obiektów. Wtedy egzemplarze konceptu C są egzemplarzami danej d , a ta dana jest wartością pewnego jednoargumentowego atrybutu A . Przykładowo, konceptem może być wyrażenie „ojciec”, „matka”, „zwierzę”, „budynek”, „rzecz” czy „kwiat”.

Rola. Dla danej d w sieci semantycznej tworzona jest również rola R , która opisuje powiązanie (związek), jakie występuje pomiędzy dwoma wystąpieniami konceptów. Wtedy dana d jest wartością pewnego dwuargumentowego atrybutu A . Rolą może być wyrażenie „jest córką”, „zawiera”, „posiada”, „pochodzi z”, „łączy się z” czy „jest bliskie”.


Wystąpienie konceptu. Wystąpieniem konceptu C nazywamy każdy obiekt należący do danego konceptu $o \in [A = d]$. Obiekt należy do selektora formuły atomowej $A = d$, tj. spełnia $A(o) = d$. Wystąpienie konceptu opisuje konkretny obiekt ze świata rzeczywistego. Przykładowo, wystąpieniem konceptu „ojciec” może być konkretna osoba „Jan”, „Marek” czy „Piotr”, natomiast wystąpieniem konceptu „zwierzę” dla ontologii utworzonej na potrzeby opisu zwierząt w zoo może być „Małpa Henio” czy „Tygrys Diego”. Powiązanie, że dany obiekt jest wystąpieniem danego konceptu, zapisujemy $o : C$, przykładowo: *Jan: ojciec* lub *Tygrys Diego: zwierzę*.

Wystąpienie roli. Wystąpieniem roli R nazywamy każdą parę obiektów, które są ze sobą powiązane daną rolą $\langle o_1, o_2 \rangle \in [A = d]$, gdzie o_1, o_2 to dwa obiekty (wystąpienia konceptu). Wystąpienia roli zapisujemy $(o_1, o_2) : R$. Przykładowo, $(Jan, Anna) : \text{jest ojcem}$ oznacza wyrażenie „Jan jest ojcem Anny”.

Asercje. Wyrażenia postaci $o : C$, stwierdzające, że o jest wystąpieniem konceptu C , oraz $(o_1, o_2) : R$, oznaczające, że para $\langle o_1, o_2 \rangle$ jest wystąpieniem roli R , nazywamy *asercjami* w sieci semantycznej. Asercja postaci $o : C$ wyraża posiadanie przez obiekty cech opisanych jako koncept C . Natomiast asercja postaci $(o_1, o_2) : R$ wyraża posiadanie przez pary obiektów własności opisanych jako rola R .

Aksjomaty. Sieć semantyczna może zostać rozszerzona o krawędzie ustalające zależności pomiędzy konceptami lub rolami. Opisy tych zależności nazywane są *aksjomatami*. Aksjomat $C_1 = C_2$ oznacza, że koncept C_1 jest identyczny z konceptem C_2 , natomiast aksjomat $C_1 \subseteq C_2$ oznacza, że koncept C_1 zawiera się (jest podkonceptem) C_2 . Podobne aksjomaty występują dla ról w sieci semantycznej. Aksjomat $R_1 = R_2$ oznacza, że rola R_1 jest identyczna z rolą R_2 , natomiast aksjomat $R_1 \subseteq R_2$ oznacza, że rola R_1 zawiera się (jest podrolą) R_2 .


Na rysunku 4.1 przedstawiono schemat struktury sieci semantycznej z uwzględnieniem wszystkich elementów sieci semantycznej opisanych powyżej.




Rysunek 4.1: Schemat sieci semantycznej. Opracowanie własne.

Najczęściej podczas tworzenia sieci semantycznych na grafie oznacza się koncepty, role oraz aksjomaty o relacjach zawierania się konceptów, pomijając poszczególne wystąpienia

konceptów. Poniżej, na rysunkach 4.2 i 4.3, przedstawiono przykładowe sieci semantyczne utworzone przy pomocy programu *Protégé* [16].



Rysunek 4.2: Przykładowa sieć semantyczna służąca do diagnostyki kotłów małej mocy. Opracowanie własne.



Rysunek 4.3: Przykładowa sieć semantyczna służąca do określania cyberbezpieczeństwa urządzeń IoT. Opracowanie własne.

W celu opisu reprezentacji wiedzy zebranej za pomocą sieci semantycznej oraz możliwych operacji, które można przeprowadzić na tej wiedzy, stosuje się tak zwaną *logikę opisową* (ang. Description Logic).

Ontologia. W ramach sieci semantycznej powstaje tak zwana *ontologia*. W informatyce ontologie zostały zaadaptowane w dziedzinie sztucznej inteligencji do dzielenia się wiedzą i jej ponownego wykorzystania [11, 12]. Powszechnie wykorzystuje się ontologie w integracji informacji, we współpracy różnych systemów informatycznych oraz w inżynierii oprogramowania opartej na agentach.

Guarino zdefiniował ontologię jako „artefakt, na który składa się określone słownictwo używane do opisu pewnej rzeczywistości, wraz z zestawem wyraźnych założeń dotyczących zamierzonego znaczenia tego słownictwa” [14]. Ontologie stanowią modele pojęciowe, które wychwytyją i wyjaśniają słownictwo używane w semantyce aplikacji. Dzięki temu eliminuje się dwuznaczności w systemach i sieciach semantycznych.

Taksonomia. Taksonomia oznacza „klasyfikację bytów informacyjnych w postaci hierarchii, zgodnie z domniemanymi relacjami bytów świata rzeczywistego, które reprezentują” – zgodnie z definicją zaprezentowaną przez Daconta i in. [10]. W taksonomii terminy są ułożone w strukturę hierarchiczną z użyciem relacji *ojciec-syn*. Jest to uogólnienie relacji „jest” lub „jest typu”. W taksonomii nie ma jednak możliwości zapisu innych związków, przykładowo: przyczynowo-skutkowych, częściowych, skojarzeniowych czy związanych z lokalizacją. Ponadto taksonomia nie pozwala na zdefiniowanie atrybutów w instrukcjach warunkowych. Oznacza to, że pojęcie taksonomii ma wiele ograniczeń, których nie ma w przypadku zastosowania ontologii.

Tezaurus. Natomiast pod pojęciem *tezaury* rozumie się zestaw relacji między pojęciami, które są zorganizowane w sposób taksonomiczny. Tezaurus można więc postrzegać jako taksonomię rozszerzoną o relacje semantyczne z sieci, takie jak równoważność, odwrotność i asocjacja. Tezaurus gwarantuje spójność w wielu bazach danych oraz ułatwia indeksowanie i wyszukiwanie danych pojęć. Można powiedzieć, że tezaurus stanowi swoisty słownik pojęć, które są uporządkowane w znanej kolejności i ustrukturyzowane w taki sposób, że relacje równoważności, hierarchii i asocjacji między terminami są wyraźnie widoczne i identyfikowane za pomocą znormalizowanych wskaźników relacji stosowanych na zasadzie wzajemności.

4.3.3 Reprezentacja wiedzy w sieci semantycznej

Logika opisowa (ang. *Description Logic*, skr. DL) jest używana do opisu elementów sieci semantycznej. W kontekście badań nad siecią semantyczną [5, 22] reprezentacja wiedzy może być określona w tak zwanym *języku atrybutowym* (ang. *Attributive Language*, skr. AL) logiki opisowej [2, 9].

Wiedza w sieci semantycznej reprezentowana jest przez trzy podstawowe składniki: **TBox**, **RBox** oraz **ABox**. Sieć semantyczna może zostać rozszerzona o krawędzie ustalające zależności pomiędzy conceptami lub rolami, a opisy tych zależności nazywane są *aksjomatami*.

TBox. TBox (*Terminological Box*) opisuje wiedzę terminologiczną, czyli ogólną, w formie pojęć i ich hierarchii. Można powiedzieć, że za pomocą TBox zapisujemy taksonomię sieci semantycznej. Terminologia zbudowana jest z deklaracji opisujących ogólne właściwości pojęć (konceptów) w sieci semantycznej. Pod względem matematycznym terminologia ma strukturę kraty, ponieważ występuje w niej relacja subsumcji między pojęciami. Jednym z kluczowych elementów bazy wiedzy DL są operacje użyte do budowy terminologii. Takie operacje są bezpośrednio związane z formami i znaczeniem dozwolonych deklaracji. Terminologia zawiera definicje konceptów w sieci semantycznej, przy czym każdy koncept ma jedną definicję, która go jednoznacznie identyfikuje. Definicje konceptów są *acykliczne*, co oznacza, że pojęcia nie są definiowane same przez siebie ani pośrednio przez inne pojęcia, które do nich się odnoszą.

ABox. ABox (*Assertional Box*) zawiera wiedzę ekstensjonalną, czyli asercyjną. Wiedza ta jest specyficzna dla danej rozpoznawanej w sieci semantycznej domeny. Wiedza asercyjna jest zależna od kontekstu i może ulegać zmianie w czasie. Przykładem są konkretne instancje pojęć i ich relacje w danej dziedzinie.

RBox. RBox (*Role Box*) zawiera aksjomaty dotyczące ról zachodzących w sieci semantycznej. Opisuje ona związki między pojęciami w sieci, pozwalając na zdefiniowanie zależności hierarchicznych oraz semantycznych między rolami.

Poniżej przedstawiono formalny opis poszczególnych elementów logiki opisowej za pomocą syntaktyki języka atrybutowego logiki opisowej.

Syntaktyka TBox W ramach zbioru nazw konceptów i ról zapisanych w TBox znajdują się podstawowe elementy, które zawsze występują w sieci semantycznej. Są to:

- $\top$ (Top) - koncept uniwersalny oraz rola uniwersalna, zawierające wszystkie koncepty w rozpatrywanej przestrzeni.
- $\perp$ (Bottom) - koncept pusty oraz rola pusta, oznaczające brak jakiegokolwiek wystąpienia konceptu lub roli (zbiór pusty).

Niech C, D będą nazwami konceptów, R nazwą roli, a m - symbolem modyfikatora. Wtedy można określić następujące *złożone koncepty*:

- $\neg C$ - negacja konceptu; wyrażenie oznacza wszystkie wystąpienia konceptów, które nie są wystąpieniami konceptu C .
- $C \sqcap D$ - przecięcie, czyli koniunkcja konceptów C i D ; oznacza wszystkie wystąpienia konceptów C i D .

- $C \sqcup D$ - suma, czyli alternatywa konceptów C i D ; oznacza wszystkie wystąpienia konceptu C lub konceptu D .
- $\exists R.C$ - kwantyfikacja egzystencjalna; oznacza wszystkie wystąpienia konceptów pozostające w roli R co najmniej raz z wystąpieniem konceptu C .
- $\forall R.C$ - kwantyfikacja ogólna; oznacza wszystkie wystąpienia konceptów, które jeśli pozostają w roli R , to pozostają w niej z jakimś wystąpieniem konceptu C .
- $m(C)$ - modyfikacja m konceptu C ; oznacza koncept będący zmodyfikowaną formą konceptu C poprzez użycie modyfikatora m . Przykładowo, m może mieć wartości takie jak: *bardzo*, *bardziej*, *najbardziej*, *wysoki*, *wyższy*, *najwyższy*.

Koncepty, które nie są złożone, nazywamy *konceptami prostymi*. Koncepty proste występują w sieci semantycznej w zależności od dziedziny, jaką dana sieć opisuje. Przykładowo, gdy sieć semantyczna dotyczy świata zwierząt, wśród konceptów mogą pojawić się takie pojęcia, jak *tygrys*, *ssak*, *żółw*, *zwierzę lądowe* itp. Natomiast role mogą przyjmować nazwy takie jak *jest gatunkiem*, *posiada*, *żyje w*, *żywi się*.

Przykładowe koncepty złożone:

$$\begin{aligned}
\text{„ssaki wodne”} &= \neg \text{„ssaki lądowe”} \\
\text{„ssaki lądowe”} &= \text{„zwierzęta lądowe”} \sqcap \text{„ssaki”} \\
\text{„ssaki”} &= \text{„ssaki lądowe”} \sqcup \text{„ssaki wodne”} \\
\text{„tygrys syberyjski”} &= \exists \text{„żyje na Syberii”} \text{ „tygrys”} \\
\text{„ssaki wodne”} &= \forall \text{„żyje w wodzie”} \text{ „ssak”} \\
\text{„tygrys azjatycki”} &= \text{„jest największy”}(\text{„tygrys”})
\end{aligned}$$

Syntaktyka ABox. Dla dowolnych wystąpień konceptów t_1, t_2 , nazwy konceptu C oraz nazwy roli R , asercjami są wyrażenia postaci:

$$t_1 : C, \quad (t_1, t_2) : R$$

czytane odpowiednio: „ t_1 jest wystąpieniem konceptu C ” oraz „para (t_1, t_2) jest wystąpieniem roli R ”.

Przykładowo, wystąpieniem konceptu „*tygrys*” może być osobnik w zoo o imieniu „*Diego*”, a wystąpieniem konceptu „*jeleń*” - osobnik „*Czarek*”. Wtedy wystąpieniem roli „*żywi się*” jest:

$$(Diego, Carek) : \text{żywi się}$$

co czytamy „Diego żywi się Czarkiem”. Wystąpienie takiej roli może być przydatne przy określaniu, które zwierzęta można umieścić w jednej zagrodzie.

Syntaktyka aksjomatów TBox. Dla dowolnych nazw konceptów C, D , aksjomatami są wyrażenia postaci:

$$C \sqsubseteq D, \quad C = D$$

oznaczające odpowiednio: „koncept C jest podkonceptem D ” oraz „koncept C jest identyczny z konceptem D ”.

Przykłady:

$$\text{„tygrys”} \sqsubseteq \text{„ssak”}, \quad \text{„tygrys”} = \text{„tiger”}.$$

Pierwszy aksjomat oznacza, że tygrys jest ssakiem, a drugi - że koncepty „*tygrys*” i „*tiger*” są tożsame.

Syntaktyka aksjomatów RBox. Dla dowolnych nazw ról R_1, R_2 , aksjomatami są wyrażenia postaci:

$$R_1 \sqsubseteq R_2, \quad R_1 = R_2$$

oznaczające odpowiednio: „rola R_1 jest podrolą R_2 ” oraz „rola R_1 jest identyczna z rolą R_2 ”.

Przykłady:

$$\begin{aligned} \text{„jest ssakiem wodnym”} &\sqsubseteq \text{„jest ssakiem”}, \\ \text{„jest ssakiem wodnym”} &= \text{„jest ssakiem”} \sqcap \text{„żyje w wodzie”}. \end{aligned}$$

Pierwszy aksjomat oznacza, że rola „*jest ssakiem wodnym*” zawiera się w roli „*jest ssakiem*”, a drugi - że obie role są równoważne, gdy występuje także relacja „*żyje w wodzie*”.

Syntaktyka formuł. Ogólnie, dowolne asercje i aksjomaty opisane powyżej są formułami. Dla formuł φ, ϕ oraz dowolnej zmiennej x , w języku atrybutowym logiki opisowej można tworzyć kolejne formuły:

- $\neg\varphi$ - negacja formuły φ ,
- $\exists x.\varphi$ - kwantyfikacja egzystencjalna formuły φ względem zmiennej x ,
- $\forall x.\varphi$ - kwantyfikacja ogólna formuły φ względem zmiennej x ,
- $\varphi \Rightarrow \phi$ - implikacja formuł φ i ϕ ,
- $\varphi \wedge \phi$ - koniunkcja formuł φ i ϕ ,

- $\varphi \vee \phi$ - alternatywa formuł φ i ϕ ,
- $\varphi \Leftrightarrow \phi$ - ekwiwalencja formuł φ i ϕ .

Rozmyta reprezentacja wiedzy. Sieć semantyczna może zostać rozszerzona o opis *rozmytości* elementów w niej występujących, czyli konceptów, ról, asercji oraz aksjomatów, zgodnie z zasadami *logiki rozmytej* [29]. *Rozmyta logika opisowa* (ang. *Fuzzy Description Logic*, skr. fuzzyDL) [24, 25] pozwala na opisanie elementów sieci semantycznej poprzez przypisanie im funkcji przynależności, określającej niepewny charakter opisywanej wiedzy.

Poniżej przedstawiono elementy syntaktyki języka AL dla logiki wyszukiwania informacji IRL, analogicznie do języka fuzzyDL. Przedstawione składnie uzupełniają syntaktykę klasycznej logiki opisowej.

Syntaktyka z uwzględnieniem rozmytości dla aksjomatów TBox. Dla dowolnych nazw konceptów C, D oraz dowolnej liczby $\alpha \in [0, 1]$, aksjomatami są wyrażenia postaci:

$$\langle C \sqsubseteq D, \alpha \rangle, \quad \langle C = D, \alpha \rangle$$

gdzie α oznacza stopień, w jakim zachodzi relacja między konceptami.

Przykłady:

$\langle \text{„zwierzę mięsożerne”} \sqsubseteq \text{„ssak”}, 0.3 \rangle$ – „zwierzę mięsożerne” jest „ssakiem” w stopniu 0.3,
 $\langle \text{„tygrys”} = \text{„tiger”}, 0.9 \rangle$ – „tygrys” nazywany jest również „tiger” w stopniu 0.9.

Oznacza to, że w 10% nie jesteśmy pewni, czy napis „tiger” odnosi się w tym kontekście do „tygrysa”.

Syntaktyka z uwzględnieniem rozmytości dla aksjomatów RBox. Dla dowolnych nazw ról R_1, R_2 oraz dowolnej liczby $\alpha \in [0, 1]$, aksjomatami są wyrażenia postaci:

$$\langle R_1 \sqsubseteq R_2, \alpha \rangle, \quad \langle R_1 = R_2, \alpha \rangle$$

Przykłady:

$\langle \text{„jest ssakiem wodnym”} \sqsubseteq \text{„jest ssakiem”}, 0.95 \rangle$ - rola zawiera się w drugiej ze stopniem rozmytości 0.95.

$\langle \text{„jest ssakiem wodnym”} = \text{„jest ssakiem”} \sqcap \text{„żyje w wodzie”}, 0.7 \rangle$ - rola „jest ssakiem wodnym” jest identyczna z rolą „jest ssakiem i żyje w wodzie” w stopniu 0.7.

Syntaktyka z uwzględnieniem rozmytości dla formuł. Dowolne asercje i aksjomaty są formułami φ, ϕ . Dla dowolnej zmiennej x oraz liczby $\alpha \in [0, 1]$ (oznaczającej stopień rozmytości) można utworzyć formułę:

$$\langle \varphi, \alpha \rangle$$

co oznacza, że formuła φ jest prawdziwa w stopniu α .

Przykłady aksjomatów podano powyżej. Natomiast przykładowa asercja dla wystąpienia konceptu „*tygrys*” o imieniu „*Diego*”, wystąpienia konceptu „*jeleń*” o imieniu „*Czarek*” oraz roli „*żywi się*”:

$$(\text{Diego, Carek}) : \text{„żywi się”}$$

może mieć przypisany stopień rozmytości:

$$\langle (\text{Diego, Carek}) : \text{„żywi się”}, 0.5 \rangle$$

co oznacza, że *Diego żywi się Czarkiem w stopniu 0.5*.

Zastosowanie. Opisywana logika wyszukiwania informacji została zastosowana do diagnostyki obiektów technicznych na podstawie klasyfikatora konstrukcyjno-technologicznego, co zostało opisane w pracy [P9]. W badaniach wykazano, w jaki sposób można zastosować sieć semantyczną oraz logikę wyszukiwania informacji do zdefiniowania *agenta diagnostycznego*, który wyszukuje informacje o charakterze konstrukcyjnym i technologicznym, odpowiadające preferencjom klientów względem referencyjnego obiektu technicznego.

Na podstawie przedstawionej metody można wdrożyć system niepewny, który korzystając z nieprecyzyjnych danych wejściowych od klientów, potrafi określić ich preferencje i dostarczyć precyzyjne informacje techniczne. Takie podejście znacząco usprawnia proces obsługi klienta i personalizuje rekomendacje.

4.3.4 Autorska logika wyszukiwania informacji

Kolejne badania skoncentrowano na rozszerzeniu autorskiej logiki wyszukiwania informacji, opracowanej podczas pracy doktorskiej habilitantki. Wyszukiwanie informacji (ang. *Information Retrieval*, IR) w sieci semantycznej polega zwykle na znajdowaniu wiarygodnych i semantycznie najbliższych źródeł wiedzy. Nie zawsze jest to jednak możliwe, gdyż dane mogą być niepewne lub nieostre, choć poprawnie opisane ontologicznie. Mimo tej niepewności można często jednoznacznie wskazać właściwe źródła wiedzy, co określa się jako *paradoks rozmytej dokładności* (ang. *fuzzy disambiguation*) [7].

W sieciach semantycznych wyszukuje się egzemplarze danych będących:

- *konceptami* – wartościami jednoargumentowych atrybutów, opisującymi cechy obiektów,
- *rolami* – wartościami dwuargumentowych atrybutów, opisującymi własności lub relacje.

Jeśli dla danych z ontologii i zaleceń ekspertów występuje akceptowany stopień zgodności z danymi tezauryasa, relację tę nazywa się *residuum*. Wyszukiwanie w zasobach Web polega zatem na określaniu stopnia podobieństwa danych szukanych do danych tezauryasa, opisywanego liczbą z przedziału $[0, 1]$. Koncepty i role interpretowane są jako zbiory rozmyte określone na adresach zasobów wiedzy oraz parach tych adresów. W ten sposób zachodzi *rozmywanie* reprezentacji, natomiast ustalenie residuum prowadzi do jej *wyostrzenia* [6].

Wyznaczenie residuum polega na wskazaniu wiarygodnego, zaakceptowanego przez ekspertów zbioru adresów reprezentujących daną wiedzę; zbiory te traktowane są jako wynik wyszukiwania informacji.

Podczas wyszukiwania stosuje się następującą *regułę residuum*:

1. Zapytanie o wiedzę jest wyrażeniem ontologicznym zbudowanym z formuł tezauryasa.
2. Jeśli jedynym zasobem wiedzy jest strona tezauryasa (tzn. zbiór szukanych adresów jest pusty), to dla wszystkich metod interpretacji stopień podobieństwa danych spoza tezauryasa jest zerowy.
3. W przeciwnym przypadku eksperci akceptują zbiór adresów zasobów wiedzy diagnostycznej jako znaczeniowo najbliższy szukanej informacji.

Na tej podstawie wprowadza się *logikę wyszukiwania informacji IRL*, która stosuje regułę residuum.

Postulaty wyszukiwania informacji

- P1.** Wyróżniony jest *tezaurus*, zawierający zbiór wzorcowych terminów i formuł języka IRL. Wyrażenia tezauryasa reprezentują wiedzę z tej samej dziedziny co poszukiwana informacja i są zbudowane z terminów i asercji zbioru *Tez*.
- P2.** Do *ontologii* należą wszystkie terminy i formuły języka IRL odnoszące się do poszukiwanej informacji; tezaurus jest jej częścią. Formuły ontologii zbudowane są ze zbioru *Ont*. Stopień podobieństwa wystąpień ontologii do tezauryasa jest ustalany przez system ekspertowy, który określa zakres akceptowanych wartości V oraz zbiór interpretacji *Fuz*.

- P3.** Przestrzeń IR to adresy zasobów wiedzy w sieci Web (lub jej fragment), semantycznie powiązane z terminami i formułami reprezentującymi poszukiwaną informację.
- P4.** Wyszukiwanie informacji polega na znalezieniu dokumentu, którego struktura semantyczna, zbudowana z terminów ontologii, jest najbardziej podobna do struktury dokumentu tezauryasa [7]. Jeśli wystąpienia wyrażeń używane są przez agentów w ten sam sposób, reprezentują tę samą wiedzę. Wyszukiwanie odbywa się według reguły *residuum*.
- P5.** Podczas wyszukiwania przecięcie konceptów lub ról reprezentuje ich wspólną wiedzę. Opisy uzupełniające się (ang. *complementarity descriptions*) φ, ϕ oznaczamy $\varphi \& \phi$. Dla każdego opisu φ istnieje dualny φ^d , taki że $\varphi \& \varphi^d$ odpowiada wiedzy pewnego opisu tezauryasa.
- P6.** Jeśli $x, y \in [0, 1]$ są stopniami podobieństwa opisów φ, ϕ do tezauryasa, to stopień podobieństwa $\varphi \& \phi$ wynosi:

$$x \ t \ y,$$

gdzie t jest *t-normą*. Jeśli podobieństwo opisu φ^d oznaczymy jako x^d , to $x^d = 1 - x$. Odpowiednia s-norma ma postać:

$$x \ s \ y = 1 - (x \ t \ y).$$

- P7.** Standardowa t-norma spełnia własności: przemienność, łączność, monotoniczność oraz:

$$1 \ t \ x = x, \quad 0 \ t \ x = 0.$$

Dodatkowo, zgodnie z postulatem P6, zachodzi dualność $x^d = 1 - x$.

T-norma definiuje implikację (*residuum*):

$$z \leq (x \rightarrow y) \iff x \ t \ z \leq y,$$

czyli

$$(x \rightarrow y) = \sup\{z \in [0, 1] : x \ t \ z \leq y\}.$$

- P8.** Stopień podobieństwa koniunkcji $\varphi \wedge \phi$ do formuł tezauryasa określa:

$$x \ \boxtimes \ y := x \ t \ (x \rightarrow y).$$

P9. Stopień podobieństwa alternatywy $\varphi \vee \phi$ określa:

$$x \boxplus y := ((x \rightarrow y) \rightarrow y) \boxtimes ((y \rightarrow x) \rightarrow x).$$

P10. Algebra

$$AL = \langle L, \boxtimes, \boxplus, t, \rightarrow, 0, 1 \rangle$$

jest *regularną rezydualną kratą* (ang. *BL-algebra*) [15]. Działania $\boxtimes$, $\boxplus$, t i $\rightarrow$ zdefiniowano zgodnie z postulatami P6–P8.

Algebra $\langle L, \boxtimes, \boxplus, 0, 1 \rangle$ jest kompletną kratą, a $\langle L, t, 1 \rangle$ — przemianą podgrupą. W algebrze AL określa się także:

$$x' := (x \rightarrow 0), \quad x \leftrightarrow y := (x \rightarrow y) \boxtimes (y \rightarrow x),$$

oraz operację dualności d z postulatu P6.

Najczęściej wystąpienia konceptów są utożsamiane z egzemplarzami danych. Egzemplarze te są uważane przez informatyków za obiekty. Tutaj przestrzeń $X \cup X \times X$ jest zbiorem adresów zasobów sieci Web oraz par tych adresów, czyli adresów wszystkich dokumentów zawierających rozważane egzemplarze danych. Na przykład konkretny napis w danym miejscu ekranu monitora komputera jest egzemplarzem pewnej danej, wskazanej przez pewien adres tego zasobu wiedzy. Egzemplarze danych to również ustalenia konkretnych związków pomiędzy danymi, wskazane przez pary adresów tych danych w sieci semantycznej. Koncepty i role interpretuje się jako zbiory rozmyte postaci:

$$\mu : X \cup X \times X \rightarrow [0, 1].$$

Rozmywanie wiedzy w IRL

Wyrażenia języka logiki IRL interpretuje się w algebrze $AL = \langle L, \boxtimes, \boxplus, t, \rightarrow, 0, 1 \rangle$ oraz w uporządkowanej algebrze zbiorów rozmytych:

$$F = \langle F, \&^F, \wedge^F, \vee^F, \neg^F, c^F, e^F, 0^F, 1^F, M, (\cdot)^d, F_0 \rangle.$$

Algebra F składa się z rodziny zbiorów rozmytych F oraz następujących operacji i funkcji:

- $\wedge^F$ - operacja przecięcia zbiorów rozmytych,
- $\vee^F$ - operacja sumy zbiorów rozmytych,

- $\neg^F$ - operacja dopełnienia zbiorów rozmytych,
- c^F - funkcja zwana stopniem zawierania się zbiorów rozmytych [15],
- e^F - funkcja zwana stopniem równości zbiorów rozmytych,

oraz zbiorów:

- 0^F - zbiór rozmyty będący funkcją o jednej wartości 0 (zbiór pusty),
- 1^F - zbiór rozmyty będący funkcją o jednej wartości 1 (zbiór pełny),
- M - zbiór operacji jednoargumentowych zwanych funkcjami modyfikacji,
- $(\cdot)^d$ - jednoargumentowa funkcja modyfikacji zbiorów rozmytych o wartościach dualnych (postulat P6),
- $F_0 \subseteq F$ - wyróżniona rodzina zbiorów rozmytych, taka że jeśli $\mu \in F_0$, to istnieje $Y \subseteq X \cup X \times X$ takie, że dla $y \in Y$, $\mu(y) = 1$, a w przeciwnym razie $\mu(y) = 0$.

Operacje sumy i iloczynu zbiorów rozmytych określają odpowiednie t-normy i s-normy. Zdefiniowane są w algebrze $AL = \langle L, \boxtimes, \boxplus, t, \rightarrow, 0, 1 \rangle$ następująco (dla dowolnych zbiorów rozmytych $\mu_A, \mu_B \in F$ oraz dowolnych $x \in [0, 1]$):

$$\begin{aligned}
(\mu_A \&^F \mu_B)(x) &= \mu_A(x) \, t \, \mu_B(x), \\
(\mu_A \wedge^F \mu_B)(x) &= \mu_A(x) \boxtimes \mu_B(x), \\
(\mu_A \vee^F \mu_B)(x) &= \mu_A(x) \boxplus \mu_B(x), \\
c^F(\mu_A, \mu_B)(x) &= \mu_A(x) \rightarrow \mu_B(x), \\
e^F(\mu_A, \mu_B)(x) &= \mu_A(x) \leftrightarrow \mu_B(x), \\
(\neg^F \mu_A)(x) &= \mu_A(x) \rightarrow 0, \\
(\mu_A^d)(x) &= 1 - \mu_A(x).
\end{aligned}$$

Niech X będzie zbiorem wszystkich adresów zasobów wiedzy (egzemplarzy danych), których dotyczy wiedza reprezentowana w sieci semantycznej, a $X \times X$ - zbiorem wszystkich uporządkowanych par elementów zbioru X .

Dla dalszych rozważań przyjmuje się, że interpretacja $I = (F^I)$ spełnia następujące warunki:

- F1. Wystąpieniom konceptów t przyporządkowuje się pewne wartości $t^I \in X$, a wystąpieniom par (t_1, t_2) przyporządkowuje się pary $(t_1^I, t_2^I) \in X \times X$.
- F2. Nazwom konceptów C przyporządkowuje się zbiory rozmyte $C^I : X \cup X \times X \rightarrow [0, 1]$, takie że dla każdego $x, y \in X$, $C^I(x, y) = C^I((x, y)) = C^I(y)$.

- F3. Nazwom roli R przyporządkowuje się zbiory rozmyte $R^I : X \cup X \times X \rightarrow [0, 1]$, równe 0 dla argumentów ze zbioru X .
- F4. Modyfikatorom m przyporządkowuje się funkcje $m^I : [0, 1] \rightarrow [0, 1]$, gdzie $m^I \in M$.
- F5. Formułom φ , w tym asercjom oraz aksjomatom, przyporządkowuje się pewną liczbę $\varphi^I \in [0, 1]$.

Semantyka logiki IRL

Poniżej przedstawiono semantykę logiki wyszukiwania informacji dla konceptów, asercji, aksjomatów oraz formuł.

Semantyka konceptów (TBox). Dla dowolnych $x \in X$, nazw konceptów C, D , nazwy roli R oraz modyfikatora m :

- F6. $T^I(x) = 1$
- F7. $\perp^I(x) = 0$
- F8. $(C^d)^I(x) = (C^I(x))^d$
- F9. $(R^d)^I(x) = (R^I(x))^d$
- F10. $(\neg C)^I(x) = (\neg^F C^I)(x)$
- F11. $(C \sqcap D)^I(x) = (C^I \wedge^F D^I)(x)$
- F12. $(C \sqcup D)^I(x) = (C^I \vee^F D^I)(x)$
- F13. $(\exists R.C)^I(x) = \sup_{y \in X} \{(R^I \wedge^F C^I)(x, y)\}$
- F14. $(\forall R.C)^I(x) = \inf_{y \in X} \{(\neg^F R^I \vee^F C^I)(x, y)\}$
- F15. $(m(C))^I(x) = m^I(C^I(x))$

Semantyka asercji (ABox). Dla dowolnych wystąpień konceptów t_1, t_2 , konceptu C oraz roli R :

- F16. $(t : C)^I = C^I(t^I)$
- F17. $((t_1, t_2) : R)^I = R^I(t_1^I, t_2^I)$

Semantyka aksjomatów. Dla dowolnych konceptów C, D i ról R_1, R_2 :

- F18. $(C \sqsubseteq D)^I = c^F(C^I, D^I)$

$$\text{F19. } (R_1 \sqsubseteq R_2)^I = c^F(R_1^I, R_2^I)$$

$$\text{F20. } (C = D)^I = e^F(C^I, D^I)$$

$$\text{F21. } (R_1 = R_2)^I = e^F(R_1^I, R_2^I)$$

Semantyka formuł. Dla dowolnych formuł φ, ϕ oraz stopni $\alpha \in [0, 1]$:

$$\text{F22. } (\neg\varphi)^I = \varphi^I \rightarrow 0$$

$$\text{F23. } (\varphi \wedge \phi)^I = \varphi^I \boxtimes \phi^I$$

$$\text{F24. } (\varphi \vee \phi)^I = \varphi^I \boxplus \phi^I$$

$$\text{F25. } (\varphi \Rightarrow \phi)^I = \varphi^I \rightarrow \phi^I$$

$$\text{F26. } (\varphi \Leftrightarrow \phi)^I = \varphi^I \leftrightarrow \phi^I$$

$$\text{F27. } (\exists x \varphi(x))^I = \sup\{y \in [0, 1] : \exists t \text{ takie, że } y = \varphi(t)^I\}$$

$$\text{F28. } (\forall x \varphi(x))^I = \inf\{y \in [0, 1] : \exists t \text{ takie, że } y = \varphi(t)^I\}$$

$$\text{F29. } \langle \varphi, \alpha \rangle^I = \begin{cases} 1, & \text{gdy } \varphi^I \geq \alpha, \\ \varphi^I, & \text{gdy } \varphi^I < \alpha \end{cases}$$

Gdy interpretacja I spełnia warunki F1-F29, nazywamy ją *rozmywaniem języka logiki IRL*. Jeżeli w wyniku rozmywania otrzymuje się jedynie funkcje charakterystyczne dla wszystkich conceptów i ról, to taką interpretację nazywa się *dokładną*. Dla terminologii, asercji i aksjomatów warunki F1-F19 są równoważne warunkom standardowej interpretacji logiki opisowej DL.

Granulacja logiki wyszukiwania informacji w bazie wiedzy

Można rozszerzyć działanie systemu wyszukiwania informacji (IR) o szukanie wiarygodnych dla ekspertów podzbiorów $X \cup X \times X$, gdzie X jest pewnym zbiorem dostępnych adresów zasobów internetowych, odnoszących się do wybranej dziedziny wiedzy. Podzbiory te, dla danego zapytania o wiedzę, wskazują wiarygodne dla ekspertów adresy sieci Web reprezentujące tę wiedzę. Za pomocą tych zbiorów można wiarygodnie interpretować wyrażenia logiki IRL. Wyrażenia te zbudowane są z prostych (nie dających się rozłożyć) conceptów i ról.

W tym celu, podobnie jak w statystyce, używany jest *zakres ufności* V . Uważa się, że najważniejsze jest, by wszyscy eksperci – na podstawie zakresu ufności V – zaakceptowali zbiór stopni przynależności obiektu do zbioru rozmytego. Wykorzystuje się system

ekspertowy ustalający bazę wiedzy:

$$K = \langle Tez, Fuz, V, Ont \rangle,$$

gdzie:

- Tez – zbiór używanych prostych (atomowych) konceptów i ról tezaury,
- Ont – zbiór używanych prostych (atomowych) konceptów i ról ontologii, określonych zgodnie z postulatem P2,
- Fuz – zbiór możliwych do użycia interpretacji (rozmywania), określonych zgodnie z postulatami P1-P9 oraz warunkami F1-F29,
- V – funkcja, która dowolnemu konceptowi C lub roli R ze zbioru $Tez \cup Ont$ przyporządkowuje zakresy ufności rozmycia:

$$V(C) = [\alpha_C, 1], \quad V(R) = [\alpha_R, 1],$$

zaakceptowane przez wszystkich ekspertów.

W celu bardziej adekwatnego określenia zbioru Fuz , tak aby dla największej liczby ustalonych przez ekspertów wzorcowych adresów sieci Web spełnione były zakresy ufności, wyróżnia się dla algebry zbiorów:

$$F = \langle F, \&^F, \wedge^F, \vee^F, \neg^F, c^F, e^F, 0^F, 1^F, M, (\cdot)^d, F_0 \rangle$$

pewne podzbiory F , zwane *granulami algebry F* dla bazy K (krótko: *granulami*).

Granule są wartościami funkcji:

$$Gr : Tez \cup Ont \longrightarrow \mathcal{P}(F),$$

zwanej *granulacją* dla bazy wiedzy $K = \langle Tez, Fuz, V, Ont \rangle$, jeśli dla dowolnych konceptów C i ról R ze zbioru $Tez \cup Ont$ zachodzą wzory:

$$\text{Gr1. } \perp^{Gr} = \{0^F\}, \quad T^{Gr} = \{1^F\}$$

$$\text{Gr2. } C^{Gr} = \{\mu_C \in F : \exists I \in Fuz, \mu_C = C^I\}$$

$$\text{Gr3. } R^{Gr} = \{\mu_R \in F : \exists I \in Fuz, \mu_R = R^I\}$$

Do wymienionych granul należą zbiory rozmyte, których wartości tylko dla pewnych wzorcowych adresów sieci Web i ich par spełniają ustalone zakresy ufności.

4.3.5 Rozszerzenia strukturalne i granularne logiki IRL

System t-norm i algebra możliwych zbiorów danych Web

W pracy [P11] przedstawiono zastosowanie *systemu t-norm* w teorii dowodów Dempstera–Shafera [13] oraz wykazano, że logika IRL może być interpretowana w ramach *algebry możliwych zbiorów danych Web* (ang. *algebra of possible Web data sets*), co umożliwia opis i przetwarzanie niepewnej wiedzy w środowiskach rozproszonych.

Wprowadzono *system dowodów* (ang. *evidence system*)

$$ES = \langle U, D, A \rangle,$$

gdzie U jest skończonym zbiorem możliwych danych, D – zbiorem danych reprezentujących wiedzę, a $A = \{a_1, \dots, a_n\}$ jest zbiorem atrybutów $a : U \rightarrow D$.

Na tej podstawie zdefiniowano *atrybutową sieć wartościowania* (ang. *attribute valuation network*),

$$AVN = \langle V_{AVN}, V_{gen}, \bullet, \downarrow, 0, 1 \rangle,$$

gdzie V_{AVN} jest zbiorem wartościowań generowanych przez V_{gen} , $\bullet$ oznacza ich kombinację, a $\downarrow$ – marginalizację. Symbole 0 i 1 oznaczają odpowiednio puste i pełne zbiory generatorów.

Pokazano, że wyrażenia logiki IRL mogą być interpretowane w *algebrze wartościowania*:

$$LA = \langle V_{AVN}, \boxtimes, \boxplus, \rightarrow, \leftrightarrow, 0, 1 \rangle$$

oraz w *algebrze możliwych zbiorów danych Web*:

$$P = \langle P, \wedge^P, \vee^P, \neg^P, c^P, e^P, 0^P, 1^P, M, P_0 \rangle.$$

W pracy zdefiniowano operacje: koniunkcji $\boxtimes$, alternatywy $\boxplus$, negacji $\rightarrow$ i równości $\leftrightarrow$ dla algebry wartościowania, oraz wszystkie operacje algebry możliwych zbiorów danych Web. W szczególności: $\wedge^P$ i $\vee^P$ oznaczają przecięcie i sumę możliwych zbiorów danych, $\neg^P$ – ich dopełnienie, c^P określa stopień zawierania, e^P – stopień równości, M jest funkcją modyfikacji, zaś P_0 wyróżnioną rodziną możliwych zbiorów.

W artykule przedstawiono układ t-norm w teorii dowodów Dempstera–Shafera oraz struktury algebraiczne umożliwiające interpretację logiki IRL w modelu możliwych zbiorów danych Web. możliwych zbiorów danych Web.

Morfologia matematyczna i granule w logice IRL

W pracy [P12] opisano metody *morfologii matematycznej* oraz *obliczeń granularnych*, pokazując, że nawet przy niejasnych i niepewnych informacjach można otrzymać precyzyjne wyniki wyszukiwania w sieci Web. Pozytywny wynik zależy zarówno od właściwego doboru dopuszczalnych stopni rozmycia konceptów i ról, jak i od odpowiedniego określenia ich interpretacji w algebrze zbiorów rozmytych. Zaproponowane podejście łączy narzędzia morfologii matematycznej, rozmytej logiki deskrypcyjnej oraz obliczeń granularnych.

Praca rozwija wcześniejsze wyniki habilitantki dotyczące uzyskiwania dokładnych odpowiedzi mimo niepewności danych [7]. Wykazano tam, że operacja *wyostrzania* pozwala otrzymać wyniki mieszczące się w zakresie ufności ustalonym przez ekspertów. W [P12] rozszerzono te koncepcje o narzędzia morfologiczne i granularne, co umożliwiło bardziej formalne określenie interpretacji konceptów i ról w kontekście rozmytym.

W pracy [P12] zdefiniowano operacje dylatacji i erozji granul algebry F , oraz wprowadzono granulę $B(G)$, zwaną *elementem strukturalnym*:

$$B(G) = \{\mu_g : g \in G, y \in X \cup (X \times X), \\ \alpha \leq g(y) \Rightarrow \mu_g(y) = 0, \alpha > g(y) \Rightarrow \mu_g(y) = g(y)\} \cup \{0^F\}. \quad (4.1)$$

Element strukturalny wskazuje te adresy sieci Web, gdzie stopnie rozmycia należy zwiększyć za pomocą dualnych zbiorów rozmytych zbioru $B(G)$.

Nowo wprowadzone postulaty:

P10. $B(G) \subseteq F$.

P11. $A_\alpha = \{\mu_a : a \in A\} \subseteq F$, gdzie

$$\mu_a(y) = \begin{cases} a(y), & y \in Y_A(\alpha), \\ 0, & \text{w przeciwnym wypadku.} \end{cases}$$

Zbiór A_α jest A *obcięty* do zakresu ufności $V = [\alpha, 1]$ i również stanowi granulę.

P12. Jeśli A ma zakres ufności $V = [\alpha, 1]$, $a \in A$, $x \in X \cup (X \times X)$ oraz $\alpha > a(x)$, to:

$$\alpha \leq (a \&^F a^d)(x).$$

Powoduje to pojawienie się w $A \boxplus B$ rozmytych zbiorów $a \&^F a^d$ spełniających zakres ufności tam, gdzie sama granula A go nie spełniała.

System granul diagnostycznych

Badania zostały dalej rozwinięte w pracy [P10], gdzie wprowadzono *granulację w wyszukiwaniu informacji w sieci semantycznej* dla danych diagnostycznych. Najpierw zdefiniowano system granul [19, 23] w postaci:

$$GrS = \langle G, O, El, v, cl \rangle,$$

gdzie:

- G – zbiór granul uzyskanych ze skończonego zbioru granul elementarnych El przy zastosowaniu operacji ze zbioru O ,
- v – funkcja *zawierania się granul* (ang. *granules inclusion*),
- cl – funkcja *bliskości granul* (ang. *closeness of granules*).

Dla systemu granul zdefiniowano operacje erozji i dylatacji, a następnie przedstawiono *system granul diagnostycznych*. Dla tego systemu określono procedury wyznaczania tezaury i ontologii oraz wprowadzono *rozmyty stopień zaufania* (ang. *fuzzy confidence range*), który służy do ustalenia, czy wyszukane informacje wskazują na szukany obiekt.

W tym celu stosuje się *wskaźnik podobieństwa* (ang. *similarity indicator*) określany wzorem:

$$c(x, y) = \begin{cases} \frac{1 - |x - y|}{x}, & x > y, \\ \frac{1 - |x - y|}{y}, & x \leq y, \end{cases}$$

gdzie x, y oznaczają stopnie ważności wyszukiwania informacji o pierwszym i drugim obiekcie.

Zwykle, gdy stopień zaufania wynosi 0.9, oznacza to, że zgodnie z wiedzą ekspercką akceptuje się różnicę w podobieństwie dwóch obiektów i ważności ich podobieństwa do poziomu 10%.

Pokazano również, że w systemie granul można przeprowadzać rozmywanie sieci semantycznej zgodnie z warunkami F1-F3, F6-F7, F10-F12, F18, F20. Jeśli granulacja danych spełnia te warunki, to zachodzi *rozmywanie konceptu*. Natomiast jeśli w wyniku rozmywania otrzymuje się wyłącznie funkcje charakterystyczne będące funkcjami przynależności dla wszystkich konceptów i ról w sieci, to taka granulacja nazywana jest *dokładną*.

Przybliżona pragmatyczna logika opisowa (RPDL)

Praca [P5] wskazuje nowy kierunek, w którym do wyszukiwania wiedzy niepewnej, niejasnej lub niekompletnej, obok teorii zbiorów rozmytych, można zastosować również teorię

zbiorów przybliżonych (ang. *rough sets*) [17]. Wprowadzono pojęcie *przybliżonej pragmatycznej logiki opisowej* (ang. *Rough Pragmatic Description Logic – RPDL*), zdefiniowano 34 aksjomaty tej logiki oraz przedstawiono jej semantykę i interpretację rozszerzoną o zbiory przybliżone.

Dla systemu pojmowania określono *adekwatne zasady pojmowania* (ang. *adequate rules of conceiving*), opisujące relacje logiczne między aksjomatami. Jeśli agenci systemu reprezentacji wiedzy stosują te reguły, oznacza to, że właściwie pojmują interpretacje aksjomatów w strukturze zbiorów przybliżonych. Na tej podstawie zdefiniowano *system pojmowania* (ang. *system of conceiving*) dla sieci semantycznej:

$$\text{Con}(\text{SN}) = \langle N, C, R, N_0, C_0, R_0 \rangle,$$

gdzie N to zbiór stałych wystąpień konceptów, a C i R są zbiorami konceptów i ról wyprowadzonymi zgodnie z syntaktyką RPDL.

Pojmowanie w sieci semantycznej rozumiane jest jako określanie relacji między węzłami sieci poprzez koncepty i role. *Drogi pojmowania* (ang. *conceiving ways*) to uporządkowane ciągi:

$$(\alpha_1, \alpha_2, \dots, \alpha_j),$$

opisujące powiązania między wystąpieniami konceptów i ról z sieci SN .

W systemie pojmowania zdefiniowano także *zamknięcie obiektu pojmowania* oraz *minimalizację obiektu pojmowania*. Aby określić adekwatność i dokładność relacji pojmowania, opisano drogi pojmowania za pomocą obliczeń na multistrukturach.

Badania doprowadziły do opisu *aproksymacji obiektu pojmowania*, w tym: *bazy pojmowania* (def. 23, [P5]), *przybliżonego obiektu pojmowania* (def. 27, [P5]) oraz *relacji nierozróżnialności obiektu pojmowania* (def. 26, [P5]).

Zaproponowany aparat teoretyczny pokazuje, że znalezienie zbioru wszystkich dróg pojmowania w systemie RPDL — w warunkach wiedzy niejasnej — jest równoważne z odnalezieniem wiedzy o danym obiekcie.

System granul informacji jako aproksymacja rozmytego kontekstu

Przeprowadzone badania doprowadziły do określenia *systemu granul informacji* jako aproksymacji rozmytego kontekstu w sieciach semantycznych, co opisano w pracy [P1]. W celu jednolitej interpretacji wyrażeń języka atrybutów AL w różnych teoriach granul (zbiorów, prawdopodobieństwa, możliwych zbiorów danych, zbiorów zacienionych, zbiorów rozmytych oraz przybliżonych) przyjmuje się, że wyrażenia te interpretuje się w wybranym *systemie granul*, formalnie zdefiniowanym przez habilitantkę.

W artykule przedstawiono formalną definicję systemu granul informacji i przykład jego

konstrukcji w teorii kontekstowych zbiorów przybliżonych. Wiedza niejasna lub niekompletna jest tam opisywana przez *rozmyte relacje kontekstowe* (ang. *fuzzy context relations*).

System granul dla języka AL zdefiniowano jako:

$$G = \langle G, M_G, \cup_G, \cap_G, \setminus_G, (\cdot)'^G, \{\}_G, \in_G, \subseteq_G, =_G, 0_G, 1_G, G_{\text{inst}}, G_{\text{set}}, G_0 \rangle,$$

gdzie $G = G_{\text{inst}} \cup G_{\text{set}}$, M_G jest zbiorem funkcji $m_G : G \rightarrow G$, zaś pozostałe operacje określają uogólnione działania na granulach. Zbiór G_0 zawiera wyróżnione *granule singletonów instancji*.

Dla funkcji $\{\}_G : U_{\text{inst}} \rightarrow G_0$ zachodzi:

$$G_0 = \{x \in G : \exists z \in G_{\text{inst}} (x = \{z\}_G)\}.$$

Ponadto system G spełnia warunki G1–G8, obejmujące m.in. relacje zawierania i bliskości granul, konstrukcję granul jako sum singletonów oraz własności operacji $\cup_G$, $\cap_G$ i $\setminus_G$.

Wyrażenia języka GAL (ang. *generalized attributive language*) interpretuje się w formalnym języku GL opisującym system granul, z translacją:

$$I : GAL \rightarrow G \cup GL.$$

Za precyzyjne koncepty i role uznaje się te, które mają deskrypcje AL interpretowane w podsystemie G^+ spełniającym warunki G1–G8. Podsystem ten nazywa się *adekwatnym podsystemem* systemu G , a język GAL^+ ma interpretację w G^+ .

W systemie granul zdefiniowano także *rozmyty kontekst* (ang. *fuzzy context*) jako zbiór rozmyty określony na parach zbiorów instancji z U_{gen} . Stopień α w relacji kontekstowej określa błąd i niedokładność wiedzy. Tezaurus zapisany w sieci semantycznej SN opisano za pomocą *jednorodnej klasyfikacji hierarchicznej* (ang. *homogeneous hierarchical classification*), co umożliwiło zdefiniowanie *rozmytej przestrzeni kontekstowej* oraz aproksymacji $C_\alpha^-(X)$, $C_\alpha^+(X)$.

Zdefiniowano również *rozmytą granulę kontekstu*:

$$\langle [X]_\alpha, \alpha \rangle, \quad [X]_\alpha = \{Y \subseteq U_{\text{gen}} : C_\alpha^-(X) = C_\alpha^-(Y) \wedge C_\alpha^+(X) = C_\alpha^+(Y)\},$$

oraz teoriomnogościowe operacje na takich granulach.

W pracy [P1] określono także system precyzyjnych granul G_{precise} i funkcję homomorfizmu:

$$h : G_{\text{precise}} \rightarrow G^+,$$

która przypisuje elementom precyzyjnych granul ich reprezentanty w systemie G^+ . Homomorfizm ten spełnia warunki H1–H7 dla operacji zawierania, bliskości oraz $\cup_G$, $\cap_G$, $\setminus_G$ i $\prime_G$.

Wyniki pracy [P1] pokazują, że wyróżnione aksjomaty języka GAL i reguły pojmowania są spełnione w systemie G , co czyni go *silnie adekwatnym* dla tego języka. Ustalono także adekwatny podsystem G^+ oraz homomorfizm podsystemu G_{precise} względem G^+ .

Percepcja opisów w systemach residuum

Praca [P8] przedstawia *percepcję opisów* w systemach residuum, w których wiedza jest reprezentowana za pomocą *granul wiedzy* – rozmytych lub przybliżonych. Wykorzystano tu elementy *percepcyjnej teorii bliskości* w kontekście zbliżania wiedzy wyszukiwanej w sieciach Web do wiedzy adekwatnej reprezentowanej w teaurusie.

W pracy zdefiniowano *logiczny system residuum*

$$S_{\text{logic}} = \langle L, \bullet_s, \rightarrow_t, 0_L, 1_L \rangle.$$

Dla sieci semantycznej

$$SN = \langle U, AS, DS \rangle,$$

obiektom percepcji są instancje o wartościach w systemie residuum S_{logic} , czyli elementy zbioru U_{gen} , gdzie $L_0 \subseteq L$ jest zbiorem wartości instancji. Dane wartości mają interpretację jako *percepcje* lub *funkcje próbkujące* (ang. *probe functions*).

Percepcję opisuje funkcja

$$\varphi : U_{\text{gen}} \rightarrow L_0,$$

określająca właściwości obiektów pojmowania [20, 21]. Zakłada się, że każdy opis $\varphi \in DS$ odpowiada pewnej percepcji $\varphi : U_{\text{gen}} \rightarrow L_0$.

System percepcji (ang. *perceptual system*) definiuje się jako:

$$PS = \langle U_{\text{gen}}, F, S_{\text{logic}} \rangle,$$

gdzie F jest zbiorem percepcji $\varphi : U_{\text{gen}} \rightarrow L_0$, a elementy L_0 są *wartościami percepcji*.

Najważniejsze twierdzenia wynikające z pracy [P8] są następujące:

Twierdzenie 1. Każdy system percepcji

$$PS = \langle U_{\text{gen}}, F, S_{\text{logic}} \rangle$$

może zawierać bazę granul informacji:

$$G_{\text{base}} = \langle G, \{ \}_G, \cup_G, \subseteq_G, =_G, 0_G, 1_G, G_{\text{inst}}, G_{\text{set}}, G_0 \rangle.$$

Twierdzenie 2. W każdej bazie granul informacji można określić *system granul*:

$$G = \langle G, \cup_G, \cap_G, \setminus_G, ' _G, \{ \}_G, \in_G, \subseteq_G, =_G, 0_G, 1_G, G_{\text{inst}}, G_{\text{set}}, G_0 \rangle.$$

Własności systemu granul obejmują m.in.:

- Przynależność granulacji:

$$x \in_G y \Leftrightarrow \{x\}_G \subseteq_G y.$$

- Zależności zbiorów instancji i granul:

$$\{x \in G_{\text{inst}} : x \in_G 0_G\} = \emptyset, \quad \{x \in G_{\text{inst}} : \exists z \in G_0 (x \in_G z)\} = G_{\text{inst}}.$$

- Granula jako suma singletonów:

$$y = \cup_G \{ \{x\}_G : x \in_G y \}.$$

- Bliskość granul:

$$y'_G = \cup_G \{ z \in G_0 : \exists x \in G_{\text{inst}} (x \in_G z \wedge \neg(x \in_G y)) \}.$$

- Iloczyn, suma i różnica granul:

$$y \cap_G z = \cup_G \{ t \in G_0 : \exists x (x \in_G t \wedge x \in_G y \wedge x \in_G z) \},$$

$$y \cup_G z = \cup_G \{ t \in G_0 : \exists x (x \in_G t \wedge (x \in_G y \vee x \in_G z)) \},$$

$$y \setminus_G z = \cup_G \{ t \in G_0 : \exists x (x \in_G t \wedge x \in_G y \wedge \neg(x \in_G z)) \}.$$

W pracy [P8] sformułowano *teorię baz granul informacji* w sieciach semantycznych, której aksjomaty spełniają standardowe twierdzenia teorii zbiorów. Modelem tej teorii jest *system granul*. Pokazano również, że złożone interpretacje wyrażeń języka *AL* w systemach granul można uprościć, sprowadzając je do interpretacji w bazach granul indukowanych przez systemy percepcji. Ponieważ dowolne granule są sumami singletonów, obliczenia można znacząco uprościć, wykonując je na reprezentantach tych elementów.

Autodiagnoza systemu IRL

Praca [P6] opisuje, w jaki sposób aksjomaty i reguły pojmowania opisane w granularnym systemie wyszukiwania informacji w sieci semantycznej można przyrównać do *naturalnych procesów poznawczych zachodzących w mózgu człowieka*.

Większość algorytmów sztucznej inteligencji opiera się na zjawiskach naturalnych, które próbujemy naśladować za pomocą modeli matematycznych i algorytmów komputerowych. Podobnie w tym przypadku, agent wyszukujący informacje w sieci przetwarza skończone zestawy opisów wiedzy.

Przez analogię do procesów świadomości, wiedza może być rozumiana jako: (1) *twierdzenia* – co podmiot wie, (2) *pojęcia* – co agent rozumie, oraz (3) *aksjomaty* – co agent pojmuje, tworząc reguły.

System wyszukiwania informacji, w którym agent ma zdolność poznawania własnych procesów, nazywany jest *autodiagnozą wyszukiwania informacji w sieci semantycznej Web*. W pracy przedstawiono teoretyczny opis takiego systemu, jego autodiagnostykę oraz odniesienia do zagadnień neuropsychologii, związanych z procesami świadomości i percepcji.

System ten diagnozuje składnię i semantykę w określonym zakresie ufności, a agent autodiagnostyczny wykorzystuje reguły pojmowania jako *symulację procesów świadomości*.

Operacje analizy, redukcji, dedukcji i syntezy

Praca [P3] przedstawia definicje *operacji analizy, redukcji, dedukcji i syntezy*, wykonywanych w systemie granul sieci semantycznej podczas wyszukiwania informacji. Abstrakcyjne operacje indukowania granul wykorzystano do zaprojektowania systemów logicznych odpowiedzialnych za te cztery typy przetwarzania.

W procesie wyszukiwania wiedzy porównuje się informację szukaną z reprezentowaną przez tezaurus, co odpowiada *autodiagnozie systemu*. Dla nieostrych danych zdefiniowano systemy norm *triangularnych* (ang. *triangular norms*), pełniące funkcję systemów percepcji informacji.

W tych systemach interpretowane są wartości logiczne: *problematyczność, hipotetyczność, zasadność i rozstrzygalność*, co umożliwia określenie *granulacji wyszukiwanej informacji* zależnie od typu rozumowania. Opracowano również algorytm pozwalający ustalić, jak agent autodiagnozy interpretuje cztery wspomniane heurystyczne metody wyszukiwania.

Poniżej przedstawiono procedurę sprawdzania *zgodności wyrażen* *wyszukanych w sieci Web z wyrażeniami tezaury*, opartą na etapach: **analizy, redukcji, dedukcji i syntezy**.

Algorithm 1: Procedura zgodności wyrażeń ontologii z wyrażeniami tezaurusa

Data: Asercja X pobrana z sieci Web przez agenta autodiagnozy

Result: Ocena zgodności X z wyrażeniami tezaurusa

1 **ANALIZA** (interpretacja analityczna):

2 **if** X należy do tezaurusa (wartość logiczna 0_R) **then**

3 **goto** SYNTEZA; zakończ proces logicznego pojmowania X .

4 **end**

5 **else if** X jest problematyczny (wartość logiczna 1_A) **then**

6 **goto** REDUKCJA.

7 **end**

8 **REDUKCJA** (interpretacja redukcyjna):

9 **if** X jest redukowalny do tezaurusa (wartość logiczna 0_R) **then**

10 **goto** DEDUKCJA; sprawdź, czy X można wyprowadzić z tezaurusa.

11 **end**

12 **DEDUKCJA** (interpretacja dedukcyjna):

13 **if** X jest wyprowadzalny z tezaurusa (wartość logiczna 1_D) **then**

14 **goto** SYNTEZA; zakończ proces logicznego pojmowania X .

15 **end**

16 **else if** X nie jest wyprowadzalny (wartość logiczna 0_D), ale ma interpretację w sieci SN **then**

17 **goto** REDUKCJA. **if** X jest hipotetyczny **then**

18 **goto** SYNTEZA; rozszerz tezaurus o X ;

19 wartość logiczna syntezy 1_S ; zakończ proces logicznego pojmowania.

20 **end**

21 **else if** X jest wyprowadzalny **then**

22 X jest niehipotetyczny (wartość logiczna 0_R).

23 **end**

24 **end**

25 **else**

26 X jest hipotetyczny (wartość logiczna 1_R); **goto** SYNTEZA.

27 **end**

28 **SYNTEZA** (interpretacja syntetyczna):

29 **if** X jest uzasadnione lub nieproblematyczne **then**

30 X jest rozstrzygnięte (wartość logiczna 1_S); **goto** end.

31 **end**

32 **else if** X jest problematyczne i hipotetyczne **then**

33 X jest do rozstrzygnięcia (wartość logiczna 0_S); **goto** ANALIZA.

34 **end**

Teoria rozmytych zbiorów n-pitagorejskich (n-PFS)

Praca [P4] wprowadza teorię rozmytych zbiorów n-pitagorejskich (ang. *n-Pythagorean Fuzzy Sets*, skr. n-PFS), które w kolejnych badaniach zostały połączone z systemem wyszukiwania wiedzy w sieciach semantycznych opartych na granulach informacji (publikacje [P7], [P2]).

Teoria n-PFS stanowi uogólnienie:

- intuicyjnych zbiorów rozmytych Atanassova (*Intuitionistic Fuzzy Sets*, IFSs) [1],
- pitagorejskich zbiorów rozmytych Yagera (*Pythagorean Fuzzy Subsets*, PFSs) [28].

W klasycznych teoriach funkcje przynależności (μ) i nieprzynależności (ν) opisuje się w skali liniowej (1 : 1) lub kwadratowej. W n-PFS dopuszcza się jednak *dowolne skale potęgowe*, dzięki czemu stopnie przynależności i nieprzynależności mogą przyjmować postać:

$$0 \leq \mu^n + \nu^n \leq 1.$$

W pracy [P4] zdefiniowano aparat pojęciowy analogiczny do klasycznej teorii zbiorów rozmytych Zadeha, zachowując formalną strukturę algebry n-PFS. Pozwala to formułować *dowolne lokalne dedukcje* w przestrzeni n-PFS, rozszerzając modelowanie wiedzy niepewnej i częściowo rozmytej w sieciach semantycznych.

4.3.6 Zastosowania granulacji informacji w IRL

Opracowane metody granulacji informacji w IRL zostały wykorzystane w systemach diagnostycznych do wnioskowania o usterkach urządzeń technicznych. Znalazły również zastosowanie w projekcie CyberEva, gdzie służą do oceny cyberbezpieczeństwa urządzeń IoT oraz analizy synergii zagrożeń.

Granulacja informacji w diagnostyce technicznej

Publikacja [P7] skupia się na *granulacji informacji* w zastosowaniu do *diagnostyki technicznej*, gdzie pary *symptom-usterka* (ang. *symptom-fault*) są modelowane jako *intuicyjne zbiory rozmyte* (ang. *intuitionistic fuzzy sets*), a także z wykorzystaniem badań nad *n-pitagorejskimi zbiorami rozmytymi* (ang. *n-Pythagorean Fuzzy Sets*, n-PFS) opisanych w pracy [P4].

W pracy opracowano aparat pojęciowy do budowy algorytmów pozyskiwania wiedzy diagnostycznej o obiekcie technicznym, dla którego testy relacji *symptom-usterka* wykazują charakter binarny. Gdy wiedza o symptomie i usterce jest rozmyta, to przy odpowiednim skalowaniu można parę (symptom, usterka) rozważać jako *intuicyjny zbiór rozmyty*.

Granulacja jest w tym ujęciu interpretacją języka deskryptywnego diagnostyki urządzeń technicznych w pewnej algebrze n-PFS zdefiniowanej na rozmytych parach symptom-usterka.

System granul diagnozy technicznej. W przykładzie analizowano dane z diagnostyki *kotła gazowego*, opracowane na podstawie dysertacji doktorskiej A. Bryniarskiej [8]. Zastosowano aparat pojęciowy diagnostyki oraz jego interpretację w teorii n-PFS.

Dla każdej diagnozy (s_i, f_j) , odpowiadającej parze *symptom-usterka*, przyjmuje się odpowiadające im funkcje rozmyte:

$$\mu_i : X \rightarrow [0, 1], \quad \nu_j : X \rightarrow [0, 1].$$

Ponieważ obserwacje symptomów i usterek są rozłączne, ich wartości spełniają warunek:

$$\mu_i(o)^n + \nu_j(o)^n \leq 1.$$

Para (μ_i, ν_j) jest zatem *rozmytym zbiorem n-pitagorejskim* (n-PFS), zwanym *granulą diagnozy technicznej*. Dla relacji binarnej R każdej interpretacji diagnozy dowolnemu symptomowi przypisuje się jedną usterkę lub żadną, zatem $X = S$.

Liczbę n w skali potęgowej wyznacza się dla każdej pary (μ, ν) poprzez znalezienie najmniejszej liczby naturalnej n , dla której:

$$\mu^{n-1} + \nu^{n-1} > 1 \quad \text{oraz} \quad \mu^n + \nu^n \leq 1.$$

Wtedy $(\mu, \nu) \in \text{n-PFS}$, a spośród wszystkich wyznaczonych wartości wybiera się największą n .

Przykład 1 Dla symptomu s_1 i usterki f_1 :

$$\begin{aligned} n = 1 : \quad & \mu^1 + \nu^1 = 0.8 + 0.4 = 1.2 > 1, \\ n = 2 : \quad & \mu^2 + \nu^2 = 0.8^2 + 0.4^2 = 0.64 + 0.16 = 0.8 \leq 1. \end{aligned}$$

Stąd $n = 2$.

Przykład 2 Dla symptomu s_1 i usterki f_2 :

$$\begin{aligned} n = 1 : \quad & \mu^1 + \nu^1 = 0.8 + 0.8 = 1.6 > 1, \\ n = 2 : \quad & \mu^2 + \nu^2 = 0.8^2 + 0.8^2 = 1.28 > 1, \\ n = 3 : \quad & \mu^3 + \nu^3 = 0.8^3 + 0.8^3 = 1.024 > 1, \\ n = 4 : \quad & \mu^4 + \nu^4 = 0.8^4 + 0.8^4 = 0.8192 \leq 1. \end{aligned}$$

Stąd $n = 4$.

W tabeli 4.1 przedstawiono przykładowe symptomy, usterki, ich stopnie rozmycia zgodnie z teorią zbiorów rozmytych oraz wyznaczone wartości n dla zbiorów n-PFS.

Tabela 4.1: Powiązanie symptomów z usterekami, stopień ich rozmycia i ustalenie n-PFS.

Symptom	Usterka	n
(s1) Kocioł nie włącza się = 0,8	(f1) Brak zasilania (problem z bezpiecznikami, zwarcie) = 0,4	2
	(f2) Zadziałanie zabezpieczenia kotła = 0,8	4
	(f3) Uszkodzony licznik gazowy = 0,4	2
	(f4) Brak dopływu gazu (lub niskie ciśnienie gazu) – reduktor lub zawór = 0,4	2
	(f5) Brak wody w instalacji lub kotle (niskie ciśnienie) = 0,6	2
(s2) Szумы, trzaski, dziwne dźwięki z kotła = 0,5	(f6) Uszkodzona pompa cyrkulacyjna = 0,4	1
(s3) Kocioł sam się wyłącza = 0,8	(f7) Wadliwie wykonany komin = 0,8	4
	(f8) Zapowietrzone grzejniki = 0,4	2
(s4) Kocioł działa w trybie CO, ale nie w CWU = 0,5	(f9) Zapowietrzony kocioł = 0,9	3
(s5) Czuć zapach gazu = 0,9	(f10) Nieszczelność na kotle = 0,4	2
(s6) Gorąca obudowa = 0,7	(f11) Uszkodzony reduktor gazowy = 0,4	2
(s7) Słysać lub widzieć iskrę, ale palnik się nie zapala = 0,9	(f12) Uszkodzona elektronika (moduł elektroniczny) = 0,4	2
	(f13) Uszkodzona elektroda zapłonowa = 0,4	2
(s8) Zapala się palnik, po kilku sekundach gaśnie = 0,8	(f14) Uszkodzony lub zanieczyszczony zespół wodny = 0,6	3

Kontynuacja tabeli 1.

Symptom	Usterka	n
	(f15) Uszkodzona elektroda jonizacyjna = 0,8	4
(s9) Palnik gaśnie po dłuższym czasie = 0,6	(f16) Przegrzew kotła = 0,4	1
	(f17) Uszkodzony zespół gazowy = 0,4	1
(s10) Palnik działa, ale mały płomień = 0,7	(f18) Zatkane filtry lub dysze palnika = 0,4	2
(s11) Słaba wydajność kotła (CO) = 0,5	(f19) Uszkodzony czujnik temperatury wody grzewczej = 0,6	2
	(f20) Zatkany, zabrudzony filtr wody CO = 0,8	2
(s12) Brak ciepłej wody lub niska temperatura CWU = 0,4	(f21) Zatkany filtr wody CWU = 0,8	2
	(f22) Zabrudzona lub uszkodzona nagrzewnica = 0,4	1
	(f23) Zanieczyszczony wtórny wymiennik ciepła = 0,6	1

Największą liczbą n , dla której wszystkie $(\mu, \nu) \in n\text{-PFS}$, jest liczba $n = 4$. Oznacza to, że diagnoza techniczna *symptom-usterka* kotła gazowego może być najszerszej interpretowana za pomocą 4-PFS i dla takiej algebry zbiorów można określić granulację diagnozy technicznej.

Tabela 4.2 wskazuje na binarną relację symptom-usterka kotła gazowego. Przyjmuje się, że jeśli $r_{ij}(s_i, f_j) = 0$, to symptom s_i lub usterka f_j występują w stopniu 0 ich wykrycia podczas diagnozy: $(0, 1)$, $(0, 0)$, $(1, 0)$, tj. jeśli:

- nie występuje symptom, to nie występuje usterka,
- nie występuje ani symptom ani usterka,
- jeśli występuje symptom, to nie występuje usterka.

Gdy $r_{ij}(s_i, f_j) = 1$ i $s_i = \mu$, $f_j = \nu$, ponieważ $(0, 1)$, $(0, 0)$, $(1, 0)$, $(\mu, \nu) \in 4\text{-PFS}$, to

Tabela 4.2: Binarna relacja symptom–usterka kotła gazowego.

r_{ij}	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8	f_9	f_{10}	f_{11}	f_{12}	f_{13}	f_{14}	f_{15}	f_{16}	f_{17}	f_{18}	f_{19}	f_{20}	f_{21}	f_{22}	f_{23}
s_1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
s_2	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
s_3	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
s_4	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
s_5	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0
s_6	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0
s_7	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0
s_8	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0
s_9	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	0	0
s_{10}	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
s_{11}	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	0	0
s_{12}	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1

istnieje taki zbiór 4-PFS p , że:

$$p_{ij}(s_k) = \begin{cases} (\mu, \nu), & \text{dla } k = i, \\ (0, 1), & \text{dla } k \neq i. \end{cases}$$

Taki 4-PFS nazywać się będzie **elementarną granulą diagnozy technicznej**.

Diagnozę: „czuć zapach gazu w stopniu 0,9, więc występuje nieszczelność w kotle w stopniu 0,4” opisuje elementarna granula:

$$p^{5,10}(s_5) = (0,9,0,4), \quad p^{5,10}(s_k) = (0,1), \quad \text{dla } k \neq 5.$$

Można pokazać, że dowolna granula diagnozy technicznej w algebrze 4-PFS jest sumą pewnych elementarnych granul.

Niech opisy symptomów i opisy (s_i, f_j) diagnozy należą do języka L_{diag} diagnozy. **Opis diagnozy będzie nazywany konceptem elementarnym.**

Granulacja diagnozy technicznej w algebrze n -PFS. Granulacja diagnozy technicznej w algebrze n -PFS to

$$\text{Gr} = \langle 4\text{-PFS}, \text{Gr} \rangle,$$

gdzie $\text{Gr} : L_{\text{diag}} \rightarrow 4\text{-PFS}$. Do języka L_{diag} należą także koncepty, których znaczenia ustala granulacja Gr w następujący sposób (dla dowolnych $x \in S$ oraz dowolnych nazw konceptów C, D):

GR0. Granulacja konceptu elementarnego:

$$(s_i, f_j)^{\text{Gr}} = p_{ij}, \text{ gdy } r_{ij}(s_i, f_j) = 1, \text{ oraz } (s_i, f_j)^{\text{Gr}} = 0, \text{ gdy } r_{ij}(s_i, f_j) = 0.$$

GR1. $\{(x_1, y_1), \dots, (x_k, y_k)\}^{\text{Gr}} = (x_1, y_1)^{\text{Gr}} \boxplus \dots \boxplus (x_k, y_k)^{\text{Gr}}.$

$$\text{GR2. } T^{\text{Gr}}(x) = \langle 0, 1 \rangle.$$

$$\text{GR3. } \perp^{\text{Gr}}(x) = \langle 1, 0 \rangle.$$

$$\text{GR4. } (\lambda C)^{\text{Gr}}(x) = \lambda C^{\text{Gr}}(x), \text{ gdzie } \lambda \in (0, 1].$$

$$\text{GR5. } (C^\lambda)^{\text{Gr}}(x) = (C^{\text{Gr}}(x))^\lambda, \text{ gdzie } \lambda \in (0, 1].$$

$$\text{GR6. } (C \wedge D)^{\text{Gr}}(x) = (C^{\text{Gr}} \boxtimes D^{\text{Gr}})(x).$$

$$\text{GR7. } (C \vee D)^{\text{Gr}}(x) = (C^{\text{Gr}} \boxplus D^{\text{Gr}})(x).$$

$$\text{GR8. } (C \sqsubseteq D)^{\text{Gr}} = (C^{\text{Gr}} \leq_n D^{\text{Gr}}).$$

$$\text{GR9. } (C = D)^{\text{Gr}} = (C^{\text{Gr}} = D^{\text{Gr}}).$$

Koncepty λC oraz C^λ są konceptami powtórzonymi odpowiednio w alternatywie oraz w koniunkcji, przy równoległym lub liniowym powtarzaniu diagnozy konceptu C , co wynika z niepewności, niedokładności lub nieostrości diagnozy. Liczba $\lambda \in (0, 1]$ jest stopniem diagnozy, wymagającym jej powtórzenia. Gdy $\lambda = 1$, diagnoza jest pewna i nie wymaga powtórzenia. Jeśli można maksymalnie powtarzać diagnozę 10 razy, wówczas $\lambda = 1 - \frac{i}{10}$, gdzie i jest liczbą powtórzeń, tj.

$$\lambda = 1, 0.9, 0.8, 0.7, 0.6, 0.5, 0.4, 0.3, 0.2, 0.1, 0.$$

Zawieranie konceptów $(C \sqsubseteq D)$ należy interpretować intuicyjnie jako relację preferencji diagnozy D nad C .

Gdy granulacja Gr spełnia warunki GR1–GR9, nazywamy ją **rozmywaniem konceptów**. Jeżeli w wyniku rozmywania otrzymujemy jedynie funkcje charakterystyczne przestrzeni X (funkcje przynależności do zbioru rozmytego typu n -PFS dla wszystkich konceptów i ról), to taką granulację nazywamy **dokładną**.

W pracy [P7] po raz pierwszy zaprezentowano aplikację teorii n -PFS i zaproponowano język diagnozy L_{diag} posiadający interpretację w algebrze n -PFS. Pojęcie diagnozy ograniczono do pozyskiwania wiedzy o układzie symptom–usterka, zakładając, że relacja r wiążąca symptomy i usterki jest binarna, a usterki są jednoznacznie przypisane symptomom.

W artykule [P2] kontynuowane są prace opisane w [P4] dotyczące n -pitagorejskich zbiorów rozmytych (n -PFS) oraz zastosowania operacji analizy, redukcji, dedukcji i syntezy opisanych w [P3] do rozszerzenia systemu granul stosowanego w sieci semantycznej.

Na tej podstawie utworzono **diagnostyczny system granul** oraz **diagnostyczną bazę granul**. Bazę granul informacji określono jako:

$$G_{\text{base}} = \langle G, \{\}_G, \cup_G, \subseteq_G, =_G, 0_G, 1_G, G_{\text{inst}}, G_{\text{set}}, G_0 \rangle.$$

W tej bazie operacja $\cup_G$ jest uogólnieniem sumowania singletonów, a operacja $\{\}_G$ przekształca instancje ze zbioru G_{inst} jako elementarne granule w singletony granul. Ze zbioru G_{inst} , przy użyciu wymienionych operacji, otrzymuje się dowolne granule informacji.

Jeśli baza granul G_{base} wyznacza granule:

$$\begin{aligned} y'_G &=_{\text{df}} \cup_G \{z \in G_0 : \exists_{x \in G_{\text{inst}}} (x \in_G z \wedge \neg x \in_G y)\}, \\ y \cap_G z &=_{\text{df}} \cup_G \{t \in G_0 : \exists_{x \in G_{\text{inst}}} (x \in_G t \wedge x \in_G y \wedge x \in_G z)\}, \\ y \cup_G z &=_{\text{df}} \cup_G \{y, z\} = \cup_G \{t \in G_0 : \exists_{x \in G_{\text{inst}}} (x \in_G t \wedge (x \in_G y \vee x \in_G z))\}, \\ y \setminus_G z &=_{\text{df}} \cup_G \{t \in G_0 : \exists_{x \in G_{\text{inst}}} (x \in_G t \wedge x \in_G y \wedge \neg x \in_G z)\}, \end{aligned}$$

to system:

$$G = \langle G, \cup_G, \cap_G, \setminus_G, 'G, \{\}_G, \in_G, \subseteq_G, =_G, 0_G, 1_G, G_{\text{inst}}, G_{\text{set}}, G_0 \rangle$$

nazywany jest **systemem granul informacji indukowanym przez bazę G_{base}** .


Modelem takiego systemu jest standardowy system granul diagnozy opisany w pracy [P2]. Stanowi on jeden z możliwych modeli wykorzystujących granulację informacji. Prowadzone badania doprowadziły do wniosku, że granule informacji zdefiniowane są przez ogólne aksjomaty bazy granul informacji.

Aplikacja teorii granul diagnozy realizowana w ramach projektu dotyczącego diagnostyki niezawodności obiektów technicznych używanych w życiu codziennym pozwala na właściwy dobór funkcji skalowania, norm triangulanych oraz normy powtórzeń wykonywania diagnozy tych obiektów. Badania skupiają się na zastosowaniach diagnostycznych, jednak możliwości wykorzystania tej teorii są znacznie szersze, czego przykładem jest jej zastosowanie w projekcie z obszaru cyberbezpieczeństwa.

System oceny cyberbezpieczeństwa urządzeń IoT


Przeprowadzone badania teoretyczne zostały zaimplementowane w projekcie badawczo-rozwojowym **CyberEva**, pt. „*System oceniający i monitorujący poziom cyberbezpieczeństwa urządzeń IoE/IoT obywateli Rzeczypospolitej Polskiej*”. W ramach projektu powstała sieć semantyczna przechowująca dane dotyczące cyberzagrożeń występujących w badanych sieciach komputerowych oraz urządzeniach internetu rzeczy (ang. *Internet of Things, IoT*). Badania powiązane z tym systemem zostały opisane w publikacji [P13].

W projekcie opracowano system, który zbiera dane ze skanu sieci komputerowej zawierającej mobilne urządzenie skanujące. Podczas skanu ustala się podstawowe parametry związane z cyberbezpieczeństwem danego urządzenia. Następnie zanonimizowane dane są przesyłane do podsystemu analizy danych, w którym utworzono moduł wykorzystujący sieci semantyczne do dalszej analizy (Rys. 4.4).



Rysunek 4.4: Schemat działania systemu oceny cyberbezpieczeństwa CyberEva. Opracowanie własne.

W module sieci semantycznej wszystkie informacje są przechowywane z wykorzystaniem ontologii i asercji zapisanych w sieci semantycznej, której struktura została przygotowana zgodnie z autorskim schematem (Rys. 4.5). W sieci zamodelowane są również asercje, których implementacją są właściwości utworzonych obiektów.



Rysunek 4.5: Fragment ontologicznego modelu sieci semantycznej systemu CyberEva. Opracowanie własne.

Kolejnym etapem była **granulacja danych w sieci semantycznej**. Na podstawie przeprowadzonych badań ustalono, że najlepsze wyniki osiąga się przy granulacji przeprowadzonej na podstawie **producenta** oraz **typu urządzenia**. Dla każdej granuli wyznaczono *reprezentanta granuli*, którego wartości poszczególnych metryk obliczano jako średnie arytmetyczne metryk ze wszystkich urządzeń przynależnych do danej granuli.

Reprezentant granuli jest następnie wykorzystywany w systemie do uzupełniania brakujących metryk dla urządzeń z tej granuli. System prezentuje także wyliczony poziom cyberbezpieczeństwa oraz poziom wprowadzanego ryzyka przez urządzenia przynależne do danej granuli. *Poziom cyberbezpieczeństwa* określa, w jakim stopniu dane urządzenie jest zabezpieczone przed atakami w cyberprzestrzeni, natomiast *poziom wprowadzanego ryzyka* określa potencjalne zagrożenie, jakie takie urządzenie stwarza względem innych elementów tej samej sieci komputerowej. Ocena taka umożliwia analizę podatności grup urządzeń oraz identyfikację typów urządzeń stanowiących istotne zagrożenie dla bezpieczeństwa infrastruktury sieciowej.

Synergia cyberzagrożeń w module sieci semantycznej. Kolejnym zadaniem modułu sieci semantycznej w systemie **CyberEva** jest obliczenie *synergii cyberzagrożeń* występujących w określonym obszarze geograficznym. Ze względu na anonimizację danych, mapę Polski podzielono na tzw. *geopiksele*, a w systemie nie zapisuje się dokładnego położenia zeskanowanego urządzenia, lecz jedynie jego przynależność do konkretnego geopiksele. Dla każdej lokalizacji określa się, jakie urządzenia w niej występują oraz do których granul przynależą.

W pierwszym etapie badań poziom bezpieczeństwa obszaru (ang. *Location Total Security Score*, LTSS) wyznaczany jest jako średnia arytmetyczna poziomów bezpieczeństwa

urządzeń wykrytych w danej lokalizacji:

$$\text{LTSS} = \frac{TSS_1 + \dots + TSS_N}{N},$$


gdzie:

- LTSS – poziom bezpieczeństwa w danej lokalizacji,
- TSS_1 – poziom bezpieczeństwa urządzenia nr 1,
- N – liczba urządzeń wykrytych w danej lokalizacji.

Wyznaczony w ten sposób poziom bezpieczeństwa jest prezentowany na mapie z wyróżnionymi geopikselami. W kolejnym kroku, zgodnie z teorią zbiorów rozmytych [29], wprowadzono *funkcję przynależności*, która określa stopień rozmycia wiedzy w zależności od liczby urządzeń należących do danej granuli w lokalizacji. Niech $G \in \{1, \dots, x\}$ będzie zbiorem granuli w danej lokalizacji, wówczas funkcja przynależności ma postać:

$$\mu_G(M) = \frac{M}{100},$$

gdzie M jest liczbą urządzeń należących do granuli G w danym geopiksle. Funkcja ta określa stopień rozmycia granuli podczas obliczania poziomu bezpieczeństwa z uwzględnieniem efektu synergii (ang. *Location Total Security Synergy Score*, LTSSS).



Rysunek 4.6: Funkcja przynależności zbioru rozmytego wykorzystywana do obliczania synergii.

Zgodnie z założeniami, im większa liczba urządzeń należących do tej samej granuli w danej lokalizacji, tym wyraźniejszy efekt synergii pomiędzy tymi urządzeniami, a tym samym większy ich wpływ na ostateczny poziom bezpieczeństwa w geopiksle. Uwzględniono przy tym niepewność wiedzy: jeżeli liczba urządzeń w danej granuli jest mniejsza niż 100, to poziom bezpieczeństwa tej grupy uznaje się za rozmyty i niepewny, co odzwierciedla zastosowany zbiór rozmyty.

Poziom bezpieczeństwa w danej lokalizacji z uwzględnieniem synergii (ang. *Location Total Synergy Security Score*, LTSSS) obliczany jest według wzoru:

$$\text{LTSSS} = \frac{TSS_{G_1} \cdot M_1 \cdot \mu_{G_1}(M) + \dots + TSS_{G_x} \cdot M_x \cdot \mu_{G_x}(M)}{M_1^2 \cdot \mu_{G_1}(M) + \dots + M_x^2 \cdot \mu_{G_x}(M)},$$

gdzie:

- LTSSS – poziom bezpieczeństwa w danej lokalizacji z uwzględnieniem synergii,
- x – liczba granul,
- $M_1, \dots, M_x$ – liczba urządzeń należących do danej granuli w lokalizacji,
- $TSS_{G_1}, \dots, TSS_{G_x}$ – suma poziomów bezpieczeństwa urządzeń w danej granuli:

$$TSS_{G_i} = TSS_1 + \dots + TSS_M,$$

gdzie M jest liczbą urządzeń w granuli G_i ,

- N – całkowita liczba urządzeń w lokalizacji:

$$N = M_1 + M_2 + \dots + M_x,$$


- $\mu_{G_i}(M)$ – rozmyta funkcja przynależności granuli G_i określona wcześniej jako:

$$\mu_{G_i}(M) = \frac{M}{100}.$$

W przedstawionym modelu uwzględnia się zarówno liczbę urządzeń należących do tej samej granuli, jak i stopień rozmytości wiedzy w sytuacji, gdy liczba obserwowanych urządzeń jest niewielka (poniżej 100 w danej lokalizacji).

Duża liczba podobnych urządzeń w danej lokalizacji powoduje, że w przypadku ataku cybernetycznego ukierunkowanego na dany typ, wszystkie urządzenia z tej granuli stanowią potencjalne zagrożenie. W takim przypadku obserwuje się *synergię zagrożenia* – im więcej takich samych lub podobnych urządzeń, tym większe ryzyko. Z kolei *dywersyfikacja urządzeń* w lokalizacji przyczynia się do zwiększenia bezpieczeństwa w regionie.

Obliczony w ten sposób synergiczny poziom bezpieczeństwa jest wyświetlany na mapie z zaznaczonymi geopikselami. Schemat działania modułu przedstawiono na Rys. 7.



Rysunek 4.7: Schemat działania modułu sieci semantycznych systemu CyberEva. Opracowanie własne.

4.3.7 Autorskie osiągnięcia w zakresie niepewnego wyszukiwania wiedzy i granulacji

W toku prac badawczych opracowano autorską koncepcję logiki wyszukiwania informacji IRL (Information Retrieval Logic), stanowiącą formalny model pozyskiwania wiedzy w sieciach semantycznych w warunkach niepewności, niejednoznaczności i niepełności danych. Logika IRL umożliwia wnioskowanie na podstawie rozmytych conceptów i relacji, przy czym interpretacja wiedzy opiera się na stopniu semantycznego podobieństwa do wzorca wiedzy (tezauryusa). W ramach tej koncepcji sformułowano postulaty wyszukiwania informacji wykorzystujące m.in. regułę residuum, semantyczną komplementarność opisów oraz operacje oparte na t-normach i s-normach.

W wyniku badań zidentyfikowano zjawisko nazwane paradoksem rozmytej dokładności (ang. fuzzy disambiguation), polegające na możliwości uzyskiwania jednoznacznych i precyzyjnych wyników wyszukiwania pomimo nieostrych, niepewnych lub niepełnych danych wejściowych, o ile spełniony zostaje warunek zgodności semantycznej z tezauresem. Zjawisko to wskazuje, że niepewność danych nie musi prowadzić do obniżenia jakości wnioskowania, lecz może stanowić istotny czynnik umożliwiający trafną identyfikację wiedzy.

Rozwinięciem badań było opracowanie metody granulacji wiedzy w sieciach semantycznych, umożliwiającej tworzenie systemów granuli wiedzy opartych na własnościach

percepcyjnych, diagnostycznych i kontekstowych. Zaproponowana metoda łączy logikę IRL z fuzzy Description Logic oraz obliczeniami granularnymi, prowadząc do redukcji przestrzeni wyszukiwania oraz poprawy efektywności przetwarzania w systemach agentowych. W ramach badań opracowano również matematyczne modele granuli diagnostycznych i percepcyjnych, które zastosowano w obszarze technologii, cyberbezpieczeństwa IoT oraz systemów oceny preferencji konstrukcyjno-technologicznych.

Rezultaty badań zostały opublikowane w pracy stanowiącej cykl [P1-P13], obejmującej zagadnienia niepewnego wyszukiwania wiedzy oraz granulacji w sieciach semantycznych.

4.3.8 Podsumowanie

Zaprezentowany cykl publikacji naukowych składa się w logiczną całość, przedstawiając badania habilitantki w obszarze wyszukiwania oraz granulacji wiedzy w sieciach semantycznych, ze szczególnym uwzględnieniem wiedzy rozmytej. W ramach prowadzonych prac naukowo-badawczych opracowano zaawansowany aparat teoretyczny do opisu wiedzy w sieci semantycznej oraz metod jej granulacji w celu wyszukiwania i analizy.

Na podstawie zaproponowanych modeli i teorii opracowano algorytmy umożliwiające formalne odwzorowanie, interpretację i przetwarzanie wiedzy niepewnej, niepełnej oraz rozmytej, w tym modele rozmywania conceptów, granulacji diagnostycznej oraz percepcji wiedzy w systemach informatycznych. Opracowane rozwiązania zostały następnie zastosowane w praktyce, przyczyniając się do stworzenia systemu analizującego poziom cyberbezpieczeństwa urządzeń Internetu Rzeczy (IoT), w którym wykorzystano autorską sieć semantyczną oraz teorię granulacji wiedzy.

Otrzymane wyniki badań potwierdzają, że granulacja wiedzy w sieciach semantycznych stanowi efektywne narzędzie wspomagające pozyskiwanie, przetwarzanie i wnioskowanie o wiedzy nieostrej. Zastosowane mechanizmy mogą być szeroko wykorzystywane w diagnostyce technicznej, cyberbezpieczeństwie, a także w innych systemach, w których wymagane jest rozumowanie w oparciu o wiedzę nieprecyzyjną lub niepełną.

4.4. Wybrane publikacje spoza cyklu

Wybrane publikacje spoza cyklu obrazują inne obszary badawcze, w których habilitantka rozwija swoje zainteresowania naukowe. Wśród nich znajdują się między innymi zagadnienia związane z zastosowaniem sztucznej inteligencji [D7,D8], badania nad logiką rozmytą [D10], wykorzystanie ontologii [D12], w szczególności w projektowaniu modeli wiedzy dla systemów medycznych i diagnostycznych, oraz opracowanie języka uniwersalnego opisu

rzeczywistości i wiedzy GEDL [D5]. Zainteresowania habilitantki obejmują również badania dotyczące różnych modeli baz danych [D6].

Szczególnie istotne miejsce w dorobku habilitantki zajmują prace związane z zastosowaniami metod sztucznej inteligencji w biomedycynie i medycynie. Dużą część działalności naukowej stanowią badania w obszarze zastosowań medycznych, w tym wykorzystania algorytmów uczenia maszynowego oraz sieci neuronowych do analizy sygnałów EEG i ERP mózgu człowieka [D1,D9,D11]. W publikacji [D13] zaprezentowano innowacyjne podejście do adaptacji dziedzinowej w uczeniu maszynowym, ukierunkowane na poprawę skuteczności rozpoznawania negatywnych emocji w danych głosowych, stanowiące ważny kierunek badań nad rozwojem inteligentnych systemów wspomagających diagnostykę. Habilitantka realizuje również badania dotyczące diagnozowania i obrazowania medycznego [D2,D4], w tym z wykorzystaniem metod rzeczywistości wirtualnej [D3].

Wykaz publikacji spoza cyklu:

- [D1] Bryniarska A., Ramos J., Fernandes M., *Machine learning classification of event-related brain potentials during a visual Go/NoGo task*, Entropy 2024, 26, 220. (100 pkt)
- [D2] Kawala-Sterniuk A. et al., *Survey on the Most Current Image Processing Methods in Huntington's Disease Diagnostics and Progression Assessment*, Computer Science 24(4) 2023: 567–586. (40 pkt)
- [D3] Mikołajewski D. et al., *The Most Current Solutions using Virtual-Reality-Based Methods in Cardiac Surgery – A Survey*, Computer Science 25(1) 2024. (40 pkt)
- [D4] Kawala-Sterniuk A. et al., *Review of the Application of the Most Current Sophisticated Image Processing Methods for the Skin Cancer Diagnostics Purposes*, Archives of Dermatological Research (2024) 316:99. (70 pkt)
- [D5] Zatwarnicki K., Pokuta W., Bryniarska A., Zatwarnicka A., Metelski A., Piotrowska E., *General Environment Description Language*, Applied Sciences 2021, 11, 740. (100 pkt / 33 pkt – 0,3 slotu)
- [D6] Pokuta W., Bryniarska A., *The Primary Command Dictionary for the Flexible Database*, 38th IBIMA Conference, Seville 2021, pp. 5299–5308. (70 pkt / 49 pkt – 0,5 slotu)
- [D7] Bryniarska A., Lewiński A., Markiewicz A., Noworolski K., Oleksik R., Szczeńsiak P., *Algorytmy stosowane w uczeniu maszynowym*, Zeszyty Naukowe Politechniki Opolskiej, OW PO, Opole 2020.

- [D8] Bryniarska A., *Inteligentne wyszukiwanie wiedzy diagnostycznej wykorzystujące rozmytą logikę opisową na przykładzie wybranej klasy obiektów diagnozowanych*, w: *Innowacyjne rozwiązania w automatyce, robotyce i pomiarach*, red. J. Kacprzyk, s. 23–38, Warszawa 2015.
- [D9] Bryniarska A., *Identyfikacja aktywności językowej mózgu*, w: *Współczesne problemy inżynierii biomedycznej i neuronauk*, red. Sz. Paszkiel, J. Sadecki, s. 77–82, PO, Opole 2016.
- [D10] Walaszek-Babiszewska A., Bryniarska A., *Podstawy teorii systemów rozmytych z zadaniami*, OW PO, Opole 2018 – **monografia dydaktyczno-naukowa**.
- [D11] Schneider P., Mikołajewski D., Bryniarska A. et al., *Methods and tools for automatic and semi-automatic recognition of selected emotions using machine learning algorithms*, PAEE 2024, IEEE. (2024)
- [D12] Lupenko S., Tomaszewski M., Bryniarska A., Pavlyshyn A., Orobchuk O., *Conceptual Modeling of the Subject Area 'Aseptic Wound' for AI-Based Medical Systems*, ITTAP 2025.
- [D13] Bryniarska A., Schneider P., Mikołajewski D., Igras-Cybulska M., Kawala-Sterniuk A., *Data domain adaptation for machine learning for the purpose of the negative emotions in voice data recognition*, Computer Science, PP-RAI 2025.

4.5. Inne istotne osiągnięcia naukowe

Habilitationka reprezentuje dyscyplinę naukową jako ekspert w krajowych i międzynarodowych projektach badawczych. Ponadto jest recenzentem w wielu czasopismach naukowych indeksowanych w bazach Scopus i WoS oraz była jurorem w konkursie studenckim dotyczącym zastosowań sztucznej inteligencji.

4.5.1 Granty naukowe

1. **01.01.2024 – 31.01.2025** – Data Engineer w projekcie *Innowacyjna aplikacja do niwelowania negatywnych emocji pracowników i klientów centrów obsługi klienta, z wykorzystaniem technologii Voice AI i VR*, finansowanym przez PARP. Numer wniosku: FENG.01.01-IP.02-1729/23. Kierownik projektu: dr inż. Dariusz Mikołajewski.s
2. **01.10.2021 – 30.06.2024** – specjalista ds. sztucznej inteligencji i sieci semantycznych w projekcie *System oceniający i monitorujący poziom cyberbezpieczeństwa*

urządzeń IoE/IoT obywateli RP (CyberEva 2021–2024), realizowanym w IV konkursie CyberSecIdent. Kierownik projektu: dr inż. Adam Czubak.

3. **01.02.2023 – 30.09.2024** – wykonawca / współpracownik w projekcie *Brainsourcing for Affective Attention Estimation*, realizowanym w ramach programu Horizon 2020 FET (ERA-NET Cofund CHIST-ERA-20-BCI-001) oraz Narodowego Centrum Nauki w Polsce, umowa nr 2021/03/Y/ST7/00008. Kierownik projektu: dr hab. inż. Aleksandra Kawala-Sterniuk.
4. **01.11.2022 – 31.05.2023** – kierownik grantu Rektora Politechniki Opolskiej (konkurs GAMMA) pt. *Zastosowanie granulacji danych do detekcji śmiertelnej choroby brązowienia drzew palmowych za pomocą elektronicznego nosa*. W ramach projektu odbyto staż naukowy w USA (05–20.02.2023). Kierownik: dr inż. Anna Bryniarska.

4.5.2 Staże naukowe

1. **05–20.02.2023** – staż naukowy w *Nova Southeastern University*, Fort Lauderdale, Florida, USA. W ramach pobytu habilitantka współpracowała z prof. Jose A. Ramosem, PhD oraz prof. Mercedes Fernandez, PhD.

4.5.3 Działalność recenzencka

1. Recenzowanie manuskryptów naukowych w czasopismach indeksowanych w bazach WoS i Scopus: *Information Sciences* (Elsevier), *Mathematics* (MDPI), *International Journal of Fuzzy System Applications* (IGI Global), *Symmetry* (MDPI), *Axioms* (MDPI), *Electronics* (MDPI).
2. Recenzowanie prac dyplomowych: 55 prac inżynierskich oraz 28 prac magisterskich na kierunku Informatyka i Automatyka na Politechnice Opolskiej.

4.5.4 Działalność ekspercka

1. **2022 – obecnie** – Biegła Sądowa przy Sądzie Okręgowym w Opolu w zakresie informatyki, specjalność: analiza informatycznych baz danych, pozyskiwanie informacji z baz danych, analiza programów komputerowych i kodów źródłowych w sprawach o naruszenia praw autorskich.
2. **2011 – obecnie** – członkostwo w Polskim Towarzystwie Informatycznym (PTI).
3. **2019** – członek Komitetu Programowego konferencji *FedCSIS 2019*.

4. Juror w konkursie *Engineer 4 Science 2023*, organizowanym przez *4 Science Institute* pod patronatem IEEE i NCBR.
5. **2024** – szkolenie zawodowe pt. „*Analiza danych EEG z wykorzystaniem oprogramowania BESA*”, finansowane ze środków Krajowego Funduszu Szkoleniowego (KFS).

Wymienione osiągnięcia potwierdzają, że habilitantka jest uznanym ekspertem w swojej dziedzinie, regularnie zapraszany do współpracy w krajowych i międzynarodowych projektach badawczych, recenzjach naukowych oraz do wydawania opinii specjalistycznych jako Biegła Sądowa.

4.6. Dane naukometryczne

- **H-index:** Google Scholar – 6, Web of Science – 5, Scopus – 5.
- **Summary IF:** 15.6
(użyto wskaźników z roku publikacji, nawet jeśli obecnie IF jest wyższy).
- **Liczba cytowań:**
 - Google Scholar: 108
 - Scopus: 66
 - Web of Science: 54
- **Liczba cytowań bez autocytowań:**
 - Scopus: 41
 - Web of Science: 34

5. Informacja o wykazywaniu się istotną aktywnością naukową realizowaną w więcej niż jednej instytucji

Główny cykl badań był prowadzony na dwóch uczelniach: w latach 2014–2015 na Uniwersytecie Opolskim (publikacje [P11] oraz [D8]), a następnie był kontynuowany na Politechnice Opolskiej. Dodatkowo habilitantka wykazała się istotną aktywnością naukową w ramach współpracy z instytucjami krajowymi i zagranicznymi:

1. **Współpraca międzynarodowa (USA), 23.04.2022 – obecnie.** Współpraca z Prof. Jose A. Ramosem, PhD oraz Prof. Mercedes Fernandez, PhD z Nova Southeastern University w Fort Lauderdale (Florida, USA). Habilitantka odbyła staż naukowy w dniach 05–20.02.2023 r. w ramach projektu pt. *„Zastosowanie granulacji danych do detekcji śmiertelnej choroby brązowienia drzew palmowych za pomocą elektronicznego nosa”*. W efekcie współpracy powstała publikacja [D1] dotycząca klasyfikacji sygnałów ERP mózgu z wykorzystaniem metod uczenia maszynowego. Badania stanowią część projektu rozróżniania osób jedno- i wielojęzycznych.
2. **Współpraca międzyuczelniana w Polsce, 01.10.2021 – 30.06.2024.** Udział w projekcie *„System oceniający i monitorujący poziom cyberbezpieczeństwa urządzeń IoE/IoT obywateli RP”* (CyberEva), realizowanym przez Uniwersytet Opolski i Politechnikę Opolską. Habilitantka była zatrudniona jako specjalista ds. sztucznej inteligencji i sieci semantycznych. Rezultatem badań jest implementacja sieci semantycznej dla urządzeń IoT oraz opracowanie metody wyliczania synergii cyberzagrożeń [P13].

Habilitantka angażuje się zarówno w projekty bezpośrednio związane z logiką wyszukiwania i granulacją wiedzy, jak i w projekty interdyscyplinarne, w których zapewnia wsparcie w obszarze inteligentnego przetwarzania danych, sieci semantycznych oraz metod sztucznej inteligencji.

6. Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę

6.1. Osiągnięcia dydaktyczne

Habilitantka jako adiunkt na Politechnice Opolskiej prowadzi zajęcia dydaktyczne z 12 przedmiotów na kierunku Informatyka (studia I i II stopnia, stacjonarne i niestacjonarne) oraz 4 przedmiotów na kierunku *Computer Engineering* (studia I stopnia prowadzone w języku angielskim).

Przedmioty prowadzone w języku polskim. Podstawy sztucznej inteligencji, Narzędzia sztucznej inteligencji, Podstawy Baz Danych, Przedmiot wybieralny IX – Aplikacje bazodanowe, Inżynieria oprogramowania, Przedmiot wybieralny II – Testowanie aplikacji i systemów, Techniki internetowe, Modelowanie z wykorzystaniem systemów rozmytych i sieci neuronowych, Bazy Danych I, Informatyka I, Programowanie III, Projektowanie Baz Danych, Metody sztucznej inteligencji w automatyce.

Przedmioty prowadzone w języku angielskim. Basics of Artificial Intelligence, Artificial Intelligence Tools, Database Basics, Elective Course IX – Database Applications.

Habilitantka corocznie otrzymuje bardzo wysokie oceny od studentów w anonimowych ankietach dydaktycznych. Średnia ocena z semestru letniego roku akademickiego 2024/2025 wyniosła **8.5/10**.

Opracowanie treści programowych. Do osiągnięć dydaktycznych należy zaliczyć opracowanie autorskich treści programowych (wykładów, laboratoriów) dla 10 przedmiotów: *Podstawy sztucznej inteligencji, Narzędzia sztucznej inteligencji, Metody sztucznej inteligencji, Podstawy baz danych, Basics of Artificial Intelligence, Artificial Intelligence Tools, Database Basics, Modelowanie z wykorzystaniem systemów rozmytych i sieci neuronowych, Bazy Danych I, Fundamentals of Databases*.

Ponadto przygotowano karty przedmiotu i treści programowe dla pięciu dodatkowych przedmiotów: *Modelowanie rozmyte i neuronowe w zagadnieniach sterowania, Przedmiot*

wybieralny I – Modelowanie baz danych, Elective Course I – Database Modeling, Przedmiot wybieralny X – Projektowanie i budowa serwisów webowych, Przedmiot wybieralny XIII – Systemy dostępu do Internetu.

Prace dyplomowe. Habilitantka jest promotorem **55 prac dyplomowych inżynierskich** oraz **28 prac magisterskich** na kierunkach Informatyka i Automatyka na Politechnice Opolskiej. Ponadto pełniła funkcję recenzenta w **30 pracach inżynierskich** oraz **13 pracach magisterskich**, głównie na kierunku Informatyka.

Projekty dydaktyczne. Od 01.10.2024 do 30.09.2025 habilitantka realizowała projekt dydaktyczny pt.: „*Opracowanie przedmiotu Podstawy sztucznej inteligencji*” (projekt EDUCATUS III nr 164/24). W ramach projektu zorganizowano szkolenie pt.: „*Modele LLM w praktyce: użycie, douczanie i prompt engineering na przykładzie DeepSeek i GPT*”, przeprowadzone 21.05.2025 r. dla studentów i pracowników kierunku Informatyka Politechniki Opolskiej.

Od dnia 1 stycznia 2025 r. do chwili obecnej (z planowaną kontynuacją do roku 2029) habilitantka pełni funkcję członka zespołu realizującego międzynarodowy projekt **Kreati-vEU** (Knowledge & Creativity European University) na Politechnice Opolskiej. Projekt stanowi strategiczny sojusz 11 uniwersytetów europejskich, współfinansowany przez Unię Europejską w ramach inicjatywy europejskich uniwersytetów. W ramach prowadzonych działań habilitantka odpowiada za koordynację zadania WP5 oraz pełni funkcję koordynatora projektu na Wydziale Informatyki, uczestnicząc w rozwijaniu współpracy międzyuczelnianej, tworzeniu wspólnych programów edukacyjnych oraz inicjatyw związanych z innowacjami, kreatywnością i transferem wiedzy w skali europejskiej.

Aktywność międzynarodowa. Zajęcia prowadzone są w sposób nowoczesny, z wykorzystaniem platformy Moodle oraz dostępu zdalnego. Habilitantka odbyła trzy dydaktyczne wyjazdy w ramach programu Erasmus do uczelni:

- Polytechnic Institute of Coimbra, Institute of Engineering, Portugalia,
- Malta College of Arts, Science and Technology MCAST, Paola, Malta,
- School of Computer Engineering, Universidad de Las Palmas de Gran Canaria, Hiszpania.

Wsparcie studentów. W roku akademickim 2024/2025 udzielono indywidualnego wsparcia studentowi z niepełnosprawnością w ramach zajęć z *Programowania współbieżnego i rozproszonego*.

Dorobek dydaktyczny. W ramach doskonalenia warsztatu dydaktycznego współtworzono monografię naukowo-dydaktyczną:

A. Walaszek-Babiszewska, A. Bryniarska, *Podstawy teorii systemów rozmytych z zadaniami*, OW Politechniki Opolskiej, Opole 2018.

ISBN 978-83-66033-054-4.

Monografia była wykorzystywana w latach 2018–2023 m.in. w ramach przedmiotu *Narzędzia sztucznej inteligencji*.

6.2. Osiągnięcia organizacyjne

Do istotnych osiągnięć organizacyjnych należy opieka nad stroną internetową Katedry Systemów Sterowania i Systemów Decyzyjnych (<http://kssisd.po.opole.pl/>) w latach 2015–2016.

W latach 2016–2019 habilitantka pełniła funkcję koordynatora ds. programów *Sylabus*, odpowiedzialnego za zarządzanie Kartami Opisu Przedmiotu na Politechnice Opolskiej. W 2017 r. była członkiem wydziałowej Komisji ds. Przygotowania Oceny Parametrycznej oraz współtworzyła siatki studiów i efekty kształcenia dla kierunku Informatyka (studia I stopnia).

W latach 2017–2020 była członkiem wydziałowego zespołu ds. publikacji oraz komisji ds. programów kształcenia. Równocześnie w latach 2016–2020 była członkiem Rady Wydziału Elektrotechniki, Automatyki i Informatyki, natomiast w latach 2017–2020 pełniła funkcję **zastępcy dyrektora Instytutu Informatyki** Politechniki Opolskiej.

W latach 2019–2020 była członkiem zespołu przygotowującego raport samooceny kierunku Informatyka na potrzeby akredytacji PKA 2020. W tym samym czasie była **przewodniczącą Rady dydaktycznej kierunku Informatyka** oraz członkiem Rady Dziekańskiej WEAiI. Dodatkowo zajmowała się obsługą systemu *Ankieter* oraz była członkiem komisji skrutacyjnych Rady Dziekańskiej, Rady Dydaktycznej oraz Rady Naukowej dyscypliny Informatyka Techniczna i Telekomunikacja.

W latach 2020–2022 habilitantka odpowiadała za system *Didacticos* oraz zarządzanie obciążeniami dydaktycznymi na kierunku Informatyka. Od 02.06.2025 r. pełni funkcję **Pełnomocnika Rektora ds. Jakości Kształcenia** na Wydziale Informatyki, aktywnie uczestnicząc w tworzeniu planów i programów studiów.

6.3. Aktywność popularyzująca i upowszechniająca naukę

W dniach 17–19.09.2025 habilitantka była główną organizatorką pierwszego międzynarodowego hackathonu **KreativHack** na Politechnice Opolskiej w ramach projektu *Kreati-*

vEU. Wydarzenie odbyło się pod hasłem „AI for Cultural Heritage” i zgromadziło studentów z ośmiu uczelni partnerskich z Europy.

W dniu 24.10.2025 r. habilitantka była prelegentem podczas **Interdyscyplinarnego Areopagu (V)** na Wydziale Teologicznym Uniwersytetu Opolskiego, przedstawiając wykład pt.: „Kierunki rozwoju sztucznej inteligencji – gdzie kończy się inżynieria, a zaczyna inteligencja?”

Habilitantka aktywnie rozpowszechnia wiedzę techniczną i popularyzuje naukę wśród młodzieży i społeczności lokalnej poprzez warsztaty i liczne wystąpienia medialne, m.in.:

- Wywiad dla TVP3 Kurier Opolski, 25.07.2025: <https://opole.tvp.pl/88017902/>
- Wywiad dla Radia Opole, 04.08.2025: <https://radio.opole.pl/611,275>
- Wywiad dotyczący projektu CyberEva podczas konferencji CACS 2023:
https://www.linkedin.com/posts/netkoncept-com_cybereva-cyberbezpiecze%C5%84stwo-cacs2023-activity-7148267356803301377-BW0y/?originalSubdomain=pl
- Wywiady i relacje związane z hackathonem KreativHack (17–19.09.2025), m.in.:
 - <https://www.kreativeu.org/en/news/355/>
 - <https://po.edu.pl/pierwszy-miedzynarodowy-hackathon-rozpoczety-na-politechnice-opolskiej/>
 - <https://po.edu.pl/final-kreativhack-outech-na-politechnice-opolskiej/>
 - <https://www.youtube.com/watch?v=k3qqUEB3HlQ>
 - <https://www.youtube.com/watch?v=FqnkECoqe8Y>
 - <https://doxa.fm/aktualnosci/region/politechnika-opolska-gospodarzem-miedzynarodowego-hackathonu/>
 - <https://radio.opole.pl/100,915748,kreativhack-na-politechnice-opolskiej-studenci-z>
 - <https://share.google/GJTGFP9LMYXt51fEp>
 - <https://www.onet.pl/styl-zycia/ppo-aipap/w-opolu-studenci-z-calego-swiata-lacza-ai-z-kultura/0psef68,0666d3f1>
 - <https://naukawpolsce.pl/aktualnosci/news%2C109596%2COpole-studenci-z-kilku-panstw-lacza-sztuczna-inteligencje-z-dziedzictwem>
 - https://www.facebook.com/story.php?story_fbid=1198067579032028&id=100064863901001
 - <https://www.instagram.com/p/D0tHdo3kYNM/>

7. Inne informacje ważne z punktu widzenia wnioskodawcy

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

Habilitantka została odznaczona za swoją pracę na Politechnice Opolskiej:

1. 30.07.2021 – medal brązowy za długoletnią służbę odznaczona przez prezydenta RP Andrzeja Dudę, legitymacja nr 234-2021-100.
2. 20.12.2021 – Nagroda Rektora Politechniki Opolskiej – nagroda indywidualna za inne osiągnięcia.

(podpis wnioskodawcy)

Bibliografia

- [1] Krassimir T. Atanassov. *Intuitionistic Fuzzy Sets*. Springer, Berlin/Heidelberg, Germany, 1999.
- [2] Franz Baader, Diego Calvanese, Deborah L. McGuinness, Daniele Nardi, and Peter F. Patel-Schneider, editors. *The Description Logic Handbook: Theory, Implementation and Applications*. Cambridge University Press, Cambridge, 2003.
- [3] Tim Berners-Lee and Mark Fischetti. *Weaving the Web: The Original Design and Ultimate Destiny of the World Wide Web by Its Inventor*. Harper, San Francisco, 1999.
- [4] Tim Berners-Lee, James Hendler, and Ora Lassila. The semantic web. *Scientific American*, 284(5):34–43, 2001.
- [5] Fernando Bobillo and Umberto Straccia. Fuzzydl: An expressive fuzzy description logic reasoner. In *Proceedings of the IEEE World Congress on Computational Intelligence*, pages 923–930, Hong Kong, June 2008.
- [6] Anna Bryniarska. The algorithm of knowledge defuzzification in semantic network. In Andrzej Grzech, Leszek Borzemski, Jerzy Świątek, and Zofia Wilimowska, editors, *Information Systems Architecture and Technology, Networks Design and Analysis*, pages 23–32. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław, 2012.
- [7] Anna Bryniarska. The paradox of the fuzzy disambiguation in the information retrieval. *International Journal of Advanced Research in Artificial Intelligence (IJARAI)*, 2(9):55–58, September 2013.
- [8] Anna Bryniarska. *Inteligentne wyszukiwanie wiedzy diagnostycznej wykorzystujące rozmytą logikę opisową na przykładzie wybranej klasy obiektów diagnozowanych*. Dysertacja doktorska, Politechnika Opolska, Opole, 2014.
- [9] Michele Cerami, Francesc Esteva, and Lluís Godo Bou. Decidability of a description logic over infinite-valued product logic. In *Proceedings of the 12th International*

- Conference on the Principles of Knowledge Representation and Reasoning (KR 2010)*, pages 203–213, 2010.
- [10] Michael Daconta, Leo Obrst, and Kevin Smith. *The Semantic Web: A Guide to the Future of XML, Web Services, and Knowledge Management*. John Wiley & Sons, New York, USA, 2003.
 - [11] John Davies, Dieter Fensel, and Frank van Harmelen, editors. *Towards the Semantic Web: Ontology Driven Knowledge Management*. John Wiley & Sons, New York, 2003.
 - [12] Dieter Fensel. *Ontologies: A Silver Bullet for Knowledge Management and Electronic Commerce*. Springer, New York, USA, 2001.
 - [13] Jean Gordon and Edward H. Shortliffe. The dempster-shafer theory of evidence. In *Rule-Based Expert Systems: The MYCIN Experiments of the Stanford Heuristic Programming Project*, pages 3–4, 832–838. 1984.
 - [14] Nicola Guarino. Formal ontology and information systems. In *Proceedings of the First International Conference on Formal Ontologies in Information Systems (FOIS'98)*, pages 3–15, Trento, Italy, 1998.
 - [15] Petr Hájek. *Metamathematics of Fuzzy Logic*. Trends in Logic, Studia Logica Library, Volume 4. Kluwer Academic Publishers, Dordrecht, 1998.
 - [16] Mark A. Musen. The protégé project: A look back and a look forward. *AI Matters*, 1(4), June 2015.
 - [17] Zdzisław Pawlak. Rough sets. *International Journal of Computer and Information Sciences*, 11(5):341–356, 1982.
 - [18] Adam Pedrycz, Kaoru Hirota, Witold Pedrycz, and Fangyan Dong. Granular representation and granular computing with fuzzy sets. *Fuzzy Sets and Systems*, 203:17–32, 2012.
 - [19] Witold Pedrycz. Allocation of information granularity in optimization and decision making models: Towards building the foundations of granular computing. In *Granular Computing: Analysis and Design of Intelligent Systems*, pages 137–145. Springer, 2014.
 - [20] James F. Peters, Andrzej Skowron, and Jarosław Stepaniuk. Nearness of objects: Extension of approximation space model. *Fundamenta Informaticae*, 79(3-4):497–512, 2007.

- [21] James F. Peters and Piotr Wasilewski. Foundations of near sets. *Information Sciences*, 179(1):3091–3109, 2009.
- [22] Nikos Simou, Theofilos Mailis, Giorgos Stoilos, and Stamatis Stamou. Optimization techniques for fuzzy description logics. In *Proceedings of the 23rd International Workshop on Description Logics (DL2010)*, volume 573 of *CEUR Workshop Proceedings*, pages 244–254, Waterloo, Canada, 2010.
- [23] Andrzej Skowron, Roman Swiniarski, and Piotr Synak. Approximation spaces and information granulation. In James F. Peters and Andrzej Skowron, editors, *Transactions on Rough Sets III*, volume 3400 of *Lecture Notes in Computer Science*, pages 175–189. Springer-Verlag, Berlin Heidelberg, 2005.
- [24] Umberto Straccia. A fuzzy description logic. In *Proceedings of the 15th National Conference on Artificial Intelligence (AAAI-98)*, pages 594–599, Madison, USA, 1998.
- [25] Umberto Straccia. Reasoning with fuzzy description logics. *Journal of Artificial Intelligence Research*, 14:137–166, 2001.
- [26] Umberto Straccia. A fuzzy description logic for the semantic web. In N. Zhong, J. Liu, and Y. Yao, editors, *Capturing Intelligence*, volume 1, pages 73–90. Elsevier, 2006.
- [27] Rudi Studer, Richard Benjamins, and Dieter Fensel. Knowledge engineering: Principles and methods. *IEEE Transactions on Data and Knowledge Engineering*, 25(1–2):161–197, 1998.
- [28] Ronald R. Yager. Pythagorean fuzzy subsets. In *Proceedings of the 2013 Joint IFSA World Congress and NAFIPS Annual Meeting (IFSA/NAFIPS)*, pages 57–61, Edmonton, AB, Canada, 2013.
- [29] Lotfi A. Zadeh. Fuzzy sets. *Information and Control*, 8(3):338–353, 1965.