

Rekrutacja do Szkoły Doktorskiej w Uniwersytecie Śląskim w Katowicach na rok akademicki 2026/2027

Tematy w dyscyplinie informatyka

Admission to the Doctoral School at the University of Silesia in Katowice for academic year 2026/2027

Topics in computer and information sciences

Spis treści	Contents
1. Ewolucyjne generowanie dzieł sztuki (generatywna sztuczna inteligencja) – prof. dr hab. Urszula Boryczka	1. Evolutionary generation of artworks (generative artificial intelligence) – prof. dr hab. Urszula Boryczka
2. Metoda redukcji transmisji danych w systemach Internetu Rzeczy z wykorzystaniem rozproszonych modeli uczenia maszynowego – dr hab. inż. Bartłomiej Płaczek, prof. UŚ	2. A Method for Reducing Data Transmission in Internet of Things Systems Using Distributed Machine Learning Models – dr hab. inż. Bartłomiej Płaczek, prof. UŚ
3. Odporność modeli uczenia maszynowego na ataki adversarialne – dr hab. Agnieszka Nowak-Brzezińska, prof. UŚ	3. Robustness of machine learning models to adversarial attacks – dr hab. Agnieszka Nowak-Brzezińska, prof. UŚ
4. Predyktoryjne algorytmy redukcji próbkowania i transmisji danych w mobilnych systemach Internetu Rzeczy – dr hab. inż. Bartłomiej Płaczek, prof. UŚ	4. Predictive Algorithms for Sampling and Data Transmission Reduction in Mobile Internet of Things Systems – dr hab. inż. Bartłomiej Płaczek, prof. UŚ
5. Uczenie maszynowe w predykcji nasłonecznienia i produkcji energii fotowoltaicznej z wykorzystaniem sieci lokalnych klasyfikatorów – dr hab. Małgorzata Przybyła-Kasperek, prof. UŚ	5. Machine learning for solar irradiance prediction and photovoltaic energy production using local classifier networks – dr hab. Małgorzata Przybyła-Kasperek, prof. UŚ
6. Wyjaśnialna analiza zmian w systemach uczących się na danych strumieniowych – dr hab. inż. Rafał Doroz, Prof. UŚ	6. Explainable Analysis of Changes in Machine Learning Systems on Data Streams – dr hab. inż. Rafał Doroz, Prof. UŚ

Informatyka temat nr 1	Computer and information sciences topic No. 1
Ewolucyjne generowanie dzieł sztuki (generatywna sztuczna inteligencja)	Evolutionary generation of artworks (generative artificial intelligence)
PhD supervisor: prof. dr hab. Urszula Boryczka	
Krótką charakterystyką założeń i celów badawczych Być może najbardziej interesująca jest obecnie możliwość ponownego badania i eksploracji ewolucyjnego podejścia do projektowania, głównie w zastosowaniu sztuki generowanej komputerowo.	Brief description of research assumptions and goals Perhaps most interesting at present is the opportunity to re-examine and explore the evolutionary approach to design, mainly in the application of computer-generated art. Early



<p>Wczesne wysiłki w dziedzinie sztuki ewolucyjnej obejmują pionierską pracę Simsa. Ta praca była wynikiem podążania za osiągnięciami podejścia komputerowego w dziedzinie rzeźby, obrazów matematycznych i animacji. Interesującym aspektem większości tych środowisk projektowych jest to, że są to środowiska interaktywne i obejmują ocenę użytkownika w celu rozróżnienia różnych efektów otrzymanych wyników w zależności od proponowanych założeń projektowych. Znaczny wysiłek został włożony w rozwój pewnych elementów zawartych w rozwiązaniach ewolucyjnych, a obejmujących reprezentację rozwiązań i ich kodowania a także stosowania konkretnych operatorów genetycznych. Praktycznie we wszystkich przypadkach dla każdej populacji zostało wygenerowanych wiele indywiduów (rozwiązań) i w każdej populacji poddawane one były modyfikacjom genetycznym a następnie ocenie estetycznej. W dziedzinie sztucznej inteligencji i sieci neuronowych, wykorzystujących uczenie głębokie postęp został poczyniony w ostatnim czasie i zaowocował GAN, czyli Generative Adversarial Networks (Generatywne Sieci Adwersarialne). To jedna z najbardziej fascynujących i innowacyjnych technologii w dziedzinie uczenia maszynowego. Być może ten nurt jest najlepiej reprezentowany przez prace Elgammala i jego zespół z Rutgers University. Interesująca jest integracja tych dwu podejść do generowania obrazów.</p>	<p>efforts in the field of evolutionary art include the pioneering work of Sims. This work was the result of following the achievements of the computational approach in the fields of sculpture, mathematical images and animation. An interesting aspect of most of these design environments is that they are interactive and involve user evaluation to distinguish between different effects of the results obtained depending on the proposed design assumptions. Considerable effort has been put into the development of certain elements contained in evolutionary solutions, including the representation of solutions and their coding, as well as the use of specific genetic operators. In virtually all cases, multiple individuals (solutions) were generated for each population, and in each population they underwent genetic modification and then aesthetic evaluation. In the field of artificial intelligence and neural networks using deep learning, progress has been made recently, resulting in GAN, or Generative Adversarial Networks. This is one of the most fascinating and innovative technologies in the field of machine learning. This trend is probably best represented by the work of Elgammal and his team at Rutgers University. The integration of these two approaches to image generation is interesting.</p>
<p>Planowany wkład w rozwój dyscypliny Rozwój generatywnej sztucznej inteligencji i jej wyjaśnialności poprzez połączenie generowania dzieł sztuki z analizą i oceną estetyczną stanowi asumpt do tego, jak w przyszłości będziemy rozumieli i doceniali dalsze kierunki badań sztucznej inteligencji i nie traktowali tych narzędzi AI jako "czarnej skrzynki". Integracja wielodyscyplinowa tych badań stanowi podstawy etycznej i wiarygodnej oceny rozwoju tej nowej gałęzi sztucznej inteligencji.</p>	<p>Planned contribution to the development of the discipline The development of generative artificial intelligence and its explainability through the combination of art generation with analysis and aesthetic evaluation provides a starting point for how we will understand and appreciate future directions in artificial intelligence research and not treat these AI tools as a "black box". The multidisciplinary integration of this research provides the basis for an ethical and credible assessment of the development of this new branch of artificial intelligence.</p>
<p>Opis wymagań – wiedza, umiejętności i kompetencje społeczne kandydata</p>	<p>Description of requirements – knowledge, skills and social competences of the candidate</p>





Biegła znajomość narzędzi grafiki komputerowej, metaheurystyk i AI, wiedza z zakresu programowania i mile widziana znajomość historii sztuki (na poziomie szkoły średniej lub wyższej).	Proficiency in computer graphics tools, metaheuristics and AI, knowledge of programming, and knowledge of art history (at secondary school or higher level) is welcome.
---	---

Informatyka temat nr 2	Computer and information sciences topic No. 2
Metoda redukcji transmisji danych w systemach Internetu Rzeczy z wykorzystaniem rozproszonych modeli uczenia maszynowego	A Method for Reducing Data Transmission in Internet of Things Systems Using Distributed Machine Learning Models

PhD supervisor: dr hab. inż. Bartłomiej Płaczek, prof. UŚ https://scholar.google.com/citations?user=8z-IMoYAAAAJ	
---	--

<p>Krótką charakterystyką założeń i celów badawczych</p> <p>Projekt badawczy będzie dotyczył jednego z kluczowych problemów współczesnych systemów Internetu Rzeczy, jakim jest nadmierna i energochłonna transmisja danych z urządzeń końcowych o ograniczonych zasobach obliczeniowych i energetycznych. W klasycznych architekturach IoT znaczna część danych generowanych przez sensory jest przesyłana do węzłów nadrzędnych lub do chmury niezależnie od ich rzeczywistej użyteczności dla procesów analitycznych i decyzyjnych. Prowadzi to do szybkiego zużycia energii, ograniczenia skalowalności systemów oraz wzrostu opóźnień komunikacyjnych. Proponowany projekt badawczy ma na celu odejście od tego paradygmatu poprzez wprowadzenie mechanizmów inteligentnej, selektywnej transmisji danych sterowanej lokalnymi decyzjami podejmowanymi w węzłach Internetu Rzeczy.</p> <p>Głównym celem badań będzie opracowanie metody redukcji transmisji danych w systemach IoT, w której węzły sensorowe wykorzystują osadzone modele uczenia maszynowego do oceny zasadności przesyłania aktualnie pozyskiwanych informacji. Decyzje te będą podejmowane lokalnie, na podstawie bieżących danych oraz wcześniej wytrenowanych modeli, i będą miały na celu minimalizację liczby transmisji przy jednoczesnym</p>	<p>Brief description of research assumptions and goals</p> <p>The proposed research project will address one of the key challenges of contemporary Internet of Things (IoT) systems, namely excessive and energy-intensive data transmission from end devices with limited computational and energy resources. In classical IoT architectures, a significant portion of the data generated by sensors is transmitted to higher-level nodes or to the cloud regardless of its actual usefulness for analytical and decision-making processes. This leads to rapid energy depletion, reduced system scalability, and increased communication latency. The proposed research project aims to depart from this paradigm by introducing mechanisms for intelligent, selective data transmission controlled by local decisions made at IoT nodes.</p> <p>The main objective of the research will be to develop a method for reducing data transmission in IoT systems in which sensor nodes use embedded machine learning models to assess the relevance of currently acquired information for transmission. These decisions will be made locally, based on current data and previously trained models, and will aim to minimize the number of transmissions while preserving the correctness of system operation at the application level. Unlike classical data reduction methods such as aggregation, compression, or signal prediction, the</p>
---	--





zachowaniu poprawności działania systemu na poziomie aplikacyjnym. W odróżnieniu od klasycznych metod redukcji danych, takich jak agregacja, kompresja czy predykcja sygnałów, proponowane podejście koncentruje się na zachowaniu jakości informacji istotnej dla procesu decyzyjnego, a nie na rekonstrukcji pełnych strumieni danych pomiarowych.

Istotnym elementem badań będzie formalizacja problemu selektywnej transmisji danych jako zagadnienia optymalizacyjnego, w którym minimalizowana jest liczba przesyłanych komunikatów przy zachowaniu wymaganej jakości wyników generowanych przez system IoT. W ramach pracy analizowane będą zależności pomiędzy kompletnością danych a jakością decyzji podejmowanych w warstwie nadrzędnej, a także wpływ dynamicznie zmieniającej się dostępności danych na stabilność i niezawodność systemu. Pozwoli to na zdefiniowanie kryteriów użyteczności danych, które mogą być stosowane w różnych klasach aplikacji Internetu Rzeczy, niezależnie od ich konkretnej dziedziny zastosowań.

W ramach projektu będą budowane i analizowane rozproszone modele decyzyjne, możliwe do implementacji w węzłach IoT o ograniczonych zasobach obliczeniowych i energetycznych. Badania obejmą ocenę różnych klas modeli uczenia maszynowego pod kątem ich skuteczności decyzyjnej, złożoności obliczeniowej oraz wpływu na zużycie energii. Szczególna uwaga zostanie poświęcona kompromisowi pomiędzy lokalnym kosztem obliczeń a globalnymi oszczędnościami wynikającymi z ograniczenia liczby transmisji. Analizowany będzie również wpływ lokalnych decyzji poszczególnych węzłów na zachowanie całego systemu IoT. Opracowana zostanie architektura systemowa, odporna na niekompletność danych, będącą naturalną konsekwencją selektywnej transmisji. Pozwoli to na tworzenie systemów IoT, które tolerują brak danych i potrafią adaptacyjnie wykorzystywać dostępne informacje.

Opracowana metoda zostanie poddana walidacji eksperymentalnej w wybranych realistycznych scenariuszach Internetu Rzeczy, z wykorzystaniem prototypowych systemów sprzętowych lub

proposed approach focuses on preserving the quality of information that is relevant to the decision-making process rather than on reconstructing complete measurement data streams.

An important part of the research will be the formalization of the selective data transmission problem as an optimization task in which the number of transmitted messages is minimized while maintaining the required quality of results generated by the IoT system. The study will analyze the relationships between data completeness and the quality of decisions made at the higher system layers, as well as the impact of dynamically changing data availability on system stability and reliability. This will enable the definition of data utility criteria that can be applied across different classes of IoT applications, regardless of their specific domains.

Within the project, distributed decision models suitable for implementation on IoT nodes with limited computational and energy resources will be developed and analyzed. The research will include an evaluation of different classes of machine learning models with respect to their decision-making effectiveness, computational complexity, and impact on energy consumption. Particular attention will be paid to the trade-off between local computational costs and global savings resulting from a reduced number of transmissions. The impact of local decisions made by individual nodes on the behavior of the entire IoT system will also be analyzed. A system architecture resilient to data incompleteness—an inherent consequence of selective transmission—will be developed. This will enable the design of IoT systems that tolerate missing data and can adaptively exploit available information.

The developed method will be experimentally validated in selected realistic IoT scenarios using prototype hardware systems or simulation environments. Validation may be carried out in IoT systems performing event and context recognition related to human activity and navigation, where continuous interpretation of sensory data is essential. Example scenarios include indoor localization and navigation systems based on





<p>środowisk symulacyjnych. Walidacja może zostać przeprowadzona w systemach IoT realizujących rozpoznawanie zdarzeń i kontekstów związanych z aktywnością człowieka oraz nawigacją, w których istotna jest ciągła interpretacja danych sensorycznych. Przykładowe scenariusze obejmują systemy lokalizacji i nawigacji wewnątrzbudynkowej bazujące na sieciach czujników i urządzeniach nasobnych, rozpoznawanie ruchu i interakcji użytkownika z otoczeniem w inteligentnych budynkach, systemy wspomaganie mobilności osób starszych lub z niepełnosprawnościami, a także systemy bezpieczeństwa reagujące na nietypowe zachowania, takie jak upadki, nagłe zatrzymania czy dezorientacja przestrzenna.</p>	<p>sensor networks and wearable devices, recognition of user movement and interaction with the environment in smart buildings, mobility assistance systems for elderly or disabled individuals, and safety systems responding to atypical behaviors such as falls, sudden stops, or spatial disorientation.</p>
<p>Planowany wkład w rozwój dyscypliny</p> <p>Planowany projekt badawczy wnieśli wkład w rozwój dyscypliny Informatyka, poprzez rozwinięcie formalnych modeli oraz algorytmów przetwarzania i selekcji danych w rozproszonych systemach obliczeniowych. Centralnym elementem badań będzie analiza problemu selektywnej transmisji danych w systemach Internetu Rzeczy jako problemu decyzyjnego i optymalizacyjnego, w którym kluczową rolę odgrywają algorytmy podejmowania decyzji oparte na modelach uczenia maszynowego działających w warunkach niepełnej informacji.</p> <p>Efektom prac będzie sformalizowanie relacji pomiędzy jakością informacji wejściowej, niekompletnej i selektywnie dostępnej, a jakością wyników algorytmów decyzyjnych działających w warstwie nadrzędnej systemu IoT. W ramach pracy zostaną zaproponowane modele matematyczne opisujące użyteczność danych oraz kryteria decyzyjne, na podstawie których algorytmy lokalne podejmują decyzje o ich przekazywaniu. Modele te pozwolą na analizę własności proponowanych algorytmów, takich jak zbieżność, stabilność decyzji oraz odporność na brak danych.</p> <p>Projekt przyczyni się również do rozwoju wiedzy w obszarze projektowania algorytmów uczenia maszynowego działających w środowiskach rozproszonych i posiadających ograniczone zasoby. Analizowane będą klasy modeli decyzyjnych pod kątem ich złożoności obliczeniowej, pamięciowej</p>	<p>Planned contribution to the development of the discipline</p> <p>The planned research project will contribute to the development of the discipline of computer science by advancing formal models and algorithms for data processing and selection in distributed computing systems. A central element of the research will be the analysis of selective data transmission in IoT systems as a decision-making and optimization problem, in which a key role is played by machine learning-based decision algorithms operating under conditions of incomplete information.</p> <p>The outcome of the research will be the formalization of the relationship between the quality of input information—being incomplete and selectively available—and the quality of the results produced by decision algorithms operating at the higher layers of an IoT system. The work will propose mathematical models describing data utility and decision criteria on the basis of which local algorithms decide whether to transmit data. These models will enable analysis of the properties of the proposed algorithms, such as convergence, decision stability, and robustness to missing data. The project will also contribute to the advancement of knowledge in the design of machine learning algorithms operating in distributed and resource-constrained environments. Classes of decision models will be analyzed in terms of computational and memory</p>





oraz kosztu aktualizacji modelu. Wkład pracy polegać będzie na określeniu kompromisów pomiędzy lokalnym kosztem obliczeń, zużyciem energii i globalną jakością realizacji zadań przez system IoT.

Projekt wniesie również wkład do metod oceny algorytmów selektywnego pozyskiwania danych w Internecie Rzeczy. Zaproponowane zostaną miary jakości i kryteria porównawcze umożliwiające empiryczną ocenę algorytmów pod kątem relacji pomiędzy redukcją przesyłanych danych wejściowych a jakością wyników obliczeń. Uzyskane wyniki będą stanowić podstawę dalszych badań nad algorytmami rozproszonymi, systemami uczącymi się oraz przetwarzaniem strumieni danych.

Projekt badawczy będzie kontynuacją badań wstępnych, opisanych artykule: Lewandowski, M.; Płaczek, B.; Bernas, M. Classifier-Based Data Transmission Reduction in Wearable Sensor Network for Human Activity Monitoring. *Sensors* 2021, 21, 85. <https://doi.org/10.3390/s21010085>.

complexity as well as model update costs. The contribution of the work will consist in identifying trade-offs between local computational costs, energy consumption, and the global quality of task execution by an IoT system.

The project will further contribute to methods for evaluating selective data acquisition algorithms in the Internet of Things. Quality metrics and comparative criteria will be proposed to enable empirical assessment of algorithms with respect to the relationship between the reduction of transmitted input data and the quality of computational results. The obtained results will form a basis for further research on distributed algorithms, learning systems, and data stream processing.

The research project will constitute a continuation of preliminary studies described in the article: Lewandowski, M.; Płaczek, B.; Bernas, M. Classifier-Based Data Transmission Reduction in Wearable Sensor Network for Human Activity Monitoring. *Sensors* 2021, 21, 85. <https://doi.org/10.3390/s21010085>

Opis wymagań – wiedza, umiejętności i kompetencje społeczne kandydata

Kandydat powinien posiadać ugruntowaną wiedzę z zakresu informatyki, w szczególności obejmującą algorytmy i struktury danych, podstawy analizy algorytmów oraz elementy teorii złożoności obliczeniowej. Wymagana jest znajomość metod uczenia maszynowego, ze szczególnym uwzględnieniem algorytmów klasyfikacyjnych i decyzyjnych, a także podstaw statystycznej analizy danych. Kandydat powinien rozumieć modele obliczeń w systemach rozproszonych oraz zagadnienia związane z przetwarzaniem danych strumieniowych i niekompletnych.

Od kandydata oczekuje się umiejętności projektowania, implementacji i analizy algorytmów, w tym algorytmów decyzyjnych opartych na modelach uczenia maszynowego. Kandydat powinien potrafić opisywać problemy badawcze w sposób formalny, proponować rozwiązania algorytmiczne oraz analizować ich własności, takie jak złożoność obliczeniowa, stabilność i odporność na brak danych. Wymagana

Description of requirements – knowledge, skills and social competences of the candidate

The candidate should possess a solid background in computer science, in particular covering algorithms and data structures, fundamentals of algorithm analysis, and elements of computational complexity theory. Knowledge of machine learning methods is required, with particular emphasis on classification and decision algorithms, as well as basic statistical data analysis. The candidate should understand computational models in distributed systems and issues related to streaming and incomplete data processing.

The candidate is expected to have skills in designing, implementing, and analyzing algorithms, including decision algorithms based on machine learning models. The candidate should be able to formally describe research problems, propose algorithmic solutions, and analyze their properties such as computational complexity, stability, and robustness to missing data. Proficiency in programming is required to enable implementation and experimental evaluation of





<p>jest biegłość w programowaniu, umożliwiającą implementację i eksperymentalną ocenę algorytmów, a także umiejętność prowadzenia badań empirycznych, w tym projektowania eksperymentów, doboru miar jakości oraz interpretacji wyników. Kandydat powinien posiadać zdolność krytycznej analizy literatury naukowej oraz umiejętność formułowania wniosków i uogólnień na podstawie uzyskanych rezultatów.</p> <p>Oczekiwana jest umiejętność pracy w środowisku naukowym, w tym współpracy z promotorem i zespołem badawczym, a także otwartość na dyskusję naukową i konstruktywną krytykę. Kandydat powinien posiadać motywację do systematycznego pogłębiania wiedzy oraz rozwijania kompetencji badawczych, a także świadomość etycznych aspektów prowadzenia badań naukowych. Ważną kompetencją jest zdolność jasnego i precyzyjnego komunikowania wyników badań w formie publikacji naukowych i wystąpień konferencyjnych.</p>	<p>algorithms, as well as the ability to conduct empirical research, including experiment design, selection of quality metrics, and interpretation of results. The candidate should be capable of critically analyzing scientific literature and formulating conclusions and generalizations based on obtained results.</p> <p>The ability to work in a scientific environment is expected, including collaboration with a supervisor and a research team, as well as openness to scientific discussion and constructive criticism. The candidate should demonstrate motivation for systematic deepening of knowledge and development of research competencies, as well as awareness of ethical aspects of conducting scientific research. An important competency is the ability to clearly and precisely communicate research results in the form of scientific publications and conference presentations.</p>

<p>Informatyka temat nr 3</p>	<p>Computer and information sciences topic No. 3</p>
<p>Odporność modeli uczenia maszynowego na ataki adwersarialne</p>	<p>Robustness of machine learning models to adversarial attacks</p>
<p>PhD supervisor: dr hab. Agnieszka Nowak-Brzezińska, prof. UŚ https://orcid.org/0000-0001-7238-1170</p>	
<p>Krótką charakterystyka założeń i celów badawczych</p> <p>Głównym celem projektu jest opracowanie nowatorskich algorytmów uczenia maszynowego nienadzorowanego (klasteryzacji oraz wykrywania anomalii), które posiadają matematycznie dowiedzioną odporność na celowe manipulacje rozkładem danych (adversarial distribution shifts). Badania koncentrują się na stworzeniu modeli zdolnych do stabilnego działania w warunkach</p>	<p>Brief description of research assumptions and goals</p> <p>The primary objective of this project is to develop innovative unsupervised machine learning algorithms (for clustering and anomaly detection) that possess mathematically proven robustness against intentional data distribution manipulations (adversarial distribution shifts). The research focuses on creating models capable of stable operation in environments characterized by active</p>





<p>aktywnego przeciwdziałania ze strony inteligentnych adversarzy, uniemożliwiając im skuteczne przeprowadzenie ataków typu poisoning (zatrucie danych) oraz evasion (omijanie detekcji).</p> <p>W trakcie badań zrealizowane będą następujące założenia projektowe:</p> <ul style="list-style-type: none">- Paradygmat Secure-by-Design: Systemy detekcji nie mogą być jedynie reaktywne; muszą być projektowane z założeniem istnienia inteligentnego, adaptacyjnego przeciwnika.- Stabilność matematyczna: Wynik klasteryzacji lub detekcji musi pozostać stabilny nawet w obliczu wprowadzenia przez napastnika celowych, subtelnych zmian w danych wejściowych.- Rozróżnialność dryftu: Algorytmy muszą precyzyjnie odróżniać naturalny dryft danych (wynikający np. ze zmian rynkowych czy technologicznych) od zmanipulowanego przesunięcia rozkładu generowanego przez autonomiczne agenty.	<p>interference from intelligent adversaries, thereby preventing the effective execution of poisoning and evasion attacks.</p> <p>To achieve this, the following design assumptions will be implemented throughout the research:</p> <ul style="list-style-type: none">- Secure-by-Design Paradigm: Detection systems must not be merely reactive; they must be designed with the fundamental assumption of an intelligent, adaptive opponent.- Mathematical Stability: The output of clustering or detection must remain stable even when faced with intentional, subtle modifications to the input data introduced by an attacker.- Drift Discernibility: Algorithms must precisely distinguish between natural data drift (resulting from market or technological shifts) and adversarial distribution shifts generated by autonomous AI agents.
<p>Planowany wkład w rozwój dyscypliny</p> <p>Proponowany projekt badawczy wnosi istotny wkład w rozwój dziedziny uczenia maszynowego oraz cyberbezpieczeństwa systemów autonomicznych w następujących obszarach:</p> <ul style="list-style-type: none">- Rozszerzenie teorii odpornego uczenia nienadzorowanego (Robust Unsupervised Learning): Opracowanie nowych modeli klasteryzacji i detekcji anomalii, które posiadają wbudowane mechanizmy odporności na ataki adversarialne. Wkładem jest przejście od modeli statycznych do modeli uwzględniających dynamikę inteligentnego przeciwnika (adversarial-aware models).- Matematyczna formalizacja "Adversarial Distribution Shifts": Zdefiniowanie i sformalizowanie różnic między naturalnym dryftem danych a celową manipulacją rozkładem dokonywaną przez agenty AI. Pozwoli to na stworzenie nowych metryk oceny stabilności modeli nienadzorowanych, które dotychczas były traktowane marginalnie w porównaniu do modeli klasyfikacyjnych (LLMs).- Opracowanie metod detekcji "Shadow Agents": Wprowadzenie nowej metodologii wykrywania aktywności autonomicznych agentów i rojów	<p>Planned contribution to the development of the discipline</p> <p>The proposed research project makes a significant contribution to the fields of Machine Learning and Autonomous Systems Cybersecurity in the following areas:</p> <ul style="list-style-type: none">- Advancing the Theory of Robust Unsupervised Learning: Developing novel clustering and anomaly detection models equipped with built-in mechanisms for resistance against adversarial attacks. This contribution marks a shift from static models to adversarial-aware models that account for the dynamics of an intelligent opponent.- Mathematical Formalization of "Adversarial Distribution Shifts": Defining and formalizing the distinctions between natural data drift and intentional distribution manipulation orchestrated by AI agents. This will enable the creation of new metrics for assessing the stability of unsupervised models, which have been marginalized to date compared to generative and classification models (LLMs).- Development of Detection Methods for "Shadow Agents": Introducing a new methodology for identifying the activities of autonomous agents and AI Predator Swarms that operate below the





<p>botów (AI Predator Swarms), które operują poniżej progu detekcji tradycyjnych systemów Outlier Detection.</p> <ul style="list-style-type: none"> - Wzmocnienie paradygmatu Secure-by-Design w systemach Agentic SOC: Dostarczenie fundamentów teoretycznych i algorytmicznych dla nowej generacji centrów operacji bezpieczeństwa (SOC), w których agenci AI muszą ufać integralności danych wejściowych, aby autonomicznie neutralizować zagrożenia. - Integracja metodyk MITRE ATLAS i OWASP z algorytmami ML: Przełożenie wysokopoziomowych ram bezpieczeństwa na konkretne parametry matematyczne modeli, co wypełnia lukę między teoretycznym opisem zagrożeń (np. Rogue AI) a techniczną implementacją mechanizmów obronnych. <p>Standardowe podejście do ML (zakładające, że dane pochodzą z rozkładu stacjonarnego) staje się niewystarczające. Wkład realizowanego tematu badań będzie polegał na redefinicji bezpieczeństwa modelu jako integralnej części jego architektury, a nie tylko zewnętrznej warstwy ochrony.</p>	<p>detection thresholds of traditional Outlier Detection systems.</p> <ul style="list-style-type: none"> - Strengthening the Secure-by-Design Paradigm in Agentic SOC Systems: Providing the theoretical and algorithmic foundations for a new generation of Security Operations Centers (SOCs), where AI agents must rely on the integrity of input data to autonomously neutralize threats. - Integration of MITRE ATLAS and OWASP Frameworks with ML Algorithms: Translating high-level security frameworks into specific mathematical model parameters, thereby bridging the gap between theoretical threat descriptions (e.g., Rogue AI) and the technical implementation of defense mechanisms. <p>The standard approach to ML, which assumes data originates from a stationary distribution, is no longer sufficient. The contribution of this research lies in redefining model security as an integral part of its architecture rather than merely an external layer of protection.</p>
<p>Opis wymagań – wiedza, umiejętności i kompetencje społeczne kandydata</p> <p>Wiedza:</p> <ul style="list-style-type: none"> - Zaawansowana statystyka i matematyka: Głęboka wiedza z zakresu teorii prawdopodobieństwa, algebry liniowej oraz metod optymalizacji (w szczególności optymalizacji odpornej). - Teoria uczenia maszynowego: Znajomość paradygmatów uczenia nienadzorowanego (clustering, density estimation) oraz mechanizmów uczenia głębokiego (Autoenkodery, GANs). - Cyberbezpieczeństwo AI: Znajomość taksonomii ataków adversarialnych (według MITRE ATLAS), rozumienie mechanizmów poisoning, evasion oraz model inversion. - Agentic AI & LLMs: Podstawowa wiedza na temat funkcjonowania agentów autonomicznych i ryzyka związanego z Rogue AI (zgodnie z wytycznymi OWASP 2026). <p>Umiejętności / Kompetencje:</p> <ul style="list-style-type: none"> - Programowanie i Frameworki: Biegłość w języku Python oraz bibliotekach dedykowanych AI (PyTorch/TensorFlow). 	<p>Description of requirements – knowledge, skills and social competences of the candidate</p> <p>Knowledge:</p> <ul style="list-style-type: none"> - Advanced Statistics and Mathematics: In-depth knowledge of probability theory, linear algebra, and optimization methods (specifically robust optimization). - Machine Learning Theory: Proficiency in unsupervised learning paradigms (clustering, density estimation) and deep learning mechanisms (Autoencoders, GANs). - AI Cybersecurity: Familiarity with adversarial attack taxonomies (e.g., MITRE ATLAS) and a thorough understanding of poisoning, evasion, and model inversion mechanisms. - Agentic AI & LLMs: Foundational knowledge of autonomous agent functionality and the risks associated with Rogue AI (in accordance with OWASP 2026 guidelines). <p>Skills and Competencies:</p> <ul style="list-style-type: none"> - Programming and Frameworks: Proficiency in Python and dedicated AI libraries (PyTorch/TensorFlow).





<ul style="list-style-type: none"> - Modelowanie Matematyczne: Zdolność do formalizacji problemów bezpieczeństwa w języku matematycznym i dowodzenia stabilności algorytmów. - Analiza Danych: Doświadczenie w pracy z dużymi zbiorami danych, w tym umiejętność wykrywania anomalii i analizy dryftu danych (data drift analysis). - Język Angielski: Biegłość na poziomie co najmniej B2, umożliwiającą analizę najnowszych publikacji na arXiv oraz prezentowanie wyników na międzynarodowych konferencjach. <p>Kompetencje społeczne:</p> <ul style="list-style-type: none"> - Myślenie analityczne i krytyczne. - Etyka zawodowa. - Samodzielność i inicjatywa: Umiejętność samodzielnego planowania eksperymentów badawczych i krytycznej oceny uzyskanych wyników. - Komunikacja naukowa: Zdolność do przekazywania skomplikowanych zagadnień technicznych w sposób zrozumiały, zarówno w formie pisemnej (artykuły naukowe), jak i ustnej. <p>Dodatkowe atuty (opcjonalnie):</p> <ul style="list-style-type: none"> - Udział w projektach skupionych na AI. - Publikacje naukowe lub czynny udział w kołach naukowych związanych z cyberbezpieczeństwem/konferencjach AI. 	<ul style="list-style-type: none"> - Mathematical Modeling: The ability to formalize security problems in mathematical terms and provide proofs for algorithmic stability. - Data Analysis: Experience working with large datasets, including proficiency in anomaly detection and data drift analysis. - English Language Proficiency: Minimum B2 level, enabling the analysis of the latest publications on arXiv and the presentation of research results at international conferences. <p>Social Competencies:</p> <ul style="list-style-type: none"> - Analytical and Critical Thinking: A strong capacity for logical reasoning and problem-solving. - Professional Ethics: A commitment to integrity and the development of responsible AI. - Autonomy and Initiative: The ability to independently plan research experiments and critically evaluate the obtained results. - Scientific Communication: The capacity to convey complex technical issues clearly, both in writing (scientific papers) and orally. <p>Additional Assets (optional):</p> <ul style="list-style-type: none"> - Participation in AI-focused projects. - Scientific publications or active involvement in student research groups related to cybersecurity or AI conferences.
--	---

Informatyka temat nr 4	Computer and information sciences topic No. 4
Predykcyjne algorytmy redukcji próbkowania i transmisji danych w mobilnych systemach Internetu Rzeczy	Predictive Algorithms for Sampling and Data Transmission Reduction in Mobile Internet of Things Systems
PhD supervisor: dr hab. Inż. Bartłomiej Płaczek, prof. UŚ https://scholar.google.com/citations?user=8z-IMoYAAAAJ	
Krótką charakterystyka założeń i celów badawczych Celem projektu badawczego jest opracowanie i analiza algorytmów predykcyjnych	Brief description of research assumptions and goals The objective of the research project is to develop and analyze predictive algorithms that enable the





umożliwiających efektywne ograniczanie ilości próbkowanych i transmitowanych danych w systemach Internetu Rzeczy. Predykcja w planowanej rozprawie doktorskiej będzie wykorzystywana jako podstawa algorytmu decyzyjnego, pozwalającego określić przez jaki czas rzeczywiste pomiary i transmisje danych z węzłów Internetu Rzeczy mogą zostać wstrzymane bez utraty poprawności działania rozpatrywanej aplikacji. Zamiast cyklicznego próbkowania i przesyłania wszystkich danych pomiarowych, system będzie wykorzystywał modele predycyjne do estymacji możliwych zakresów przyszłych wartości mierzonych parametrów oraz tempa ich zmian. Na tej podstawie wyznaczone będą przedziały czasowe, w których aktualna wiedza o stanie systemu pozostaje wystarczająca do podejmowania decyzji. Próbkowanie i transmisja danych będą inicjowane dopiero wtedy, gdy predykcja wskaże na możliwość istotnych zmian w odczytach sensorów, co oznacza, że nowa informacja może wpłynąć na wynik decyzji. W ten sposób predykcja będzie wykorzystywana do harmonogramowania aktywności węzłów IoT, umożliwiając jednocześnie ograniczenie liczby próbek, liczby transmisji oraz zużycia energii, przy zachowaniu poprawności funkcjonowania systemu. Zakłada się, że opracowane algorytmy pozwolą na przewidywanie momentów, w których aktualne dane mogą stać się niewystarczające do poprawnej obsługi danej aplikacji, oraz inicjowanie pomiarów tylko wtedy, gdy jest to konieczne. Istotnym elementem badań będzie również analiza wpływu dynamiki środowiska oraz mobilności węzłów na skuteczność predycyjnej redukcji danych.

Celem praktycznym jest stworzenie modelu algorytmicznego modelu, który może być bezpośrednio wykorzystany w rzeczywistych systemach Internetu Rzeczy do wydłużania czasu życia urządzeń zasilanych za pomocą baterii, ograniczania kosztów transmisji oraz poprawy skalowalności aplikacji, przy jednoczesnym zachowaniu wymaganej poprawności działania systemu.

Walidacja eksperymentalna opracowanych algorytmów predycyjnych zostanie

effective reduction of the amount of sampled and transmitted data in Internet of Things systems. In the planned doctoral dissertation, prediction will be used as the basis of a decision-making algorithm that makes it possible to determine for how long actual measurements and data transmissions from IoT nodes can be suspended without compromising the correctness of the operation of the considered application. Instead of periodic sampling and transmission of all measurement data, the system will employ predictive models to estimate possible ranges of future values of measured parameters and the rate of their changes. On this basis, time intervals will be determined during which the current knowledge of the system state remains sufficient for decision-making. Sampling and data transmission will be initiated only when prediction indicates the possibility of significant changes in sensor readings, meaning that new information may affect the outcome of a decision. In this way, prediction will be used to schedule the activity of IoT nodes, enabling a simultaneous reduction in the number of samples, the number of transmissions, and energy consumption, while maintaining the correct operation of the system. It is assumed that the developed algorithms will allow for predicting the moments when the currently available data may become insufficient for the proper operation of a given application and for initiating measurements only when necessary. An important aspect of the research will also be the analysis of the impact of environmental dynamics and node mobility on the effectiveness of predictive data reduction.

The practical objective is to develop an algorithmic decision-making model that can be directly applied in real-world Internet of Things systems to extend the lifetime of battery-powered devices, reduce transmission costs, and improve application scalability, while maintaining the required correctness of system operation.

Experimental validation of the developed predictive algorithms will be carried out in realistic Internet of Things scenarios, with particular emphasis on mobile sensor networks in which node positions and the values of recorded parameters change continuously over time. In such





przeprowadzona w realistycznych scenariuszach Internetu Rzeczy, ze szczególnym uwzględnieniem mobilnych sieci czujników, w których położenie węzłów oraz wartości rejestrowanych parametrów ulegają ciągłym zmianom. W takich systemach węzły mogą być umieszczone na urządzeniach przenośnych, pojazdach, robotach mobilnych lub noszone przez użytkowników, a ich zadaniem jest np. monitorowanie parametrów środowiskowych lub odległości od obiektów referencyjnych. Walidacja będzie obejmowała scenariusze, w których istotne jest dynamiczne wskazywanie np. węzła charakteryzującego się najwyższą jakością sygnału, najmniejszą odległością od określonej lokalizacji lub gwarantującego najbardziej reprezentatywny pomiar w danym obszarze, przy jednoczesnym ograniczeniu aktywności pozostałych węzłów. Przewiduje się eksperymenty, w których algorytmy predykcyjne umożliwią węzłom mobilnym pozostawanie w stanie uśpienia przez dłuższe okresy, a próbkowanie i transmisja danych będą inicjowane jedynie w momentach, gdy wymaga tego przewidywana dynamika ruchu lub zmiana odczytów. Analiza będzie również obejmowała sytuacje nagłych zmian trajektorii ruchu lub warunków w otoczeniu węzłów, pozwalając ocenić zdolność algorytmów do szybkiej adaptacji. Scenariusze eksperymentów będą uwzględniały ocenę skuteczności proponowanych metod w wybranych mobilnych aplikacjach Internetu Rzeczy, takich jak systemy lokalizacji, śledzenie użytkowników i obiektów, inteligentne systemy transportowe oraz aplikacje wspierające monitorowanie środowiska.

systems, nodes may be deployed on portable devices, vehicles, mobile robots, or worn by users, and their tasks may include, for example, monitoring environmental parameters or distances to reference objects. The validation will include scenarios in which it is important to dynamically identify, for instance, the node characterized by the highest signal quality, the shortest distance to a given location, or the most representative measurement in a given area, while limiting the activity of the remaining nodes. Experiments are planned in which predictive algorithms will allow mobile nodes to remain in a sleep state for extended periods, while sampling and data transmission will be initiated only when required by the predicted dynamics of movement or changes in sensor readings. The analysis will also include situations involving sudden changes in movement trajectories or environmental conditions, allowing the assessment of the algorithms' ability to rapidly adapt. Experimental scenarios will evaluate the effectiveness of the proposed methods in selected mobile Internet of Things applications, such as localization systems, user and object tracking, intelligent transportation systems, and applications supporting environmental monitoring.

Planowany wkład w rozwój dyscypliny

Planowany projekt badawczy wnieśli wkład w rozwój dyscypliny Informatyka poprzez opracowanie i sformalizowanie algorytmicznego podejścia do predykcyjnego sterowania procesem zbierania danych w rozproszonych systemach Internetu Rzeczy. Praca rozwinie koncepcję predykcji wykorzystywanej do podejmowania decyzji o konieczności pozyskania nowych danych, co stanowi istotne rozszerzenie klasycznych metod przetwarzania strumieni danych. Takie ujęcie problemu wpisuje się w nurt badań nad

Planned contribution to the development of the discipline

The planned research project will contribute to the development of the discipline of Computer Science through the development and formalization of an algorithmic approach to predictive control of the data collection process in distributed Internet of Things systems. The work will extend the concept of prediction used for deciding when new data acquisition is necessary, which constitutes a significant extension of classical stream data processing methods. This perspective aligns with





algorytmami działającymi na niepełnej i adaptacyjnie aktualizowanej informacji.

Wkład naukowy rozprawy polegać będzie na zaproponowaniu modeli decyzyjnych, w których momenty próbkowania i transmisji danych są wynikiem obliczeń predykcyjnych. Opracowane algorytmy pozwolą na analizę zależności pomiędzy dynamiką zmian danych wejściowych, dokładnością predykcji i poprawnością decyzji podejmowanych przez system IoT. W szczególności rozprawa przyczyni się do lepszego zrozumienia, w jaki sposób prognozowane zakresy przyszłych wartości i tempo ich zmian mogą być wykorzystywane do wyznaczania przedziałów czasowych, w których aktualna informacja pozostaje wystarczająca do poprawnego działania systemu IoT w dynamicznym środowisku.

Ważnym elementem będzie również analiza możliwości wykorzystania algorytmów predykcyjnych w kontekście mobilnych sieci czujników, które charakteryzują się zmienną topologią oraz znaczną dynamiką danych. Przeprowadzona zostanie ocena odporności opracowanych algorytmów na nagłe zmiany warunków środowiskowych i trajektorii ruchu węzłów. Wyniki badań przyczynią się do rozwoju metod projektowania systemów IoT, które zachowują poprawność działania mimo ograniczonego i nieregularnego dostępu do danych. Planowana walidacja eksperymentalna w realistycznych scenariuszach Internetu Rzeczy umożliwi ocenę praktycznych konsekwencji proponowanych rozwiązań algorytmicznych.

Zaproponowane podejście stanowić będzie punkt wyjścia do dalszych badań nad algorytmami predykcyjnymi, adaptacyjnymi i energooszczędnymi, umacniając rolę informatyki jako dyscypliny dostarczającej formalnych rozwiązań dla problemów wynikających z rosnącej skali i dynamiki współczesnych systemów obliczeniowych.

Projekt badawczy będzie kontynuacją wcześniejszych badań, opisanych artykule: Płaczek, Bartłomiej. "Prediction-based data reduction with dynamic target node selection in IoT sensor networks." *Future Generation Computer Systems* 152 (2024): 225–238. <https://doi.org/10.1016/j.future.2023.11.007>.

research on algorithms operating on incomplete and adaptively updated information.

The scientific contribution of the dissertation will consist in proposing decision-making models in which sampling and data transmission times are determined as a result of predictive computations. The developed algorithms will enable the analysis of relationships between the dynamics of input data changes, prediction accuracy, and the correctness of decisions made by the IoT system. In particular, the dissertation will contribute to a better understanding of how predicted ranges of future values and the rate of their changes can be used to determine time intervals during which the available information remains sufficient for the correct operation of an IoT system in a dynamic environment.

An important element will also be the analysis of the applicability of predictive algorithms in the context of mobile sensor networks, which are characterized by changing topology and significant data dynamics. The resistance of the developed algorithms to sudden changes in environmental conditions and node movement trajectories will be evaluated. The research results will contribute to the development of methods for designing IoT systems that maintain correct operation despite limited and irregular access to data. Planned experimental validation in realistic Internet of Things scenarios will enable the assessment of the practical consequences of the proposed algorithmic solutions.

The proposed approach will constitute a starting point for further research on predictive, adaptive, and energy-efficient algorithms, strengthening the role of computer science as a discipline providing formal solutions to problems arising from the increasing scale and dynamics of contemporary computing systems.

The research project will be a continuation of earlier work described in the following publication: Płaczek, Bartłomiej. "Prediction-based data reduction with dynamic target node selection in IoT sensor networks." *Future Generation Computer Systems* 152 (2024): 225–238. <https://doi.org/10.1016/j.future.2023.11.007>.





<p>152 (2024): 225-238, https://doi.org/10.1016/j.future.2023.11.007.</p>	
<p>Opis wymagań – wiedza, umiejętności i kompetencje społeczne kandydata</p> <p>Kandydat powinien posiadać ugruntowaną wiedzę z zakresu informatyki, w szczególności obejmującą algorytmy i struktury danych, podstawy analizy algorytmów oraz elementy teorii złożoności obliczeniowej. Wymagana jest znajomość metod predykcyjnych, podstaw uczenia maszynowego i analizy szeregów czasowych. Kandydat powinien rozumieć zagadnienia związane z przetwarzaniem danych strumieniowych. Istotna jest również wiedza dotycząca architektury systemów Internetu Rzeczy, w tym zasad działania węzłów brzegowych oraz ograniczeń wynikających z limitowanych zasobów obliczeniowych i energetycznych urządzeń IoT.</p> <p>Od kandydata oczekuje się umiejętności implementacji i analizy algorytmów predykcyjnych oraz algorytmów decyzyjnych. Kandydat powinien potrafić formalnie opisywać problemy badawcze, proponować rozwiązania algorytmiczne oraz analizować ich własności, takie jak poprawność, złożoność obliczeniowa, stabilność działania. Wymagana jest biegłość w programowaniu umożliwiającą implementację i eksperymentalną ocenę algorytmów w realistycznych scenariuszach Internetu Rzeczy. Kandydat powinien posiadać umiejętność analizy wyników oraz interpretacji uzyskanych rezultatów. Oczekiwana jest również zdolność krytycznej analizy literatury naukowej oraz formułowania wniosków i uogólnień na podstawie przeprowadzonych badań.</p> <p>Oczekuje się umiejętności pracy w środowisku naukowym, w tym efektywnej współpracy z promotorem oraz innymi członkami zespołu badawczego. Kandydat powinien wykazywać otwartość na dyskusję naukową, umiejętność przyjmowania konstruktywnej krytyki oraz gotowość do modyfikowania przyjętych założeń badawczych w świetle nowych wyników. Ważna jest motywacja do systematycznego pogłębiania wiedzy i rozwijania kompetencji badawczych. Kandydat powinien również posiadać świadomość etycznych aspektów prowadzenia badań, w tym</p>	<p>Description of requirements – knowledge, skills and social competences of the candidate</p> <p>The candidate should possess a solid background in computer science, in particular covering algorithms and data structures, fundamentals of algorithm analysis, and elements of computational complexity theory. Knowledge of predictive methods, basic machine learning techniques, and time series analysis is required. The candidate should understand issues related to stream data processing. Knowledge of Internet of Things system architectures is also important, including the principles of operation of edge nodes and the limitations resulting from constrained computational and energy resources of IoT devices.</p> <p>The candidate is expected to have the ability to implement and analyze predictive algorithms and decision-making algorithms. The candidate should be able to formally describe research problems, propose algorithmic solutions, and analyze their properties, such as correctness, computational complexity, and operational stability. Proficiency in programming is required to enable the implementation and experimental evaluation of algorithms in realistic Internet of Things scenarios. The candidate should be able to analyze results and interpret the obtained findings. The ability to critically analyze scientific literature and to formulate conclusions and generalizations based on conducted research is also expected.</p> <p>The candidate is expected to be able to work in a scientific environment, including effective collaboration with the supervisor and other members of the research team. Openness to scientific discussion, the ability to accept constructive criticism, and readiness to modify adopted research assumptions in light of new results are required. Motivation for systematic deepening of knowledge and development of research competencies is important. The candidate should also be aware of the ethical aspects of conducting scientific research, including integrity in data analysis and result presentation. An important</p>



<p>rzetelności w analizie danych i prezentacji wyników. Istotną kompetencją jest zdolność jasnego, precyzyjnego i zrozumiałego komunikowania rezultatów badań w formie publikacji naukowych, raportów badawczych lub wystąpień konferencyjnych.</p>	<p>competence is the ability to clearly, precisely, and comprehensibly communicate research results in the form of scientific publications, research reports, or conference presentations.</p>
---	--

<p>Informatyka temat nr 5</p>	<p>Computer and information sciences topic No. 5</p>
<p>Uczenie maszynowe w predykcji nasłonecznienia i produkcji energii fotowoltaicznej z wykorzystaniem sieci lokalnych klasyfikatorów</p>	<p>Machine learning for solar irradiance prediction and photovoltaic energy production using local classifier networks</p>
<p>PhD supervisor: dr hab. Małgorzata Przybyła-Kasperek, prof. UŚ https://scholar.google.com/citations?hl=pl&user=2hDgv3gAAAAJ&view_op=list_works&sortby=pubdate</p>	
<p>Krótką charakterystyką założeń i celów badawczych Obecnie duży nacisk kładzie się na badanie metod efektywnego wykorzystania energii odnawialnej i ograniczania emisji gazów cieplarnianych związanych ze spalaniem węgla lub gazu. Kluczowe źródła energii odnawialnej obejmują panele fotowoltaiczne (PV), turbiny wiatrowe, prąd rzeczny lub źródła geotermalne. Chociaż zasoby te mają ogromny potencjał, ich wykorzystanie nie jest jednakowe, przy czym najczęściej stosowane są instalacje fotowoltaiczne. Jednym z wyzwań związanych z pełną integracją energii odnawialnej z codzienną siecią energetyczną jest nieprzewidywalny charakter produkcji. Ilość energii generowanej z tych źródeł jest trudna do przewidzenia, a produkcja nie jest stała i zmienia się w zależności od położenia geograficznego, pory dnia czy pory roku. Różnorodne czynniki naturalne odgrywają znaczącą rolę w poziomie produkcji energii elektrycznej z paneli fotowoltaicznych. Nawet najbardziej skomplikowane numeryczne modele prognozowania pogody i nasłonecznienia,</p>	<p>Brief description of research assumptions and goals A great deal of attention is currently being devoted to developing methods for the efficient use of renewable energy and for reducing greenhouse gas emissions associated with the combustion of coal and natural gas. Key sources of renewable energy include photovoltaic (PV) panels, wind turbines, river flow, and geothermal resources. Although these resources have considerable potential, their use is uneven, with photovoltaic installations being the most widespread. One of the major challenges in fully integrating renewable energy into the power grid is the highly unpredictable nature of its generation. The amount of energy produced from these sources is difficult to forecast, since output varies with geographic location, time of day, and season. Numerous natural factors play an important role in determining the level of electricity generated by photovoltaic panels. Even advanced numerical weather and irradiance forecasting models, as well as statistical models</p>



a także statystyczne modele prognozowania oparte na danych historycznych często obarczone są dużymi błędami ze względu na postępujący i nieprzewidywalny charakter zmian klimatycznych. W rezultacie dokładne i wiarygodne prognozy pogody stają się trudne w regionach charakteryzujących się znaczną zmiennością klimatyczną. W literaturze można znaleźć wiele różnych podejść opartych na uczeniu maszynowym, które łączą predykcję nasłonecznienia z prognozowaniem pogody i zachmurzenia. Jednak, według najlepszej wiedzy, w literaturze nie zaproponowano modeli, które byłyby na tyle uniwersalne, aby można było je zastosować dla różnych położeń geograficznych oraz uwzględniłyby wiele czynników mających wpływ na nasłonecznienie i produkcję paneli fotowoltaicznych. Ponadto ważnym problemem jest odpowiednie zagospodarowanie energii wyprodukowanej przez panele. W literaturze w tym celu stosowane są często metody optymalizacji rojowej, algorytmy ewolucyjne lub sieci neuronowe.

Projekt zakłada również opracowanie i analizę sieci lokalnych klasyfikatorów, z których każdy jest trenowany dla konkretnej lokalizacji, warunków pogodowych lub profilu energetycznego. Na podstawie stopnia podobieństwa między klasyfikatorami (np. korelacja predykcji, podobieństwo strukturalne sieci neuronowych, podobieństwo błędów, ważności atrybutów) będą tworzone koalicje klasyfikatorów. Pozwoli to na budowę dynamicznych zespołów modeli, które samodzielnie łączą się w grupy w zależności od kontekstu danych.

Cele badawcze:

- Predykcja nasłonecznienia z wykorzystaniem modeli uczenia maszynowego. Zbadanie i rozwój modeli uczenia maszynowego do predykcji dziennego nasłonecznienia, z uwzględnieniem lokalnych zmiennych środowiskowych.
- Predykcja produkcji energii z instalacji fotowoltaicznych na podstawie prognozy nasłonecznienia w różnych warunkach geograficznych i klimatycznych.
- Analiza wpływu zmiennych środowiskowych (lokalizacja geograficzna, kąt padania słońca,

based on historical data, often exhibit substantial errors due to the increasing and unpredictable impact of climate change. As a result, accurate and reliable weather forecasts are particularly difficult in regions with high climatic variability.

The literature offers many machine learning approaches that combine irradiance prediction with weather and cloud-cover forecasting. However, to the best of our knowledge, no existing model is universal enough to be applied across different geographic locations while simultaneously accounting for the wide range of factors that influence solar irradiance and PV production. Another important challenge is the effective management of energy generated by PV panels. Various optimization techniques - such as swarm optimization methods, evolutionary algorithms, and neural networks - are commonly used for this purpose.

The project also involves developing and analysing networks of local classifiers, each trained for a specific location, weather pattern, or energy-generation profile. Coalitions of classifiers will be formed based on their degree of similarity (e.g., prediction correlation, structural similarity of neural networks, error similarity, or attribute-importance similarity). This approach will enable the construction of dynamic ensembles of models that autonomously group themselves depending on data context.

Research objectives:

- Solar irradiance prediction using machine learning models.
- Investigation and development of machine learning methods for daily irradiance forecasting, incorporating local environmental variables.
- Prediction of energy production from photovoltaic installations based on irradiance forecasts under different geographic and climatic conditions.
- Analysis of the impact of environmental variables (geographic location, solar angle, weather conditions, cloud cover, precipitation, ground-surface color) on prediction accuracy.
- Development of local classifier networks - a set of models trained under different environmental,





<p>pogoda, zachmurzenie, opady, kolor podłoża) na dokładność predykcji.</p> <ul style="list-style-type: none">– Budowa lokalnych sieci klasyfikatorów – zestawów modeli trenowanych w różnych warunkach (geograficznych, czasowych, pogodowych), które wspólnie tworzą system rozproszony.– Tworzenie koalicji klasyfikatorów na podstawie miar podobieństwa – analiza metod łączenia modeli predykcyjnych w dynamiczne koalicje oraz badanie, jak koalicje wpływają na jakość predykcji. <p>Hipotezy badawcze:</p> <ul style="list-style-type: none">– Koalicje klasyfikatorów tworzone na podstawie miar podobieństwa poprawią jakość predykcji w porównaniu z pojedynczymi modelami trenowanymi lokalnie.– Modele uczenia maszynowego uwzględniające zmienne środowiskowe pozwolą na bardziej precyzyjną predykcję nasłonecznienia niż tradycyjne metody.	<p>temporal, or weather-related conditions, forming a distributed predictive system.</p> <ul style="list-style-type: none">– Formation of classifier coalitions based on similarity measures - analysis of methods for combining predictive models into dynamic coalitions and evaluation of how such coalitions affect prediction quality. <p>Research hypotheses:</p> <ul style="list-style-type: none">– Classifier coalitions formed on the basis of similarity measures will improve prediction quality compared to individual locally trained models.– Machine learning models that incorporate environmental variables will enable more accurate irradiance prediction than traditional methods.
<p>Planowany wkład w rozwój dyscypliny</p> <p>W literaturze można znaleźć wiele badań dotyczących przewidywania produkcji paneli słonecznych z uwzględnieniem warunków pogodowych. Badania te często zależą od położenia geograficznego. Do prognozowania energii słonecznej wykorzystywane są różne metody. Podejścia oparte na szeregach czasowych umożliwiają modelowanie wpływu historycznych danych meteorologicznych na obecne warunki pogodowe w określonych ramach czasowych. Algorytmy uczenia maszynowego uwzględniające prognozę pogody są również często wykorzystywane do prognozowania natężenia irradiancji. Stosowane są tutaj różne metody, od prostych i interpretowalnych drzew decyzyjnych po bardziej skomplikowane metody zespołowe. Ponadto stosowane są różne modele głębokiego uczenia, takie jak rekurencyjne sieci neuronowe czy splotowe sieci neuronowe. Alternatywnym podejściem jest przewidywanie natężenia irradiancji na podstawie obrazów nieba pochodzących z satelity lub kamery. Nowatorstwo projektu polega na zastosowaniu lokalnych sieci klasyfikatorów, które tworzą</p>	<p>Planned contribution to the development of the discipline</p> <p>There is a substantial body of literature devoted to predicting the energy output of solar panels while taking weather conditions into account. Such studies are often highly dependent on geographic location. Various methods are used for solar energy forecasting. Time-series approaches make it possible to model the influence of historical meteorological data on current weather conditions within specific time windows. Machine learning algorithms that incorporate weather forecasts are also commonly applied to predict irradiance intensity; these methods range from simple and interpretable decision trees to more advanced ensemble techniques. In addition, different deep-learning models are employed, including recurrent neural networks and convolutional neural networks. An alternative line of research focuses on predicting irradiance intensity based on sky images captured by satellites or ground-based cameras.</p> <p>The innovative aspect of the proposed project lies in the use of local classifier networks that form dynamic coalitions of models based on prediction</p>





<p>dynamiczne koalicje modeli oparte na podobieństwie predykcji. Jest to zgodne z trendami w kierunku rozproszonych, samoorganizujących się systemów sztucznej inteligencji.</p> <p>Proponowany projekt ma kluczowe znaczenie zarówno w kontekście rozwoju dyscypliny informatyki, jak i w kontekście społecznym i ekologicznym. Opracowanie modeli predykcji nasłonecznienia i produkcji energii z instalacji fotowoltaicznych oraz optymalizacja ich wykorzystania przyczyni się do bardziej efektywnego zarządzania zieloną energią. Dzięki temu możliwe będzie lepsze wykorzystanie odnawialnych źródeł energii, co ma istotne znaczenie dla zrównoważonego rozwoju i ochrony środowiska.</p>	<p>similarity. This approach is consistent with current trends toward distributed and self-organizing artificial intelligence systems.</p> <p>The proposed project is important not only for advancing computer science as a discipline but also in broader social and environmental contexts. Developing models for predicting solar irradiance and photovoltaic energy production, as well as optimizing the use of the generated energy, will contribute to more efficient management of renewable energy resources. This, in turn, enables better utilization of green energy sources, which is crucial for sustainable development and environmental protection.</p>
<p>Opis wymagań – wiedza, umiejętności i kompetencje społeczne kandydata</p>	<p>Description of requirements – knowledge, skills and social competences of the candidate</p>

<p>Informatyka temat nr 6</p>	<p>Computer and information sciences topic No. 6</p>
<p>Wyjaśnialna analiza zmian w systemach uczących się na danych strumieniowych</p>	<p>Explainable Analysis of Changes in Machine Learning Systems on Data Streams</p>
<p>PhD supervisor: dr hab. inż. Rafał Doroz, Prof. UŚ</p>	
<p>Krótką charakterystyka założeń i celów badawczych</p> <p>Systemy uczące się na danych strumieniowych coraz częściej znajdują zastosowanie w praktyce, jak np. w systemach rekomendacyjnych, monitorowaniu transakcji finansowych, analizie danych medycznych czy systemach wykrywania anomalii. W tego typu systemach dane napływają w sposób ciągły, a model musi podejmować decyzje w środowisku, którego właściwości zmieniają się w czasie. Wspomniane zmiany mogą dotyczyć zarówno samych danych wejściowych, jak</p>	<p>Brief description of research assumptions and goals</p> <p>Systems that learn from streaming data are increasingly used in practice, e.g., in recommendation systems, financial transaction monitoring, medical data analysis, and anomaly detection. In such systems, data flows continuously, and the model must make decisions in an environment whose properties change over time. These changes can affect both the input data and the relationship between the data and the model's decisions.</p>





i relacji pomiędzy danymi a decyzjami podejmowanymi przez model.

Przykładowo, system dedykowany do analizy transakcji bankowych może początkowo uznawać wysoką kwotę i zagraniczną lokalizację za silne sygnały podejrzanej operacji. Z czasem jednak, wraz z upowszechnieniem płatności międzynarodowych i zmianą zachowań klientów, te same cechy przestają mieć kluczowe znaczenie. Model zaczyna podejmować inne decyzje dla podobnych transakcji niż wcześniej, mimo że formalnie nadal działa poprawnie. Tego typu sytuacja prowadzi do stopniowej degradacji jakości modelu oraz spadku zaufania do jego decyzji.

Klasyczne metody analizy zmian w danych strumieniowych koncentrują się głównie na wykryciu momentu wystąpienia zmiany, np. poprzez sygnalizację alarmu lub obserwację spadku jakości predykcji. Takie podejście nie odpowiada jednak na pytania kluczowe z punktu widzenia użytkownika i projektanta systemu: co dokładnie się zmieniło, które cechy lub fragmenty danych są za to odpowiedzialne oraz w jaki sposób zmiana wpłynęła na decyzje modelu. W praktyce oznacza to, że system informuje jedynie, że „coś się stało”, bez wskazania przyczyn i mechanizmów.

Celem doktoratu jest opracowanie metod wyjaśnialnej analizy zmian w systemach uczących się na danych strumieniowych poprzez połączenie algorytmów detekcji zmian z technikami Explainable Artificial Intelligence (XAI), w tym metodami atrybucji cech (np. wartości SHAP) oraz lokalnymi wyjaśnieniami decyzji modeli. Temat zakłada nie tylko identyfikację momentu zmiany, lecz także interpretację jej przyczyn poprzez analizę zmian rozkładów danych, zmian znaczenia cech oraz lokalnych struktur decyzyjnych modeli w czasie.

Cele badawcze projektu:

1. Detekcja zmian z interpretacją – opracowanie metod wykrywania zmian w strumieniach danych wraz z mechanizmami ich wyjaśniania (co uległo zmianie i w jakim zakresie).
2. Analiza zmian rozkładów danych – identyfikacja i charakteryzacja zmian w danych wejściowych oraz ich związku ze zmianą zachowania modelu.

For example, a system dedicated to analysing bank transactions may initially treat a high amount and a foreign location as strong signals of a suspicious transaction. Over time, however, with the proliferation of international payments and changes in customer behaviour, these same characteristics become less critical. The model begins to make different decisions for similar transactions than before, even though it is still formally functioning correctly. This type of situation leads to a gradual degradation of the model's quality and a decline in confidence in its decisions.

Classic methods of analysing changes in streaming data focus mainly on detecting the moment when a change occurs, e.g. by signalling an alarm or observing a decline in prediction quality. However, this approach does not answer the key questions from the point of view of the user and system designer: what exactly has changed, which features or data fragments are responsible for this, and how the change has affected the model's decisions. In practice, this means that the system only informs that ‘something has happened’ without indicating the causes and mechanisms.

The aim of the PhD is to develop methods for explainable analysis of changes in systems learning from streaming data by combining change detection algorithms with Explainable Artificial Intelligence (XAI) techniques, including feature attribution methods (e.g. SHAP values) and local explanations of model decisions. The topic involves not only identifying the moment of change, but also interpreting its causes by analysing changes in data distributions, changes in feature significance, and local decision structures of models over time.

Research objectives of the project:

1. Change detection with interpretation – development of methods for detecting changes in data streams along with mechanisms for explaining them (what has changed and to what extent).
2. Analysis of changes in data distributions – identification and characterisation of changes in input data and their relationship to changes in model behaviour.
3. Analysis of changes in feature importance – tracking the evolution of feature contributions to





<p>3. Analiza zmian znaczenia cech – śledzenie ewolucji wkładu cech w decyzje modelu z wykorzystaniem technik XAI (np. SHAP) w ujęciu globalnym i lokalnym.</p> <p>4. Ocena wpływu na jakość i stabilność – zbadanie, w jakim stopniu wyjaśnialna analiza zmian pomaga utrzymać stabilność, jakość i wiarygodność modeli.</p> <p>5. Użyteczna prezentacja wyników – opracowanie sposobów przedstawiania wyników analizy zmian tak, aby wspierały decyzje o monitorowaniu, adaptacji i utrzymaniu modeli.</p>	<p>model decisions using XAI techniques (e.g. SHAP) in global and local terms.</p> <p>4. Assessment of impact on quality and stability – examining the extent to which explainable change analysis helps maintain the stability, quality and reliability of models.</p> <p>5. Useful presentation of results – developing ways to present the results of change analysis so that they support decisions about monitoring, adapting and maintaining models.</p>
<p>Planowany wkład w rozwój dyscypliny</p> <p>Projekt wniesie wkład w rozwój badań nad uczeniem maszynowym w środowiskach dynamicznych poprzez opracowanie metod, które łączą detekcję zmian w danych strumieniowych z ich wyjaśnianiem na poziomie cech i decyzji modelu. Oczekiwane rezultaty obejmują: (i) metody pozwalające przejść od sygnału „zmiana wystąpiła” do odpowiedzi „co i dlaczego się zmieniło”, (ii) podejścia do śledzenia ewolucji znaczenia cech (np. z użyciem SHAP) oraz zmian lokalnej logiki decyzyjnej modeli, (iii) kryteria i procedury oceny wpływu tych analiz na stabilność i wiarygodność modeli. Wkład projektu będzie istotny zarówno z punktu widzenia teorii i metodologii monitorowania modeli, jak i zastosowań praktycznych w systemach wymagających transparentności i zaufania do decyzji algorytmicznych</p>	<p>Planned contribution to the development of the discipline</p> <p>The project will contribute to the advancement of research on machine learning in dynamic environments by developing methods that combine the detection of changes in streaming data with their explanation at the level of model features and decisions. The expected results include: (i) methods to move from the signal ‘a change has occurred’ to the response ‘what has changed and why’, (ii) approaches to tracking the evolution of feature importance (e.g. using SHAP) and changes in the local decision logic of models, (iii) criteria and procedures for assessing the impact of these analyses on the stability and reliability of models. The project's contribution will be significant both from the point of view of model monitoring theory and methodology, as well as practical applications in systems requiring transparency and trust in algorithmic decisions.</p>
<p>Opis wymagań – wiedza, umiejętności i kompetencje społeczne kandydata</p> <p>Od kandydata oczekuje się podstawowej wiedzy z zakresu uczenia maszynowego, analizy danych oraz statystyki. Wymagane są: podstawowa umiejętność programowania (np. Python), znajomość podstaw budowy i oceny modeli (klasyfikacja/regresja, walidacja). Kandydat powinien wykazywać zdolność analitycznego myślenia, samodzielność w rozwiązywaniu problemów badawczych oraz gotowość do pracy eksperymentalnej z danymi rzeczywistymi. Ważne są także kompetencje społeczne: umiejętność</p>	<p>Description of requirements – knowledge, skills and social competences of the candidate</p> <p>The candidate is expected to have basic knowledge of machine learning, data analysis and statistics. Required skills include basic programming skills (e.g. Python) and knowledge of the basics of model construction and evaluation (classification/regression, validation). The candidate should demonstrate analytical thinking skills, independence in solving research problems, and a willingness to work experimentally with real data. Social skills are also important: the ability to work in a team, communicate results (in writing</p>





współpracy w zespole, komunikowania wyników (pisemnie i ustnie) oraz konsekwencja w realizacji długoterminowego planu badawczego.

and orally), and consistency in implementing a long-term research plan.

