

**Propozycje tematów prac dyplomowych magisterskich**  
**kierunek studiów: Informatyka, specjalność: Technologie geoinformatyczne i mobilne**  
**czerwiec 2026 r.**

**Temat 1**

<b>Temat</b>	Analiza jakości transmisji mowy z użyciem aplikacji WhatsApp
<b>Temat w języku angielskim</b>	Speech transmission quality analysis using WhatsApp
<b>Opiekun pracy</b>	dr inż. Przemysław Falkowski-Gilski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest dokonanie analizy jakości transmisji sygnałów mowy z wykorzystaniem aplikacji WhatsApp. Badania należy przeprowadzić porównując wyniki z klasyczną transmisją mowy w sieciach komórkowych 2G, 3G, 4G oraz 5G. Możliwe jest również zbadanie wpływu transmisji VoLTE na poprawę jakości sygnału. Kampania powinna uwzględniać różne smartfony, pracujące pod kontrolą systemów operacyjnych Android i/lub iOS. Badania powinny skupiać się na subiektywnych metrykach oceny jakości. Testy należy przeprowadzić w różnych wariantach skali MOS, w tym np. DCR, CCR.
<b>Zadania</b>	<ol style="list-style-type: none"> <li>1. Przegląd dostępnej literatury tematu.</li> <li>2. Wytypowanie warstwy sprzętowej i programowej.</li> <li>3. Przeprowadzenie szeregu testów transmisji sygnałów mowy.</li> <li>4. Analiza uzyskanych wyników.</li> </ol>
<b>Literatura</b>	<ol style="list-style-type: none"> <li>1. Kumar, R., Saini, S. (2011). Measuring parameters for speech quality in cellular networks. International Journal of Advances in Computer Networks and its Security, 1, 746-194.</li> <li>2. Patel, N., Patel, S., Tan, W. L. (2018). Performance comparison of Whatsapp versus Skype on smart phones. 2018 28th International Telecommunication Networks and Applications Conference (ITNAC). IEEE.</li> <li>3. Maros, A., Almeida, J., Benevenuto, F., Vasconcelos, M. (2020). Analyzing the use of audio messages in Whatsapp groups. Proceedings of the Web Conference 2020. ACM.</li> <li>4. Fernandez-Amaya, L. (2022). A linguistic overview of WhatsApp communication. Leiden: Brill.</li> </ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	Temat uzgodniony ze studentem

## Temat 2

<b>Temat</b>	Segmentacja semantyczna obszarów portowych w obrazach optycznych
<b>Temat w języku angielskim</b>	Semantic segmentation of seaport areas in optical satellite imagery
<b>Opiekun pracy</b>	dr hab. Marcin Ciecholewski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	<p>Celem pracy jest opracowanie metod segmentacji semantycznej obszarów portowych w obrazach optycznych z wykorzystaniem wybranych technik głębokiego uczenia, takich jak U-Net, DeepLabv3+, SegFormer oraz UNetFormer. Segmentacja obejmować będzie klasy takie jak obszary wodne, lądowe oraz elementy infrastruktury portowej.</p> <p>Istotnym elementem pracy będzie analiza wpływu architektury modeli oraz jakości danych wejściowych na skuteczność segmentacji. W tym celu wykorzystane zostaną dostępne zbiory danych o zróżnicowanej rozdzielczości.</p> <p>Opracowane rozwiązanie zostanie zintegrowane z systemem QGIS w postaci wtyczki umożliwiającej zastosowanie modeli w środowisku GIS. W ramach pracy zapewniony będzie dostęp do infrastruktury obliczeniowej GPU umożliwiającej efektywne przetwarzanie modeli głębokiego uczenia.</p>
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd istniejących rozwiązań na podstawie literatury</li><li>2. Opracowanie rozwiązania</li><li>3. Zaprojektowanie architektury sieci neuronowej i jej trening</li><li>4. Opracowanie wtyczki do programu QGIS</li><li>5. Przetestowanie zastosowanych rozwiązań</li><li>6. Ewaluacja jakości segmentacji z wykorzystaniem metryk (np. IoU, Dice)</li><li>7. Analiza porównawcza modeli oraz wpływu parametrów danych</li></ol>
<b>Literatura</b>	<p>[1] The QGIS Development Team. QGIS Geographic Information System. <a href="https://qgis.org/">https://qgis.org/</a></p> <p>[2] Zhang, Bo, et al. "A spatial and semantic alignment fusion network for sea-land port segmentation." IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing (2025).</p> <p>[3] Wang, Wenhai, et al. "Pyramid vision transformer: A versatile backbone for dense prediction without convolutions." Proceedings of the IEEE/CVF international conference on computer vision. 2021.</p> <p>[4] Wang, Libo, et al. "UNetFormer: A UNet-like transformer for efficient semantic segmentation of remote sensing urban scene imagery." ISPRS Journal of Photogrammetry and Remote Sensing 190 (2022): 196-214.</p> <p>[5] Chen, Liang-Chieh, et al. "Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs." IEEE transactions on pattern analysis and machine intelligence 40.4 (2017): 834-848.</p> <p>[6] Fu, Jun, et al. "Dual attention network for scene segmentation." Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2019.</p> <p>[7] Cao, Hu, et al. "Swin-unet: Unet-like pure transformer for medical image segmentation." European conference on computer vision. Cham: Springer Nature Switzerland, 2022.</p>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

### Temat 3

<b>Temat</b>	Analiza metod akceleracji obliczeń cyfrowych na tensorach pod kątem zastosowania w inferencji sieci neuronowych
<b>Temat w języku angielskim</b>	Analysis of methods for acceleration for digital tensor computation, focusing on applications in neural network inference
<b>Opiekun pracy</b>	dr inż. Krzysztof Bikonis
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Przegląd i analiza istniejących metod projektowania układów cyfrowych przeznaczonych do wydajnych obliczeń tensorowych, zaproponowanie ewentualnych usprawnień, z uwzględnieniem zastosowania w inferencji sieci neuronowych. Implementacja i testy przykładowego rdzenia obliczeniowego, z uwzględnieniem zaproponowanych rozwiązań, przeznaczonego do inferencji sieci neuronowych, w języku opisu sprzętu.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury - w szczególności istniejących metod akceleracji.</li><li>2. Zaproponowanie usprawnień na podstawie przeprowadzonej analizy.</li><li>3. Implementacja rdzenia do inferencji sieci neuronowych w języku opisu sprzętu.</li><li>4. Testy i analiza wpływu proponowanych usprawnień na wydajność obliczeń.</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. IEEE Standard for Verilog® Hardware Description Language (<a href="https://www.eg.bucknell.edu/~csci320/2016-fall/wp-content/uploads/2015/08/verilog-std-1364-2005.pdf">https://www.eg.bucknell.edu/~csci320/2016-fall/wp-content/uploads/2015/08/verilog-std-1364-2005.pdf</a>).</li><li>2. A Computational Model for Tensor Core Units (<a href="https://dl.acm.org/doi/abs/10.1145/3350755.3400252">https://dl.acm.org/doi/abs/10.1145/3350755.3400252</a>).</li></ol>
<b>Proponowana liczba osób</b>	2
<b>Informacje dodatkowe</b>	Temat uzgodniony ze studentami.

## Temat 4

<b>Temat</b>	Analiza metod optymalizacji niskopoziomowego kodu pośredniego
<b>Temat w języku angielskim</b>	Analysis of methods for optimization of Low-Level Intermediate Code Representation
<b>Opiekun pracy</b>	dr inż. Krzysztof Bikonis
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest analiza kilku wybranych istniejących metod optymalizacji niskopoziomowego kodu pośredniego generowanego dynamicznie (takich jak propagacja stałych, czy rozwijanie pętli), ich implementacja i testy. Rozwiązania zostaną porównane pod kątem efektywności ich zastosowania w systemach JIT (ang. just-in-time) - stosunku ich statystycznego narzutu względem oferowanej optymalizacji.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury - w szczególności istniejących metod optymalizacji.</li><li>2. Implementacja zaproponowanych rozwiązań związanych z tematyką realizowanej pracy.</li><li>3. Testy i analiza wpływu optymalizacji pod kątem efektywności ich zastosowania w systemach JIT.</li><li>4. Wnioski.</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Optimized Unrolling of Nested Loops (<a href="https://web.eecs.umich.edu/~mahlke/courses/583w23/lectures/Mar27/Group2_paper.pdf">https://web.eecs.umich.edu/~mahlke/courses/583w23/lectures/Mar27/Group2_paper.pdf</a>).</li><li>2. Constant Propagation with Conditional Branches (<a href="https://bears.ece.ucsb.edu/class/ece253/papers/wegman91.pdf">https://bears.ece.ucsb.edu/class/ece253/papers/wegman91.pdf</a>).</li><li>3. An algorithm for reduction of operator strength (<a href="https://dl.acm.org/doi/abs/10.1145/359863.359888">https://dl.acm.org/doi/abs/10.1145/359863.359888</a>).</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	Temat uzgodniony ze studentem.

## Temat 5

<b>Temat</b>	Badanie wydajności technologii WebAssembly i WebGPU na potrzeby rozwiązywania równań liniowych w środowisku przeglądarek internetowych.
<b>Temat w języku angielskim</b>	Performance evaluation of WebAssembly and WebGPU for solving systems of linear equations in Web Browsers
<b>Opiekun pracy</b>	dr hab. inż. Marek Moszyński
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Głównym celem pracy jest ocena wydajności i efektywności technologii WebAssembly oraz WebGPU w procesie rozwiązywania układów równań liniowych bezpośrednio w środowisku przeglądarki internetowej. Badanie koncentruje się na porównaniu czasu obliczeń oraz stopnia wykorzystania zasobów sprzętowych (CPU i GPU) w zestawieniu z tradycyjnymi rozwiązaniami opartymi na czystym języku JavaScript. Wyniki analizy pozwolą określić, w jakim stopniu nowoczesne standardy webowe mogą zastąpić aplikacje natywne w zadaniach wymagających dużej mocy obliczeniowej, takich jak symulacje inżynierskie czy analiza danych.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Analiza stanu wiedzy: Krytyczny przegląd możliwości standardów WebAssembly i WebGPU w kontekście akceleracji obliczeń numerycznych oraz metod rozwiązywania układów równań liniowych.</li><li>2. Implementacja algorytmów: Opracowanie i integracja zrównoleglonych solverów macierzowych wykorzystujących natywną wydajność kodu binarnego oraz moc obliczeniową układów graficznych w środowisku przeglądarkowym.</li><li>3. Weryfikacja i testy: Wielokryterialna ocena porównawcza wydajności czasowej, precyzji obliczeń oraz obciążenia zasobów sprzętowych dla różnych rozmiarów danych i architektur systemowych.</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Press, Teukolsky, Vetterling, Flannery), Numerical Recipes: The Art of Scientific Computing</li><li>2. Yousef Saad, Iterative Methods for Sparse Linear Systems</li><li>3. Brian Sletten, WebAssembly: The Definitive Guide</li><li>3. Dokumentacje techniczne WebGPU, <a href="https://gpuweb.github.io/gpuweb/">https://gpuweb.github.io/gpuweb/</a></li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 6

<b>Temat</b>	Filtracja cętek ze zobrazenia SAR z wykorzystaniem uczenia maszynowego
<b>Temat w języku angielskim</b>	Speckle filtering from SAR imagery using machine learning
<b>Opiekun pracy</b>	dr hab. inż. Tomasz Berezowski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Głównym celem pracy jest opracowanie, implementacja oraz ocena skuteczności nowoczesnych algorytmów opartych na uczeniu maszynowym w procesie filtracji szumu cętkowego (speckle) w zobrazeniach radarowych SAR, a także ich krytyczne porównanie z tradycyjnymi metodami filtracji statystycznej i nielokalnej.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury</li><li>2. Pozyskanie i przygotowanie danych - Podstawowym materiałem badawczym są dane symulacyjne generowane przy wykorzystaniu narzędzia dostarczonego przez partnera zewnętrznego. Etap obejmuje partycypację w wytwarzaniu danych poprzez projektowanie i generowanie konkretnych scen symulacyjnych, a następnie ich przetworzenie oraz przygotowanie zbiorów treningowych, walidacyjnych i testowych wraz z ewentualną augmentacją. Dodatkowo, w miarę dostępności, przewiduje się walidację uzyskanych wyników na rzeczywistych danych radarowych.</li><li>3. Implementacja metod referencyjnych - Implementacja wybranych klasycznych filtrów szumu cętkowego w celu utworzenia punktu odniesienia do dalszych porównań.</li><li>4. Projektowanie i implementacja metod opartych na uczeniu maszynowym - Zaprojektowanie i implementacja nowoczesnych architektur przeznaczonych do filtracji cętek. Zakres analizowanych podejść będzie dostosowywany w oparciu o wyniki uzyskiwane w kolejnych etapach pracy.</li><li>5. Eksperymenty i ocena jakości - Przeprowadzenie badań eksperymentalnych z wykorzystaniem metryk jakości obrazu, takich jak ENL czy PSNR. Zdefiniowanie scenariuszy testowych obejmujących różne poziomy szumu i typy zobrazeń.</li><li>6. Analiza porównawcza - Porównanie skuteczności opracowanych metod pod kątem jakości odszumiania, zachowania szczegółów strukturalnych, czasu przetwarzania oraz wymagań obliczeniowych.</li><li>7. Walidacja</li></ol>
<b>Literatura</b>	<ul style="list-style-type: none"><li>- Fracastoro, G., Magli, E., Poggi, G., Scarpa, G., Valsesia, D., &amp; Verdoliva, L. (2021). Deep learning methods for synthetic aperture radar image despeckling: An overview of trends and perspectives. <i>IEEE Geoscience and Remote Sensing Magazine</i>, 9(2), 29-51.</li><li>- Mohan, E., Rajesh, A., Sunitha, G., Konduru, R. M., Avaniya, J., &amp; Ganesh Babu, L. (2021). A deep neural network learningbased speckle noise removal technique for enhancing the quality of synthetic aperture radar images. <i>Concurrency and Computation: Practice and Experience</i>, 33(13), e6239.</li><li>- Mestre-Quereda, A., &amp; Lopez-Sanchez, J. M. (2025). Deep learning-based speckle filtering for polarimetric SAR images. Application to Sentinel-1. <i>IEEE Transactions on Geoscience and Remote Sensing</i>, 63, 1-18.</li></ul>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	Temat uzgodniony ze studentem Kierunek: Informatyka, Elektronika i telekomunikacja, Inżynieria biomedyczna stacjonarne II stopnia

## Temat 7

<b>Temat</b>	Grafowe sieci neuronowe jako modele zastępcze w fizyce zjawisk rozpraszania fal
<b>Temat w języku angielskim</b>	Graph Neural Networks as surrogate models for the physics of wave scattering phenomena
<b>Opiekun pracy</b>	dr hab. inż. Marek Moszyński
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Głównym celem pracy jest opracowanie i ewaluacja modelu zastępczego (surrogate model) opartego na grafowych sieciach neuronowych, zdolnego do aproksymacji wyników złożonych symulacji rozpraszania fal. Badania koncentrują się na zdolności sieci do generalizacji zjawisk fizycznych na nieregularnych siatkach obliczeniowych oraz na zachowaniu wysokiej wierności wyników w porównaniu z klasycznymi metodami numerycznymi. Praca ma na celu wykazanie, że zastosowanie architektur grafowych pozwala na znaczącą akcelerację obliczeń pola rozproszonego przy jednoczesnym uwzględnieniu geometrycznych uwarunkowań obiektów rozpraszających.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd metod tworzenia modeli zastępczych w fizyce obliczeniowej oraz przygotowanie zbioru danych treningowych zawierającego wyniki symulacji rozpraszania fal dla różnorodnych geometrii obiektów</li><li>2. Opracowanie architektury grafowej sieci neuronowej zdolnej do odwzorowania relacji między geometrią siatki a rozkładem pola rozproszonego oraz przeprowadzenie procesu uczenia modelu na danych fizycznych.</li><li>3. Porównanie wyników generowanych przez model GNN z wynikami uzyskanymi metodami klasycznymi pod kątem błędu aproksymacji, czasu obliczeń oraz zdolności do generalizacji dla nowych, nieznanych wcześniej kształtów.</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. PFAFF, Tobias, Meire FORTUNATO, Alvaro SANCHEZ-GONZALEZ i Peter BATTAGLIA. Learning Mesh-Based Simulation with Graph Networks. 2021, <a href="https://arxiv.org/abs/2010.03409">https://arxiv.org/abs/2010.03409</a>.</li><li>2. KASHEFI, Ali i Tapan MUKERJI. Physics-Informed PointNet: A Deep Learning Solver for Steady-state Incompressible Navier-Stokes Equations. 2022, <a href="https://arxiv.org/abs/1809.05910">https://arxiv.org/abs/1809.05910</a>.</li><li>3. RAISSI, Maziar, Paris PERDIKARIS i George E. KARNIADAKIS. Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations. Journal of Computational Physics, 2019.</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 8

<b>Temat</b>	Implementacja i analiza efektywności algorytmów usuwania zachmurzenia w wysokorozdzielczych obrazach satelitarnych z wykorzystaniem fuzji danych optycznych i radarowych
<b>Temat w języku angielskim</b>	Implementation and analysis of the effectiveness of cloud removal algorithms in high-resolution satellite images using optical and radar data fusion
<b>Opiekun pracy</b>	dr hab. inż. Tomasz Berezowski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Głównym celem pracy jest opracowanie i implementacja autorskiego potoku przetwarzania danych, który rozwiązuje problem nieciągłości w optycznym monitoringu powierzchni Ziemi wynikający z występowania pokrywy chmur. Praca koncentruje się na stworzeniu algorytmu fuzji danych, który wykorzystuje sygnały radarowe (Sentinel-1), zdolne do penetracji chmur, jako dane referencyjne do rekonstrukcji brakujących informacji spektralnych w obrazach optycznych (Sentinel-2). Istotnym elementem projektu jest analiza porównawcza wydajności obliczeniowej oraz dokładności różnych metod interpolacji i uczenia maszynowego. Możliwość implementacji w środowisku chmurowym. Wynikiem końcowym będzie narzędzie umożliwiające generowanie bezchmurnych kompozytów czasowych o wysokiej rozdzielczości, gotowych do dalszej analizy w systemach teledetekcyjnych.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury</li><li>2. Budowa modułu pozyskiwania i preprocessingu danych</li><li>3. Implementacja algorytmów detekcji chmur i cieni</li><li>4. Opracowanie i implementacja modelu fuzji danych</li><li>5. Walidacja wyników</li><li>6. Dokumentacja i analiza wyników</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Huang, Bo, et al. "Cloud removal from optical satellite imagery with SAR imagery using sparse representation." IEEE Geoscience and Remote Sensing Letters 12.5 (2015): 1046-1050.</li><li>2. Liu, Shuaijun, et al. "Innovative SAR-optical data fusion for reflectance time series reconstruction in vegetation-covered regions." International Journal of Applied Earth Observation and Geoinformation 140 (2025): 104567.</li><li>3. Cresson, Rémi, et al. "Comparison of convolutional neural networks for cloudy optical images reconstruction from single or multitemporal joint SAR and optical images." arXiv preprint arXiv:2204.00424 (2022).</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 9

<b>Temat</b>	Klasyfikacja rodzaju obiektów w terenie z wykorzystaniem zobrazowań satelitarnych oraz danych ze skanowania lidarowego
<b>Temat w języku angielskim</b>	Classification of the type of objects in the field using satellite imagery and LiDAR scanning data
<b>Opiekun pracy</b>	dr hab. inż. Zbigniew Łubniewski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	<p>Obecnie technologia skanowania laserowego LiDAR, dająca w wyniku nieuporządkowaną chmurę punktów umieszczonych w przestrzeni trójwymiarowej, jest jedną z częściej stosowanych metod do pomiaru położenia i kształtu obiektów, również w odniesieniu do topografii terenu. Ostatnie lata przyniosły znaczący rozwój metod klasyfikacji opartych na uczeniu maszynowym, w tym głębokim, również i w tej dziedzinie tj. z wykorzystaniem danych lidarowych, opracowane metody nie są jednak tu jeszcze tak dojrzałe jak w np. w przypadku klasyfikacji opartej na zdjęciach lotniczych i satelitarnych. Celem pracy jest zaproponowanie, implementacja, przetestowanie oraz weryfikacja działania algorytmów klasyfikacji rodzaju obiektów występujących w terenie, np.: budynek, inna budowla, roślinność niska, roślinność wysoka, grunt, zbiornik wodny itp., w oparciu o użycie następujących danych: 1) zobrazowania satelitarne, 2) nieuporządkowane chmury punktów ze skanowania lidarowego. Należy przeprowadzić porównanie wyników klasyfikacji otrzymywanych dla dwóch ww. rodzajów danych źródłowych, dla tego samego terenu. Możliwe jest użycie różnych metod klasyfikacji: od najprostszych, po wykorzystanie głębokich sieci neuronowych, w przypadku danych lidarowych opartych np. na dedykowanych modelach w rodzaju PointNet++ czy RandLA-Net.</p>
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Zapoznanie się z aktualnym stanem wiedzy w zakresie metod klasyfikacji obiektów wykorzystujących obie ww. techniki pomiarowe</li><li>2. Przygotowanie zbiorów danych wejściowych</li><li>3. Opracowanie, implementacja i testowanie metod i algorytmów</li><li>4. Analiza, w tym porównawcza, otrzymanych wyników</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. R. A. Schowengerdt, Remote Sensing: models and methods for image processing. 3rd Edition. Elsevier, 2011</li><li>2. Q. Hu, B. Yang, L. Xie, S. Rosa, Y. Guo, Z. Wang, N. Trigoni, and A. Markham, Randlanet: Efficient semantic segmentation of large-scale point clouds. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2020</li><li>3. M. Elgendy, Deep learning for vision systems. Manning Publications, 2020</li><li>4. Materiały dostępne u opiekuna</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 10

<b>Temat</b>	Model heurystyk aktywnej percepcji dla autonomicznych pojazdów podwodnych wykorzystujących sonary typu FLS w warunkach niepełnej informacji
<b>Temat w języku angielskim</b>	A Heuristic Framework for Active Perception in Autonomous Underwater Vehicles Using Forward-Looking Sonar Under Incomplete Information
<b>Opiekun pracy</b>	dr inż. Andrzej Chybicki
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest opracowanie modelu heurystyk aktywnej percepcji wspomagającego autonomiczne zachowanie pojazdu podwodnego wykorzystującego sonar typu Forward-Looking Sonar (FLS) w warunkach niepełnej informacji. Model będzie wspierał wybór manewrów pojazdu zwiększających pewność detekcji i klasyfikacji obserwowanych obiektów. Celem pracy będzie również weryfikacja opracowanego podejścia na danych eksperymentalnych pochodzących z pomiarów sonarowych.
<b>Zadania</b>	<ul style="list-style-type: none"><li>• Analiza literatury oraz istniejących metod detekcji, klasyfikacji i aktywnej percepcji dla autonomicznych pojazdów podwodnych wykorzystujących sonary typu FLS.</li><li>• Opracowanie modelu heurystyk aktywnej percepcji wspomagającego wybór manewrów pojazdu zwiększających pewność detekcji i klasyfikacji obiektów w warunkach niepełnej informacji.</li><li>• Implementacja oraz integracja opracowanego modelu z procedurą analizy danych sonarowych i przygotowanie scenariuszy eksperymentalnych dla danych pomiarowych.</li><li>• Weryfikacja i ocena skuteczności zaproponowanego podejścia na danych eksperymentalnych oraz analiza uzyskanych wyników.</li></ul>
<b>Literatura</b>	<ul style="list-style-type: none"><li>• Galceran, E., Djapic, V., Carreras, M., Williams, D.P., A Real-Time Underwater Object Detection Algorithm for Multi-Beam Forward Looking Sonar, IFAC Proceedings Volumes, Vol. 45, No. 5, 2012, pp. 306311. DOI: 10.3182/20120410-3-PT-4028.00051.</li><li>• dos Santos, M., Ribeiro, P.O.C.S., Núñez, P., Drews-Jr, P., Botelho, S., Object Classification in Semi-Structured Environment Using Forward-Looking Sonar, Sensors, Vol. 17, No. 10, 2235, 2017. DOI: 10.3390/s17102235.</li><li>• Sung, M. et al., Imaging-Sonar-Based Underwater Object Recognition Utilizing Objects Yaw Angle Estimation with Deep Learning, IFAC-PapersOnLine, Vol. 53, No. 2, 2020, pp. 1547515480. DOI: 10.1016/j.ifacol.2020.12.2371.</li><li>• Xie, K., Yang, J., Qiu, K., A Dataset with Multibeam Forward-Looking Sonar for Underwater Object Detection, Scientific Data, Vol. 9, 739, 2022. DOI: 10.1038/s41597-022-01854-w.</li></ul>
<b>Proponowana liczba osób</b>	2
<b>Informacje dodatkowe</b>	

## Temat 11

<b>Temat</b>	Model szacowania wpływu progów zwalniających na zużycie paliwa i emisję CO w ruchu miejskim z wykorzystaniem danych OSM i zobrażeń teledetekcyjnych
<b>Temat w języku angielskim</b>	A Model for Estimating the Impact of Speed Bumps on Fuel Consumption and CO Emissions in Urban Traffic Using OSM Data and Remote Sensing Imagery
<b>Opiekun pracy</b>	dr inż. Andrzej Chybicki
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest opracowanie modelu szacowania wpływu progów zwalniających na zużycie paliwa oraz emisję CO w ruchu miejskim z wykorzystaniem danych OpenStreetMap oraz zobrażeń teledetekcyjnych. W ramach pracy planuje się identyfikację i inwentaryzację progów zwalniających na ograniczonym poligonie testowym obejmującym obszar miasta Gdańska. Na tej podstawie opracowany zostanie model oceny dodatkowego zużycia paliwa i emisji wynikających z wymuszonego hamowania i przyspieszania pojazdów. Wyniki pracy posłużą do oceny energetycznych i środowiskowych skutków stosowania tego typu elementów infrastruktury uspokojenia ruchu.
<b>Zadania</b>	<ul style="list-style-type: none"><li>Przegląd literatury oraz analiza dostępnych danych źródłowych dotyczących progów zwalniających, modeli zużycia paliwa, emisji CO oraz wykorzystania danych OSM i zobrażeń teledetekcyjnych.</li><li>Identyfikacja i inwentaryzacja progów zwalniających na wybranym poligonie testowym (np. obszar miasta Gdańska) z wykorzystaniem danych geoprzestrzennych oraz metod analizy obrazów.</li><li>Opracowanie modelu szacowania wpływu progów zwalniających na dodatkowe zużycie paliwa i emisję CO wynikające z hamowania i ponownego przyspieszania pojazdów.</li><li>Implementacja i weryfikacja modelu oraz analiza wyników dla wybranego obszaru badawczego, wraz z oceną energetycznych i środowiskowych skutków stosowania progów zwalniających.</li></ul>
<b>Literatura</b>	<ol style="list-style-type: none"><li>González, J., et al. (2020). The Effect of Speed Humps on Instantaneous Traffic Emissions. Applied Sciences, 10(5), 1592. Artykuł bezpośrednio związany z tematem pokazuje wpływ progów zwalniających na emisje CO, NOx i PM przy różnych gęstościach ruchu. <a href="https://doi.org/10.3390/app10051592">https://doi.org/10.3390/app10051592</a></li><li>Oskarbski, J., et al. (2023). Estimation of Vehicle Energy Consumption at Intersections Using Microscopic Traffic Models. Bardzo dobry jako podbudowa do modelowania cyklu hamowanieprzyspieszenie i szacowania zużycia paliwa. <a href="https://mostwiedzy.pl/pl/publication/estimation-of-vehicle-energy-consumption-at-intersections-using-microscopic-traffic-models,152772-1">https://mostwiedzy.pl/pl/publication/estimation-of-vehicle-energy-consumption-at-intersections-using-microscopic-traffic-models,152772-1</a></li><li>Wang, L., et al. (2025). Estimating Link Level Traffic Emissions: Enhancing MOVES with Open-Source Data. Mocna pozycja pod wykorzystanie OSM, open data i estymację emisji. <a href="https://arxiv.org/abs/2510.03362">https://arxiv.org/abs/2510.03362</a></li><li>Hosseinkhah, S., et al. (2025). Application of Deep Neural Networks in Detecting Speed Bumps and Speed Humps for Fuel Consumption Optimization. Idealnie pasuje do komponentu detekcji progów z danych obrazowych. <a href="https://trid.trb.org/View/2602585">https://trid.trb.org/View/2602585</a></li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	kierunek: Informatyka, Technologie Kosmiczne i Satelitarne, Technologie Kosmiczne i Satelitarne (joint Master's double-degree program, Brema) stacjonarne II stopnia

## Temat 12

<b>Temat</b>	Automatyczna segmentacja infrastruktury drogowej w obrazach satelitarnych z wykorzystaniem modelu Segment Anything (SAM)
<b>Temat w języku angielskim</b>	Automatic segmentation of road infrastructure in satellite imagery using the Segment Anything Model (SAM)
<b>Opiekun pracy</b>	dr hab. Marcin Ciecholewski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	<p>Celem pracy jest opracowanie systemu automatycznej segmentacji infrastruktury drogowej na podstawie obrazów satelitarnych. W pracy zostanie wykorzystany model Segment Anything Model (SAM) [1,2] do generowania masek segmentacyjnych obiektów, wspomagany dodatkowymi informacjami (np. danymi referencyjnymi lub procedurami automatycznego generowania promptów), w celu identyfikacji elementów infrastruktury drogowej, takich jak ronda, skrzyżowania, mosty czy parkingi.</p> <p>Uzyskane wyniki segmentacji w postaci masek rastrowych zostaną zintegrowane z systemem QGIS [3], który stanowi wieloplatformowe, otwarte oprogramowanie geoinformacyjne (GIS). Istotnym elementem pracy będzie przygotowanie oraz przetwarzanie danych wejściowych, w tym pozyskiwanie i integracja danych z ogólnodostępnych źródeł (np. Sentinel-2, Google Earth oraz OpenStreetMap jako dane referencyjne), dostępnych z poziomu środowiska QGIS.</p> <p>W ramach pracy zapewniony będzie dostęp do infrastruktury obliczeniowej GPU umożliwiającej efektywne przetwarzanie modeli głębokiego uczenia.</p>
<b>Zadania</b>	<ol style="list-style-type: none"><li>1) Przegląd literatury dotyczącej segmentacji obrazów satelitarnych</li><li>2) Analiza modelu SAM 3 i jego możliwości</li><li>3) Przygotowanie i przetwarzanie danych</li><li>4) Implementacja modelu segmentacji w języku Python</li><li>5) Integracja z QGIS</li><li>6) Ewaluacja jakości wyników</li><li>7) Analiza porównawcza z innymi metodami segmentacji</li><li>8) Analiza wpływu jakości danych wejściowych (np. rozdzielczości przestrzennej) na wyniki segmentacji</li></ol>
<b>Literatura</b>	<p>[1] SAM 3: Segment Anything with Concepts, <a href="https://docs.ultralytics.com/models/sam-3/">https://docs.ultralytics.com/models/sam-3/</a></p> <p>[2] Carion, Nicolas, et al. "Sam 3: Segment anything with concepts." arXiv preprint arXiv:2511.16719 (2025).</p> <p>[3] The QGIS Development Team, <a href="https://qgis.org/">https://qgis.org/</a></p> <p>[4] Madajczak, A., &amp; Ciecholewski, M. (2025). Object detection with different categories using YOLOv8 for optical remote sensing images. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 20129-20148.</p> <p>[5] Madajczak, A., &amp; Ciecholewski, M. (2024, July). Detecting objects of various categories in optical remote sensing imagery using neural networks. In IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium (pp. 8971-8974). IEEE.</p>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 13

<b>Temat</b>	Hybrydowy system detekcji obiektów w obrazach satelitarnych z automatycznym generowaniem danych treningowych z wykorzystaniem modeli Segment Anything i YOLO
<b>Temat w języku angielskim</b>	Hybrid object detection system for satellite imagery using Segment Anything and YOLO models
<b>Opiekun pracy</b>	dr hab. Marcin Ciecholewski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	<p>Celem pracy jest opracowanie hybrydowego systemu detekcji obiektów w obrazach satelitarnych, łączącego model Segment Anything (SAM) z modelami detekcji obiektów YOLO. Model SAM zostanie wykorzystany do generowania masek segmentacyjnych potencjalnych obiektów na podstawie automatycznie generowanych promptów lub danych pomocniczych.</p> <p>Na podstawie uzyskanych masek zostaną utworzone automatyczne adnotacje (bounding boxy), które posłużą jako dane treningowe do uczenia modeli YOLO. Następnie przeprowadzona zostanie analiza skuteczności detekcji oraz wpływu jakości automatycznie generowanych danych treningowych na wyniki modelu.</p> <p>W ramach pracy zapewniony będzie dostęp do infrastruktury obliczeniowej GPU umożliwiającej efektywne przetwarzanie modeli głębokiego uczenia.</p>
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd istniejących rozwiązań na podstawie literatury</li><li>2. Analiza modelu SAM 3 i jego możliwości</li><li>3. Opracowanie rozwiązania w języku Python</li><li>4. Przetestowanie zastosowanych rozwiązań</li><li>5. Analiza porównawcza z innymi metodami</li><li>6. Ewaluacja jakości detekcji z wykorzystaniem standardowych metryk (np. mAP)</li><li>7. Analiza wpływu jakości automatycznie generowanych danych treningowych na skuteczność modelu YOLO</li></ol>
<b>Literatura</b>	<p>[1] SAM 3: Segment Anything with Concepts, <a href="https://docs.ultralytics.com/models/sam-3/">https://docs.ultralytics.com/models/sam-3/</a></p> <p>[2] Carion, Nicolas, et al. "Sam 3: Segment anything with concepts." arXiv preprint arXiv:2511.16719 (2025).</p> <p>[3] YOLO12: Attention-Centric Object Detection, <a href="https://docs.ultralytics.com/models/yolo12/">https://docs.ultralytics.com/models/yolo12/</a></p> <p>[4] Madajczak, A., &amp; Ciecholewski, M. (2025). Object detection with different categories using YOLOv8 for optical remote sensing images. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 20129-20148.</p> <p>[5] Madajczak, A., &amp; Ciecholewski, M. (2024, July). Detecting objects of various categories in optical remote sensing imagery using neural networks. In IGARSS 2024-2024 IEEE International Geoscience and Remote Sensing Symposium (pp. 8971-8974). IEEE.</p>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 14

<b>Temat</b>	Opracowanie metody przewidywania aktywności peptydów antypatogenowych z wykorzystaniem uczenia maszynowego
<b>Temat w języku angielskim</b>	Development of a method for predicting the activity of antimicrobial peptides using machine learning
<b>Opiekun pracy</b>	dr hab. inż. Emilia Lubecka
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest przeszukanie dostępnych baz danych peptydów przeciwdrobnoustrojowych (Antimicrobial Peptide Database (APD)) pod kątem ich aktywności oraz stworzenie na ich podstawie własnej bazy danych. Następnie opracowanie modelu do przewidywania aktywności peptydów drobnoustrojowych z wykorzystaniem stworzonej bazy danych oraz zaproponowanie na podstawie uzyskanych korelacji nowych potencjalnie bardzo aktywnych sekwencji peptydowych.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury tematu</li><li>2. Analiza dostępnych baz danych</li><li>3. Stworzenie własnej bazy danych na podstawie istniejących</li><li>4. Dobór metod rozwiązania</li><li>5. Opracowanie optymalnego rozwiązania</li><li>6. Przygotowanie przypadków testowych, które posłużą później do analizy porównawczej wyników prac</li><li>7. Testowanie opracowanego rozwiązania</li><li>8. Prezentacja osiągniętych wyników</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Wang, G., Schmidt, C., Li, X. and Wang, Z. (2026) APD6: The antimicrobial peptide database is expanded to promote research and development by deploying an unprecedented information pipeline. <i>Nucleic Acids Research</i> 54, D363-D374.</li><li>2. Malak Pirtskhalava, Anthony A Armstrong, Maia Grigolava, Mindia Chubinidze, Evgenia Alimbarashvili, Boris Vishnepolsky, Andrei Gabrielian, Alex Rosenthal, Darrell E Hurt, Michael Tartakovsky, DBAASP v3: database of antimicrobial/cytotoxic activity and structure of peptides as a resource for development of new therapeutics, <i>Nucleic Acids Research</i>, Volume 49, Issue D1, 8 January 2021, Pages D288D297.</li><li>3. Gawde U, Chakraborty S, Waghu F H, Barai R S, Khanderkar A, Indraguru R, Shirsat T, Idicula-Thomas S. CAMPR4: a database of natural and synthetic antimicrobial peptides. <i>Nucleic Acids Research</i>, 2023, Vol. 51, Database issue: D377-D383.</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 15

<b>Temat</b>	Prognozowanie rozkładu zanieczyszczenia powietrza w Polsce z użyciem danych satelitarnych i uczenia maszynowego
<b>Temat w języku angielskim</b>	Forecasting the distribution of air pollution in Poland using satellite data and machine learning
<b>Opiekun pracy</b>	dr hab. inż. Tomasz Berezowski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest zaprojektowanie i implementacja modelu uczenia maszynowego zdolnego do prognozowania przestrzennego rozkładu stężeń zanieczyszczeń (np. NO <sub>2</sub> , SO <sub>2</sub> , CO, CH <sub>4</sub> ) na podstawie danych z sensora TROPOMI (Sentinel-5P). System będzie integrował heterogeniczne źródła danych (satelitarne, przestrzenne i meteorologiczne). W pracy należy przeprowadzić analizę wyjaśnialności oraz wskazać optymalną architekturę modelu.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury</li><li>2. Budowa zautomatyzowanego potoku ETL</li><li>3. Wybór i implementacja modeli uczenia maszynowego</li><li>4. Badanie wyjaśnialności</li><li>5. Analiza wyników</li></ol>
<b>Literatura</b>	<ul style="list-style-type: none"><li>– Alkayal, Salma, et al. "Air pollution trends and predictive modeling for three cities with different characteristics using Sentinel-5 satellite data and deep learning." <i>Atmosphere</i> 16.2 (2025): 211.</li><li>– Javadi, Mohammad Amin, Maryam Zare Shahne, and Zahra Amiri. "Integration of Sentinel-5P satellite data and machine learning for spatiotemporal prediction of NO<sub>2</sub> in Delhi: Impacts of COVID-19 lockdown." <i>Atmospheric Pollution Research</i> (2025): 102702.</li><li>– Verma, Abhishek, Virender Ranga, and Dinesh Kumar Vishwakarma. "BREATH-Net: a novel deep learning framework for NO<sub>2</sub> prediction using bi-directional encoder with transformer." <i>Environmental Monitoring and Assessment</i> 196.4 (2024): 340.</li></ul>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 16

<b>Temat</b>	Segmentacja kręgów w obrazach tomografii komputerowej z wykorzystaniem głębokich sieci neuronowych i informacji lokalizacyjnej
<b>Temat w języku angielskim</b>	Vertebrae segmentation in CT images using deep neural networks and spatial priors
<b>Opiekun pracy</b>	dr hab. Marcin Ciecholewski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	<p>Celem pracy jest opracowanie i ocena metod segmentacji poszczególnych kręgów w obrazach tomografii komputerowej (TK) z wykorzystaniem technik głębokiego uczenia. W pracy zostaną zastosowane wybrane architektury sieci neuronowych, umożliwiające segmentację semantyczną oraz instancyjną struktur anatomicznych.</p> <p>Istotnym elementem pracy będzie wykorzystanie dodatkowych informacji o lokalizacji kręgów (np. środków ciężkości) w celu poprawy jakości segmentacji oraz stabilności działania modeli. Rozważone zostaną różne strategie przetwarzania danych, w tym podejścia oparte na analizie całych wolumenów 3D oraz fragmentów obrazów wyznaczanych na podstawie informacji lokalizacyjnej.</p> <p>W ramach pracy przeprowadzona zostanie szczegółowa ewaluacja uzyskanych wyników z wykorzystaniem standardowych metryk jakości segmentacji oraz analiza wpływu zastosowanych architektur i metod przetwarzania danych na końcową skuteczność modeli.</p>
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury dotyczącej segmentacji obrazów medycznych, ze szczególnym uwzględnieniem metod segmentacji kręgów w obrazach tomografii komputerowej.</li><li>2. Analiza dostępnych zbiorów danych oraz przygotowanie danych wejściowych do procesu uczenia (w tym wstępne przetwarzanie i augmentacja danych).</li><li>3. Opracowanie i implementacja wybranych architektur sieci neuronowych do segmentacji kręgów (np. U-Net, nnU-Net lub inne modele segmentacyjne).</li><li>4. Zaprojektowanie i implementacja podejścia wykorzystującego informacje o lokalizacji kręgów (np. środki ciężkości) w celu poprawy jakości segmentacji.</li><li>5. Przeprowadzenie procesu treningu i walidacji modeli z wykorzystaniem dostępnej infrastruktury GPU.</li><li>6. Ewaluacja jakości segmentacji z wykorzystaniem standardowych metryk (np. Dice coefficient, Intersection over Union).</li><li>7. Analiza porównawcza uzyskanych wyników dla różnych architektur oraz strategii przetwarzania danych.</li><li>8. Opracowanie wniosków końcowych oraz wskazanie kierunków dalszych badań</li></ol>
<b>Literatura</b>	<p>[1] Sekuboyina, Anjany, et al. "VerSe: A vertebrae labelling and segmentation benchmark for multi-detector CT images." <i>Medical image analysis</i> 73 (2021): 102166.</p> <p>[2] Lessmann, N., van Ginneken, B., &amp; Išgum, I. (2018, March). Iterative convolutional neural networks for automatic vertebra identification and segmentation in CT images. In <i>Medical Imaging 2018: Image Processing</i> (Vol. 10574, pp. 39-44). SPIE.</p> <p>[3] Löffler, Maximilian T., et al. "A vertebral segmentation dataset with fracture grading." <i>Radiology: Artificial Intelligence</i> 2.4 (2020): e190138.</p> <p>[4] Liebl, Hans, et al. "A computed tomography vertebral segmentation dataset with anatomical variations and multi-vendor scanner data." <i>Scientific Data</i> 8.1 (2021): 284.</p> <p>[5] Zareie, Mina, et al. "Automatic segmentation of vertebrae in 3D CT images using adaptive fast 3D pulse coupled neural networks." <i>Australasian physical &amp; engineering sciences in medicine</i> 41 (2018): 1009-1020.</p>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 17

<b>Temat</b>	Stworzenie modelu do przewidywania cytotoksyczności peptydów przeciwdrobnoustrojowych
<b>Temat w języku angielskim</b>	Development of a model to predict the cytotoxicity of antimicrobial peptides
<b>Opiekun pracy</b>	dr hab. inż. Emilia Lubecka
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest przeszukanie dostępnych baz danych peptydów przeciwdrobnoustrojowych (Antimicrobial Peptide Database (APD)) pod kątem ich cytotoksyczności oraz stworzenie na ich podstawie własnej bazy danych. Następnie opracowanie modelu do przewidywania poziomu cytotoksyczności peptydów przeciwdrobnoustrojowych z wykorzystaniem stworzonej bazy danych.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury tematu</li><li>2. Analiza dostępnych baz danych</li><li>3. Stworzenie własnej bazy danych na podstawie istniejących</li><li>4. Dobór metod rozwiązania</li><li>5. Opracowanie optymalnego rozwiązania</li><li>6. Przygotowanie przypadków testowych, które posłużą później do analizy porównawczej wyników prac</li><li>7. Testowanie opracowanego rozwiązania</li><li>8. Prezentacja osiągniętych wyników</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Wang, G., Schmidt, C., Li, X. and Wang, Z. (2026) APD6: The antimicrobial peptide database is expanded to promote research and development by deploying an unprecedented information pipeline. <i>Nucleic Acids Research</i> 54, D363-D374.</li><li>2. Malak Pirtskhalava, Anthony A Amstrong, Maia Grigolava, Mindia Chubinidze, Evgenia Alimbarashvili, Boris Vishnepolsky, Andrei Gabrielian, Alex Rosenthal, Darrell E Hurt, Michael Tartakovsky, DBAASP v3: database of antimicrobial/cytotoxic activity and structure of peptides as a resource for development of new therapeutics, <i>Nucleic Acids Research</i>, Volume 49, Issue D1, 8 January 2021, Pages D288D297.</li><li>3. Gawde U, Chakraborty S, Waghv F H, Barai R S, Khandekar A, Indraguru R, Shirsat T, Idicula-Thomas S. CAMPR4: a database of natural and synthetic antimicrobial peptides. <i>Nucleic Acids Research</i>, 2023, Vol. 51, Database issue: D377-D383.</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 18

<b>Temat</b>	Wpływ metod filtracji danych na dokładność estymacji położenia w systemach lokalizacji opartych na RFID dalekiego zasięgu
<b>Temat w języku angielskim</b>	Impact of Data Filtering Methods on Position Estimation Accuracy in Long-Range RFID-Based Localization Systems
<b>Opiekun pracy</b>	dr inż. Jerzy Demkowicz
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	<p>Celem pracy jest opracowanie systemu lokalizacji opartego na technologii long-range RFID oraz analiza metod poprawy jego dokładności. Na podstawie danych pozyskiwanych z czytników RFID estymowana jest odległość znacznika (tagu) od poszczególnych punktów pomiarowych, a następnie wyznaczana jest jego pozycja w przestrzeni.</p> <p>Ze względu na niestabilność wskaźnika RSSI (Received Signal Strength Indicator), pomiary obarczone są znacznymi błędami, co negatywnie wpływa na dokładność lokalizacji. W celu ich ograniczenia zastosowane zostaną metody filtracji danych, takie jak średnia krocząca oraz filtr Kalmana, które umożliwiają wygładzenie sygnału oraz redukcję zakłóceń.</p> <p>Ostatnim etapem pracy będzie porównanie dokładności lokalizacji przed i po zastosowaniu filtracji. Pozwoli to na ocenę skuteczności poszczególnych metod oraz wskazanie najbardziej efektywnego podejścia do poprawy jakości systemu lokalizacji.</p>
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Analiza i przegląd literatury</li><li>2. Projekt systemu oraz stanowiska badawczego</li><li>3. Zbieranie danych Implementacja algorytmów filtracji sygnału w systemie</li><li>4. Testowanie i weryfikacja systemu</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. The Power of RFID: Transforming Industries through Innovative Technology by Charles Nehme, Independent, 2024</li><li>2. RFID Handbook: Technology, Applications, Security and Privacy, Gordon Colbach, Amazon 2018</li><li>3. RFID Handbook: Fundamentals and Applications in Contactless Smart Cards and Identification, Klaus Finkenzeller, Wiley, 2003</li><li>4. RFID Design Fundamentals and Applications, Albert Lozano, CRC Press, 2017</li><li>5. RFID Essentials Theory in Practice PictureBill Glover, Himanshu Bhatt, O'Reilly Media, Inc. ISBN:978-0-596-00944-1, 2006</li><li>6. Chipless RFID Handbook: Fundamentals and Applications, Fátima Villa-González, Daniel Valderas, Etienne Perret, Antonio Lázaro, Simone Genovesi, Rahul Bhattacharyya, Springer 2025</li><li>7. Frequency-Based Passive Chipless RFID Tag Using Microstrip Openstub Resonators, V. Karthikeyan, U. Saravanakumar, P. Suresh, Springer 2020.</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 19

<b>Temat</b>	Wykorzystanie grafowych sieci neuronowych do wygładzania siatek trójkątów
<b>Temat w języku angielskim</b>	Surface Smoothing of Triangular Meshes Using Graph Neural Networks
<b>Opiekun pracy</b>	dr hab. inż. Marek Moszyński
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Głównym celem pracy jest opracowanie i analiza modelu grafowych sieci neuronowych (GNN) dedykowanego do wygładzania geometrii obiektów trójwymiarowych. Badanie koncentruje się na weryfikacji zdolności architektury sieciowej do skutecznej redukcji szumu przy jednoczesnym zachowaniu kluczowych cech geometrycznych siatki, takich jak krawędzie i wierzchołki charakterystyczne. Praca dąży do porównania efektywności zaproponowanego rozwiązania opartego na uczeniu maszynowym z klasycznymi, iteracyjnymi algorytmami wygładzania w kontekście jakości rekonstrukcji powierzchni i kosztu obliczeniowego.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd metod reprezentacji geometrii 3D za pomocą grafów oraz analiza istniejących architektur Graph Neural Networks pod kątem ich zastosowania w przetwarzaniu cech powierzchniowych.</li><li>2. Opracowanie modelu sieci oraz przygotowanie potoku przetwarzania danych, zdolnego do uczenia się nieliniowych filtrów wygładzających na zbiorach siatek trójkątów.</li><li>3. Przeprowadzenie testów porównawczych z klasycznymi algorytmami, oceniających błąd rekonstrukcji, zachowanie ostrych krawędzi oraz wydajność inferencji modelu.</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. BRONSTEIN, Michael M., Joan BRUNA, Taco COHEN i Petar VELIČKOVIĆ. Geometric Deep Learning: Grids, Groups, Graphs, Geodesics, and Gauges. 2021, geometricdeeplearning.com</li><li>2. BOTSCH, Mario, Leif KOBBELT, Mark PAULY, Pierre ALLIEZ i Bruno LÉVY. Polygon Mesh Processing. CRC Press, 2010. ISBN 978-1-56881-426-1.</li><li>3. Wang, Z., Chen, X., Yan, J., &amp; Liu, J. (2025). An intelligent mesh-smoothing method with graph neural networks. Frontiers of Information Technology &amp; Electronic Engineering, 26(4).</li><li>4. Sheng, J., Zheng, Y., &amp; Chen, L. (2024). An attention enhanced dual graph neural network for mesh denoising. Computer Aided Geometric Design, 111, 102330</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 20

<b>Temat</b>	Wykorzystanie metod sztucznej inteligencji do przewidywania struktury peptydów antypatogenowych
<b>Temat w języku angielskim</b>	Using artificial intelligence methods to predict the structure of antimicrobial peptides
<b>Opiekun pracy</b>	dr hab. inż. Emilia Lubecka
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest przeszukanie dostępnych baz danych peptydów przeciwdrobnoustrojowych (Antimicrobial Peptide Database (APD)) pod kątem tworzonej przez nie struktury przestrzennej oraz stworzenie na ich podstawie własnej bazy danych. Z uwagi na dużą dynamikę peptydów uwzględniona powinna być także stabilność tych struktur oraz ruchliwość poszczególnych fragmentów. Następnie opracowanie modelu do przewidywania struktury peptydów przeciwdrobnoustrojowych z wykorzystaniem stworzonej bazy danych.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury tematu</li><li>2. Analiza dostępnych baz danych</li><li>3. Stworzenie własnej bazy danych na podstawie istniejących</li><li>4. Dobór metod rozwiązania</li><li>5. Opracowanie optymalnego rozwiązania</li><li>6. Przygotowanie przypadków testowych, które posłużą później do analizy porównawczej wyników prac</li><li>7. Testowanie opracowanego rozwiązania</li><li>8. Prezentacja osiągniętych wyników</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Wang, G., Schmidt, C., Li, X. and Wang, Z. (2026) APD6: The antimicrobial peptide database is expanded to promote research and development by deploying an unprecedented information pipeline. <i>Nucleic Acids Research</i> 54, D363-D374.</li><li>2. Malak Pirtskhalava, Anthony A Amstrong, Maia Grigolava, Mindia Chubinidze, Evgenia Alimbarashvili, Boris Vishnepolsky, Andrei Gabrielian, Alex Rosenthal, Darrell E Hurt, Michael Tartakovsky, DBAASP v3: database of antimicrobial/cytotoxic activity and structure of peptides as a resource for development of new therapeutics, <i>Nucleic Acids Research</i>, Volume 49, Issue D1, 8 January 2021, Pages D288D297.</li><li>3. Gawde U, Chakraborty S, Waghu F H, Barai R S, Khanderkar A, Indraguru R, Shirsat T, Idicula-Thomas S. CAMPR4: a database of natural and synthetic antimicrobial peptides. <i>Nucleic Acids Research</i>, 2023, Vol. 51, Database issue: D377-D383.</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 21

<b>Temat</b>	Wykorzystanie uczenia maszynowego do przewidywania tendencji do agregacji peptydów przeciwdrobnoustrojowych
<b>Temat w języku angielskim</b>	Using machine learning to predict aggregation tendencies of antimicrobial peptides
<b>Opiekun pracy</b>	dr hab. inż. Emilia Lubecka
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Celem pracy jest przeszukanie dostępnych baz danych peptydów przeciwdrobnoustrojowych (Antimicrobial Peptide Database (APD)) pod kątem ich tendencji do agregacji. Podział peptydów na grupy ze względu na sposób agregacji. Stworzenie na podstawie powyższych wyników własnej bazy danych. Opracowanie modelu do przewidywania tendencji do agregacji peptydów przeciwdrobnoustrojowych (i jej rodzaju) z wykorzystaniem stworzonej bazy danych.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Przegląd literatury tematu</li><li>2. Analiza dostępnych baz danych</li><li>3. Stworzenie własnej bazy danych na podstawie istniejących</li><li>4. Dobór metod rozwiązania</li><li>5. Opracowanie optymalnego rozwiązania</li><li>6. Przygotowanie przypadków testowych, które posłużą później do analizy porównawczej wyników prac</li><li>7. Testowanie opracowanego rozwiązania</li><li>8. Prezentacja osiągniętych wyników</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Wang, G., Schmidt, C., Li, X. and Wang, Z. (2026) APD6: The antimicrobial peptide database is expanded to promote research and development by deploying an unprecedented information pipeline. <i>Nucleic Acids Research</i> 54, D363-D374.</li><li>2. Malak Pirtskhalava, Anthony A Armstrong, Maia Grigolava, Mindia Chubinidze, Evgenia Alimbarashvili, Boris Vishnepolsky, Andrei Gabrielian, Alex Rosenthal, Darrell E Hurt, Michael Tartakovsky, DBAASP v3: database of antimicrobial/cytotoxic activity and structure of peptides as a resource for development of new therapeutics, <i>Nucleic Acids Research</i>, Volume 49, Issue D1, 8 January 2021, Pages D288D297.</li><li>3. Gawde U, Chakraborty S, Waghu F H, Barai R S, Khanderkar A, Indraguru R, Shirsat T, Idicula-Thomas S. CAMPR4: a database of natural and synthetic antimicrobial peptides. <i>Nucleic Acids Research</i>, 2023, Vol. 51, Database issue: D377-D383.</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	

## Temat 22

<b>Temat</b>	Zastosowanie uczenia głębokiego do klasyfikacji lądowych form glacialnych z wykorzystaniem danych z numerycznego modelu terenu
<b>Temat w języku angielskim</b>	Application of deep learning for classification of glacial landforms using Digital Terrain Model data
<b>Opiekun pracy</b>	dr hab. inż. Zbigniew Łubniewski
<b>Konsultant pracy</b>	
<b>Cel pracy</b>	Na podstawie rzeźby terenu w obszarze polodowcowym specjalista geolog jest w stanie wyróżnić i oznaczyć występujące formy glacialne, np. moreny czołowe i denne, pola sandrowe, pradoliny, zastoiska, stożki napływowe itp. Metody automatycznej detekcji i klasyfikacji takich form, jak też i innych form morfologicznych, na podstawie numerycznego modelu terenu (Digital Terrain Model - DTM) charakteryzują się dużym potencjałem rozwoju. Celem pracy jest opracowanie oraz i zweryfikowanie działania metod automatycznej klasyfikacji takich form polodowcowych w terenie na podstawie danych DTM. Przewiduje się wykorzystanie metod opartych na głębokich sieciach neuronowych, np. sieciach splotowych, transformerach wizyjnych itp. oraz ich modyfikacjach, jak np. Pyramid Vision Transformer. Alternatywnie możliwe jest zastosowanie bardziej klasycznych metod klasyfikacji i uczenia maszynowego wraz z obliczaniem szeregu parametrów charakteryzujących lokalnie rzeźbę terenu.
<b>Zadania</b>	<ol style="list-style-type: none"><li>1. Analiza aktualnego stanu wiedzy w zakresie automatycznej klasyfikacji lądowych form glacialnych</li><li>2. Opracowanie i implementacja algorytmów klasyfikacji</li><li>3. Analiza i dyskusja wyników</li></ol>
<b>Literatura</b>	<ol style="list-style-type: none"><li>1. Ł. Janowski, K. Tylmann, K. Trzcińska, S. Rudowski, J. Tęgowski, Exploration of glacial landforms by object-based image analysis and spectral parameters of digital elevation model. IEEE Transactions on Geoscience and Remote Sensing , vol. 60, pp. 1-17</li><li>2. P. Nadachowski, Z. Łubniewski, A. Malecha-Łysakowska, K. Trzcińska, R. Wróblewski, J. Tęgowski, Classification of Glacial and Fluvio-glacial Landforms by Convolutional Neural Networks Using a Digital Elevation Model, IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2024, 17, 18548-18565; <a href="https://dx.doi.org/10.1109/JSTARS.2024.3470253">https://dx.doi.org/10.1109/JSTARS.2024.3470253</a></li><li>3. P. Nadachowski , Z. Łubniewski , K. Trzcińska , R. Wróblewski, J. Tęgowski, Leveraging vision transformer architectures for glacial and fluvio-glacial landform classification, International Journal of Digital Earth, 2026, 19:1, 2644685; <a href="https://doi.org/10.1080/17538947.2026.2644685">https://doi.org/10.1080/17538947.2026.2644685</a></li><li>4. S. Raschka, V. Mirjalili, Python Machine Learning. Packt Publishing, 2019</li><li>5. M. Elgendy, Deep learning for vision systems. Manning Publications, 2020</li><li>6. J. Krohn, G. Beyleveld, A. Bassens, Uczenie głębokie i sztuczna inteligencja. Interaktywny przewodnik ilustrowany. Wydawnictwo Helion, 2021</li><li>7. Materiały dostępne u opiekuna</li></ol>
<b>Proponowana liczba osób</b>	1
<b>Informacje dodatkowe</b>	