

Autoreferat

dr n. med. Konrad Pieszko

Katedra Kardiologii Interwencyjnej i Kardiochirurgii Uniwersytetu Zielonogórskiego

Spis treści

SPIS TREŚCI.....	2
I. IMIĘ I NAZWISKO: KONRAD PIESZKO	4
II. POSIADANE DYPLOMY, STOPNIE NAUKOWE LUB ARTYSTYCZNE	4
III. INFORMACJA O DOTYCHCZASOWYM ZATRUDNIENIU W JEDNOSTKACH NAUKOWYCH	4
IV. OMÓWIENIE OSIĄGNIĘĆ, O KTÓRYCH MOWA W ART. 219 UST. 1 PKT. 2 USTAWY Z DNIA 20 LIPCA 2018 R. PRAWO O SZKOLNICTWIE WYŻSZYM I NAUCE (DZ. U. Z 2021 R. POZ. 478 Z PÓŻN. ZM.).....	5
V. INFORMACJA O WYKAZYWANIU SIĘ ISTOTNĄ AKTYWNOŚCIĄ NAUKOWĄ REALIZOWANĄ W WIĘCEJ NIŻ JEDNEJ UCZELNI LUB INSTYTUCJI NAUKOWEJ W SZCZEGÓLNOŚCI ZAGRANICZNEJ	19
A. WSPÓŁPRACA Z INSTYTUCJAMI NAUKOWYMI	19
VI. PODSUMOWANIE DOROBKU NAUKOWEGO NA PODSTAWIE ANALIZY BIBLIOMETRYCZNEJ	20
C. OPIS AKTYWNOŚCI NAUKOWEJ POZA OSIĄGNIĘCIEM, O KTÓRYM MOWA W ART. 219 UST. 1 PKT. 2 USTAWY.....	20
1. ZASTOSOWANIE METOD UCZENIA MASZYNOWEGO W DIAGNOSTYCE I PROGNOZOWANIU RYZYKA W OSTRYCH ZESPÓŁACH WIEŃCOWYCH	20
Wybrane publikacje przed osiągnięciem stopnia Doktora Nauk Medycznych.....	20
Podsumowanie kierunku badań.....	20
2. SZTUCZNA INTELIGENCJA W KARDIOLOGII – PRZEGLĄD I KIERUNKI ROZWOJU	21
Publikacje przed osiągnięciem stopnia Doktora Nauk Medycznych:.....	21
Publikacje po osiągnięciu stopnia doktora nauk medycznych:	21
Podsumowanie kierunku badań.....	22
3. ZAAWANSOWANA ANALIZA DANYCH Z BADAŃ OBRAZOWYCH SERCA W OCENIE RYZYKA SERCOWO-NACZYNIOWEGO	22
4. MARKERY STANU ZAPALNEGO W STRATYFIKACJI RYZYKA CHOROÓB SERCOWO-NACZYNIOWYCH	24
VI. INFORMACJA O OSIĄGNIĘCIACH DYDAKTYCZNYCH, ORGANIZACYJNYCH ORAZ POPULARYZUJĄCYCH NAUKĘ	25
A. DZIAŁALNOŚĆ DYDAKTYCZNA.....	25
B. DZIAŁALNOŚĆ ORGANIZACYJNA	26
VII. INNE INFORMACJE DOTYCZĄCE KARIERY ZAWODOWEJ	26
A. STAŻE ZAGRANICZNE	26

B. WYSTĄPIENIA NA ZAPROSZENIE:	27
C. CZŁONKOSTWO W MIĘDZYNARODOWYCH LUB KRAJOWYCH ORGANIZACJACH I TOWARZYSTWACH NAUKOWYCH WRAZ Z INFORMACJĄ O PEŁNIONYCH FUNKCJACH	27
D. NAGRODY I WYRÓŻNIENIA	28
E. FUNKCJA RECENZENTA W CZASOPISMACH Z LISTY JCR	28
VIII. WYKAZ UŻYTYCH SKRÓTÓW I AKRONIMÓW:.....	29

I. Imię i nazwisko: Konrad Pieszko

II. Posiadane dyplomy, stopnie naukowe lub artystyczne

- **2021** – Stopień doktora nauk medycznych z wyróżnieniem
Uniwersytet Medyczny im. Karola Marcinkowskiego w Poznaniu
Tytuł rozprawy: "Ocena czynników ryzyka oraz rokowania pacjentów z chorobami sercowo-naczyniowymi przy wykorzystaniu metod uczenia maszynowego."
(na podstawie cyklu publikacji, obroniona z wyróżnieniem, promotor: prof. dr hab. Paweł Burchardt)
- **2008-2015** Dyplom lekarza, Wydział Lekarski, Uniwersytet Medyczny we Wrocławiu
- **2009-2011** Studia inżynierskie (Automatyka i Robotyka) Wydział Elektroniki, Politechnika Wrocławska,
- **2022** – uzyskanie dyplomu lekarza specjalisty w dziedzinie Kardiologii;
- **od stycznia 2024** - w trakcie specjalizacji lekarskiej z Radiologii i Diagnostyki Obrazowej

III. Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych

- **Listopad 2024 – sierpień 2025** - Advanced cardiac imaging research fellow, Sant Pau Research Institute, Hospital de la Santa Creu i Sant Pau, Barcelona, Hiszpania.
- **2025 - obecnie** Dolnośląskie Centrum Chorób serca MEDINET - członek zespołu ekspertów, współautor protokołu badania klinicznego OPTIMUS-CABG nr 2024/ABM/01/00016 (ABM, 2025)
- **2018 – obecnie** – Adiunkt
Klinika Kardiologii, Katedra Kardiologii Interwencyjnej i Kardiochirurgii, Collegium Medicum, Uniwersytet Zielonogórski
- **2023 – obecnie** – Współbadacz (wykonawca) w grantie OPUS 2021/41/B/NZ5/02630, główny badacz: dr hab. n. med. Jacek Kwieciński, Narodowy Instytut Kardiologii im. Stefana Wyszyńskiego, Warszawa
- **Luty 2021 – Grudzień 2021** – Badacz (postdoctoral research scientist) - Cedars Sinai Medical Center, Los Angeles, USA
- **2021 – 2024** – Współbadacz, Narodowy Instytut Kardiologii im. Stefana Wyszyńskiego, Warszawa (członek zespołu projektowego: ECBIG – EUROPEJSKIE CENTRUM BIOINFORMATYKI I GENOMIKI - MOSAIC)
- **2016 – 2024** – Lekarz asystent w Klinicznym Oddziale Kardiologii
Wielospecjalistyczny Szpital w Nowej Soli, Nowa Sól

IV. Omówienie osiągnięć, o których mowa w art. 219 ust. 1 pkt. 2 ustawy z dnia 20 lipca 2018 r. Prawo o szkolnictwie wyższym i nauce (Dz. U. z 2021 r. poz. 478 z późn. zm.).

Cykl powiązanych tematycznie publikacji pod tytułem:

„Zastosowanie metod sztucznej inteligencji w odniesieniu do badań obrazowych w diagnostyce i prognozowaniu ryzyka u pacjentów z chorobami sercowo-naczyniowymi”

Cykl obejmuje łącznie 4 publikacje oryginalne, w tym 2 prace opublikowane jako wyłączny pierwszy autor i dwie jako równorzędny pierwszy autor („equal contribution as the first author”).

Sumaryczny współczynnik Impact Factor osiągnięcia naukowego: **79**

Sumaryczna punktacja MEiN osiągnięcia naukowego: **700**

Wszystkie wymienione prace zostały opublikowane po uzyskaniu stopnia doktora nauk medycznych.

A. Wykaz prac naukowych wchodzących w skład osiągnięcia naukowego

Publikacja 1.

Pieszko K, Shanbhag AD, Lemley M, Hyun M, Van Krieking S, Otaki Y, Liang JX, Berman DS, Dey D, Slomka PJ. Reproducibility of quantitative coronary calcium scoring from PET/CT attenuation maps: comparison to ECG-gated CT scans. Eur J Nucl Med Mol Imaging. 2022 Oct;49(12):4122-4132. doi: 10.1007/s00259-022-05866-x,

IF 9.100; MEiN 140; Liczba cytowań (Web of Science): 19

Mój udział w powstaniu publikacji polegał na opracowaniu koncepcji i założeń analiz, analizie piśmiennictwa, zebraniu i ujednoliceniu danych, przeprowadzeniu całości analiz statystycznych, interpretacji wyników (rola wiodąca), przygotowaniu wszystkich tabel i rycin, napisaniu całości manuskryptu.

Publikacja 2.

Pieszko K*, Shanbhag AD*, Killekar A, Miller RJH, Lemley M, Otaki Y, Singh A, Kwiecinski J, Gransar H, Van Krieking SD, Kavanagh PB, Miller EJ, Bateman T, Liang JX, Berman DS, Dey D, Slomka PJ. Deep Learning of Coronary Calcium Scores From PET/CT Attenuation Maps Accurately Predicts Adverse Cardiovascular Events. *JACC Cardiovasc Imaging*. 2023 May;16(5):675-687. doi:10.1016/j.jcmg.2022.06.006,

IF 12.8; MEiN 200; Liczba cytowań (Web of Science): 33

*równorzędny pierwszy autor

Mój udział w powstaniu publikacji polegał na opracowaniu koncepcji i założeń analiz (rola wiodąca), analizie piśmiennictwa, zebraniu i ujednoliceniu danych, zaprojektowaniu i przeprowadzeniu analiz statystycznych, interpretacji wyników (rola wiodąca), przygotowaniu wszystkich tabel i rycin, napisaniu całości manuskryptu. Rola równorzędnego pierwszego autora AD Shanbhag polegała na opracowaniu architektury sieci neuronowej oraz implementacji eksperymentów mających na celu optymalizację tej architektury oraz post-processingu masek segmentacji w celu otrzymania ostatecznych automatycznie obliczonych wartości calcium score.

Publikacja 3.

Miller RJH*, **Pieszko K*** Shanbhag AD, Feher A, Lemley M, Killekar A, Kavanagh PB, Van Krieking SD, Liang JX, Huang C, Miller EJ, Bateman T, Berman DS, Dey D, Slomka PJ. Deep Learning Coronary Artery Calcium Scores from SPECT/CT Attenuation Maps Improve Prediction of Major Adverse Cardiac Events. *J Nucl Med*. 2023 Apr;64(4):652-658. doi: 10.2967/jnumed.122.264423.

IF 9.1 ; MEiN 140; Liczba cytowań (Web of Science): 30

*równorzędny pierwszy autor

W publikacji tej występuję jako **równorzędny pierwszy autor** z profesorem Robertem JH Millerem z University of Calgary, Kanada. Mój udział w powstaniu publikacji polegał na adaptacji modelu sztucznej sieci neuronowej do automatycznej segmentacji zwapnień w obrazach TK serca bez kontrastu wykonanych w celu korekcji atenuacji obrazów SPECT a następnie na zwalidowaniu modelu oraz opracowaniu wyników w formie tabelarycznej i graficznej i przeprowadzeniu analiz statystycznych. Rola profesora Millera polegała na wykonaniu pierwszego draftu manuskryptu w oparciu o przygotowane wyniki. Brałem aktywny udział we wszystkich etapach przygotowania publikacji, w tym w przygotowaniu rycin, tabel oraz w rewizjach manuskryptu.

Publikacja 4.

Pieszko K, Shanbhag AD, Singh A, Hauser MT, Miller RJH, Liang JX, Motwani M, Kwieciński J, Sharir T, Einstein AJ, Fish MB, Ruddy TD, Kaufmann PA, Sinusas AJ, Miller EJ, Bateman TM, Dorbala S, Di Carli M, Berman DS, Dey D, Slomka PJ. Time and event-specific deep learning for personalized risk assessment after cardiac perfusion imaging. *NPJ Digit Med*. 2023 May 1;6(1):78. doi: 10.1038/s41746-023-00806-x.

IF 12,4; MEiN 20; Liczba cytowań (Web of Science): 14

Mój udział w powstaniu publikacji polegał na opracowaniu nowatorskiej koncepcji i założeń analiz (rola wiodąca) dotyczących dynamicznej, spersonalizowanej i zależnej od czasu oceny ryzyka. Byłem odpowiedzialny za implementację, trenowanie oraz walidację modeli głębokiego uczenia na wielkoskalowych, wielośrodkowych zbiorach danych. Przeprowadziłem całość zaawansowanych analiz statystycznych, w tym porównanie skuteczności prognostycznej modelu z istniejącymi metodami klinicznymi. Przygotowałem wszystkie ryciny i tabele w manuskrypcie, włączając w to złożone wizualizacje krzywych ryzyka w czasie oraz wykresy wyjaśnialności modelu (tzw. *waterfall plots* – generowane dynamicznie dla każdego wyniku ryciny, które wyjaśniają w jaki sposób poszczególne dane wejściowe przyczyniły się do ostatecznego wyniku działania modelu). Moja rola obejmowała również interpretację wyników (rola wiodąca), która doprowadziła do sformułowania wniosków, oraz napisanie całości manuskryptu.

Publikacja 5.

Pieszko K, Hiczkiewicz J, Łojewska K, Uziębło-Życzkowska B, Krzesiński P, Gawałko M, Budnik M, Starzyk K, Woźakowska-Kapłon B, Daniłowicz-Szymanowicz L, Kaufmann D, Wójcik M, Błaszczyk R, Mizia-Stec K, Wybraniec M, Kosmalska K, Fijałkowski M, Szymańska A, Dłużniewski M, Kucio M, Haberk M, Kupczyńska K, Michalski B, Tomaszuk-Kazberuk A, Wilk-Śledziwska K, Wachnicka-Truty R, Koziński M, Kwieciński J, Wolny R, Kowalik E, Kolasa I, Jurek A, Budzianowski J, Burchardt P, Kapłon-Cieślicka A, Słomka PJ. Artificial intelligence in detecting left atrial appendage thrombus by transthoracic echocardiography and clinical features: the Left Atrial Thrombus on Transoesophageal Echocardiography (LATTEE) registry. Eur Heart J. 2024 Jan 7;45(1):32-41. doi: 10.1093/eurheartj/ehad431,

IF 35,6; MEiN 200; Liczba cytowań (Web of Science): 19

Mój udział w powstaniu publikacji polegał na opracowaniu koncepcji i założeń analiz (rola wiodąca), przygotowaniu zbioru danych pod kątem analiz z wykorzystaniem uczenia maszynowego, impementacji modeli uczenia maszynowego i przeprowadzeniu eksperymentów mających na celu optymalizację oraz wybór najlepszego modelu, przeprowadzeniu testów modelu oraz analiz statystycznych, wykonaniu wszystkich tabel oraz rycin w manuskrypcie, interpretacji wyników (rola wiodąca), napisaniu całości manuskryptu. Wykonałem również osobiście aplikację on-line pozwalającą na praktyczne wykorzystanie modelu, dostępną pod adresem: <https://huggingface.co/spaces/konradpieszko/LAT-AI>

B. Omówienie osiągnięcia naukowego

Wprowadzenie

Choroby sercowo-naczyniowe (ChSN) pozostają główną przyczyną zachorowalności i umieralności na świecie. Skuteczne strategie diagnostyczne i prognostyczne są kluczowe dla poprawy wyników leczenia. Tradycyjne metody oceny ryzyka, oparte na parametrach klinicznych i prostych badaniach laboratoryjnych, często okazują się niewystarczające. W ostatnich latach obserwuje się dynamiczny rozwój metod sztucznej inteligencji (SI), które umożliwiają analizę dużych zbiorów danych medycznych z niespotykaną dotąd dokładnością i szybkością. Metody te znajdują coraz szersze zastosowanie w kardiologii, otwierając nowe możliwości w zakresie diagnostyki, stratyfikacji ryzyka i planowania terapii.

Cel główny osiągnięcia naukowego

Głównym celem cyklu publikacji stanowiącego osiągnięcie naukowe jest opracowanie i walidacja nowych modeli prognostycznych opartych na metodach sztucznej inteligencji, które mogą poprawić identyfikację pacjentów z podwyższonym ryzykiem zdarzeń sercowo-naczyniowych. Badania koncentrują się na wykorzystaniu danych z badań obrazowych (tomografia komputerowa, echokardiografia) oraz danych klinicznych w celu stworzenia narzędzi wspomagających decyzje kliniczne.

Skrócony opis osiągnięcia naukowego

Publikacje 1-5 stanowią efekt mojej współpracy z Cedars-Sinai Medical Center w Los Angeles oraz innymi ośrodkami naukowymi w Polsce i na świecie która została nawiązana po obronie stopnia doktora nauk medycznych, w szczególności w trakcie wyjazdu na stypendium im. Profesora Walczaka sfinansowane przez Narodową Agencję Wymiany Akademickiej (NAWA). W ramach prowadzonych badań wykorzystałem metody uczenia maszynowego, w tym głębokie sieci neuronowe, do analizy danych obrazowych i klinicznych. Prace koncentrują się na następujących obszarach:

- Ocena możliwości wykorzystania niskodawkowej tomografii komputerowej do automatycznej oceny wskaźnika uwapnienia tętnic wieńcowych.
- Opracowanie modeli prognostycznych opartych na sztucznej inteligencji do uzyskania dodatkowych danych prognostycznych (wartości wskaźnika uwapnień calcium score) na podstawie niskodawkowych skanów CT wykonywanych w celach pomocniczych podczas badań perfuzji mięśnia sercowego w celu polepszenia stratyfikacji ryzyka zdarzeń sercowo-naczyniowych.
- Opracowanie i walidacja nowatorskiego, spersonalizowanego modelu ryzyka opartego na głębokim uczeniu, który pozwala na dynamiczną w czasie ocenę prawdopodobieństwa wystąpienia konkretnych zdarzeń sercowo-naczyniowych (zgon, ostry zespół wieńcowy, rewaskularyzacja) na podstawie obrazów perfuzji mięśnia sercowego.
- Stworzenie algorytmu do oceny ryzyka wystąpienia skrzepliny w uszku lewego przedsionka serca na podstawie danych z echokardiografii przezklatkowej oraz danych klinicznych.

Cele publikacji stanowiących osiągnięcie naukowe:

- Analiza inter-reader i inter-scan agreement dla oceny wskaźnika uwapnień tętnic wieńcowych za pomocą standardowej metody i za pomocą niskodawkowej tomografii komputerowej wykonanej w celu korekty atenuacji przy badaniach perfuzji mięśnia sercowego
- Opracowanie i walidacja w skanach PET/CT oraz SPECT/CT metody automatycznej oceny wskaźnika uwapnień tętnic wieńcowych.
- Ocena wartości prognostycznej automatycznie ocenionego wskaźnika uwapnień tętnic wieńcowych i porównanie z metodą standardową.
- Stworzenie i walidacja wyjaśnialnego (explainable) modelu głębokiego uczenia do spersonalizowanej i zależnej od czasu prognozy ryzyka wystąpienia poszczególnych zdarzeń sercowo-naczyniowych, co stanowi krok w kierunku precyzyjnego, zindywidualizowanego poradnictwa dla pacjentów po badaniach obrazowych serca.
- Zastosowanie doświadczeń i wiedzy pozyskanej przy badaniach w oparciu o badania perfuzji mięśnia sercowego do opracowania narzędzia opartego na sztucznej inteligencji do integracji danych klinicznych i echokardiografii przekłatkowej w celu oceny ryzyka wystąpienia skrzepliny w uszku lewego przedsionka serca u pacjentów z migotaniem przedsionków.

C. Szczegółowy opis publikacji stanowiących osiągnięcie naukowe

Publikacja 1.

Reproducibility of quantitative coronary calcium scoring from PET/CT attenuation maps: comparison to ECG-gated CT scans. *Eur J Nucl Med Mol Imaging*. 2022 Oct;49(12):4122-4132.


Celem badania była ocena powtarzalności wyników ilościowej oceny wskaźnika uwapnienia tętnic wieńcowych (CAC) uzyskiwanych z niskodawkowych, niebramkowanych elektrokardiograficznie skanów tomografii komputerowej (CT) wykorzystywanych do korekty atenuacji w badaniach PET/CT serca (CTAC) i porównanie ich z wynikami uzyskanymi ze standardowych, bramkowanych EKG badań CT (standardowy skan Calcium Score)

W badaniu przeanalizowano dane 200 pacjentów, u których wykonano tego samego dnia badania PET/CT serca i bramkowany EKG skan CT. Oceny CAC na podstawie CTAC i standardowych skanów CAC dokonano niezależnie przez dwóch doświadczonych badaczy (**Rycina 1**). Zastosowano standardowe oprogramowanie do ilościowej oceny CAC. Oceniono zgodność między odczytami w 5 kategoriach CAC: 0, 1-10, 11-100, 101-400 i >400.

Wykazano, że wskaźniki zgodności między odczytami (*inter-scan concordance index*) oraz współczynnik Kappa Cohen'a dla dwóch badaczy wyniosły odpowiednio 0.69; 0.75 oraz 0.72; 0.8. Zgodność między odczytami wykonanymi na podstawie standardowego badania CT i CTAC była wysoka. Największe różnice w odczytach obserwowano dla skanów z niskim stopniem zwapnienia (CAC<100).

Wnioski:

- Wyniki badania wskazują, że CAC można wiarygodnie oceniać ilościowo na podstawie niskodawkowych map atenuacji CT wykorzystywanych podczas badań PET/CT serca. Metoda ta charakteryzuje się dobrą zgodnością ze standardowym badaniem CT, chociaż ma nieco mniejszą czułość w wykrywaniu niewielkich zwapnień. Ocena CAC z użyciem CTAC może być wykonywana bez modyfikacji protokołu badania PET i dodatkowej dawki promieniowania, jednak w uwagi na niższą jakość skanów ocena manualna może być bardziej pracochłonna. Dotychczas ocena uwapnień tętnic wieńcowych w tego rodzaju skanach nie była rutynowo praktykowana. Wynik niniejszego badania stanowi teoretyczny fundament pod podjęcie wysiłków związanych z opracowaniem automatycznych metod oceny CAC w badaniu CTAC.



Rycina 1. Schemat badania.

Publikacja 2.

Deep Learning of Coronary Calcium Scores From PET/CT Attenuation Maps Accurately Predicts Adverse Cardiovascular Events. *JACC Cardiovasc Imaging.* 2023 May;16(5):675-687.

Celem badania było opracowanie modelu głębokiego uczenia (DL) zdolnego do automatycznej oceny wskaźnika uwapnienia tętnic wieńcowych (CAC) na podstawie niskodawkowych skanów tomografii komputerowej (CTAC), pozyskiwanych rutynowo podczas badań PET/CT serca oraz ocena wartości predykcyjnej tego modelu w kontekście ryzyka wystąpienia poważnych zdarzeń sercowo-naczyniowych (MACE).


Do treningu modelu wykorzystano dane 9,543 skanów CT, a do testowania 4,331 pacjentów z zewnętrznej kohorty, którzy przeszli badanie PET/CT. W grupie testowej u 2,737 pacjentów dostępne były również wyniki standardowego, bramkowanego EKG badania CT. Oceniono ryzyko MACE w 4 kategoriach CAC (0, 1-100, 101-400, >400) w odniesieniu do ocen uzyskanych przez ekspertów i automatycznych ocen DL.

Model DL osiągnął bardzo krótki czas oceny CAC wynoszący mniej niż 6 sekund na skan. Wartości CAC uzyskane przez model dobrze stratyfikowały ryzyko przyszłych zdarzeń sercowo-naczyniowych (HR do 3.2; $P < 0.001$). Model DL nie był istotnie gorszy w ocenie ryzyka MACE w porównaniu ze standardową oceną CAC dokonywaną przez ekspertów (-0.02; 95% CI: -0.11 do 0.07), **Rycina 2**. Wartość predykcyjna ujemna dla MACE w grupie pacjentów z CAC=0 dla standardowej oceny CAC (85%) i oceny DL (83%) była porównywalna ($P=0.19$).

Wnioski:

- Automatyczna ocena CAC oparta na modelu DL w niestandardowych niskodawkowych skanach CTAC jest porównywalna z oceną manualną dokonywaną przez doświadczonych operatorów manualnie w pełnej jakości standardowych skanach, co zostało potwierdzone porównaniem do standardowego bramkowanego EKG badania CT. Automatyczna analiza skanów CTAC umożliwia szybką i wiarygodną ocenę CAC, nie wymagając modyfikacji protokołu badania PET/CT przy wykorzystaniu skanów CTAC wykonywanych rutynowo jednak dotychczas w praktyce nie wykorzystywanych do tego celu.
- Stratyfikacja ryzyka przez CAC uzyskany automatycznie ze skanów CTAC była równie dobra jak stratyfikacja ryzyka uzyskana z dedykowanych skanów CAC ocenianych przez ekspertów.

Risk stratification by clinical CAC score and DL from CTAC



Rycina 2. Ocena ryzyka sercowo naczyniowego za pomocą sztucznej inteligencji przy wykorzystaniu niskodawkowych skanów do korekcji atenuacji (prawy panel) pozwoliła na stratyfikację ryzyka porównywalną z oceną przez eksperta w oparciu o dedykowany skan (lewy panel).

Publikacja 3.

Deep Learning Coronary Artery Calcium Scores from SPECT/CT Attenuation Maps Improve Prediction of Major Adverse Cardiac Events. *J Nucl Med.* 2023 Apr;64(4):652-658.


Celem badania było opracowanie i ocena modelu głębokiego uczenia (DL) do automatycznej oceny wskaźnika uwapnienia tętnic wieńcowych (CAC) na podstawie niskodawkowych skanów CTAC uzyskanych w trakcie badania SPECT/CT perfuzji mięśnia sercowego i ocena wpływu uwzględnienia wyników oceny CAC na predykcję poważnych niekorzystnych zdarzeń sercowo-naczyniowych (MACE). Badanie to stanowiło kontynuację prac z Publikacji 2 i obejmowało adaptację sztucznej inteligencji do danych z nowej modalności (skany CTAC dla badania SPECT/CT) oraz walidację modelu w populacji pacjentów poddawanych SPECT/CT.

Do oceny modelu DL wykorzystano dane z trzech ośrodków, z czego dane z dwóch ośrodków (6608 skanów) wykorzystano do treningu modelu, a jeden ośrodek (2271 pacjentów) posłużył jako kohorta walidacyjna. Oceniono zgodność ocen CAC dokonywanych przez DL i ekspertów. Oceniono również związek między występowaniem MACE a kategoriami CAC (0, 1-100, 101-400, >400) dla wyników uzyskiwanych automatycznie z użyciem modelu DL i manualnie przez doświadczonych operatorów.

Model DL wykazał doskonałą zgodność z ocenami eksperckimi (κ 0.80) oraz pozwolił na stratyfikację ryzyka niepożądanych zdarzeń sercowo-naczyniowych nie gorzej niż ocena eksperta (**Rycina 3**). Czas oceny CAC był znacząco krótszy dla modelu DL (<2 sekund) niż dla ekspertów (2,5 minuty). W analizie wieloczynnikowej Coxa CAC ocenione przez model było niezależnym czynnikiem ryzyka wystąpienia MACE. Wartość wskaźnika NRI (net reclassification index) dla modelu DL była zbliżona do wartości uzyskanej dla ocen dokonywanych przez ekspertów.

Wnioski:

- Model DL CAC pozwala na uzyskanie *automatycznej, szybkiej i wiarygodnej oceny CAC z wykorzystaniem niskodawkowej tomografii komputerowej* wykonywanej podczas badania SPECT/CT serca. Wyniki oceny CAC za pomocą algorytmu opartego o DL są podobnie jak wyniki standardowej oceny CAC niezależnym czynnikiem ryzyka wystąpienia MACE.



Rycina 3. Krzywe przeżycia Kaplana–Meiera dla MACE. Wzrost kategorii CAC był związany ze wzrostem ryzyka wystąpienia MACE zarówno dla wyników CAC ocenionych przez model głębokiego uczenia (DL), jak i przez ekspertów na mapach osłabienia SPECT/CT.

Publikacja 4.

Time and event-specific deep learning for personalized risk assessment after cardiac perfusion imaging.
NPJ Digit Med. 2023 May 1;6(1):78.

Dotychczasowe modele prognostyczne w kardiologii najczęściej ograniczają się do oceny ogólnego ryzyka wystąpienia złożonego punktu końcowego w stałym, arbitralnie przyjętym horyzoncie czasowym. Takie podejście nie pozwala na precyzyjne, zindywidualizowane poradnictwo, które uwzględniałoby dynamicznie zmieniające się w czasie ryzyko wystąpienia konkretnych zdarzeń, takich jak zgon, ostry zespół wieńcowy (OZW) czy konieczność rewaskularyzacji.


Celem niniejszego badania było opracowanie i walidacja wyjaśnialnego (explainable) modelu głębokiego uczenia, zdolnego do przewidywania spersonalizowanego ryzyka dla trzech kluczowych zdarzeń sercowo-naczyniowych w dowolnym punkcie czasowym po badaniu perfuzyjnym serca.

Model został wytrenowany na ogromnej kohorcie 20 418 pacjentów, a następnie poddany rygorystycznej walidacji zewnętrznej na danych z trzech niezależnych ośrodków (n=13 988). Do budowy modelu wykorzystano dane obrazowe z badań perfuzji mięśnia sercowego (mapy polarne) oraz 15 kluczowych cech klinicznych. Oceniono zdolność modelu do przewidywania ryzyka zgonu z jakiegokolwiek przyczyny, OZW oraz rewaskularyzacji w perspektywie krótko- i długoterminowej. Zastosowano również techniki wyjaśnialnej AI (tzw. wykresy wodospadowe, waterfall plots), aby zwizualizować, które czynniki w największym stopniu wpłynęły na prognozę dla konkretnego pacjenta.

Model wykazał wysoką skuteczność, szczególnie w prognozie krótkoterminowej – w ciągu pierwszych 6 miesięcy po badaniu uśrednione pole pod krzywą ROC (cAUC) dla OZW i zgonu wyniosło odpowiednio 0.76 i 0.78. Model przewyższał tradycyjne wskaźniki perfuzyjne we wszystkich punktach czasowych, a jego przewaga rosła wraz z upływem czasu. Co najważniejsze, opracowane narzędzie pozwala generować indywidualne krzywe prawdopodobieństwa zdarzeń w czasie, co umożliwia spersonalizowaną ocenę ryzyka i może wspierać lekarza oraz pacjenta w procesie podejmowania wspólnych decyzji terapeutycznych (**Rycina 4**).

Wnioski:

- Możliwe jest stworzenie wysoce skutecznego modelu prognostycznego, który przewiduje nie tylko *czy*, ale również *kiedy i jakie* zdarzenie sercowo-naczyniowe może wystąpić u danego pacjenta.
- Zastosowanie wyjaśnialnej sztucznej inteligencji pozwala na identyfikację i prezentację kluczowych, modyfikowalnych czynników ryzyka, co otwiera drogę do medycyny w pełni spersonalizowanej, w której ocena zagrożenia jest dynamiczna i dostosowana do indywidualnego profilu pacjenta. Ta praca stanowi zwieńczenie cyklu, przenosząc analizę ryzyka z oceny statycznych biomarkerów (jak CAC) na dynamiczne, spersonalizowane prognozowanie kliniczne.



Rycina 4. Model głębokiego uczenia do analizy czasu do zdarzenia został wytrenowany (pael górny) z wykorzystaniem danych z 5 ośrodków rejestru REFINE SPECT ($n = 20\,401$), następnie przetestowany wewnątrz w schemacie 10-krotnej walidacji krzyżowej oraz przetestowany w 3 zewnętrznych ośrodkach ($n = 13\,988$) (panel po prawej); Model 'time-to-event' wykorzystuje jako dane wejściowe 5 map polarnych SPECT oraz 15 cech klinicznych (środkowy panel), a następnie przewiduje zależne od czasu prawdopodobieństwo zgonu (pomarańczowa linia), zespołu wieńcowego (zielona linia, ACS) oraz rewaskularyzacji (niebieska linia); Skuteczność modelu (dolny lewy panel) oceniano za pomocą skumulowanego, dynamicznego pola pod krzywą ROC (cAUC). Czerwona linia przedstawia model czasu do zdarzenia, natomiast niebieska linia odnosi się do nieprawidłowości perfuzji. Wyjaśnienie predykcji przedstawiono w formie wykresu wodospadowego, gdzie niebieskie strzałki oznaczają cechy zmniejszające ryzyko, a czerwone strzałki – cechy je zwiększające (dolny prawy panel).

Publikacja 5.

Artificial intelligence in detecting left atrial appendage thrombus by transthoracic echocardiography and clinical features: the Left Atrial Thrombus on Transoesophageal Echocardiography (LATTEE) registry. *Eur Heart J.* 2024 Jan 7;45(1):32-41.

Badanie to było owocem współpracy nawiązanej przez członków Klubu 30 Polskiego Towarzystwa Kardiologicznego. Rejestr LATTEE (Left Atrial Thrombus on Transoesophageal Echocardiography) powstał z inicjatyw i pod kierownictwem prof. dr hab. Agnieszki Kapłon-Cieślickiej. W tym obserwacyjnym prospektywnym rejestrze zbierano dane kliniczne, dane dotyczące aktualnej terapii oraz pomiary z echokardiografii przezklatkowej u pacjentów poddawanych badaniu przezprzełykowemu USG serca w celu wykluczenia obecności skrzepliny w uszku lewego przedsionka przed ablacją lub kardiowersją. Rejestr ten dostarczył m in. dowodów na to, że duży odsetek pacjentów pomimo stosowania doustnej terapii przeciwkrzepliwej ma stwierdzaną obecność skrzepliny w uszku lewego przedsionka serca.

Celem przeprowadzonego przeze mnie na bazie danych z rejestru LATTEE badania było opracowanie modelu uczenia maszynowego (LAT-AI) do przewidywania obecności skrzepliny w uszku lewego przedsionka (LAT) na podstawie danych klinicznych i parametrów uzyskanych podczas echokardiografii przezklatkowej (TTE). Model ten miał mieć za zadanie wyselekcjonowanie pacjentów, którzy mają niskie ryzyko wystąpienia skrzepliny w LAA i przez to mogą mieć wykonany zabieg ablacji lub kardiowersji bez wcześniejszego wykluczania obecności skrzepliny w uszku lewego przedsionka.

Model LAT-AI trenowano na danych z 12 ośrodków ($n=2,827$) i testowano w 2 ośrodkach na pacjentach będących w trakcie przewlekłej antykoagulacji ($n=1,284$). Oceniono również czy przyjęcie określonej wartości odcięcia dla modelu LAT-AI może pozwolić zidentyfikować grupę pacjentów, u których nie ma konieczności wykonywania TOE. Porównano wartość predykcijną modelu LAT-AI z frakcją wyrzutową lewej komory (LVEF) oraz skalą CHA2DS2-VASc.


W grupie testowej LAT wykryto u 5.5% pacjentów. Model LAT-AI osiągnął wartość AUC równą 0.85 (95% CI: 0.82-0.89), przewyższając wskaźniki LVEF (0.81, 95% CI 0.76-0.86, $P < 0.0001$) i skali CHA2DS2-VASc (0.69, 95% CI: 0.63-0.7, $P < 0.0001$). Zastosowanie modelu LAT-AI do podejmowania decyzji o konieczności wykonania TOE mogłoby pozwolić uniknąć tej procedury u około 40% pacjentów w grupie testowej będących w trakcie przewlekłej antykoagulacji.

Model LAT-AI został zaimplementowany w postaci aplikacji online (nagrodzonej w sesji „Digital Cardio Area” podczas kongresu Polskiego Towarzystwa Kardiologicznego w Poznaniu za najlepsze wdrożenie systemu medycyny cyfrowej). Aplikacja ta pozwala w dynamiczny sposób wygenerować predykcje modelu wraz z wykresami wodospadowymi (waterfall plots), które pozwalają na wyjaśnienie konkretnej predykcji modelu (Rycina 5).

Wnioski:

- Model LAT-AI pozwala na dokładne przewidywanie obecności skrzepliny w uszku lewego przedsionka. Zastosowanie protokołu opartego na LAT-AI mogłoby pomóc w podejmowaniu decyzji o konieczności wykonywania TOE u pacjentów będących w trakcie przewlekłej antykoagulacji.

- Mój wkład w powstanie publikacji obejmował opracowanie koncepcji, zebranie i ujednolicenie danych, zaprojektowanie i przeprowadzenie analiz z zastosowaniem metod uczenia maszynowego, interpretację wyników (rola wiodąca), nadzór nad pracą zespołu badawczego oraz napisanie całości manuskryptu.



Rycina 5. Przykłady ilustrujące znaczenie poszczególnych cech w dwóch konkretnych przypadkach pacjentów. Takie wykresy mogą być przedstawione lekarzowi wraz z wynikiem podsumowującym. Wykres zaczyna się u góry od średniego wyniku dla całej populacji (przerwana linia pionowa) i kończy na dole końcowym wynikiem przewidywania. Czerwone strzałki skierowane w prawo wskazują, że dana cecha zwiększa ryzyko zakrzepu w uszku lewego przedsionka, natomiast niebieskie strzałki skierowane w lewo oznaczają, że dana cecha zmniejsza to ryzyko. Wykonanie przezprętkowego badania echokardiograficznego przed kardiowersją lub ablacją cewnikową jest zalecane u pacjentów z wysokimi wynikami (różowy obszar po prawej stronie) i może być pominięte przy niskich wynikach (niebieski obszar po lewej stronie). A i B – pacjent z wynikiem CHA₂DS₂-VASc równym 4, ale niskim ryzykiem zakrzepu w uszku lewego przedsionka (LAT), co wskazują wyniki LAT-AI (A) i LAT-AI reduced (B); brak zakrzepu w TOE. C i D – pacjent z obecnością LAT w TOE, u którego zarówno wynik LAT-AI (C), jak i LAT-AI reduced (D) wskazywały na wysokie ryzyko zakrzepu.

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

A. Współpraca z instytucjami naukowymi

Moja działalność naukowa jest osadzona w szerokiej współpracy z wiodącymi ośrodkami badawczymi w Polsce i na świecie. Po ukończeniu studiów na Uniwersytecie Medycznym we Wrocławiu i studiów inżynierskich na Politechnice Wrocławskiej, rozpocząłem pracę nad wykorzystaniem sztucznej inteligencji w medycynie, co stało się osią moich dalszych działań naukowych.

W ramach pracy doktorskiej na Uniwersytecie Medycznym im. Karola Marcinkowskiego w Poznaniu (2018-2021) opracowałem nowe algorytmy prognostyczne dla pacjentów z ostrym zespołem wieńcowym, wykorzystując metody uczenia maszynowego (publikacje przed uzyskaniem stopnia doktora, opisane w sekcji VI.C). Zdobyte wówczas doświadczenia w zastosowaniu uczenia maszynowego wykorzystałem do opracowania analiz dla Goethe University Frankfurt, Frankfurt, Germany, co zaowocowało wspólnymi badaniami dotyczącymi zastosowania markerów zapalnych do przewidywania wyników odległych po wszczepieniu przezskórnej protezy zastawki aortalnej (Hoffman et al., ESC Heart Failure 2020).

Po uzyskaniu stopnia doktora, otrzymałem stypendium im. Profesora Walczaka, co umożliwiło mi odbycie 10-miesięcznego stażu naukowego (luty-grudzień 2021) w Cedars Sinai Medical Center w Los Angeles, USA, w Division of Artificial Intelligence in Medicine pod kierownictwem prof. Piotra Słomki. W trakcie stażu brałem udział w projektach związanych z wykorzystaniem sztucznej inteligencji w analizie obrazowych danych medycznych (tomografia komputerowa serca, badania nuklearne serca). W tym czasie *zdobyłem unikalne doświadczenie w tworzeniu i walidacji algorytmów głębokiego uczenia* i analizy danych obrazowych w dużych kohortach pacjentów, co zaowocowało współautorstwem 8 publikacji (w tym 4 jako pierwszy lub równorzędny pierwszy autor) o łącznym IF 100.45 (w tym jako pierwszy lub równorzędny pierwszy autor: 49.5) (publikacje 1-4 będące częścią dorobku habilitacyjnego). Po zakończeniu stażu otrzymałem propozycję pracy na etacie badawczym w Cedars Sinai Medical Center, co zaowocowało przedłużeniem mojego pobytu w USA o kolejne 4 miesiące. Współpracę z ośrodkiem Cedars Sinai kontynuuję po dziś dzień co owocuje niedawnymi wspólnymi publikacjami (Zhou J, et al. *European Heart Journal - Cardiovascular Imaging*. 2025, Michałowska AM, et al. *Journal of Nuclear Medicine*. 2024)

Po powrocie do Polski rozpocząłem pracę jako adiunkt w Klinice Kardiologii Collegium Medicum Uniwersytetu Zielonogórskiego, gdzie prowadzę działalność dydaktyczną i naukową. Zainicjowałem i jestem opiekunem dwóch studenckich kół naukowych (Kardiologii Interwencyjnej oraz Sztucznej Inteligencji w Medycynie), gdzie *staram się przekazywać swoje doświadczenia młodszemu pokoleniu lekarzy i naukowców*. Uczestniczę również w projektach naukowych realizowanych przez Narodowy Instytut Kardiologii im Kardynała Wyszyńskiego w Warszawie w roli wykonawcy w projektach OPUS nr 2021/41/B/NZ5/02630 oraz ECBIG – EUROPEJSKIE CENTRUM BIOINFORMATYKI I GENOMIKI – MOSAIC.

Aktywnie współpracuję z licznymi ośrodkami w Polsce, *biorąc udział w projektach badawczych z zakresu kardiologii interwencyjnej oraz echokardiografii*. Zwieńczeniem współpracy z 13 polskimi ośrodkami akademickimi w ramach rejestru LATTEE było powstanie i opublikowanie badania w European Heart Journal (publikacja 5 stanowiąca część dorobku habilitacyjnego). Praca ta mogła powstać dzięki wykorzystaniu

doświadczenia w wykorzystaniu metodologii machine learning nabytego podczas stażu w Los Angeles danymi pozyskanymi w wyniku współpracy międzyośrodkowej.

Obecnie przebywam na 6-miesięcznym stażu naukowym w Sant Pau Research Institute w Barcelonie, gdzie *pogłębiam swoją wiedzę kliniczną w zakresie zaawansowanych technik obrazowania serca i testuję modele opracowane w ramach grantu SONATA NCN.*

VI. Podsumowanie dorobku naukowego na podstawie analizy bibliometrycznej

Podsumowanie danych bibliometrycznych – łącznie:

- Impact Factor: **240.409 (przed doktoratem 29.679, po doktoracie 210.73)**
- Punktacja MEiN: 3400 (przed doktoratem 745, po doktoracie 2655)
- Liczba cytowań (bez autocytowań): 665
- Indeks Hirsha: 14

C. Opis aktywności naukowej poza osiągnięciem, o którym mowa w art. 219 ust. 1 pkt. 2 ustawy

Poniżej podsumowuję wybrane prace z głównych obszarów moich zainteresowań naukowych. Pełna lista publikacji została załączona w Wykazie Osiągnięć:

1. Zastosowanie metod uczenia maszynowego w diagnostyce i prognozowaniu ryzyka w ostrych zespołach wieńcowych

Wybrane publikacje przed osiągnięciem stopnia Doktora Nauk Medycznych

1.1. Pieszko K, Hiczkiewicz J, Budzianowski P, Rzeźniczak J, Budzianowski J, Błaszczczyński J, Słowiński R, Burchardt P. Machine-learned models using hematological inflammation markers in the prediction of short-term acute coronary syndrome outcomes. *J Transl Med.* 2018;16(1):334. doi: 10.1186/s12967-018-1702-5, **IF 4.098; MEiN 100; Liczba cytowań (Web of Science): 14**

1.2. Pieszko K, Hiczkiewicz J, Budzianowski P, Budzianowski J, Rzeźniczak J, Pieszko K, Burchardt P. Predicting Long-Term Mortality after Acute Coronary Syndrome Using Machine Learning Techniques and Hematological Markers. *Dis Markers.* 2019;2019:9056402. doi: 10.1155/2019/9056402, **IF 2.738; MEiN 70; Liczba cytowań (Web of Science): 27**

Podsumowanie kierunku badań

Choroba wieńcowa (CAD) jest schorzeniem o podłożu miażdżycowym, w którym przewlekły proces zapalny w śródbłonku naczyń przyczynia się do powstawania blaszek miażdżycowych i ich potencjalnej destabilizacji, co może prowadzić do ostrego zespołu wieńcowego (ACS). Mimo zaawansowanych strategii leczenia inwazyjnego, istotna część pacjentów po przebytych ACS doświadcza powikłań, takich jak

niewydolność serca czy kolejne zdarzenia sercowo-naczyniowe. Wykazano, że biomarkery stanu zapalnego mogą odgrywać kluczową rolę w prognozowaniu rokowania pacjentów, co podkreśla konieczność opracowania precyzyjnych narzędzi identyfikujących osoby o najwyższym ryzyku niepoomyślnych wyników klinicznych.

Dynamiczny rozwój metod sztucznej inteligencji (AI), w tym uczenia maszynowego, otwiera nowe możliwości w analizie dużych zbiorów danych medycznych i wspomaganiu procesów decyzyjnych. W ramach niniejszej pracy przeprowadzono badania mające na celu ocenę skuteczności algorytmów AI w prognozowaniu rokowania pacjentów z ACS na podstawie retrospektywnych danych obejmujących 6769 hospitalizacji w latach 2012–2017 (praca 1) oraz 5053 pacjentów z minimum rocznym follow-upem (praca 2). W badaniach wykorzystano różne modele predykcyjne, w tym algorytmy Xgboost oraz DRSA-BRE, a ich skuteczność porównano z klasyczną regresją logistyczną oraz modelem GRACE Score 2.0. Wykazano, że zastosowanie uczenia maszynowego umożliwia skuteczniejsze prognozowanie śmiertelności wewnątrzszpitalnej oraz odległego rokowania po ACS, przy jednoczesnym uwzględnieniu biomarkerów hematologicznych, takich jak RDW, NLR, liczba neutrofilów i monocytów.

W pracy pierwszej skoncentrowano się na krótkoterminowej prognozie śmiertelności wewnątrzszpitalnej oraz obecności istotnego zwężenia tętnicy wieńcowej. Modele oparte na DRSA-BRE oraz Xgboost osiągnęły wyższą skuteczność w przewidywaniu śmiertelności niż klasyczna regresja logistyczna, a kluczowe znaczenie prognostyczne miały wskaźniki zapalne i parametry hemodynamiczne przy przyjęciu. W drugiej pracy rozszerzono analizę na długoterminowe rokowanie, wykazując istotną rolę markerów zapalnych w ocenie przeżywalności po 6 i 12 miesiącach od ACS. Modele bazujące na Xgboost przewyższały skutecznością model GRACE Score 2.0 w długoterminowej predykcji zgonu. Podkreślono jednak, że dalsze badania prospektywne są konieczne, aby w pełni ocenić kliniczną wartość zastosowania AI w prognozowaniu wyników pacjentów z ACS.

2. Sztuczna inteligencja w kardiologii – przegląd i kierunki rozwoju

Publikacje przed osiągnięciem stopnia Doktora Nauk Medycznych:

2.1. **Pieszko K**, Hiczkiewicz J, Budzianowski J, Musielak B, Hiczkiewicz D, Faron W, Rzeźniczak J, Burchardt P. Clinical applications of artificial intelligence in cardiology on the verge of the decade. *Cardiol J.* 2021;28(3):460-472. doi: 10.5603/CJ.a2020.0093
IF 3.387; MEiN 100; Liczba cytowań (Web of Science): 7

Publikacje po osiągnięciu stopnia doktora nauk medycznych:

2.2. **Pieszko K**, Slomka PJ. Assessing Performance of Machine Learning. *JAMA Cardiol.* 2021;6(12):1465. doi: 10.1001/jamacardio.2021.3712, **[List do redakcji]**
IF 14.676; MEiN 200; Liczba cytowań (Web of Science): 6

2.3 Lin A, **Pieszko K**, Park C, Ignor K, Williams MC, Slomka P, Dey D. Artificial intelligence in cardiovascular imaging: enhancing image analysis and risk stratification. *BJR Open*. 2023 May 17;5(1):20220021. doi: 10.1259/bjro.20220021.

IF - MEiN 5; Liczba cytowań (Web of Science): 9

Podsumowanie kierunku badań

Brałem udział w badaniach nad zastosowaniem sztucznej inteligencji w kardiologii, koncentrując się na jej roli w obrazowaniu sercowo-naczyniowym oraz optymalizacji procesów diagnostycznych. W artykule przeglądowym opublikowanym w *Cardiology Journal* analizowałem szerokie spektrum zastosowań AI w tej dziedzinie, podkreślając jej potencjał w poprawie precyzji diagnostycznej, automatyzacji interpretacji danych i przewidywaniu wyników klinicznych. Wskazałem również na konieczność standaryzacji metod zbierania danych oraz walidacji modeli, co ma kluczowe znaczenie dla ich implementacji w praktyce klinicznej.

W ramach współpracy nad listem do redakcji *JAMA Cardiology* skupiliśmy się na ocenie wydajności modeli AI, zwracając uwagę na potrzebę stosowania odpowiednich metryk, takich jak precyzja, czułość i krzywe ROC. Podkreśliliśmy znaczenie rzetelnej walidacji modeli w różnych populacjach pacjentów, aby uniknąć ograniczonej możliwości ich zastosowania w populacjach na których nie były one trenowane (generalizability). W innym artykule, opublikowanym w *BJR Open*, współtworzyłem przegląd na temat wykorzystania AI w nieinwazyjnym obrazowaniu sercowo-naczyniowym, omawiając jej rolę w segmentacji, kwantyfikacji i ocenie ryzyka zdarzeń sercowo-naczyniowych na podstawie danych z tomografii komputerowej, rezonansu magnetycznego i echokardiografii.

Wspomniane prace poglądowe miały na celu nie tylko ukazanie możliwości, jakie niesie AI w kardiologii, ale także zwrócenie uwagi na wyzwania związane z jej implementacją, takie jak konieczność rygorystycznej walidacji i transparentności algorytmów. Prace te przyczyniły się do lepszego zrozumienia, jak AI może wspierać klinicystów w podejmowaniu decyzji diagnostycznych i terapeutycznych, pod warunkiem, że zostaną spełnione odpowiednie standardy jakości i bezpieczeństwa.

3. Zaawansowana analiza danych z badań obrazowych serca w ocenie ryzyka sercowo-naczyniowego

Publikacje po osiągnięciu stopnia doktora nauk medycznych:

3.1. Miller RJH, Han D, Singh A, **Pieszko K**, Slomka PJ, Gransar H, Park R, Otaki Y, Friedman JD, Hayes S, Thomson L, Rozanski A, Berman DS. Relationship between ischaemia, coronary artery calcium scores, and major adverse cardiovascular events. *Eur Heart J Cardiovasc Imaging*. 2022 Nov 1;23(11):1423-1433. doi: 10.1093/ehjci/jeac082.

IF 9.130 ; MEiN 140; Liczba cytowań (Web of Science): 28

3.2. Singh A, Kwiecinski J, Miller RJH, Otaki Y, Kavanagh PB, Van Krieking SD, Parekh T, Gransar H, **Pieszko K**, Killekar A, Tummala R, Liang JX, Di Carli MF, Berman DS, Dey D, Slomka PJ. Deep Learning for Explainable Estimation of Mortality Risk From Myocardial Positron Emission Tomography Images. *Circ Cardiovasc Imaging*. 2022 Sep;15(9):e014526. doi: 10.1161/CIRCIMAGING.122.014526.

IF 7.5; MEiN 140; Liczba cytowań (Web of Science): 22

3.3. Miller RJH, Killekar A, Shanbhag A, Bednarski B, Michalowska AM, Ruddy TD, Einstein AJ, Newby DE, Lemley M, **Pieszko K**, Van Krieking SD, Kavanagh PB, Liang JX, Huang C, Dey D, Berman DS, Slomka PJ. Predicting mortality from AI cardiac volumes mass and coronary calcium on chest computed tomography. *Nat Commun*. 2024 Mar 29;15(1):2747. doi: 10.1038/s41467-024-46977-3.

IF 15.7; MEiN 200; Liczba cytowań (Web of Science): 7

3.4. Lin A, Manral N, McElhinney P, Killekar A, Matsumoto H, Kwiecinski J, **Pieszko K**, Razipour A, Grodecki K, et al. Deep learning-enabled coronary CT angiography for plaque and stenosis quantification and cardiac risk prediction: an international multicentre study. *Lancet Digit Health*. 2022 Apr;4(4):e256-e265. doi: 10.1016/S2589-7500(22)00022-X.

IF 30.8; MEiN 20; Liczba cytowań (Web of Science): 176

3.5. Shanbhag AD, Miller RJH, **Pieszko K**, Lemley M, Kavanagh P, Feher A, Miller EJ, Sinusas AJ, Kaufmann PA, et al. Deep Learning-Based Attenuation Correction Improves Diagnostic Accuracy of Cardiac SPECT. *J Nucl Med*. 2023 Mar;64(3):472-478. doi: 10.2967/jnumed.122.264429.

IF 9,1; MEiN 140; Liczba cytowań (Web of Science): 28

3.6. Feher A, **Pieszko K**, Miller R, Lemley M, Shanbhag A, Huang C, Miras L, Liu YH, Sinusas AJ, Miller EJ, Slomka PJ. Integration of coronary artery calcium scoring from CT attenuation scans by machine learning improves prediction of adverse cardiovascular events in patients undergoing SPECT/CT myocardial perfusion imaging. *J Nucl Cardiol*. 2023 Apr;30(2):590-603. doi: 10.1007/s12350-022-03099-x

IF 3.0; MEiN 100; Liczba cytowań (Web of Science): 15

Podsumowanie kierunku badań

Istotnym obszarem mojej działalności naukowej, realizowanym głównie w ramach współpracy z Cedars-Sinai Medical Center w Los Angeles, było wykorzystanie sztucznej inteligencji do maksymalizacji wartości prognostycznej płynącej z obrazowych badań serca. Celem tych prac było opracowanie i walidacja w pełni zautomatyzowanych, obiektywnych narzędzi wspierających diagnostykę i stratyfikację ryzyka.

Moje zaangażowanie w tym obszarze obejmowało projekty badające komplementarną wartość prognostyczną oceny anatomii (wskaźnik uwapnienia tętnic wieńcowych, CAC) i funkcji (niedokrwienie w badaniach perfuzyjnych), gdzie wykazaliśmy, że ich łączne zastosowanie oferuje najdokładniejszą ocenę ryzyka (3.1). Kluczowym aspektem była automatyzacja tego procesu. Brałem udział w tworzeniu i walidacji modeli głębokiego uczenia, które umożliwiają w pełni automatyczną i błyskawiczną analizę obrazów medycznych, m.in. do ilościowej oceny blaszek miażdżycowych i zwężeń w angiografii-TK (3.4) oraz do pomiaru masy i objętości jam serca z niebramkowanych badań TK klatki piersiowej (3.3). W obu przypadkach parametry uzyskane dzięki AI okazały się silnymi i niezależnymi czynnikami prognostycznymi.

Kolejnym ważnym elementem moich badań było tworzenie tzw. wyjaśnialnych modeli AI, które nie tylko dostarczają prognozy, ale także wskazują, które cechy kliniczne i obrazowe miały na nią największy wpływ, co zademonstrowaliśmy w pracy dotyczącej przewidywania śmiertelności na podstawie obrazów PET (3.2). Mój wkład obejmował również prace nad poprawą samych technik obrazowych, czego przykładem jest model AI generujący mapy korekcji atenuacji dla badań SPECT bez potrzeby wykonywania skanu TK, co zwiększa dokładność diagnostyczną przy jednoczesnym ograniczeniu dawki promieniowania (3.5). Ponadto wykazaliśmy, że integracja oceny CAC, uzyskanej z map atenuacyjnych za pomocą uczenia maszynowego, znacząco poprawia predykcję zdarzeń sercowo-naczyniowych w badaniach SPECT/CT (3.6).

Prace te przyczyniły się do rozwoju narzędzi, które automatyzują, obiektywizują i pogłębiają analizę obrazową, przesuując granicę w kierunku szybszej, bardziej precyzyjnej i spersonalizowanej medycyny.

4. Markery stanu zapalnego w stratyfikacji ryzyka chorób sercowo-naczyniowych

Publikacje przed uzyskaniem stopnia dr nauk medycznych:

4.1. Hoffmann J, Mas-Peiro S, Berkowitsch A, Boeckling F, Rasper T, **Pieszko K**, De Rosa R, Hiczkiewicz J, Burchardt P, Fichtlscherer S, Zeiher AM, Dimmeler S, Nicotera MV. Inflammatory signatures are associated with increased mortality after transfemoral transcatheter aortic valve implantation. *ESC Heart Fail.* 2020 Oct;7(5):2597-2610. doi: 10.1002/ehf2.12837.

IF 4.411 ; MEiN 40; Liczba cytowań (Web of Science): 34

4.2. Budzianowski J, Hiczkiewicz J, Burchardt P, **Pieszko K**, Rzeźniczak J, Budzianowski P, Korybalska K. Predictors of atrial fibrillation early recurrence following cryoballoon ablation of pulmonary veins using statistical assessment and machine learning algorithms. *Heart Vessels.* 2019 Feb;34(2):352-359. doi: 10.1007/s00380-018-1244-z.

IF 1.618 ; MEiN 70; Liczba cytowań (Web of Science): 31

4.3. Budzianowski J*, **Pieszko K***, Burchardt P, Rzeźniczak J, Hiczkiewicz J. The Role of Hematological Indices in Patients with Acute Coronary Syndrome. *Dis Markers*. 2017;2017:3041565. doi: 10.1155/2017/3041565. * = „equal contribution as the first author”

IF 2.949 ; MEiN 25; Liczba cytowań (Web of Science): 111

Podsumowanie kierunku badań

Jednym z ważnych nurtów mojej działalności naukowej, szczególnie z okresu sprzed uzyskania stopnia doktora nauk medycznych, było badanie roli markerów stanu zapalnego w prognozowaniu ryzyka u pacjentów z chorobami sercowo-naczyniowymi. Badania te opierały się na założeniu, że proces zapalny jest centralnym elementem patofizjologii miażdżycy i jej powikłań.

Moje doświadczenie w tej dziedzinie zaowocowało również udziałem w międzynarodowych projektach badawczych. W ramach współpracy z Goethe University we Frankfurcie (4.1), współtworzyłem pracę analizującą złożone sygnatury zapalne (m.in. subpopulacje limfocytów i monocytów) jako predyktory śmiertelności u pacjentów po zabiegu przezcewnikowej implantacji zastawki aortalnej (TAVI). Ponadto, w badaniu dotyczącym pacjentów po krioablacji z powodu migotania przedsionków (4.2), wykorzystaliśmy metody uczenia maszynowego do identyfikacji biomarkerów (w tym markerów uszkodzenia i zapalenia) jako czynników predykcyjnych dla wczesnego nawrotu arytmii. Ekspertyzę zdobytą przy pracy nad rolą prognostyczną markerów stanu zapalnego w ostrych zespołach wieńcowych zwięździła cytowana ponad 90 razy praca poglądowa, w której jestem równorzędnym pierwszym autorem z dr. Janem Budzianowskim (4.3).

Ten nurt badawczy pozwolił na wykazanie, że markery stanu zapalnego – od prostych wskaźników morfologii krwi po złożone profile immunologiczne – stanowią potężne narzędzie w stratyfikacji ryzyka w różnych populacjach kardiologicznych, a ich wartość prognostyczna może być dodatkowo wzmocniona przez zastosowanie nowoczesnych metod analitycznych.

VI. Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę

A. Działalność dydaktyczna

Od roku 2018 prowadzę zajęcia dydaktyczne dla studentów kierunku lekarskiego na Uniwersytecie Zielonogórskim w ramach Kliniki Kardiologii. Prowadzone przeze mnie zajęcia obejmują:

- Wykłady i seminaria z zakresu kardiologii, diagnostyki i leczenia chorób serca.

- Ćwiczenia kliniczne, podczas których studenci mają możliwość zdobywania praktycznych umiejętności z zakresu badania pacjentów kardiologicznych.

Jestem opiekunem naukowym i założycielem dwóch studenckich kół naukowych działających w Uniwersytecie Zielonogórskim: Koła Naukowego Kardiologii Interwencyjnej oraz Koła Naukowego Sztucznej Inteligencji w Medycynie. W ramach tych kół naukowych *wspieram studentów w rozwijaniu ich zainteresowań naukowych, prowadzeniu badań i publikowaniu wyników*. Wśród konkretnych osiągnięć wymienić mogę poniższe:

1. W roku 2020 studentki z Koła Naukowego Kardiologii Interwencyjnej pod moją opieką otrzymały **nagrodę za najlepszą pracę studencką prezentowaną podczas kongresu Polskiego Towarzystwa Kardiologicznego** (praca pt. "Występowanie niepożądanych incydentów sercowo-naczyniowych i krwawień wśród pacjentów przed i po zabiegu zamknięcia uszka lewego przedsionka").
2. W roku 2023 Studenci Barbara Filipiak i Paweł Walenciak przygotowali pod moim kierownictwem i zaprezentowali na sesji przypadków klinicznych Ogólnopolskiej Konferencji Asocjacji Echokardiografii PTK PolEcho 2023 pracę pt. „Śródzabiegowe uwidocznienie i usunięcie skrzepliny podczas zabiegu przezskórnego zamknięcia uszka lewego przedsionka”.
3. W roku 2023 pełniłem funkcję **promotora pomocniczego pracy magisterskiej** pt. "Porównanie modeli statystycznych oraz uczenia maszynowego w zagadnieniu modelowania czasu przeżycia pacjentów z ostrym zespołem wieńcowym" na wydziale Matematyki, Informatyki i Ekonometrii Uniwersytetu Zielonogórskiego.
4. W 2024 studentka Iga Kolasa zaprezentowała pracę przygotowaną pod moim kierownictwem pt. "Pomiary oceniane przez sztuczną inteligencję w tomografii komputerowej serca ze wzmocnieniem kontrastowym jako czynniki określające ryzyko nawrotu migotania przedsionków po zabiegu krioabblacji" na **Sesji prac oryginalnych nominowanych do nagrody Komitetu Naukowego Kongresów PTK**.

B. Działalność organizacyjna

- Członek Komisji Informatyki i Telemedycyny Polskiego Towarzystwa Kardiologicznego.
- Aktywny członek 'Klubu 30' Polskiego Towarzystwa Kardiologicznego.
- Członek komitetu organizacyjnego Konferencji naukowej studentów Uniwersytetu Zielonogórskiego.
- Associate Editor w czasopiśmie *Cardiology Journal*.
- Współpraca przy organizacji rejestru LATTEE (Left Atrial Appendage Thrombus on Transesophageal Echocardiography) - wieloośrodkowe badanie naukowe dotyczące oceny ryzyka skrzepliny w uszku lewego przedsionka.
- Główny badacz w prospektywnym rejestrze IMAGE-AF (NCT06584266).

VII. Inne informacje dotyczące kariery zawodowej

A. Staże zagraniczne

- 2024-2025 – Sant Pau Research Institute, Barcelona, Hiszpania – staż naukowo-kliniczny (staż naukowy w ramach stypendium NAWA 6 miesięcy + zatrudnienie na stanowisku asystenta kardiologa (praca kliniczno-naukowa – 4 miesiące, łącznie 10 miesięcy)
- 2021 – Cedars Sinai Medical Center, Los Angeles, USA – staż naukowy (staż naukowy w ramach stypendium NAWA 6 miesięcy + zatrudnienie na stanowisku postdoc 4 miesiące, razem 10 miesięcy)

- 2016 – Hospital Universitario Dr. Negrin, Las Palmas, Gran Canaria, Hiszpania – staż kliniczny (4 miesiące)
- 2014 – Nationwide Children's Hospital, Columbus, Ohio, USA – staż kliniczny (1 miesiąc)
- 2013 – Universitätsspital Zürich, Zurych, Szwajcaria – staż kliniczny (1 miesiąc)
- 2012 – Hamamatsu Hospital, Hamamatsu, Japonia – staż naukowy (1 miesiąc)

B. Wystąpienia na zaproszenie:

1. 2024-05-10, XXV Ogólnopolska Konferencja Asocjacji Echokardiografii PTK PolEcho 2024 -
Wykład: Prawdopodobieństwo zakrzepu w LAA – rejestr LATTEE
2. 2024-09-19, XXVIII Międzynarodowy Kongres Polskiego Towarzystwa Kardiologicznego -
Wykład: LATTEE (Left Atrial Thrombus on TEE) – u których pacjentów z migotaniem przedsionków można zrezygnować z echa przezpręłykowego przed kardiowersją?
3. 2023-09-29, XXVII Międzynarodowy Kongres Polskiego Towarzystwa Kardiologicznego,
Wykład: Programy NAWA – program im. prof. Walczaka
4. 2022-09-22, XXVI Międzynarodowy Kongres Polskiego Towarzystwa Kardiologicznego-
Wykład: Uczenie maszynowe w ocenie rokowania pacjentów kardiologicznych
5. 2022-09-23, XXVI Międzynarodowy Kongres Polskiego Towarzystwa Kardiologicznego,
Wykład: Zastosowanie sztucznej inteligencji w badaniach obrazowych w kardiologii
6. 2024-09-11, SCIENCE CAMP Nauka dla Zdrowia
Wykład: Sztuczna Inteligencja w Kardiologii
7. 2023-09-14, SCIENCE CAMP Nauka dla Zdrowia
Wykład: Sztuczna Inteligencja w Kardiologii
8. 2023-03-10, Warszawskie Dni Kardiologii Akademickiej,
Wykład: Leczenie przeciwplatek i przeciwkrzepliwie po zabiegu LAAC

C. Członkostwo w międzynarodowych lub krajowych organizacjach i towarzystwach naukowych wraz z informacją o pełnionych funkcjach

- Członek Komisji Informatyki i Telemedycyny Polskiego Towarzystwa Kardiologicznego.
- Aktywny członek 'Klubu 30' Polskiego Towarzystwa Kardiologicznego.
- Członek European Society of Cardiology (ESC).
- Członek Polskiego Towarzystwa Kardiologicznego (PTK).

D. Nagrody i wyróżnienia

- 2024 – Nagroda za „Publikację Roku 2023” Polskiego Towarzystwa Kardiologicznego
 - 2023 - Nagroda Naukowa Klubu 30 PTK im. Prof. Leszka Ceremużyńskiego za rok 2022
 - 2023 – Pierwsza Nagroda w sesji „Digital Cardio Area” podczas kongresu Polskiego Towarzystwa Kardiologicznego w Poznaniu za najlepsze wdrożenie systemu medycyny cyfrowej (model LAT-AI i kalkulator online).
 - 2022 –Young Investigator Award podczas kongresu European Society of Cardiology 2022 w Barcelonie (kategoria Thrombosis) za abstrakt „Predicting the presence of left atrial appendage thrombus with clinical features and transthoracic measurements using machine learning”.
 - 2021 – Finalista Nagrody dla Młodych Badaczy (Young Investigator Award) podczas kongresu American Society of Nuclear Cardiology 2021 za abstrakt „Convolutional Multi-Task Deep Neural Network Precisely predicts Time-Dependent Survival of Major Adverse Cardiac Events After Myocardial Perfusion Imaging”.
 - 2018 – Nagroda Komitetu Naukowego PTK za najlepszy plakat podczas kongresu Polskiego Towarzystwa Kardiologicznego za abstrakt „Application of machine-learning to prediction of in-hospital mortality and significant coronary lesion in acute coronary syndrome patients”.
 - Nagroda Rektora Uniwersytetu Zielonogórskiego za osiągnięcia naukowe – przyznana w roku: 2022, 2023, 2024
-
- Stypendium im. Profesora Walczaka (2021, 2024)
 - Grant SONATA Narodowego Centrum Nauki (2024)

E. Funkcja recenzenta w czasopismach z listy JCR

- JACC: Cardiovascular Imaging (JIMG051424-0668, JIMG052623-0757, JIMG071024-0987, JIMG092224-1401)
- NPJ: Digital Medicine (Manuscript10562, Manuscript20250615)
- Nature Medicine (NMED-A139134A-Z)
- Circulation: Cardiovascular Research (CIRCCVIM/2024/016990)
- BMC Medical Imaging (c26b8860-21d5-4d9f-9cc8-02fe2ca313eb)
- Heart (heartjnl-2025-325740)
- Cardiology Journal (CJ-23-93887 , CJ-21-75658 , CJ-25-105753, dodatkowo pełnię funkcję associate editor od 2024 roku)
- Frontiers (MS 1543816)

VIII. Wykaz użytych skrótów i akronimów:

- **ABM** – Agencja Badań Medycznych
- **ACS** – (ang. *Acute Coronary Syndrome*); ostry zespół wieńcowy
- **AI / SI** – (ang. *Artificial Intelligence*); sztuczna inteligencja
- **AUC** – (ang. *Area Under the Curve*); pole pod krzywą
- **CAC** – (ang. *Coronary Artery Calcium*); wskaźnik uwapnienia tętnic wieńcowych
- **CAD** – (ang. *Coronary Artery Disease*); choroba wieńcowa
- **cAUC** – (ang. *cumulative/dynamic Area Under the Curve*); skumulowane/dynamiczne pole pod krzywą
- **CHA₂DS₂-VASc** – (ang. *Congestive heart failure, Hypertension, Age ≥ 75 , Diabetes, Stroke, Vascular disease, Age 65–74, Sex category*); skala kliniczna służąca do oceny ryzyka udaru u pacjentów z migotaniem przedsionków
- **ChSN** – Choroby sercowo-naczyniowe
- **CI** – (ang. *Confidence Interval*); przedział ufności
- **CT/ TK** – (ang. *Computed Tomography*); tomografia komputerowa
- **CTAC** – (ang. *Computed Tomography for Attenuation Correction*); tomografia komputerowa używana do korekcji atenuacji (osłabienia sygnału)
- **DL** – (ang. *Deep Learning*); głębokie uczenie
- **ECG** – (ang. *Electrocardiogram*); elektrokardiogram
- **ESC** – (ang. *European Society of Cardiology*); Europejskie Towarzystwo Kardiologiczne
- **HR** – (ang. *Hazard Ratio*); iloraz hazardu
- **IF** – (ang. *Impact Factor*); współczynnik wpływu, wskaźnik cytowalności czasopisma naukowego
- **JCR** – (ang. *Journal Citation Reports*); baza danych z listą czasopism naukowych i wskaźnikami ich cytowań
- **LAA** – (ang. *Left Atrial Appendage*); uszko lewego przedsionka
- **LAAC** – (ang. *Left Atrial Appendage Closure*); zamknięcie uszka lewego przedsionka
- **LAT** – (ang. *Left Atrial Thrombus*); skrzeplina w lewym przedsionku
- **LATTEE** – (ang. *Left Atrial Thrombus on Transoesophageal Echocardiography*); skrzeplina w lewym przedsionku w echokardiografii przezprzełykowej
- **LVEF** – (ang. *Left Ventricular Ejection Fraction*); frakcja wyrzutowa lewej komory
- **MACE** – (ang. *Major Adverse Cardiovascular Events*); poważne niepożądane zdarzenia sercowo-naczyniowe
- **MEiN** – Ministerstwo Edukacji i Nauki
- **NAWA** – Narodowa Agencja Wymiany Akademickiej
- **NCN** – Narodowe Centrum Nauki
- **NCT** – (ang. *National Clinical Trial*); numer identyfikacyjny badania klinicznego
- **NRI** – (ang. *Net Reclassification Index*); wskaźnik reklasyfikacji netto

- **OZW** – Ostry zespół wieńcowy
- **PET/CT** – (ang. *Positron Emission Tomography/Computed Tomography*); pozytonowa tomografia emisyjna / tomografia komputerowa
- **PTK** – Polskie Towarzystwo Kardiologiczne
- **ROC** – (ang. *Receiver Operating Characteristic*); krzywa charakterystyki operacyjnej odbiorcy
- **SPECT/CT** – (ang. *Single Photon Emission Computed Tomography/Computed Tomography*); tomografia emisyjna pojedynczego fotonu / tomografia komputerowa
- **TAVI** – (ang. *Transcatheter Aortic Valve Implantation*); przezcewnikowa implantacja zastawki aortalnej
- **TOE** – (ang. *Transoesophageal Echocardiography*); echokardiografia przezprzełykową
- **TTE** – (ang. *Transthoracic Echocardiography*); echokardiografia przezklatkowa
- **USG** – Ultrasonografia

Konrad Pieszko

(podpis wnioskodawcy)