AI w medycynie weterynaryjnej możliwości i perspektywy

Andrzej Jarynowski
Polskie Towarzystwo Higieniczne, Wrocław; Główny Inspektorat Sanitarny, Warszawa; Uniwersytet Medyczny we Wrocławiu; Instytut Biometrii i Epidemiologii Weterynaryjnej, FU Berlin

Sztuczna inteligencja ma olbrzymi potencjał w poprawie wydajności i dobrostanu w produkcji mleka, wołowiny i wieprzowiny. Jej wdrażanie wymaga jednak spełnienia kilku warunków.

Gospodarstwa z Polski i regionu mają duży potencjał w czasach zmian wdrażając systemy oparte na sztucznej inteligencji do zarządzania żywym inwentarzem, szczególnie w przypadku bydła mlecznego i świń. Demokratyzacja sztucznej inteligencji za pomocą niedrogich urządzeń (takich jak telewizja przemysłowa i smartfony) stanowi potencjał dla opłacalnej rewolucji w medycynie weterynaryjnej. Jednak nadal istnieją wyzwania związane ze skalowaniem rozwiązań precyzyjnej hodowali opartych na sztucznej inteligencji i równoważenie wydajności z dobrostanem zwierząt. Pomimo kilku udanych studiów przypadków w regionie, odstajemy znacznie w innowacyjności w tym obszarze nie tylko od Europy Zachodniej czy USA, ale też większości krajów Europy Wschodniej, a ostatnio Chin i Indii. Również dynamika międzynarodowych regulacji prawnych (AI Act) i rekomendacji towarzystw naukowych nie idzie w parze w mocno przestarzałą legislacją w Polsce. Dlatego podkreślam znaczenie integracji edukacji w zakresie sztucznej inteligencji z programami nauczania zootechników i lekarzy weterynarii.

Wprowadzenie

Obecnie technologia rozwija się w zawrotnym tempie, sztuczna inteligencja (AI) obejmuje niemal każdy obszar nauki i badań (Chmielewski & Kasprzyk, 2018). AI oznacza inteligencję maszyn, przeciwstawną do inteligencji ludzi oraz innych organizmów. Można ją postrzegać jako działanie „inteligentnego proxy" (Zybertowicz & Piekutowski, 2022) – algorytmu lub urządzenia, które rozumie i ocenia swoje otoczenie, a następnie podejmuje działania prowadzące do realizacji wyznaczonych celów. Szczególną kategorią AI jest **uczenie maszynowe (ML)**, w ramach którego algorytmy uczą się i przyswajają nową wiedzę (Duch i in., 2000).

Dynamiczny rozwój AI/ML naturalnie skłania badaczy do poszukiwania ich zastosowań we wszystkich dziedzinach nauki i przemysłu (Racewicz i in., 2021). Inteligentna hodowla zwierząt nie stanowi wyjątku: nowoczesne gospodarstwa inwestują w ulepszony sprzęt i oprogramowanie, by sprostać rosnącym wymaganiom w zakresie zarządzania paszą oraz zwiększania produkcji. Wykorzystują wizję komputerową, ML i techniki głębokiego uczenia do optymalizacji produkcji – od wczesnego wykrywania chorób i selekcji reproduktorów, po zarządzanie środowiskiem i prognozowanie przyrostów. Coraz więcej gospodarstw **w Polsce i w Europie Środkowo-Wschodniej (CEE)** testuje systemy AI do monitorowania zdrowia zwierząt i działalności rolniczej (Herwart, 2023).

Wojna w Ukrainie sprawiła jednak, że najlepsi specjaliści od elektroniki i programowania zostali skierowani do przemysłu obronnego. Współpracownicy autora – inżynierowie produkujący czujniki dla zwierząt i drony rolnicze – przenieśli się do sektora wojskowego po wybuchu pełnoskalowego konfliktu w 2022 roku. Sam autor również został zmobilizowany do resortu obrony, gdzie uczestniczył w działaniach antybioterrorystycznych (Jarynowski, 2023) i szkolił się z AI/ML u ekspertów

ryc. 1. **Schemat Innowacyjności AI w medycynie weterynaryjnej**

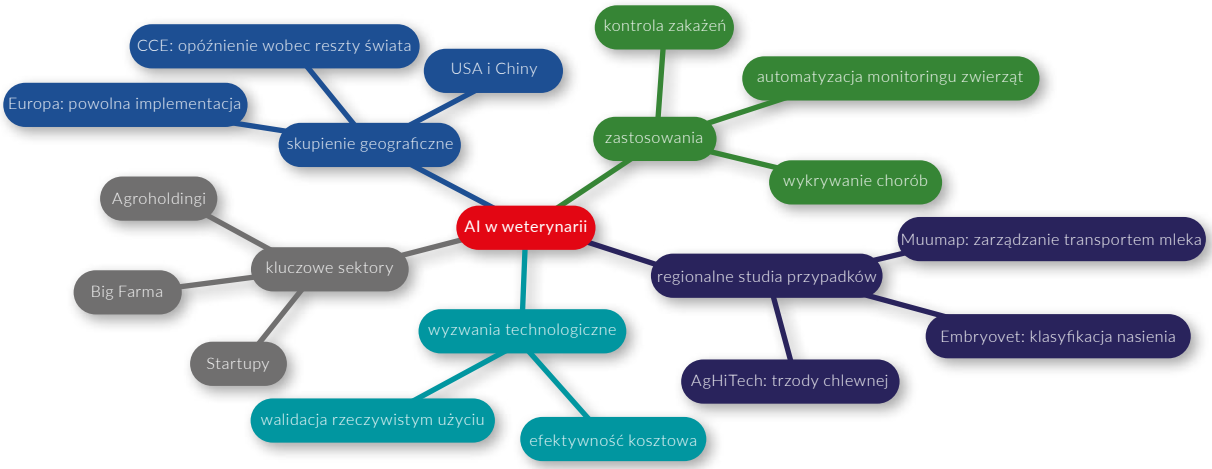

NATO, podobnie jak wielu innych lekarzy weterynarii. Miejmy nadzieję, że po zakończeniu działań wojennych specjaliści ci powrócą do rolnictwa, wzbogaceni o nowe umiejętności i doświadczenia zdobyte przy pracy z zaawansowanymi technologiami amerykańskimi i izraelskimi.

Opis słabości i możliwości rozwiązań precyzyjnego rolnictwa zwierzęcego

Kraje Europy Środkowo-Wschodniej (CEE) mogą brać udział w projektach finansowanych z unijnych mechanizmów, jednak są w nich słabo reprezentowane. Przykładowo, mniej niż 10% projektów z obszaru **ICT (Information and Communication Technology)** dla produkcji zwierzęcej realizowanych w programie ICT-AgriFood (https://ictagrifood.eu) prowadzą instytucje z regionu CEE. Dysproporcje są jeszcze większe w sektorze prywatnym, gdyż większość ośrodków badawczo-rozwojowych mieści się w Europie Zachodniej, gdzie mają siedziby duże firmy farmaceutyczne (Big Pharma) i agroholdingi (Milanović 2016).

Choć większość innowacji czwartej rewolucji przemysłowej w hodowli zwierząt powstała w trzech regionach: 1) Ameryka Północna – Australia/Nowa Zelandia – Republika Południowej Afryki, 2) Europa Zachodnia, 3) Chiny/Indie (Ćwiklicki i in. 2022), nowe technologie otwierają dziś perspektywy także dla krajów CEE. Wiele rozwiązań **precyzyjnego rolnictwa zwierzęcego (PLF)** opartych na sztucznej inteligencji, opracowanych w ośrodkach o wysokiej intensywności badań (Facilitating PLF, 2024), może jednak być trudnych do skalowania w warunkach Europy Środkowo-Wschodniej. Proponujemy więc wykorzystanie istniejących zasobów, kompetencji i już dostępnych danych do optymalizacji systemu produkcji.

Państwa o wysokich dochodach inwestowały w ciągu ostatnich pięciu dekad w czujniki zwierzęce i technologie analogowe, lecz postęp w robotyce, diagnostyce i logistyce wymaga dziś bardzo zaawansowanych rozwiązań, a konkurencja w tych obszarach jest silna (Ćwiklicki i in. 2022). Rozprzestrzenianie się tanich urządzeń o podwójnym zastosowaniu – takich jak kamery przemysłowe, smartfony czy programowalne czujniki – demokratyzuje dostęp do technologii. Kolczyki lub inne znaczniki (Sibanda i in. 2022) oraz czujniki środowiskowe, które transmitują i gromadzą dane, mogą kosztować 10-30 PLN za sztukę (np. polska firma https://kontakt.io), co jest zwykle kosztem pomijalnym wobec ceny paszy. Tanie systemy AI mogłyby nieprzerwanie analizować strumienie wideo i dane z czujników (Serwata i in. 2024) na smartfonach, wykrywać oznaki chorób, prognozować tempo wzrostu i automatycznie korygować warunki środowiskowe – praktycznie bez dodatkowych kosztów dla rolników lub służb weterynaryjnych (z wyjątkiem wysokich marż międzynarodowych koncernów sprzedających takie systemy).

Praktyczna definicja sztucznej inteligencji w medycynie weterynaryjnej

Postępy w mocy obliczeniowej i technikach modelowania oraz stale rosnąca ilość danych (Jarynowski, Maksymowicz i in. 2023) pochodzących

z i) nadzoru chorób, ii) rejestrów, iii) śladów cyfrowych, umożliwiają w medycynie weterynaryjnej:

- uczenie maszynowe
- analizę złożonych systemów
- zastosowanie standardowych narzędzi statystycznych
- symulacje komputerowe.

W kontekście PLF sztuczna inteligencja oznacza wykorzystanie zaawansowanych metod obliczeniowych – wizji komputerowej (Fernandes i in. 2020), algorytmów regułowych, modelowania statystycznego czy głębokiego uczenia – aby usprawnić zarządzanie i monitoring gospodarstw.

Kluczową cechą nowoczesnych systemów AI jest transfer learning: można wykorzystać wstępnie wytrenowane modele i doskonalić je na własnych danych, dzięki czemu system „uczy się" specyfiki konkretnego gospodarstwa lub regionu. Systemy AI w PLF analizują ogromne strumienie danych z czujników, kamer i innych urządzeń Internetu Rzeczy (IoT). W inspekcjach weterynaryjnych (np. w Anglii czy Australii) systemy AI bazują głównie na zdigitalizowanej dokumentacji stad (Davies i in. 2024). Zgodnie z unijnymi regulacjami także w Polsce wdrażany jest system teleinformatyczny do ewidencji leczenia zwierząt i stosowanych

ryc. 2. **Wygenerowane przez AI ilustrująca możliwości niskokosztowych sensorów wspartych AI.**

produktów leczniczych, dlatego w gospodarstwie powinien działać prosty system ICT – najlepiej z automatycznym pobieraniem danych.

Dyrektywa UE 98/58/WE, regulująca hodowlę trzody chlewnej i bydła, nakłada na rolników obowiązek codziennego monitorowania dobrostanu zwierząt oraz ich potrzeb biologicznych i behawioralnych (Kjosevski i in. 2021). Duże modele językowe (LLM) to obiecujące narzędzie do optymalizacji pracy gospodarstw (Jarynowski & Romanowska 2024). LLM, trenowane na ogromnych zbiorach tekstu, potrafią rozumieć i generować język zbliżony do ludzkiego, odpowiadając na różnorodne pytania (Jarynowski, Krzowski i in. 2024). Pozwalają rolnikom podejmować decyzje oparte na danych, zwiększając wydajność, dobrostan zwierząt (Animal Welfare) i produktywność – często przy niższych kosztach i minimalnej interwencji człowieka (Fang i in. 2021).

Potencjał tych technologii potwierdziła Nagroda Nobla 2024 przyznana przez Karolinska Institutet i Szwedzką Akademię Nauk za osiągnięcia w termodynamice sieci neuronowych, transkryptonice i modelowaniu strukturalnym, mające zastosowanie również w naukach weterynaryjnych – od badań patogenezy po projektowanie nowoczesnych leków i szczepionek. Trzeba jednak podkreślić, że z perspektywy klinicysty kluczowe jest zrozumienie decyzji algorytmu; klasyczne sieci neuronowe, działające jak „czarna skrzynka", stanowią wyzwanie regulacyjne. Mogą więc wspierać lekarza weterynarii, lecz ostateczną odpowiedzialność za decyzję ponosi wyłącznie człowiek (WHO 2024).

Globalna scena dla sztucznej inteligencji w nauce i praktyce biomedycznej

Doświadczenia autora z udziału w targach takich jak Horticultural Expo 2023, Expo 2022, ArabHealth 2022, Digital Health Euro (2022, 2024), VetCongress 2022, Polagra 2021, EuroMedica 2021, WOHC 2024 oraz w wizytach studyjnych odbytych w latach 2022-2024 na wszystkich kontynentach poza Antarktydą pokazują, że coraz większy nacisk kładzie się na wdrażanie rozwiązań AI, a nie jedynie na pokazywanie jej potencjału (Jarynowski, Maksymowicz, i in., 2023).

Wiedza i postęp w skutecznym wykrywaniu, monitorowaniu oraz leczeniu chorób powszech-

nych pozostają ograniczone; potrzebne są dalsze prace nad metodami i podejściami. Zauważalne jest natomiast rosnące zainteresowanie wykorzystaniem AI do identyfikowania i terapii chorób rzadkich, w tym nowo pojawiających się patogenów. W Europie powstaje wiele pomysłów na aplikacje i rozwiązania software'owe, podczas gdy faktyczny rozwój technologii koncentruje się głównie w USA i Chinach. Proces cyfryzacji postępuje wolniej w klinicznej medycynie weterynaryjnej niż w administracji, a liczba dostępnych narzędzi przewyższa rzeczywiste wdrożenia (Racewicz i in., 2021). Najwięcej implementacji mają globalne koncerny farmaceutyczne – Boehringer-Ingelheim, Bayer, Merck, Zoetis – oraz agroholdingi Cargill i Tyson/Smithfield Foods. Koszt-efektywność nowych rozwiązań wciąż bywa niepewna; wiele projektów AI dobrze sprawdza się w laboratorium, lecz rzadko trafia do praktyki. Kluczowa pozostaje walidacja w warunkach rzeczywistych, o czym naukowcy często zapominają.

Europa, w tym Europa Zachodnia, coraz wyraźniej odstaje nie tylko od Ameryki Północnej i Australii, lecz także od Chin i Indii. Jest to szczególnie istotne dla Europy Środkowo-Wschodniej, gdzie zasoby zaawansowanych technologicznie rozwiązań PLF koncentrują się w „starych" krajach EEA, a słabiej uprzywilejowane regiony otrzymują głównie wsparcie na konsumpcję lub działalność niepriorytetową, np. rolnictwo ekologiczne (Ziętara & Mirkowska, 2024).

Przykłady wdrożeń AI/ML w Polsce i regionie CEE

Muumap (Polska, Serbia, Rumunia, Czechy) – system zarządzania transportem, który w czasie rzeczywistym optymalizuje „zimny łańcuch" dostaw surowego mleka, łącząc rolników z kierowcami, kontrolując temperaturę i planując wielopunktowe trasy za pomocą transponderów GPS.

Embriovet/embryogen (Polska, Litwa, Łotwa) – model ML do klasyfikacji nasienia trzody i bydła; łączy analizę biomarkerów z wizją komputerową do oceny aktywności plemników.

AgHiTech (Polska, Węgry, Estonia) – czujniki środowiskowe (powietrze, temperatura, wilgotność) do monitoringu brojlerów, kur niosek i świń; projekt współtworzony przez UPWr.

Aidmed (Polska, Słowacja, Chorwacja) – czujniki monitorujące zdrowie (kolka koni, przeżuwanie, problemy oddechowe, kulawizna bydła); ze względu na brak rynku weterynaryjnego firma skupiła się na systemach dla ludzi.

Promity (Polska) – usługa pozwalająca na podstawie zdjęcia ze smartfona policzyć komórki somatyczne w mleku; rozwijana we współpracy z SGGW.

SLIDE (Polska) – system analizy danych z kolczyków świń; dotąd bez szerszego zastosowania (UP Poznań, IZ PIB).

Dicella (Polska) – automatyczne rozpoznawanie patogenów i liczenie kolonii bakteryjnych na szalkach Petriego; przydatne przy masowych

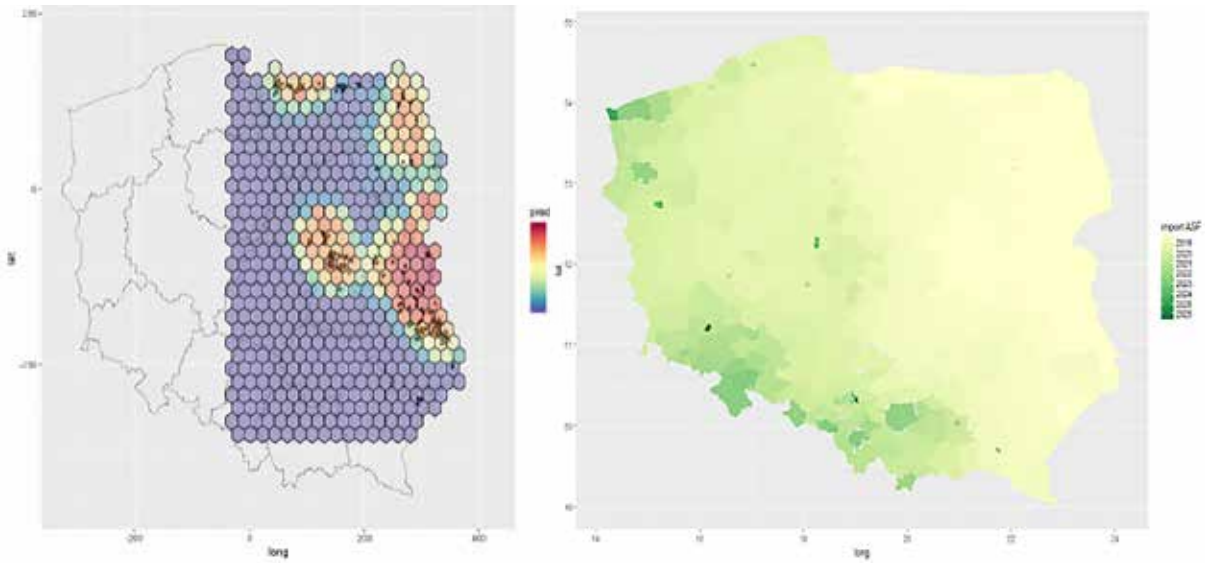

ryc. 3. **Własne model propagacji ASF w Polsce w 2018/2019** (Jarynowski & Belik, 2019).

badaniach wody po powodziach; rozwijane z UJ-UR/AGH.

Vetapp (Polska, Estonia) – modele LLM do triażu problemów zdrowotnych zwierząt przez właścicieli; cenne źródło danych epidemiologicznych w czasie rzeczywistym.

Wielowymiarowa analiza systemów AI w weterynaryjnym zdrowiu publicznym

Polska dysponuje dużym potencjałem w cyfryzacji produkcji mlecznej, priorytetowej dla rynku krajowego i eksportu (Lardy i in., 2023). W sektorze trzody chlewnej również potrzebne są modernizacje technologiczne (Edwards, 2021), lecz rozwój hamują choroby zakaźne, zwłaszcza ASF (Jarynowski, Czekaj, i in., 2024). Po 2019 r. polskie ośrodki naukowe praktycznie zaprzestały publikowania własnych badań nad AI w rolnictwie, co wskazuje na regres branży (Racewicz i in., 2021). W efekcie wysoką wartość mają systemy AI wspierające bioasekurację.

Stworzony przez autora stochastyczno-agentowy model rozprzestrzeniania ASF z 2017 r., zaktualizowany w 2019 r., trafnie przewidywał kierunki i tempo szerzenia się wirusa, m.in. skok ognisk na ziemię wschowską. Model lasu losowego osiągnął czułość 90 % i swoistość 95% w prognozowaniu, czy obszar sąsiadujący z ogniskiem zachowa status wolny od ASF w następnym miesiącu (Czekaj, 2017). Te rozwiązania znalazły kontynuację w Rumunii i Danii (Hayes i in., 2024). Próby wykorzystania dronów do lokalizacji siedlisk dzików (Szczepaniak i in., 2023) czy inteligentnych ogrodzeń w Estonii nie przyniosły oczekiwanych rezultatów, lecz dane z sensorów pomogły zrozumieć zachowania watah, co zwiększa precyzję kolejnych modeli agentowych. Warto kontynuować projekty wykorzystujące zdjęcia satelitarne, GPS, czujniki podczerwieni, fale RF/Bluetooth i drony w kontroli ASF, pod warunkiem bardziej rozważnego finansowania. Wykorzystanie bogatszych danych sensorowych i doświadczenia specjalistów z innych sektorów, pozyskanego m.in. podczas ostatniego konfliktu, może przyspieszyć rozwój precyzyjnej hodowli zwierząt w CEE.

Sytuacja w zakresie zastosowań AI w hodowli bydła mlecznego wygląda w Polsce znacznie lepiej niż w sektorze trzody chlewnej. W ostatnich latach obserwuje się wzrost liczby publikacji opisujących własne wdrożenia – od Szczecina (Grzesiak i in., 2023), przez Poznań (Grodkowski i in., 2022), po Wrocław (Wełeszczuk i in., 2022).

Jak uczenie maszynowe sprawdza się w praktyce?

Najszerszym polem badań i wdrożeń jest dziś wykorzystanie ML/AI do ekstrakcji oraz konwersji danych obrazowych (ze zdjęć i kamer przemysłowych) na cechy fenotypowe (Grys i in., 2017). W uproszczeniu typowy proces wygląda następująco (Benos i in., 2021):

Rejestracja materiału – w warunkach eksperymentalnych (pełna kontrola w instytucie badawczym) nagrywa się wideo lub wykonuje zdjęcia zwierzętom.

Etykietowanie danych – lekarze weterynarii i inni specjaliści nadają etykiety zgodnie z po-

ryc. 4. **Pętla iteracyjna uczenia maszynowego we wdrożeniach.**

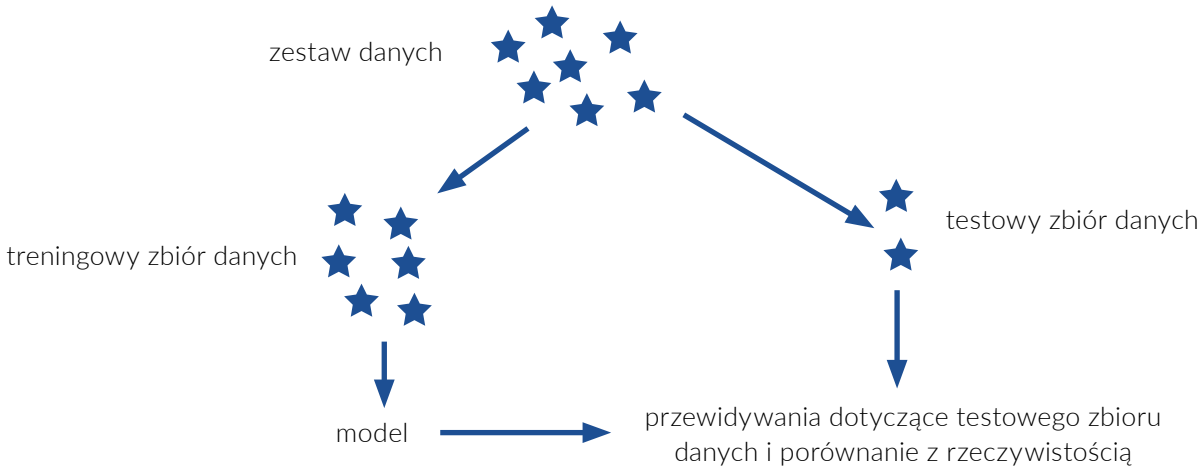

trzebą projektu. Przy wykrywaniu bólu (Belik, Jarynowski & Sergeeva, 2024) stosowaliśmy zweryfikowaną Cows Pain Scale (CPS); kolejne kadry oznaczano odpowiednią oceną.

Uczenie modelu – głęboka sieć neuronowa rozpoznaje kategorie na zbiorze uczącym, a następnie podlega walidacji wewnętrznej. Analitycy, posługując się odpowiednimi metrykami, badają trafność decyzji i próbują zrozumieć, czym kieruje się algorytm.

Test w warunkach fermowych – jeśli model działa w laboratorium, wdraża się go na farmie. Nasze doświadczenia wskazują na częste problemy: model nieprawidłowo segmentuje obraz (Dong & Belik, 2023) lub myli stany fizjologiczne i patologiczne.

Douczenie i kolejna walidacja – gromadzi się dane z fermy, ponownie etykietuje i doucza model, a następnie weryfikuje na materiałach z innych kamer czy lokalizacji.

Skalowanie – gdy model sprawdza się w różnych warunkach (najwięcej projektów odpada na tym etapie), powstaje interfejs użytkownika: aplikacje mobilne i webowe hurtownie danych. Rozpoczyna się komercjalizacja.

Deklaracja parametrów AI – przy wprowadzaniu produktu weterynaryjnego producent podaje rodzaj algorytmu oraz miary wydajności (dokładność, czułość, swoistość, wartości predykcyjne) jako substytut regulacji (Bellamy, 2023), ponieważ obecnie nie ma obowiązku zgłaszania takich systemów do URPL ani certyfikacji CE, to się zmieni od 2027 roku ze względu na AI Act (Komisja Europejska, 2024).

Dzięki temu ciągłemu procesowi douczania i walidacji systemy AI stają się coraz bardziej niezawodne, a ich implementacja w hodowli bydła mlecznego postępuje szybciej niż w sektorze trzody chlewnej.

Jakie są tendencje globalne w zastosowaniu AI w weterynarii?

Zdolność systemów sztucznej inteligencji do wykrywania wczesnych oznak chorób na podstawie analizy zachowania i monitorowania dźwięku może skrócić czas leczenia lub przyspieszyć decyzję o uboju, a tym samym ograniczyć cierpienie zwierząt (Akinsulie i in., 2024). Próby różnicowania etiologii schorzeń oddechowych wyłącznie na podstawie nagrań kaszlu z chlewni (Yamsakul i in., 2023) nie zakończyły się sukcesem; algorytmy poprawnie odróżniają jednak kaszel od innych odgłosów, dzięki czemu możliwy jest pomiar jego intensywności w stadzie (liczba kaszlnięć na jednostkę czasu). Wielomikrofonowe układy potrafią lokalizować ogniska choroby pomiędzy pojedynczymi kojcami, co umożliwia hodowcy i lekarzowi weterynarii bieżącą ocenę postępów terapii.

W krajach UE narasta presja na poprawę dobrostanu zwierząt, a rozważa się nawet całkowite odejście od chowu klatkowego. Monitorowanie oparte na AI może wspierać ocenę dobrostanu w okresie przejściowym: wybrane elementy protokołów (np. punktacja jakości dobrostanu (Lardy i in., 2023)) można już częściowo automatyzować. Zintegrowane systemy sterują oświetleniem, ogrzewaniem, wentylacją czy nawilżaniem, zapewniając optymalne warunki środowiskowe dla świń (Oczak i in., 2023) i krów (Lavrova i in., 2023).

Autor specjalizuje się w analizie sieci kontaktów (Sibanda i in., 2022) tworzonych przez zwierzęta na podstawie danych z czujników podczerwieni, Bluetooth i GPS. Znajomość dynamiki takich sieci ułatwia identyfikację osobników agresywnych, które należy wykluczyć ze stada. Zespół dra Oczaka (absolwenta UR Kraków) w Wiedniu próbuje podobnej selekcji, wykorzystując kamery przemysłowe do wykrywania obgryzania ogonów u świń.

Wykorzystując dane o temperaturze, wilgotności oraz poborze wody i paszy, autor współtworzył prosty model przyrostu biomasy (Belik, Jarynowski, Turan, i in., 2024); uwzględnienie informacji z czujników kontaktowych dodatkowo poprawia jego trafność, m.in. dzięki korekcie na zmiany zachowania wywołane chorobą (Palmini i in., 2023). Trzeba jednak pamiętać, że betonowe konstrukcje chlewni i obór tłumią fale radiowe, a sprzęt RFID bywa zawodny i wymaga okresowych przeglądów. Duża awaryjność doprowadziła m.in. do wycofania się firmy, w której pracował autor, z rynku weterynaryjnego (Romaszko-Wojtowicz i in., 2023).

Etycy zwracają uwagę na ryzyko zaniedbania aspektów dobrostanu, których obecne systemy AI nie mierzą ilościowo (Neethirajan, 2017). Zbyt duże zaufanie do technologii może ograniczyć bezpośrednią obserwację zwierząt, choć z drugiej strony lekarz weterynarii, oszczędzając

czas na dojazdach, może go przeznaczyć na profilaktykę i leczenie. Świadomy hodowca, łącząc diagnozę AI z doświadczeniem i znajomością stada, zyskuje narzędzie do skuteczniejszej kontroli zdrowia.

Badania na zwierzętach – w tym kontrolowane zakażenia Clostridium perfringens – umożliwiają precyzyjne znakowanie danych treningowych (z wykorzystaniem wszelakich sensorów, ale przede wszystkim wizji komputerowej), co w medycynie ludzkiej byłoby trudne lub niemożliwe. Dlatego w Chinach i USA rozwój komputerowo wspomaganej weterynarii, jako dziedziny komplementarnej do medycyny ludzi, gwałtownie przyspieszył (Kolasa i in., 2024). Akcelerometry (również polskiej produkcji) doskonale sprawdzają się w detekcji kulawizn (Lavrova i in., 2023), a tanie kamery przemysłowe – często wspierane obrazowaniem termicznym – rewolucjonizują diagnostykę chorób układu ruchu (Akinsulie i in., 2024).

Analiza big data mikrobioty pozwala optymalizować żywienie, zwłaszcza w doborze pre- i probiotyków, a modele z rodziny Alpha Fold (nagroda Nobla z chemii 2024) przyspieszają projektowanie nowych leków. Przykładem jest halicyna – pierwszy od dekad antybiotyk o nowym mechanizmie działania, dopuszczany do użycia weterynaryjnego prawdopodobnie w Chinach (Wang i in., 2024).

Trwają intensywne badania nad automatycznym wykrywaniem emocji zwierząt (ból, stres termiczny), opartym głównie na analizie mimiki pyska; w perspektywie dziesięciu lat takie wskaźniki mogą trafić do obowiązkowej oceny dobrostanu w UE (Bryant i in., 2024).

Wyzwania globalne, działania lokalne

Dotychczas liderami sztucznej inteligencji w hodowli były Big Tech, Big Pharma i agroholdingi. Nie należy jednak polegać wyłącznie na glo-

ryc. 5. Polska na poziomie Serbii w naukowym dyskursie w Europie z uwzględnieniem liczby publikacji naukowych na 1 mln mieszkańców w selekcji wariantów hodowli zwierząt
[na podstawie zapytań w PubMed dotyczących ML (uczenia maszynowego) i AI (sztucznej inteligencji)].

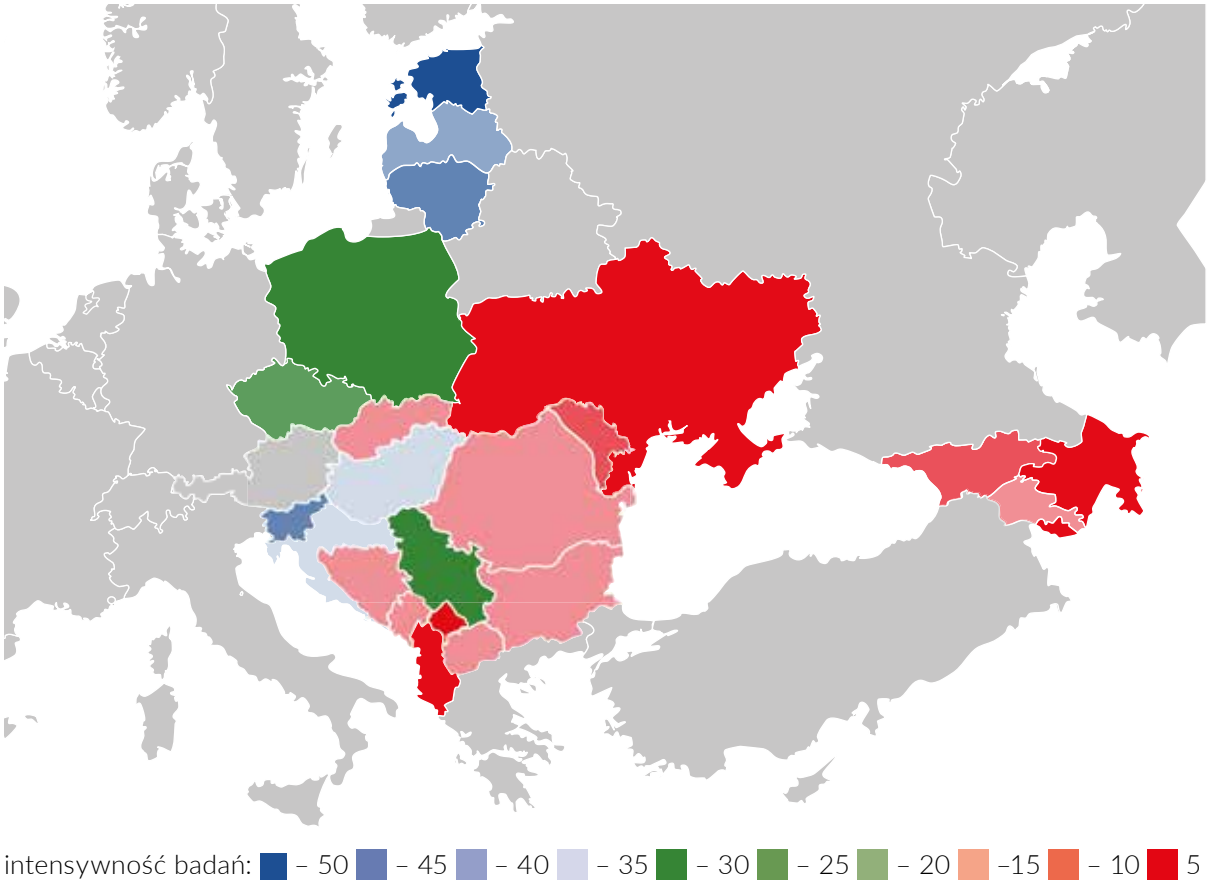

balnych rozwiązaniach (Zybertowicz & Piekutowski, 2022). Meta wniosła kluczowy wkład w rozwój YOLO (zwłaszcza technologie YOLOv7 i YOLOv8 powstałe na przełomie 2022–2023 w kontekście rozpoznawania zwierząt) – najpopularniejszego algorytmu rozpoznawania zwierząt – a Google udostępnia pre-trenowane modele w Cloud Vision API. Ponieważ wszystkie duże LLM pozostają pod kontrolą USA, rozwój europejskich alternatyw ma strategiczne znaczenie. Właśnie wizja komputerowa jest dziś uznawana za najbardziej przełomową dziedzinę AI we weterynarii (Burti i in., 2024).

Polscy informatycy – tradycyjnie silni w Krakowie (Tadeusiewicz & Korohoda, 1997) – prowadzą badania na światowym poziomie, choć zwykle we współpracy z zagranicznymi lekarzami weterynarii, a nie z krajowymi. Wysoką skuteczność wykazują systemy wspierające decyzje terapeutyczne, np. w antybiotykoterapii: już dekadę temu proste drzewa decyzyjne okazały się lepsze od lekarzy medycyny (Tokgöz i in., 2024). Systemy AI mogą optymalizować przemieszczanie krów między pastwiskami w wypasie ekstensywnym (czujniki ruchu, zdjęcia satelitarne), a w intensywnej produkcji – jak model ML z UPWr, przewidujący wskaźnik ekonomiczny i okres międzywycieleniowy bez długich obserwacji (Wełeszczuk i in., 2022).

Z drugiej strony algorytmy, szczególnie „czarne skrzynki", mogą sprzyjać nadużyciom antybiotyków, zwiększając problem AMR (Jarynowski, Romanowska, i in., 2023; Maksymowicz, 2023). AI stworzy nowe miejsca pracy dla wykwalifikowanych rolników, lecz może równocześnie wypierać małe, tradycyjne gospodarstwa, rodząc wątpliwości etyczne i społeczne (Jarynowski, 2024). Modele językowe mogą też posłużyć do planowania ataków biologicznych (Jarynowski, Krzowski, i in., 2024) czy szerzenia dezinformacji żywnościowej (Chowdhury i in., 2023)) – między innymi poprzez przekazy ukierunkowane na młode matki, zniechęcające do spożywania mleka. Dlatego kluczowe pozostaje zwalczanie bionegacjonizmu i wzmacnianie zaufania społecznego do naukowo zweryfikowanej produkcji zwierzęcej, zwłaszcza w Europie Środkowo-Wschodniej.

Podsumowując, dzięki klasycznym czujnikom (mikrofonom, akcelerometrom, transponderom RFID i termometrom oraz nowocześniejszym urządzeniom, takim jak kamery CCTV i smartfony) hodowcy mogą odkrywać wzorce zachowań zwierząt i optymalizować produkcję (Akinsulie i in., 2024).

Komunikacja i edukacja

Interdyscyplinarna współpraca między twórcami AI, naukowcami zajmującymi się zwierzętami i rolnikami jest kluczowa dla ciągłego doskonalenia systemów. Aby rolnicy i lekarze weterynarii potrafili interpretować złożone dane generowane przez algorytmy, potrzebne są skuteczne programy szkoleniowe, zwłaszcza rozwijające umiejętności matematyczne i statystyczne.

Nowe pokolenie studentów weterynarii w regionie CEE powinno uczestniczyć w kursach z zakresu cyfrowej medycyny weterynaryjnej (Meletis i in., 2024). Choć podobne zajęcia są już standardem na wielu uczelniach Europy Zachodniej, Ameryki Północnej i Australii, w Polsce do roku akademickiego 2024/2025 żaden wydział weterynarii nie oferował pełnego, dedykowanego przedmiotu. Wyjątek stanowi seminarium „AI w weterynarii" (aivetconference.com, wiosna 2024, 2025 i planowane na 2026) na Uniwersytecie Przyrodniczym we Wrocławiu, kontynuujące tradycję tamtejszych Seminariów Zastosowań Matematyki. To jednak zbyt mało jak na kraj o tak silnych tradycjach rolniczych i weterynaryjnych, w których polskie wydziały plasują się w pierwszej setce światowych rankingów (Maksymowicz i in., 2024), podczas gdy najwyżej notowana polska uczelnia oceniana całościowo zajmuje około 600. miejsce (Ponikowski, 2024). Międzynarodowe wydarzenia, takie jak Symposium on Artificial Intelligence in Veterinary Medicine (2024 i 2025, USA), Symposium on Veterinary Epidemiology and Economics Symposium (Australia, 2024) czy Artificial Intelligence 4 Animal Science (2025, Szwajcaria), zazwyczaj przyciągają obywateli polskich pracujących w zagranicznych instytucjach i tylko bardzo rzadko angażują polskie uniwersytety lub firmy. Doświadczenie autora w prowadzeniu podobnych kursów pokazuje, że studenci najlepiej przyswajają wiedzę podczas praktycznych sesji z wykorzystaniem LLM, takich jak ChatGPT, w kontekście medycyny i weterynarii (Jarynowski, Romanowska, i in., 2023).

Rekomendacje dla uczelni i ośrodków kształcenia podyplomowego:

- Wdrożyć osobne przedmioty z cyfrowej medycyny weterynaryjnej, łączące wykłady i laboratoria (programowanie w R/python, analiza danych, podstawy LLM, obsługa sensorów, modelowanie epizootyczne w formie gier symulacyjnych).
- Uzupełnić istniejące zajęcia kliniczne o moduły wykorzystujące rzeczywiste dane z czujników, nagrań wideo i bio-sygnałów.
- Rozszerzyć współpracę z lokalnymi ekspertami AI (częściej to będą firmy niż uczelnie i instytutu badawcze) oraz alumni pracującymi w ośrodkach zagranicznych (zwłaszcza SGGW, UP-Poz, UJ-UR, UPWr), podobnie jak to się dzieje w ramach polskiego programu badawczego AI https://www.qaif.org/events/aintern.

AI Act a telemedycyna weterynaryjna w Polsce

AI Act (Rozporządzenie UE 2024/1689) klasyfikuje systemy AI stosowane u zwierząt jako wysokiego ryzyka i nakłada obowiązek analizy ryzyka, oceny zgodności, monitoringu oraz pełnej transparentności (Komisja Europejska, 2024).
Polskie przepisy nie blokują takich rozwiązań – wręcz przeciwnie, tworzą furtkę. Ustawa o zawodzie lekarza weterynarii (Dz.U. 2023, poz. 154) zobowiązuje do pracy „zgodnie ze współczesną wiedzą naukową", pozostawiając wybór narzędzi. Kodeks Etyki Lekarza Weterynarii daje swobodę metod diagnostycznych; zaznaczając, że odpowiedzialność dotyczy decyzji klinicznej, nie technologii. Ustawa o zakładach leczniczych (Dz.U. 2019, poz. 24) nakazuje świadczenia usługi weterynaryjnej przez lekarza weterynarii posiadającego prawo wykonywania zawodu, w ramach działalności zakładu leczniczego dla zwierząt, nie wyklucza ona natomiast świadczenia tych usług poza siedzibą tego zakładu, co do zasady. Brak osobnych regulacji teleporad oznacza, że zasada technicznej neutralności prawa dopuszcza konsultacje online. Międzynarodowe wytyczne wspierają innowacje: Federacja Europejskich Izb Weterynaryjnych FVE (2024) zaleca telemedycynę i AI, a OECD/WHO/WOAH wskazują cyfrową weterynarię jako filar zdrowia zwierząt, a wedle strategii One Health (Parlament Europejski, 2024) wymagania prawne telemedyczne wobec lecznictwa zwierząt mają być uwspólnianie z medycyną ludzką. Regulacje prawna w zakresie weterynarii, wielokrotnie nowelizowana, jest przestarzała, nie uwzględnia dynamicznie zmieniającej się rzeczywistości technologicznej oraz nie koreluje z ogólnoświatowymi trendami i zaleceniami, a niekiedy także wiążącymi państwa regulacjami prawnymi na poziomie międzynarodowym czy unijnym. W regionie Polsce wykorzystanie AI w kontekście dobrostanu zwierząt i bioasekuracji dopiero się rozwija, a eksperci podczas spotkań weterynaryjnych w latach 2024–2025 podkreślali, że AI nie zastąpi wkrótce doświadczonych lekarzy weterynarii. Wskazano również na rozbieżność między badaniami naukowymi (głównie systemy oparte na computer vision i large language models przetwarzających dane nieustrukturyzowane) a praktycznymi wdrożeniami (bazującymi na sensorach i analizie ustrukturyzowanych danych produkcyjnych) oraz omówiono przyczyny tej rozbieżności. W dyskusji o powołaniu Agencji Badań Medycyny Weterynaryjnej warto uwzględnić polskie firmy, a nie uniwersytety i instytuty badawcze jako najważniejszy „koń pociągowy" AI w medycynie weterynaryjnej.

Wnioski końcowe

Sztuczna inteligencja ma olbrzymi potencjał w poprawie wydajności i dobrostanu w produkcji mleka, wołowiny i wieprzowiny (Jarynowski, 2024). Jej wdrażanie wymaga jednak:

- Zarządzania ryzykiem związanym z dobrostanem zwierząt oraz nadmiernym poleganiem na technologii oraz zgodnością z prawem krajowym i unijnym,
- Systematycznej edukacji rolników i lekarzy weterynarii,
- Ścisłej współpracy pomiędzy centrami badawczymi (przede wszystkim komercyjnymi) a branżą.

Tylko spełnienie tych warunków pozwoli w pełni wykorzystać możliwości AI, minimalizując jednocześnie zagrożenia dla zwierząt, ludzi i środowiska. Brak inicjatywy może skutkować utratą potencjału innowacyjnego, a w efekcie marginalizacją polskiej nauki i praktyki weterynaryjnej. Tym bardziej, że inteligentne rozwiązania mogą być kołem zamachowym rolnictwa redukując przestrzenne nierówności w dochodach w Polsce i przeciwdziałać wyludnianiu wsi oraz zapewnienić dobrostan zwierząt (Jarynowski, i in., 2025).

Piśmiennictwo:

1. Adejola, Y. A., Sibanda, T. Z., Ruhnke, I., Boshoff, J., Pokhrel, S., & Welch, M. (2025). Analyzing the Risk of Short-Term Losses in Free-Range Egg Production Using Commercial Data. Agriculture, 15(7), 743.
2. Akinsulie, O. C., Idris, I., Aliyu, V. A., Shahzad, S., Banwo, O. G., Ogunleye, S. C., Olorunshola, M., Okedoyin, D. O., Ugwu, C., Oladapo, I. P., & others. (2024). The potential application of artificial intelligence in veterinary clinical practice and biomedical research. Frontiers in Veterinary Science, 11, 1347550.
3. Andresen, N., Wöllhaf, M., Hohlbaum, K., Lewejohann, L., Hellwich, O., Thöne-Reineke, C., & Belik, V. (2020). Towards a fully automated surveillance of well-being status in laboratory mice using deep learning: Starting with facial expression analysis. PLOS ONE, 15(4), e0228059. https://doi.org/10.1371/journal.pone.0228059
4. Belik, V., Jarynowski, A., & Sergeeva, A. (2024, wrzesień). Enhancing Cattle Pain Assessment: Integrating Machine Learning with Traditional Scoring Methods. Epidemiologie und One Health.
5. Belik, V., Jarynowski, A., Turan, C., Radas, S., Welch, M., & Ruhnke, I. (2024, wrzesień). Investigating the impact of free-range hens mobility and contact patterns on egg production. Epidemiologie und One Health.
6. Bellamy, J. E. C. (2023). Artificial intelligence in veterinary medicine requires regulation. The Canadian Veterinary Journal = La Revue Veterinaire Canadienne, 64(10), 968–970.
7. Benos, L., Tagarakis, A. C., Dolias, G., Berruto, R., Kateris, D., & Bochtis, D. (2021). Machine Learning in Agriculture: A Comprehensive Updated Review. Sensors, 21(11), 3758. https://doi.org/10.3390/s21113758
8. Bryant, C., Aiking, H., Alessandrini, R., Behrens, P., Creutzig, F., Eshel, G., Green, R., Hutchings, N., Leip, A., Milo, R., Smith, P., & Van Zanten, H. (2024). The Dublin Declaration fails to recognize the need to reduce industrial animal agriculture. Nature Food. https://doi.org/10.1038/s43016-024-01054-2
9. Burti, S., Banzato, T., Coghlan, S., Wodzinski, M., Bendazzoli, M., & Zotti, A. (2024). Artificial intelligence in veterinary diagnostic imaging: Perspectives and limitations. Research in Veterinary Science, 175, 105317. https://doi.org/10.1016/j.rvsc.2024.105317
10. Busch, F., Hoffmann, L., Truhn, D., Ortiz-Prado, E., Makowski, M. R., Bressem, K. K., Adams, L. C., COMFORT Consortium, Abdala, N., Navarro, Á. A., Aerts, H. J. W. L., Águas, C., Aineseder, M., Alomar, M., Angkurawaranon, S., Angus, Z. G., Asouchidou, E., Bakhshi, S., Bamidis, P. D., … Zhang, L. (2024). Global cross-sectional student survey on AI in medical, dental, and veterinary education and practice at 192 faculties. BMC Medical Education, 24(1), 1066. https://doi.org/10.1186/s12909-024-06035-4
11. Chmielewski, M., & Kasprzyk, R. (2018). Zastosowanie technologii informatycznych w ochronie zdrowia i bezpieczeństwie obywalil (s. 139–162).
12. Chowdhury, A., Kabir, K. H., Abdulai, A.-R., & Alam, M. F. (2023). Systematic Review of Misinformation in Social and Online Media for the Development of an Analytical Framework for Agri-Food Sector. Sustainability, 15(6), 4753. https://doi.org/10.3390/su15064753
13. Czekaj, Ł. (2017). Modele Bayesowskie. Co ma wspólnego Logistyka Morska i Epidemiologia? ML Gdańsk, Gdańsk. https://www.mlgdansk.pl/spotkania-grafik/
14. Ćwiklicki, M., Duplaga, M., & Klich, J. (Red.). (2022). The digital transformation of healthcare: Health 4.0. Routledge.
15. Davies, H., Nenadic, G., Alfattni, G., Arguello Casteleiro, M., Al Moubayed, N., Farrell, S. O., Radford, A. D., & Noble, P.-J. M. (2024). Text mining for disease surveillance in veterinary clinical data: Part one, the language of veterinary clinical records and searching for words. Frontiers in Veterinary Science, 11, 1352239. https://doi.org/10.3389/fvets.2024.1352239
16. Dong, G., & Belik, V. (2023). Deep convolutional models for cattle pose estimation [Doktorancka praca śródokresowa]. FU Berlin.
17. Duch, W., Nałęcz, M., Korbicz, J., Rutkowski, L., & Tadeusiewicz, R. (2000). Sieci neuronowe. Akademicka Oficyna Wydawnicza Exit.
18. Edwards, S. (Red.). (2021). Understanding the behaviour and improving the welfare of pigs. Burleigh Dodds Science Publishing Limited.
19. Facilitating PLF Technology Adoption in the Pig and Poultry Industries. (2024). Studies in Agricultural Economics. https://doi.org/10.7896/j.2725
20. Fang, C., Zhang, T., Zheng, H., Huang, J., & Cuan, K. (2021). Pose estimation and behavior classification of broiler chickens based on deep neural networks. Computers and Electronics in Agriculture, 180, 105863.
21. Fernandes, A. F. A., Dórea, J. R. R., Fitzgerald, R., Herring, W., & Rosa, G. J. M. (2020). A novel automated system to acquire biometric and morphological measurements and predict body weight of pigs via 3D computer vision. Journal of Animal Science, 98(3), skaa021.
22. Gradon, K. T. (2024). Generative artificial intelligence and medical disinformation. BMJ, q579. https://doi.org/10.1136/bmj.q579
23. Grodkowski, G., Szwaczkowski, T., Koszela, K., Mueller, W., Tomaszyk, K., Baars, T., & Sakowski, T. (2022). Early detection of mastitis in cows using the system based on 3D motions detectors. Scientific Reports, 12(1), 21215. https://doi.org/10.1038/s41598-022-25275-2
24. Grys, B. T., Lo, D. S., Sahin, N., Kraus, O. Z., Morris, Q., Boone, C., & Andrews, B. J. (2017). Machine learning and computer vision approaches for phenotypic profiling. Journal of Cell Biology, 216(1), 65–71. https://doi.org/10.1083/jcb.201610026
25. Grzesiak, W., Zaborski, D., Pilarczyk, R., Wójcik, J., & Adamczyk, K. (2023). Classification of Daily Body Weight Gains in Beef Calves Using Decision Trees, Artificial Neural Networks, and Logistic Regression. Animals, 13(12), 1956. https://doi.org/10.3390/ani13121956
26. Hayes, B. H., Vergne, T., Rose, N., Mortasivu, C., & Andraud, M. (2024). A multi-host mechanistic model of African swine fever emergence and control in Romania. https://doi.org/10.1101/2024.01.09.574784
27. Herwart, M. (2023). Wykorzystanie sztucznej inteligencji w pracy hodowlanej i w projektach badawczych. 13. Ogólnopolska Konferencja Echa Kongresu ESPHM.
28. Jarynowski, A. (2023). Agroterrorism involving biological agents and related threats in Poland and Europe in the context of the COVID-19 pandemic and the war in Ukraine. Terroryzm, 4 (4), 405–444. https://doi.org/10.4467/27204383TER.23.032.18334
29. Jarynowski, A. (2024). Protesty rolników a hodowla zwierząt jako koło zamachowe dobrobytu na prowincji w obliczu kryzysu. Nowa Konfederacja. https://nowakonfederacja.pl/nadchodzi-szosta-fala-pandemii-covid-19-jak-sobie-z-nia-radzic/
30. Jarynowski, A., & Belik, V. (2019). African Swine Fever (ASF) Virus propagation in Poland (Spatio-temporal analysis).
31. Jarynowski, A., Buda, A., PŁATEK, D., & Belik, V. (2019). African Swine Fever Awareness in the Internet Media in Poland–exploratory review. E-methodology, 6(6), 100–115.
32. Jarynowski, A., Czekaj, Ł., Semenov, A., & Belik, V. (2024). Multiplex Network Approach for Modeling the Spread of African Swine Fever in Poland. W M. H. Hà, X. Zhu, & M. T. Thai (Red.), Computational Data and Social Networks (T. 14479, s. 349–360). Springer Nature Singapore. https://doi.org/10.1007/978-981-97-0669-3_32
33. Jarynowski, A., Krzowski, Ł., Maksymowicz, S., & Romanowska, M. (2024). Assessing Large Language Models in the Context of Bioterrorism: An Epidemiological Perspective with Experimental Insights. War Science Academy, Warsaw. https://www.slideshare.net/slideshow/assessing-large-language-models-in-the-context-of-bioterrorism-an-epidemiological-perspective-with-experimental-insights/269599413
34. Jarynowski, A., Maksymowicz, S., & Ślósarz, L. (2023). The future of AI in medicine and education—10th anniversary of E-methodology community. E-methodology, 10(10), 6–12.
35. Jarynowski, A., & Romanowska, M. (2024). Sztuczna inte-

ligencja/uczenie maszynowe w kontroli chorób zakaźnych-Wprowadzenie do generatywnej sztucznej inteligencji i LLM.
36. Jarynowski, A., Romanowska, M., & Belik, V. (2023). Nasłuchiwanie nowych mediów w celu monitorowania stosowania środków przeciwdrobnoustrojowych i ich percepcji. IPF, Olsztyn. http://interdisciplinary-research.eu/wp-content/uploads/2023/11/antybiotyki_same.pdf
37. Kjosevski, M., Nikolovski, M., Ilievska, K., Pendovski, L., & Ilieski, V. (2021). The three pillars of applied farm animal welfare. Veterinarski glasnik, 75(2), 99–111.
38. Kolasa, K., Admassu, B., Hołownia-Voloskova, M., Kędzior, K. J., Poirrier, J.-E., & Perni, S. (2024). Systematic reviews of machine learning in healthcare: A literature review. Expert Review of Pharmacoeconomics & Outcomes Research, 24(1), 63–115. https://doi.org/10.1080/14737167.2023.2279107
39. Lardy, R., Botreau, R., De Boyer Des Roches, A., Van Eerdenburg, F. J. C. M., De Graaf, S., Haskell, M. J., Kirchner, M. K., Mounier, L., Kjosevski, M., Tuyttens, F. A. M., & Veissier, I. (2023). Improvement of the Welfare Quality scoring model for dairy cows to fit experts' opinion. Animal, 17(11), 101018. https://doi.org/10.1016/j.animal.2023.101018
40. Lavrova, A. I., Choucair, A., Palmini, A., Stock, K. F., Kammer, M., Querengässer, F., Doherr, M. G., Müller, K. E., & Belik, V. (2023). Leveraging Accelerometer Data for Lameness Detection in Dairy Cows: A Longitudinal Study of Six Farms in Germany. Animals, 13(23), 3681. https://doi.org/10.3390/ani13233681
41. Maksymowicz, S. (2023). Zielony Ordokonserwatyzm. Nowa Konfederacja. https://nowakonfederacja.pl/wp-content/uploads/2023/12/Raport_Zielony_ordokonserwatyzm.pdf
42. Maksymowicz, S., Jarynowski, A., Belik, V., Sergiejewa, A., Romanowska, M., Skawina, I., Kubacki, J., Krzowski, Ł., Meletis, E., & Kostoulas, P. (2024, czerwiec 14). Monitoring i nasłuch epidemiologiczny: „One-Health – Jedno Zdrowie – Jedna Planeta". One-Health – Jedno Zdrowie – Jedna Planeta, Olsztyn.
43. Meletis, E., Jarynowski, A., Maksymowicz, S., Kostoulas, P., & Belik, V. (2024). Animal Health Discourse during Ecological Crises in the Media—Lessons Learnt from the Flood in Thessaly from the One Health Perspective. Veterinary Sciences, 11(4), 140. https://doi.org/10.3390/vetsci11040140
44. Mencel, M., Maksymowicz, S., Jarynowski, A., Bogacz, K., Szczegielniak, J., & Belik, V. (2025). Attitude towards Telemedicine among various health students in Wrocław. E-methodology, 12(12).
45. Milanovic, B. (2016). Global Inequality: A New Approach for the Age of Globalization. Cambridge/Harvard University Press.
46. Neethirajan, S. (2017). Recent advances in wearable sensors for animal health management. Sensing and Bio-Sensing Research, 12, 15–29.
47. Oczak, M., Maschat, K., & Baumgartner, J. (2023). Implementation of Computer-Vision-Based Farrowing Prediction in Pens with Temporary Sow Confinement. Veterinary Sciences, 10(2), 109. https://doi.org/10.3390/vetsci10020109
48. Palmini, A., Jarynowski, A., Welch, M., Belik, V., Sibanda, T., & Ruhnke, I. (2023). Infectious disease spread in free-range egg-laying hens based on empirical mobility patterns and contact networks. 25th International Congress on Modelling and Simulation, 664. mssanz.org.au/modsim2023
49. Ponikowski, P. (Reżyser). (2024). Uniwersytet Medyczny wyprzedził takie instytucje jak Uniwersytet Jagielloński oraz Uniwersytet Warszawski i został najlepszą uczelnią w Polsce. [Broadcast]. https://www.radiowroclaw.pl/articles/view/144954/Gosciem-Rozmowy-Dnia-Radia-Wroclaw-jest-prof-Piotr-Ponikowski
50. Racewicz, P., Ludwiczak, A., Skrzypczak, E., Składanowska-Baryza, J., Biesiada, H., Nowak, T., Nowaczewski, S., Zaborowicz, M., Stanisz, M., & Ślósarz, P. (2021). Welfare Health and Productivity in Commercial Pig Herds. Animals, 11(4), 1176. https://doi.org/10.3390/ani11041176
51. Romaszko-Wojtowicz, A., Jaśkiewicz, Ł., Jurczak, P., & Doboszyńska, A. (2023). Telemedicine in Primary Practice in the Age of the COVID-19 Pandemic—Review. Medicina, 59(9), 1541. https://doi.org/10.3390/medicina59091541
52. Serwata, D., Nurek, M., & Michalski, R. (2024). A Perspective on the Ubiquity of Interaction Streams in Human Realm. W L. Franco, C. De Mulatier, M. Paszynski, V. V. Krzhizhanovskaya, J. J. Dongarra, & P. M. A. Sloot (Red.), Computational Science – ICCS 2024 (T. 14836, s. 353–367). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-63775-9_26
53. Sibanda, T. Z., Belik, V., Jarynowski, A., Welch, M., Boshoff, J., Schneider, D., Ruhnke, I., & edited by P. A. Robinson & K. M. McIntyre and the SVEPM Executive Committee. (2022). Understanding time series of RFID sensor data for predicting mortality in laying hens (s. 197–207). SVEPM. http://interdisciplinary-research.eu/wp-content/uploads/2022/03/SVEPM_Proceedings_jarynowski_hens.pdf
54. Szczepaniak, P., Kalinowski, P., Ułanowicz, L., & Sibilski, K. (2023). Zastosowanie aerofotogrametrii w podczerwieni do śledzenia dzików w ich naturalnym środowisku oraz identyfikacji osobników zarażonych afrykańskim pomorem świń. Cz. II–badania systemu ASFochrona. XX Konferencja „Mechanika w Lotnictwie (ML-XX)".
55. Tadeusiewicz, R., & Korohoda, P. (1997). Komputerowa analiza i przetwarzanie obrazów. Wydawnictwo Fundacji Postępu Telekomunikacji.
56. Tokgöz, P., Krayter, S., Hafner, J., & Dockweiler, C. (2024). Decision support systems for antibiotic prescription in hospitals: A survey with hospital managers on factors for implementation. BMC Medical Informatics and Decision Making, 24(1), 96. https://doi.org/10.1186/s12911-024-02490-7
57. Wang, S., Zhao, K., Chen, Z., Liu, D., Tang, S., Sun, C., Chen, H., Wang, Y., & Wu, C. (2024). Halicin: A New Horizon in Antibacterial Therapy against Veterinary Pathogens. Antibiotics, 13(6), 492. https://doi.org/10.3390/antibiotics13060492
58. Wełeszczuk, J., Kosińska-Selbi, B., & Cholewińska, P. (2022). Prediction of Polish Holstein's economical index and calving interval using machine learning. Livestock Science, 264, 105039. https://doi.org/10.1016/j.livsci.2022.105039
59. WHO. (2024). Ethics and governance of artificial intelligence for health: Guidance on large multi-modal models. World Health Organization. https://iris.who.int/handle/10665/375579
60. Yamsakul, P., Yano, T., Department of Food Animal Clinic, Faculty of Veterinary Medicine, Chiang Mai University, Chiang Mai 51000 Thailand, Na Lampang, K., Department of Veterinary Bioscience and Veterinary Public Health, Faculty of Veterinary Medicine, Chiang Mai University, Chiang Mai 50100, Thailand, Khamkong, M., Department of Statistics, Faculty of Science, Chiang Mai University, Chiang Mai 50100, Thailand, Srikitjakarn, L., & PODD center, Chiang Mai University, Chiang Mai 50100, Thailand. (2023). Classification and correlation of coughing sounds and disease status in fattening pigs. Veterinary Integrative Sciences, 21(2), 291–308. https://doi.org/10.12982/VIS.2023.023
61. Ziętara, W., & Mirkowska, Z. (2024). Rolnictwo ekologiczne w Polsce – uwarunkowania i kierunki rozwoju. Wieś i Rolnictwo, 1 (202), 69–93. https://doi.org/10.53098/wir.2024.1.202/03
62. Zybertowicz, A., & Piekutowski, J. (2022). Cyber kontra real: Cywilizacja w techno-pułapce (S. Maksymowicz, Red.). Wydawnictwo Nowa Konfederacja.
63. Komisja Europejska. (2024). Regulation (EU) 2024/1689 on harmonised rules on artificial intelligence (AI Act). Official Journal of the European Union, L 163.
64. Federation of Veterinarians of Europe. (2024). Position and recommendations on the use of telemedicine in veterinary practice. Brussels: FVE.
65. Parlament Europejski. (2024). Resolution on proposals for amending the treaties (C/2024/4216).
66. Jarynowski, A., Semenov, A., Platek, D., & Belik, V. (2025). Tracing farmers' protests online in Europe 2024. In International Conference on Computational Data and Social Networks (pp. 365–372)

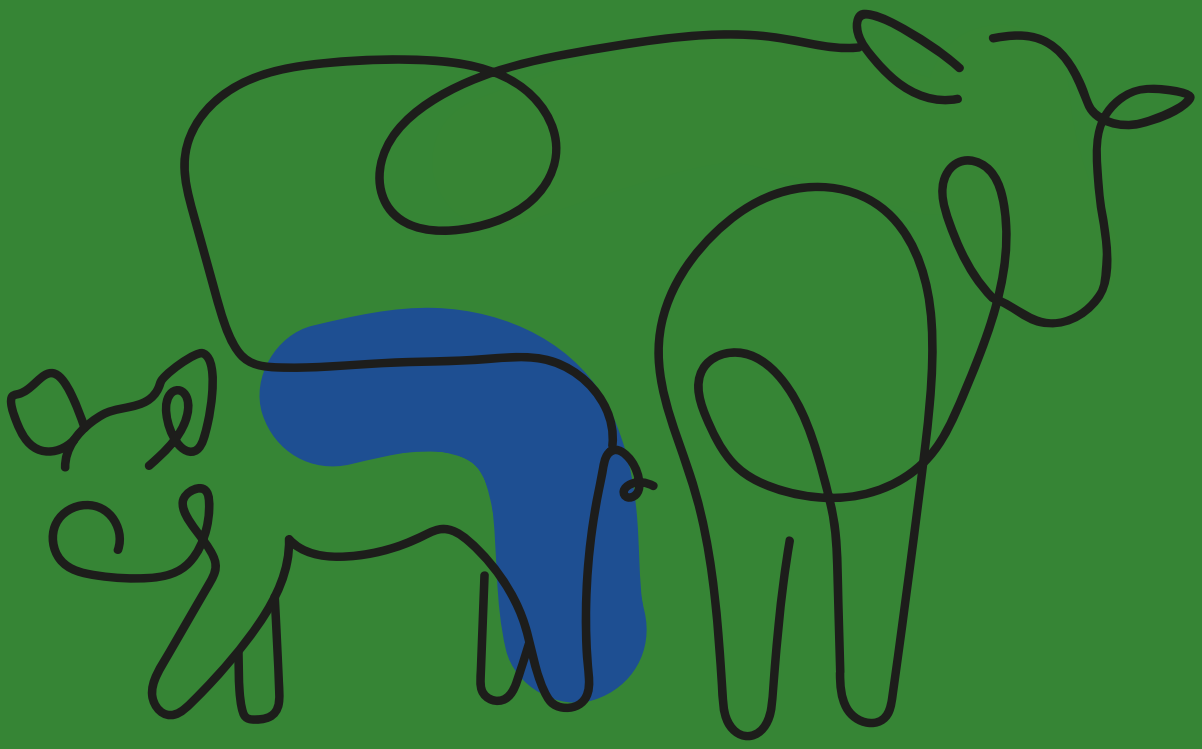

15. edycja Konferencji

ECHA KONGRESOW