


SZTUCZNA INTELIGENCJA W MEDYCYNIE WETERYNARYJNEJ – OD PODSTAW DO PRAKTYKI

Maciej Gad¹, Monika Szymańska²

¹PolyversAI, ²Librax AI

Ryc. 1. Kamienie milowe rozwoju sztucznej inteligencji w medycynie weterynaryjnej (2010–2024).



Na osi czasu zaznaczono przełomowe momenty w rozwoju technologii AI i jej zastosowań w praktyce weterynaryjnej, od pierwszych symulacji edukacyjnych po zaawansowane systemy wspomagania decyzji klinicznych.

Wprowadzenie

Sztuczna inteligencja (SI, ang. artificial intelligence – AI) to dziedzina informatyki, której celem jest tworzenie systemów i maszyn zdolnych do wykonywania zadań wymagających ludzkiej inteligencji. SI obejmuje technologie, które pozwalają maszynom uczyć się na podstawie doświadczeń, rozwiązywać złożone problemy oraz podejmować decyzje. W ostatnich latach obserwujemy intensywny rozwój SI w niemal każdej dziedzinie życia, w tym w medycynie ludzkiej i weterynaryjnej. Dynamiczny rozwój mocy obliczeniowej i technik głębokiego uczenia sprawił, że SI stała się realnym wsparciem także dla lekarzy weterynarii, mogąc usprawnić diagnostykę i terapię w codziennej praktyce. W niniejszym artykule przedstawiamy najważniejsze pojęcia związane z SI, podstawy jej działania oraz perspektywy jej zastosowania w medycynie weterynaryjnej.

Historia sztucznej inteligencji

Historia SI sięga lat 50. XX wieku, kiedy to Alan Turing zaproponował test mający ocenić, czy maszyna może wykazywać cechy ludzkiej inteligencji (test Turinga). W 1956 roku na konferencji w Dartmouth po raz pierwszy użyto terminu „sztuczna inteligencja”, inicjując formalne badania w tej dziedzinie. W latach 60. i 70. XX wieku powstały pierwsze systemy eksperckie, takie jak MYCIN (1976), który diagnozował bakteryjne zakażenia krwi u ludzi – ta technologia stała się inspiracją dla późniejszych narzędzi weterynaryjnych. Przełomem dla SI okazał się rozwój uczenia maszynowego w latach 80., a zwłaszcza publikacja algorytmu back-

propagation (1986), który umożliwił efektywne trenowanie wielowarstwowych sieci neuronowych.

W weterynarii pierwsze eksperymenty z SI pojawiły się dopiero w latach 90., głównie w zakresie symulacji edukacyjnych dla studentów. Prawdziwy przełom nastąpił w latach 2010–2020, gdy upowszechnienie dużych zbiorów danych (np. otwartych repozytoriów obrazów RTG zwierząt) oraz rozwój frameworków do głębokiego uczenia (TensorFlow, PyTorch) umożliwiły tworzenie wyspecjalizowanych modeli dla weterynarii. W 2018 roku opublikowano przełomowe badanie (2), w którym sieć neuronowa osiągnęła 95 % dokładności w rozpoznawaniu nowotworów sutka u suk na podstawie obrazów histopatologicznych – to wydarzenie uznaje się za kamień milowy w praktycznym zastosowaniu SI w tej dziedzinie.

Podstawowe pojęcia – sztuczna inteligencja (SI), uczenie maszynowe (ML) i głębokie uczenie (DL)

Chociaż terminy takie jak SI, uczenie maszynowe (ML) i głębokie uczenie (DL) są ze sobą ściśle powiązane, odnoszą się do różnych podejść w tworzeniu inteligentnych systemów. SI to ogólny termin dotyczący każdego systemu komputerowego, który może wykonywać zadania wymagające ludzkiej inteligencji. Uczenie maszynowe (ML) to podgrupa SI, która zakłada, że maszyny uczą się na podstawie danych, a nie wyłącznie na wstępnie zaprogramowanych regułach. Głębokie uczenie (DL) to bardziej zaawansowana forma ML, oparta na sieciach neuronowych wzorowanych na strukturze ludzkiego mózgu. Sieci te są w stanie analizować ogrom-

Artificial Intelligence in veterinary medicine – from basics to practice

Artificial intelligence (AI) is transforming veterinary medicine by enhancing diagnostic accuracy, personalizing treatment, and improving patient management. This article explores AI's applications in diagnostic imaging, internal medicine, and therapy, highlighting its potential to support veterinarians, reduce diagnostic errors, and optimize treatment processes. Challenges such as data availability, ethical concerns, and implementation costs are also discussed. AI's ability to analyze complex data sets and provide real-time monitoring offers significant benefits for animal health and welfare.

Keywords: Artificial Intelligence, Veterinary Medicine, Diagnostic Imaging, Personalized Therapy, Predictive Algorithms.

ne ilości danych i wyciągać z nich wnioski, co sprawia, że DL jest szczególnie przydatne w takich dziedzinach jak rozpoznawanie obrazów czy dźwięków.

ML – uczenie maszynowe

Uczenie maszynowe w weterynarii opiera się głównie na modelach nadzorowanych, takich jak drzewa decyzyjne, lasy losowe oraz algorytmy gradient boosting (np. XGBoost). W ostatnich latach rośnie także popularność metod nienadzorowanych, np. grupowania (clustering), które pomagają w segmentacji danych klinicznych bez konieczności ręcznego etykietowania.

DL – głębokie uczenie

Głębokie sieci neuronowe, takie jak konwolucyjne sieci neuronowe (CNN), znajdują zastosowanie w analizie obrazów weterynaryjnych, umożliwiając automatyczną detekcję zmian patologicznych w RTG i USG. Z kolei modele rekurencyjne (RNN, LSTM) mogą być wykorzystywane do analizy sygnałów EKG u zwierząt, identyfikując nieregularności pracy serca w czasie rzeczywistym.

NLP – przetwarzanie języka naturalnego

Natural Language Processing (NLP) jest coraz częściej wykorzystywane

Tab. 1. Zastosowania sztucznej inteligencji w diagnostyce weterynaryjnej.

(Zestawienie głównych metod SI wraz z ich obszarami zastosowania i udokumentowaną skutecznością na podstawie badań klinicznych. Uwagę zwracają wysokie wskaźniki czułości (90–97 %) w rozpoznawaniu zmian nowotworowych i kardiologicznych, co podkreśla przydatność SI w przyspieszaniu diagnozy i redukcji błędów.).

Metoda AI	Obszar zastosowania	Skuteczność	Źródło
Deep Learning CNN	Wykrywanie kardiomegalii (RTG)	92 %	Źródło
Machine Learning	Predykcja AKI u psów	89 %	Źródło
Neural Networks	Diagnostyka nowotworów	97 %	Źródło
Real-time ML	Detekcja arytmii	95 %	Źródło
Computer Vision	Analiza obrazów mikroskopowych	88 %	Źródło

w weterynarii do analizy dokumentacji medycznej, umożliwiając automatyczne przetwarzanie notatek klinicznych i raportów diagnostycznych. Modele takie jak BERT czy GPT mogą pomagać w strukturyzacji danych pacjentów, przyspieszając proces decyzyjny lekarzy weterynarii.

Zastosowania SI w medycynie weterynaryjnej

Korzyści płynące z zastosowania SI w weterynarii są nie do przecenienia. Wśród nich wymienić można wzrost precyzji diagnostycznej, lepszą personalizację leczenia oraz optymalizację procesów w klinikach. SI może wykonywać zadania czasochłonne i skomplikowane, pozwalając lekarzom skupić się na bardziej złożonych przypadkach. Ponadto SI usprawnia organizację pracy (np. zarządzanie harmonogramami, obsługę płatności). Jednym z kluczowych zastosowań jest szybsze wykrywanie problemów zdrowotnych u zwierząt, co ma szczególne znaczenie w przypadkach wymagających pilnej interwencji (3).

Choć zastosowania SI w medycynie ludzkiej są już dobrze udokumentowane, w weterynarii technologia ta jest nadal w fazie eksperymentalnej, ale jej potencjał jest ogromny.

Personalizacja leczenia i monitorowanie zdrowia

SI przyczynia się do personalizacji leczenia, analizując dane z poprzednich wizyt, historię chorób i wyniki badań, aby zaproponować najbardziej efektywne terapie (4). W przypadku chorób przewlekłych, takich jak cukrzyca, niewydolność serca czy choroby nerek, SI może pomóc w ustaleniu optymalnej dawki leków, częstotliwości podawania i monitorowania stanu pacjenta. Systemy te mogą analizować dane z urządzeń monitorujących (glukometry, czujniki tętna) i w trybie ciągłym dostosowywać terapię.

W internistyce weterynaryjnej SI znajduje zastosowanie w diagnozowaniu chorób metabolicznych, endokrynologicznych i kardiologicznych (5). Algorytmy predykcyjne pozwalają na przewidywanie przebiegu chorób na podstawie danych klinicznych (wyniki badań laboratoryjnych czy historia chorób).

Diagnostyka obrazowa

W medycynie ludzkiej SI jest już z powodzeniem stosowana do analizy zdjęć rentgenowskich, tomografii komputerowych (TK) czy rezonansu magnetycznego (MRI). W medycynie weterynaryjnej potencjał jest podobny. Algorytmy głębokiego uczenia potrafią wykrywać niewielkie zmiany patologiczne w obrazach RTG i USG, co przyspiesza diagnostykę,

a także analizować obrazy tomograficzne pod kątem nowotworów i zmian zapalnych. Badania pokazują, że SI osiąga nawet 92-97 % czułości w wykrywaniu nowotworów u psów na podstawie obrazów histopatologicznych (2).

W innym badaniu Aubreville i współautorzy (12) wykazali, że algorytmy deep learning są w stanie przewyższyć skuteczność doświadczonych patologów weterynaryjnych w wykrywaniu figur mitotycznych w nowotworach. Ich model osiągnął korelację 0,963-0,979 z tzw. ground truth, co dodatkowo potwierdza wysoki potencjał algorytmów CNN w precyzyjnej ocenie zmian morfologicznych.

W najnowszym przeglądzie literatury Hennessey i współautorów (4) podkreślono, że chociaż wciąż istnieje stosunkowo niewielka liczba publikacji na temat SI w weterynaryjnej diagnostyce obrazowej, rozwój tej dziedziny postępuje dynamicznie. Kluczowymi wyzwaniami pozostają jakość i standaryzacja danych, a także współpraca między ekspertami z obszaru weterynarii i specjalistami w dziedzinie uczenia maszynowego.

Sieci neuronowe w analizie obrazów RTG, TK i MRI

Do analizy obrazów medycznych w weterynarii stosuje się głównie konwolucyjne sieci neuronowe (CNN), takie jak ResNet, EfficientNet czy U-Net. Modele te są w stanie segmentować obrazy diagnostyczne, co umożliwia automatyczną identyfikację zmian patologicznych, np. nowotworowych, złamań czy anomalii strukturalnych. Szczególnie U-Net jest wykorzystywany w segmentacji obrazów ultrasonograficznych, pozwalając na lepszą detekcję tkanek i narządów w obrazach niskiej jakości.

Diagnostyka laboratoryjna

W diagnostyce laboratoryjnej SI analizuje i interpretuje wyniki badań, takie jak morfologia krwi, badania biochemiczne czy analiza moczu. Dzięki zaawansowanym algorytmom SI jest w stanie wykrywać subtelne wzorce i korelacje w danych, które mogą wskazywać na wczesne stadia chorób lub sugerować ukryte problemy zdrowotne (6).

ML w analizie danych biomedycznych

Modele oparte na algorytmach gradient boosting (np. XGBoost, LightGBM) oraz sieciach neuronowych (np. MLP – Multi-Layer Perceptron) są szeroko

stosowane do analizy laboratoryjnej. Pozwalają one na wykrywanie subtelnych wzorców w wynikach badań krwi czy biochemii, co może wskazywać na rozwijające się choroby, zanim staną się one klinicznie widoczne. Dzięki zastosowaniu technik wyjaśnialnej AI (XAI), takich jak SHAP czy LIME, modele te mogą dostarczać interpretowalnych wyjaśnień, wspierając lekarzy w podejmowaniu decyzji.

Monitorowanie zdrowia w czasie rzeczywistym

Kolejnym istotnym zastosowaniem SI jest monitorowanie stanu zdrowia zwierząt w czasie rzeczywistym. Aplikacje mobilne i urządzenia noszone, zintegrowane z systemami SI, pozwalają na ciągłe śledzenie parametrów życiowych, takich jak tętno, temperatura czy aktywność fizyczna. Dzięki temu możliwe jest wczesne wykrywanie odchyłeń od normy, które mogą sygnalizować rozwijające się problemy zdrowotne. W przypadku zwierząt hodowlanych systemy te mogą monitorować całe stada, pomagając w identyfikacji i izolacji chorych osobników oraz zapobiegając rozprzestrzenianiu się chorób zakaźnych.

SI w urządzeniach noszonych i telemedycynie

Systemy oparte na Long Short-Term Memory (LSTM) oraz Transformerach mogą analizować sygnały z urządzeń noszonych (wearables) w czasie rzeczywistym. Dzięki algorytmom wykrywającym anomalie, takim jak Isolation Forest czy One-Class SVM, możliwe jest identyfikowanie nieprawidłowości w rytmie serca, aktywności zwierzęcia czy temperaturze ciała, co pozwala na szybsze reagowanie na potencjalne zagrożenia zdrowotne.

Automatyzacja diagnostyki mikroskopowej

W diagnostyce mikroskopowej SI automatycznie identyfikuje i klasyfikuje komórki, pasożyty, bakterie czy inne mikroorganizmy obecne w preparatach. Na przykład w badaniach parazytologicznych systemy SI są w stanie szybko przesiewać próbki kału w poszukiwaniu jaj pasożytów, co znacznie skraca czas badania i zwiększa jego dokładność. Podobnie w cytologii algorytmy mogą wspierać patologów w rozpoznawaniu komórek nowotworowych czy atypowych, co jest szczególnie przydatne

w diagnozowaniu chorób nowotworowych u zwierząt (7).

SI w patomorfologii

Modele CNN, takie jak VGG16, InceptionV3 oraz nowsze architektury Vision Transformers (ViT), są używane do klasyfikacji komórek w obrazach histopatologicznych. Dzięki zaawansowanym technikom augmentacji danych oraz samouczących się sieci neuronowych (Self-Supervised Learning) możliwe jest osiągnięcie wyników porównywalnych z oceną manualną wykonywaną przez patologów weterynaryjnych. Metody takie jak GAN (Generative Adversarial Networks) pozwalają z kolei na generowanie syntetycznych obrazów próbek, które można wykorzystać do dalszego szkolenia modeli w warunkach ograniczonej dostępności danych klinicznych.

Korzyści ze stosowania SI w weterynarii

Główne korzyści z zastosowania SI w medycynie weterynaryjnej obejmują:

1. Zwiększoną efektywność diagnostyczną: szybsza i dokładniejsza diagnostyka przekłada się na wcześniejsze wdrożenie leczenia i lepsze rokowanie dla pacjentów.
2. Personalizację terapii: SI umożliwia dostosowanie leczenia do indywidualnych potrzeb pacjenta, co zwiększa skuteczność terapii i minimalizuje ryzyko działań niepożądanych.
3. Redukcję błędów diagnostycznych: obiektywna i precyzyjna analiza danych przez SI pomaga uniknąć błędów wynikających z ludzkich ograniczeń.
4. Optymalizację procesów leczenia: algorytmy SI wspomagają monitorowanie pacjentów i dostosowywanie planów leczenia w czasie rzeczywistym.
5. Poprawę jakości życia pacjentów: wczesna diagnostyka i skuteczniejsze leczenie przekładają się na ogólną poprawę jakości życia zwierząt (9).

Wyzwania związane z wdrażaniem SI w weterynarii

Choć korzyści z SI są liczne, istnieją istotne bariery ograniczające jej powszechne wdrożenie. Według wytycznych Światowego Stowarzyszenia Lekarzy Weterynarii (11), należy zwrócić uwagę na następujące aspekty:

Dostępność i standaryzacja danych

Jednym z kluczowych wyzwań jest ograniczona dostępność wysokiej jakości da-

nych treningowych. Skuteczne modele SI wymagają dużych, reprezentatywnych zbiorów danych, które uwzględniają różnorodność gatunków, ras, chorób i warunków klinicznych.

Kwestie etyczne i prywatność

Wdrażanie SI rodzi także poważne dylematy etyczne. Pierwszym jest kwestia odpowiedzialności za decyzje podejmowane przez algorytmy. Gdy system SI błędnie zdiagnozuje chorobę lub zaleci niewłaściwe leczenie, trudno ustalić, kto ponosi winę: twórca oprogramowania, lekarz nadzorujący czy właściciel kliniki. Dodatkowo, jak zauważają Johnson i Lee (6), pojawia się problem „biasu algorytmicznego”, prywatności danych oraz przejrzystości modeli. Konieczne jest opracowanie jasnych regulacji i standardów etycznych, aby zapewnić bezpieczeństwo pacjentów oraz odpowiedzialność prawną lekarzy i producentów oprogramowania.

Koszty i dostępność technologii

Choć technologie SI oferują ogromny potencjał, ich wdrożenie wiąże się z wysokimi kosztami, co stanowi barierę szczególnie dla mniejszych klinik i gabinetów weterynaryjnych. Koszty obejmują nie tylko zakup sprzętu i oprogramowania, ale także konieczność przeszkolenia personelu oraz utrzymania infrastruktury. Z drugiej strony wiele praktyk zauważa, że automatyzacja pozwala w dłuższej perspektywie skracać czas diagnostyki i redukować liczbę powikłań, co może przekładać się na rozwój bazy pacjentów oraz poprawę przychodów.

Co istotne, badanie ekonomiczne Johnson i współautorów (13) wykazało, że aż 83,8 % klinik odzyskuje poniesione nakłady w ciągu 18-24 miesięcy, głównie dzięki redukcji czasu diagnostyki o 35-40 %. Z kolei według raportu Grand View Research (14), rynek oprogramowania weterynaryjnego osiągnął w 2024 roku wartość 1,44 mld USD, a do 2030 prognozuje się wzrost na poziomie 13,2 % CAGR. Analiza ta wskazuje, że modele subskrypcyjne mogą obniżyć koszty wdrożenia nawet o 60-70 %, co znacząco ułatwia dostęp do zaawansowanych narzędzi SI także mniejszym klinikom.

Dobrze zaprojektowane wdrożenie SI (w tym modele subskrypcyjne lub chmurowe) może więc okazać się opłacalne nawet dla mniejszych klinik, zwłaszcza jeśli uwzględnimy potencjalny wzrost zafundowania klientów i przyspieszenie procedur medycznych.

Tab. 2. Wyzwania we wdrażaniu sztucznej inteligencji w medycynie weterynaryjnej.

(Przedstawiono kluczowe bariery technologiczne, etyczne i finansowe utrudniające powszechne stosowanie SI. Zestawienie ukazuje także potencjalne rozwiązania, takie jak programy szkoleń czy modele subskrypcyjne, które pozwalają mniejszym klinikom czerpać korzyści z SI mimo ograniczonych zasobów.).

Kategoria	Problem	Potencjalne rozwiązania
Dane	Brak standaryzacji danych medycznych	Wprowadzenie jednolitych standardów dokumentacji [13]
Etyka	Odpowiedzialność za decyzje podejmowane przez AI	Jasne wytyczne etyczne i prawne [14]
Koszty	Wysokie koszty wdrożenia i utrzymania systemów	Modele subskrypcyjne, współdzielenie zasobów [4]
Edukacja	Brak przygotowania personelu do pracy z systemami AI	Programy szkoleniowe, symulacje VR [11]

Perspektywy

Sztuczna inteligencja ma potencjał, by zrewolucjonizować kształcenie przyszłych lekarzy weterynarii. Badania wykazują, że symulacje SI mogą zwiększyć efektywność nauki nawet o 30-40 % w porównaniu z tradycyjnymi metodami.

Precyzyjna medycyna

Precyzyjna medycyna, wspierana przez SI, to przyszłość weterynarii, w której leczenie dostosowuje się nie tylko do gatunku czy rasy, lecz także do indywidualnych cech genetycznych, stylu życia i środowiska pacjenta.

Telemedycyna

Telemedycyna, wspierana przez SI, ma ogromny potencjał w poprawie dostępu do opieki weterynaryjnej, szczególnie w rejonach wiejskich lub słabiej rozwiniętych. Zdalne konsultacje mogą być uzupełniane analizami opartymi na SI, co przyspiesza proces diagnostyczny i umożliwia szybką interwencję w razie wykrycia nieprawidłowości.

Współpraca w edukacji i integracja z innymi technologiami

Oprócz telemedycyny i personalizacji leczenia, SI może odegrać kluczową rolę w nowoczesnej edukacji weterynaryjnej. Symulacje i wirtualna rzeczywistość (VR) pozwalają studentom ćwiczyć zabiegi w warunkach kontrolowanych, a algorytmy uczenia maszynowego mogą oceniać postępy w sposób obiektywny. Jest to szczególnie ważne w dziedzi-

nach wymagających precyzji (np. chirurgii). Co więcej, integracja SI z systemami robotycznymi bądź urządzeniami IoT otwiera drogę do jeszcze sprawniejszej diagnostyki i leczenia, stanowiąc ciekawą perspektywę rozwoju weterynarii na poziomie zarówno klinicznym, jak i badawczym.

Zoonozy i zapobieganie chorobom odzwierzęcym

SI może również wspierać monitorowanie i zapobieganie chorobom odzwierzęcym (tzw. zoonozom), które nierzadko stanowią poważne zagrożenie dla zdrowia publicznego. Systemy analizujące dane epidemiologiczne z gospodarstw i klinik weterynaryjnych mogą wcześniej wykrywać ogniska zakażeń, co pozwala na szybką izolację chorych osobników i minimalizowanie rozprzestrzeniania się patogenów. Dzięki temu SI staje się pomostem między medycyną ludzką a weterynaryjną, zwiększając poziom bezpieczeństwa biologicznego i chroniąc zdrowie publiczne.

Podsumowanie


Sztuczna inteligencja w medycynie weterynaryjnej to nie futurystyczna wizja, lecz realne narzędzie, które już dziś wpływa na praktykę kliniczną. Jak wykazują badania, algorytmy SI osiągają czułość na poziomie 92-97 % w wykrywaniu nowotworów u psów na podstawie obrazów histopatologicznych (2). Te liczby potwierdzają, że SI może być nieocenionym wsparciem w codziennej pracy lekarzy



weterynarii. Konieczne jednak jest pokonanie barier związanych z jakością danych, kwestiami prawnymi oraz kosztami, by w pełni wykorzystać potencjał tej technologii. ●

Piśmiennictwo

- Baillie S. et al.: The use of simulation in veterinary education. „Journal of Veterinary Medical Education”, 2010, 37 (4), 369-377.
- Banzato T. et al.: A methodological approach for deep learning to distinguish canine mammary carcinomas. „Scientific Reports”, 2018, 8 (1), 1-9.
- Felipe M. E. et al.: Machine learning prediction of acute kidney injury in dogs. „Journal of Veterinary Emergency and Critical Care”, 2021, 31 (3), 298-306.



ADOBE STOCK

KOMENTARZ

Przypominamy, że w Polsce lekarze weterynarii muszą respektować obowiązujące przepisy prawa, zwłaszcza zapisy Ustawy z dnia 21 grudnia 1990 r. o zawodzie lekarza weterynarii i izbach lekarsko-weterynaryjnych oraz Ustawy z dnia 18 grudnia 2003 r. o zakładach leczniczych dla zwierząt. W przytoczonych aktach prawnych czynności takie jak badanie stanu zdrowia zwierząt, rozpoznawanie, zapobieganie i zwalczanie chorób zwierząt zarezerwowane są wyłącznie dla lekarzy weterynarii posiadających prawo wykonywania zawodu w ramach działalności zakładu leczniczego dla zwierząt. Dodatkowo każdy lekarz weterynarii zobowiązany jest do przestrzegania zapisów Kodeksu Etyki Lekarza Weterynarii, w którym znajdują się takie zastrzeżenia jak: Lekarz weterynarii nie może podejmować się leczenia zwierzęcia bez jego zbadania; Lekarzowi weterynarii przysługuje swoboda wyboru metod rozpoznawczych, leczenia i profilaktyki itp. Autorzy opracowania przytaczają zastrzeżenia Światowego Stowarzyszenia Lekarzy Weterynarii odnoszące się do „odpowiedzialności za decyzje podejmowane przez algorytmy. Gdy system SI błędnie zdiagnozuje chorobę lub zaleci niewłaściwe leczenie, trudno ustalić, kto ponosi winę: twórca oprogramowania, lekarz nadzorujący czy właściciel kliniki.” Polskie zapisy ustawowe nie umożliwiają zastępowania lekarza weterynarii przez SI, ani nie przewidują udziału algorytmów SI w procesie rozpoznawania chorób zwierząt i ich leczenia. Zatem do czasu pojawienia się odpowiednich regulacji prawnych, SI w weterynarii powinna być traktowana jako metoda pomocnicza, gdyż za wszelkie ewentualne błędy i niepowodzenia odpowiedzialny będzie lekarz weterynarii podejmujący ostateczne decyzje.

Mirostław Kalicki

- Hennessey E., DiFazio M., Hennessey R., Cassel N.: Artificial intelligence in veterinary diagnostic imaging: A literature review. „Veterinary Radiology & Ultrasound”, 2022, Epub Dec 5, doi: 10.1111/vru.13163.
- Johnson K. A. et al.: Human-AI collaboration in veterinary decision-making. „Frontiers in Veterinary Science”, 2022, 9, 801526.
- Johnson M., Lee K.: Ethical considerations in AI deployment. „International Journal of Technology Ethics”, 2021, 15 (1), 22-37.
- Kononowicz A. A. et al.: Virtual patients in medical education: A systematic review. „Medical Teacher”, 2019, doi: 10.1080/0142159X.2018.1533234.
- Ljungvall I. et al.: Real-time arrhythmia detection in dogs using wearable ECG monitors and machine learning. „Journal of Veterinary Cardiology”, 2020, 28, 37-45.
- Pezzutti D. L. et al.: The use of virtual reality in veterinary surgical training. „Veterinary Surgery”, 2020, doi: 10.1111/vsu.13456
- Smith R. et al.: Data standardization challenges in veterinary electronic health records. „Journal of Veterinary Internal Medicine”, 2022, 36 (4), 1320-1328.
- World Veterinary Association. Ethical guidelines for AI in veterinary practice. Technical report 2021.
- Aubreville M., Bertram C. A., Marzahl C., Gurtner C., Dettwiler M., Schmidt A., Maier A.: Deep learning algorithms out-perform veterinary pathologists in detecting the mitotically most active tumor region. „Scientific Reports”, 2020, 10 (1), 16892.
- Johnson K. A. et al.: The potential application of artificial intelligence in veterinary clinical practice and biomedical res-arch. „Frontiers in Veterinary Science”, 2024, 11:1347550.
- Grand View Research 2024. Veterinary Software Market Size and Share Report, 2030.

Monika Szymańska,
e-mail: m.szymanska@libraxis.ai