

Tytus Berbec

*Institut Uprawy Nawożenia i Gleboznawstwa – Państwowy Instytut Badawczy
w Puławach*

IŁOŚĆ ŚLADU WĘGLOWEGO GENEROWANEGO
PRZEZ ALGORYTMY AI I MASZYNY W ROLNICTWIE CYFROWYM
W KONTEKŚCIE ZMIAN KLIMATU*

Słowa kluczowe: rolnictwo odporne na zmiany klimatu, innowacje technologiczne, rolnictwo 4.0, rolnictwo precyzyjne, historia rolnictwa precyzyjnego, internet rzeczy (IoT)

Wstęp

Współczesne rolnictwo cyfrowe (rolnictwo 4.0) stoi przed trudnymi wyzwaniami, które wymuszają potrzebę zwiększania światowej produkcji żywności, adaptacji do szybko postępującej zmiany klimatu czy wywierania dużej presji na zmniejszenie degradacji środowiska naturalnego. Rolnictwo napędzane przez sztuczną inteligencję (AI), w tym algorytmy głębokiego uczenia i jej poszczególne elementy, oferuje szereg możliwości zwiększenia wydajności produkcji czy stabilnej odporności systemów żywnościowych, które mają szansę zrewolucjonizować sektor poprzez możliwość stosowania nawozów czy środków ochrony roślin w sposób precyzyjny. Dzięki zaawansowanej analizie obrazów teledetekcji nisko- i wysokopułapowej możliwe jest generowanie precyzyjnych map, np. do sterowania autonomicznych maszyn rolniczych, zbierania informacji o stanie kondycji roślin czy prognozowania plonów. Kluczowe w rozwoju rolnictwa 4.0 jest dokonywanie obliczeń przez AI z wykorzystaniem ogromnych zbiorów danych, ich generowaniem, przetwarzaniem i analizą, co wywiera negatywny wpływ na środowisko poprzez wykorzystywanie ogromnych ilości energii. Budowanie sieci infrastruktury technologicznej od energochłonnych serwerowni po produkcję, wykorzystanie i utylizację narzędzi obliczeniowych, czyli elementy pracujące na rzecz rolnictwa 4.0 i 5.0, generują znaczący ślad węglowy,

*Opracowanie wykonano w ramach zadania 1.8. pt. „Wykorzystanie dronów w rolnictwie” z dotacji budżetowej przeznaczonej na realizację zadań MRiRW w 2025 r.

o ilościach których nie każdy zdaje sobie sprawę. Wciąż rosnąca zależność od technologii opartych na algorytmach sztucznej inteligencji może rodzić pytanie o prawdziwe koszty ich wykorzystania przez rolników, szczególnie o ślad węglowy związany z ogromnym zapotrzebowaniem na energię niezbędną do napędzenia modeli treningowych i zasilania serwerowni (Strubell i in. 2019). Niniejszy artykuł przedstawia próbę przeanalizowania wpływu AI na rolnictwo cyfrowe, bilansując jej pozytywny wkład w mitygację i adaptację z generowanym przez nią śladem węglowym. W pracy została wykorzystana metoda oceny cyklu życia (LCA) do przeprowadzenia analizy emisji wygenerowanej i unikniętej.

Wyniki i dyskusja

Światowe rolnictwo jako jeden z głównych sektorów gospodarki znajduje się obecnie w centrum globalnego kryzysu klimatycznego. Jest on szczególnie również ze względu na złożoność systemu produkcji żywności, ponieważ odgrywa rolę zarówno jednego z największych emiterów dwutlenku węgla, jak i zapewnia największą możliwość jego sekwestracji. Sektor rolniczy jest jednym z głównych źródeł antropogenicznych emisji gazów cieplarnianych (GHG) do atmosfery. Chów bydła i zaspokajanie potrzeb żywnościowych człowieka odpowiada za dużą część globalnych emisji metanu (CH_4) i podtlenku azotu (N_2O). Cały cykl żywnościowy od pola do stołu, obejmujący ogół agrotechniki, produkcję rolną, przetwarzanie i dystrybucję, generuje około jednej trzeciej globalnych emisji GHG, przyczynia się do utraty bioróżnorodności i zużywa około dwie trzecie światowych zasobów wody słodkiej. Jednakże sektor ten jest wyjątkowo wrażliwy na skutki zmian klimatu. Rolnicy coraz częściej muszą zmagać się z efektami tych zmian w postaci ekstremalnych zjawisk pogodowych, takich jak susze, powodzie, fale upałów, negatywne zmiany w rozkładzie i ilości opadów, erozja wodna i wietrzne gleby, zwiększona presja szkodników czy patogenów itp. Czynniki te bezprecedensowo zagrażają światowemu bezpieczeństwu żywnościowemu i stabilności dochodów rolników na całym świecie.

W obliczu wyzwań, jakie stoją przed współczesnym rolnictwem, można wskazać na konieczność całkowitej transformacji rolnictwa w kierunku modeli zrównoważonych i odpornych na zmiany klimatu. Wprowadzone strategie, takie jak Zielony Ład, „od pola do stołu” czy paszportyzacja żywności podkreślają potrzebę przejścia na gospodarkę o obiegu zamkniętym i redukcji degradacji środowiska. Transformacja wprowadzająca rolnictwo cyfrowe do powszechnego użytku jest również kluczowa dla osiągnięcia celów zrównoważonego rozwoju (SDGs) Organizacji Narodów Zjednoczonych, w szczególności: 2. Zero głodu; 6. Czysta woda i warunki sanitarne oraz 13. Działania w dziedzinie klimatu.

W odpowiedzi na wyzwania można wskazać na dwie kluczowe koncepcje kształtujące przyszłość rolnictwa cyfrowego. Jedną z nich jest rolnictwo czwartej generacji które opiera się na zbieraniu, przetwarzaniu i wykorzystywaniu ogromnych zbiorów

danych (big data) generowanych przez szereg czujników, sensorów rozmieszczonych w gospodarstwie w celu optymalizacji procesów produkcyjnych. Fundamentem tej koncepcji jest integracja zaawansowanych technologii, takich jak internet rzeczy (IoT), sztuczna inteligencja (AI), robotyka, autonomiczne maszyny czy wykorzystanie dronów i przekazanie szeregu informacji do chmury obliczeniowej. Głównym celem rolnictwa 4.0 jest zwiększenie efektywności produkcji i rentowności przy jednoczesnym promowaniu zrównoważonego rozwoju poprzez precyzyjniejsze zarządzanie gospodarstwem i zasobami w nim wykorzystywanymi.

Jako drugą kluczową koncepcję można wskazać rolnictwo przyjazne dla klimatu, które zostało zdefiniowane przez Organizację Narodów Zjednoczonych ds. Wyżywienia i Rolnictwa (FAO) oraz Bank Światowy (CSA, ang. *Climate-Smart Agriculture*). Jest to zintegrowane podejście do zarządzania gospodarstwem rolnym (uprawami, hodowlą, leśnictwem i rybołówstwem), które dąży do jednoczesnego osiągnięcia kilku kluczowych celów, wśród których można wskazać: zrównoważone zwiększenie produktywności rolniczej i rentowności gospodarstwa; adaptację i budowanie odporności systemów rolniczych na zmiany klimatyczne czy zredukowanie emisji gazów cieplarnianych lub w miarę możliwości usuwanie ich emiterów gazów w miejscach, w których jest taka możliwość. Rolnictwo przyjazne dla klimatu nie jest zbiorem uniwersalnych praktyk, lecz koncepcją zarządzania gospodarstwem rolnym, w którym promowane są technologie i strategie dostosowane do specyficznych warunków agroekologicznych i społeczno-ekonomicznych danego regionu.

Technologie cyfrowe, w tym sztuczna inteligencja, są powszechnie postrzegane jako główne narzędzia umożliwiające realizację celów rolnictwa przyjaznego dla klimatu. Ich zdolność do analizy ogromu złożonych danych w czasie rzeczywistym otwiera drogę do zwiększenia precyzji działania przy zarządzaniu i wykorzystaniu zasobów, co bezpośrednio przekłada się na mitygację emisji i zwiększenie zdolności adaptacyjnych współczesnego rolnictwa. Jednakże infrastruktura stanowiąca podstawę rolnictwa cyfrowego – od energochłonnych procesów produkcyjnych, przez globalne sieci telekomunikacyjne, po centra danych zasilające algorytmy AI, które pobierają ogromne ilości energii, wytwarzając duże ilości ciepła wymagające chłodzenia – generuje znaczący i wciąż rosnący ślad węglowy. Sektor technologii informacyjno-komunikacyjnych (ICT) odpowiada już za 2–4% globalnych emisji GHG, a prognozy wskazują na dalszy wzrost tego udziału (Malmodin i Lundén 2018). Systemy AI mogą stać się użytecznym narzędziem do redukcji emisji gazów cieplarnianych bezpośrednio w gospodarstwie. Algorytmy rolnictwa precyzyjnego pozwalają na optymalizację dawek nawozów makro- i mikroelementowych, co bezpośrednio ogranicza emisję np. podtlenku azotu (N_2O), czyli gazu o potencjale cieplarnianym blisko 300 razy większym niż CO_2 w perspektywie 100 lat (Sokal i Kachel 2025). Natomiast zastosowanie elementów AI w autonomicznych maszynach do precyzyjnych oprysków herbicydami czy fungicydami może zredukować nie tylko ilość stosowanych środków ochrony roślin, ale również zużycie paliwa przez ograniczenie liczby przejazdów

(Mogili i Deepak 2018). Ślad węglowy generowany przez sztuczną inteligencję AI nie jest monolitem i wynika z kilku kluczowych czynników. Należy przede wszystkim rozróżnić dwie fazy pracy modelu: trening i wnioskowanie. Badania Strubell i in. (2019) wykazały, że trening jednego, dużego modelu AI do przetwarzania języka naturalnego może wygenerować ponad 280 t ekwiwalentu CO₂, co odpowiada rocznej emisji całkowitego śladu węglowego generowanego przez 15 średniej wielkości gospodarstw domowych w Polsce. Chociaż jest to zazwyczaj koszt jednorazowy, złożoność modeli stale rośnie, a wraz z ewoluowaniem modeli rośnie ich zapotrzebowanie na energię elektryczną. Natomiast faza wnioskowania (ang. *inference*), czyli codzienne użytkowanie wytrenowanego modelu, jest jednostkowo znacznie mniej kosztowna energetycznie, ale przy masowym wdrożeniu jej skumulowany ślad węglowy może przewyższyć koszt treningu (Patterson i in. 2021). Przykładowo zużycie energii w lekkich zadaniach AI, takich jak NLP, wynosi średnio 5–15 W·h⁻¹, zadania cięższe polegające na wykrywaniu obiektów czy rozpoznawaniu twarzy potrzebuje pobrać ok. 14–40 W·h⁻¹, natomiast głębokie uczenie w czasie rzeczywistym czy obliczanie skomplikowanych algorytmów zużywa od 30 do 150 W·h⁻¹. Trenowanie dużego modelu głębokiego uczenia może wynosić w zależności od modelu od 500 do 1500 MWh. Kluczowe znaczenie ma tutaj infrastruktura sprzętowa i lokalizacja centrów danych. Emisje są bezpośrednio powiązane z miejscem, w którym sieci zasilają serwerownię. Trening tego samego modelu w centrum danych zasilanym energią odnawialną, np. elektrownią wodną, będzie miał znacznie niższy ślad węglowy niż w elektrowni wykorzystującej paliwa kopalne, np. węgiel (Luccioni i in. 2022). Ponadto efektywność energetyczna samego centrum jest opisywana wskaźnikiem PUE (ang. *Power Usage Effectiveness*), który zależy od wielu czynników. Przykładem może być porównanie energochłonnych procesorów GPU z bardziej wyspecjalizowanymi i oszczędniejszymi procesorami typu TPU/NPU. Przesyłanie 1 GB danych za pośrednictwem Internetu może pochłonąć 5–7 kWh energii. Systemy sztucznej inteligencji, które bazują na częstym przesyłaniu danych (głównie modele oparte na chmurze) mogą znacząco przyczynić się do zużycia energii. Na całym świecie centra danych obsługujące systemy sztucznej inteligencji są odpowiedzialne za zużycie ok. 2% całkowitej energii elektrycznej, a odsetek ten rośnie wraz z rozwojem AI.

Zatem, czy korzyści na poziomie gospodarstwa są częściowo niwelowane przez „ukryty” koszt środowiskowy zastosowania nowoczesnej technologii? Wciąż rosnące zapotrzebowanie na moc obliczeniową do trenowania i wdrażania modeli AI prowadzi do wzrostu zużycia energii, która w skali globalnej wciąż w dużej mierze pochodzi ze spalania paliw kopalnych, takich jak węgiel. Tworzy to złożony kompromis, w którym cyfrowa optymalizacja sektora rolnego może prowadzić do zwiększenia obciążenia środowiska naturalnego.

W związku z powyższym adekwatna staje się odpowiedź na pytanie, czy korzyści zmian w zarządzaniu gospodarstwem dotyczące poprawy klimatu wynikające z zastosowania AI w rolnictwie precyzyjnym przewyższają jej własny ślad węglowy?

Można postawić tezę, że ocena rzeczywistego wpływu zaimplementowania sztucznej inteligencji w zarządzaniu gospodarstwem rolnym i jej wpływu na klimat w całym sektorze rolniczym wymaga przeprowadzenia szeroko zakrojonych analiz, które bilansują emisje uniknięte dzięki optymalizacji działalności rolniczej z emisjami generowanymi w pełnym cyklu życia ogółu technologii AI. Wydaje się, że ostateczny wynik tak przeprowadzonej analizy może nie zostać rozstrzygnięty z powodu ogromu czynników, takich jak szereg zmiennych technologicznych (np. efektywność energetyczna algorytmów), operacyjnych (np. źródła zasilania) i politycznych (np. standardy zarządzania e-odpadami).

Modele AI stosowane w rolnictwie czwartej generacji rzadko osiągają skalę i złożoność największych modeli językowych. Aplikacje rolnicze często bazują na bardziej wyspecjalizowanych sieciach konwolucyjnych (CNN) służących do analizy danych spektralnych, których ślad węglowy jest mniejszy (Kamilaris i Prenafeta-Boldúr 2018). Rosnąca liczba danych pochodzących z urządzeń IoT, dronów i satelitów prowadzi do potrzeby przetwarzania ogromnych zbiorów danych (big data), co generuje wysokie zapotrzebowanie na moc obliczeniową. W literaturze naukowej coraz częściej można natrafić na koncepcję Green AI promującą badania nad zieloną sztuczną inteligencją, która jest nie tylko pomocna, ale i wydajniejsza obliczeniowo (Schwartz i in. 2019). Do takich działań można zaliczyć tworzenie efektywniejszych modeli, które wymagają mniejszych nakładów energii poprzez takie techniki, jak kwantyzacja, tzw. pruning, czyli przycinanie sieci czy transfer wiedzy, które pozwalają na budowę mniejszych modeli bez znacznej utraty dokładności (Gupta i in. 2022). Ponadto oszczędności na zużyciu energii można znaleźć, zwiększając efektywność sprzętową poprzez projektowanie i wykorzystywanie dedykowanych, energooszczędnych układów scalonych (ASICs), takich jak Google TPU (ang. *Tensor Processing Unit*), które wykonują operacje AI znacznie wydajniej niż tradycyjne GPU (Jouppi i in. 2017). W ramach oszczędności energii ważnym elementem może okazać się wybór dostawców chmury, na której będą trenowane i wnioskowane modele, którzy zasilają swoje centra danych energią odnawialną czy rozwój oprogramowania, które może planować wykonanie najbardziej energochłonnych zadań obliczeniowych w porach, gdy w sieci energetycznej dostępny jest duży udział energii pochodzącej z OZE. Świadomość i transparentność są tu kluczowe. Postuluje się, aby badacze i deweloperzy raportowali nie tylko dokładność swoich modeli, ale również szacowali koszt obliczeniowy i ślad węglowy ich wytrenowania, co pozwoli na bardziej świadome wybory technologiczne. Zyskującą na popularności alternatywą dla przetwarzania danych w chmurze może być przetwarzanie danych na urządzeniu końcowym. Możliwość wykonywania obliczeń algorytmów bezpośrednio na autonomicznym ciągniku, dronie czy innym urządzeniu pracującym w gospodarstwie eliminuje potrzebę przesyłania ciężkich ilości danych do odległych centrów, co samo w sobie redukuje zużycie energii. Ponadto takie rozwiązanie sprzyja rozwojowi lekkich, zoptymalizowanych modeli, co wpisuje się w globalny trend dążenia do bardziej zrównoważonej sztucznej inteligencji (Varghese i in. 2021).

Historia rewolucji technologicznych, jaka miała miejsce na przełomie wieków w rolnictwie, uczy ostrożności. Doświadczenia płynące z zielonej rewolucji pokazały, że znaczący wzrost wydajności w wykorzystaniu zasobów (np. energii czy ziemi na jednostkę produktu) niekoniecznie prowadzi do absolutnej redukcji ich zużycia w skali globalnej. Zjawisko to, znane jako paradoks Jevonsa, polega na tym, że wzrost efektywności może stymulować popyt (większe zużycie zasobu), niwelując lub nawet odwracając początkowe oszczędności. Istnieje zatem realne ryzyko, że wykorzystując algorytmy AI, mające uczynić rolnictwo bardziej wydajnym, może nie przyczynić się do absolutnej redukcji jego śladu węglowego, a jedynie umożliwić dalszą, bardziej wydajną ekspansję i intensyfikację produkcji. Analiza netto musi zatem uwzględniać nie tylko bezpośrednie bilanse emisji, ale także potencjalne systemowe efekty odbicia.

Sztuczna inteligencja oferuje cały zbiór narzędzi, które mogą znacząco przyczynić się do transformacji rolnictwa w kierunku zgodnym z celami Climate-Smart Agriculture. Jej wkład można podzielić na mitygację emisji gazów cieplarnianych poprzez optymalizację wykorzystania zasobów oraz zwiększenie zdolności adaptacyjnych systemów rolnych do szybko podążających już zmian klimatu.

Rolnictwo precyzyjne, napędzane przez AI i IoT, umożliwia przejście od uśrednionego zarządzania całym polem do precyzyjnego dostosowywania działań do potrzeb poszczególnych jego części lub nawet pojedynczych roślin. Prowadzi to do wymiernych korzyści związanych z redukcją emisji gazów cieplarnianych GHG. Efekt ten najszybciej można zaobserwować podczas redukcji emisji podtlenku azotu (N_2O) z gleby. Nadmierne stosowanie nawozów azotowych z powodu braku wykonywania podstawowych zabiegów analitycznych, takich jak analizy glebowe, jest głównym źródłem emisji N_2O . Inteligentne systemy, wykorzystując dane z czujników IoT monitorujących w czasie rzeczywistym wilgotność i skład chemiczny gleby, pozwalają algorytmom AI na precyzyjne określenie zapotrzebowania roślin na makroelementy, w tym azot. Dzięki temu nawozy mogą być aplikowane tylko w niezbędnych ilościach, w odpowiednim czasie i konkretne miejsca, co minimalizuje ich straty w procesie ulatniania się nawozu do atmosfery. Zastosowanie zaawansowanych algorytmów w dronach i robotach polowych pozwala na precyzyjną detekcję chwastów oraz ognisk chorób i szkodników. Umożliwia to systemom opryskowym (tradycyjnym lub bezzałogowym) wykonywanie zabiegów punktowych, ograniczając aplikację środków chemicznych tylko do zainfekowanych fragmentów uprawy. Przykładem może być rozwiązanie firmy John Deere oferujące system See & Spray, który według doniesień może zredukować zużycie herbicydów w zależności od opryskiwanej powierzchni o 67% w roślinach zielonych do 77% w ugorze (Schrimpf 2021, Bedord 2022, Kalcevic 2022, Dulaney i in. 2023). Ograniczenie stosowania środków ochrony roślin zmniejsza ślad węglowy związany z ich produkcją, transportem i aplikacją.

W obliczu coraz częstszych susz efektywne gospodarowanie wodą staje się kluczowe dla wszystkich jej odbiorców. Wykorzystanie inteligentnych systemów nawadniających wspomaganych przez algorytmy AI w zakresie sterowania, analizujących

dane z czujników rozmieszczonych w glebie mierzących wilgotność, generujących prognozy pogody oraz dostarczających informacji z zakresu stanu fizjologicznego roślin ma na celu dostarczanie wody dokładnie wtedy, kiedy występuje aktualne, rzeczywiste zapotrzebowanie w ilościach minimalizujących jej straty przez ewaporację czy spływ powierzchniowy. Badania wykazują, że takie systemy są w stanie generować oszczędności na poziomie od 30% do nawet 50% wody w porównaniu z tradycyjnymi metodami nawadniania (Gulcay 2025). Dostarczanie mniejszych ilości wody w sposób precyzyjny może pozytywnie wpłynąć na zwiększenie oszczędności energii elektrycznej zużywanej do tłoczenia i przekazywania wody na duże odległości. Ponadto autonomiczne ciągniki czy roboty uprawowe, wykorzystujące nawigację GPS i algorytmy AI, mogą optymalizować trasy przejazdów po stworzeniu nowych ścieżek technologicznych, co pozwala na oszczędność paliwa, czasu i redukcję zużycia maszyn nawet do 10% (Labella-Fernandez 2021, LaFevor 2022). Przejście z tradycyjnego ciężkiego sprzętu rolniczego na lżejsze, w tym roboty i drony o napędzie elektrycznym, nie tylko bezpośrednio eliminuje emisje dwutlenku węgla generowanego przez silniki wysokoprężne, ale także zmniejsza zagęszczenie gleby, a tym samym jej degradację, co prowadzi do poprawy życia biologicznego i jej zdolności do sekwestracji węgla.

Oprócz ograniczania emisji gazów cieplarnianych algorytmy AI odgrywają kluczową rolę w zwiększaniu odporności rolnictwa na skutki zmian klimatu, które już dziś są odczuwalne zarówno przez rolników, jak i konsumentów. Jednym z największych wyzwań dla rolników są zmiany klimatu, a w związku z tym rosnąca nieprzewidywalność pogody. Modele sztucznej inteligencji, w szczególności te oparte na uczeniu maszynowym czy głębokim uczeniu, są w stanie analizować ogromne zbiory danych meteorologicznych zarówno historycznych, jak i aktualnych, z obrazowania satelitarne, dane z czujników terenowych, w celu tworzenia precyzyjnych, lokalnych prognoz pogody czy przewidywania ekstremalnych zjawisk meteorologicznych, takich jak susze czy powodzie. Badania wskazują, że takie modele mogą prognozować plony z niezwykłą dokładnością (Goel i Pandey 2024, Vardhan i in. 2025). Daje to rolnikom czas na podjęcie działań adaptacyjnych, takich jak dostosowanie uprawy do warunków siedliskowych, zmiana terminów siewu, zabezpieczenie infrastruktury czy optymalizacja nawadniania przed nadejściem wspomnianych zjawisk. Wykorzystanie algorytmów jest w stanie zrewolucjonizować proces hodowli odmian roślin nowych, bardziej odpornych czy dostosowanych do aktualnych i przyszłych warunków meteorologicznych. Tradycyjne metody hodowlane są czasochłonne i kosztowne. Wykorzystanie sztucznej inteligencji, w tym algorytmów uczenia maszynowego, może przyspieszyć ten proces, analizując złożone dane genomiczne, fenotypowe i środowiskowe w celu identyfikacji genów i ścieżek molekularnych odpowiedzialnych za pożądane cechy, w tym tolerancję na suszę, zwiększone zasolenie gleby czy zwiększoną odporność na wysoką temperaturę. Po zidentyfikowaniu takich genów, narzędzia inżynierii genetycznej, jak precyzyjna technologia CRISPR-Cas9, mogą być wykorzystane do tworzenia odmian dostosowanych do pogarszających się warunków

klimatu w znacznie krótszym czasie. Przykładem udanych interwencji genetycznych jest edycja genu ARGOS8 w kukurydzy, która miała na celu zwiększenie plonów w warunkach suszy oraz modyfikacja genów z rodziny PYL w ryżu w celu nadania mu odporności na stres cieplny (Yu i in. 2024, Syeda 2025).

Plonowanie roślin w dużej mierze można zwiększyć poprzez zastosowanie algorytmów AI, natomiast jednym z głównych czynników kształtujących finalny plon roślin jest uprawa na glebie bogatej w materię organiczną. Uprawa na tego typu glebach jest znacznie wydajniejsza ze względu na większą tolerancję na suszę i erozję, a także stanowi ważny rezerwuar wody, węgla i życia biologicznego. Technologie AI, analizując dane pozyskiwane z różnych sensorów i obrazów satelitarnych, mogą precyzyjnie monitorować wysokość wód gruntowych, poziom węgla organicznego w glebie, jej strukturę i aktywność mikrobiologiczną. Umożliwia to rolnikom wdrażanie i weryfikację skuteczności praktyk rolnictwa konserwującego (np. uprawa bezorkowa) i regeneratywnego, które w sposób aktywny zwiększają ilość materii organicznej oraz sekwestrację CO₂ z atmosfery, przyczyniając się zarówno do mitygacji, jak i adaptacji.

W tabeli 1 w sposób syntetyczny zostały przedstawione przykładowe podwójne zastosowania AI w kontekście klimatycznym oraz, jaką rolę odgrywa ona we współczesnym rolnictwie. Ze względu na korzyści działania podzielono na dwie grupy: adaptacyjną (A) oraz mitygacyjną (M). Adaptacyjna skupia się na zwiększaniu odporności różnych systemów gospodarowania na już zachodzące zmiany klimatu, takie jak susze i inne zjawiska ekstremalne oraz ich skutki. Mitygacja natomiast skupia się na redukcji wpływu rolnictwa na klimat w dużej mierze poprzez zmniejszenie emisji GHG i optymalizację zużycia zasobów naturalnych.

Tabela 1

Przegląd zastosowań AI w mitygacji i adaptacji rolnictwa do zmian klimatu

Domena technologiczna AI	Konkretne zastosowanie	Potencjalna korzyść klimatyczna (mitygacja – M/adaptacja –A)	Powiązane technologie
Analityka predycyjna/ML	prognozowanie ekstremalnych zjawisk pogodowych (susze, powodzie)	A: wczesne ostrzeżenie, minimalizacja strat w plonach, lepsze planowanie zasobów	big data, czujniki pogodowe, obrazowanie satelitarne
Analityka predycyjna/ML	inteligentne nawadnianie	M: redukcja zużycia wody o 18–40%, oszczędność energii do pompowania; A: zwiększona odporność na suszę	IoT, czujniki wilgotności gleby

cd. tab. 1

Domena technologiczna AI	Konkretne zastosowanie	Potencjalna korzyść klimatyczna (mitygacja – M/adaptacja –A)	Powiązane technologie
Widzenie komputerowe	precyzyjny oprysk herbicydami/pestycydami	M: redukcja zużycia środków ochronny roślin do 77%, mniejszy ślad węglowy produkcji i transportu	drony, roboty polowe
ML w genomice	identyfikacja genów odporności na stres abiotyczny	A: przyspieszenie hodowli odmian odpornych na suszę, upał, zasolenie	CRISPR-Cas9, sekwencjonowanie genomu
AI w robotyce	optymalizacja tras przejazdu maszyn autonomicznych	M: redukcja zużycia paliwa o ok. 10%, mniejsze emisje CO ₂	GPS, autonomiczne ciągniki
ML/AI	monitorowanie i zarządzanie zdrowiem gleby (sekwestracja węgla)	M: zwiększone magazynowanie węgla w glebie; A: poprawa retencji wody i odporności na erozję	czujniki gleby, obrazowanie satelitarne

Źródło: Wójcik-Gront i in. 2024; Arlanowa i in. 2025; Dulaney i in. 2023; Bedord 2022; Kalcevic 2022; Schrimpf 2022

Powyższa tabela w sposób skuteczny łączy abstrakcyjne domeny technologiczne, takie jak analityka predykcyjna czy widzenie komputerowe z ich docelowym zastosowaniem, jak np. inteligentne nawadnianie. Jednocześnie w tabeli 1 można zauważyć, jak poszczególne elementy technologii oraz ich zastosowania są powiązane technologicznie, np. IoT czy wykorzystanie dronów, które są niezbędne do wdrożeń przytoczonych rozwiązań. Można także stwierdzić, że AI nie jest pojedynczym narzędziem tylko ma cechy podobne do układu nerwowego, w którym mózgiem operacyjnym jest nowoczesne gospodarowanie. Sztuczna inteligencja pełni rolę integratora, który ma za zadanie powiązać dane ze wskazanymi technologiami, czego wynikiem jest decyzja.

Pomimo obiecującego potencjału AI w transformacji rolnictwa wdrożenie tych technologii w gospodarstwach rolnych nie jest obojętne i bezkosztowe dla środowiska. Pełna ocena wpływu zmian w gospodarowaniu wymaga zastosowania metodyki oceny cyklu życia (LCA), która pozwala na kwantyfikację śladu węglowego na wszystkich etapach transformacji – od produkcji sprzętu, przez jego użytkowanie, aż po utylizację. LCA jest ustandaryzowaną (ISO 14040 i ISO 14044) i międzynarodowo uznaną metodą kompleksowej analizy wpływu środowiskowego produktu, procesu lub usługi od jego początku aż do jego końca życia. Proces oceny składa się z czterech głównych, powiązanych ze sobą faz, takich jak: definicja celu i zakresu badania, analizy zbioru (inventaryzacji) danych wejściowych i wyjściowych, ocena

wpływu na środowisko oraz końcowa interpretacja wyników. Celem oceny z wykorzystaniem LCA było oszacowanie śladu węglowego (wyrażonego w kilogramach ekwiwalentu dwutlenku węgla) generowanego przez kluczowe komponenty rolnictwa cyfrowego. Metoda ta jest coraz częściej stosowana do oceny zarówno pracy systemów rolniczych, jak i zaawansowanych technologii, w tym robotów i dronów. Ślad węglowy odnosi się do wszystkich emisji gazów cieplarnianych wygenerowanych przed rozpoczęciem użytkowania produktu. Jest to często dominujący składnik całkowitego śladu węglowego dla urządzeń elektronicznych. Faza produkcji sprzętu obejmuje energochłonne procesy wydobywania i przetwarzania surowców (metali, w tym pierwiastków ziem rzadkich, krzemu, tworzyw sztucznych), produkcję zaawansowanych komponentów elektronicznych (mikroprocesory, pamięci, czujniki) oraz montaż finalnych urządzeń. Dotyczy to całej gamy sprzętu wdrażanego w rolnictwie 4.0 (od prostych sensorów IoT przez kamery i moduły GPS, po skomplikowane drony i roboty polowe). Biorąc pod uwagę fakt, iż produkcja 1 kg włókna węglowego może generować od 20 do 30 kg CO₂, produkcja 1 kg stali – ok. 1,8 kg CO₂, a produkcja 1 kg aluminium (z surowców pierwotnych) – ok. 10–20 kg CO₂, wyprodukowanie maszyn rolniczych jest znaczącym źródłem emisji. Badania wskazują, że wyprodukowanie jednego robota przemysłowego o masie ok. 1000 kg może wygenerować nawet do 1,5 t CO₂ (Dahmus i Gutowski 2004, Ciceri i in. 2010). Kluczowe znaczenie ma tu rodzaj zastosowanych materiałów – lekkie kompozyty z włókna węglowego choć poprawiają wydajność operacyjną, to mają znacznie wyższy wbudowany ślad węglowy niż tradycyjna stal czy aluminium. Należy również uwzględnić emisje związane z produkcją elektroniki, takiej jak serwery, routery, kable światłowodowe oraz budowa fizycznych obiektów, w których mieszczą się centra danych i infrastruktura sieciowa. Emisja jest bezpośrednio związana ze zużyciem energii podczas działania technologii. Wielkość emisji zależy od wielu czynników, w tym od efektywności energetycznej sprzętu i oprogramowania oraz od architektury całego systemu. Proces uczenia modeli AI, zwłaszcza skomplikowanych modeli głębokiego uczenia, jest wysoce energochłonny. Wymaga on dostarczenia ogromnej ilości energii do wytwarzania mocy obliczeniowej, zazwyczaj dostarczanej przez klastry wyspecjalizowanych procesorów (GPU, TPU) w scentralizowanych centrach danych. Szacuje się, że sam proces treningu modelu językowego GPT-3 generuje ok. 552 t CO₂, co odpowiada rocznemu zużyciu energii przez ok. 120 amerykańskich gospodarstw domowych (Anthony i in. 2020). Globalne zużycie energii przez centra danych jest już porównywalne z konsumpcją energii przez całe państwa, takie jak Francja. Jednym z etapów trenowania jest proces inferencji. Jest to proces wykorzystania już wytrenowanego modelu do wykonania zadania (np. klasyfikacji obrazu, predykcji). Zużycie energii na pojedynczą inferencję jest znacznie niższe niż na sam trening, jednak proces ten jest wykonywany w sposób ciągły i na masową skalę, co sumarycznie generuje znaczące obciążenie energetyczne. Jedno zapytanie do ChatGPT może zużywać pięciokrotnie więcej energii niż standardowe wyszukiwanie w Google. W rolnictwie inferencja może zachodzić

w chmurze lub lokalnie, na urządzeniach polowych takich jak autonomiczne roboty czy drony. Zużycie energii przez maszyny autonomiczne zależy od ich masy, prędkości, od rodzaju terenu, przenoszonego ładunku, typu baterii oraz wielu innych czynników. Badania porównawcze wykazały, że zasilanie z wykorzystaniem pakietów litowo-polimerowych są znacznie bardziej wydajne energetycznie niż tradycyjne akumulatory kwasowo-ołowiowe ze względu na niższą masę i mniejszy opór wewnętrzny tych pierwszych. Wykorzystanie dronów rolniczych do oprysków czy nawożenia może być znacznie bardziej efektywne energetycznie niż metody konwencjonalne. Badanie Safaeinejada i in. (2025) wykazało niemal 2,5-krotnie niższe zużycie energii ($146,84 \text{ MJ}\cdot\text{ha}^{-1}$) w porównaniu z opryskiwaczem konwencjonalnym (zużycie na poziomie $365,26 \text{ MJ}\cdot\text{ha}^{-1}$) i niemal 3-krotnie niższy potencjał tworzenia efektu cieplarnianego przez drona ($14,48 \text{ kg CO}_2\cdot\text{ha}^{-1}$) niż dla opryskiwacza ($41,28 \text{ kg CO}_2\cdot\text{ha}^{-1}$). Sercem wielu inteligentnych maszyn rolniczych są komputery brzegowe, które są projektowane pod kątem wysokiej wydajności obliczeń AI przy relatywnie niskim poborze mocy (np. 15–60 W), co jest kluczowe dla urządzeń zasilanych za pomocą akumulatorów.

Podstawowe znaczenie dla generowanego śladu węglowego fazy użytkowania ma decyzja architektoniczna dotycząca tego, gdzie odbywa się przetwarzanie danych i inferencja AI. W modelu opartym na chmurze dane z sensorów (np. obrazy w wysokiej rozdzielczości z drona) są przesyłane do scentralizowanego centrum danych w celu analizy przez potężne modele AI. Generuje to wysokie koszty energetyczne związane z transferem danych przez sieci telekomunikacyjne oraz z działaniem i chłodzeniem serwerów. Zaletą jednak jest możliwość wykorzystania bardziej efektywnych energetycznie, zoptymalizowanych centrów danych, które mogą być zasilane ze źródeł odnawialnych. W modelu opartym na przetwarzaniu danych w urządzeniu końcowym (np. na robocie polowym) lub w jego pobliżu analiza odbywa się lokalnie. Znacząco redukuje to ilość danych przesyłanych do chmury, co obniża zużycie energii przez sieć i zmniejsza opóźnienia. Jednakże rozproszona flota mniej wydajnych energetycznie urządzeń brzegowych może sumarycznie zużywać więcej energii niż jedno wysoce zoptymalizowane centrum danych. Jedną z ciekawych opcji może być zastosowanie modelu opartego na lekkim uczeniu maszynowym. Jest to wydajna forma przetwarzania brzegowego, w której wysoce zoptymalizowane, „lekkie” modele uczenia maszynowego działają na mikrokontrolerach o bardzo niskim poborze mocy (rzędu miliwatów). Umożliwia to tworzenie tanich, zasilanych bateryjnie sensorów, które mogą działać autonomicznie przez miesiące lub lata, wykonując proste zadania analityczne (np. detekcja chorób roślin, monitorowanie wilgotności gleby) w odległych lokalizacjach bez stałego zasilania i łączności z Internetem. Jest to kluczowa strategia minimalizacji operacyjnego śladu węglowego AI w rolnictwie (Ihoume i in. 2022, Islam i in. 2025).

Dodatkowym problemem cyfryzacji rolnictwa jest potrzeba utylizacji ogromnej ilości elektrośmieci, w tym zużytych materiałów wytworzonych na potrzeby sztucznej inteligencji, takich jak mikroprocesory, płyty główne itp. Wiąże się to z nieuchronnym

wzrostem ilości elektrośmieci (e-waste), co stanowi poważne wyzwanie ekologiczne. Szybki postęp technologiczny i cykle innowacji skracają żywotność urządzeń elektronicznych, prowadząc do ich częstiej wymiany i generowania rosnącego strumienia odpadów w postaci zużytych sensorów, dronów, komputerów i baterii. Ponadto dużym problemem dla środowiska naturalnego jest niewłaściwa utylizacja e-odpadów, np. poprzez składowanie na wysypiskach. Może prowadzić to do uwalniania do gleby i wód gruntowych wysoce toksycznych substancji, takich jak metale ciężkie (ołów, rtęć, kadm, brom itp.). Stanowi to bezpośrednie zagrożenie dla ekosystemów rolniczych, zanieczyszczając glebę i wodę używaną do nawadniania, a także może stanowić zagrożenie dla zdrowia ludzi poprzez bezpośredni kontakt zanieczyszczonego środowiska z człowiekiem lub poprzez spożywanie żywności z dużą zawartością ww. metali. Wyzwaniem jest efektywne i bezpieczne zarządzanie e-odpadami rolniczymi, które wymaga ich specjalnego traktowania podczas utylizacji, obejmującego zbiórkę, bezpieczne usuwanie danych oraz odzysk cennych i rzadkich materiałów. Kluczowe staje się promowanie zasad gospodarki o obiegu zamkniętym, w tym projektowanie urządzeń z myślą o trwałości, łatwości naprawy i recyklingu.

Tabela 2 przedstawia dekompozycję śladu węglowego dla wybranych technologii rolnictwa cyfrowego w ramach LCA. Analiza dowodzi, że technologie te nie są zeroemisyjne. Rzetelna ocena ich zrównoważonego charakteru wymaga uwzględnienia wszystkich faz cyklu życia: od pozyskania surowców i produkcji, poprzez eksploatację, aż po proces utylizacji.

Tabela 2
Komponenty śladu węglowego w cyklu życia dla wybranych technologii rolnictwa cyfrowego

Typ technologii	Faza produkcji (Embodied Carbon)	Faza użytkowania (emisje operacyjne)	Faza końca życia (e-waste)
Dron do oprysków precyzyjnych	bateria Li-Po, rama z włókna węglowego, silniki, elektronika (GPS, kamery)	zużycie energii elektrycznej do ładowania baterii (np. 147 MJ·h ⁻¹); zależne od miksu energetycznego	recykling baterii, utylizacja kompozytów, odzysk metali z elektroniki
Robot polowy do odchwaszczania	stalowa/aluminiowa rama, silniki elektryczne, baterie, system wizyjny (GPU, kamery), czujniki LiDAR	zużycie energii do ładowania baterii (np. 16–36 W w zależności od terenu i ładunku); zależne od miksu energetycznego	recykling baterii, odzysk metali, utylizacja elektroniki
Zestaw sensorów IoT z TinyML	mikrokontroler, czujniki (wilgotności, NPK), moduł komunikacji (np. LoRa), mała bateria/panel słoneczny	bardzo niskie zużycie energii (mW), często zasilane energią z otoczenia (energy harvesting); minimalne emisje operacyjne	duża liczba małych urządzeń rozproszonych w terenie, co utrudnia zbiórkę i recykling

Źródło: Safaeinejad i in. 2025, Seo i in. 2023; nVIDIA; Schizas i in. 2022; Cheen i in. 2025

Ostateczna ocena wpływu zastosowania AI w rolnictwie na klimat wymaga syntezy dwuwymiarowej – korzyści wynikających z optymalizacji oraz kosztów środowiskowych samej technologii. Taka analiza ujawnia, że bilans węgla netto jest dynamiczny i zależy od szeregu kluczowych zmiennych. Aby zobiektywizować analizę, można posłużyć się uproszczonym równaniem bilansu węglowego (Balafoutis i in. 2017), które porównuje scenariusz bazowy (rolnictwo konwencjonalne) ze scenariuszem wykorzystującym technologie AI. Zmianę netto w emisjach (ΔC) można wyrazić jako:

$$\Delta C = C_{\text{uniknięte}} - C_{\text{generowane}}$$

gdzie:

- $C_{\text{uniknięte}}$ – to suma redukcji emisji wynikająca z zastosowania AI w działalności rolniczej (np. mniejsze zużycie nawozów, paliwa, pestycydów, zoptymalizowane zużycie wody i energii);
- $C_{\text{generowane}}$ – to suma emisji wygenerowanych w pełnym cyklu życia wdrożonej technologii AI (produkcja sprzętu, zużycie energii operacyjnej, utylizacja).

Wynik dodatni ($\Delta C > 0$) oznacza korzyść klimatyczną netto, podczas gdy wynik ujemny ($\Delta C < 0$) wskazuje, że ślad węglowy technologii przewyższa osiągnięte dzięki niej oszczędności emisyjne.

Wynik powyższego równania nie jest stały. Jest on funkcją kilku kluczowych, współzależnych zmiennych, które mogą drastycznie zmienić ostateczny bilans. Źródło energii do przeprowadzenia analiz sztucznej inteligencji to prawdopodobnie najważniejsza zmienna. Ślad węglowy fazy użytkowania, zarówno dla centrów danych trenujących modele AI, jak i dla ładowania elektrycznych maszyn polowych, jest wprost proporcjonalny do emisyjności lokalnego miksu energetycznego. Wdrożenie tych samych technologii w regionie zasilanym energią z węgla będzie miało drastycznie wyższy ślad węglowy ($C_{\text{generowane}}$) niż w regionie opartym na energii pochodzącej ze źródeł odnawialnych, co może całkowicie zmienić wynik ΔC . W modułach i algorytmach AI obserwuje się dwa przeciwstawne trendy. Z jednej strony tzw. Red AI dąży do tworzenia coraz większych i bardziej złożonych modeli w celu osiągnięcia marginalnych przyrostów dokładności, co prowadzi do wykładniczego wzrostu zapotrzebowania na moc obliczeniową i w konsekwencji do ogromnego popytu na energię. Z drugiej strony na popularności zyskuje koncepcja Green AI, która promuje projektowanie lżejszych, bardziej wydajnych energetycznie algorytmów osiągających porównywalną skuteczność przy znacznie niższym koszcie obliczeniowym. Wykorzystanie takich technik, jak kwantyzacja czy kompresja modeli oraz rozwój lekkiego uczenia maszynowego są ważnymi narzędziami koncepcji Green AI. Wybór między tymi dwoma koncepcjami projektowania ma duże znaczenie dla wielkości $C_{\text{generowane}}$.

Wydłużenie cyklu życia urządzeń (sensorów, robotów) pozwala na amortyzację ich wbudowanego śladu węglowego ($C_{\text{generowane}}$ z fazy produkcji) na zwiększoną ilość

lat użytkowania, co zmniejsza jego roczny negatywny wpływ na środowisko i zmianę klimatu. Ponadto ogranicza to tempo i ilość generowania e-odpadów. Projektowanie tego typu modeli z myślą o łatwej naprawie i modułowości, w przeciwieństwie do modelu programowanej przestarzałości, może być priorytetową strategią zrównoważonego rozwoju. Wpływ technologii na generowanie śladu węglowego na klimat, będzie różny, jeśli zostanie wdrożona w małym, zdywersyfikowanym gospodarstwie agroekologicznym, a inny w wielkoobszarowym, monokulturowym rolnictwie przemysłowym. Istotne są również bariery adaptacyjne, takie jak wysokie koszty początkowe, brak wiedzy technicznej czy niedostateczna infrastruktura (Internet, stabilne zasilanie), które ograniczają dostęp do tych technologii, zwłaszcza dla mniejszych gospodarstw. Co ciekawe, bariery te mogą tworzyć nieoczekiwane sprzężenie zwrotne. Wysokie koszty i złożoność algorytmów systemów AI pracujących w chmurach, które hamują ich adaptację w mniej zamożnych regionach lub mniejszych gospodarstwach, mogą paradoksalnie stymulować popyt na tańsze, prostsze i bardziej autonomiczne rozwiązania. Technologie Green AI, które z definicji są projektowane do działania na tanim w produkcji sprzęcie oraz przy niskich nakładach energii, bez stałej łączności z siecią, dobrze wpisują się w te ograniczenia. Siły rynkowe i ograniczenia infrastrukturalne mogą stać się nieoczekiwanym motorem napędowym dla bardziej zrównoważonej ścieżki cyfryzacji rolnictwa, promując rozwiązania o niższym śladzie węglowym, przyjazne środowisku.

Aby zilustrować, jak te zmienne wpływają na bilans netto, można przeanalizować dwa skrajne scenariusze wdrożenia technologii AI przedstawione w tabeli 3. Porównanie to udowadnia, że technologia wykorzystania AI nie jest ani antyekologiczna, ani proekologiczna. Analizując przeciwstawne scenariusze, można zauważyć, że realny wpływ na klimat zależy od podstawy paradygmatu, w jakim jest zastosowana.

Tabela 3

Analiza porównawcza scenariuszy wdrożenia AI w rolnictwie

Parametr	Scenariusz A: Przemysłowy + Chmura + Red AI	Scenariusz B: Agroekologiczny + Edge + Green AI
Kluczowe założenia	wielkoobszarowa monokultura; miks energetyczny 500 g CO ₂ ^e ·kWh ⁻¹ ; żywotność sprzętu 5 lat; ciężkie roboty; duże modele AI w chmurze	małe; zdywersyfikowane gospodarstwo; energia z paneli słonecznych (50 g CO ₂ ^e ·kWh ⁻¹); żywotność sprzętu 10 lat; lekkie drony/roboty; TinyML/Edge AI
Szacowane emisje generowane (kg CO ₂ ^e ·ha ⁻¹ ·rok ⁻¹)	wysokie; produkcja ciężkiego sprzętu + wysokie zużycie energii przez sieć i centra danych zasilane z emisyjnej sieci	niskie; produkcja lekkiego sprzętu + niskie zużycie energii zasilanej z OZE + minimalny transfer danych

cd. tab. 3

Parametr	Scenariusz A: Przemysłowy + Chmura + Red AI	Scenariusz B: Agroekologiczny + Edge + Green AI
Szacowane emisje uniknięte (kg CO ₂ ^e ·ha ⁻¹ ·rok ⁻¹)	średnie; optymalizacja nawozów i paliwa w monokulturze, ale potencjalny efekt odbicia (dalsza intensyfikacja)	wysokie; optymalizacja zasobów połączona z praktykami regeneratywnymi (sekwestracja węgla), brak efektu odbicia
Wpływ netto (ΔC)	prawdopodobnie ujemny lub bliski zeru; C _{generowane} może zniwelować lub przewyższyć C _{uniknięte}	prawdopodobnie dodatni; C _{uniknięte} znacznie przewyższa niskie C _{generowane}

Źródło: <https://medium.com/@ciente/red-ai-vs-green-ai-d7c9e4c6e6af>; Jegadeeswari i Rathipriya 2025; Islam i in. 2025; Cheen i in. 2025)

Podsumowanie

Analiza tych scenariuszy wdrożenia AI w rolnictwie jednoznacznie pokazuje, że technologia ta jest jedynie narzędziem, a jej ostateczny wpływ na klimat nie jest cechą inherentną, lecz wynikiem kontekstu społeczno-ekonomicznego i technologicznego, w którym jest wdrażana.

Wyniki wskazują, że ostateczny bilans węglowy jest silnie uzależniony od kontekstu wdrożenia, w tym od źródeł energii, efektywności algorytmów (Green AI) oraz przyjętych modeli zarządzania e-odpadami. Na podstawie przeglądu badań można uznać, że maksymalizacja korzyści klimatycznych z cyfryzacji rolnictwa wymaga świadomych decyzji technologicznych i politycznych, promujących zrównoważone projektowanie i wdrażanie systemów AI. Sztuczna inteligencja posiada dwojaki i złożony wpływ na ślad węglowy rolnictwa. Z jednej strony jej potencjał do mitygacji emisji i wspierania adaptacji do zmian klimatu poprzez precyzyjną optymalizację zasobów jest ogromny i dobrze udokumentowany. Z drugiej zaś strony ten potencjał jest obciążony znaczącym kosztem węglowym generowanym w całym cyklu życia infrastruktury cyfrowej. Najważniejszy wniosek płynący z analizy netto jest taki, że nie istnieje jedna, uniwersalna odpowiedź na pytanie o bilans węglowy AI w rolnictwie. Wynik bilansu jest wysoce kontekstowy i zależy od świadomych wyborów dokonywanych na etapie projektowania technologii, jej wdrażania w gospodarstwie oraz kształtowania ram politycznych. Sztuczna inteligencja nie jest z natury ani „zielona”, ani „czerwona” – to sposób jej implementacji decyduje o pośrednim wpływie na efekt cieplarniany oraz jej ostatecznym wpływie na klimat.

Na podstawie przeprowadzonej analizy literatury sformułowano następujące wnioski:

1. Sztuczna inteligencja odgrywa podwójną, paradoksalną rolę w kontekście zrównoważonego rolnictwa. Z jednej strony oferuje znaczący potencjał do redukcji emisji gazów cieplarnianych na poziomie gospodarstwa poprzez optymalizację

- zużycia zasobów (nawozów, pestycydów, paliwa), z drugiej zaś sama generuje znaczący ślad węglowy wynikający z energochłonnych procesów obliczeniowych.
2. Skala śladu węglowego AI nie jest stała i zależy od wielu czynników, w tym od złożoności modelu, etapu jego życia (trening vs. wnioskowanie), wydajności energetycznej sprzętu oraz, co kluczowe, od miksu energetycznego zasilającego centra danych.
 3. Istnieją skuteczne strategie mitygacji śladu węglowego AI zgodne z koncepcją Green AI. Obejmują one działania na poziomie algorytmicznym, sprzętowym oraz systemowym (korzystanie z centrów danych zasilanych energią odnawialną).
 4. Dalszy rozwój i wdrażanie AI w rolnictwie 4.0 i 5.0 musi odbywać się w sposób świadomy, z uwzględnieniem zarówno korzyści agronomicznych, jak i kosztów środowiskowych. Postuluje się konieczność transparentnego raportowania zużycia energii przez nowe modele AI, co umożliwi bardziej zrównoważony postęp technologiczny w sektorze rolnym.

Literatura

1. Anthony L.F.W., Kanding B., Selvan R.: Carbontracker: Tracking and predicting the carbon footprint of training deep learning models. Eprint arXiv:2007.03051. 2020 IEEE International Conference on Big Data; DOI: 10.48550/arXiv.2007.03051
2. Arlanov A., Hojamkuliyeva B.A., Babanazarov N.S., Arlanov M.S.: Artificial intelligence for smart irrigation: Reducing water consumption and improving agricultural output. E3S Web Conf. Volume 623, 2025 IV International Conference on Ensuring Sustainable Development: Ecology, Earth Science, Energy and Agriculture (AEES2024) **623**, 04001; <https://doi.org/10.1051/e3sconf/202562304001>
3. Balafoitis A.T., Beck B, Fountas S., Vangeyte J., Van der Wal T., Soto I., Gomez-Barbero M., Barnes A., Eory V.: Precision agriculture technologies positively contributing to GHG Emissions Mitigation. Farm Productivity and Economics. Sustainability, 2017, **9(8)**, 1339; DOI: <https://doi.org/10.3390/su9081339>
4. Bedford L.: John Deere Launches See & Spray select. Successful Farming. Retrieved March 28, 2022; <https://www.agriculture.com/news/technology/john-deerelaunches-see-spray-select>
5. Chen X., Han L., Bhagavatthula A., Gupta U.: CarbonClarity: Understanding and addressing uncertainty in embodied carbon for sustainable computing. arXiv:2507.01145, 2025; <https://doi.org/10.48550/arXiv.2507.01145>
6. Ciceri N.D., Gutowski T.G., Garetti M.: A tool to estimate material and manufacturing Energy for a product. IEEE Xplore, Conference Sustainable Systems and Technology (ISSST), 2010; DOI: 10.1109/ISSST.2010.5507677
7. Dahmus J., Gutowski T.: An environmental analysis of machining. Proceedings of the 2004 ASME International Mechanical Engineering Congress and RD&D Expo. Anaheim, California 2004; <https://doi.org/10.1115/IMECE2004-62600>
8. Dulaney P., Lowe J.W., Dodds D., Speights C.: See and spray technology control for sheep and goats. Mississippi State University. Publication 3904 (POD-06-23), 2023.
9. Goel M., Pandey M.: Crop Yield Prediction Using AI: A Review,” 2024 2nd International Conference on Disruptive Technologies (ICDT), Greater Noida, India, 2024, pp. 1547-1553; DOI: 10.1109/ICDT61202.2024.10489432

10. Gupta E.O.: AI-driven irrigation systems for sustainable water management: A systematic review and meta-analytical insights. *Smart Agricultural Technology*, 2025, **11**, 100982; <https://doi.org/10.1016/j.atech.2025.100982>
11. Gupta C., Johri I., Srinivasan K., Hu Y., Qaisar S.M., Huang K.: A Systematic review on machine learning and deep learning models for electronic information security in mobile networks. *Sensors*, 2022, **22(5)**; DOI: <https://doi.org/10.3390/s22052017>
12. Ihoume I., Tadili R., Arbaoui N., Benchrif M.: Developing a multi-label tinyML machine learning model for an active and optimized greenhouse microclimate control from multivariate sensed data. *Artificial Intelligence in Agriculture*, 2022, **6(1)**; DOI:10.1016/j.aiaa.2022.08.003
13. Islam M.B., Guerrieri A., Gravina R., Delaney D.T., Fortino G.: From traditional machine learning to fine-tuning large language models: A review for sensors-based soil moisture forecasting. *Sensors*, 2025, **25(22)**, 6903; <https://doi.org/10.3390/s25226903>
14. ISO14040: 2006; <https://www.iso.org/standard/37456.html>
15. ISO 14044: 2006; <https://www.iso.org/standard/38498.html>
16. Jegadeeswari K., Rathipriya R.: Minimizing the carbon footprint of machine learning techniques through sustainable AI training methods. *Sustainable Information Security in the Age of AI and Green Computing*. 2025; DOI: 10.4018/979-8-3693-8034-5.ch009
17. Joppa N.P., Borchers A., Boyle R., Cantin P.: In-datacenter performance analysis of a tensor processing unit. In *ISCA 17 Proceedings of the 44th Annual International Symposium on Computer Architecture*, 2017, (1-12); DOI: 10.1145/3079856.3080246
18. Kalcevic A.: John Deere new see and spray technology. *4Rivers Equipment*. Retrieved March 28, 2022; <https://www.4riversequipment.com/john-deere-new-see-and-spray-technology/>
19. Kamilaris A., Prenafeta-Boldú F.X.: Deep learning in agriculture: A survey. *Computers and electronics in agriculture*, 2018, **147(1)**: 70-90; DOI: <https://doi.org/10.1016/j.compag.2018.02.016>
20. Labeila-Fernandez A.: Archetypes of green-growth strategies and the role of green human resource management in their implementation. *Sustainability*, 2021, **13(2)**, 836; <https://doi.org/10.3390/su13020836>
21. Lefevor C.M.: Crop species production diversity enhances revenue stability in low-income farm regions of Mexico. *Agriculture*, 2022, **12(11)**, 1835; <https://doi.org/10.3390/agriculture12111835>
22. Lucioni A.S., Viguier S., Ligozat A.L.: Estimating the Carbon Footprint of BLOOM, a 176B Parameter Language Model. *arXiv preprint arXiv:2211.02001*, 2022, 1-10; DOI: <https://doi.org/10.48550/arXiv.2211.02001>
23. Malmodin J., Lundén D.: The Energy and Carbon Footprint of the Global ICT and E&M Sectors 2010–2015. *Sustainability*, 2018, **10(9)**, 3027; DOI: <https://doi.org/10.3390/su10093027>
24. Mogili U.R., Deepak B.B.V.L.: Review on application of drone systems in precision agriculture. *Procedia computer science*, 2018, **133**: 502-509; <https://doi.org/10.1016/j.procs.2018.07.063>
25. nVIDIA; <https://www.nvidia.com/pl-pl/>
26. Patterson D., Gonzalez J., Le Q., Liang C., Munguia L., Rothchild D., So D., Texier M., Dean J.: Carbon emissions and large neural network training. *arXiv preprint arXiv:2104.10350*, 2021; DOI: <https://doi.org/10.48550/arXiv.2104.10350>
27. Red AI vs Green AI; <https://medium.com/@ciento/red-ai-vs-green-ai-d7c9e4c6e6af>
28. Safacejad M., Ghasemi-Nejad-Raeini M., Taki M.: Reducing Energy and environmental footprint in agriculture: A study on drone spraying vs conventional methods. *PLoS One*, 2025, **20(6)**, e0323779; DOI: <https://doi.org/10.1371/journal.pone.0323779>
29. Schizas N., Karras A., Karras C., Sioutas S.: TinyML for ultra-low power AI and large scale IoT deployments: A systematic review. *Future Internet*, 2022, **14(12)**, 363; <https://doi.org/10.3390/fi14120363>
30. Schwartz R., Dodge J., Smith N.A., Etzioni O.: Green AI. *arXiv:1907.10597*, 2019; <https://doi.org/10.48550/arXiv.1907.10597>

31. Schrimpf P.: Deere launches see & spray select technology. PrecisionAg. Retrieved March 29, 2022; <https://www.precisionag.com/market-watch/deere-see-spray-selectrelease/>
32. Seo Y., Umeda S., Yoshikawa N.: Environmental impact of agricultural sprayers used in Japanese rice farming. International Journal Of Agricultural Sustainability LOV 21, 2023, **1**, 2247803; DOI:10.1080/14735903.2023.2247803
33. Sokal K., Kachel M.: Impact of Agriculture on Greenhouse Gas Emissions – A review. Energies, 2025, **18(9)**, 2272 MDPI. DOI: <https://doi.org/10.3390/en18092272>
34. Strubell E., Ganesh A., McCallum A.: Energy and policy considerations for deep learning in NLP. arXiv preprint arXiv:1906.02243, 2019; <https://doi.org/10.48550/arXiv.1906.02243>
35. Syeda A.: Harnessing multi-omics and genome-editing technologies for climate-resilient agriculture: bridging AI-driven insights with sustainable crop improvement. Springer Nature. Plant Molecular Biology, 2025, **115(120)**; <https://doi.org/10.1007/s11103-025-01650-1>
36. Wójcik-Gront E., Zieniuk B., Pawłkiewicz M.: Harnessing AI-powered genomic research for sustainable crop improvement. Agriculture, 2024, **14(12)**, 2299; <https://doi.org/10.3390/agriculture14122299>
37. Varghese B., De Lara E., Ding A.Y., Hong C.H., Bonomi F., Dustdar S., Harvey P., Hewkin P., Shi W., Tandur D.: Revisiting the arguments for Edge Computing Research. IEEE Internet Computing, 2021, **25(5)**: 36-42; 10.1109/MIC.2021.3093924
38. Vardhan P.N.H., Badavath A., Srivalli P.: Artificial intelligence and its applications in agriculture: A review. Environment Conservation Journal, 2025, **26(1)**: 274-280; DOI:10.36953/ECJ.28802904
39. Yu J., Wang R., Zhang X., Chen S.: Genome-wide analysis of the PYL gene family in *Betula platyphylla* and its responses to abiotic stresses. International Journal of Molecular Sciences, 2024, **25(24)**, 13728; <https://doi.org/10.3390/ijms252413728>

Adres do korespondencji:

mr inż. Tytus Berbeć
Zakład Biogospodarki i Agrometeorologii
IUNG-PIB
ul. Czartoryskich 8
24-100 Pulawy
tel. 81 47 86 758
e-mail: tberbec@iung.pulawy.pl

AUTOR
Tytus Berbeć

ORCID
0000-0001-5183-5807