

dr Anna Orzeł

Uniwersytet WSB Merito we Wrocławiu, Wydział Finansów i Zarządzania

ORCID: 0000-0002-7581-6480

dr inż. Adam Busławski

Uniwersytet WSB Merito we Wrocławiu filia w Opolu, Wydział Ekonomiczny

ORCID: 0000-0002-6329-278X

mgr inż. Anita Nikodem - Smołuch

Pomorska Szkoła Wyższa w Starogardzie Gdańskim

Instytutu Zarządzania, Ekonomii i Logistyki

Od zimna do inteligencji: jak AI, IoT i identyfikowalność przebudowują łańcuch chłodniczy żywności

From Cold to Intelligence: How AI, IoT and Traceability Are Reshaping the Food Cold Chain

Streszczenie

Łańcuch chłodniczy żywności przestaje być wyłącznie systemem transportu i magazynowania w kontrolowanej temperaturze, a staje się środowiskiem podejmowania decyzji opartym na danych. Celem artykułu jest krytyczna analiza roli sztucznej inteligencji, Internetu rzeczy oraz cyfrowej identyfikowalności w zarządzaniu jakością, bezpieczeństwem i efektywnością energetyczną łańcucha chłodniczego. Na podstawie zweryfikowanej literatury naukowej i źródeł instytucjonalnych zaproponowano model Cold Chain Decision Intelligence, który łączy pięć warstw: pomiar, wiarygodność danych, predykcję, decyzję operacyjną oraz nadzór. Wskazano, że korzyści technologiczne zależą nie tylko od jakości algorytmów, lecz również od interoperacyjności, reguł odpowiedzialności, walidacji modeli i zdolności organizacji do przełożenia sygnału z czujnika na działanie. Artykuł formułuje rekomendacje wdrożeniowe i agendę badań dla inteligentnej, odpornej i zrównoważonej logistyki chłodniczej.

Słowa kluczowe: łańcuch chłodniczy, sztuczna inteligencja, Internet rzeczy, identyfikowalność, logistyka żywności, zrównoważony rozwój

Abstract

The food cold chain is evolving from a temperature controlled transport and storage system into a data driven decision environment. This article critically examines the roles of artificial intelligence, the Internet of Things and digital traceability in managing quality, safety and energy efficiency across food cold chains. Drawing on verified peer reviewed literature and institutional sources, the paper proposes a Cold Chain Decision Intelligence model composed of five layers: sensing, data trust, prediction, operational decision and governance. The analysis shows that technological benefits depend not only on algorithmic performance but also on interoperability, accountability rules, model validation and an organisation's ability to convert sensor signals into timely action. The paper provides implementation recommendations and a research agenda for intelligent, resilient and sustainable cold chain logistics.

Keywords: cold chain, artificial intelligence, Internet of Things, traceability, food logistics, sustainability

Wprowadzenie

Łańcuch chłodniczy jest jednym z tych systemów logistycznych, w których jakość decyzji operacyjnej bezpośrednio przekłada się na jakość produktu. Temperatura, czas ekspozycji, wilgotność, sposób przeładunku, dostępność energii oraz ciągłość informacji oddziałują na bezpieczeństwo żywności i jej pozostały okres przydatności. Z tego powodu tradycyjne rozumienie chłodnictwa jako technicznego utrzymywania zadanej temperatury jest niewystarczające. Współczesny łańcuch chłodniczy jest systemem społeczno technicznym, w którym infrastruktura, dane, algorytmy, pracownicy i reguły odpowiedzialności tworzą wspólną architekturę sterowania.

Znaczenie problemu ma wymiar globalny. Raport UNEP i FAO wskazuje, że brak efektywnej infrastruktury chłodniczej jest istotnym czynnikiem strat żywności, a rozwój zrównoważonych łańcuchów chłodniczych wymaga jednoczesnego uwzględnienia bezpieczeństwa żywności, efektywności energetycznej i oddziaływania klimatycznego (United Nations Environment Programme & Food and Agriculture Organization of the United Nations,

2022). Raport podkreśla również skalę strat związanych z niewystarczającym chłodzeniem. Oznacza to, że poprawa łańcucha chłodniczego nie jest jedynie problemem technicznym, ale również zagadnieniem gospodarczym, środowiskowym i społecznym.

Badania nad zarządzaniem temperaturą pokazują, że odchylenia występują na wielu etapach przepływu, od wstępnego schładzania, przez transport, po ekspozycję detaliczną i etap konsumencki. Mercier et al. (2017) wykazali, że efektywność komercyjnych łańcuchów chłodniczych pozostaje nierówna, a samo gromadzenie danych nie eliminuje ryzyka, jeżeli informacja nie zostanie odpowiednio zinterpretowana i wykorzystana. Podobny wniosek wynika z przeglądu Ndraha et al. (2018), którzy wskazali, że monitoring temperatury wnosi istotną wartość, lecz jego potencjał zależy od praktycznej integracji technologii z procesami zarządzania.

Obecna fala cyfryzacji wzmacnia tę zależność. Czujniki Internetu rzeczy mogą dostarczać dane w czasie zbliżonym do rzeczywistego, sztuczna inteligencja może przewidywać zakłócenia i degradację jakości, a rozwiązania identyfikowalności mogą tworzyć spójny zapis zdarzeń w wielu ogniwach łańcucha dostaw. Najnowsza literatura wskazuje na rosnącą konwergencję AI, IoT i technologii rejestrowania zdarzeń logistycznych (Idrissi et al., 2024; Mustafa et al., 2024; Ronchei et al., 2026). Jednocześnie nadal pozostaje luka pomiędzy techniczną możliwością obserwacji procesu a zdolnością organizacji do podjęcia wiarygodnej, szybkiej i rozliczalnej decyzji.

Do takiego właśnie problemu odnosi się artykuł Zeng et al. (2026), który integruje AI, analizę dużych zbiorów danych, energooszczędne IoT oraz identyfikowalność opartą na blockchainie w koncepcyjnym modelu łańcucha chłodniczego. Autorzy podkreślają jednak brak empirycznej walidacji modelu. Stanowi to ważny punkt wyjścia do dalszej dyskusji: problemem nie jest już wyłącznie pytanie, czy technologię można połączyć, ale czy połączenie to tworzy rzeczywistą zdolność decyzyjną, którą można zweryfikować w warunkach operacyjnych.

Celem niniejszego artykułu jest zatem odpowiedź na pytanie, w jaki sposób połączyć warstwę pomiarową, analityczną i identyfikowalności z warstwą decyzji i nadzoru tak, aby cyfrowy łańcuch chłodniczy był jednocześnie skuteczny, odporny i możliwy do audytowania. Artykuł ma charakter koncepcyjno-przeglądowy. Nie deklaruje systematycznego przeglądu literatury. Podstawę analizy stanowią publikacje recenzowane, których dane bibliograficzne

I identyfikatory DOI zostały zweryfikowane, oraz źródła instytucjonalne UNEP, FAO i Unii Europejskiej.

1. Łańcuch chłodniczy jako system decyzji, a nie tylko temperatury

Definicja łańcucha chłodniczego koncentruje się zazwyczaj na utrzymaniu produktów w określonym zakresie temperatur w kolejnych etapach magazynowania, transportu i dystrybucji. Z perspektywy zarządczej kluczowa jest jednak ciągłość kontroli. Pojedynczy poprawny pomiar nie przesądza o jakości procesu. Istotna jest trajektoria warunków, czas odchylenia, wrażliwość produktu, miejsce wystąpienia zdarzenia oraz możliwość reakcji.

Klasyczne badania dotyczące inteligentnej logistyki żywności już wcześniej wskazywały, że celem monitoringu powinno być nie tylko rejestrowanie temperatury, lecz także wsparcie decyzji dotyczących pozostałego okresu przydatności i kolejności wydawania produktów. Jedermann et al. (2014) argumentowali, że informacja o rzeczywistym przebiegu warunków może wspierać bardziej racjonalne zarządzanie produktami łatwo psującymi się, w tym odejście od statycznego podejścia opartego wyłącznie na nominalnej dacie ważności.

To rozróżnienie ma istotne konsekwencje. W łańcuchu chłodniczym można wyróżnić co najmniej trzy poziomy informacji. Pierwszy to informacja o stanie, czyli odpowiedź na pytanie, co dzieje się teraz. Drugi to informacja prognostyczna, odpowiadająca na pytanie, co prawdopodobnie wydarzy się w krótkim horyzoncie. Trzeci to informacja decyzyjna, która wskazuje, jakie działanie należy podjąć oraz kto ponosi odpowiedzialność za jego wykonanie. Cyfryzacja często rozwija pierwszy poziom, coraz lepiej wspiera drugi, lecz najsłabiej projektowany pozostaje poziom trzeci.

Praktyczny przykład pokazuje różnicę. Alarm o temperaturze wyższej od wartości oczekiwanej jest jedynie sygnałem. Aby stał się elementem zarządzania, system powinien uwzględnić między innymi czas trwania odchylenia, charakter produktu, lokalizację partii, historię wcześniejszych zdarzeń, prognozowany czas do punktu odbioru i możliwość przekierowania dostawy. Dopiero wtedy możliwe jest rozstrzygnięcie, czy właściwą reakcją jest korekta parametrów chłodzenia, zmiana trasy, priorytetowy rozładunek, kontrola jakości, skrócenie deklarowanego okresu przydatności albo wycofanie partii.

Z punktu widzenia bezpieczeństwa żywności znaczenie ma również identyfikowalność. Aung i Chang (2014) wskazują, że system traceability ma wspierać zarówno bezpieczeństwo, jak i jakość poprzez możliwość odtworzenia historii produktu i szybkiego zawężenia zakresu reakcji. W Unii Europejskiej obowiązek identyfikowalności żywności wynika z art. 18 rozporządzenia (WE) nr 178/2002. Cyfrowa transformacja nie tworzy więc potrzeby identyfikowalności od zera, lecz zmienia jej rozdzielnosć, szybkość oraz sposób łączenia informacji jakościowej ze zdarzeniami logistycznymi.

2. Warstwa pomiarowa: IoT i problem wiarygodności danych

Internet rzeczy w łańcuchu chłodniczym obejmuje znacznie więcej niż termometr z modułem komunikacyjnym. W praktyce jest to środowisko czujników, identyfikatorów, urządzeń brzegowych, sieci komunikacyjnych i platform analitycznych. Mierzone mogą być między innymi temperatura, wilgotność względna, stężenia gazów, wstrząsy, lokalizacja, stan otwarcia drzwi oraz parametry energetyczne urządzeń chłodniczych.

Lamberty i Kreyenschmidt (2022) wykazują, że dla świeżych owoców i warzyw szczególną wartość mają pomiary temperatury, wilgotności, tlenu, dwutlenku węgla oraz wstrząsów. Jednocześnie autorki podkreślają, że nie istnieje jedno uniwersalne rozwiązanie dla wszystkich produktów i wszystkich łańcuchów. Heterogeniczność żywności, różnice w podatności na uszkodzenia i odmienne konfiguracje logistyczne powodują, że architektura pomiarowa musi być projektowana dla konkretnego zastosowania.

Doświadczenia z RFID pokazują, że idea łączenia identyfikacji produktu z danymi środowiskowymi nie jest nowa. Abad i współautorzy (2009) zademonstrowali inteligentny znacznik RFID z czujnikami temperatury i wilgotności w międzykontynentalnym łańcuchu świeżych ryb. Znaczenie tego badania jest nadal aktualne, ponieważ pokazuje ono podstawową zasadę inteligentnej logistyki: wartość powstaje wtedy, gdy informacja o warunkach jest przypisana do konkretnego produktu lub partii i może podróżować wraz z nim informacyjnie przez kolejne etapy.

Rozwój IoT nie usuwa jednak problemu jakości danych. Czujnik może być rozkalibrowany, błędnie umieszczony, pozbawiony zasilania, chwilowo odłączony od sieci albo generować dane, które nie są reprezentatywne dla całej przestrzeni ładunkowej. W konsekwencji system analityczny może wykonać bardzo zaawansowane obliczenia na danych, które nie

odzwierciedlają rzeczywistości. Właśnie dlatego pierwszym warunkiem dojrzałej architektury cyfrowej powinno być zarządzanie wiarygodnością pomiaru.

Praktyczne systemy zdalnego zarządzania chłodniami potwierdzają możliwość integracji pomiarów i sterowania. Mohammed et al. (2022) opisują rozwiązanie IoT umożliwiające zdalne monitorowanie i kontrolę chłodni. Z perspektywy organizacyjnej szczególnie istotne jest jednak uzupełnienie takiej architektury o procedury kalibracji, zarządzania brakami danych, weryfikację kompletności strumienia, oznaczenie źródła pomiaru i kontrolę wersji reguł sterujących.

Można zatem sformułować pierwszą zasadę proponowanej w tym artykule koncepcji: dane operacyjne nie powinny być traktowane jako fakty tylko dlatego, że pochodzą z czujnika. Powinny posiadać mierzalny poziom wiarygodności. Oznacza to, że wraz z wartością pomiarową system powinien przechowywać metadane o urządzeniu, czasie, lokalizacji, kalibracji, kompletności oraz ewentualnych transformacjach wykonanych przed analizą.

3. Warstwa predykcyjna: sztuczna inteligencja jako narzędzie wcześniejszej reakcji

Sztuczna inteligencja zmienia wartość danych z dwóch powodów. Po pierwsze, umożliwia wykrywanie wzorców trudnych do zidentyfikowania na podstawie pojedynczego progu alarmowego. Po drugie, przesuwa punkt reakcji z chwili wystąpienia problemu na moment, w którym problem staje się prawdopodobny. Jest to przejście od monitoringu reaktywnego do zarządzania predykcyjnego.

W logistyce chłodniczej zastosowania AI można podzielić na kilka grup. Pierwsza dotyczy prognozowania zmian temperatury i jakości produktu. Druga obejmuje wykrywanie anomalii, na przykład nietypowej pracy agregatu, nietypowych sekwencji otwierania drzwi lub odchyłeń poboru energii. Trzecia grupa dotyczy optymalizacji, na przykład trasy, czasu przeładunku, kolejności obsługi partii albo parametrów chłodzenia. Czwarta obejmuje analizę obrazu i automatyczną ocenę widocznych cech jakościowych. Piąta odnosi się do predykcyjnego utrzymania infrastruktury.

Bibliometryczna analiza Ronchei et al. (2026) potwierdza rosnącą obecność AI w badaniach nad łańcuchami żywności i łańcuchami chłodniczymi. Z kolei Chen et al. (2026) wskazują, że inteligentna optymalizacja coraz częściej musi godzić wiele celów jednocześnie, w tym jakość produktu, koszt, wykorzystanie energii i oddziaływanie środowiskowe. Ta

wielokryterialność jest szczególnie ważna, ponieważ najniższa temperatura nie zawsze oznacza najlepszą decyzję. Nadmierne chłodzenie może zwiększać zużycie energii, a dla części produktów także pogarszać jakość.

Największym ryzykiem jest utożsamienie trafności modelu z trafnością decyzji. Model może poprawnie przewidywać wzrost temperatury, lecz organizacja może nie posiadać zasobu lub procedury, która umożliwi odpowiednią reakcję. Może również powstać problem fałszywych alarmów, które z czasem zmniejszają gotowość personelu do reagowania. Dlatego miary jakości modelu powinny być uzupełniane miarami operacyjnymi, takimi jak czas od detekcji do interwencji, odsetek alarmów zakończonych działaniem, koszt interwencji oraz rzeczywista redukcja strat.

Drugim ryzykiem jest dryf modelu. Warunki eksploatacji floty, zachowania kierowców, sezonowość, dostawcy, opakowania i charakterystyka produktów mogą się zmieniać. Model uczony na danych historycznych traci część swojej wartości, jeżeli organizacja nie monitoruje zmiany rozkładu danych i nie prowadzi ponownej walidacji. Badania nad strumieniami danych wskazują, że zmiany rozkładu danych mogą prowadzić do pogorszenia działania modeli i wymagają mechanizmów detekcji oraz adaptacji (Arora et al., 2024). W zastosowaniach związanych z bezpieczeństwem żywności algorytm powinien być zatem traktowany jako element systemu jakości, a nie jako samodzielny autorytet.

Warto podkreślić, że najbardziej dojrzałe wykorzystanie AI nie polega na automatyzowaniu każdej decyzji. Część decyzji może być automatyczna, część wymaga akceptacji pracownika, a część powinna pozostać wyłącznie decyzją ekspercką. Badania nad podejściem human in the loop pokazują, że człowiek może pełnić różne role w procesie uczenia, walidacji i wykorzystania modelu, a projekt interakcji wpływa na użyteczność całego systemu (Mosqueira Rey et al., 2023). Jednocześnie właściwa kalibracja zaufania do AI wymaga komunikowania ograniczeń, niepewności i przesłanek rekomendacji (Mehrotra et al., 2024). Kryterium podziału odpowiedzialności powinny stanowić konsekwencje błędu, odwracalność działania, jakość danych oraz możliwość wyjaśnienia podstaw rekomendacji.

4. Identyfikowalność: od zapisu zdarzeń do zaufania międzyorganizacyjnego

Cyfrowa identyfikowalność jest warstwą łączącą przepływ fizyczny z przepływem informacji. Jej podstawowym zadaniem jest odpowiedź na pytania: co, kiedy, gdzie i przez kogo

wydarzyło się z produktem lub partią. W inteligentnym łańcuchu chłodniczym do tych pytań dochodzi kolejne: w jakich warunkach wydarzenie miało miejsce.

Badania Aung i Chang (2014) pokazują, że traceability wspiera bezpieczeństwo i jakość, ponieważ skraca czas identyfikacji źródła problemu i pozwala precyzyjniej określić zakres działań. Wraz z rozwojem IoT rośnie możliwość dołączania do historii partii informacji o temperaturze, wilgotności i lokalizacji. Powstaje zatem cyfrowy ślad, który może służyć nie tylko do dochodzenia po incydencie, ale także do bieżącego sterowania.

Blockchain bywa przedstawiany jako technologia, która automatycznie rozwiązuje problem zaufania. Taki sposób myślenia jest nadmiernym uproszczeniem. Feng et al. (2020) wskazują korzyści w zakresie przejrzystości i bezpieczeństwa zapisu, ale jednocześnie zwracają uwagę na bariery implementacyjne. Rana et al. (2021) w przeglądzie dotyczącym zrównoważonego łańcucha rolno spożywczego również pokazują, że wartość blockchainu zależy od sposobu włączenia go w szerszy system informacyjny.

Najważniejszy paradoks brzmi: niezmiennosc zapisu nie gwarantuje prawdziwości danych wejściowych. Jeżeli błędny pomiar albo błędnie zidentyfikowana partia zostaną zapisane w rozproszonej bazie, system może bardzo skutecznie utrwalić błąd. Dlatego blockchain powinien być traktowany jako mechanizm integralności i współdzielenia danych, a nie jako substytut jakości danych.

Nowsze przeglądy potwierdzają, że technologia nadal rozwija się w kierunku integracji z IoT i systemami identyfikowalności. Rejeb et al. (2026) wskazują na utrzymujące się znaczenie transparentności, efektywności operacyjnej i bezpieczeństwa żywności, ale także na potrzebę dalszych badań nad rzeczywistą skalowalnością rozwiązań. Z punktu widzenia przedsiębiorstwa decyzja o blockchainie powinna więc wynikać z konkretnego problemu zaufania lub współdzielenia danych, a nie z samej dostępności technologii.

Warunkiem praktycznej identyfikowalności pozostaje interoperacyjność. Jeżeli każdy uczestnik łańcucha stosuje własne nazwy zdarzeń, własne identyfikatory i własne formaty czasu, historia produktu staje się zbiorem lokalnych narracji. Standard EPCIS wraz z Core Business Vocabulary został opracowany właśnie po to, aby umożliwiać wymianę zdarzeń dotyczących widoczności łańcucha dostaw w ujednoliconym modelu danych i wspólnym słowniku biznesowym, w tym z obsługą danych z czujników istotnych dla łańcucha chłodniczego (GS1,

2022). Z tego względu standaryzacja semantyki danych i jednoznaczne identyfikatory są często ważniejsze niż wybór konkretnej bazy danych.

5. Energia, emisje i paradoks zrównoważonego chłodzenia

Łańcuch chłodniczy ogranicza straty żywności, ale jednocześnie sam zużywa energię i korzysta z czynników chłodniczych. Powstaje zatem klasyczny konflikt celów. Zbyt słabe chłodzenie zwiększa ryzyko pogorszenia jakości i strat produktu, natomiast nadmierne chłodzenie może zwiększać koszt i ślad środowiskowy bez proporcjonalnej korzyści jakościowej.

Raport UNEP i FAO (2022) traktuje zrównoważony łańcuch chłodniczy jako system, który powinien jednocześnie ograniczać straty żywności i minimalizować negatywne oddziaływanie energetyczne oraz klimatyczne. W tym ujęciu technologia cyfrowa jest narzędziem do lepszego dopasowania chłodzenia do rzeczywistego zapotrzebowania, a nie celem samym w sobie.

Chen et al. (2026) opisują zrównoważoną optymalizację jako problem wieloskalowy, obejmujący poziom urządzeń chłodniczych, przepływ produktu, operacje łańcucha dostaw i politykę. Taka perspektywa jest szczególnie użyteczna dla zarządzania, ponieważ pokazuje, że lokalna oszczędność energii może nie być optymalna z punktu widzenia całego systemu. Na przykład zmniejszenie intensywności chłodzenia w jednym ogniwie może zwiększyć straty produktu w innym.

Sztuczna inteligencja może wspierać sterowanie adaptacyjne, przewidywać obciążenie, identyfikować nieefektywne cykle pracy i wspierać harmonogramowanie urządzeń. Jednak każda deklaracja oszczędności powinna być oceniana na podstawie danych empirycznych i jasno określonej wartości bazowej. Artykuły koncepcyjne, w tym praca Zeng et al. (2026), są użyteczne do budowania architektury rozwiązań, lecz nie powinny być traktowane jako dowód konkretnej skali redukcji energii, jeżeli nie przeprowadzono walidacji w rzeczywistym środowisku.

Z tego względu w dojrzałym wdrożeniu należy równolegle monitorować co najmniej cztery grupy wskaźników: jakość i bezpieczeństwo produktu, zużycie energii, emisje związane z eksploatacją oraz straty i odpady. Dopiero wspólna analiza pozwala uniknąć optymalizacji jednego wskaźnika kosztem pozostałych.

6. Proponowany model Cold Chain Decision Intelligence

Na podstawie przeprowadzonej syntezy proponuje się model Cold Chain Decision Intelligence, dalej CCDI. Jego założeniem jest przesunięcie punktu ciężkości z integracji technologii na integrację decyzji. Model składa się z pięciu warstw, które powinny być projektowane łącznie.

Warstwa	Główne pytanie	Przykładowe komponenty	Kluczowe ryzyko
1. Pomiar	Co dzieje się z produktem i infrastrukturą?	Czujniki temperatury i wilgotności, lokalizacja, RFID, dane agregatu	Błąd lub brak reprezentatywności pomiaru
2. Wiarygodność danych	Czy danym można zaufać?	Kalibracja, synchronizacja czasu, walidacja, metadane, kontrola braków	Dobra analiza wykonana na złych danych
3. Predykcja	Co może wydarzyć się za chwilę?	Modele anomalii, prognoza jakości, prognoza awarii, estymacja pozostałego okresu przydatności	Dryf modelu i fałszywa pewność
4. Decyzja operacyjna	Co należy zrobić teraz?	Reguły reakcji, optymalizacja trasy, priorytet rozładunku, zmiana parametrów chłodzenia	Brak właściciela decyzji lub opóźniona reakcja
5. Nadzór i rozliczalność	Czy decyzja była zgodna, skuteczna i audytowalna?	Historia zdarzeń, identyfikowalność, uprawnienia, rejestr decyzji, okresowa walidacja	Automatyzacja bez odpowiedzialności

Tabela 1. Model Cold Chain Decision Intelligence. Opracowanie własne.

Warstwa pierwsza obejmuje fizyczne pozyskanie danych. Jej jakość zależy od poprawnego rozmieszczenia czujników, częstotliwości próbkowania, zasilania, transmisji i identyfikacji obiektu. Warstwa druga ma znaczenie krytyczne, ponieważ ustanawia zaufanie do danych. To tutaj system powinien określać, czy pomiar jest kompletny, aktualny, zsynchronizowany i zgodny z wymaganiami jakościowymi.

Warstwa trzecia odpowiada za interpretację i przewidywanie. Nie powinna generować jedynie pojedynczej etykiety alarmowej, lecz informację o prawdopodobieństwie zdarzenia, horyzoncie czasu i poziomie niepewności. Pozwala to różnicować reakcje oraz ograniczać problem automatycznego traktowania każdego odchylenia jako incydentu o tej samej wadze.

Warstwa czwarta jest najważniejszym elementem modelu. Łączy predykcję z możliwością wykonania działania. Każda klasa zdarzenia powinna posiadać zdefiniowany zestaw możliwych reakcji, właściciela procesu, maksymalny czas reakcji i kryterium eskalacji. To właśnie w tej warstwie pojawia się rzeczywista wartość biznesowa, ponieważ decyzja wpływa na produkt, koszt, terminowość i poziom ryzyka.

Warstwa piąta tworzy nadzór. Obejmuje identyfikowalność, rejestrowanie podjętych decyzji, uprawnienia, ocenę skuteczności działania i okresową walidację modeli. W tym miejscu technologie niezmiennego zapisu mogą mieć największe uzasadnienie, jeżeli kilka organizacji potrzebuje wspólnego, audytowalnego rejestru zdarzeń. Nie oznacza to jednak, że blockchain jest wymagany elementem każdego wdrożenia.

Nowość modelu CCDI polega zatem nie na dodaniu kolejnej technologii, lecz na ustanowieniu ciągłości pomiędzy obserwacją a odpowiedzialnością. Inteligentny łańcuch chłodniczy powinien być oceniany nie przez liczbę czujników i algorytmów, ale przez zdolność do skrócenia czasu wykrycia, poprawy trafności interwencji i ograniczenia skutków odchylenia.

7. Bariery wdrożenia i punkty krytyczne

Pierwszą barierą jest interoperacyjność. W łańcuchu chłodniczym spotykają się systemy producenta, operatora logistycznego, przewoźnika, magazynu, detalisty i jednostek kontroli. Integracja techniczna bez wspólnej semantyki danych tworzy pozorną cyfryzację, ponieważ ten sam produkt, partia lub zdarzenie mogą być opisywane inaczej w każdym systemie.

Drugą barierą jest ekonomika wdrożenia. Czujniki stają się tańsze, ale koszt całego rozwiązania obejmuje także transmisję, utrzymanie, wymianę urządzeń, integrację z systemami przedsiębiorstwa, cyberbezpieczeństwo, rozwój modeli, walidację i szkolenie personelu. Ocena opłacalności powinna więc obejmować całkowity koszt posiadania oraz wartość unikniętych strat, a nie tylko cenę pojedynczego sensora.

Trzecią barierą są czynniki ludzkie. Mustafa et al. (2024) wskazują, że literatura dotycząca food cold chain logistics nadal pozostawia luki w zakresie praktycznych zastosowań technologii i czynników ludzkich. Badania nad systemami human in the loop wskazują jednocześnie, że skuteczność współpracy człowieka z algorytmem zależy od właściwego zaprojektowania interakcji oraz roli człowieka w procesie decyzyjnym (Mosqueira Rey et al., 2023). Jest to szczególnie ważne, ponieważ alarm, który nie jest zrozumiały lub pojawia się zbyt często, może być ignorowany. Personel powinien rozumieć nie tylko to, co wskazuje system, ale również jaka jest pewność rekomendacji i jakie konsekwencje ma brak reakcji.

Czwartą barierą jest cyberbezpieczeństwo. Połączenie urządzeń chłodniczych z siecią rozszerza powierzchnię potencjalnego ataku. Systematyczny przegląd Jonesa i Feoktistova

(2025) wskazuje, że cyfryzacja łańcucha żywnościowego tworzy złożone systemy cyberfizyczne, w których podatności mogą występować na wielu etapach łańcucha. Manipulacja danymi pomiarowymi może prowadzić do błędnych decyzji, a przejęcie funkcji sterowania może wpływać na produkt i proces. Wrażliwość rośnie szczególnie wtedy, gdy system posiada możliwość automatycznej zmiany parametrów urządzeń.

Piątą barierą jest walidacja. Rozwiązanie testowane w jednym produkcie, klimacie, typie pojazdu i konfiguracji opakowania nie musi zachować jakości w innym środowisku. Dlatego pilotaż powinien obejmować scenariusze normalne, graniczne i awaryjne. Ocena modelu powinna uwzględniać zarówno dokładność analityczną, jak i skutki operacyjne błędnej rekomendacji.

Szóstą barierą jest odpowiedzialność. Im większa automatyzacja, tym bardziej potrzebne są jasne reguły określające, kto odpowiada za konfigurację progów, akceptację modelu, reakcję na alarm, zmianę parametrów i decyzję o dopuszczeniu produktu. Brak takiego przypisania może prowadzić do sytuacji, w której system dostarcza informację, lecz żaden uczestnik procesu nie czuje się właścicielem decyzji.

8. Implikacje dla praktyki zarządzania

Przedsiębiorstwa planujące cyfrową transformację łańcucha chłodniczego powinny zaczynać od decyzji, a nie od technologii. Pierwszym krokiem jest identyfikacja zdarzeń, które generują największe straty lub ryzyko, oraz wskazanie decyzji, które dziś są podejmowane zbyt późno albo na podstawie niepełnej informacji. Dopiero potem należy określić, jakie dane są potrzebne do poprawy tych decyzji.

Drugim krokiem jest ustanowienie minimalnego zestawu danych krytycznych. Nie każdy możliwy parametr musi być mierzony. Nadmiar danych zwiększa koszty i utrudnia analizę. Zestaw powinien wynikać z cech produktu, procesu i ryzyka. W przypadku świeżych produktów roślinnych będzie on inny niż w transporcie mrożonek, farmaceutyków czy specjalistycznych surowców chemicznych.

Trzecim krokiem jest stworzenie reguł jakości danych. Każdy krytyczny czujnik powinien mieć określony status, historię kalibracji i mechanizm wykrywania przerw w transmisji. Dane

bez statusu jakościowego nie powinny automatycznie uruchamiać decyzji o wysokich konsekwencjach.

Czwartym krokiem jest projektowanie człowieka w pętli decyzyjnej. Automatyzacja powinna być stopniowana. Dla zdarzeń o niskim ryzyku system może działać automatycznie. Dla zdarzeń o wysokich konsekwencjach powinien generować rekomendację, uzasadnienie i poziom pewności, pozostawiając zatwierdzenie osobie odpowiedzialnej.

Piątym krokiem jest mierzenie skuteczności wdrożenia. Oprócz parametrów technicznych należy monitorować czas reakcji, redukcję strat, liczbę niepotrzebnych interwencji, zużycie energii, poziom reklamacji i jakość identyfikowalności. Wdrożenie powinno być uznane za skuteczne dopiero wtedy, gdy poprawia wyniki procesu, a nie tylko zwiększa ilość dostępnych danych.

Szóstym krokiem jest budowa zasad współdzielenia informacji z partnerami. W praktyce nie każdy uczestnik łańcucha potrzebuje dostępu do wszystkich danych. Należy rozróżnić dane wymagane dla bezpieczeństwa i identyfikowalności od danych stanowiących wrażliwą informację operacyjną lub handlową. Dopiero na tym poziomie można racjonalnie zdecydować, czy potrzebna jest wspólna platforma, standard wymiany zdarzeń lub rozwiązanie rozproszone.

9. Agenda dalszych badań

Pierwszym kierunkiem badań powinna być walidacja zintegrowanych modeli w rzeczywistych łańcuchach chłodniczych. Literatura nadal zawiera znaczną liczbę modeli koncepcyjnych oraz rozwiązań pilotażowych. Potrzebne są badania wieloobektowe, w których porównywane będą wyniki przed i po wdrożeniu przy jasno zdefiniowanej wartości bazowej.

Drugi kierunek dotyczy łączenia miar technicznych z miarami zarządczymi. Dokładność predykcji jest ważna, ale z punktu widzenia przedsiębiorstwa równie istotne są czas decyzji, koszt reakcji i wielkość unikniętej straty. Potrzebne są modele oceny, które łączą te poziomy w jednej strukturze.

Trzecim obszarem jest wyjaśnialność rekomendacji AI. W systemach o wysokiej odpowiedzialności pracownik powinien rozumieć główne przesłanki decyzji. Badania powinny zatem porównywać modele nie tylko pod względem trafności, lecz także pod względem zrozumiałości, stabilności i podatności na audyt.

Czwarty obszar to interoperacyjność semantyczna. Warto badać, jakie minimalne zestawy zdarzeń i parametrów pozwalają na skuteczną współpracę między producentem, operatorem logistycznym, przewoźnikiem i odbiorcą bez konieczności ujawniania wszystkich danych biznesowych.

Piąty kierunek obejmuje optymalizację wielokryterialną. Coraz ważniejsze staje się jednocześnie uwzględnienie bezpieczeństwa produktu, pozostałego okresu przydatności, energii, emisji, kosztu i terminowości. Badania Chen et al. (2026) wskazują, że właśnie ten kierunek może stanowić podstawę kolejnej generacji autonomicznych systemów chłodniczych.

Szósty kierunek powinien obejmować odporność na awarie i cyberataki. Inteligentny łańcuch chłodniczy musi zachować zdolność do bezpiecznego działania także w sytuacji braku łączności, błędu modelu, utraty części danych lub kompromitacji urządzenia. Potrzebne są zatem badania nad trybami degradacji kontrolowanej oraz nad mechanizmami bezpiecznego przejścia z automatyzacji do sterowania ręcznego.

10. Dyskusja

Przegląd literatury prowadzi do wniosku, że rozwój inteligentnego łańcucha chłodniczego znajduje się w punkcie przejścia. Techniczna zdolność pozyskiwania danych jest już relatywnie wysoka. Dostępne są rozwiązania dla monitoringu temperatury, wilgotności, położenia i stanu urządzeń, a literatura opisuje liczne zastosowania RFID, IoT, uczenia maszynowego i blockchainu. Problem badawczy i wdrożeniowy przesunął się więc z pytania o dostępność technologii na pytanie o jakość architektury decyzyjnej.

To przesunięcie pozwala inaczej interpretować konwergencję AI, IoT i blockchainu. Idrissi et al. (2024) pokazują, że technologie te są coraz częściej analizowane wspólnie w logistyce. Nie oznacza to jednak, że każda z nich musi być obecna w każdym wdrożeniu. IoT jest potrzebne wtedy, gdy brak danych o stanie fizycznym procesu. AI ma uzasadnienie wtedy, gdy istnieje wystarczająca jakość danych i problem przekracza możliwości prostych reguł. Blockchain ma sens wtedy, gdy występuje międzyorganizacyjny problem integralności i zaufania do współdzielonej historii zdarzeń.

Z tej perspektywy model CCDI może być traktowany jako narzędzie diagnostyczne do oceny dojrzałości wdrożenia. Organizacja może posiadać rozbudowaną warstwę pomiarową, ale

słabą warstwę wiarygodności danych. Może dysponować dobrym modelem predykcyjnym, ale nie mieć procedury reakcji. Może też posiadać doskonały zapis zdarzeń, lecz nie mierzyć, czy decyzje rzeczywiście ograniczają straty. Takie rozdzielenie warstw ujawnia, gdzie powstaje wąskie gardło.

Ważnym wnioskiem jest także konieczność zachowania ostrożności wobec deklarowanych efektów. W literaturze koncepcyjnej często pojawiają się przewidywane korzyści energetyczne lub jakościowe. Bez jasno opisanej metodologii, danych bazowych i walidacji nie powinny być one traktowane jako uniwersalne wartości referencyjne. Z naukowego punktu widzenia szczególnie potrzebne są badania terenowe obejmujące pełny cykl operacyjny oraz porównanie kilku kategorii produktów i konfiguracji logistycznych.

Artykuł ma ograniczenia. Jako opracowanie koncepcyjno przeglądowe nie jest systematycznym przeglądem literatury ani metaanalizą. Dobór źródeł został podporządkowany bezpośredniej przydatności dla konstrukcji modelu i możliwości weryfikacji bibliograficznej. Model CCDI wymaga empirycznej walidacji, w szczególności sprawdzenia, czy jego zastosowanie poprawia czas reakcji, ogranicza straty i podnosi jakość decyzji w porównaniu z klasycznymi systemami monitoringu.

Wnioski

Inteligentny łańcuch chłodniczy nie powinien być definiowany przez liczbę czujników, wielkość zbioru danych ani obecność sztucznej inteligencji. Jego dojrzałość wyraża się zdolnością do przekształcenia wiarygodnego pomiaru w trafną, terminową i rozliczalną decyzję.

Analiza literatury potwierdza, że IoT zwiększa widoczność procesu, AI rozszerza możliwości predykcji i optymalizacji, a cyfrowa identyfikowalność może zwiększać przejrzystość i szybkość reakcji. Jednocześnie każda z tych technologii generuje nowe zależności związane z jakością danych, interoperacyjnością, walidacją, cyberbezpieczeństwem i odpowiedzialnością.

Proponowany model Cold Chain Decision Intelligence porządkuje te zależności w pięciu warstwach: pomiaru, wiarygodności danych, predykcji, decyzji operacyjnej oraz nadzoru. Takie ujęcie przesuwaa dyskusję od technologicznej integracji do jakości zarządzania. W praktyce może

ono służyć jako rama do projektowania pilotaży, audytu dojrzałości cyfrowej i oceny ryzyka wdrożeń.

Najbardziej obiecującym kierunkiem rozwoju nie jest pełna automatyzacja za wszelką cenę, lecz inteligentna orkiestracja ludzi, danych i algorytmów. W łańcuchu chłodniczym właśnie ta zdolność może decydować o tym, czy cyfryzacja faktycznie ograniczy straty, zużycie energii i ryzyko, czy pozostanie jedynie rozbudowanym systemem rejestrowania zdarzeń.

Bibliografia

- Abad, E., Palacio, F., Nuin, M., González de Zárate, A., Juarros, A., Gómez, J. M., & Marco, S. (2009). RFID smart tag for traceability and cold chain monitoring of foods: Demonstration in an intercontinental fresh fish logistic chain. *Journal of Food Engineering*, 93(4), 394–399. <https://doi.org/10.1016/j.jfoodeng.2009.02.004>
- Arora, S., Rani, R., & Saxena, N. (2024). A systematic review on detection and adaptation of concept drift in streaming data using machine learning techniques. *WIREs Data Mining and Knowledge Discovery*, 14(4), e1536. <https://doi.org/10.1002/widm.1536>
- Aung, M. M., & Chang, Y. S. (2014). Traceability in a food supply chain: Safety and quality perspectives. *Food Control*, 39, 172–184. <https://doi.org/10.1016/j.foodcont.2013.11.007>
- Chen, Q., Wang, J., Li, J., Ren, Z., Liu, Z., Wei, Y., Ma, W., Yu, J., & Qian, J. (2026). Ubiquitous intelligent optimization promotes sustainable food cold chain logistics: Research progress, challenges, and future trends. *Trends in Food Science & Technology*, 170, 105593. <https://doi.org/10.1016/j.tifs.2026.105593>
- European Parliament and Council of the European Union. (2002). Regulation (EC) No 178/2002 laying down the general principles and requirements of food law, establishing the European Food Safety Authority and laying down procedures in matters of food safety. *Official Journal of the European Communities*, L 31, 1–24.
- Feng, H., Wang, X., Duan, Y., Zhang, J., & Zhang, X. (2020). Applying blockchain technology to improve agri-food traceability: A review of development methods, benefits and challenges. *Journal of Cleaner Production*, 260, 121031. <https://doi.org/10.1016/j.jclepro.2020.121031>

- GS1. (2022). *EPCIS and Core Business Vocabulary (CBV), version 2.0*.
<https://www.gs1.org/standards/epcis>
- Idrissi, Z. K., Lachgar, M., & Hrimech, H. (2024). Blockchain, IoT and AI in logistics and transportation: A systematic review. *Transport Economics and Management*, 2, 275–285.
<https://doi.org/10.1016/j.team.2024.09.002>
- Jedermann, R., Nicometo, M., Uysal, I., & Lang, W. (2014). Reducing food losses by intelligent food logistics. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 372(2017), 20130302. <https://doi.org/10.1098/rsta.2013.0302>
- Jones, R., & Feoktistov, D. (2025). Cybersecurity vulnerabilities in the food supply chain and their impact on food security: A systematic literature review. *Global Smart Food Systems*, 1(1), 1–27. <https://doi.org/10.1108/GSFS-10-2024-0001>
- Lamberty, A., & Kreyenschmidt, J. (2022). Ambient parameter monitoring in fresh fruit and vegetable supply chains using Internet of Things-enabled sensor and communication technology. *Foods*, 11(12), 1777. <https://doi.org/10.3390/foods11121777>
- Mehrotra, S., Degachi, C., Vereschak, O., Jonker, C. M., & Tielman, M. L. (2024). A systematic review on fostering appropriate trust in human-AI interaction: Trends, opportunities and challenges. *ACM Journal on Responsible Computing*, 1(4), Article 26, 1–45.
<https://doi.org/10.1145/3696449>
- Mercier, S., Villeneuve, S., Mondor, M., & Uysal, I. (2017). Time-temperature management along the food cold chain: A review of recent developments. *Comprehensive Reviews in Food Science and Food Safety*, 16(4), 647–667. <https://doi.org/10.1111/1541-4337.12269>
- Mohammed, M., Riad, K., & Alqahtani, N. (2022). Design of a smart IoT-based control system for remotely managing cold storage facilities. *Sensors*, 22(13), 4680.
<https://doi.org/10.3390/s22134680>
- Mosqueira-Rey, E., Hernández-Pereira, E., Alonso-Ríos, D., Bobes-Bascarán, J., & Fernández-Leal, Á. (2023). Human-in-the-loop machine learning: A state of the art. *Artificial Intelligence Review*, 56, 3005–3054. <https://doi.org/10.1007/s10462-022-10246-w>
- Mustafa, M. F. M. S., Navaranjan, N., & Demirovic, A. (2024). Food cold chain logistics and management: A review of current development and emerging trends. *Journal of Agriculture and Food Research*, 18, 101343. <https://doi.org/10.1016/j.jafr.2024.101343>

- Ndraha, N., Hsiao, H. I., Vlajic, J., Yang, M. F., & Lin, H. T. V. (2018). Time-temperature abuse in the food cold chain: Review of issues, challenges, and recommendations. *Food Control*, 89, 12–21. <https://doi.org/10.1016/j.foodcont.2018.01.027>
- Rana, R. L., Tricase, C., & De Cesare, L. (2021). Blockchain technology for a sustainable agri-food supply chain. *British Food Journal*, 123(11), 3471–3485. <https://doi.org/10.1108/BFJ-09-2020-0832>
- Rejeb, A., Rejeb, K., Treiblmaier, H., Süle, E., & Lahbib, M. (2026). Blockchain technology for food supply chain traceability using a systematic literature review and co-word analysis. *Discover Sustainability*. <https://doi.org/10.1007/s43621-026-04096-7>
- Ronchei, A., Monferdini, L., Bigliardi, B., & Bottani, E. (2026). Artificial intelligence in the cold and food supply chains: A bibliometric analysis. *Procedia Computer Science*, 277, 1181–1193. <https://doi.org/10.1016/j.procs.2026.02.158>
- United Nations Environment Programme, & Food and Agriculture Organization of the United Nations. (2022). *Sustainable food cold chains: Opportunities, challenges and the way forward*. <https://doi.org/10.4060/cc0923en>
- Zeng, S., Wu, Y., Wang, J., & Xia, K. (2026). AI-driven big data acquisition and optimization in cold chain logistics using energy-aware IoT systems. *Sustainable Computing: Informatics and Systems*, 50, 101362. <https://doi.org/10.1016/j.suscom.2026.101362>