



POLITECHNIKA POZNAŃSKA
WYDZIAŁ INŻYNIERII MECHANICZNEJ

Inteligentny system nadzorowania zautomatyzowanego procesu technologicznego konfekcjonowania wyrobów

mgr inż. Hubert Kędziora

ROZPRAWA DOKTORSKA

**Promotor: dr hab. inż. Małgorzata Jasiulewicz-Kaczmarek
Promotor pomocniczy: dr inż. Justyna Trojanowska**

POZNAŃ 2025

Pani Promotor, dr hab. inż. Małgorzacie Jasiulewicz-Kaczmarek, prof. PP, składam serdeczne podziękowania za nieocenione wsparcie, cenne wskazówki merytoryczne oraz okazywaną życzliwość w trakcie realizacji niniejszej rozprawy doktorskiej.

Profesjonalizm i zaangażowanie Pani Profesor były dla mnie źródłem inspiracji i motywacji, a możliwość pracy pod Jej kierunkiem stanowiła dla mnie prawdziwy zaszczyt.

Mojej Żonie, Alicji, pragnę podziękować za cierpliwość, wyrozumiałość i wsparcie, które towarzyszyły mi podczas całego okresu przygotowywania niniejszej rozprawy.

Pracę tę dedykuję Żonie, Synowi Stanisławowi, Córcie Małgorzacie oraz Kolejnej Pociesze, która wkrótce przyjdzie na świat – jako wyraz wdzięczności i miłości dla Najbliższych, będących dla mnie największą motywacją i siłą w tej drodze.

Rozprawa doktorska została zrealizowana w ramach programu "Doktorat wdrożeniowy",
finansowanego z budżetu Państwa i realizowanego przy współpracy Politechniki
Poznańskiej oraz Mróz S.A., Umowa nr DWD/4/22/2020
Opiekun pomocniczy: mgr inż. Szymon Dobrychłop

Spis treści

Wykaz skrótów i oznaczeń	6
STRESZCZENIE	9
ABSTRACT	10
1. Wprowadzenie.....	11
1.1. Geneza tematu pracy	11
1.2. Problem badawczy	12
1.3. Cel pracy.....	13
1.4. Struktura pracy	14
2. Przegląd stanu wiedzy – badania literaturowe	16
2.1. Nadzorowanie procesów produkcyjnych	16
2.1.1. Od manualnego nadzoru do Przemysłu 5.0	16
2.1.2. Funkcje inteligentnego nadzorowania procesów.....	17
2.1.3. Systemy i technologie wspomagające nadzorowanie procesów produkcyjnych.....	19
2.1.4. Architektura inteligentnego systemu nadzorowania	25
2.1.5. Metody oceny i wskaźniki efektywności inteligentnego nadzorowania procesów	27
2.2. Konfekcjonowanie.....	32
2.2.1. Znaczenie i charakterystyka procesu konfekcjonowania	32
2.2.2. Wyzwania operacyjne i jakościowe w procesie konfekcjonowania	36
2.2.3. Metody oraz narzędzia nadzorowania w procesach konfekcjonowania	38
2.2.4. Integracja i perspektywy rozwoju systemów nadzorowania procesu konfekcjonowania ...	43
2.3. Podsumowanie stanu wiedzy.....	45
3. Koncepcja i projekt systemu	48
3.1. Środowisko wdrożeniowe	48
3.2. Identyfikacja problemów występujących w analizowanym procesie.....	55
3.3. Koncepcja systemu.....	58
4. Budowa inteligentnego systemu nadzorowania procesu konfekcjonowania wyrobów	66
4.1. Moduł nadzorowania masy porcji	66
4.2. Moduł nadzorowania „nieszczelności I”	69
4.3. Moduł nadzorowania „nieszczelności II”	85
4.4. Moduł nadzorowania etykiet i ich treści	103
4.5. Moduł nadzorowania odrzutu wyrobów niezgodnych	107
4.6. Cyberbezpieczeństwo systemu.....	111
5. Walidacja i ocena działania systemu	112
5.1. Weryfikacja modułów i modeli	112
5.2. Walidacja całościowa na danych operacyjnych.....	116

5.3. Analiza SWOT implementacji.....	128
6. Podsumowanie i wnioski.....	130
6.1. Najważniejsze rezultaty badań i efektów wdrożenia.....	130
6.2. Wnioski poznawcze.....	131
6.3. Wnioski uylitarne	133
6.4. Ograniczenia badań i napotkane problemy	133
6.5. Rekomendacje i kierunki dalszych badań	134
ZAŁĄCZNIKI.....	137
SPIS RYSUNKÓW	147
SPIS TABEL	150
SPIS ZAŁĄCZNIKÓW	151
BIBLIOGRAFIA.....	152

Wykaz skrótów i oznaczeń

- 5G – piąta generacja technologii sieci komórkowych, zapewniająca wyższą przepływność i niższe opóźnienia.
- ADR – międzynarodowa konwencja dotycząca przewozu drogowego towarów niebezpiecznych (ang. European Agreement concerning the International Carriage of Dangerous Goods by Road).
- AGV – autonomiczny pojazd transportowy (ang. Automated Guided Vehicle).
- AHP – metoda hierarchicznej analizy problemów decyzyjnych (ang. Analytic Hierarchy Process).
- AI – sztuczna inteligencja (ang. Artificial Intelligence).
- API – interfejs programistyczny do komunikacji między programami (ang. Application Programming Interface).
- AR – rozszerzona rzeczywistość (ang. Augmented Reality).
- ARIMA – model statystyczny do analizy i prognozowania szeregów czasowych (ang. Autoregressive Integrated Moving Average).
- AUC – pole pod krzywą ROC; miara skuteczności klasyfikatora (ang. Area Under the Curve).
- AVEVA – globalny dostawca oprogramowania inżynierskiego i przemysłowego.
- BERT – dwukierunkowe reprezentacje z transformera (ang. Bidirectional Encoder Representations from Transformers).
- BI – analityka biznesowa; procesy i narzędzia przekształcające dane w informacje wspierające decyzje (ang. Business Intelligence).
- Big Data – duże, zmienne i różnorodne zbiory danych oraz techniki ich przetwarzania.
- Blockchain – rozproszony, niezmienny rejestr danych przechowywanych w kryptograficznie powiązanych blokach.
- BP – wsteczna propagacja błędów w sieciach neuronowych (ang. Backpropagation).
- CCP – krytyczny punkt kontroli w systemie HACCP (ang. Critical Control Point).
- CCR – wskaźnik reklamacji klientów (ang. Customer Complaint Rate).
- Cloud computing – usługi chmurowe zapewniające dostęp do zasobów obliczeniowych przez Internet.
- CMMS – zintegrowane oprogramowanie do zarządzania utrzymaniem ruchu (ang. Computerized Maintenance Management System).
- CNC – komputerowe sterowanie numeryczne obrabiarek (ang. Computer Numerical Control).
- CNN – konwolucyjna sieć neuronowa (ang. Convolutional Neural Network).
- COPQ – koszty złej jakości (ang. Costs of Poor Quality).
- CRM – zarządzanie relacjami z klientami (ang. Customer Relationship Management).
- CSF – kluczowe czynniki sukcesu (ang. Critical Success Factors).
- Data Matrix – dwuwymiarowy matrycowy kod kreskowy (ang. Data Matrix Code).
- DBSCAN – algorytm klasteryzacji oparty na gęstości (ang. Density-Based Spatial Clustering of Applications with Noise).
- DCS – rozproszony system sterowania (ang. Distributed Control System).
- Digital Twin – cyfrowy bliźniak; wirtualna reprezentacja obiektu lub systemu zsynchronizowana z jednostką fizyczną.
- DL – uczenie głębokie (ang. Deep Learning).
- DPMO – liczba defektów na milion szans (ang. Defects Per Million Opportunities).
- DQN – głęboka sieć Q ucząca się ze wzmocnieniem (ang. Deep Q-Network).
- Edge computing – model obliczeniowy polegający na przetwarzaniu danych blisko ich źródła (na krawędzi sieci).
- ERP – system zarządzania zasobami przedsiębiorstwa (ang. Enterprise Resource Planning).
- FFS – formowanie, napełnianie i zgrzewanie opakowań (ang. Form-Fill-Seal).
- FPY – wydajność pierwszego przejścia (ang. First Pass Yield).
- GAN – generatywna sieć przeciwstawna (ang. Generative Adversarial Network).
- GMP – dobra praktyka produkcyjna (ang. Good Manufacturing Practice).
- GRU – jednostka bramkowana w sieciach rekurencyjnych (ang. Gated Recurrent Unit).

- HACCP – system analizy zagrożeń i krytycznych punktów kontroli (ang. Hazard Analysis and Critical Control Points).
- HFFS – poziome formowanie, napełnianie i zamykanie (ang. Horizontal Form-Fill-Seal).
- HMI – interfejs człowiek-maszyna (ang. Human-Machine Interface).
- IEC 62264 – międzynarodowy standard modeli i terminologii integracji systemów przedsiębiorstwa.
- IIoT – przemysłowy Internet Rzeczy (ang. Industrial Internet of Things).
- IoT – Internet Rzeczy; sieć połączonych urządzeń wyposażonych w czujniki i oprogramowanie (ang. Internet of Things).
- IP67 – stopień ochrony przed wnikaniem pyłu (6) i wody (7).
- ISA-95 – międzynarodowy standard integracji systemów produkcyjnych i biznesowych.
- ISO 22000 – norma zarządzania bezpieczeństwem żywności.
- ISO/IEC 16022 – norma określająca wymagania dla symboliki Data Matrix.
- IT – technologia informacyjna (ang. Information Technology).
- Kanban – metoda zarządzania przepływem prac i produkcji.
- K-means – algorytm klasteryzacji nienadzorowanej (k-średnich).
- KPI – kluczowy wskaźnik efektywności (ang. Key Performance Indicator).
- LabVIEW – graficzne środowisko programistyczne firmy National Instruments.
- LCA – analiza cyklu życia (ang. Life Cycle Assessment).
- Lean – koncepcja zarządzania ukierunkowana na eliminację marnotrawstwa.
- LIMS – system zarządzania informacjami laboratoryjnymi (ang. Laboratory Information Management System).
- LSTM – architektura rekurencyjnych sieci neuronowych do modelowania sekwencji (ang. Long Short-Term Memory).
- MAP – pakowanie w modyfikowanej atmosferze (ang. Modified Atmosphere Packaging).
- MATLAB – platforma i język programowania dla inżynierów i naukowców.
- MES – system realizacji i monitorowania produkcji (ang. Manufacturing Execution System).
- ML – uczenie maszynowe (ang. Machine Learning).
- MOM – zarządzanie operacjami produkcyjnymi (ang. Manufacturing Operations Management).
- MQTT – lekki protokół przesyłania komunikatów (ang. Message Queuing Telemetry Transport).
- MŚP – małe i średnie przedsiębiorstwa.
- MTBF – średni czas między awariami (ang. Mean Time Between Failures).
- MTTF – średni czas do uszkodzenia (ang. Mean Time To Failure).
- MTTR – średni czas naprawy (ang. Mean Time To Repair).
- MySQL – system zarządzania relacyjnymi bazami danych.
- NLP – przetwarzanie języka naturalnego (ang. Natural Language Processing).
- NN – sieć neuronowa (ang. Neural Network).
- OCR – optyczne rozpoznawanie znaków (ang. Optical Character Recognition).
- OEE – całkowita efektywność wyposażenia produkcyjnego (ang. Overall Equipment Effectiveness).
- OPC UA – standard komunikacji przemysłowej (ang. Open Platform Communications Unified Architecture).
- OT – technologia operacyjna; systemy i urządzenia przemysłowe sterujące procesami (np. PLC, HMI, SCADA) (ang. Operational Technology).
- OTD – terminowość realizacji dostaw (ang. On-Time Delivery).
- PCA – analiza głównych składowych (ang. Principal Component Analysis).
- PdM – predykcyjne utrzymanie ruchu (ang. Predictive Maintenance).
- PFS – system automatycznego pakowania (ang. Pick-Fill-Seal).
- PLC – programowalny sterownik logiczny (ang. Programmable Logic Controller).
- QR – dwuwymiarowy kod graficzny (ang. Quick Response Code).
- R – język programowania i środowisko do obliczeń statystycznych i wizualizacji.
- ResNet – rodzina głębokich sieci rezydualnych (ang. Residual Network).

- RFID – identyfikacja radiowa (ang. Radio-Frequency Identification).
- RL – uczenie ze wzmocnieniem (ang. Reinforcement Learning).
- RNN – rekurencyjna sieć neuronowa (ang. Recurrent Neural Network).
- ROC – krzywa charakterystyki klasyfikatora binarnego (ang. Receiver Operating Characteristic).
- RPA – robotyzacja procesów biznesowych (ang. Robotic Process Automation).
- RTU – zdalna jednostka telemetryczna (ang. Remote Terminal Unit).
- SAP – rodzina systemów ERP (niem. Systeme, Anwendungen und Produkte in der Datenverarbeitung).
- SCADA – system nadzoru i akwizycji danych (ang. Supervisory Control and Data Acquisition).
- SCARA – robot przegubowy o selektywnej podatności (ang. Selective Compliance Articulated Robot Arm).
- SCM – zarządzanie łańcuchem dostaw (ang. Supply Chain Management).
- Six Sigma – metoda doskonalenia jakości oparta na analizie danych.
- SKU – jednostka asortymentowa (ang. Stock Keeping Unit).
- SMED – szybka wymiana oprzyrządowania (ang. Single-Minute Exchange of Die).
- Stretch hood – system pakowania palet elastyczną folią kapturową rozciąganą na ładunek.
- SVM – maszyna wektorów nośnych (ang. Support Vector Machine).
- TEEP – całkowita efektywność wykorzystania wyposażenia (ang. Total Effective Equipment Performance).
- TPM – całkowite produktywne utrzymanie ruchu (ang. Total Productive Maintenance).
- Traceability – możliwość śledzenia pochodzenia i historii produktu.
- Traysealer – urządzenie do zgrzewania preformowanych tacek folią.
- UR – utrzymanie ruchu (ang. Maintenance).
- VFFS – pionowe formowanie, napełnianie i zamykanie (ang. Vertical Form-Fill-Seal).
- VR – wirtualna rzeczywistość (ang. Virtual Reality).
- VSM – mapowanie strumienia wartości (ang. Value Stream Mapping).
- WMS – system zarządzania magazynem (ang. Warehouse Management System).
- XAI – wyjaśnialna sztuczna inteligencja (ang. Explainable Artificial Intelligence).
- XGBoost – algorytm uczenia maszynowego do klasyfikacji i regresji (ang. Extreme Gradient Boosting).
- YOLO – sieć do detekcji obiektów w czasie rzeczywistym (ang. You Only Look Once).

STRESZCZENIE

Rozprawa doktorska dotyczy opracowania i wdrożenia inteligentnego systemu nadzorowania zautomatyzowanego procesu technologicznego konfekcjonowania wyrobów w przedsiębiorstwie Mróz S.A. W procesie konfekcjonowania zidentyfikowano trzy krytyczne operacje: naważanie, pakowanie oraz etykietowanie. To właśnie w tych obszarach najczęściej dochodziło do powstawania niezgodności jakościowych, strat surowcowych i reklamacji klientów, co wskazało na potrzebę opracowania rozwiązania integrującego narzędzia analityczne, systemy wizyjne i metody sztucznej inteligencji.

Celem pracy było zaprojektowanie oraz implementacja systemu nadzorowania, który umożliwia cyfrową akwizycję danych procesowych, analizę parametrów technologicznych oraz predykcyjne wspomaganie sterowania procesem. Rozwiązanie miało zapewnić wczesne wykrywanie odchyłeń, ograniczenie liczby badań niszczących, a także wsparcie decyzyjne operatorów w czasie rzeczywistym. Opracowana architektura obejmuje cztery warstwy (akwizycji, analityczną, decyzyjną i wizualizacyjną) oraz pięć modułów funkcjonalnych, dedykowanych poszczególnym obszarom procesu.

W ramach badań opracowano i zweryfikowano kilka kluczowych modeli predykcyjnych i diagnostycznych. Najważniejszym osiągnięciem był model predykcyjny oparty na regresji logistycznej służący do prognozowania ryzyka mikronieszczelności w procesie pakowania. Równolegle zbudowano i zwalidowano klasyfikator wizyjny oparty na konwolucyjnych sieciach neuronowych. Uzupełnieniem tych rozwiązań był model diagnostyczny analizujący zmienność temperatury elementów grzewczych maszyn pakujących, wspierający ocenę stabilności procesu. W module etykietowania zastosowano algorytmy OCR i analizy kodów, które umożliwiły pełną automatyzację kontroli treści etykiet i jakości nadruków. Dodatkowo prace obejmowały budowę i kategoryzację bazy danych obrazowych, przygotowanie zbiorów treningowych i walidacyjnych, zastosowanie metod augmentacji oraz przeprowadzenie walidacji systemu w warunkach przemysłowych.

Walidacja w rzeczywistym środowisku produkcyjnym wykazała znaczną poprawę stabilności i efektywności procesu. Zaobserwowano spadek odchyłeń w masie porcji, wzrost wydajności linii oraz poprawę wskaźników efektywności wykorzystania maszyn, a także redukcję reklamacji i strat surowcowych. Wyniki te jednoznacznie potwierdziły skuteczność opracowanego rozwiązania.

Rezultaty badań mają wymiar poznawczy i utylitarny. W aspekcie naukowym zidentyfikowano zależności pomiędzy parametrami technologicznymi a stabilnością procesu, a także potwierdzono możliwość zastosowania metod sztucznej inteligencji w środowisku przemysłowym. W wymiarze aplikacyjnym rozprawa stanowi przykład skutecznego wdrożenia architektury warstwowej i modułowej zgodnie z koncepcją Przemysłu 4.0, wskazując jednocześnie na jej potencjał adaptacji do innych linii technologicznych i branż przemysłowych.

ABSTRACT

This doctoral dissertation concerns the development and implementation of an intelligent monitoring system for the automated technological process of product packaging at Mróz S.A. Within the packaging process, three critical operations were identified: weighing, sealing, and labelling. These stages were most frequently associated with quality nonconformities, raw material losses, and customer complaints, which highlighted the need for a solution integrating analytical tools, vision systems, and artificial intelligence methods.

The objective of the dissertation was to design and implement a monitoring system enabling digital acquisition of process data, analysis of technological parameters, and predictive support for process control. The solution was intended to ensure early detection of deviations, reduce the number of destructive tests, and provide real-time decision support for operators. The proposed architecture comprises four layers (acquisition, analytical, decision-making, and visualization) and five functional modules dedicated to specific process areas.

As part of the research, a series of predictive and diagnostic models were developed and validated. The most significant achievements include a logistic regression model for predicting micro-leakages, a diagnostic model analysing temperature variability of the heating elements of sealing machines, and convolutional neural networks (CNN) for classifying packaging defects. In the labelling module, OCR algorithms and code analysis were applied, enabling full automation of label content and print quality inspection. Furthermore, the research encompassed the construction and categorization of an image database, preparation of training and validation datasets, the application of data augmentation techniques, and the industrial validation of the system.

Validation in a real production environment demonstrated a significant improvement in process stability and efficiency. Reductions in portion weight deviations were observed, along with increased line throughput, enhanced equipment effectiveness indicators, and a decline in customer complaints and raw material losses. These outcomes clearly confirmed the effectiveness of the proposed solution.

The results of the dissertation have both cognitive and utilitarian dimensions. From a scientific perspective, dependencies between technological parameters and process stability were identified and quantified, and the applicability of artificial intelligence methods in industrial environments was confirmed. From a practical perspective, the dissertation provides an example of a successful implementation of a layered and modular system architecture in line with the Industry 4.0 concept, while also demonstrating the potential for adaptation to other production lines and industrial sectors.

1. Wprowadzenie

1.1. Geneza tematu pracy

Dynamiczny rozwój technologii produkcyjnych w ostatnich dekadach, związany z wdrażaniem koncepcji Przemysłu 4.0, doprowadził do istotnych przemian w sposobie organizacji i nadzorowania procesów technologicznych. Szczególnego znaczenia nabiera tu proces konfekcjonowania, rozumiany jako dozowanie, pakowanie, kompletowanie, etykietowanie i przygotowanie wyrobów do dystrybucji, który stanowi jeden z kluczowych etapów w łańcuchu wartości przedsiębiorstwa produkcyjnego. Jest obszarem, w którym spotykają się wymagania dotyczące jakości, elastyczności i terminowości, w którym wyroby uzyskują swoją ostateczną formę użytkową, handlową i estetyczną. Proces ten, mimo rosnącej automatyzacji, charakteryzuje się wysoką wrażliwością na zakłócenia, wynikającą m.in. z dużej zmienności zleceń, krótkich serii produkcyjnych oraz częstych przebrojeń (Coles i in., 2003; Yan i in., 2022). Dodatkowym wyzwaniem jest konieczność elastycznego dostosowywania się do indywidualnych wymagań odbiorców, które obejmują zróżnicowane formaty opakowań, specyficzne oznakowanie czy niestandardowe zestawienia produktów. Czynniki te sprawiają, że proces konfekcjonowania staje się szczególnie podatny na błędy, opóźnienia oraz straty materiałowe, co wprost przekłada się na koszty operacyjne i poziom satysfakcji klienta.

W praktyce przemysłowej, zwłaszcza w sektorze małych i średnich przedsiębiorstw, dostrzegalna jest potrzeba wdrożenia rozwiązań pozwalających na inteligentne, zintegrowane nadzorowanie linii konfekcjonowania, które obejmowałoby zarówno monitorowanie stanu maszyn i urządzeń, jak i ocenę jakości wytwarzanych wyrobów w czasie rzeczywistym. Z jednej strony klasyczne systemy automatyki i kontroli jakości okazują się niewystarczające w warunkach wysokiej zmienności i rosnącej złożoności procesów. Z drugiej natomiast, brak narzędzi zapewniających bieżące monitorowanie kluczowych wskaźników takich jak wydajność linii, dostępność maszyn czy wskaźniki jakościowe prowadzi do sytuacji, w których przedsiębiorstwa reagują na problemy dopiero po ich wystąpieniu, zamiast je przewidywać i eliminować (Fantozzi i in., 2023; Popescu i in., 2022). W tym kontekście niezbędne staje się wykorzystanie narzędzi sztucznej inteligencji, metod uczenia maszynowego oraz integracja systemów pomiarowych z rozwiązaniami cyfrowymi, umożliwiającymi predykcyjne podejmowanie decyzji i automatyczne reagowanie na odchylenia od stanu pożądanego. Dzięki temu przedsiębiorstwa mogą przejść od nadzorowania reaktywnego, opartego na interwencji w sytuacjach kryzysowych, do nadzorowania proaktywnego i predykcyjnego, którego celem jest minimalizacja zakłóceń oraz maksymalizacja efektywności procesów (Ayvaz i in., 2021).

Z perspektywy przedsiębiorstwa Mróz S.A. będącego przedmiotem badań, konfekcjonowanie pełni funkcję strategiczną. Jest obszarem, który umożliwia realizację zasad personalizacji produkcji i elastycznego dostosowania do wymagań klientów. Stanowi zatem, ze względu na ofertę produktową przedsiębiorstwa istotne narzędzie budowania przewagi konkurencyjnej. Analiza funkcjonowania przedsiębiorstwa wykazała, że pomimo zastosowania zaawansowanych linii pakujących, utrzymanie

stabilności procesu wciąż napotyka istotne trudności. Problemy ujawniały się m.in. w postaci odchyień masy porcji (niedowagi lub nadwagi), błędów etykietowania (np. brak lub uszkodzenie etykiety, nieprawidłowe dane) czy nieszczelności opakowań jednostkowych. Każdy z tych problemów rodzi konkretne zagrożenia dla efektywności i jakości procesu. Nawet nieznaczne odchylenia w naważaniu skutkują stratami surowcowymi i podwyższeniem kosztów produkcji, błędy etykietowania prowadzą do reklamacji i obniżenia wiarygodności przedsiębiorstwa w oczach klientów, natomiast awarie urządzeń konfekcjonujących powodują spadek wskaźników efektywności, przestoje produkcyjne i wzrost kosztów eksploatacyjnych. Przedstawione powyżej wyzwania wskazują na potrzebę opracowania **inteligentnego systemu nadzorowania zautomatyzowanego procesu technologicznego konfekcjonowania w przedsiębiorstwie**, który umożliwiłby integrację danych z różnych etapów procesu, zastosowanie metod sztucznej inteligencji oraz ich implementację w przedsiębiorstwie. Takie rozwiązanie pozwoli nie tylko podnieść stabilność i powtarzalność produkcji, ale również ograniczyć straty materiałowe, zredukować liczbę reklamacji i zwiększyć konkurencyjność przedsiębiorstwa w warunkach dynamicznie zmieniającego się rynku.

Temat pracy pt. „*Inteligentny system nadzorowania zautomatyzowanego procesu technologicznego konfekcjonowania wyrobów*” powstał więc jako odpowiedź na wyzwania przedsiębiorstwa Mróz S.A. oraz zapotrzebowanie na nowatorskie rozwiązania łączące perspektywę inżynierii mechanicznej z narzędziami sztucznej inteligencji i cyfrowymi technologiami nadzorowania procesów. Celem badań było opracowanie koncepcji oraz implementacja systemu, który nie tylko poprawia efektywność i stabilność procesu konfekcjonowania, lecz także zapewnia zgodność z wymogami jakościowymi oraz odporność na zakłócenia w zmiennym otoczeniu rynkowym.

1.2. Problem badawczy

Analiza stanu wiedzy i obserwacje praktyki przemysłowej prowadzą do wniosku, że proces konfekcjonowania, mimo swojego kluczowego znaczenia, pozostaje stosunkowo skromnie opisany w literaturze naukowej. Większość dostępnych publikacji naukowych dotyczących konfekcjonowania koncentruje się na wybranych operacjach, takich jak pakowanie czy etykietowanie, traktując je w sposób izolowany, bez uwzględnienia całego procesu jako spójnego i złożonego systemu technologicznego. Takie fragmentaryczne podejście ogranicza możliwości opracowania rozwiązań integrujących poszczególne podsystemy i tym samym utrudnia kompleksowe nadzorowanie procesu. Ponadto przegląd literatury wskazuje na wyraźną dominację badań o charakterze teoretycznym i symulacyjnym nad badaniami prowadzonymi w rzeczywistych warunkach przemysłowych, co dodatkowo potwierdza istnienie luki badawczej w tym obszarze. Wiele z zaproponowanych rozwiązań, choć interesujących, nie zostało poddanych praktycznej weryfikacji w zakładach produkcyjnych. Ogranicza to możliwość oceny ich faktycznej skuteczności, niezawodności i przydatności dla operatorów czy kadry technicznej.

Jak zauważają Weichert i in. (2019) przejście od modelu laboratoryjnego do wdrożenia przemysłowego stanowi wciąż istotne wyzwanie, a właśnie ten etap przesądza o realnej wartości

proponowanych w literaturze rozwiązań. Kolejnym aspektem, na który należy zwrócić uwagę jest brak podejścia integracyjnego, które łączyłoby akwizycję danych z różnych źródeł np. wag, czujników procesowych, systemów wizyjnych z analizą predykcyjną i bieżącym wspomaganie decyzji operatorów. Dostępne są liczne technologie cząstkowe, które osiągają wysoką skuteczność w swoich obszarach (np. algorytmy głębokiego uczenia w analizie obrazu), ale ich działanie pozostaje izolowane od innych modułów procesu. Brakuje systemu, który spinałby te elementy w jeden strumień informacyjny i udostępniał wnioski w czasie rzeczywistym na potrzeby stabilizacji procesu i szybkiego reagowania na odchylenia (Sundaram i in., 2023).

Biorąc pod uwagę powyższe, problem badawczy niniejszej rozprawy, można zdefiniować następująco: **jak zaprojektować i wdrożyć inteligentny system nadzorowania procesu konfekcjonowania, który integruje różne źródła danych, wykorzystuje metody analityczne i sztucznej inteligencji oraz wspiera operatorów w podejmowaniu decyzji w czasie rzeczywistym?**

Dla tak sformułowanego problemu badawczego zdefiniowano trzy pytania badawcze:

1. Jakie czynniki determinują efektywność i stabilność procesu konfekcjonowania oraz charakterystyki jakościowe wyrobów?
2. Jakie dane procesowe są kluczowe dla skutecznego identyfikowania niezgodności w zautomatyzowanym procesie konfekcjonowania?
3. Jakie narzędzia i metody będą w sposób skuteczny wspierać nadzorowanie parametrów procesu konfekcjonowania?

Odpowiedź na powyższe pytania umożliwi uzupełnienie zidentyfikowanych ograniczeń dotychczas proponowanych rozwiązań oraz opracowanie koncepcji, która łączy wymiar naukowy, tj. identyfikację zależności między parametrami procesu a jego stabilnością, z wymiarem aplikacyjnym, obejmującym wdrożenie i ocenę systemu nadzorowania procesu konfekcjonowania w warunkach rzeczywistych konkretnego przedsiębiorstwa.

1.3. Cel pracy

Tradycyjne systemy nadzorowania mają ograniczone możliwości w zakresie predykcyjnego wykrywania nieprawidłowości oraz dostosowywania parametrów operacyjnych do dynamicznie zmieniających się warunków. W kontekście transformacji cyfrowej szczególnego znaczenia nabiera wykorzystanie zaawansowanej analityki danych, sztucznej inteligencji oraz systemów wspierających decyzje w celu zapewnienia stabilności, jakości i efektywności procesów.

Celem pracy doktorskiej jest opracowanie koncepcji oraz weryfikacja w warunkach przemysłowych inteligentnego systemu nadzorowania zautomatyzowanego procesu konfekcjonowania wyrobów, który wykorzystuje metody zaawansowanej analityki danych i sztucznej inteligencji do:

- wczesnego wykrywania nieprawidłowości w przebiegu procesu,
- bieżącej oceny krytycznych charakterystyk jakościowych wyrobu,
- wspierania procesu decyzyjnego operatorów i personelu technicznego.

W pracy przewidziano przeprowadzenie badań niezbędnych do budowy potrzebnych modeli decyzyjnych. Realizacja prac badawczo-wdrożeniowych ma charakter aplikacyjny. Realizowane będą z wykorzystaniem rzeczywistych danych oraz infrastruktury przemysłowej badanego przedsiębiorstwa, z uwzględnieniem występujących w nim ograniczeń technicznych i organizacyjnych. Dla osiągnięcia wskazanego celu przyjęto następujące **cele szczegółowe**:

1. Identyfikacja krytycznych operacji i parametrów procesu konfekcjonowania, które wymagają nadzorowania.
2. Określenie i ustandaryzowanie zbioru parametrów technologicznych o decydującym wpływie na stabilność procesu oraz jakość wyrobów (wartości nominalne, tolerancje, progi alarmowe oraz ich odpowiedzialność za odchylenia).
3. Zaprojektowanie i uruchomienie cyfrowej akwizycji danych z urządzeń i czujników linii, zapewniającej ciągłość zapisu, jednoznaczną identyfikację partii i synchronizację czasową.
4. Dobór i weryfikacja metod nadzorowania (w tym modeli predykcyjnych i klasyfikacyjnych), umożliwiających detekcję odchylenia w czasie rzeczywistym oraz ocenę ryzyka powstania niezgodności.
5. Integracja modułów w spójny system nadzorowania (wizualizacja, alarmowanie, raportowanie), wraz z definicją ścieżki decyzyjnej dla operatorów i służb technicznych.
6. Walidacja systemu w środowisku produkcyjnym na podstawie uzgodnionych mierników (m.in. wskaźniki jakości i efektywności procesu).

Cele te, poprzez zaprojektowanie i integrację rozwiązań, tworzą układ prowadzący od identyfikacji kluczowych uwarunkowań procesu konfekcjonowania, poprzez wskazanie sposobu jego (procesu) poprawy, aż do ich weryfikacji w warunkach rzeczywistej produkcji.

1.4. Struktura pracy

W **rozdziale pierwszym** przedstawiono tło problematyki badawczej, wskazując na rosnącą złożoność systemów produkcyjnych oraz szczególną rolę procesu konfekcjonowania jako etapu kluczowego dla zapewnienia jakości i efektywności wytwarzania. Zaprezentowano genezę tematu, problem i pytania badawcze oraz sformułowano cel główny wraz z celami szczegółowymi. Rozdział kończy się opisem struktury rozprawy.

Rozdział drugi obejmuje przegląd stanu wiedzy dotyczący inteligentnego nadzorowania procesów produkcyjnych, ze szczególnym uwzględnieniem procesu konfekcjonowania. Omówiono ewolucję podejść do nadzoru, kluczowe funkcje systemów oraz ekosystem technologiczny obejmujący integrację warstw architektury z systemami SCADA, MES i ERP, a także rozwiązania oparte na IoT, chmurze obliczeniowej i sztucznej inteligencji. Przedstawiono metody oceny skuteczności nadzorowania z wykorzystaniem wskaźników KPI oraz determinanty efektywności technicznej, organizacyjnej i informacyjnej. W drugiej części rozdziału scharakteryzowano proces konfekcjonowania, wskazując typowe problemy jakościowe i operacyjne oraz dostępne metody ich ograniczania. Synteza literatury

pozwoili na zdefiniowanie ograniczeŃ badawczych i potrzeb wdroŹeniowych w kontekŹcie koncepcji Przemysłu 4.0 i 5.0.

W **rozdziale trzecim** zaprezentowano koncepcjê inteligentnego systemu nadzorowania oraz załoŹenia projektowe zwiąŹane z jego implementacj¹. Opiszano Źrodowisko wdroŹeniowe, obejmuj¹ce charakterystykê zakładu produkcyjnego, infrastrukturê linii badawczej oraz bariery techniczne i organizacyjne. Zidentyfikowano problemy wystêpuj¹ce w operacjach nawaŹania, pakowania i etykietowania, a nastêpnie opracowano koncepcjê systemu w oparciu o strukturê warstwow¹ i modułow¹. Przedstawiono g³ówne wymagania projektowe oraz opiszano załoŹenia piêciu modu³ów funkcjonalnych, które razem tworz¹ spójn¹ koncepcjê systemu nadzorowania.

Rozdzia³ czwarty dotyczy budowy systemu i przejŹcia od koncepcji do realizacji. Szczegółowo opiszano piêć modu³ów funkcjonalnych: nadzorowanie masy porcji, detekcjê nieszczelnoŹci metodami wizyjnymi („nieszczelnoŹci I”), predykcyjn¹ ocenê ryzyka wystêpowania mikronieszczelnoŹci („nieszczelnoŹci II”), kontrolê etykiet i ich treŹci oraz automatyczny odrzut wyrobów niezgodnych. KaŹdy z modu³ów zosta³ osadzony w czterowarstwowej architekturze systemu, a w opisie ujęto technologie, algorytmy i modele, w tym regresjê logistyczn¹ i konwolucyjne sieci neuronowe. W rozdziale omówiono równieŹ aspekty cyberbezpieczeŹstwa i ochrony danych.

Kolejny, **rozdzia³ pi¹ty** przedstawia walidacjê systemu w warunkach przemys³owych. Oceniono skutecznoŹć poszczególnych modu³ów i systemu jako ca³oŹci na podstawie danych z lat 2021–2025. Analiza wykaza³a poprawê wskaŹników jakoŹci i efektywnoŹci, redukcjê przewaŹeŃ surowca oraz skutecznoŹć predykcji i klasyfikacji wad.

W **rozdziale szóstym** zaprezentowano podsumowanie wyników oraz wnioski koŹcowe. Przedstawiono wnioski poznawcze, odnosz¹ce siê do identyfikacji zaleŹnoŹci miêdzy parametrami procesu a jego stabilnoŹci¹ oraz wnioski uŹytkarne, zwi¹zane z opracowaniem i wdroŹeniem systemu spe³niaj¹cego cele praktyczne. Omówiono ograniczenia badaŹ oraz wskazano kierunki dalszych prac.

2. Przegląd stanu wiedzy – badania literaturowe

2.1. Nadzorowanie procesów produkcyjnych

2.1.1. Od manualnego nadzoru do Przemysłu 5.0

Rozwój systemów produkcyjnych jest nierozzerwalnie związany z postępowaniem technologicznym i zmieniającymi się wymaganiami rynku. Każda kolejna dekada przynosiła rozwiązania, które nie tylko usprawniały procesy wytwórcze, lecz także stopniowo zmieniały sposób ich nadzorowania, rozumiany jako złożony proces ukierunkowanego oddziaływania, obejmujący dostarczanie wskazówek, wyznaczanie kierunków działań oraz sprawowanie kontroli w celu realizacji założonych celów organizacyjnych i zarządczych (Mayasari i in., 2023). Skuteczność nadzorowania zależy od jakości monitorowania i diagnozowania. Monitorowanie dostarcza danych, które są analizowane podczas diagnozowania, a wyniki tej analizy są wykorzystywane do podejmowania decyzji w procesie nadzorowania.

W literaturze z zakresu inżynierii produkcji nadzór jest traktowany jako proces zarządzania przepływem informacji i podejmowania decyzji na podstawie bieżących danych o stanie maszyn, zasobów i jakości wytwarzanych wyrobów (Baines, 2006). W ujęciu koncepcji Przemysłu 4.0, nadzorowanie obejmuje również wykorzystanie technologii cyfrowych, analityki danych i sztucznej inteligencji do predykcyjnego sterowania procesami oraz zapobiegania zakłóceniom (Zhong i in., 2017). Proces nadzorowania charakteryzuje się koniecznością planowania, wdrażania, monitorowania i ewaluacji działań, co umożliwia nie tylko formułowanie skutecznych polityk i decyzji zarządczych, lecz także bieżącą ocenę przestrzegania przepisów oraz wprowadzanie korekt adekwatnych do zmieniających się uwarunkowań (Mayasari i in., 2023). Skuteczność nadzorowania zależy od jakości monitorowania i diagnozowania.

Biorąc pod uwagę powyższe, w pracy **nadzorowanie procesów produkcyjnych** rozumiane będzie jako zorganizowany system działań menedżerskich i technicznych, polegający na bieżącym monitorowaniu, analizowaniu i kontrolowaniu parametrów procesu wytwórczego, w celu utrzymania jego stabilności, jakości i efektywności, przy jednoczesnym spełnieniu wymagań dotyczących bezpieczeństwa, środowiska i kosztów. Natomiast **inteligentne nadzorowanie procesów produkcyjnych** to wykorzystanie zaawansowanych technologii cyfrowych, metod sztucznej inteligencji i analityki danych do monitorowania, prognozowania i optymalizowania przebiegu produkcji. **Inteligentny system nadzorowania** to zintegrowany układ metod, narzędzi i technologii cyfrowych, którego celem jest monitorowanie, analiza, diagnozowanie oraz prognozowanie przebiegu procesów produkcyjnych w czasie rzeczywistym. Jego kluczową cechą jest autonomiczność w reagowaniu na odchylenia, optymalizacja wykorzystania zasobów oraz doskonalenie procesów wytwórczych, przy jednoczesnym uwzględnianiu aspektów jakości, bezpieczeństwa, kosztów i zrównoważonego rozwoju.

Nowoczesne systemy nadzorowania wykorzystują automatyzację, aby ograniczyć ingerencję człowieka, zwiększając w ten sposób wydajność i zmniejszając prawdopodobieństwo wystąpienia błędów (Belmonte i in., 2006), wykorzystują zaawansowane technologie, takie jak Big Data, przetwarzanie w chmurze i IoT, aby udoskonalić możliwości gromadzenia, analizowania i raportowania danych (Xu i in., 2020). Integracja zaawansowanych technologii Przemysłu 4.0 z istniejącymi systemami produkcyjnymi, szczególnie w małych i średnich przedsiębiorstwach (MŚP), może być skomplikowana i kosztowna (Singh i in., 2024) ponieważ ich wdrożenie wymaga znacznych inwestycji w nowy sprzęt, infrastrukturę i szkolenia, co może stanowić barierę dla niektórych firm (Bazen i in., 2022). Inteligentny system nadzorowania linii produkcyjnej charakteryzuje się integracją zaawansowanych technologii (Cheng i in., 2021), możliwościami monitorowania i diagnozowania w czasie rzeczywistym (Fang i in., 2025), zdolnością adaptacji (Olalere i in., 2020), ulepszonymi procesami decyzyjnymi (Guo, 2023) oraz koncentracją na poprawie jakości i wydajności (Y. Xu i in., 2024).


2.1.2. Funkcje inteligentnego nadzorowania procesów

W literaturze podkreśla się, że skuteczność nowoczesnych systemów produkcyjnych zależy w dużej mierze od funkcji realizowanych przez systemy nadzorowania. To one decydują o możliwości utrzymania ciągłości procesów, zapewnienia ich bezpieczeństwa oraz utrzymania wysokiej jakości wyrobów. Funkcje te odzwierciedlają praktyczne wykorzystanie zaawansowanych komponentów technicznych i algorytmicznych w codziennej pracy zakładów przemysłowych.

Jedną z podstawowych funkcji inteligentnych systemów nadzorowania jest **monitorowanie danych w czasie rzeczywistym**. Dzięki integracji czujników środowiskowych i procesowych możliwe jest nieprzerwane śledzenie parametrów krytycznych, takich jak temperatura, wilgotność, ciśnienie czy stężenia substancji chemicznych, a także analiza warunków eksploatacyjnych maszyn i urządzeń (Chen i in., 2022; Xia i in., 2016). Ciągła rejestracja i wizualizacja danych pozwalają na szybkie wykrywanie odchyłeń od wartości referencyjnych i natychmiastową reakcję operatorów. Kolejną kluczową funkcją jest **diagnostyka anomalii**. Inteligentne systemy umożliwiają automatyczne identyfikowanie i diagnozowanie usterek w czasie rzeczywistym, co znacząco obniża ryzyko awarii i wypadków, a tym samym poprawia bezpieczeństwo eksploatacji (Lu i in., 2025). Zastosowanie algorytmów detekcji anomalii pozwala dodatkowo na identyfikację nietypowych stanów pracy i **wczesne ostrzeganie o potencjalnych awariach** (Mirzaraxmedova i in., 2019). Dzięki temu systemy te pełnią funkcję predykcyjną, wspierając utrzymanie ruchu w modelu prewencyjnym. Nieodłączną częścią inteligentnego nadzorowania jest **przetwarzanie i analiza danych**. Systemy gromadzą dane w scentralizowanych bazach, umożliwiają ich długoterminową archiwizację i analizę porównawczą, co pozwala na identyfikację trendów oraz powtarzających się problemów (Rymarczyk i in., 2021). Coraz częściej stosowane są tu metody sztucznej inteligencji oraz uczenia maszynowego, które umożliwiają tworzenie modeli predykcyjnych oraz automatyczną klasyfikację zdarzeń procesowych (Qu & Tao,

2013). Nowoczesne rozwiązania oferują również **zdalne monitorowanie i sterowanie procesami**. Dzięki wykorzystaniu sieci bezprzewodowych i platform chmurowych dane mogą być przesyłane i analizowane w dowolnym miejscu, a operatorzy uzyskują dostęp do kluczowych informacji z poziomu urządzeń mobilnych (Xia i in., 2016; Pang i in., 2018). Rozwiązania te wspierają integrację rozproszonych instalacji i skracają czas reakcji w przypadku awarii, jednocześnie zmniejszając koszty eksploatacyjne. Systemy inteligentnego nadzorowania realizują także funkcje związane ze **wspomaganiem procesu decyzyjnego**. Integracja metod analitycznych, takich jak logika rozmyta, algorytmy predykcyjne czy modele optymalizacyjne, umożliwia generowanie rekomendacji działań korygujących oraz planowanie przeglądów i konserwacji (Lee, 2007; Chang i in., 2023). Funkcje te pozwalają operatorom i menedżerom podejmować decyzje oparte na danych, a nie jedynie na intuicji czy doświadczeniu. Szczególnie istotną funkcją jest **alarmowanie i powiadamianie**. Inteligentne systemy wyposażone są w mechanizmy umożliwiające automatyczne alarmowanie o wykrytych anomaliach czy krytycznych odchyleniach parametrów od normy (Zhu i in., 2012; Chou i in., 2017). Funkcja ta znacząco podnosi poziom bezpieczeństwa, umożliwiając szybką reakcję personelu i ograniczenie strat wynikających z awarii. Ostatnim, ale niezwykle ważnym obszarem funkcjonalnym jest **integracja i interoperacyjność**. Inteligentne systemy nadzorowania bazują na architekturach wieloagentowych i hybrydowych modelach analitycznych, które umożliwiają współpracę różnych komponentów w sposób rozproszony i autonomiczny. Dzięki temu mogą one elastycznie reagować na zmienne warunki pracy i zwiększać skalowalność rozwiązania.


Rysunek 2.1 przedstawia zestawienie kluczowych funkcji realizowanych przez inteligentne systemy nadzorowania. Uwzględniono zarówno funkcje operacyjne, takie jak monitorowanie w czasie rzeczywistym, wykrywanie usterek, wczesne ostrzeganie, alarmowanie czy zdalne sterowanie, jak i funkcje wspierające proces decyzyjny, obejmujące analizę i interpretację danych, prognozowanie, klasyfikację zdarzeń, generowanie rekomendacji oraz planowanie działań konserwacyjnych. Zintegrowane działanie tych elementów pozwala systemowi nie tylko obserwować procesy, ale również je interpretować, przewidywać potencjalne zagrożenia oraz inicjować działania zapobiegawcze i korygujące.



Rysunek 2.1. Funkcje inteligentnych systemów nadzorowania (opracowanie własne na podstawie: Pang i in., 2018; Mirzaraxmedova i in., 2019; Chang i in., 2023).

2.1.3. Systemy i technologie wspomagające nadzorowanie procesów produkcyjnych

Systemy nadzorowania procesów produkcyjnych to rozwiązania organizacyjno-techniczne służące do bieżącego monitorowania, kontrolowania i analizowania przebiegu procesów wytwórczych. Ich zadaniem jest zapewnienie zgodności realizacji produkcji z przyjętymi wymaganiami jakościowymi, kosztowymi, terminowymi i środowiskowymi. Mogą one funkcjonować na różnych poziomach złożoności, od klasycznych systemów kontroli jakości i nadzoru operatorskiego, po zaawansowane rozwiązania oparte na systemach cyber-fizycznych i sztucznej inteligencji. Hierarchiczną strukturę systemów wg. ISA-95 przedstawiono na **Rysunku 2.2. ISA-95**, to międzynarodowy standard integracji systemów przedsiębiorstwa i sterowania (Enterprise-Control System Integration), który zapewnia ramy dla komunikacji i wymiany danych między różnymi poziomami automatyzacji produkcji. Standard definiuje hierarchię procesów produkcyjnych (tzw. piramidę ISA-95), ułatwiając przepływ informacji (Lang i in., 2020).



Rysunek 2.2. Piramida systemów nadzorowania procesów produkcyjnych według standardu ISA-95 (opracowanie własne na podstawie: Lang i in., 2020; van der Pas i in., 2025).

Podstawę piramidy stanowią urządzenia i procesy fizyczne realizowane w przedsiębiorstwie. Maszyny i linie produkcyjne generują sygnały będące fundamentem całego systemu nadzorowania. **Czujniki** (np. temperatury, ciśnienia, drgań, wilgotności) zbierają dane z procesów technologicznych. Bez wiarygodnych danych wejściowych nie jest możliwe skuteczne monitorowanie ani analiza procesów. Na kolejnym poziomie znajdują się **PLC (Programmable Logic Controllers)**, odpowiedzialne za automatyczne sterowanie maszynami i urządzeniami. Ich zadaniem jest realizacja algorytmów sterowania, zapewniających prawidłowy przebieg operacji technologicznych (Shrivastava i in., 2025). Ważnym elementem jest także zapewnienie niezawodnej komunikacji pomiędzy warstwami systemu np. poprzez preferowane obecnie ze względu na uniwersalność **OPC UA (Open Platform Communications Unified Architecture)** (Paul, 2024).

Wyżej usytuowane są systemy **SCADA/HMI (Supervisory Control and Data Acquisition / Human-Machine Interface)**. Systemy te stanowią jeden z kluczowych elementów architektury automatyki przemysłowej, umożliwiając nadzór, wizualizację i kontrolę złożonych procesów technologicznych w czasie rzeczywistym. Ich głównym zadaniem jest gromadzenie danych z urządzeń obiektowych (np. czujników, sterowników PLC), przetwarzanie tych danych oraz udostępnianie operatorowi interfejsów do monitorowania i ingerencji w proces (Popescu i in., 2022; Grbac i in., 2022). Typowa architektura SCADA składa się z czterech podstawowych komponentów: jednostek zdalnych (RTU - Remote Terminal Unit), sterowników PLC, infrastruktury komunikacyjnej oraz systemu nadzorczego z interfejsem HMI. SCADA umożliwia centralne zarządzanie dużą liczbą rozproszonych obiektów technologicznych, przy zachowaniu ciągłości i bezpieczeństwa procesu (Thoben i in., 2017; Sverko i in., 2022). Jedną z głównych zalet tych systemów jest możliwość długoterminowej archiwizacji danych procesowych, co pozwala na tworzenie raportów, analizę trendów oraz wspomaganie działań

predykcyjnych w zakresie utrzymania ruchu (Lidong i in., 2016; Trzmiel i in., 2018). Wysoka skalowalność SCADA sprawia, że systemy te znajdują zastosowanie zarówno w małych instalacjach, jak i w rozległych sieciach przemysłowych, np. w energetyce, przemyśle chemicznym, wodno-kanalizacyjnym, hutnictwie czy motoryzacji (Popescu i in., 2022; Sverko, Grbac i in., 2022).

Kolejną warstwę tworzą systemy **MES (Manufacturing Execution Systems)** które odgrywają kluczową rolę w operacyjnym zarządzaniu produkcją, umożliwiając bezpośrednie sterowanie, monitorowanie i raportowanie działań realizowanych na poziomie hali produkcyjnej. W przedsiębiorstwach bywa, że SCADA i MES działają **równolegle**, a dane są wymieniane przez interfejsy OPC UA, MQTT czy AP. Ich podstawowym zadaniem jest zapewnienie płynnego przepływu informacji między warstwą zarządzania przedsiębiorstwem (systemy ERP), a warstwą wykonawczą (sterowniki PLC, SCADA) (Chohan i in., 2022; Mantravadi i in., 2023). MES integruje dane pochodzące z maszyn, operatorów i systemów automatyki, umożliwiając kompleksową kontrolę nad przebiegiem zleceń produkcyjnych w czasie rzeczywistym. Dzięki temu możliwe jest bieżące śledzenie postępu prac, analiza wskaźników wydajności (np. OEE), kontrola jakości oraz zarządzanie zasobami i harmonogramami (Mantravadi i in., 2023). Systemy tego typu wspierają podejmowanie decyzji na poziomie operacyjnym, eliminując opóźnienia wynikające z ręcznego przetwarzania danych oraz minimalizując ryzyko błędów wynikających z niewłaściwego raportowania lub braku aktualnych informacji (Chohan i in., 2022). Współczesne rozwiązania MES są również zgodne z koncepcją Przemysłu 4.0, coraz częściej wykorzystują technologie takie jak IIoT, czy metody sztucznej inteligencji, co umożliwia dynamiczne dostosowanie planów produkcyjnych, predykcyjną analizę zakłóceń oraz optymalizację procesów w oparciu o rzeczywiste dane (Qi i in., 2019). Ponadto MES zapewnia zgodność procesów z normami jakościowymi, regulacjami branżowymi oraz wymogami dotyczącymi identyfikowalności (traceability), co czyni go nieodzownym elementem cyfrowego ekosystemu produkcyjnego (Mantravadi i in., 2023; Cate i in., 2025).

Na szczycie piramidy znajduje się warstwa **ERP (Enterprise Resource Planning)** która pełni kluczową rolę w zarządzaniu zasobami przedsiębiorstwa, umożliwiając kompleksową integrację obszarów produkcji, logistyki, finansów, magazynowania, zaopatrzenia czy kadr. W kontekście przemysłowym, ERP stanowi nadrzędny poziom systemów informatycznych, który komunikuje się z niższymi warstwami (np. MES, SCADA), konsolidując dane operacyjne i strategiczne w jednym środowisku (Pop, 2020; Sai Avvaru i in., 2020). Zasadniczym celem ERP jest centralizacja i automatyzacja przepływu informacji pomiędzy poszczególnymi działami przedsiębiorstwa. Poprzez bieżący dostęp do ustandaryzowanych i aktualnych danych, systemy te wspierają procesy decyzyjne, umożliwiają planowanie produkcji, kontrolę stanów magazynowych, zarządzanie zamówieniami oraz nadzór nad budżetami (Gunia, 2019; Sai Avvaru i in., 2020). Ich wdrożenie znacząco poprawia transparentność działań operacyjnych i strategicznych, minimalizuje redundancję danych i redukuje ryzyko błędów wynikających z ręcznej obsługi (Sai Avvaru i in., 2020).

W celu usystematyzowania ról poszczególnych systemów w **Tabeli 2.1** zestawiono charakterystyczne cechy SCADA, MES i ERP. Zestawienie obejmuje m.in. poziom działania, zakres funkcji, źródła danych, czas reakcji, typowych użytkowników oraz przykładowe technologie.

Tabela 2.1. Porównanie systemów SCADA, MES i ERP.

Kryterium	SCADA	MES	ERP
Poziom działania	Operacyjny	Operacyjno-taktyczny (hala, wydział)	Strategiczny (przedsiębiorstwo)
Główne funkcje	Monitoring, wizualizacja, alarmowanie, akwizycja danych, sterowanie nadrzędne	Kontrola realizacji zleceń, śledzenie partii i genealogii, kontrola jakości, raportowanie efektywności (np. OEE)	Planowanie zasobów i produkcji, finanse, zakupy, sprzedaż, magazyny, łańcuch dostaw
Źródła danych	Czujniki, PLC, RTU, DCS	SCADA, maszyny, HMI, wpisy operatorów	MES, bazy transakcyjne, dokumenty biznesowe
Czas reakcji	Rzeczywisty (sekundy)	Krótki (godziny–dni)	Średni i długi (dni–miesiące)
Zasięg	Maszyna, gniazdo, linia	Hala lub zakład	Całe przedsiębiorstwo (także grupa)
Użytkownicy	Operatorzy, technicy utrzymania ruchu	Kierownicy zmian, inżynierowie procesu i jakości, planiści operacyjni	Kadra kierownicza, controlling, logistyka, finanse
Integracja z innymi systemami	PLC, HMI, DCS, IIoT, OPC UA	SCADA, ERP, CMMS, LIMS, WMS	MES, CRM, BI, SCM, systemy finansowo-księgowe
Przykładowe technologie	AVEVA System Platform, Siemens WinCC, Ignition	Siemens Opcenter, Dassault Apriso, GE Proficy	SAP S/4HANA, Oracle NetSuite, Microsoft Dynamics 365

Opracowanie własne na podstawie: Awotidebe, 2025; Esther, 2024; Milewska, 2020; Wei i in., 2020.

Współczesne systemy nadzorowania procesów przemysłowych wykorzystują szereg nowoczesnych technologii, które wspierają ich skuteczność, elastyczność i bezpieczeństwo. Jednym z podstawowych rozwiązań jest Internet Rzeczy (IoT). Dzięki niemu możliwe jest monitorowanie parametrów pracy maszyn a następnie szybkie wykrywanie odchyłeń od normy. W praktyce pozwala to zapobiegać awariom i minimalizować przestoje w produkcji (Popa i in., 2019; Ayvaz i in., 2021). Kolejnym filarem jest Big Data wraz z analityką danych, które umożliwiają przetwarzanie bardzo dużych zbiorów informacji pochodzących z maszyn i linii produkcyjnych. Zaawansowane platformy analityczne potrafią wykrywać ukryte zależności i wzorce, na przykład między ustawieniami procesów a jakością wyrobów, co daje podstawę do optymalizacji zarówno produkcji, jak i działań serwisowych (Lidong i in., 2016; Kumar i in., 2024). Coraz większe znaczenie w przemyśle ma także koncepcja cyfrowego bliźniaka, czyli wirtualnej kopii rzeczywistych maszyn i procesów. Pozwala ona na ich symulację w warunkach cyfrowych, testowanie różnych scenariuszy oraz optymalizację pracy urządzeń bez ryzyka dla faktycznego ciągu technologicznego. Dzięki temu przedsiębiorstwa mogą szybciej reagować na zmiany i wprowadzać usprawnienia, ograniczając jednocześnie koszty (Kukushkin i in., 2022; Wang i in., 2024).

Niezbędnym elementem nowoczesnych systemów jest chmura obliczeniowa, która zapewnia skalowalne i bezpieczne środowisko do przechowywania oraz analizy danych. Z jej pomocą można w elastyczny sposób zwiększać moc obliczeniową w zależności od potrzeb, a dostęp do informacji i narzędzi analitycznych możliwy jest z dowolnej lokalizacji. To szczególnie istotne w przypadku rozproszonych zakładów produkcyjnych, które generują ogromne ilości danych wymagających centralnego nadzoru (Colombo, 2014; Komeil, 2021).

Należy podkreślić również rolę sztucznej inteligencji, która staje się narzędziem umożliwiającym nie tylko automatyzację i analizę danych, ale także predykcyjne podejmowanie decyzji oraz optymalizację procesów. Analizując dane historyczne i bieżące, algorytmy są w stanie rozpoznawać wzorce poprzedzające awarie, prognozować zużycie elementów oraz podejmować decyzje wspierające optymalizację procesów. Zastosowanie metod AI pozwala więc przejść od podejścia reaktywnego do proaktywnego w nadzorowaniu procesów, co znacząco poprawia niezawodność i efektywność całego systemu produkcyjnego (Hector i in., 2024; Ucar, Karakose i in., 2024). Szczególne znaczenie dla rozwoju inteligentnych systemów nadzorowania ma implementacja metod uczenia maszynowego i głębokiego uczenia w obszarze kontroli jakości. Badania Ramesha i in. (2025) pokazują, że zastosowanie modelu YOLOv5 w połączeniu z przetwarzaniem obrazu oraz modułami sterowania sprzętowego umożliwia niemal całkowitą automatyzację procesu inspekcji. Uzyskane przez autorów wyniki wskazują, że zastosowane rozwiązanie znacząco przewyższa skuteczność tradycyjnych metod wizualnych i podkreśla, że funkcją systemów nadzorczych staje się nie tylko rejestrowanie parametrów i generowanie alarmów, lecz także autonomiczne wykrywanie wad, predykcja zagrożeń oraz podejmowanie działań korygujących w czasie rzeczywistym. Jest to krok w stronę koncepcji pełnej automatyzacji jakości oraz adaptacyjnego sterowania w ramach inteligentnej fabryki (Ramesh i in., 2025).

Uczenie maszynowe wspiera również przetwarzanie danych w czasie rzeczywistym i detekcję anomalii. Rozwiązania te stosowane są zarówno w środowiskach przemysłowych, jak i w systemach opartych na Internecie Rzeczy. Integracja algorytmów z sieciami czujników IoT umożliwia stały nadzór nad parametrami środowiskowymi oraz stanem urządzeń, a także wczesne rozpoznawanie odchyłeń od normy i uruchamianie działań predykcyjnych ograniczających ryzyko awarii (Rane i in., 2024). W obszarze bezpieczeństwa algorytmy ML analizują np. obraz z kamer w trybie ciągłym, automatycznie rozróżniając aktywności normalne i nietypowe oraz sygnalizując zagrożenia w czasie rzeczywistym. Kolejną ważną rolę sztucznej inteligencji w systemach nadzorowania jest predykcja i wspomaganie procesu decyzyjnego. Modele uczone na danych historycznych i bieżących pozwalają prognozować stany krytyczne, a następnie dobierać optymalne strategie sterowania. W obszarze zarządzania energią umożliwiają one analizę profili zużycia i wdrażanie mechanizmów redukcji kosztów poprzez lepsze planowanie oraz optymalizację obciążeń (Rezaei i in., 2025). W medycynie systemy oparte na AI monitorują parametry zdrowotne użytkowników, przewidują potencjalne zagrożenia i generują wczesne ostrzeżenia (Ramezani i in., 2025). Istotnym polem zastosowań pozostaje także automatyzacja

i poprawa efektywności procesów produkcyjnych. Algorytmy ML wspierają wykrywanie defektów, rozumianych jako odchylenia przekraczające dopuszczalne granice tolerancji i prowadzące do powstania wyrobów niezgodnych. Należy podkreślić, że nie każde odchylenie parametrów procesowych stanowi defekt, część z nich mieści się w naturalnej zmienności procesu. Systemy oparte na sztucznej inteligencji pozwalają jednak identyfikować te nieprawidłowości, które mają znaczenie jakościowe, a tym samym wymagają interwencji. Dzięki temu możliwa jest optymalizacja cyklu wytwarzania oraz adaptacyjne sterowanie parametrami procesowymi, co skraca przestoje i podnosi jakość wyrobów. Z kolei w sporcie umożliwiają bieżącą analizę przebiegu gry i wspierają podejmowanie decyzji taktycznych w czasie rzeczywistym (Shafi i in., 2023).

Zakres zastosowań metod sztucznej inteligencji jest zatem bardzo szeroki i obejmuje zarówno przemysł, jak i medycynę czy analizę danych. W **Tabeli 2.2** zestawiono przegląd metod i technologii AI wraz z przykładami ich praktycznego wykorzystania w systemach inteligentnego nadzorowania.


Tabela 2.2. Przegląd metod i technologii AI wykorzystywanych w systemach nadzorowania.

Kategoria	Technologie / metody / narzędzia	Przykładowe zastosowania
1. Metody uczenia maszynowego	Regresja logistyczna, SVM, drzewa decyzyjne, Random Forest, XGBoost, k-means	Klasyfikacja stanów maszyn, prognozowanie awarii, adaptacyjne sterowanie procesami
2. Architektury sieci neuronowych	CNN, RNN, LSTM/GRU, autoenkodery, GAN, transformery (Vision Transformers, BERT)	Wizyjna kontrola jakości, analiza szeregów czasowych, detekcja anomalii, generowanie danych
3. Algorytmy i systemy hybrydowe	Logika rozmyta, systemy ekspertowe, modele hybrydowe (np. ARIMA + NN)	Obsługa niepewności, wspomaganie decyzji, predykcja procesów
4. Technologie wspierające AI	Computer Vision, Machine Vision Systems, NLP, Predictive Analytics, Anomaly Detection	Analiza obrazów i sygnałów, analiza raportów i logów, prognozowanie trendów
5. Infrastruktura i integracja	Big Data Analytics, IoT/IIoT + Edge AI, chmura obliczeniowa, Digital Twins, Blockchain + AI, SCADA/MES/MOM z modułami AI	Przetwarzanie danych w czasie rzeczywistym, symulacja procesów, bezpieczeństwo danych
6. Inteligentne technologie pomocnicze	Hiperspektralne systemy wizyjne, analiza sygnałów akustycznych i drganiowych, Predictive Maintenance (PdM), HMI z AI, robotyka współpracująca	Diagnostyka predykcyjna, inspekcja jakości, wsparcie operatora, automatyzacja procesów pomocniczych

Opracowanie własne na podstawie: Negnevitsky, 2005; Kumar i in., 2021; Rane i in., 2024; Rahman i in., 2025.

2.1.4. Architektura inteligentnego systemu nadzorowania

Architektura inteligentnego systemu nadzorowania określa sposób organizacji i współdziałania jego elementów. Ukazuje hierarchię warstw oraz przepływy informacji, które zapewniają spójność działania całego systemu. W literaturze i praktyce przemysłowej najczęściej przyjmuje się ujęcie warstwowe, pozwalające powiązać poziom urządzeń technicznych z systemami zarządzania produkcją i przedsiębiorstwem (Gao i in., 2025). W warunkach Przemysłu 4.0 model ten został rozszerzony o nowe elementy, takie jak komunikacja w czasie rzeczywistym, przetwarzanie rozproszone, cyfrowe bliźniaki oraz moduły sztucznej inteligencji. Dzięki temu możliwe jest nie tylko monitorowanie i kontrola procesów, lecz także ich predykcja, optymalizacja i integracja z decyzjami biznesowymi (Kim i in., 2023). W efekcie współczesny inteligentny system nadzorowania można przedstawić jako warstwy funkcjonalne (**Rysunek 2.3**).



Rysunek 2.3. Warstwy architektury inteligentnego systemu nadzorowania (opracowanie własne na podstawie: Kim i in., 2023; Gao i in., 2025).

1. **Warstwa percepcji** (czujniki, maszyny, IoT, PLC). Obejmuje urządzenia odpowiedzialne za rejestrację parametrów procesu, w tym czujniki środowiskowe i procesowe, systemy wizyjne oraz sterowniki **PLC**, które stanowią interfejs pomiędzy maszynami a cyfrowym systemem nadzoru (Shrivastava i in., 2025). W środowisku przemysłowym coraz częściej stosuje się rozwiązania **Industrial IoT (IIoT)**, umożliwiające sieciową integrację tych elementów i zapewniające ciągłe, wiarygodne pozyskiwanie danych w czasie rzeczywistym (Vaclavova i in., 2022).
2. **Warstwa komunikacji** odpowiada za transmisję danych między urządzeniami a systemami wyższych poziomów. Obejmuje zarówno **media transmisyjne**, jak przewodowe sieci przemysłowe

(np. Ethernet przemysłowy, PROFINET) oraz rozwiązania bezprzewodowe (np. Wi-Fi, sieci czujnikowe, 5G), jak i protokoły komunikacyjne, które zapewniają interoperacyjność i spójność wymiany danych. Do najczęściej stosowanych należą m.in. OPC UA, umożliwiający bezpieczną i ustandaryzowaną komunikację (Paul, 2024), czy MQTT, szeroko wykorzystywany w rozwiązaniach IIoT do przesyłania informacji w czasie rzeczywistym (Ruchi, 2023). Zastosowanie nowoczesnych mediów, takich jak sieci 5G, pozwala dodatkowo na uzyskanie dużej przepustowości i niskich opóźnień, co wspiera nadzór w czasie rzeczywistym, np. w sterowaniu robotami czy pojazdami AGV (Oyekanlu i in., 2020). Warstwa ta zapewnia szybkie i niezawodne połączenia w całym systemie, od czujników po aplikacje biznesowe.

3. **Warstwa przetwarzania danych** (Edge, Cloud, Big Data). Skupia się na gromadzeniu, wstępnym przetwarzaniu i składowaniu danych z procesu. Współcześnie przyjmuje formę hybrydową, łącząc Edge Computing tj. przetwarzanie blisko źródła danych, z minimalnymi opóźnieniami (Qi i in., 2019) oraz chmurę obliczeniową, oferującą dużą moc obliczeniową i przestrzeń do analiz Big Data i trenowania modeli AI. Zalecane są architektury rozproszone, w których dane krytyczne przetwarzane są lokalnie, a szerokie analizy prowadzone w chmurze (Cao i in., 2020). Przykładowo, alarmy jakości mogą być wykrywane przez algorytmy edge przy linii produkcyjnej, podczas gdy analiza trendów i predykcja odbywają się w chmurze. Warstwa ta stanowi kręgosłup informacyjny systemu, zapewniając integralność i dostępność danych oraz przygotowując je do dalszej analizy w warstwie inteligencji.
4. **Warstwa aplikacyjna** (MES, ERP, HMI, SCADA). Czwarta warstwa obejmuje systemy wspierające zarządzanie produkcją, nadzór operatorski i planowanie biznesowe. Należą do niej SCADA/HMI, MES i ERP, które tworzą zintegrowane środowisko zarządzania. SCADA odpowiada za bieżący nadzór nad procesem, zbieranie danych z czujników i sterowników oraz prezentację ich operatorom. Architektura SCADA obejmuje RTU/PLC, sieci komunikacyjne i stacje nadzorcze, umożliwiając obserwację linii produkcyjnej w czasie rzeczywistym i reakcję na alarmy (Mendes, 2020). MES działa na poziomie zakładu, koordynuje harmonogramy, śledzi zlecenia i integruje dane z maszyn oraz SCADA, zapewniając kontrolę nad produkcją i natychmiastową reakcję na odchylenia. Stanowi pomost między biznesowymi planami ERP a operacjami hali produkcyjnej (Esther, 2024). ERP zarządza zasobami całego przedsiębiorstwa, obejmując planowanie produkcji, logistykę i finanse. Integracja MES–ERP pozwala automatycznie korygować plany w oparciu o rzeczywiste postępy i stany magazynowe. Warstwa ta obejmuje również interfejsy HMI i pulpity menedżerskie, zapewniając wgląd w proces i jego kontrolę. Jej znaczenie rośnie wraz z rozszerzaniem SCADA i MES o funkcje analityczne oraz integrację z AI.
5. **Warstwa decyzyjna** (adaptacja, optymalizacja, planowanie). Najwyższa warstwa odpowiada za podejmowanie decyzji sterujących i planistycznych na podstawie danych z niższych poziomów. Stanowi zwieńczenie architektury, gdzie zintegrowane analizy przekładają się na działania korygujące i usprawniające proces. Może być realizowana przez człowieka lub automatyczne

mechanizmy oparte na algorytmach. W inteligentnych systemach nadzoru przyjmuje postać modułów optymalizacji i adaptacji, które dynamicznie regulują parametry maszyn czy harmonogramy produkcji (Zhang i in., 2025). Zastosowanie metod ewolucyjnych czy optymalizacji wielokryterialnej pozwala ograniczać straty i przestoje, a uczenie ze wzmocnieniem wspiera optymalizację sekwencji operacji. Warstwa obejmuje także planowanie strategiczne np. aktualizację planów w razie przewidywanych awarii czy reorganizację zleceń pod wpływem nowych priorytetów. Jej kluczową cechą jest sprzężenie zwrotne: decyzje są przekazywane do warstwy percepcji, co umożliwia zamknięty cykl monitorowania i korekt. Coraz częściej wdrażana jest w formie systemów ekspertowych nadzorujących działanie modeli ML i tłumaczących ich wyniki na działania zgodne z normami (Yang, 2024). Dojrzały system tej klasy automatycznie przekształca dane w decyzje i działania, zwiększając efektywność operacyjną i ograniczając przestoje (Sundaram i in., 2023). Choć nadzór człowieka pozostaje istotny, kierunek rozwoju zmierza ku rosnącej autonomii decyzyjnej opartej na AI.

Przedstawione na rysunku pięć poziomów przenika **warstwa sztucznej inteligencji**, która działa **przekrojowo**. Wspiera wszystkie poziomy architektury, dostosowując metody AI/ML do skali problemu i horyzontu czasowego. Na najniższych warstwach (percepcja, komunikacja) działa blisko sprzętu, w środkowych warstwach (przetwarzanie, aplikacje) zapewnia analizy predykcyjne i preskrypcyjne, a w warstwie decyzyjnej wspiera strategiczne wybory menedżerskie. Dzięki temu tworzy się spójny system. Warstwa ta, choć nieujęta w pierwotnym standardzie ISA-95, współpracuje z systemami SCADA/MES przez interfejsy API i protokoły OPC UA/MQTT. Dzięki temu modele predykcyjne przekazują wyniki analiz do systemów sterowania, co rozszerza funkcje SCADA o moduły AI i Big Data. Warstwa inteligencji pełni rolę „mózgu” systemu, wspierając wyższe poziomy architektury w podejmowaniu decyzji (Aksel de Vries, 2021). Takie podejście pozwala tworzyć systemy elastyczne, skalowalne i zdolne do adaptacji w zmiennym otoczeniu produkcyjnym. Skoro jednak architektura wyznacza ramy działania systemu, równie istotne staje się pytanie o jego skuteczność, które pozwalają ocenić stopień realizacji przyjętych celów i mierzyć wartość dodaną wynikającą z wdrożenia tego typu rozwiązań.

2.1.5. Metody oceny i wskaźniki efektywności inteligentnego nadzorowania procesów

Współczesne systemy nadzorowania procesów produkcyjnych, szczególnie w zautomatyzowanych środowiskach przemysłowych, podlegają ciągłemu doskonaleniu ze względu na rosnące wymagania jakościowe, skracanie cykli produkcyjnych oraz potrzebę redukcji kosztów (Kliment i in., 2020; Majstorovic i in., 2020). Jednocześnie badania pokazują, że wdrożenie zintegrowanych systemów nadzorowania może istotnie poprawić stabilność procesów, zmniejszyć liczbę reklamacji oraz zwiększyć efektywność operacyjną zakładów. Efektywność nadzorowanych procesów produkcyjnych nie zależy jednak wyłącznie od parametrów technicznych maszyn czy czasu operacyjnego, ale wynika

z synergii wielu czynników, obejmujących aspekty technologiczne, organizacyjne, informacyjne oraz środowiskowe (Berić i in. 2018; Popescu i in., 2022). W ujęciu ogólnym efektywność oznacza relację między osiągniętymi wynikami a nakładami poniesionymi na ich uzyskanie. Może być interpretowana zarówno jako efektywność techniczna (związana z wykorzystaniem zasobów), jak i efektywność ekonomiczna (relacja między wartością produkcji a kosztami jej wytworzenia) (Meredyk, 2003; Pyszka, 2015; Sajin i in., 2025). W literaturze efektywność procesu często przedstawiana jest za pomocą ogólnego wzoru:

$$\text{Efektywność} = \frac{\text{Efekt}}{\text{Nakład}}$$

gdzie:

- Efekt to uzyskane wartościowe rezultaty (np. liczba zapakowanych jednostek, wartość produkcji, poziom jakości),
- Nakład to zużyte zasoby (czas pracy, energia, materiały, koszty)


Efektywność procesu wyrobów zależy od wielu powiązanych ze sobą czynników, które można pogrupować w cztery główne obszary: technologiczne, organizacyjne, informacyjne i środowiskowe. Precyzyjna identyfikacja tych czynników stanowi punkt wyjścia do analizy procesów oraz ich dalszej optymalizacji, zarówno w ujęciu operacyjnym, jak i strategicznym (Sani i in., 2013; Kliment i in., 2020).

- **Czynniki technologiczne** odnoszą się do infrastruktury technicznej i poziomu automatyzacji systemów produkcyjnych. Obejmują m.in. rodzaj i konfigurację maszyn, zastosowane technologie przetwarzania i kontroli, a także stopień integracji z systemami sterowania. Istotne znaczenie ma niezawodność urządzeń, jakość używanych materiałów oraz zdolność adaptacji technologii do zmiennych warunków eksploatacyjnych (Rohée i in., 2009; Sani i in., 2013).
- **Czynniki organizacyjne** obejmują strukturę zarządzania produkcją, planowanie i alokację zasobów, rotację i kwalifikacje personelu oraz organizację pracy zmianowej. Kluczową rolę odgrywa poziom kompetencji operatorów i inżynierów, a także stopień wdrożenia metod doskonalenia, takich jak Lean Manufacturing, Total Productive Maintenance (TPM) czy Six Sigma (Huaman-Monzon i in., 2024; Narayan, 2024).
- **Czynniki informacyjne** odnoszą się do dostępności i jakości danych w czasie rzeczywistym, stopnia integracji systemów IT oraz zdolności do analizy wskaźników procesowych. Spójne i wiarygodne dane umożliwiają podejmowanie trafnych decyzji operacyjnych, usprawniają harmonogramowanie zleceń i wspierają predykcyjne utrzymanie ruchu (Wei i in., 2020; Ji i in., 2025).
- **Czynniki środowiskowe** obejmują warunki pracy systemów, takie jak temperatura, wilgotność, zapylenie, hałas czy wymagania sanitarne. W branżach o wysokim reżimie higienicznym kluczowe

znaczenie ma utrzymanie odpowiedniego mikroklimatu, co bezpośrednio wpływa na trwałość i jakość produktów oraz zgodność z wymaganiami norm (np. HACCP, ISO 22000) (Mendis i in., 2009; Gil L, 2017; Ruben i in., 2019).

Identyfikacja czynników technologicznych, organizacyjnych, informacyjnych i środowiskowych stanowi punkt wyjścia do oceny skuteczności inteligentnych systemów nadzorowania. Aby ich wpływ można było obiektywnie monitorować i analizować, konieczne jest zastosowanie mierzalnych wskaźników efektywności (**KPI - Key Performance Indicators**), które przekładają złożone uwarunkowania procesu na wartości liczbowe możliwe do bieżącej obserwacji i porównania. Wskaźniki te pozwalają na ilościową ocenę stabilności, jakości i niezawodności procesu, a tym samym wspierają podejmowanie uzasadnionych decyzji zarządczych. Przykładowo, **OEE** (Overall Equipment Effectiveness) dostarcza zintegrowanej informacji o wykorzystaniu maszyn. Spadek OEE może sygnalizować problemy z dostępnością (awarie), wydajnością (spowolnienia) lub jakością (wzrost braków) (Leśniewski i in., 2023; Sifiso Phenyane, 2023). **FPY** (First Pass Yield) czy **DPMO (Defects Per Million Opportunities)** natychmiast pokazują jakość procesu, gdzie niska wydajność pierwszego przejścia lub rosnąca liczba defektów na milion wskazują na potrzebę interwencji (usprawnienia procesu, kalibracji maszyn, szkoleń itp.) (Nugraha i in., 2024). **MTBF** (Mean Time Between Failures) / **MTTR** (Mean Time To Repair) z kolei informują o stanie utrzymania ruchu; pogarszające się wartości (np. spadek MTBF, wydłużenie MTTR) ostrzegają przed rosnącą awaryjnością bądź niewystarczającą skutecznością służb technicznych (Sajin i in., 2025). **Scrap rate** i **COPQ** (Cost of Poor Quality) przekładają się bezpośrednio na koszty a ich wzrost oznacza marnotrawstwo zasobów i wyższe koszty (Chiu i in., 2007). **Wskaźniki reklamacji** oraz **OTD** (On Time Delivery) to z kolei barometr satysfakcji klienta i sprawności organizacyjnej; zwiększona liczba reklamacji lub spadek terminowości dostaw świadczą o obniżeniu jakości odczuwanej i mogą skutkować utratą zaufania klientów (Kamali, 2018). Dzięki takiemu zestawowi KPI system nadzorowania może wcześniej wykrywać odchylenia od wartości docelowych i inicjować działania korygujące zanim drobne problemy urosną do poważnych awarii czy strat (Kang i in., 2016). Innymi słowy, wskaźniki efektywności pełnią rolę sprzężenia zwrotnego, dostarczają informacji o funkcjonowaniu procesu, pozwalając mierzyć postępy doskonalenia, porównywać wydajność w czasie oraz między liniami/zakładami, a ostatecznie ocenić skuteczność samego systemu nadzorowania (czy przynosi on poprawę tychże wskaźników) (Fantozzi i in., 2023).

Na potrzeby usystematyzowania mierników przedstawionych w literaturze, na **Rysunku 2.4** zaprezentowano klasyfikację wskaźników efektywności (KPI) stosowanych w inteligentnym nadzorowaniu procesów. Wskaźniki te zostały pogrupowane w trzy kategorie: produkcyjne, jakościowe oraz związane z utrzymaniem ruchu, obejmujące aspekty techniczne, ekonomiczne i organizacyjne.



Rysunek 2.4. Klasyfikacja wskaźników efektywności (KPI) w inteligentnym nadzorowaniu procesów (opracowanie własne na podstawie: Kang i in., 2016; Luo i in., 2023; Czerwińska i in., 2025).

W kontekście Przemysłu 4.0 monitorowanie wskaźników efektywności jest zintegrowane z zaawansowanymi systemami cyfrowymi: SCADA, MES, ERP oraz narzędziami AI. SCADA i MES automatycznie zbierają dane z czujników i sterowników, umożliwiając obliczanie KPI w czasie rzeczywistym i ich wizualizację na panelach operatorskich oraz w raportach dla kadry zarządzającej (Omisola i in., 2023). MES integruje dane z wielu stanowisk, wspierając analizę całych linii produkcyjnych, identyfikację wąskich gardeł i korektę harmonogramów. Połączenie systemów IT z warstwą produkcyjną eliminuje opóźnienia i błędy wynikające z ręcznego raportowania. Sztuczna inteligencja dodatkowo rozszerza te możliwości, gdzie modele uczenia maszynowego analizują dane w celu prognozowania awarii (wydłużając MTBF, skracając MTTR) oraz wczesnego wykrywania odchyleń jakości (poprawiając FPY i DPMO) (Chowdhury i in., 2023). Systemy AI mogą również dynamicznie optymalizować harmonogramy i zasoby. Tym samym KPI stają się narzędziem wspierającym decyzje w czasie rzeczywistym i umożliwiającym ciągłe doskonalenie procesów poprzez redukcję strat, zwiększenie produktywności i poprawę jakości. Wdrożenie monitoringu KPI, zwłaszcza OEE, uznaje się za pierwszy krok w cyfryzacji fabryk i budowie inteligentnych systemów nadzorowania (Gomaa, 2025). **Tabela 2.3** przedstawia zestawienie wybranych wskaźników efektywności wykorzystywanych do oceny procesów produkcyjnych w środowisku zautomatyzowanym.

Tabela 2.3. Kluczowe wskaźniki efektywności (KPI) w inteligentnym nadzorowaniu procesów.

Wskaźnik	Definicja	Wzór	Jednostka	Interpretacja
OEE (Overall Equipment Effectiveness)	Całkowita efektywność wyposażenia jako iloczyn dostępności, wydajności i jakości	$\text{Dostępność} * \text{Wydajność} * \text{Jakość}$	%	Wskaźnik określający relację rzeczywistej produkcji dobrych wyrobów do produkcji teoretycznie możliwej w warunkach pełnej dostępności, nominalnej prędkości i braku defektów
A – Availability (dostępność)	Udział czasu operacyjnego w czasie planowanym	$\frac{\text{Czas rzeczywistego działania maszyny}}{\text{Planowany czas pracy}} * 100\%$	%	Miara strat z tytułu przestojów planowanych i nieplanowanych
P – Performance (wydajność)	Relacja rzeczywistego tempa pracy do tempa nominalnego	$\frac{\text{Liczba wyprodukowanych sztuk}}{\text{(Czas operacyjny maszyny} * \text{Nominalna wydajność)}} * 100\%$	%	Miara spowolnień i mikroprzestojów względem prędkości odniesienia
Q – Quality (jakość)	Udział wyrobów dobrych w całej produkcji	$\frac{\text{Liczba produktów dobrych}}{\text{Całkowita liczba wyprodukowanych produktów (PQ)}} * 100\%$	%	Miara braków wewnętrznych i poprawek
FPY (First Pass Yield)	Wydajność pierwszego przejścia bez poprawek	$\frac{\text{Liczba dobrych jednostek}}{\text{Całkowita liczba wyprodukowanych jednostek}} * 100\%$	%	Stabilność i powtarzalność procesu w jednym przebiegu
DPMO (Defects Per Million Opportunities)	Liczba defektów na milion szans wystąpienia wady	$\frac{\text{Całkowita liczba defektów}}{\text{(Całkowita liczba jednostek} * \text{Liczba możliwości defektu na jednostkę)}} * 1\,000\,000$	liczba na 10^6	Miara jakości w metodologii Six Sigma
Scrap rate (wskaźnik braków)	Udział wyrobów brakowych w całej produkcji	$\frac{\text{Liczba wyrzuconych sztuk}}{\text{Całkowita produkcja}} * 100\%$	%	Miara marnotrawstwa materiałowego i czasu
MTBF (Mean Time Between Failures)	Średni czas pracy między awariami	$\frac{\text{Całkowity czas pracy}}{\text{Liczba awarii}}$	godzina	Im wyższy MTBF, tym większa niezawodność maszyn
MTTR (Mean Time to Repair)	Średni czas usunięcia awarii	$\frac{\text{Całkowity czas napraw w danym okresie}}{\text{Liczba napraw w tym samym okresie}}$	godzina	Im niższy MTTR, tym szybsza reakcja utrzymania ruchu
Koszt jednostkowy	Średni koszt wytworzenia jednej sztuki	$\frac{\text{Całkowite koszty produkcji}}{\text{Liczba wyprodukowanych jednostek}}$	waluta/szt.	Miara efektywności ekonomicznej procesu

OTD (On Time Delivery)	Terminowość realizacji zleceń	Liczba dostaw zrealizowanych na czas / Całkowita liczba dostarczonych zamówień) * 100%	%	Zdolność dotrzymywania terminów produkcji i dostaw
CCR (Customer Complaint Rate)	Odsetek sprzedanych wyrobów objętych reklamacją	Całkowita liczba skarg / Całkowita liczba transakcji lub klientów) * 100%	%	Jakość postrzegana przez klienta
RCR (Repeat Complaint Rate)	Odsetek klientów zgłaszających reklamację повторно	Liczba powtórnych zgłoszeń w danym okresie / Całkowita liczba zgłoszeń w danym okresie) * 100%	%	Miara skuteczności działań korygujących i stabilności jakości

Opracowanie własne na podstawie: Kang i in., 2016; Gopang, 2024; Czerwińska i in., 2025.

W środowisku Industry 4.0 wskaźniki te nie są analizowane oddzielnie, lecz wykorzystywane łącznie w systemach zarządzania. Przykładowo OEE oraz MTBF/MTTR stanowią podstawę programów **TPM** (Total Productive Maintenance), ukierunkowanych na eliminację sześciu wielkich strat i zwiększanie dyspozycyjności maszyn (Mouhib i in., 2025). Z kolei DPMO, FPY i poziom braków to istotne miary w projektach **Six Sigma**, ukierunkowanych na redukcję zmienności i defektów (Nowicki, 2016). Natomiast zasady **Lean** kładą nacisk na ograniczenie marnotrawstwa (np. nadprodukcji, braków, przestojów) w celu poprawy wskaźników wydajności i kosztów (Harshitkumar, 2021). Tym samym inteligentne nadzorowanie procesów produkcyjnych wykorzystuje sprawdzone metodologie poprawy efektywności, integrując monitorowanie KPI z narzędziami analitycznymi. Efektem jest **ciągłe doskonalenie**, gdzie system nadzorujący nie tylko raportuje bieżące wartości wskaźników, ale też wspiera diagnozę przyczyn odchyleń i rekomenduje działania korygujące, aby docelowo podnosić efektywność procesu we wszystkich wymiarach (technicznej, jakościowej, ekonomicznej i organizacyjnej).

2.2. Konfekcjonowanie

2.2.1. Znaczenie i charakterystyka procesu konfekcjonowania

Konfekcjonowanie stanowi zespół operacji przygotowujących produkt do dalszych etapów w łańcuchu dystrybucji. Obejmuje m.in. porcjowanie, pakowanie, etykietowanie, foliowanie, umieszczaniu dodatkowych materiałów promocyjnych (np. ulotek lub materiałów informacyjnych), formowanie zestawów promocyjnych czy przepakowywanie wyrobów. Celem tych działań jest nie tylko zabezpieczenie produktu, lecz także dostosowanie jego formy do wymagań logistycznych, jakościowych i identyfikacyjnych (Kirwan i in., 2003; Gordon L. Robertson, 2012). Proces ten może być realizowany zarówno manualnie, jak i przy użyciu zautomatyzowanych linii pakujących, w tym zintegrowanych systemów formowania, napełniania i zamykania (form-fill-seal), które pozwalają na wykonanie kilku operacji w jednym ciągu technologicznym (Seifi i in., 2023). Konfekcjonowanie pełni

rolę kluczowego ogniwa pomiędzy wytworzeniem produktu a jego dostarczeniem na rynek. Wpływa bezpośrednio na zachowanie parametrów jakościowych (świeżość, trwałość, wygląd) oraz bezpieczeństwo wyrobów w trakcie magazynowania i transportu (Fung i in., 2018). W branży spożywczej właściwe opakowanie chroni żywność przed zanieczyszczeniami i zepsuciem, a etykieta dostarcza konsumentom niezbędnych informacji o składzie, alergenach i dacie przydatności do spożycia. Z kolei w sektorach takich jak farmacja czy kosmetyki wymagana jest wyjątkowa precyzja, ponieważ nawet drobne niezgodności (np. w dawkowaniu lub oznakowaniu) mogą skutkować poważnymi konsekwencjami zdrowotnymi i prawnymi (Sani i in., 2013). Struktura procesu konfekcjonowania może obejmować następujące etapy:

- **Porcjowanie** często realizowane poprzez naważanie, polega na dokładnym odmierzaniu odpowiednich ilości produktu przed umieszczeniem go w opakowaniu jednostkowym. Jest to niezwykle istotny etap szczególnie w branżach takich jak spożywcza, farmaceutyczna czy kosmetyczna, gdzie precyzyjna dawka produktu ma kluczowe znaczenie dla jakości i bezpieczeństwa. Automatyczne systemy naważające (np. multihead weighers) umożliwiają szybkie i precyzyjne porcjowanie, minimalizując straty materiałowe i zwiększając wydajność produkcji (García-Jiménez, 2021). Nowoczesne rozwiązania w zakresie naważania wykorzystują technologie cyfrowe i systemy sterowania umożliwiające integrację z liniami pakującymi oraz systemami kontroli jakości. Takie podejście jest zgodne z koncepcją Przemysłu 4.0 i wspiera rozwój inteligentnych systemów produkcyjnych (McGuire i in., 2025).
- **Pakowanie** to jeden z podstawowych etapów konfekcjonowania. Ma ono za zadanie zapewnić produktowi bezpieczeństwo w trakcie transportu i przechowywania, a także estetyczny wygląd, który może decydować o wyborze konsumenta. Szczególnie znaczenie ma to w branży e-commerce, gdzie pierwsze wrażenie klienta często zależy od jakości i wyglądu opakowania. Karton, w którym znajduje się towar, musi być nie tylko atrakcyjny wizualnie, ale także spełniać wymogi przewoźnika i zabezpieczać produkt przed uszkodzeniem (Dobrucka, 2013; Han i in., 2018).
- **Etykietowanie** to kolejny ważny etap procesu, zapewnia identyfikację produktu i przekazanie informacji niezbędnych do dalszej obróbki lub użytkowania. Etykiety mogą zawierać kody kreskowe, daty przydatności, oznaczenia partii produkcyjnej, a także treści marketingowe lub techniczne (Biji et al., 2015).

Obok tradycyjnych metod ręcznych i półautomatycznych, cechujących się elastycznością, ale ograniczoną wydajnością, coraz częściej stosuje się zintegrowane linie automatyczne typu form-fill-seal, które w jednym ciągu technologicznym formują opakowanie, napełniają je odmierzoną porcją i szczelnie zamykają (Seifi i in., 2023). W skład takich linii wchodzi również urządzenia kontrolno-pomiarowe, jak wagi wielogłowicowe oraz etykieciarki zapewniające powtarzalność i zgodność procesu z normami jakościowymi (Hambir i in., 2008). Rozwój technologiczny doprowadził także do pojawienia

się rozwiązań określanych mianem Packaging 4.0, obejmujących np. czujniki czasowo-temperaturowe czy etykiety RFID, które umożliwiają monitorowanie warunków otoczenia produktu w czasie rzeczywistym i sygnalizowanie nieprawidłowości (Zhu i in., 2023). Dzięki nim możliwe jest zapewnienie pełnej identyfikowalności partii oraz szybkie reagowanie na potencjalne zagrożenia jakościowe. Różnorodność stosowanych rozwiązań, od manualnych, przez półautomatyczne, po zintegrowane i inteligentne systemy obrazuje ewolucję podejścia do konfekcjonowania. W Tabeli 2.4 przedstawiono zestawienie wybranych systemów wraz z ich charakterystyką i obszarami zastosowań.

Tabela 2.4. Przegląd systemów konfekcjonowania – charakterystyka i zastosowanie.

Systemy konfekcjonowania	Charakterystyka	Zastosowanie
Systemy ręczne i półautomatyczne	Niski poziom automatyzacji, wysoka elastyczność przy częstych zmianach asortymentu, relatywnie niskie nakłady inwestycyjne, ograniczona wydajność i powtarzalność. Wymagają stałej obecności operatora, umożliwiają szybkie uruchomienie i rekonfigurację stanowisk.	Małe i średnie serie, produkcja rzemieślnicza, prototypowanie, środowiska o dużej zmienności SKU.
Systemy modułowe i hybrydowe	Budowa modułowa pozwala na skalowanie linii, szybkie przebrojenia i rozbudowę funkcji. Łączą stacje automatyczne i manualne. Umożliwiają integrację z etykietowaniem, kontrolą wizyjną, wagami kontrolnymi i systemami śledzenia partii.	Linie średniej skali, zakłady o zróżnicowanym portfelu produktów i częstych przebrojeniach.
Zintegrowane linie form fill seal (VFFS/HFFS, flow pack)	Automatyzacja sekwencji formowanie, napełnianie i zgrzewanie w jednym cyklu. Wersje pionowe VFFS dla produktów sypkich i drobnych oraz poziome HFFS, w tym rozwiązania flow pack, dla produktów o stałej formie. Łatwa integracja z dozownikami, wagami, kontrolą szczelności i systemami wizyjnymi. Wysoka wydajność i jakość zamknięć.	Przemysł spożywczy, chemiczny, kosmetyczny; produkcja wielkoseryjna, procesy o podwyższonych wymaganiach higienicznych.
Kartoniarki i systemy kartonowania	Formowanie, napełnianie i zamykanie opakowań kartonowych pojedynczych i zbiorczych. Układy top load, side load oraz wrap around. Możliwa integracja z urządzeniami pick and place, etykietowaniem oraz kontrolą masy i wizyjną.	Farmacja, kosmetyka, FMCG; pakowanie jednostek w opakowania zbiorcze, przygotowanie do dystrybucji.
Systemy z robotami przemysłowymi	Zastosowanie robotów delta, SCARA lub sześciopięciowych. Zadania pick and place, pakowanie do kartonów, paletyzacja i depaletyzacja. Wysoka precyzja i powtarzalność, szybka zmiana programu, możliwość współpracy z systemami wizyjnymi i czujnikami siły. Dostępne także rozwiązania cobotowe.	Duże linie o wysokiej wydajności, logistyka i pakowanie końcowe, środowiska z dużą zmiennością wariantów produktu.

Systemy wykorzystujące sztuczną inteligencję	Analiza strumieni danych w czasie rzeczywistym, detekcja anomalii i wizyjna kontrola jakości, predykcyjne utrzymanie ruchu oraz adaptacyjne sterowanie parametrami. Integracja z systemami SCADA, MES i ERP. Zdolność do poprawy wskaźników OEE i FPY przy zachowaniu ścieżek wyjaśniania decyzji.	Zaawansowane linie pakujące, zakłady realizujące transformację Przemysłu 4.0, środowiska wymagające wysokiej stabilności jakości i ograniczenia przestoju.
--	--	--

Opracowanie własne na podstawie: Kirwan i in., 2003; Habib, Rizvan i in., 2023; Farah-Alva i in., 2024; Henok i in., 2024; Pantoja-Benavides i in., 2024; Roslan i in., 2024; Sundar i in., 2024.

Proces konfekcjonowania, będący kluczowych etapem łańcucha produkcyjnego, różni się znacząco w zależności od branży, rodzaju produktu oraz wymagań jakościowych i logistycznych. Różnorodność środowisk przemysłowych wyklucza istnienie jednego uniwersalnego rozwiązania, każda branża kładzie nacisk na inne parametry, co determinuje wybór technologii, rodzaju opakowań i poziomu automatyzacji (Han i in., 2018).

W **przemysle spożywczym** dominuje potrzeba zapewnienia bezpieczeństwa mikrobiologicznego i zachowania świeżości produktów. Stosuje się tutaj technologie takie jak pakowanie w atmosferze ochronnej (MAP), linie typu form-fill-seal, integrację z wagami wielogłowicowymi oraz systemy detekcji ciał obcych i etykietowania zgodnego z przepisami sanitarnymi. Kluczowe znaczenie ma również kontrola temperatury, wilgotności i czasu pakowania, a także możliwość śledzenia partii produktu (traceability) (Sani i in., 2013; Hallmann i in., 2018). W **branży farmaceutycznej i kosmetycznej** wymagana jest wyjątkowa precyzja oraz zgodność z normami GMP. W tym środowisku powszechnie stosuje się zautomatyzowane systemy dozujące, blisterowanie, etykietowanie z pełną identyfikowalnością oraz systemy walidacji danych produkcyjnych. Ze względu na konieczność spełnienia rygorystycznych przepisów dotyczących bezpieczeństwa, konfekcjonowanie w tej branży ściśle wiąże się z dokumentacją, kontrolą jakości i monitoringiem (Salunke, 2022; Mohita Thakur, 2025). W przypadku **e-commerce**, elastyczność i szybkość procesu konfekcjonowania są priorytetem. Wykorzystuje się tu rozwiązania umożliwiające automatyczne dopasowanie opakowania do rozmiaru produktu, etykietowanie zgodne z wymaganiami platform sprzedażowych (np. Amazon) oraz możliwość personalizacji, np. dodawanie materiałów marketingowych. Konieczna jest też integracja z systemami ERP/WMS i szybka rekonfiguracja linii produkcyjnych (Jacobs, 2024; Huaman-Monzon i in., 2024). Z kolei w **przemysle ciężkim** proces konfekcjonowania obejmuje pakowanie zbiorcze, foliowanie stretch hood lub termobkurczające, a także automatyczną paletyzację i zabezpieczanie produktów do transportu. Nacisk kładziony jest tu na wytrzymałość opakowania oraz odporność na czynniki środowiskowe i transportowe (Mosconi i in., 2024; Mahalik, 2014). Zróżnicowanie wymagań poszczególnych sektorów gospodarki pokazuje, że konfekcjonowanie nie jest procesem jednorodnym, lecz dostosowuje się do specyfiki produktu, regulacji prawnych i oczekiwań rynku. W **Tabeli 2.5**

zestawiono porównanie metod konfekcjonowania w wybranych branżach, wskazując ich główne cechy, technologie dominujące oraz kluczowe czynniki determinujące skuteczność i bezpieczeństwo procesu.

Tabela 2.5. Metody konfekcjonowania w wybranych branżach.

Branża	Stosowane rozwiązania technologiczne	Kluczowe wymagania
Spożywcza	MAP, linie form fill seal VFFS i HFFS, systemy flow pack, wagi wielogłowicowe, dozowniki objętościowe i wagowe, kontrola metali i skanery rentgenowskie, wizyjna kontrola jakości, wagi kontrolne, etykietowanie z kodami GS1, znakowanie daty przydatności, systemy śledzenia partii	Higiena procesu i materiałów, utrzymanie świeżości i wydłużenie trwałości, integralność zgrzewu, utrzymanie łańcucha chłodniczego, identyfikowalność i zgodność z HACCP oraz ISO 22000, szybkie przezbrajanie i czyszczenie, minimalizacja kontaktu człowieka z produktem
Farmaceutyczna	Blistry termoformowane i typu cold-form Alu-Alu, linie do fiolek i ampulek z izolatorami lub RABS, technologia Blow Fill Seal dla preparatów płynnych, kontrola wizyjna obecności i poprawności, wagi kontrolne z rejestracją danych, serializacja i track and trace, etykietowanie z elementami zabezpieczającymi	Zgodność z GMP i wymaganiami jakości dla wyrobów leczniczych, aseptyka i kontrola zanieczyszczeń, integralność zamknięć, pełna identyfikowalność z agregacją, integralność danych i audytowalność, walidacja urządzeń i procesów
E-commerce	Automaty pakujące pod wymiar, automatyczne formatowanie kartonów, systemy bagging do folii, dozowanie wypełnień, druk i aplikacja etykiet, sortery automatyczne, stanowiska pick and place, integracja z WMS i ERP	Elastyczność i personalizacja, wysoka przepustowość w szczytach, dokładność etykietowania i komplekacji, minimalizacja kosztu jednostkowego i objętości przesyłki, odporność opakowań na transport kurierski, śledzenie zamówień i zwrotów
Przemysł ciężki	Owijarki stretch i systemy stretch hood, kapturowanie termokurczliwe, paletyzatory konwencjonalne i zrobotyzowane, wiązarki taśmą PET lub stalową, top-sheet i narożniki ochronne, linie workujące FFS dla materiałów sypkich, systemy znakowania i etykietowania ładunków, kontrola masy i stabilności palety	Stabilizacja ładunku i bezpieczeństwo transportu, odporność opakowań na wilgoć, kurz i UV, ochrona antykorozyjna opcjonalnie z użyciem VCI, dostosowanie do wymogów transportu i składowania, zgodność z regulacjami dotyczącymi materiałów niebezpiecznych w tym ADR, trwałe znakowanie i identyfikowalność ładunków

Opracowanie własne na podstawie: Mahalik, 2014; Chisenga i in., 2020; Hui i in., 2020; Thirupathi i in., 2023; Dodke, 2025.

2.2.2. Wyzwania operacyjne i jakościowe w procesie konfekcjonowania

Mimo istotnej roli konfekcjonowania, proces ten wiąże się z wieloma wyzwaniami natury operacyjnej i jakościowej. Złożoność działań pakujących, wysokie wymagania higieniczne oraz presja czasu sprawiają, że nawet drobne uchybienia mogą prowadzić do poważnych konsekwencji. Jak zauważono w literaturze, nawet niewielkie odchylenia w przebiegu operacji pakowania czy

etykietowania potrafią skutkować problemami ekonomicznymi i reputacyjnymi dla producenta. Innymi słowy, błąd na tym etapie produkcji jest bardzo kosztowny, gdyż zazwyczaj dotyczy już w pełni wytworzonego produktu o wysokiej wartości dodanej (Elmadhoun i in. 2025). Poniżej przedstawiono typowe problemy pojawiające się w procesie konfekcjonowania, które stanowią wyzwania dla utrzymania płynności produkcji i wymaganej jakości wyrobów:

- **Odchylenia masy i dozowania** – Niewłaściwe porcjowanie produktu (np. z powodu błędnej kalibracji wag lub zmienności surowca) skutkuje niezgodnością masy netto z deklaracją na opakowaniu. Zarówno niedowaga, jak i nadwyżka są niepożądane: pierwsza narusza przepisy i zaufanie klientów, druga generuje straty surowca i podnosi koszty jednostkowe. Utrzymanie wymaganej tolerancji masy wymaga ciągłego nadzorowania systemów naważających oraz ich regularnej kalibracji (McGuire i in., 2025). W praktyce przemysłowej często stosuje się wagi kontrolne (checkweighery) na końcu linii, odrzucające opakowania poza specyfikacją wagową.
- **Błędy etykietowania i oznakowania** – Oznaczenie niezgodną etykietą lub kodem produktu może skutkować koniecznością wycofania wyrobu gotowego z rynku (ang. product recall), szczególnie gdy błąd dotyczy informacji alergennych lub daty ważności. Typowe problemy to: pomylenie etykiet między produktami, brak części informacji na etykiecie, nieczytelny nadruk lub nieprawidłowe umiejscowienie etykiety na opakowaniu. Zdarzają się również sytuacje naklejenia etykiety krzywo lub uszkodzenia jej podczas aplikacji (Soon i in., 2021). Zapobieganie tym błędom wymaga ścisłej synchronizacji systemu etykietującego z podajnikiem produktów oraz wizyjnej kontroli obecności etykiety i ich czytelności.
- **Uszkodzenia opakowań i nieszczelność** – Opakowanie pełni funkcję ochronną, dlatego jego niezgodność (np. uszkodzona folia, nieszczelna zgrzeina, niedomknięta pokrywka) zagraża jakości produktu (utrata świeżości, wysychaniem, zakażeniem drobnoustrojami). Źródłem problemów mogą być zarówno wady materiałów opakowaniowych, jak i nieprawidłowe ustawienia maszyn pakujących. Szczególną uwagę zwraca się na integralność opakowań próżniowych i MAP (pakowanych w atmosferze modyfikowanej), gdzie nawet mikro nieszczelność niweczy założony wydłużony okres przydatności do spożycia. Dlatego powszechnie wdraża się testy szczelności opakowań oraz systemy wizyjne monitorujące jakość zgrzein i obecność ciał obcych na łączeniach folii. Raporty branżowe wskazują, że defekty opakowań są jedną z częstszych przyczyn reklamacji produktów spożywczych (Altemimi i in., 2025).
- **Awaryjność i przestoje linii** – Linie konfekcjonujące składają się z wielu współpracujących urządzeń (dozowniki, pakowaczki, etykieciarki, systemy przenośników), których praca musi być precyzyjnie zsynchronizowana. Braki synchronizacji lub awaria jednego z elementów często powoduje zatrzymanie linii (Ricetti, 2013). Na przykład, jeśli etykieciarka nie nadąży za tempem napełniarki, dochodzi do gromadzenia się produktów i konieczności wstrzymania produkcji. Częste przebrojenia ze względu na różne formaty opakowań również generują przestoje i zwiększają

ryzyko błędów ustawień. Wyzwanie stanowi zatem zarówno zapewnienie niezawodności maszyn (co wiąże się z regularnym serwisem i wdrażaniem prewencyjnych strategii utrzymania ruchu), jak i optymalizacja harmonogramów produkcji, by minimalizować liczbę formatów opakowań w ciągu zmiany produkcyjnej.

- **Czynnik ludzki i organizacja pracy** – Pomimo postępu automatyzacji, wiele operacji konfekcjonowania wciąż wymaga interwencji człowieka (np. kontrola wzrokowa, uzupełnianie materiałów). Błędy operatorów, niedostateczne przeszkolenie personelu czy przemęczenie mogą przekładać się na pomyłki w nastawach maszyn lub przeoczenie wad produktu. Organizacyjne aspekty, takie jak odpowiednie planowanie obsady na linii pakującej, monitorowanie kluczowych wskaźników (np. OEE) oraz motywowanie pracowników do zgłaszania nieprawidłowości, również należą do istotnych czynników jakościowych (Ngadiman i in., 2016). Literatura podkreśla potrzebę kształtowania proaktywnych kultur jakości, w których personel rozumie znaczenie standardów pakowania i czuje się odpowiedzialny za końcowy wynik procesu (Kałkowska, 2020).

Zidentyfikowane powyżej problemy wskazują, że nadzorowanie nad procesem konfekcjonowania wymaga wieloaspektowego podejścia. Konieczne jest łączenie rozwiązań technicznych (automatyzacja, czujniki, systemy wizyjne) z działaniami organizacyjnymi (szkolenia, procedury kontrolne) w celu minimalizacji ryzyka błędów. Utrzymanie wysokiej jakości i efektywności pakowania jest wyzwaniem, zwłaszcza przy rosnącej złożoności produktów i skracającym się cyklu życia wyrobów. Dlatego przedsiębiorstwa produkcyjne poszukują nowych metod i narzędzi, które wesprą utrzymanie stabilności procesu konfekcjonowania mimo wymienionych trudności. Kierunek tych poszukiwań wyznaczają aktualne trendy technologiczne w przemyśle o czym traktuje kolejna część tego przeglądu.

2.2.3. Metody oraz narzędzia nadzorowania w procesach konfekcjonowania

W literaturze opisano szereg podejść mających na celu usprawnienie nadzorowania nad procesami konfekcjonowania, począwszy od klasycznych metod organizacyjnych po zaawansowane techniki sztucznej inteligencji. Podejścia szczupłego zarządzania produkcją (lean manufacturing) oraz Total Productive Maintenance (TPM) były z powodzeniem wdrażane w zakładach konfekcjonujących produkty w celu poprawy ich wydajności i jakości. Przykładowo, Habib i in. (2023) zastosowali narzędzia lean (mapowanie strumienia wartości VSM, system kanban, metodę SMED) w fabryce etykietowania i pakowania, uzyskując skrócenie czasu realizacji o ok. 7% oraz aż 83% redukcję wskaźnika reklamacji klientów. Podobnie Farah-Alva i in. (2024) wykazali, że integracja filozofii lean z filarami TPM w procesie pakowania produktów rolnych przekłada się na wzrost produktywności i eliminację strat (np. przestojów i braków). Również metody ciągłego doskonalenia wsparte danymi IIoT testowane przez Sundar i in. (2024) opisali wykorzystanie Industrial IoT wraz z metodyką Kata do usprawnienia linii montażowo-pakującej, co pozwoliło zwiększyć produktywność operacji. Warto jednak zauważyć, że podejścia te koncentrują się głównie na organizacyjnej stronie procesu i eliminacji

marnotrawstwa, nie zapewniając automatycznego nadzoru jakości w czasie rzeczywistym ani predykcji błędów a efektywność zależy nadal od poprawności wdrożenia i zaangażowania personelu.

Różnorodne metody nadzorowania zautomatyzowanego procesu naważania i porcjowania były opisywane w literaturze i obejmują one zarówno podejścia tradycyjne, jak i nowoczesne oparte na AI. Na przykład Matuszek i Opolska (2012) przeprowadzili analizę statystyczną automatycznego procesu dozowania składników paszy, wykorzystując m.in. regresję liniową i testy nieparametryczne, co ujawniło istotne odchylenia mas dozowanych komponentów oraz ograniczenia dokładności urządzeń dozujących (największe błędy stwierdzono przy naważaniu pszenicy). Bazydło i in. (2015) opracowali zintegrowany system dynamicznego ważenia oparty na środowisku SCADA połączonym z Matlab/LabVIEW, umożliwiający zaawansowane przetwarzanie sygnałów wagowych, wizualizację danych i sterowanie procesem w czasie rzeczywistym. Prototyp ten wykazał skuteczność w tłumieniu zakłóceń i bieżącym nadzorze masy produktu, jednak jego implementacja wymagała integracji wielu środowisk programistycznych (funkcjonalności niemożliwe do osiągnięcia w standardowym SCADA). W branży spożywczej istotnym zagadnieniem jest optymalizacja pracy wielogłowicowych naważarek. García-Jiménez i in. (2021) zaproponowali nowy algorytm doboru kombinacji zasobników w dwuwarstwowej naważarce wielogłowicowej, który zmniejszył zmienność masy porcji i poprawił wydajność konfekcjonowania w porównaniu z konwencjonalnymi algorytmami sterowania. Rozwiązanie to zwiększyło stabilność procesu ważenia, choć dotyczyło specyficznej konfiguracji urządzenia, co ogranicza uniwersalność metody (dedykowane do określonego typu naważarki). Z kolei w obszarze farmaceutycznym pojawiają się rozwiązania oparte na AI. Barmpalexis i in. (2020) zastosowali sieć neuronową do predykcji rezultatów napełniania kapsulek na podstawie właściwości peletek (gęstości nasypowej, rozmiaru cząstek), uzyskując model o wysokiej dokładności ($R^2 > 0,95$) i lepszej zdolności uogólniania niż klasyczna regresja. Również w przemyśle spożywczym odnotowano korzyści z AI, gdzie Liu (2022) donosi o regulatorze rozmyto-neuronowym zaimplementowanym w linii rozlewu piwa, który zredukował maksymalne odchylenie masy napełnienia do 1,7 g i zwiększył precyzję dozowania o 50% względem klasycznego PID (przyspieszając czas reakcji o 55%). Podsumowując, mimo obiecujących wyników tych zróżnicowanych metod nadzoru (zarówno konwencjonalnych, jak i inteligentnych), brak jest integracji tych rozwiązań w jednym spójnym, inteligentnym systemie nadzorującym cały proces a dostępne prace skupiają się na wybranych etapach lub technologiach.

Dużą uwagę poświęca się wykorzystaniu **systemów wizyjnych** do kontroli jakości opakowań i etykiet na liniach konfekcjonowania. Już konwencjonalne rozwiązania oparte o czujniki wizyjne i kamery znacząco podniosły skuteczność wykrywania wad opakowań w porównaniu do kontroli manualnej. Przykładowo, (Połomski, 2016) opisał wdrożenie zautomatyzowanej kontroli etykiet w przemyśle farmaceutycznym, gdzie system wizyjny weryfikował poprawność etykiet (m.in. poprzez odczyt kodu kreskowego Pharmacode lub kodu EAN-13), sprawdzał nadruk daty ważności i numeru serii oraz obecność etykiety na każdym opakowaniu. Rozwiązanie to, bazujące na zintegrowanych czujnikach wizyjnych, zapewniło zgodność procesu etykietowania z wymogami GMP i wyeliminowało

wiele błędów ludzkich. W ostatnich latach do kontroli opakowań coraz śmielej wkraczają metody **głębokiego uczenia** i zaawansowane algorytmy analizy obrazu, które znacząco zwiększają zakres i precyzję wykrywania defektów. Banús i in. (2021) opracowali system wizyjny do inspekcji zamknięcia i zgrzeiny opakowań pizzy, wykorzystujący sieci konwolucyjne (ResNet) do klasyfikacji poprawności każdej tacki. Dzięki temu rozwiązaniu możliwa stała się **automatyczna kontrola 100% opakowań w linii**, osiągając przy tym precyzję wykrywania wad na poziomie ~99,8% oraz dwukrotnie większą przepustowość inspekcji w porównaniu z pracą manualną. Podobne wyniki uzyskano w branży farmaceutycznej, gdzie badacze zaproponowali system oparty na ulepszonym algorytmie detekcji YOLOv8 do kontroli blistrów z tabletkami. Uzyskano skuteczność mAP rzędu 97,4% przy prędkości ~79 klatek/s, co przewyższa osiągi wcześniejszych modeli i umożliwia wychwytywanie wad (np. brakujących lub uszkodzonych tabletek) w czasie rzeczywistym (Vijayakumar i in., 2024). Takie rozwiązanie, określone jako CBS-YOLOv8, dzięki ulepszonej ekstrakcji cech i optymalizacji obliczeń potrafi szybciej i dokładniej identyfikować defekty blistrów, usprawniając system zapewnienia jakości na liniach pakujących leki. Należy podkreślić, że systemy oparte na wizji maszynowej, zwłaszcza w połączeniu z AI pozwalają wykrywać szerokie spektrum nieprawidłowości: od brakującej etykiety lub krzywo naklejonej naklejki, przez nieszczelną zgrzeinę folii, aż po drobne uszkodzenia produktu. Ograniczeniem pozostaje jednak konieczność zgromadzenia odpowiednich danych treningowych i dostosowania algorytmu do warunków konkretnej linii (oświetlenie, szybkość podajników itp.), a integracja takiego systemu z istniejącą infrastrukturą sterującą bywa wyzwaniem inżynierskim.

Kolejnym nurtem badań jest **analiza danych procesowych i predykcja występowania niezgodności** z użyciem sztucznej inteligencji. Zamiast reagować na wykryte wady po fakcie, celem tych rozwiązań jest wcześniejsze przewidywanie, kiedy produkt lub partia może okazać się niezgodna, lub kiedy nastąpi awaria urządzenia pakującego. W literaturze pojawiają się pierwsze próby wykorzystania uczenia maszynowego do bieżącej analizy parametrów procesu konfekcjonowania. Przykładowo, Antony (2024) zaprezentował hybrydowe podejście, w którym model logistic regression szacuje prawdopodobieństwo wystąpienia wady produktu na podstawie danych historycznych, zaś model lasu losowego (random forest) klasyfikuje typ wykrytej niezgodności. Połączenie tych dwóch technik pozwoliło znacząco poprawić skuteczność identyfikacji wadliwych jednostek produkcji. Co istotne, rozwiązanie to wykorzystuje dane z czujników linii i urządzeń IoT w czasie rzeczywistym, umożliwiając automatyczne monitorowanie procesu i korygowanie ustawień zanim powstaną braki. Również w obszarze **predykcyjnego utrzymania ruchu** odnotowuje się wdrożenia dotyczące linii pakujących. Dzięki czujnikom IoT mierzącym m.in. drgania, temperatury i obciążenia maszyn, dane te analizowane są przez algorytmy ML w poszukiwaniu subtelnych oznak zużycia lub rozkalibrowania urządzeń. Jak podaje **raport PMMI** przytoczony przez Egan (2023), systemy AI potrafią wykryć anomalie takie jak wzrost wibracji czy drobne odchyłki wymiarów opakowań i przewidzieć awarię zanim do niej dojdzie, co minimalizuje nieplanowane przestoje i poprawia OEE. Zastosowania AI w konfekcjonowaniu obejmują ponadto analizy danych łańcucha dostaw, optymalizację planowania

produkcji oraz personalizację opakowań pod gusta klientów. Wdrożenia te napotykają jednak pewne wyzwania, na które zwracają uwagę zarówno badacze, jak i praktycy przemysłowi. Jednym z głównych problemów jest zarządzanie dużymi strumieniami danych generowanymi przez czujniki i systemy. Wymaga to solidnej infrastruktury IT oraz zaawansowanych narzędzi analitycznych, aby z danych tych wydobyć użyteczne wnioski. Ponadto konieczne jest posiadanie wyspecjalizowanej kadry zdolnej do obsługi i interpretacji systemów AI, co oznacza potrzebę szkoleń lub zatrudnienia nowych ekspertów. Inną barierą bywa integracja różnych źródeł danych (np. wagi, kamery, sterowniki PLC różnych producentów) i zapewnienie ich spójności. Brak jednolitych standardów komunikacyjnych utrudnia tworzenie jednego, centralnego systemu nadzoru.

W Tabeli 2.6 przedstawiono syntetyczny przegląd metod nadzorowania stosowanych w procesach konfekcjonowania, obejmujący kontekst ich zastosowania, uzyskane rezultaty, a także zidentyfikowane ograniczenia. Zestawienie to pozwala uchwycić różnorodność podejść od metod organizacyjnych, poprzez rozwiązania statystyczne i systemowe, aż po techniki oparte na sztucznej inteligencji i wizji maszynowej oraz wskazuje na ich zalety i ograniczenia w praktyce przemysłowej.

Tabela 2.6. Przegląd metod oraz narzędzi nadzorowania procesów konfekcjonowania w literaturze.

Metoda / narzędzie	Obszar	Najważniejsze wyniki	Ograniczenia / problemy	Źródło
Lean (VSM, Kanban, SMED)	Etykietowanie i pakowanie	Spadek lead time ok. 7%; spadek reklamacji klientów ok. 83%	Metoda organizacyjna (brak nadzoru jakości w czasie rzeczywistym i predykcji); zależność od kultury/zaangażowania	Habib, Rizvan, Ahmed (2023)
Lean + TPM	Pakowanie produktów rolnych	Wzrost produktywności; poprawa wskaźników (przestoje, braki)	Skupienie na eliminacji marnotrawstwa, nie na analityce online; wymagane trwałe zmiany organizacyjne	Farah-Alva, Montaño-Va ez, Quiroz-Flors (2024)
IIoT + metodyka Kata	Linia montażowo-pakująca	Wzrost produktywności dzięki cyfrowemu monitorowaniu	Odcinkowe wdrożenie; brak pełnej integracji z modułami QC i predykcją	Sundar, Chowdhury, Kamarthi (2024)
Analiza statystyczna (regresja, testy nieparametryczne)	Dozowanie/naważanie składników	Wykryte istotne odchylenia mas; wskazanie komponentu o największym błędzie	Ograniczona dokładność urządzeń; brak nadzoru online	Matuszek, Opolska (2012)
Algorytm doboru kombinacji (naważarka wielogłowicowa 2-warstw)	Porcjowanie	Spadek wariancji masy porcji; wzrost przepustowości	Metoda dedykowana do konkretnej architektury naważarki	García-Jiménez, García-Díaz, Pulido-Rojano (2021)
Sieć neuronowa	Napełnianie kapsułek	Wysoka dokładność modelu $R^2 > 0,95$;	Dane najczęściej offline; brak pełnej integracji in-line	Barmpalexis i in. (2020)

Regulator rozmyto-neuronowy	Rozlew piwa	Spadek maks. odchylenie do ~1,7 g; wzrost precyzji ~+50%; spadek czasu reakcji ~55%	Wymaga strojenia i stabilnych warunków; studium przypadku	Liu (2022)
System wizyjny (czujniki + OCR/kody)	Etykietowanie	Automatyczna weryfikacja obecności/zgodności etykiet; redukcja błędów ludzkich	Bez DL; dostrajanie do SKU/warunków oświetlenia	Połomski (2016)
Głębokie uczenie (CNN/ResNet) + 3 kamery	Inspekcja zgrzewu/opakowań	Skuteczność ~99,8%; ~2× większa przepustowość vs. inspekcja manualna	Duże zbiory etykietowanych danych; dostrajanie do produktu	Banús i in. (2021)
Detekcja obiektów (CBS-YOLO v8)	Blistry farmaceutyczne	mAP ~97,4%; ~79 FPS (real-time)	Potrzeba danych treningowych; adaptacja do linii/produktów	Vijayakumar i in. (2024)
Model hybrydowy: Logistic Regression + Random Forest	Predykcja niezgodności	Lepsza identyfikacja wadliwych jednostek; monitoring online	Potrzeba walidacji przemysłowej; integracja danych z wielu źródeł	Akisetty, Ayyagari (2024)
AI do wykrywania anomalii (analiza wibracji/wymiarów)	Predykcyjne UR w liniach pakujących	Wczesne ostrzeżenie o awariach; poprawa OEE	Raport branżowy, uogólnienia	Egan (2023)
Predykcyjne utrzymanie ruchu (IoT + ML)	Linie produkcyjne/pakujące	Skuteczne przewidywanie awarii; planowanie serwisu; spadek przestoju	Wysokie wymagania dot. danych i integracji IIoT	Ayvaz, Alpay (2021)
„Smart Quality” (IoT + AI + analityka)	Pakowanie	Uzasadnia QC w czasie rzeczywistym; przegląd metod i wdrożeń	Luka wdrożeniowa: brak architektur end-to-end	Sundaram, Zeid (2023)

SCADA dla linii HFFS (MAP)	Pakowanie żywności (świeże warzywa)	Sterowanie/monitoring parametrów (temp. zgrzewu, gaz, prędkość); wzrost elastyczności, spadek błędów operatorów	Wdrożenie case-study; wymagania integracyjne	Seifi i in. (2023)
----------------------------	-------------------------------------	---	--	--------------------

Opracowanie własne na podstawie: Antny i in., 2024; Ayvaz i in., 2021; Banus i in., 2021; Barmpalexis i in., 2020; García-Jiménez, 2021; Liu, 2022; Matuszek, 2012; Połomski, 2016; Seifi i in., 2023; Sundaram i in., 2023; Vasuki i in., 2023.

Mimo opisanych postępów **nadal brakuje w literaturze spójnych rozwiązań obejmujących kompleksowe nadzorowanie całego procesu konfekcjonowania** jako systemu. Większość prac skupia się na wybranych etapach lub pojedynczych zadaniach np. kontrola wizyjna opakowań, predykcja awarii maszyny pakującej albo monitorowanie dokładności naważania i często prezentowana jest w formie studium przypadku bądź symulacji laboratoryjnej. Stwierdza się wręcz, że brakuje opracowań integrujących **ważenie, dozowanie, pakowanie, etykietowanie i kontrolę jakości** w jeden skoordynowany system, zdolny do działania w rzeczywistych warunkach produkcyjnych. Dotyczy to zwłaszcza średnich i małych przedsiębiorstw, gdzie zmienność asortymentu, ograniczona powtarzalność procesów oraz mieszana infrastruktura technologiczna stanowią dodatkowe utrudnienie. Powyższe obserwacje pozwalają identyfikować potrzebę prowadzenia badań nad opracowaniem metodycznych zasad projektowania i wdrażania systemów nadzorowania procesu konfekcjonowania, które mogą być elastycznie adaptowane do różnych środowisk produkcyjnych. Integracja różnorodnych metod (czujniki masy, systemy wizyjne, analityka danych) w jedną inteligentną platformę pozwala nie tylko eliminować poszczególne błędy, lecz również osiągać efekt synergii, w którym informacje z jednego etapu (np. wahań masy porcji) mogą automatycznie wpływać na decyzje na kolejnych etapach (np. dostosowanie prędkości pakowania czy wygenerowanie alarmu do prewencyjnej regulacji maszyny). W konsekwencji, dotychczasowe prace stanowią cenne punkty odniesienia i pokazują możliwości zastosowania metod i narzędzi AI w nadzorze produkcji, jednak **żadne nie rozwiązuje w pełni problemu kompleksowego nadzorowania procesu konfekcjonowania**, co uzasadnia podjęcie badań w tym kierunku.

2.2.4. Integracja i perspektywy rozwoju systemów nadzorowania procesu konfekcjonowania

Jednym z kluczowych wyzwań w nadzorowaniu całego procesu konfekcjonowania jest obecnie integracja zróżnicowanych źródeł danych i narzędzi. Linie pakujące generują informacje z wielu urządzeń, które często działają w odrębnych obszarach technologicznych. Brak ujednoliconych standardów komunikacji i interoperacyjności sprawia, że łączenie tych danych w spójny obraz procesu bywa utrudnione (Ji i in., 2025). Raporty branżowe wskazują, że trudności z integracją danych z różnych źródeł należą do najczęściej wymienianych barier we wdrażaniu inteligentnych rozwiązań, obok braku odpowiednio wykwalifikowanego personelu oraz problemów z infrastrukturą informatyczną.

Konsekwencją jest rozproszenie narzędzi analitycznych i nadzorczych: np. osobne aplikacje do monitorowania stanu maszyn, oddzielne systemy kontroli jakości oraz niezintegrowane moduły raportowania. W efekcie zarządzanie procesem konfekcjonowania jako całością jest mało efektywne, gdyż informacje o odchyleniach czy awariach nie przepływają swobodnie między warstwami produkcyjnymi. W literaturze podkreśla się, że dopiero ścisła współpraca wszystkich poziomów od urządzeń na hali po systemy MES/ERP umożliwia pełne wykorzystanie danych procesowych w decyzjach operacyjnych. Mimo to kompleksowa integracja nadal stanowi wyzwanie, a wiele proponowanych rozwiązań ma charakter wyspowy lub prototypowy (Mantravadi i in., 2023).

Patrząc perspektywicznie, integracja systemów nadzorujących konfekcjonowanie wpisuje się w szersze koncepcje Przemysłu 5.0, kładące nacisk na synergiczną współpracę człowieka z maszyną oraz zrównoważony rozwój produkcji. Oznacza to, że przyszłe systemy nadzoru będą projektowane nie tylko pod kątem automatyzacji, ale też „human-centric” uwzględniając rolę operatorów jako nadzorców i beneficjentów informacji. Przemysł 5.0 zakłada łączenie kreatywności i wiedzy eksperckiej ludzi z możliwościami sztucznej inteligencji i robotyki, co ma przynieść wyższy poziom personalizacji produktów oraz elastyczności procesów (Stall, 2025). W kontekście konfekcjonowania oznacza to zdolność szybkiego przezbrownienia linii i dostosowania parametrów pakowania do indywidualnych zamówień czy preferencji klienta. Już dziś w branży e-commerce obserwuje się trend „mass customization” opakowań, gdzie zintegrowane linie potrafią automatycznie dopasować format pudełka, nadruk etykiety czy dołożenie materiałów marketingowych pod konkretny produkt lub odbiorcę. Wymaga to jednak ścisłego powiązania systemu pakowania z danymi z poziomu zamówień i modułami wykonawczymi. W literaturze wskazuje się na potrzebę takiej integracji: przyszłe linie powinny charakteryzować się personalizacją i elastycznością pakowania oraz integracją z automatycznymi sorterami i systemami etykietującymi sterowanymi danymi z systemów ERP (Pavel i in., 2024). Równie istotny jest wymiar zrównoważonego rozwoju. Zintegrowane systemy nadzorujące mogą przyczynić się do ograniczenia marnotrawstwa materiałów opakowaniowych i energii. Poprzez ciągłe monitorowanie parametrów procesu i szybką identyfikację odchyleń, zmniejsza się odsetek wadliwych lub nadmiernie zużywających surowce opakowań. Trend ten współgra z ideą gospodarki o obiegu zamkniętym, gdzie minimalizacja odpadów i optymalizacja zużycia materiałów staje się priorytetem. System nadzorowania przyszłości mógłby np. dynamicznie dostosowywać ustawienia maszyn pakujących, by zapewnić jak najmniejsze zużycie folii przy zachowaniu wymaganej jakości zabezpieczenia produktu (Turner i in., 2022). Takie podejście nie tylko obniża koszty i wpływ środowiskowy, ale też wpisuje się w rosnące oczekiwania społeczne wobec zielonych technologii w przemyśle.

Podsumowując, integracja systemów nadzorowania procesu konfekcjonowania staje się warunkiem koniecznym dla osiągnięcia w pełni inteligentnych i efektywnych linii produkcyjnych. W literaturze odnotowuje się wprawdzie liczne obiecujące rezultaty cząstkowe, od zaawansowanych systemów wizyjnej kontroli jakości po platformy predykcyjnej konserwacji, jednak brak wciąż kompleksowych rozwiązań integrujących te elementy w jednolity ekosystem działający w warunkach przemysłowych.

Wielu autorów podkreśla potrzebę dalszych badań ukierunkowanych na holistyczne ujęcie nadzoru produkcji, ze szczególnym naciskiem na pełną integrację nowych technologii z istniejącą infrastrukturą fabryczną. Fakt ten potwierdza słuszność kierunku przyjętego w niniejszej rozprawie, czyli dążenie do opracowania własnego, zintegrowanego systemu nadzorowania procesu konfekcjonowania jest odpowiedzią na zidentyfikowaną lukę i stanowi próbę połączenia rozproszonych dotąd funkcji monitorowania, kontroli i analizy w jedno spójne rozwiązanie. Dzięki temu możliwe będzie nie tylko zweryfikowanie koncepcji przedstawianych w literaturze, ale przede wszystkim praktyczne sprawdzenie ich skuteczności w warunkach rzeczywistej linii pakującej.

2.3. Podsumowanie stanu wiedzy

W wyniku badań nad teoretycznymi aspektami związanymi z tematem pracy **przedstawiono i usystematyzowano** kluczowe zagadnienia związane z inteligentnym nadzorowaniem procesów produkcyjnych: od **ewolucji podejścia do nadzoru** (od rozwiązań manualnych do koncepcji Przemysłu 5.0), przez determinanty skuteczności, po funkcje nowoczesnych systemów, wspierające je technologie oraz architekturę warstwową poszerzoną o komponenty AI i moduły decyzyjne. Uporządkowano metody oceny skuteczności i wskaźniki KPI, które tworzą spójny aparat pomiarowy dla wydajności, jakości, niezawodności i ekonomiki procesów. Następnie skoncentrowano się na procesie konfekcjonowania, charakteryzując jego znaczenie, typowe wyzwania, praktykowane metody nadzoru oraz perspektywy integracji.

Podsumowując przeprowadzony w rozdziale drugim przegląd aktualnego stanu wiedzy, można zauważyć, iż pomimo wyraźnego rozwoju metod i systemów nadzorowania nadal brakuje jednoznacznych rozwiązań w zakresie **kompleksowego nadzorowania**. Dotyczy to w szczególności **procesu konfekcjonowania**, gdzie złożoność technologiczna, wymogi jakościowe i presja czasu kumulują się w jednym, wrażliwym na zakłócenia fragmencie łańcucha wytwarzania. W tym świetle **identyfikacja ograniczeń i rozbieżności** między stanem badań a potrzebami przemysłu (w szczególności potrzeb przedsiębiorstwa będącego przedmiotem badań) stanowi niezbędny punkt wyjścia dla dalszych prac. Poniżej przedstawiono najistotniejsze ograniczenia obecnego stanu wiedzy, które wprost uzasadniają podjęcie prac badawczo-wdrożeniowych oraz przygotowanie niniejszej rozprawy doktorskiej, ukierunkowanych na opracowanie i implementację inteligentnego systemu nadzorowania procesu konfekcjonowania:

1. Ograniczone podejście do procesu konfekcjonowania w literaturze naukowej. Zdecydowana większość publikacji traktuje pojedyncze operacje (np. naważanie, pakowanie, etykietowanie) jako byty odrębne, bez ujęcia całego procesu konfekcjonowania jako spójnego systemu technologicznego ze sprzężeniami między operacyjnymi. Skutkuje to brakiem modeli integrujących przepływ informacji i decyzji między operacjami oraz utratą możliwości oceny synergii i kumulacji błędów na kolejnych etapach.

2. Dominacja rozwiązań teoretycznych i symulacyjnych nad badaniami wdrożeniowymi.

W licznych pracach prezentowane są wyniki na danych laboratoryjnych lub syntetycznych albo studia przypadków. Rzadkością są wdrożenia „end-to-end” w warunkach przemysłowych dla złożonych linii konfekcjonujących, uwzględniające zmienność SKU, przebrojenia, zróżnicowane źródła danych oraz ograniczenia komunikacyjne i czasowe. To utrudnia ocenę transferowalności i trwałości efektów.

3. Dla podobnych problemów istnieje wiele propozycji rozwiązań pozytywnie zweryfikowanych, lecz brak podejścia integrującego lub wskazówek co do optymalnego wyboru narzędzi i metod.

Dojrzałe rozwiązania cząstkowe (np. algorytmy doboru kombinacji w naważarkach, systemy wizyjne z DL do inspekcji zgrzewu, modele ML dla predykcyjnego UR) wskazują na potencjał technologiczny, jednak funkcjonują zwykle w izolacji. Brakuje architektur łączących akwizycję, analitykę i sterowanie z poziomu całego procesu, a nie pojedynczej maszyny lub operacji.

Powyższe ograniczenia wzmacniają znaczenie szeregu problemów praktycznych, które uwypuklają lukę między koncepcją a fabryką. Niska jakość, niejednorodność i niesynchronizowanie danych z urządzeń wagowych, systemów wizyjnych, czujników procesowych i sterowników PLC utrudniają budowę niezawodnych modeli ML/DL, szczególnie tam, gdzie występują rzadkie zdarzenia (np. mikronieszczelności, defekty etykiet, sporadyczne awarie). Integracja i interoperacyjność warstw napotyka bariery protokołów komunikacyjnych, formatów danych i spójności semantycznej, a także na wymogi deterministycznego działania w czasie rzeczywistym, co jest krytyczne przy inspekcji 100% strumienia i podejmowaniu decyzji „online”.

Dodatkowym utrudnieniem jest zmienność procesu wynikająca z częstych przebrojeń i różnorodności formatu opakowań, bez kompleksowego zarządzania recepturami (parametry/tolerancje procesu), i walidacji nastaw po zmianach konfiguracji trudno o stabilność i powtarzalność. Nie bez znaczenia pozostają kwestie organizacyjne jak niedobór kompetencji integracyjnych i analitycznych, konieczność rozwoju ról i procedur a także zaufanie operatorów do systemów AI. Algorytmy postrzegane jako „czarne skrzynki” wymagają przejrzystych mechanizmów wyjaśniania, audytowalności i nadzoru nad cyklem życia modeli zaś integracja technologii operacyjnych z sieciami IT rodzi nowe wymagania w zakresie cyberbezpieczeństwa i traceability.

Ważnym aspektem jest również niedojrzałość infrastruktury integracyjnej. Raporty branżowe wskazują, że choć aż 89% firm produkcyjnych uznaje AI za kluczowy element transformacji cyfrowej, to jedynie około 16% osiągnęło zamierzone rezultaty wdrożenia co potwierdza skalę luki (Windmann i in., 2024). Najczęściej wskazywane bariery to trudności z integracją danych z różnych źródeł, brak odpowiednio przeszkolonego personelu oraz wyzwania związane z bezpieczeństwem informacji i cyberbezpieczeństwem systemów produkcyjnych. Na to wszystko nakłada się konieczność wykazania mierzalnych korzyści w relacji do nakładów. Wdrożenia systemów nadzorowania powinny być uzasadnione istotną, statystycznie potwierdzoną poprawą wskaźników OEE, FPY, DPMO, MTBF/MTTR, scrap, COPQ, OTD czy CCR/RCR, z równoległą analizą controllingową i ujęciem

kosztu jakości. Praktyka pokazuje również niedobór elastycznych rozwiązań „plug-and-play”, zdolnych do pracy w zróżnicowanych warunkach produkcyjnych bez kosztownej personalizacji; ryzyko uzależnienia od dostawcy i rosnące całkowite koszty posiadania dodatkowo zwiększają próg wejścia dla przedsiębiorstw, zwłaszcza MŚP.

W konsekwencji przedstawione ograniczenia i wyzwania wskazują, że choć literatura dostarcza wielu przykładów częściowych rozwiązań, brak jest ustalonej metodyki pozwalającej na budowę kompleksowych systemów nadzorowania procesu konfekcjonowania. Każdorazowe wdrożenie wymaga zatem przeprowadzenia działań badawczych dostosowanych do specyfiki danego zakładu oraz doboru odpowiednich narzędzi i metod, co pozwala na identyfikację krytycznych parametrów technologicznych, określenie ich wartości granicznych oraz walidację skuteczności proponowanych rozwiązań w rzeczywistych warunkach przemysłowych.

W przypadku przedsiębiorstwa Mróz S.A. uzasadnieniem podjęcia prac są konkretne problemy procesowe i związane z nimi straty. Celem rozprawy doktorskiej jest wykorzystanie dostępnej wiedzy naukowej i technologicznej do opracowania oraz wdrożenia inteligentnego systemu nadzorowania zautomatyzowanego procesu konfekcjonowania w tym właśnie przedsiębiorstwie. Projektowany system ma umożliwiać:

- wczesne wykrywanie nieprawidłowości w przebiegu procesu,
- stabilizację i kontrolę parametrów operacyjnych,
- bieżącą ocenę krytycznych charakterystyk jakościowych,
- wsparcie decyzyjne operatorów i personelu technicznego.

3. Koncepcja i projekt systemu

3.1. Środowisko wdrożeniowe

Aby możliwe było skuteczne zaprojektowanie i implementacja inteligentnego systemu nadzorowania, konieczne stało się szczegółowe rozpoznanie uwarunkowań techniczno-organizacyjnych przedsiębiorstwa oraz diagnoza stanu wyjściowego procesu konfekcjonowania.

Prace badawczo-wdrożeniowe prowadzone były w zakładzie produkcyjnym **Foodmakers Sp. z o.o.**, należącym do **Grupy Kapitałowej Mróz S.A.** (Rysunek 3.1). Obiekt zlokalizowany jest w nowoczesnym kompleksie spełniającym standardy jakościowe, takie jak **BRC** i **IFS**. Organizacja przedsiębiorstwa oparta jest na klasycznej strukturze funkcjonalnej, obejmującej działy: produkcji, utrzymania ruchu, jakości, zakupów, R&D oraz IT.

W niniejszym podrozdziale przedstawiono **środowisko wdrożeniowe** systemu, obejmujące aspekty techniczne, organizacyjne oraz jakościowe, które determinują przebieg dalszych prac badawczo-wdrożeniowych. Przede wszystkim przedstawiono proces, który będzie nadzorowany, infrastrukturę linii technologicznej, identyfikację barier technicznych i organizacyjnych, a także analizę danych historycznych obejmujących awarie, zakłócenia i reklamacje, które pozwoliły ukazać skalę i wagę problemów występujących w procesie konfekcjonowania. Zebrane informacje stanowiły punkt odniesienia dla opracowania koncepcji oraz architektury systemu.



Rysunek 3.1. Zakład produkcyjny Foodmakers Sp. z o.o. (Grupa Mróz S.A.) (dane udostępnione przez przedsiębiorstwo).

0.24 Pom. produkcji kanapek
227,9m² żywnia epoksydowa cleanroom

0.26 Pom. pomocnicze
9,2m² żywnia epoksydowa cleanroom

0.27 Pom. pomocnicze
29,9m² żywnia epoksydowa cleanroom

0.34 Słuzka
24,6m² żywnia epoksydowa cleanroom

0.35 Pom. produkcji dań gotowych
345,4m² żywnia epoksydowa cleanroom

Linia 2 - Mix kanapkowy

Waga kontrolna

Flowpack

Unifilter

Uzupełnianie sosu

Stanowisko zawijania Wrapsów

5-01

0.31

0.32

0.33

0.34

0.35

0.36

0.37

0.38

0.39

0.40

0.41

0.42

0.43

0.44

0.45

0.46

0.47

0.48

0.49

0.50

0.51

0.52

0.53

0.54

0.55

0.56

0.57

0.58

0.59

0.60

0.61

0.62

0.63

0.64

0.65

0.66

0.67

0.68

0.69

0.70

0.71

0.72

0.73

0.74

0.75

0.76

0.77

0.78

0.79

0.80

0.81

0.82

0.83

0.84

0.85

0.86

0.87

0.88

0.89

0.90

0.91

0.92

0.93

0.94

0.95

0.96

0.97

0.98

0.99

1.00

1.01

1.02

1.03

1.04

1.05

1.06

1.07

1.08

1.09

1.10

1.11

1.12

1.13

1.14

1.15

1.16

1.17

1.18

1.19

1.20

1.21

1.22

1.23

1.24

1.25

1.26

1.27

1.28

1.29

1.30

1.31

1.32

1.33

1.34

1.35

1.36

1.37

1.38

1.39

1.40

1.41

1.42

1.43

1.44

1.45

1.46

1.47

1.48

1.49

1.50

1.51

1.52

1.53

1.54

1.55

1.56

1.57

1.58

1.59

1.60

1.61

1.62

1.63

1.64

1.65

1.66

1.67

1.68

1.69

1.70

1.71

1.72

1.73

1.74

1.75

1.76

1.77

1.78

1.79

1.80

1.81

1.82

1.83

1.84

1.85

1.86

1.87

1.88

1.89

1.90

1.91

1.92

1.93

1.94

1.95

1.96

1.97

1.98

1.99

2.00

2.01

2.02

2.03

2.04

2.05

2.06

2.07

2.08

2.09

2.10

2.11

2.12

2.13

2.14

2.15

2.16

2.17

2.18

2.19

2.20

2.21

2.22

2.23

2.24

2.25

2.26

2.27

2.28

2.29

2.30

2.31

2.32

2.33

2.34

2.35

2.36

2.37

2.38

2.39

2.40

2.41

2.42

2.43

2.44

2.45

2.46

2.47

2.48

2.49

2.50

2.51

2.52

2.53

2.54

2.55

2.56

2.57

2.58

2.59

2.60

2.61

2.62

2.63

2.64

2.65

2.66

2.67

2.68

2.69

2.70

2.71

2.72

2.73

2.74

2.75

2.76

2.77

2.78

2.79

2.80

2.81

2.82

2.83

2.84

2.85

2.86

2.87

2.88

2.89

2.90

2.91

2.92

2.93

2.94

2.95

2.96

2.97

2.98

2.99

3.00

3.01

3.02

3.03

3.04

3.05

3.06

3.07

3.08

3.09

3.10

3.11

3.12

3.13

3.14

3.15

3.16

3.17

3.18

3.19

3.20

3.21

3.22

3.23

3.24

3.25

3.26

3.27

3.28

3.29

3.30

3.31

3.32

3.33

3.34

3.35

3.36

3.37

3.38

3.39

3.40

3.41

3.42

3.43

3.44

3.45

3.46

3.47

3.48

3.49

3.50

3.51

3.52

3.53

3.54

3.55

3.56

3.57

3.58

3.59

3.60

3.61

3.62

3.63

3.64

3.65

3.66

3.67

3.68

3.69

3.70

3.71

3.72

3.73

3.74

3.75

3.76

3.77

3.78

3.79

3.80

3.81

3.82

3.83

3.84

3.85

3.86

3.87

3.88

3.89

3.90

3.91

3.92

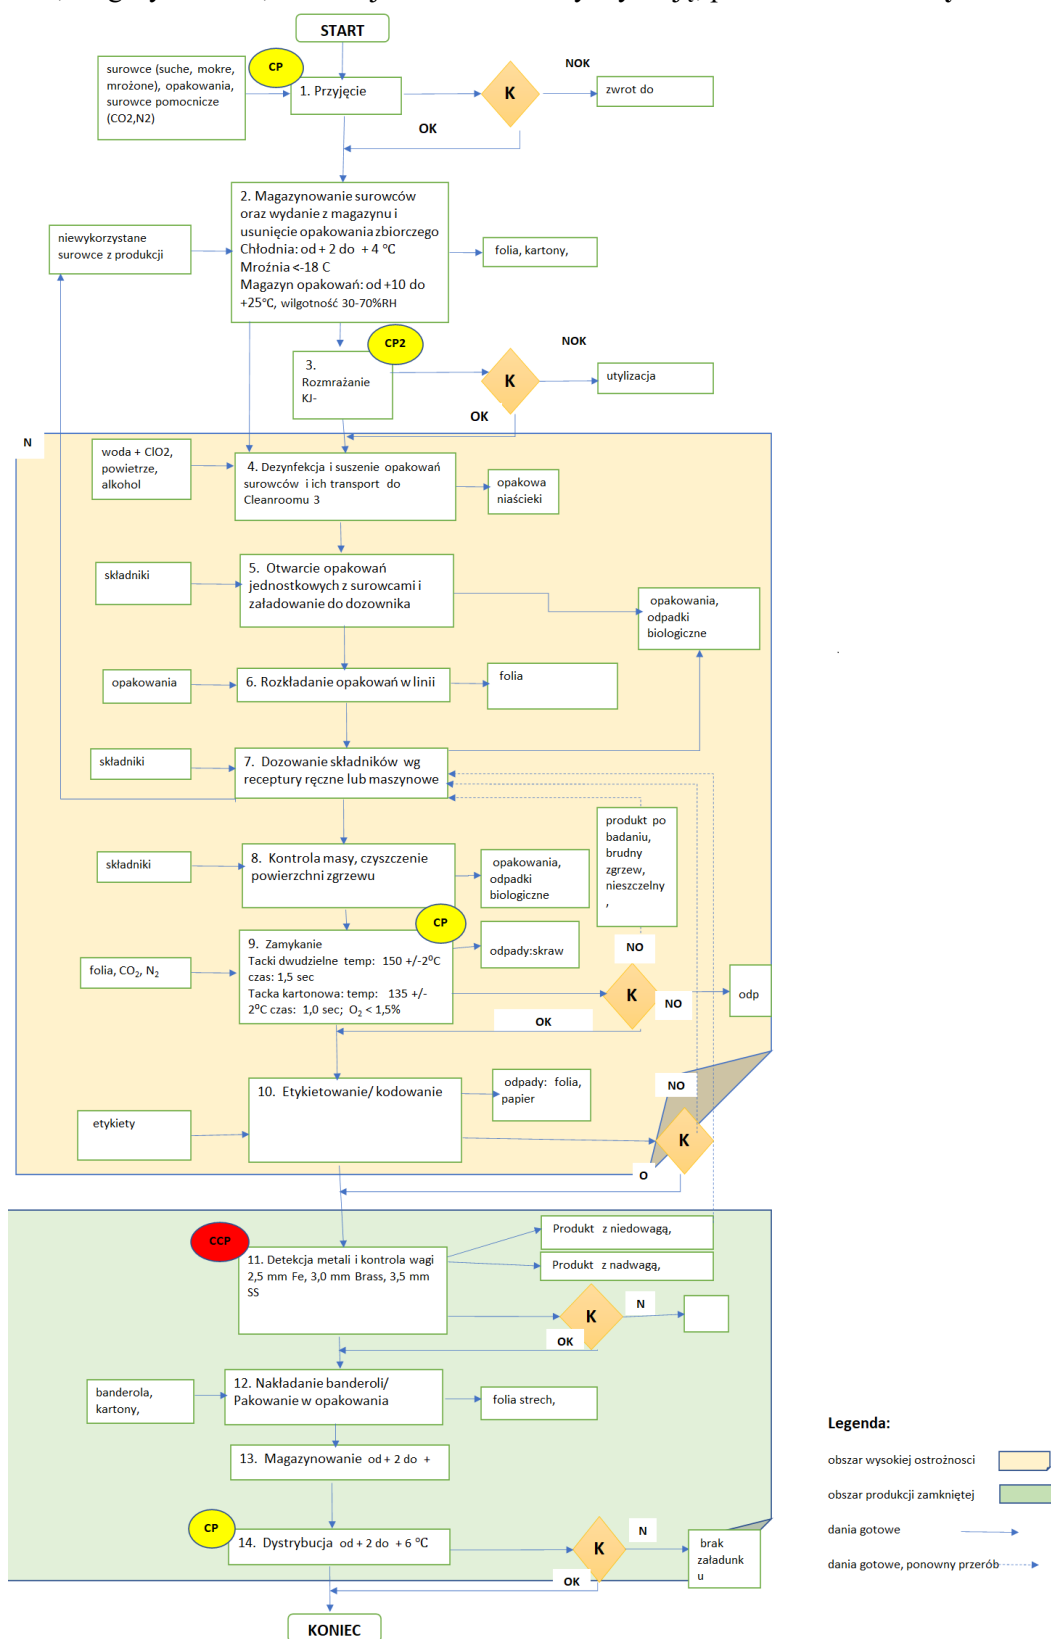
3.93

3.94

3.9


49

Schemat przebiegu procesu produkcyjno-logistycznego w badanym zakładzie, obejmujący przyjęcie surowców, magazynowanie, konfekcjonowanie oraz dystrybucję, przedstawiono na **Rysunku 3.3**.



Rysunek 3.3. Schemat przebiegu procesu produkcyjno-logistycznego w zakładzie – stan wyjściowy (2021 r.) (dane udostępnione przez przedsiębiorstwo).

W momencie rozpoczęcia prac badawczo-wdrożeniowych linia produkcyjna była wyposażona w zestaw maszyn i stanowisk technologicznych tworzących kompletny układ do realizacji procesu konfekcjonowania (**Rysunek 3.4**). Numeracja przedstawiona na rysunku odpowiada kolejno opisanym niżej stanowiskom oraz urządzeniom.



Rysunek 3.4. Schemat linii konfekcjonowania z oznaczeniem urządzeń i stanowisk (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

1. **Półautomatyczna maszyna podająca puste opakowania** na linię produkcyjną,
2. **Półautomatyczny dozownik sosów**,
3. **Wagi i miarki tradycyjne**, stosowane do ręcznego naważania składników,
4. **Automatyczna maszyna pakująca typu tray sealer**, pracująca w technologii MAP,
5. **Automatyczne urządzenie drukująco-etykietujące**, służące do nanoszenia danych identyfikacyjnych na opakowania,
6. **Stanowiska kontrolne** przeznaczone do badań zawartości tlenu w opakowaniach oraz prowadzenia dokumentacji jakościowej,
7. **Detektor metali** pełniący funkcję końcowej kontroli bezpieczeństwa wyrobu.

Wszystkie elementy linii były zintegrowane w jeden układ transportowy, zapewniający ciągłość przepływu opakowań i wyrobów pomiędzy poszczególnymi stanowiskami. W stanie wyjściowym część operacji realizowano manualnie, a dane procesowe nie były gromadzone w sposób zcentralizowany. Wstępna analiza przebiegu procesu pozwoliła wskazać trzy operacje o szczególnym znaczeniu dla jakości i stabilności produkcji: **naważanie, pakowanie i etykietowanie**. Zostały one potraktowane jako obszary priorytetowe do dalszej weryfikacji w ramach analizy danych historycznych.

W analizowanym okresie (2021-2022) istotnym aspektem środowiska wdrożeniowego, były także uwarunkowania **techniczne** i **organizacyjne**. Po stronie **technicznej** do najważniejszych czynników należały ograniczony dostęp do danych procesowych oraz brak otwartych interfejsów komunikacyjnych w części maszyn, w tym w szczególności w maszynie pakującej typu tray sealer. W zakładzie funkcjonował system klasy ERP, stosowany głównie w obszarach administracyjnych, jednak nie był on

powiązany z poziomem produkcyjnym. Dodatkowym ograniczeniem była infrastruktura serwerowa, która nie pozwalała na pełną archiwizację większych wolumenów danych procesowych. Po stronie **organizacyjnej** wyzwaniem był niedobór specjalistów z obszaru automatyki, IT i utrzymania ruchu, co skutkowało koniecznością angażowania zespołów operacyjnych oraz korzystania ze wsparcia firm zewnętrznych w zakresie bardziej zaawansowanych działań. Na przebieg prac badawczo-wdrożeniowych wpływały także czynniki zewnętrzne, w tym pandemia COVID-19, która spowodowała czasowe wstrzymanie eksploatacji linii.

Kolejnym elementem diagnozy środowiska wdrożeniowego była **analiza danych historycznych** dotyczących awarii oraz reklamacji (wewnętrznych i zewnętrznych). Zestawienia z lat 2021–2022 pozwoliły zidentyfikować powtarzalne zdarzenia techniczne oraz uchybienia organizacyjne, odczuwalne w trzech kluczowych obszarach operacyjnych. Poniżej (**Tabela 3.1**) zebrano najczęściej występujące przypadki wraz z opisem skutków.

Tabela 3.1. Najczęściej występujące zdarzenia techniczne w kluczowych operacjach procesu (2021–2022).

Lp.	Operacja	Rodzaj zdarzenia	Opis skutków
1	Naważanie	Rozszczelnienie układu dozującego	Niestabilna dawka surowca, konieczność dodatkowej kontroli masy
2	Etykietowanie	Spadek jakości nadruku etykiet (daty przydatności, numeru partii oraz kodów kreskowych)	Spadek czytelności nadruku daty przydatności; okresowo nieczytelne kody kreskowe, utrudnienia w identyfikacji numerów partii
3	Pakowanie	Uszkodzenie czujników położenia/obecności opakowań w maszynie pakującej	Przestoje linii w wyniku wyłączenia maszyny
4		Uszkodzenie czujników temperatury płyt grzewczych maszyny pakującej typu tray sealer	Niejednorodne zgrzeiny, powstawanie nieszczelności, opakowania z podwyższoną zawartością tlenu
5		Nadmierne podciśnienie w komorze pakującej	Deformacje opakowań, nieszczelności i zanieczyszczenia w obszarze zgrzeiny
6		Niesynchronizowane prędkości przenośników	Kolizja produktów i zakłócenia przepływu w procesie

Opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo.

Obok zdarzeń technicznych istotnym źródłem problemów w badanym środowisku wdrożeniowym były także zakłócenia organizacyjne oraz błędy wynikające z obsługi linii produkcyjnej. Obejmowały one np. błędne nastawy maszyn, nieprawidłowe przebrojenia, problemy z konfiguracją urządzeń kontrolnych, zakłócenia w przepływie materiałów oraz błędy ewidencji. Zestawienie najczęściej rejestrowanych zakłóceń w latach 2021–2022 przedstawiono w **Tabeli 3.2**.

Tabela 3.2. Zakłócenia organizacyjne w kluczowych operacjach procesu (2021–2022).

Lp.	Operacja	Rodzaj zakłócenia	Opis przyczyn	Skutki
1	Naważanie	Błędy związane z ustawieniami dozowników i wag	Niewłaściwe przezbrowanie i nieprawidłowe nastawy parametrów dozowania.	Odchylenia masy jednostkowej, konieczność dodatkowych kontroli.
2	Etykietowanie	Niewłaściwa obsługa aplikatora etykiet i niestabilność HMI	Trudności w obsłudze panelu operatorskiego oraz okresowa niestabilność interfejsu HMI.	Brak nadruku kodów i danych, przerwy w etykietowaniu, ryzyko błędnej identyfikacji partii.
3		Błędne identyfikatory partii i daty trwałości	Nieprawidłowa konfiguracja pól na HMI mimo prawidłowego planu produkcji; brak kontroli dwustopniowej.	Partie z błędnym numerem i terminem trwałości, wykrycie dopiero na etapie zwolnienia jakościowego.
4	Pakowanie	Niestabilność procesu MAP po zmianach parametrów	Samodzielna zmiana temperatury grzewania i parametrów atmosfery ochronnej; niewystarczająca czystość tacek.	Deformacje opakowań, zanieczyszczenia w obszarze zgrzeiny, zmienna siła otwarcia opakowania, konieczność przepakowania partii.
5		Rozbieżności bilansu produkcyjnego przy zamknięciu partii	Błędy ewidencji i sumowania przy zakończeniu serii; brak integracji liczników i rejestru partii.	Nadwyżki lub braki względem planu, negatywna ocena klienta w przypadku braków.

Opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo.

Kolejną grupę problemów stanowiły reklamacje jakościowe, zgłaszane zarówno przez dział kontroli wewnętrznej, jak i przez odbiorców końcowych (zewnętrznych). Najczęściej powtarzające się typy reklamacji przyporządkowane do operacji realizowanych w procesie konfekcjonowania przedstawiono w Tabeli 3.3.

Tabela 3.3. Najczęściej występujące reklamacje jakościowe (2021–2022).

Lp.	Operacja	Rodzaj reklamacji	Opis przyczyn	Skutki
1	Naważanie	Niepełna zawartość wyrobu	Brak jednego lub kilku składników w daniu gotowym lub zaniżona wartość względem specyfikacji.	Reklamacje konsumenckie kierowane do sieci handlowych; dokumentacja zdjęciowa i oficjalne numery spraw.

2	Pakowanie	Szczelność i jakość opakowania	Nieszczelne opakowania powodujące zmiany organoleptyczne; zjawisko bombażu; wady zapachu i smaku przy zachowaniu terminu i warunków chłodniczych.	Wykrycie na etapie zwolnienia produktu, reklamacje klientów; część wyrobów zwrócona, ryzyko pogorszenia wizerunku marki.
3	Etykietowanie	Znakowanie i identyfikacja	Brak nadruku terminu przydatności do spożycia i numeru partii; błędne lub nieczytelne kody (EAN-13, GS1); nadruk przesunięty na obszar o niskim kontraście.	Reklamacje od odbiorców hurtowych i detalicznych; w jednym przypadku wycofanie partii z obrotu przez centrum logistyczne.

Opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo.

Skala reklamacji była znacząca. W 2021 roku ogólny wskaźnik reklamacji w przedsiębiorstwie, obejmujących zarówno obszary produkcji, logistyki, magazynowania, jak i dystrybucji, wyniósł **0,16%** przy założonym celu **0,01%**, co oznacza przekroczenie wartości docelowej szesnastokrotnie. W roku 2022, pomimo podjęcia działań doskonalących, wskaźnik spadł jedynie do **0,03%**, pozostając trzykrotnie powyżej limitu.

Na potrzeby szczegółowej oceny stanu wyjściowego procesu konfekcjonowania wykorzystano natomiast wskaźnik **DPMO (Defects Per Million Opportunities)**, definiowany jako liczbę defektów na milion szans, który pozwalał na precyzyjne monitorowanie jakości w poszczególnych operacjach procesu.

W ramach klasyfikacji źródeł niezgodności wyróżniono trzy główne kategorie DPMO:

- **DPMO – masa:** związane z operacją naważania,
- **DPMO – etykieta:** związane z operacją etykietowania,
- **DPMO – opakowanie:** związane z operacją pakowania

Analiza wykazała, że największy udział w ogólnym wskaźniku DPMO miały niezgodności związane z pakowaniem oraz etykietowaniem, przy mniejszym, choć nadal istotnym, udziale niezgodności w obszarze naważania (**Tabela 3.4**). Zidentyfikowane defekty skutkowały nie tylko stratami surowcowymi, lecz także konsekwencjami organizacyjnymi i ekonomicznymi, takimi jak zwiększone koszty kontroli wewnętrznej, dodatkowe audyty zewnętrzne czy konieczność realizacji działań korygujących.

Tabela 3.4. Zestawienie wskaźników DPMO w latach 2021–2022.

Kategoria DPMO	2021	2022
DPMO - masa	7,6	12,6
DPMO - etykieta	25,8	15,6
DPMO - opakowanie	27,4	37,9
DPMO - pozostałe	19,8	13,6
DPMO - ogółem	80,6	79,7

Opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo.

Kolejnym elementem diagnozy stanu wyjściowego była ocena podstawowych wskaźników operacyjnych, w tym wydajności procesu oraz możliwości wyznaczenia wskaźnika **OEE (Overall Equipment Effectiveness)**. W roku 2021 brakowało jednak pełnej cyfrowej rejestracji parametrów, co uniemożliwiało obliczanie OEE w pełnym zakresie. Dopiero od 2022 roku, wraz z uruchomieniem systemów rejestrujących dane oraz wag kontrolnych, możliwe stało się systematyczne monitorowanie liczby jednostek zapakowanych w ujęciu godzinowym. Średnia wydajność produkcyjna w 2022 roku wyniosła **13,44 szt./min**, a uzyskane dane posłużyły do dalszego wyznaczania składowych wskaźnika OEE, który ostatecznie w 2022 r. osiągnął **51,37%**. We wcześniejszym okresie ocena organizacyjna opierała się także na wskaźniku wydajności pracy, rozumianym jako liczba wyrobów gotowych przypadających na jedną roboczogodzinę pracy operatorów. Wskaźnik ten wyniósł odpowiednio **60,4 szt./roboczogodzin (rg.)** w 2021 roku oraz **63,5 szt./rg.** w 2022 roku. Zestawienie awarii technicznych, zakłóceń organizacyjnych oraz reklamacji jakościowych potwierdziło, że największe ryzyko dla stabilności procesu i jakości wyrobu skupia się właśnie w operacjach **naważania, pakowania i etykietowania**. Dlatego to one zostały uznane za operacje **krytyczne**, które w kolejnych etapach pracy stanowią podstawę identyfikacji problemów i projektowania koncepcji systemu nadzorowania.

Proces konfekcjonowania w stanie wyjściowym charakteryzował się **dużym udziałem pracy manualnej** oraz **ograniczoną cyfrową rejestracją danych**. Występowała **powtarzalność awarii urządzeń i błędów obsługowych**, a także **wysoki poziom reklamacji jakościowych**, szczególnie w obszarze etykietowania i szczelności opakowań. Dodatkowym ograniczeniem były **utrudnione możliwości pełnej oceny efektywności (OEE)** wynikające z braku systematycznej akwizycji danych. Całość dopełniała **zmiennosc i niska powtarzalność procesu**, które wpływały negatywnie na stabilność parametrów produkcji.

3.2. Identyfikacja problemów występujących w analizowanym procesie

Na etapie opracowywania koncepcji inteligentnego systemu nadzorowania procesu konfekcjonowania konieczne było przeprowadzenie szczegółowej identyfikacji niezgodności w kluczowych operacjach tego procesu. W badanym środowisku produkcyjnym proces konfekcjonowania obejmuje trzy podstawowe operacje: naważanie, pakowanie oraz etykietowanie. Analiza została oparta na dokumentacji reklamacji zewnętrznych (od klientów) oraz wewnętrznych (wynikających z bieżącej kontroli jakości), a także uzupełniona wynikami przeglądu środowiska wdrożeniowego, obejmującego obserwacje procesów oraz analizę dostępnej infrastruktury technicznej. Dzięki temu możliwa była identyfikacja zarówno formalnie rejestrowanych niezgodności, jak i problemów występujących w praktyce eksploatacyjnej linii konfekcjonowania. Na tej podstawie określono trzy obszary procesu, w których zidentyfikowano istotne problemy:

1. Operacja **naważania** obejmuje przygotowanie kilku różnych składników (jednego, dwóch, trzech lub więcej), dla których kluczowe jest zachowanie zadanej masy w określonej tolerancji. Każdy składnik musi być naważony precyzyjnie, ponieważ zarówno masa jednostkowa każdego składnika, jak i masa

całkowita gotowego opakowania (wszystkich składników) wpływa na zgodność wyrobu z wymaganiami specyfikacji.

Dla operacji naważania zidentyfikowano następujące problemy:

- **Niedoważenia** – masa netto porcji poniżej wartości zadanej w specyfikacji,
- **Przeważenia** – przekroczenia wartości nominalnej,
- **Braki składnika** – całkowite pominięcie jednego lub kilku składników.
- **Niewłaściwe proporcje składników** – sytuacje, w których łączna masa opakowania spełnia wymagania specyfikacji, lecz relacje pomiędzy poszczególnymi składnikami są zaburzone (np. jeden składnik jest przeważony, a inny niedoważony).


2. Dla operacji **pakowania** wyróżniono dwie kategorie wad związanych z nieszczelnościami opakowań:

- **Nieszczelności możliwe do identyfikacji metodami wizyjnymi, nazwane na potrzeby tej pracy „Nieszczelnościami I”**. Obejmują one w szczególności: zabrudzenia w obszarze zgrzeiny, uszkodzenia mechaniczne (pęknięcia, perforacje, deformacje), wady materiałowe, takie jak rozwarstwienia folii, nieciągłości lub widoczne mikropęknięcia.
- **Nieszczelności niemożliwe do identyfikacji metodami wizyjnymi, nazwane dalej „Nieszczelnościami II”**. Dotyczą one mikronieszczelności, których weryfikacja możliwa jest jedynie przy użyciu metod pośrednich. Wiarygodne rozstrzygnięcie możliwe jest na drodze badań niszczących, takich jak pomiar zawartości tlenu wewnątrz opakowania.

3. W zakresie **etykietowania** zidentyfikowano następujące problemy:

- **brak etykiety** – całkowity brak naniesionej etykiety na opakowaniu,
- **błędy treści** – niepełne, błędne lub nieaktualne dane (np. termin przydatności, numer partii),
- **niska jakość nadruku** – słaba kontrastowość, rozmazania, deformacje czcionek,
- **nieczytelne lub błędne kody** – kody niezgodne ze specyfikacją, o obniżonej klasie ISO/IEC, utrudniające automatyczną identyfikację i śledzenie partii.

Zestawienie operacji procesu wraz z przypisanymi im problemami przedstawiono na **Rysunku 3.5**.



Rysunek 3.5. Przebieg procesu konfekcjonowania w badanym środowisku oraz zidentyfikowane niezgodności (opracowanie własne).

Konsekwencją powyższych niezgodności są **reklamacje klientów**, **straty materiałowe** oraz **obniżenie efektywności** wykorzystania linii produkcyjnej. W przypadku operacji naważania skutki dotyczą przede wszystkim ryzyka **naruszenia wymagań prawnych** w zakresie masy porcji poszczególnych składników oraz masy całkowitej wyrobu gotowego co bezpośrednio wpływa na zgodność z recepturą i zapewnieniem specyfikacji produktu końcowego. Dodatkowo pojawiają się **koszty** wynikające z przeważań. W obszarze pakowania nieszczelności opakowań prowadzą do **obniżenia trwałości** produktów, a w konsekwencji do **strat ekonomicznych** oraz ryzyka konieczności **wycofania** całych partii z rynku. Z kolei problemy w etykietowaniu skutkują utrudnieniem **identyfikowalności partii**, nieprawidłowym oznakowaniem terminów przydatności czy numerów partii, co generuje ryzyko błędów logistycznych oraz utraty **zaufania klientów**. Łącznie prowadzi to do **pogorszenia charakterystyki jakościowej wyrobu** rozumianej jako:

- **Dla naważania:** spełnienie wymagań dotyczących masy poszczególnych składników oraz masy całkowitej wyrobu gotowego,
- **Dla pakowania:** zapewnienie szczelności opakowania i utrzymanie odpowiedniej atmosfery ochronnej (zawartość tlenu < 1%),
- **Dla etykietowania:** prawidłowe oznakowanie i pełna identyfikowalność wyrobu (czytelna treść etykiety, poprawny termin przydatności do spożycia, numer partii oraz kod).

Aby zaprojektować skuteczny system nadzorowania, sama identyfikacja problemów nie była wystarczająca. Konieczne stało się również określenie źródeł ich powstawania, co pozwoliło wskazać najważniejsze obszary wymagające wsparcia i nadzorowania. Analiza przyczyn przeprowadzona dla poszczególnych operacji procesu konfekcjonowania wykazała, że:

1. W **naważaniu** podstawowym problemem są niedoważenia, przeważenia oraz braki składnika, a ich źródeł można upatrywać przede wszystkim w **niedoskonałościach tradycyjnych metod naważania**, opartych na ograniczonej automatyzacji i kontroli, a także w **braku stałego monitoringu parametrów procesu**. Do przyczyn należy zaliczyć również **błędy ludzkie**

wynikające z obsługi urządzeń, **rozkalibrowanie wag** oraz niewystarczającą stabilność urządzeń w długotrwałej eksploatacji.

- W **pakowaniu** kluczowym problemem pozostaje nieszczelność opakowań („Nieszczelności I” oraz „Nieszczelności II”). Ich powstawanie wiąże się przede wszystkim z **fluktuacjami krytycznych parametrów procesu pakowania**. Oznacza to, że jeden lub kilka parametrów procesu może ulegać okresowym odchyleniom. Wzrosty, spadki bądź przekroczenia wartości granicznych tych zmiennych prowadzą do zaburzenia stabilności procesu, a w konsekwencji do utraty integralności opakowania. Źródłem problemu można upatrywać zarówno w niewłaściwym przebiegu procesu technologicznego, jak i w czynnikach organizacyjno-eksploatacyjnych. Do typowych przyczyn zaliczają się **błędy w doborze programów czy nastaw**, brak odpowiedniej reakcji na przekroczenia limitów granicznych parametrów procesu, a także **awarie lub uszkodzenia elementów maszyn pakujących**, które bezpośrednio wpływają na szczelność opakowania. Dodatkowym problemem jest niewykrywanie nieszczelności wynikających z **pęknięć, wad materiału** opakowaniowego czy **zabrudzeń** w obszarze zgrzeiny, które często pozostają poza zasięgiem standardowych metod kontroli jakości.
- W **etykietowaniu** istotnym problemem są braki etykiet, błędy w ich treści, niska jakość nadruku i nieczytelne lub błędne kody. Przyczyny tych niezgodności obejmują zarówno **nieprawidłowości w procesie drukowania i nanoszenia etykiet**, jak i **niewłaściwą kalibrację urządzeń kontrolnych**. Dodatkowo znaczący wpływ ma **postępujące zużycie elementów eksploatacyjnych, w szczególności głowic drukujących**, które prowadzi do pogarszania jakości zadruku i spadku klasy kodów kreskowych. Ważnym źródłem problemów są także **błędy ludzkie na etapie programowania danych**, w tym wprowadzanie niepoprawnych terminów trwałości, numerów partii czy kodów identyfikacyjnych.

3.3. Koncepcja systemu


Dla rozwiązania problemów zidentyfikowanych w kluczowych operacjach procesu konfekcjonowania zaproponowano opracowanie i wdrożenie dedykowanego systemu jego nadzorowania.

Po przeanalizowaniu cech środowiska wdrożeniowego i identyfikacji występujących niesprawności procesu stwierdzono, że system powinien w szczególności:

1. **Rejestrować i gromadzić dane procesowe w czasie rzeczywistym**, obejmujące m.in. masę jednostkowych porcji, parametry przebiegu procesu pakowania oraz dane dotyczące etykietowania.
2. **Prowadzić ciągłą inspekcję wizyjną wyrobów**, która powinna umożliwiać klasyfikację opakowań jako szczelnych lub obarczonych „nieszczelnościami I”, w tym także wykrywać uszkodzenia powierzchniowe oraz inne defekty.
3. **Nadzorować obecność etykiet i ich treści** w celu weryfikacji kompletności, czytelności oraz poprawności treści. System powinien sygnalizować błędy w sposób natychmiastowy.

4. **Realizować automatyczny odrzut** wyrobów niespełniających określonych charakterystyk jakościowych, z jednoczesną rejestracją przyczyn podjętej decyzji. Proces odrzutu powinien być deterministyczny, w pełni zsynchronizowany z przepływem wyrobów na linii produkcyjnej.
5. **Dokonywać oceny ryzyka wystąpienia nieszczelności II** z wykorzystaniem metod predykcyjnych i diagnostycznych.
6. **Zapewniać wizualizację, alarmowanie oraz raportowanie wskaźników efektywności**, obejmujące bieżące monitorowanie parametrów procesu i wsparcie operatorów w podejmowaniu decyzji.

Koncepcja systemu nadzorowania procesu konfekcjonowania została przedstawiona na **Rysunku 3.6**.



Rysunek 3.6. Koncepcja systemu nadzorowania procesu konfekcjonowania wyrobów (opracowanie własne).

Na etapie koncepcji przyjęto, że, projektowany system będzie miał charakter **warstwowy i modułowy**. Biorąc pod uwagę przeprowadzone badania literaturowe, założono, że organizacyjnie system zostanie zbudowany z **czterech warstw**:

- **Warstwa akwizycji danych** będzie stanowiła podstawę działania systemu. Będzie odpowiadała za pozyskiwanie pełnych i wiarygodnych informacji. Będą gromadzone sygnały z urządzeń pomiarowych i wykonawczych oraz obrazy z systemów wizyjnych, które umożliwią inspekcję strumienia wyrobów. Każdy zapis otrzyma znacznik czasu i jednoznaczne powiązanie z partią lub serią, co zapewni identyfikowalność i pozwoli odtworzyć kontekst powstania niezgodności na poziomie konkretnej operacji procesu.
- **Warstwa analityczna** będzie odpowiadała za porządkowanie i przetwarzanie danych w celu nadania im wartości analitycznej. Obejme to filtrowanie i normalizację, synchronizację źródeł oraz wykrywanie odchyleń od wartości zadanych. W warstwie tej, w razie potrzeby zostaną zaimplementowane algorytmy analizy obrazu i metody wspomagające, a także modele predykcyjne i diagnostyczne.

- **Warstwa decyzyjna** będzie konsolidowała wyniki analiz i przekształcała je w jednoznaczne decyzje jakościowe. Będzie to obejmowało decyzje OK lub NOK przekazywane do układu odrzutu oraz wskazania dodatkowych działań, w tym kierowanie wyrobów do badań niszczących w przypadku podwyższonego ryzyka mikronieszczelności. Będą również generowane komunikaty o przekroczeniach wartości granicznych oraz sygnały diagnostyczne dla służb utrzymania ruchu. Warstwa ta domknie pętlę nadzoru i zapewni deterministyczną reakcję systemu na wykryte niezgodności.
- **Warstwa wizualizacyjna** będzie udostępniała operatorom informacje o stanie procesu, wynikach analiz i przyczynach decyzji. Obejmie dedykowane interfejsy HMI, mechanizmy alarmowania oraz raportowanie wskaźników efektywności, w tym mierników jakości i produktywności. Czytelna prezentacja danych będzie wspierała podejmowanie działań korygujących, skracała czas reakcji i ograniczała ryzyko błędów ludzkich.

Funkcjonalnie system podzielono na moduły, ściśle powiązane z zidentyfikowanymi operacjami procesu konfekcjonowania i zidentyfikowanymi w nich problemami. Dzięki temu każda operacja jak naważanie, pakowanie i etykietowanie zostaną wsparte przez dedykowane moduły, których zadaniem będzie zapobieganie, ograniczanie lub eliminacja poszczególnych zidentyfikowanych niezgodności. Korzyścią z takiego założenia jest jasny podział funkcji i możliwość niezależnego rozwijania i etapowego wdrażania modułów, a przez to ograniczenie ryzyka wdrożeniowego i uzyskiwanie korzyści już na wczesnych etapach implementacji.

Zaproponowano **pięć modułów funkcjonalnych**:

1. **Moduł nadzorowania masy porcji** – będzie powiązany z problemem niedoważeń i przeważeń; będzie korzystał z warstwy akwizycji (pomiaru masy z wag), analitycznej (algorytmy odchylen), decyzyjnej (OK/NOK) i wizualizacyjnej (aplikacje HMI prezentujące wyniki pomiarów, alarmy oraz przyczyny decyzji). Ściśle powiązany będzie z operacją naważania.
2. **Moduł nadzorowania „nieszczelności I”** – będzie powiązany nieszczelnościami możliwymi do identyfikacji metodami wizyjnymi; będzie korzystał z warstwy akwizycji (obrazy opakowań rejestrowane przez systemy wizyjne), analitycznej (algorytmy detekcji defektów), decyzyjnej (OK/NOK) i wizualizacyjnej (aplikacje HMI prezentujące obrazy defektów, wyniki klasyfikacji oraz komunikaty diagnostyczne dla operatora). Ściśle powiązany będzie z operacją pakowania.
3. **Moduł nadzorowania „nieszczelności II”** – będzie powiązany z nieszczelnościami niewidocznymi wizualnie, niewykrywalnych metodami wizyjnymi; będzie korzystał z warstwy akwizycji (parametry procesu z czujników), analitycznej (modele predykcyjne), decyzyjnej (kwalifikacja do badań na zawartość tlenu lub decyzja OK/NOK) i wizualizacyjnej (aplikacje HMI udostępniające informacje diagnostyczne o stanie procesu i wskazania dotyczące ryzyka wystąpienia niezgodności). Ściśle powiązany będzie z operacją pakowania.

4. **Moduł nadzorowania etykiet i ich treści** – będzie powiązany z problemem braku etykiety, błędami ich treści, niską jakością nadruku oraz nieczytelnymi bądź błędnymi kodami; będzie korzystał z warstwy akwizycji (obrazy etykiet rejestrowane przez systemy wizyjne), analitycznej (algorytmy weryfikacji treści i jakości kodów), decyzyjnej (OK/NOK) i wizualizacyjnej (aplikacje HMI prezentujące wyniki weryfikacji, sygnalizujące błędy oraz generujące raporty dla operatora). Ściśle powiązany będzie z operacją etykietowania.
5. **Moduł nadzorowania odrzutu wyrobów niezgodnych** – będzie powiązany z potrzebą fizycznej eliminacji wyrobów oznaczonych jako NOK; będzie korzystał z warstwy akwizycji (czujniki obecności, enkodery), decyzyjnej (impuls sterujący odrzutem) i wizualizacyjnej (statystyki NOK oraz komunikaty alarmowe dla operatora). Ściśle powiązany będzie z wszystkimi operacjami procesu konfekcjonowania, stanowiąc końcowy element pętli jakości.

W ramach prowadzonych badań literaturowych dokonano analizy rynku oraz stosowanych w praktyce przemysłowej metod i narzędzi rozwiązywania zidentyfikowanych problemów.

W Tabelach 3.5 do 3.7 przedstawiono zestawienie rozwiązań możliwych do zastosowania.

Tabela 3.5. Analiza rozważanych metod kontroli masy porcji (naważanie).

Lp.	Rozważana metoda/technologia	Zalety	Ograniczenia	Ocena / decyzja
1	Wagi platformowe z cyfryzacją i komunikacją	Wysoka dokładność pomiaru, pełna identyfikowalność danych (partia, operator), łatwa integracja z PLC i HMI, elastyczność dla różnych wyrobów	Wyższy koszt w porównaniu z rozwiązaniami manualnymi	Wybrane jako rozwiązanie docelowe
2	Dynamiczna waga kontrolna (checkweigher)	Inspekcja całego strumienia produkcyjnego, szybka kwalifikacja OK/NOK	Działa na wyrób gotowy, co zwiększa koszty odrzutów i nie eliminuje źródła ochyłen poszczególnych składników	Rozwiązanie uzupełniające
3	Dozowanie objętościowe lub przepływowe dla składników płynnych	Wysoka wydajność dla jednorodnych surowców płynnych, prosta automatyzacja	Wrażliwość na lepkość i temperaturę, ograniczona identyfikowalność porcji, niewystarczające dla składników stałych	Rozwiązanie uzupełniające (dla płynów)
4	Dozowniki grawimetryczne typu loss-in-weight	Dobra stabilność dla materiałów sypkich, ciągła regulacja strumienia	Ograniczona elastyczność przy porcjowaniu wieloskładnikowym, wymagająca adaptacja do otoczenia produkcyjnego	Rozwiązanie uzupełniające

Opracowanie własne.

Tabela 3.6. Analiza rozważanych metod kontroli szczelności opakowań (nieszczelności I).

Lp.	Rozważana metoda/technologia	Zalety	Ograniczenia	Ocena / decyzja
1	Kontrola tradycyjna	Brak kosztów inwestycyjnych; możliwość natychmiastowej reakcji operatora	Subiektywizm, niska powtarzalność, ograniczona skuteczność przy dużych wolumenach	Odrzucone
2	Klasyczne systemy wizyjne (threshold, blob analysis)	Automatyczna analiza obrazów, dostępność na rynku	Niska odporność na zmienne oświetlenie i różnorodność defektów, duży odsetek fałszywych alarmów	Rozwiązanie uzupełniające
3	Czujniki szczelności (ciśnieniowe, gazowe)	Rozwiązania przemysłowe dostępne na rynku, stosowane do testów integralności opakowań	Badania niszczące lub półniszczące, brak kontroli całego strumienia wyrobów	Rozwiązanie uzupełniające
4	Systemy wizyjne z głębokim uczeniem (CNN)	Automatyczna klasyfikacja w czasie rzeczywistym, odporność na zmienność obrazu, możliwość doskonalenia modeli poprzez uczenie	Wyższy koszt wdrożenia, wymagane przygotowanie zbioru danych	Wybrane jako rozwiązanie docelowe

Opracowanie własne.

Tabela 3.7. Analiza rozważanych metod kontroli mikronieszczelności (nieszczelności II).

Lp.	Rozważana metoda / technologia	Zalety	Ograniczenia	Ocena / decyzja
1	Badania niszczące (np. pomiar zawartości tlenu, testy wodne)	Wysoka dokładność oznaczenia, powszechnie stosowane, zgodne z wymaganiami jakościowymi	Wymagają zniszczenia próbki, duża czasochłonność, brak możliwości 100% kontroli strumienia	Metoda referencyjna, stosowana jako uzupełniająca
2	Metody półniszczące (czujniki ciśnienia, spektroskopia gazowa)	Dostępność komercyjna, częściowa automatyzacja, możliwość weryfikacji wybranych próbek	Ograniczona powtarzalność, brak pełnej integracji inline, kosztowne przy dużych partiach	Rozwiązanie uzupełniające
3	Modelowanie predykcyjne na danych procesowych	Metoda nieniszcząca, możliwość prognozowania ryzyka mikronieszczelności w czasie rzeczywistym, redukcja liczby badań niszczących	Wymaga cyfryzacji danych procesowych i walidacji modelu w warunkach przemysłowych	Wybrane jako rozwiązanie docelowe

Opracowanie własne.

W obszarze naważania stwierdzono, że w badanym środowisku wdrożeniowym, najbardziej adekwatnym a jednocześnie wystarczającym rozwiązaniem jest zastosowanie **zaawansowanych wag platformowych**, wyposażonych w funkcje cyfryzacji, komunikacji i integracji z systemem sterowania. Rozwiązanie powinno umożliwiać zarówno możliwość bieżącej kontroli parametrów, jak i generowania ustrukturyzowanych danych do analiz badawczych.

Dla Nieszczelności I przeprowadzona analiza wykazała, że **tradycyjna kontrola** jest niewystarczająca ze względu na subiektywizm oceny i ograniczoną powtarzalność. Klasyczne systemy wizyjne, oparte na regułowych algorytmach progowych (thresholding, blob analysis), cechują się ograniczoną skutecznością w zmiennych warunkach procesu. Czujniki ciśnieniowe i gazowe umożliwiają ocenę integralności, lecz są metodami **niszczącymi** lub **półniszczącymi**, co ogranicza ich zastosowanie w kontroli w 100% strumienia wyrobów. Za najlepsze rozwiązanie, przyjęte do wdrożenia, uznano system wizyjny oparty na **metodach głębokiego uczenia**. Zasadniczą przewagą tego podejścia jest zdolność do automatycznej klasyfikacji defektów w czasie rzeczywistym, wysoka odporność na zmienne warunki oświetleniowe oraz różnorodność wad opakowań, a także potencjał dalszego doskonalenia poprzez trening sieci neuronowych na rozszerzanych zbiorach danych. Przyjęcie tego kierunku pozwala na eliminację subiektywnego czynnika ludzkiego i dostosowanie kontroli jakości do wymogów produkcji seryjnej.

Dla Nieszczelności II wyniki analizy wskazują, że stosowane dotąd metody niszczące i półniszczące, mimo swojej dokładności, nie pozwalają na pełny nadzór nad całym strumieniem produkcyjnym. Rozwiązaniem **przyjętym do wdrożenia**, umożliwiającym zarówno bieżącą kontrolę, jak i prognozowanie ryzyka niezgodności, jest podejście predykcyjne oparte na analizie danych procesowych. Stabilność procesu konfekcjonowania wyrobów w dużej mierze zależy od **utrzymania kluczowych parametrów technologicznych w wąskich granicach tolerancji**. Dlatego w module nadzorowania „nieszczelności II” zaproponowano zastosowanie **modelu predykcji wystąpienia mikronieszczelności**, bazujący na wartościach parametrów procesowych.

Z punktu widzenia wdrożenia systemu istotne jest, że metody przyjęte do rozwiązania obu problemów nieszczelności wymagają przeprowadzenia **badania eksperymentalnych i modelowych**, prowadzących do budowy odpowiednich modeli decyzyjnych. W szczególności wyboru rodzaju modelu i jego parametrów oraz przygotowaniu danych do trenowania, testowania i walidowania modelu. Biorąc pod uwagę wielość modeli możliwych do zastosowania (szczególnie w przypadku Nieszczelności II), konieczne jest również przeprowadzenie oceny uzyskanych modeli i wybór modelu najlepszego.


Dla pełnego uporządkowania toku pracy przygotowano zestawienie, które syntetycznie przedstawia powiązania między operacjami procesu, występującymi w nich problemami a odpowiadającymi im modułami oraz przypisanymi warstwami architektury. Zestawienie w **Tabeli 3.8** prezentuje moduły w układzie: operacja procesu - problem – moduł – warstwa - funkcja. Dzięki temu, struktura modułowa stanowi bezpośrednią odpowiedź na problemy występujące w procesie konfekcjonowania, a jednocześnie w pełni realizuje założenia koncepcji i architektury systemu.

Tabela 3.8. Powiązanie modułów funkcjonalnych z operacjami procesu, problemami jakościowymi, warstwami architektury oraz funkcjami systemu.

Powiązana operacja procesu	Zidentyfikowany problem	Moduł	Powiązane warstwy systemu	Funkcje modułu
Naważanie	Niedoważenia Przeważenia Braki składnika	Nadzorowanie masy porcji	Akwizycji (wagi), Analityczna (algorytmy odchyłeń), Decyzyjna (OK/NOK), Wizualizacyjna	Rejestracja i analiza danych procesowych; sygnalizacja błędów
Pakowanie	Nieszczelności możliwe do identyfikacji metodami wizyjnymi	Nadzorowanie „nieszczelności I”	Akwizycji (systemy wizyjne), Analityczna (algorytmy detekcji defektów), Decyzyjna (OK/NOK), Wizualizacyjna	Inspekcja wizyjna 100% wyrobów; automatyczne wykrywanie defektów
	Nieszczelności niemożliwe do identyfikacji metodami wizyjnymi	Nadzorowanie „nieszczelności II”	Akwizycji (czujniki procesowe), Analityczna (modele predykcyjne), Decyzyjna (kwalifikacja do badań niszczących/OK-NOK), Wizualizacyjna	Predykcja ryzyka nieszczelności; redukcja badań na zawartość tlenu
Etykietowanie	Brak etykiety, błędy treści, niska jakość nadruku, nieczytelne lub błędne kody	Nadzorowanie etykiet i ich treści	Akwizycji (systemy wizyjne), Analityczna (algorytmy weryfikacji treści i jakości kodów), Decyzyjna (OK/NOK), Wizualizacyjna	Analiza etykiet i kodów; blokada przekazywania wyrobów z błędami
Wszystkie operacje	Konieczność fizycznej eliminacji wyrobów NOK	Nadzorowanie odrzutu wyrobów niezgodnych	Akwizycji (czujniki obecności, enkodery), Decyzyjna (impuls sterujący odrzutem), Wizualizacyjna	Automatyczny odrzut wyrobów NOK; rejestracja przyczyn decyzji

Opracowanie własne.

Zaproponowana architektura wraz z przypisanymi modułami funkcjonalnymi tworzy spójny system nadzorowania, który bezpośrednio odpowiada na zidentyfikowane problemy procesu konfekcjonowania. Struktura warstwowa zapewnia przejrzyste rozdzielanie zadań, natomiast modułowa budowa umożliwia powiązanie każdej operacji z odpowiadającym jej mechanizmem nadzoru. Schemat architektury systemu, obrazujący przepływ danych pomiędzy warstwami przedstawiono na **Rysunku 3.7.**



Rysunek 3.7. Architektura warstwowa inteligentnego systemu nadzorowania procesu konfekcjonowania wyrobów (opracowanie własne).

4. Budowa inteligentnego systemu nadzorowania procesu konfekcjonowania wyrobów

Budowę inteligentnego systemu nadzorowania należy rozumieć jako proces obejmujący zarówno projektowanie, jak i wdrażanie rozwiązań w środowisku przemysłowym. Poszczególne moduły systemu były realizowane w określonej kolejności począwszy od pierwszych elementów i stopniowo rozszerzane o kolejne funkcje. Nie zawsze jednak możliwe było zachowanie pełnej sekwencji działań. Wiele prac prowadzono równolegle, a uzyskiwane wyniki powodowały konieczność powrotu do wcześniej opracowanych fragmentów systemu, ich modyfikacji i doskonalenia. Wynikało to zarówno z charakteru badań wdrożeniowych, jak i z potrzeby bieżącego dostosowywania rozwiązań do uwarunkowań technicznych badanego zakładu.

Tak rozumiana budowa obejmowała przełożenie założeń koncepcyjnych i architektonicznych na rozwiązanie modułowe, ich integrację w czterowarstwowej strukturze systemu oraz weryfikację funkcjonalności w warunkach przemysłowych. Efektem było powstanie spójnego układu, który z jednej strony odpowiadał na potrzeby operacyjne zakładu poprzez monitorowanie i podejmowanie decyzji jakościowych w czasie rzeczywistym, a z drugiej tworzył bazę badawczą dostarczającą ustrukturyzowanych danych do analiz, modelowania i walidacji. W dalszej części rozdziału przedstawiono poszczególne moduły wraz z ich rolą w systemie, przypisanymi warstwami architektury oraz powiązanymi modelami analitycznymi.

4.1. Moduł nadzorowania masy porcji

Na etapie koncepcji przyjęto, że do budowy tego modułu wykorzystane zostaną **zaawansowane wagi platformowe**, wyposażone w funkcje cyfryzacji, komunikacji i integracji z systemem sterowania. Rozwiązanie powinno umożliwiać zarówno możliwość bieżącej kontroli parametrów, jak i generowania ustrukturyzowanych danych do analiz badawczych.

Od wybranego rozwiązania oczekiwano, że zapewni ono:

- ograniczenie udziału **czynnika ludzkiego** poprzez odejście od **tradycyjnych metod naważania**,
- **bieżący monitoring masy w czasie rzeczywistym**, umożliwiający natychmiastową reakcję na odchylenia,
- **wsparcie operatora** poprzez sygnalizację wizualną w przypadku przekroczeń progów tolerancji,
- **pełną identyfikowalność pomiarów** poprzez przypisanie wyników do partii i operatora,
- **archiwizację danych w formie cyfrowej**, umożliwiającą prowadzenie analiz statystycznych, budowę wskaźników (m.in. DPMO–masa) oraz walidację działania systemu w dłuższej perspektywie,
- **spójność i zgodność z przyjętą architekturą systemu**.

Moduł został osadzony w **czterowarstwowej architekturze systemu**:

1. Dla warstwy **akwizycji danych** stanowiska wagowe wyposażono w precyzyjne platformy pomiarowe ze stali kwasoodpornej o dokładności 1 g, dostosowane do pracy w warunkach przemysłowych. Zasadniczym elementem tych urządzeń były **belki tensometryczne z czujnikami tensometrycznymi** które umożliwiały przekształcenie odkształceń mechanicznych w sygnały elektryczne i ich dalsze przetwarzanie w układzie sterowania. Każde stanowisko zostało zintegrowane z 15-calowym panelem operatorskim HMI w obudowie IP67, co zapewniało odporność na warunki środowiska produkcyjnego (**Rysunek 4.1**). Rozmieszczenie wag wzdłuż linii umożliwiało kontrolę masy kluczowych składników oraz jednoznaczne przypisanie wyników pomiarów do operatora i partii produkcyjnej. Dane z wag były automatycznie rejestrowane w aplikacji lokalnej i przekazywane do serwera FTP, co gwarantowało ciągłość zapisu i pełną identyfikowalność. Każdy pomiar archiwizowano wraz z numerem partii, identyfikatorem operatora, czasem i wynikiem ważenia, co tworzyło kompletną bazę danych źródłowych. Aby zapewnić wiarygodność wyników i spójność pomiarową, urządzenia poddawano regularnej kalibracji z wykorzystaniem wzorcowanych odważników referencyjnych, zgodnych z wymaganiami metrologicznymi i prawnymi.



Rysunek 4.1. Stanowisko wagowe z panelem operatorskim HMI (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

2. W **warstwie analitycznej** realizowano porównanie wyników pomiarowych z wartościami normatywnymi (M_0) oraz granicami tolerancji (T_- , T_+). Dane były przetwarzane w czasie rzeczywistym, umożliwiając tworzenie histogramów rozkładu mas porcji, wykresów trendów oraz analizę zmienności. Opracowane algorytmy pozwalały na agregację wyników w ujęciu partii i zmian produkcyjnych, a także na wyznaczanie wskaźników jakościowych, takich jak **DPMO – masa**. Dzięki temu moduł nie tylko wspierał kontrolę operacyjną, ale również pełnił rolę źródła danych badawczych do oceny stabilności procesu i walidacji systemu.

3. Na podstawie obliczeń z warstwy analitycznej stosowano trzystopniową logikę kwalifikacji wyników (**Rysunek 4.2**):

- **zielona** – masa porcji w zakresie tolerancji,
- **żółta** – wynik bliski granicy tolerancji, wskazujący na potrzebę korekty,
- **czerwona** – wynik poza zakresem, oznaczający kwalifikację NOK i konieczność odrzutu.

Logika **decyzyjna** została zaimplementowana w sposób deterministyczny, a decyzje były rejestrowane i przekazywane do modułu odrzutu wyrobów niezgodnych. Rozwiązanie to ograniczało ryzyko błędnej interpretacji przez operatora i zapewniało spójność ocen w całym procesie.

```


INPUT:
M      - zmierzona masa
M0     - masa zadana
T_min  - dolna tolerancja
T_max  - górna tolerancja

ALGORITHM:
IF (M >= M0 - T_min) AND (M <= M0 + T_max):
    sygnał = "zielony"
ELSE IF ((M >= M0 - 2*T_min) AND (M < M0 - T_min)) OR
        ((M > M0 + T_max) AND (M <= M0 + 2*T_max)):
    sygnał = "żółty"
ELSE:
    sygnał = "czerwony"

OUTPUT:
    sygnał + zapis wyniku do bazy + aktualizacja raportu
  
```

Rysunek 4.2. Logika modułu nadzorowania masy porcji (opracowanie własne).

4. Integralną część modułu stanowiła **warstwa wizualizacyjna** wyposażona w dedykowaną aplikację operatorską. Interfejs aplikacji umożliwiał konfigurację parametrów normatywnych, przypisywanie zadań do partii i operatorów oraz bieżące monitorowanie procesu naważania. Na **Rysunku 4.3** przedstawiono ekran konfiguracyjny oraz panel monitoringu, na którym operator mógł śledzić wyniki pomiarów w czasie rzeczywistym wraz z sygnalizacją kolorystyczną progów tolerancji.



Rysunek 4.3. Interfejs aplikacji: konfiguracja i monitoring operacji naważania (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

Kolejny widok aplikacji, zaprezentowany na **Rysunku 4.4**, przedstawia kartotekę towarów i surowców. Funkcjonalność ta umożliwiała jednoznaczną identyfikację używanych komponentów, ich parametrów normatywnych oraz przypisanie do konkretnej partii produkcyjnej.

Kartoteka towarów / Towary Dodaj

Kod - Nazwa - Aktywny - Typ - Grupa towarowa - Nr katalogowy - Strategia magazynowania - Mnożony - Przejęty się - PKWU - Kod CN - Data utworzenia - Ostatnia modyfikacja -

Jednostka (symbol) - ■

Pokaż: 50 << < 1 > >>

☐	Kod	Nazwa	Aktywny	Typ	Grupa towarowa	Nr katalogowy	Strategia magazynowania	Mnożony	Przejęty się	PKWU	Kod CN	Data utworzenia	Ostatnia modyfikacja	Jednostka
☐	FM.MRO.00160	Wędzone kawałki łososia	●	Towar			Brak	⊖	⊖			11.01.2023 12:23:48	13.08.2024 09:34:45	kg
☐	FM.PPP.00298	Węprzowina kostka sous vide	●	Towar			Brak	⊖	⊖			2.10.2024 15:31:32	2.10.2024 15:32:28	kg

Rysunek 4.4. Interfejs aplikacji: kartoteka towarów i surowców (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

W ramach warstwy wizualizacyjnej dostępna była również funkcja raportowania, której przykładowy wynik zaprezentowano na **Rysunku 4.5**. Raport obejmował zestawienie pomiarów wykonanych w danej partii wraz z informacjami o operatorze i czasie wykonania, co umożliwiało analizę retrospektywną oraz budowę wskaźników jakościowych.

Source.Name	Terminal	Użytkownik	Surowiec	Zakres mas	Pomiar wagi	Jednostka	Data	Godzina
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.028	kg	22.06.2023	09:46:27
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.028	kg	22.06.2023	09:46:33
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.026	kg	22.06.2023	09:46:36
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.026	kg	22.06.2023	09:46:41
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:47:23
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:47:28
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.026	kg	22.06.2023	09:48:10
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:48:16
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:48:32
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.028	kg	22.06.2023	09:48:38
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:48:44
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.026	kg	22.06.2023	09:48:57
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:49:02
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.026	kg	22.06.2023	09:49:10
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:49:15
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.028	kg	22.06.2023	09:49:21
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:49:25
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:49:28
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.030	kg	22.06.2023	09:49:39
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.028	kg	22.06.2023	09:49:47
reverseWeighingTERM00122062023.xlsx	TERM001	admin	Wędzone kawałki łososia	0.026 - 0.03	0.026	kg	22.06.2023	09:49:55

Rysunek 4.5. Interfejs aplikacji – raport z modułu nadzorowania masy porcji (opracowanie własne).

Integracja modułu z układem sterowania linii i repozytorium danych pozwoliła na odwzorowanie pełnego przepływu informacji w architekturze systemu oraz na uzyskanie identyfikowalności niezbędnej do analiz i walidacji.

4.2. Moduł nadzorowania „nieszczelności I”

Szczelność opakowania stanowi jeden z kluczowych czynników determinujących bezpieczeństwo oraz trwałość wyrobów konfekcjonowanych. Nieszczelności I są jednym z głównych źródeł reklamacji zewnętrznych i wewnętrznych, a ich skuteczne wykrywanie jest niezbędnym warunkiem stabilności operacji pakowania. Po przeprowadzeniu analizy technicznej dostępnych na rynku rozwiązań wybrano urządzenia wizyjne firmy SICK typu InspectorP63x, które umożliwia zastosowanie metod głębokiego

uczenia. W budowanym systemie zastosowano rozwiązanie wizyjne oparte na wielowarstwowych sieciach neuronowych. Szczegóły architektury sieci neuronowej, opracowanej przez firmę SICK, nie były publicznie ujawnione, a działania badawcze w szczególności koncentrowały się na:

- budowie i uporządkowaniu bazy danych obrazowych oraz ich kategoryzacji,
- przygotowaniu i optymalizacji zbiorów treningowych i walidacyjnych, w tym zastosowaniu metod augmentacji danych,
- **budowie klasyfikatora** opartego na konwolucyjnych sieciach neuronowych oraz jego optymalizacji,
- trenowaniu i walidacji modeli z wykorzystaniem różnych konfiguracji parametrów,
- analizie jakości modeli z użyciem funkcji straty, macierzy pomyłek oraz wskaźników takich jak dokładność, czułość i precyzja,
- walidacji klasyfikatora w warunkach przemysłowych i ocenie jego przydatności w nadzorze procesu.

Od wybranego rozwiązania oczekiwano, że zapewni ono:

- **automatyczną** detekcję defektów w czasie rzeczywistym,
- **cyfrową rejestrację obrazów** z przypisaniem identyfikatorów partii i znaczników czasowych,
- tworzenie **bazy obrazów**, wykorzystywanej zarówno w bieżącej inspekcji operacyjnej, jak i w badaniach,
- odporność na **zmienne warunki** oświetlenia oraz różnorodność defektów,
- możliwość dalszego **doskonalenia** systemu poprzez trening sieci neuronowych na rozszerzanych zbiorach danych.


Moduł został osadzony w **czterowarstwowej architekturze systemu**:

1. W ramach warstwy akwizycji opracowano stanowisko wizyjne umożliwiające automatyczną rejestrację obrazów opakowań w czasie rzeczywistym. Dane wejściowe w postaci **zdjęć jednostek opakowaniowych** były pozyskiwane bezpośrednio w trakcie pracy linii produkcyjnej. Zastosowano trzy kamery przemysłowe SICK InspectorPx, zintegrowane z dedykowanym systemem oświetlenia LED, co zapewniało jednolite warunki akwizycji i minimalizowało ryzyko powstawania refleksów. Aby uzyskać powtarzalność rejestracji obrazów, stanowisko zostało odpowiednio skonfigurowane i odseparowane od zakłóceń otoczenia. Synchronizację działania kamer z transporterem zrealizowano poprzez czujnik pozycji i enkoder, dzięki czemu każda jednostka produkcyjna mogła zostać uchwycona indywidualnie. Uzyskane obrazy były nie tylko wykorzystywane do bieżącej analizy przy użyciu metod inspekcji wizyjnej, lecz także systematycznie **archiwizowane na serwerze FTP**, co umożliwiało ich późniejsze wykorzystanie do badań statystycznych i uczenia modeli. Układ stanowiska zaprezentowano na **Rysunku 4.6**. Widoczne na nim jest rozmieszczenie kamer oraz system oświetlenia.



Rysunek 4.6. Stanowisko modułu nadzorowania „nieszczelności I” (opracowanie własne).

Na **Rysunku 4.7** przedstawiono interfejs oprogramowania kamery przemysłowej, umożliwiający podgląd pojedynczej próbki wraz z parametrami akwizycji. Widoczne są m.in. ustawienia czasu ekspozycji, kontrastu, jasności oraz pola widzenia, które pozwalały na precyzyjną konfigurację stanowiska i zapewniały powtarzalność rejestrowanych obrazów.



Rysunek 4.7. Interfejs kamery w module nadzorowania „nieszczelności I” – podgląd próbki i parametry akwizycji obrazu (opracowanie własne).

Szczegółową specyfikację wykorzystanej aparatury zestawiono w **Tabeli 4.1**, obejmującej elementy rejestrujące obraz, infrastrukturę synchronizacyjną oraz komponenty odpowiedzialne za archiwizację danych.

Tabela 4.1. Aparatura wykorzystana w budowie modułu nadzorowania „nieszczelności I”.

Lp.	Element	Model/typ	Producent	Funkcja w systemie
1	Czujnik wizyjny 2D	2 × InspectorP63x, V2D632P-2MXCXB0	SICK	Rejestracja obrazów i wstępna analiza wizualna
2	Czujnik wizyjny 2D	InspectorP61x, V2D611P-MMSCI4	SICK	Rejestracja obrazów uzupełniająca, analiza wizualna
3	Oświetlenie LED, filtry, obiektywy	Zestaw dedykowany	—	Stabilizacja warunków oświetleniowych, redukcja odbłasków
4	Oprogramowanie inspekcyjne	SICK AppSpace SensorApps: Intelligent Inspection; Label Checker	SICK	Klasyfikacja OK/NOK oraz implementacja modeli głębokiego uczenia (CNN)
5	Synchronizacja i okablowanie	Czujnik pozycji, enkoder, złącza, skrzynki przyłączeniowe	—	Synchronizacja akwizycji obrazu z transporterem
6	Komputer przemysłowy i repozytorium	IPC, serwer FTP	ELMATIC	Archiwizacja danych obrazowych i metadanych

Opracowanie własne.

Należy podkreślić, że przedstawiona aparatura została zaprojektowana i wdrożona z myślą o wykorzystaniu w więcej niż jednym obszarze nadzorowania. W module nadzorowania „nieszczelności I” kluczową rolę pełni kamera **InspectorP63x** z oprogramowaniem Intelligent Inspection, obsługująca analizę obrazów w celu identyfikacji defektów opakowań. Drugi egzemplarz kamery tego samego typu został natomiast skonfigurowany z narzędziami służącymi do analizy treści etykiet. Jego zastosowanie zostanie szczegółowo omówione w dalszej części pracy, w module **nadzorowania etykiet ich treści**. Dzięki takiemu podejściu całość aparatury tworzy jednolite stanowisko wizyjne, które obsługuje zarówno nadzorowanie szczelności opakowań, jak i inspekcję etykiet w ramach jednej linii produkcyjnej.

2. Do przygotowania zastosowanego w warstwie analitycznej, klasyfikatora neuronowego, zgromadzone w procesie akwizycji zdjęcia jednostek opakowaniowych zostały uporządkowane i przetworzone w postaci dedykowanej bazy danych obrazów. Baza ta pełniła podwójną funkcję: **operacyjną**, umożliwiając bieżącą klasyfikację opakowań jako zgodnych (OK) lub potencjalnie niezgodnych (NOT OK - na potrzeby niniejszego podrozdziału określenia NOT OK i NOK są stosowane zamiennie i oznaczają wyrób niezgodny), oraz **badawczą**, stanowiąc materiał źródłowy do analiz statystycznych i do uczenia modeli głębokiego uczenia.

Każdemu obrazowi przypisywano metadane, takie jak numer partii, znacznik czasowy oraz identyfikacje operatora. Dane te były archiwizowane zarówno lokalnie, jak i na serwerze FTP, co zapewniało pełną identyfikowalność i możliwość późniejszej analizy. Utworzona baza obejmowała docelowo około **500 obrazów**, które zostały wykorzystane w procesie trenowania modeli. Należy podkreślić, że liczba ta odnosi się do końcowej wersji repozytorium, natomiast sam proces budowy i testowania baz danych obejmował **tysiące zdjęć**, grupowanych w różne warianty o mniejszej i większej liczebności. Takie podejście umożliwiało między innymi analizę wpływu wielkości zbioru danych na skuteczność klasyfikacji i stabilność działania algorytmów. Wersja bazy wykorzystana w badaniach obejmowała:

- obrazy wyrobów **zgodnych (OK)**, pełniące rolę referencji,
- obrazy wyrobów potencjalnie niezgodnych (**NOT OK**), obejmujących różne typy niezgodności zidentyfikowanych dla „nieszczelności I”. Na etapie budowy bazy danych i prowadzenia badań kategorie te określano potocznie jako „Brak folii”, „Pęknięta tacka”, „Otwarta tacka”, „Pusta tacka”, „Zabrudzona tacka”, „Inna”. Co do zasady, odpowiadają one niezgodnościom formalnie opisanym we wcześniejszej identyfikacji problemów i niezgodności w obszarze operacji pakowania.

Przykładowy widok uporządkowanej bazy danych obrazów wraz z wstępną kategoryzacją niezgodności zaprezentowano na **Rysunku 4.8**.

Classes

Class name

[+ Create class](#)

Ok 198 Data Items

 Drop files or folders, [browse files](#), or [browse folders](#).

Brak Folii 20 Data Items

 Drop files or folders, [browse files](#), or [browse folders](#).


Peknieta 36 Data Items

 Drop files or folders, [browse files](#), or [browse folders](#).

Otwarta 63 Data Items


 Drop files or folders, [browse files](#), or [browse folders](#).

Pusta 35 Data Items

 Drop files or folders, [browse files](#), or [browse folders](#).

Rysunek 4.8. Baza danych obrazów z wstępną kategoryzacją defektów (przykłady obrazów OK i niezgodnych) (opracowanie własne).

Z kolei na **Rysunku 4.9** przedstawiono szczegółowe obrazy opakowań zarejestrowane w trakcie budowania bazy danych. Zestawienie obejmuje zarówno jednostkę zgodną (OK), jak i wybrane przypadki niezgodności, które były najczęściej identyfikowane w procesie konfekcjonowania.



Rysunek 4.9. Przykładowe obrazy opakowań w module nadzorowania „nieszczelności I” – opakowanie zgodne (OK) oraz wybrane przypadki opakowań niezgodnych (NOT OK): pęknięte opakowanie, otwarte opakowanie, opakowanie z zabrudzeniem w obszarze zgrzeiny (opracowanie własne).

Uporządkowane i sklasyfikowane dane obrazowe stanowiły podstawę do opracowania **modelu inspekcji wizyjnej**. Do realizacji klasyfikatora obrazu wykorzystano **konwolucyjne sieci neuronowe**, które automatycznie wyodrębniają istotne cechy z obrazu, redukują wymiarowość i dokonują końcowej klasyfikacji. Architektura **CNN** (Convolutional Neural Network) zapewnia odporność na przesunięcia, różnice w oświetleniu oraz drobne deformacje, co czyni ją szczególnie użyteczną w warunkach przemysłowych. Proces uczenia przeprowadzono w środowisku **SICK Intelligent Inspection (dStudio)**, umożliwiającym trenowanie i walidację modeli oraz ich bezpośredni eksport do kamer pracujących w linii produkcyjnej. W trakcie badań przeprowadzono wiele iteracji treningowych, testując różne konfiguracje zbiorów danych i parametry akwizycji.

Na pierwotnym etapie przygotowania dane obrazowe zostały zweryfikowane pod względem jakości i zapisane w plikach o odpowiednim formacie (PNG), umożliwiającym ich wykorzystanie w procesie uczenia. Zbiór danych podzielono na część **treningową** i **walidacyjną**, co jest standardem w procesie uczenia głębokiego. Aby zrównoważyć nierównomierny rozkład próbek między klasami, zastosowano techniki augmentacji (obróć obrazu, zmiany jasności), co zwiększyło różnorodność danych. W celu

zapewnienia wiarygodności działania modułu przyjęto **próg ufności** (confidence) na poziomie 90%, co stanowiło kompromis między ograniczeniem ryzyka fałszywych akceptacji wyrobów wadliwych a minimalizacją nadmiarowych odrzuceń wyrobów zgodnych.

Pierwotnie przyjęto sześć rozróżnialnych kategorii stanu:

1. OK – opakowania zgodne,
2. Brak folii,
3. Pęknięta tacka,
4. Otwarta tacka,
5. Pusta tacka,
6. Inna – defekty nietypowe (np. zabrudzenia, deformacje).


Wyniki uzyskane dla tego wariantu, w trakcie fazy trenowania i analizy przebiegów funkcji straty oraz dokładności prezentowały stabilne zachowanie i spełniały oczekiwania jednak szczegółowa analiza macierzy pomyłek wykazała istotne rozbieżności w klasyfikacji. Podczas walidacji w warunkach przemysłowych problem ten uległ nasileniu a model szczególnie często wykazywał trudności w jednoznacznym przypisaniu wyrobów niezgodnych do odpowiednich kategorii, co wynikało ze złożoności i niejednorodności defektów. Jednocześnie potwierdzono, że klasyfikator osiągał bardzo wysoką skuteczność w identyfikacji wyrobów zgodnych (OK), natomiast problemy koncentrowały się głównie na rozróżnianiu przypadków niezgodnych.

W związku z tym zdecydowano się uprościć klasyfikację do trzech kategorii:

1. **OK**,
2. **NOT OK** (łączy wszystkie defekty powodujące „nieszczelności I”),
3. **PUSTA**.


Redukcja liczby klas pozwoliła znacząco zwiększyć stabilność i dokładność klasyfikacji przy jednoczesnym uproszczeniu logiki decyzyjnej, co zostało potwierdzone zarówno w dalszych testach symulacyjnych, jak i w walidacji przemysłowej.

Dla **pierwotnej** wersji klasyfikatora, obejmującej sześć klas niezgodności, przeprowadzono proces trenowania sieci neuronowej, który pozwolił na ocenę zdolności modelu do rozróżniania różnych typów niezgodności opakowań w rzeczywistych warunkach przemysłowych. Na **Rysunku 4.10** przedstawiono przebieg dokładności klasyfikatora w funkcji liczby kroków treningu, osobno dla zbioru treningowego i walidacyjnego. Model osiągnął dokładność na poziomie **100%** dla danych treningowych oraz **93,5%** dla danych walidacyjnych. Uzyskany wynik świadczy o dobrej zdolności generalizacji modelu w kontekście wieloklasowej klasyfikacji wad wyrobu, co jest istotne w aplikacjach przemysłowych, gdzie defekty mogą mieć zróżnicowaną charakterystykę wizualną.




Rysunek 4.10. Dokładność pierwotnej klasyfikacji modelu w procesie trenowania – przebieg dla zbioru treningowego i walidacyjnego (6 klas) (opracowanie własne).

W celu pełniejszej oceny jakości trenowanego modelu, analizie poddano również przebieg funkcji straty (loss), która opisuje błąd predykcji modelu w trakcie uczenia. Na **Rysunku 4.11** zaprezentowano przebieg straty w skali logarytmicznej. Taka prezentacja umożliwia obserwację minimalnych wahań wartości błędu w fazie treningu oraz pozwala ocenić proces adaptacji modelu do złożonych wzorców wizualnych. Widać wyraźnie, że w miarę wzrostu liczby kroków treningowych model skutecznie redukował błąd i stabilizował się na zadowalającym poziomie.




Rysunek 4.11. Przebieg pierwotnej funkcji straty (loss) w procesie uczenia modelu – skala logarytmiczna (opracowanie własne).

Dla uproszczonych interpretacji różnic pomiędzy stratą na danych treningowych a walidacyjnych, ten sam przebieg przedstawiono w skali liniowej na **Rysunku 4.12**. Wykres ten ukazuje stabilność błędu na zbiorze treningowym oraz umiarkowane wahania dla zbioru walidacyjnego, typowe przy pracy z ograniczonymi zbiorami danych i niejednorodnością klas defektów.




Rysunek 4.12. Przebieg pierwotnej funkcji straty (loss) w procesie uczenia modelu – skala liniowa (opracowanie własne).

Dla **ostatecznej** wersji klasyfikatora, w której kategorie zredukowano do trzech (OK, NOT OK, PUSTA), przeprowadzono kompletny cykl trenowania sieci neuronowych w środowisku **dStudio**. Optymalizacja parametrów akwizycji obrazu oraz przygotowanie wyselekcjonowanej bazy danych umożliwiły uzyskanie wysokiej skuteczności i stabilnych wyników klasyfikacji. Ostateczny model osiągnął **100% dokładności na zbiorze treningowym** oraz **97% na zbiorze walidacyjnym**, co potwierdza jego zdolność do prawidłowej generalizacji w warunkach przemysłowych. Na **Rysunku 4.13** przedstawiono przebieg dokładności (accuracy) w funkcji liczby kroków treningowych. Widać, że model bardzo szybko osiągnął wysoki poziom skuteczności i utrzymywał go stabilnie zarówno dla danych treningowych, jak i walidacyjnych, bez oznak przeuczenia.




Rysunek 4.13. Dokładność ostatecznej klasyfikacji modelu w procesie trenowania – przebieg dla zbioru treningowego i walidacyjnego (3 klasy) (opracowanie własne).

Analiza funkcji straty w skali logarytmicznej, przedstawiona na **Rysunku 4.14**, pokazuje systematyczne zmniejszanie błędów predykcji na zbiorze treningowym oraz utrzymywanie się stabilnej wartości straty na zbiorze walidacyjnym. Logarytmiczna skala umożliwia obserwację drobnych wahań w końcowej fazie uczenia, które potwierdzają proces adaptacji modelu do złożonych wzorców wizualnych. Takie zachowanie wskazuje na brak przeuczenia (overfittingu) i potwierdza zdolność modelu do prawidłowej generalizacji w warunkach przemysłowych.



Rysunek 4.14. Przebieg ostatecznej funkcji straty (loss) w procesie uczenia modelu – skala logarytmiczna (opracowanie własne).


Dla przejrzystości porównania wartości strat, na **Rysunku 4.15** przedstawiono ich przebieg w skali liniowej. Widać wyraźnie, że strata na zbiorze treningowym bardzo szybko spadła do wartości bliskiej zeru i utrzymywała się na stabilnym poziomie w całym procesie uczenia. Strata na zbiorze walidacyjnym utrzymywała się w granicach **0,2–0,4**, wykazując umiarkowane wahania typowe dla rzeczywistych danych przemysłowych. Taki przebieg potwierdza brak przeuczenia i zdolność modelu do stabilnej generalizacji.



Rysunek 4.15. Przebieg ostatecznej funkcji straty (loss) w procesie uczenia modelu – skala liniowa (opracowanie własne).


Celem weryfikacji działania modelu inspekcji wizyjnej w module nadzorowania „nieszczelności I” było potwierdzenie skuteczności automatycznej klasyfikacji stanu opakowań oraz niezawodności jego pracy w warunkach przemysłowych. Model ten, bazujący na kamerach 2D i algorytmach głębokiego uczenia, zastąpił dotychczasowe kontrole, które w warunkach dużej skali produkcji nie gwarantowały pełnej wykrywalności niezgodności. Proces walidacji przeprowadzono wieloetapowo, początkowo w środowisku testowym **dStudio**, a następnie w warunkach rzeczywistej linii produkcyjnej.

Dla oceny modeli wykorzystano **macierze pomyłek** (confusion matrices), które pozwoliły na **ocenę dokładności klasyfikacji** względem rzeczywistych klas wyrobów (ground truth). Wyniki dla pierwotnych wersji modeli przedstawiono na **Rysunku 4.16**. Obejmują one zarówno klasyfikację sześcioklasową, jak i pierwsze próby uproszczenia klasyfikatora do trzech klas. W obu przypadkach skuteczność była niezadowalająca, zauważalne były liczne pomyłki między kategoriami oraz niska stabilność wyników. Macierze te dobrze obrazują trudności, jakie pojawiały się na początkowych etapach badań i uzasadniały konieczność **dalszej optymalizacji budowy klasyfikatora**.



Rysunek 4.16. Macierze pomyłek dla pierwotnych wersji modelu inspekcji wizyjnej w module nadzorowania „nieszczelności I” (opracowanie własne).

Wyniki ostatecznej wersji modelu inspekcji wizyjnej w module nadzorowania „nieszczelności I” przedstawiono na **Rysunku 4.17**. Macierz pomyłek potwierdza wysoką skuteczność klasyfikacji w układzie trójklasowym (OK, NOT OK, PUSTA). Wszystkie próbki z kategorii **PUSTA** i **OK** zostały zaklasyfikowane prawidłowo, natomiast w przypadku klasy **NOT OK** odnotowano pojedynczą pomyłkę polegającą na błędnej kwalifikacji jednej próbki.




Rysunek 4.17. Macierz pomyłek dla ostatecznej wersji modelu inspekcji wizyjnej w module nadzorowania „nieszczelności I” (opracowanie własne).

Ostateczny model osiągnął następujące parametry skuteczności:

- **dokładność** (accuracy) 97% na zbiorze walidacyjnym oraz 100% na zbiorze treningowym,
- **czułość** (sensitivity) dla klasy NOT OK: 95% (19/20),
- **precyzja** (precision) dla klasy NOT OK: 100% (19/19),
- tylko jeden przypadek błędnej klasyfikacji (false negative) wśród 49 próbek testowych.


Walidację uzupełniono o testy w rzeczywistych warunkach produkcyjnych. W pierwszej próbie kontrolnej, obejmującej podstawianie do linii opakowań z celowo wprowadzonymi niezgodnościami, model poprawnie **zidentyfikował 9 z 10** wadliwych próbek, co odpowiada **skuteczności na poziomie 90%**. Następnie przeprowadzono testy ciągłe, w których oceniano stabilność pracy modelu i czas reakcji systemu. Statystyki przedstawione na **Rysunku 4.18** potwierdzają, że model osiągał **99% poprawnych klasyfikacji** w serii ponad 880 próbek. Średni czas akwizycji i klasyfikacji pojedynczego obrazu wyniósł **233 ms**, co umożliwiało pełną synchronizację z pracą linii produkcyjnej bez konieczności obniżania jej wydajności.



Rysunek 4.18. Statystyki walidacji modelu inspekcji wizyjnej w module nadzorowania „nieszczelności I” – testy w warunkach produkcyjnych (opracowanie własne).

Opracowany model inspekcji wizyjnej oparty na metodach głębokiego uczenia pełni przede wszystkim funkcję **klasyfikatora wyrobów na podstawie danych obrazowych**. Jego działanie polega na analizie obrazów rejestrowanych w trakcie pracy linii produkcyjnej i przypisywaniu ich do jednej z trzech klas jakościowych: OK, NOT OK lub PUSTA. Z tego względu można uznać, że model ten w istotnym stopniu należy do **warstwy analitycznej** modułu nadzorowania „nieszczelności I”, zapewniając obiektywną ocenę jakości w oparciu o dane procesowe. Wyniki klasyfikacji stanowią jednocześnie dane wejściowe dla **warstwy decyzyjnej**, w której określana jest dalsza ścieżka postępowania z wyrobem.

3. Warstwa decyzyjna w module nadzorowania „nieszczelności I” odpowiada za deterministyczne podejmowanie decyzji dotyczących jakości wyrobu na podstawie wyników uzyskanych w warstwie analitycznej. Wynik klasyfikacji generowany przez model inspekcji wizyjnej oparty na metodach głębokiego uczenia (CNN) stanowi podstawę do przypisania wyrobu do jednej z trzech kategorii: **OK, NOT OK lub PUSTA**. Na **Rysunku 4.19** przedstawiono przykładowy widok działania klasyfikatora w trakcie pracy modułu nadzorowania „nieszczelności I”. Widoczny jest wynik klasyfikacji przypisujący opakowanie do klasy OK wraz z wartością confidence powyżej 90%, co pozwala na pozytywną decyzję o dopuszczeniu wyrobu. Dla predykcji o pewności poniżej 90% przyjmowano decyzję zachowawczą: wyrób kierowano do kategorii NOT OK, co minimalizowało ryzyko fałszywej akceptacji.



Rysunek 4.19. Widok klasyfikatora AI w module nadzorowania „nieszczelności I” – wynik klasyfikacji z wartością confidence (opracowanie własne).

Decyzje klasyfikacyjne są następnie przekazywane na porty cyfrowe urządzenia inspekcyjnego, co umożliwia sterowanie dalszym przepływem wyrobów w linii produkcyjnej. Przyjęto następującą logikę działania:

- **IO3 (WynikOK)** – aktywacja w przypadku zaklasyfikowania wyrobu do klasy OK,
- **IO5 (WynikNOK)** – aktywacja w przypadku zaklasyfikowania wyrobu do klasy NOT OK lub PUSTA.

Schemat konfiguracji wyjść cyfrowych zaprezentowano na **Rysunku 4.20**, gdzie przedstawiono przypisanie sygnałów sterujących do poszczególnych kategorii jakościowych.

Digital Output ...

The Digital Output tool sends tool results to the device's digital outputs. [Read more...](#)

Port	Enabled	Result	Deactivate after	State
IO3	☒	WynikOk/Value	☒ - 250 + ms	●
IO4	☐	All passed	☐ - 390 + ms	●
IO5	☒	WynikNok/Value	☒ - 250 + ms	●
IO6	☐	All passed	☐ - 10 + ms	●

Rysunek 4.20. Konfiguracja wyjść cyfrowych dla logiki decyzyjnej w module nadzorowania „nieszczelności I” (opracowanie własne).

System działa w sposób deterministyczny, co oznacza, że każda próbka musi zostać jednoznacznie zaklasyfikowana do jednej z trzech kategorii. Decyzja o dalszym postępowaniu z wyrobem podejmowana jest automatycznie, a w przypadku aktywacji wyjścia IO5 uruchamiany jest mechanizm odrzutu. Działanie logiki systemu można przedstawić w postaci uproszczonego pseudokodu, zaprezentowanego na **Rysunku 4.21**. Schemat ten obrazuje, że w przypadku przypisania wyrobu do klasy NOT OK lub PUSTA system natychmiast inicjuje procedurę odrzutu, podczas gdy wyroby sklasyfikowane jako OK kierowane są do dalszego etapu konfekcjonowania.

```
INPUT:
class      – wynik klasyfikacji (OK / NOT OK / PUSTA)
confidence – pewność klasyfikacji [%]

ALGORITHM:
IF (confidence ≥ 90%) AND (class == "OK"):
    sygnał = "zielony" // produkt zgodny – kontynuacja
ELSE IF (confidence ≥ 90%) AND (class == "NOT OK" OR class == "PUSTA"):
    sygnał = "czerwony" // produkt niezgodny – odrzut

OUTPUT:
sygnał + sterowanie odrzutnikiem + zapis do bazy
```

Rysunek 4.21. Uproszczony pseudokod logiki decyzyjnej w module nadzorowania „nieszczelności I” (opracowanie własne).

4. Warstwa wizualizacyjna w module nadzorowania „nieszczelności I” pełni rolę interfejsu pomiędzy systemem a operatorem, zapewniając przejrzystą prezentację wyników pracy modelu inspekcji wizyjnej oraz ułatwiając nadzór nad operacją pakowania. Jej głównym zadaniem jest przedstawienie wyników klasyfikacji próbek w czasie rzeczywistym, z jednoznacznym wskazaniem kategorii jakościowej (OK, NOT OK, PUSTA) oraz wartości wskaźnika confidence. Na ekranach aplikacji możliwe jest nie tylko śledzenie bieżącej klasyfikacji, ale także dostęp do ustawień i parametrów konfiguracji stanowiska inspekcyjnego. Operator ma możliwość kontroli takich elementów, jak czas ekspozycji, kontrast czy jasność, co pozwala na bieżące dostosowanie warunków akwizycji obrazu w zależności od sytuacji na linii produkcyjnej. Ważnym elementem warstwy wizualizacyjnej jest sygnalizacja kolorystyczna, ułatwiająca szybkie odczytywanie statusu wyrobów np. kolor zielony dla próbek zgodnych (OK), czerwony dla wyrobów zaklasyfikowanych jako NOT OK. Takie rozwiązanie skraca czas reakcji operatora i zwiększa przejrzystość pracy systemu. Warstwa wizualizacyjna obejmuje również funkcje raportowania i archiwizacji. Dane dotyczące wyników klasyfikacji, oznaczone identyfikatorami partii, operatora i znacznikami czasowymi, są automatycznie zapisywane w bazie systemu, a następnie mogą być eksportowane do plików raportowych (np. w formacie Excel). Dzięki temu operatorzy i personel techniczny mają dostęp do pełnej historii inspekcji, co wspiera analizy retrospektywne, audyty jakości oraz doskonalenie procesu.

4.3. Moduł nadzorowania „nieszczelności II”

Operacja pakowania stanowi centralny etap procesu konfekcjonowania, decydujący o szczelności opakowań. W ramach niniejszej pracy operacja pakowania była realizowana z użyciem maszyny typu tray sealer. Proces polegał na zamykaniu tacek folią barierową, przy jednoczesnym zastąpieniu powietrza mieszaniną gazów ochronnych. W badaniach wykorzystano następujące **materiały opakowaniowe**:

- **Tacka opakowaniowa W1/602 (187/137/50), 850 ml, polipropylen (PP)** – szczegółową specyfikację techniczną zamieszczono w **Załączniku Z.2**.
- **Folia CX-P AHB 55 AF / CX-P AHB 55 AF peel** – szczegółową specyfikację techniczną zamieszczono w **Załączniku Z.1**.

W przeprowadzonej analizie problemów wskazano, że stabilność procesu konfekcjonowania wyrobów i związana z nią szczelność opakowań w dużej mierze zależy od **utrzymania kluczowych parametrów technologicznych w wąskich granicach tolerancji**. Dlatego w module nadzorowania „nieszczelności II” opracowano **model predykcji mikronieszczelności** opakowań oparty na regresji logistycznej.

Zastosowana metoda, zaliczana do podstawowych technik uczenia maszynowego, pozwala na modelowanie prawdopodobieństwa wystąpienia niezgodności w zależności od wartości parametrów procesowych. Jej wdrożenie umożliwiło nie tylko prognozowanie potencjalnych defektów, ale również ilościową ocenę wpływu poszczególnych zmiennych na ryzyko utraty szczelności. Zbudowany model był wynikiem realizacji **programu badań**, którego istotą było prowadzenie eksperymentów, gromadzenie i cyfryzacja danych procesowych oraz ich analiza w celu identyfikacji i ilościowej oceny czynników determinujących ryzyko mikronieszczelności.


Prace obejmowały:

- **eksperymenty czynne** których celem było spośród wielu badanych zmiennych wytypowanie kluczowych parametrów technologicznych, a następnie przeprowadzenie analizy zależności pomiędzy tymi parametrami a stabilnością i efektywnością procesu oraz charakterystykami jakościowymi wyrobu. Kolejnym krokiem było wyznaczenie progów i limitów wartości tych parametrów, określających obszar stabilnej pracy operacji pakowania,
- **cyfryzację i integrację danych procesowych** obejmującą opracowanie infrastruktury umożliwiającej ciągły pomiar, rejestrację i archiwizację kluczowych zmiennych technologicznych. Rozwiązanie to pozwoliło na pełną identyfikowalność cykli produkcyjnych, synchronizację czasową obserwacji i przygotowanie spójnej bazy danych, która stała się fundamentem dalszych analiz statystycznych oraz budowy modeli,
- **budowę modelu predykcyjnego**, którego celem było prognozowanie ryzyka występowania „nieszczelności II” oraz przygotowanie do implementacji w systemie nadzorowania w czasie rzeczywistym. Proces obejmował przygotowanie zbioru danych z etykietami jakościowymi (na

podstawie badań niszczących zawartości tlenu), estymację parametrów modelu oraz analizę istotności zmiennych. Dzięki temu możliwe było ilościowe określenie wpływu wybranych parametrów technologicznych na prawdopodobieństwo wystąpienia niezgodności.

- **walidację modelu w warunkach przemysłowych**, zrealizowaną na rzeczywistych danych produkcyjnych. Obejmowała ona zarówno klasyczne miary jakości klasyfikacji (accuracy, sensitivity, specificity), jak i analizę krzywej ROC oraz wartości AUC, co pozwoliło ocenić zdolność modelu do praktycznego rozróżniania wyrobów zgodnych i niezgodnych.

Na **Rysunku 4.22** zaprezentowano plan badań odnoszący się do modułu nadzorowania „nieszczelności II”. Schemat ten ilustruje kolejne etapy postępowania. Tak zaplanowany i zrealizowany program sprawił, że moduł „nieszczelności II” stanowi najbardziej istotny element rozprawy w aspekcie naukowym, a jego szczegółowa analiza została przedstawiona w dalszej części pracy.



Rysunku 4.22. Plan badań w module nadzorowania „nieszczelności II” (opracowanie własne).

Pierwszym etapem przygotowywania modułu nadzorowania „nieszczelności II” była **eksperymentalna analiza parametrów technologicznych** odpowiadających za szczelność opakowań. W tym celu przeprowadzono serię prób czynnych, w ramach których modyfikowano wiele parametrów jak wartości temperatury zgrzewania, ciśnienia w komorze pakującej, czasu cyklu, wydajności linii, siły docisku elementów zgrzewających oraz naciągu folii. Eksperymenty obejmowały różne kombinacje nastaw, pozwalając na obserwację i ocenę stabilności procesu w odniesieniu do wyników pomiarów zawartości tlenu w opakowaniu. Jeden z układów eksperymentalnych wraz z zestawieniem badanych wariantów parametrów technologicznych przedstawiono na **Rysunku 4.23**. Należy podkreślić, że był to istotny etap badań w ramach niniejszej rozprawy, gdyż umożliwił identyfikację czynników o największym znaczeniu dla powstawania potencjalnych mikronieszczelności. Dzięki takiemu postępowaniu uzyskano **dane empiryczne** obejmujące zarówno przebieg procesu w warunkach

zgodnych ze specyfikacją techniczną, jak i w sytuacjach krytycznych sprzyjających powstawaniu wad. Stworzona w ten sposób baza pomiarów posłużyła nie tylko do wskazania parametrów krytycznych, lecz także stanowiła fundament dalszych analiz statystycznych oraz budowy modeli predykcyjnych.

Opakowanie: W1/602(187/137/50) 850ML TRANSPARENT PP													
Folia CX-P AHB 55 AF / CX-P AHB 55 AF peel													
Wariant	Temperatura [C°]	Czas zgrzewania	Ciśnienie VACUM	Ciśnienie gaz	Wydajność [szt/min]	Pomiar resztki tlenowej [%]					Uwagi		
1	153	1,5 s	50 m bar	800 m bar	15	0.17	1.55	0.41	0.14	0.09			
2	143	1,5 s	50 m bar	800 m bar	15	19.78	19.78	19.77	19.77	19.76	całkowita nieszczelność		
3	173	1,5 s	50 m bar	800 m bar	15	0.23	0.10	0.19	0.10	0.07	zauważalne przepalenia		
4	183	1,5 s	50 m bar	800 m bar	15	0.09	3.87	1.63	6.49	0.16	awaria maszyny		
5	163	1 s	50 m bar	800 m bar	15	0.19	0.14	0.16	0.13	0.21			
6	163	0,5 s	50 m bar	800 m bar	15	0.08	8.52	0.21	8.05	8.49			
7	163	2 s	50 m bar	800 m bar	15	0.13	0.12	0.16	0.35	0.71	zauważalne przepalenia		
8	163	2,5 s	50 m bar	800 m bar	15	0.41	0.13	0.57	0.10	0.37	zauważalne przepalenia		
9	163	1,5 s	35 m bar	800 m bar	15	0.64	0.14	0.07	0.11	0.09			
10	163	1,5 s	20 m bar	800 m bar	15	0.29	0.04	0.05	0.27	0.34	defekt opakowania		
11	163	1,5 s	65 m bar	800 m bar	15	0.19	0.18	0.21	0.16	0.16			
12	163	1,5 s	80 m bar	800 m bar	15	0.30	0.62	0.48	0.28	0.20	defekt opakowania		
13	163	1,5 s	50 m bar	700 m bar	15	0.25	0.30	0.15	0.23	0.13	defekt opakowania		
14	163	1,5 s	50 m bar	600 m bar	15	0.47	0.27	0.62	0.19	1.90			
15	163	1,5 s	50 m bar	900 m bar	15	0.37	0.35	0.13	0.13	0.07			
16	163	1,5 s	50 m bar	1000 m bar	15	0.18	0.08	0.11	0.06	0.05	defekt opakowania		
17	163	1,5 s	50 m bar	800 m bar	10	0.23	0.17	0.17	0.10	0.13	wydajność min		
18	163	1,5 s	50 m bar	800 m bar	10	0.27	0.28	0.21	0.16	0.11	wydajność min		
19	163	1,5 s	50 m bar	800 m bar	30	0.10	0.46	0.19	0.52	0.14	wydajność max		
20	163	1,5 s	50 m bar	800 m bar	30	0.14	0.45	0.11	0.11	0.15	wydajność max		

Rysunek 4.23. Układ eksperymentalny: warianty parametrów technologicznych operacji pakowania (opracowanie własne).

Wyniki eksperymentów czynnych umożliwiły wskazanie **trzech parametrów krytycznych**, których utrzymanie w określonych granicach stanowi warunek zachowania szczelności opakowania oraz utrzymania wartości tlenu poniżej progu 1,0%. Selekcja tych parametrów była wynikiem analizy zależności pomiędzy zmiennymi procesowymi a wynikami pomiarów zawartości tlenu, stanowiącego podstawowe kryterium jakościowego. Wykazano, że **temperatura zgrzewania, ciśnienie bezwzględne w komorze pakującej oraz wydajność linii** pozostają ze sobą wzajemnie skorelowane, wprost lub odwrotnie proporcjonalnie a ich odchylenia prowadzą do powstawania mikronieszczelności. Pozostałe analizowane zmienne nie wносиły istotnej wartości, co potwierdziły wyniki testów niszczących polegających na pomiarze zawartości tlenu w opakowaniach. W konsekwencji to właśnie te trzy parametry uznano za kluczowe w dalszych analizach i do nich przypisano limity operacyjne procesu. Charakter ich oddziaływania przedstawiono poniżej:

- **temperatura zgrzewania** – czynnik decydujący o szczelności opakowania; wartości poniżej zakresu skutkowały nieszczelnościami, natomiast zbyt wysokie powodowały przegrzewanie zgrzeiny,
- **ciśnienie bezwzględne w komorze pakującej** – zbyt niskie wartości sprzyjały mikronieszczelnościom oraz podwyższonym wynikom pomiarów zawartości tlenu, natomiast zbyt wysokie prowadziły do „wybrzuszeń” folii,

- **wydajność linii** – determinowała czas oddziaływania czynników procesowych; niższe prędkości stabilizowały proces, natomiast wyższe skutkowały pogorszeniem szczelności i wzrostem zawartości tlenu.

Następnie wyznaczono **limity parametrów krytycznych**, określające obszar stabilnej pracy operacji pakowania:

- temperatura zgrzewania: **162,8–163,2 °C**,
- ciśnienie bezwzględne w komorze pakującej: **30–60 mbar**,
- wydajność linii: **0–30 szt./min.**

Zakresy te ustalono w wyniku **analizy eksperymentalnej** oraz **weryfikacji praktycznej**, a także w odniesieniu do zaleceń zawartych w **kartach technicznych opakowań i folii (Załączniki Z.1 i Z.2)**. Warto zaznaczyć, że ocena szczelności opakowania za pomocą pomiaru zawartości tlenu miała charakter metody niszczącej. W badaniach wykorzystano **analizator gazowy OXY BABY**, umożliwiający oznaczenie zawartości tlenu w atmosferze ochronnej wewnątrz opakowania. Dla badanego asortymentu przyjęto **wartość graniczną 1,0%**, ustaloną na podstawie doświadczeń zakładowych i badań mikrobiologicznych. Jej przekroczenie klasyfikowano jako **niezgodność krytyczną**. Stanowisko pomiarowe zaprezentowano na **Rysunku 4.24**. W celu potwierdzenia prawidłowości stosowanych procedur pomiarowych i jakości uzyskiwanych danych do pracy dołączono **świadczenia kalibracji analizatora gazu (Załączniki Z.9 i Z.10)**.



Rysunek 4.24. Stanowisko do pomiaru zawartości tlenu w opakowaniach (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

W ramach nadzoru nad operacją pakowania kluczowe znaczenie miała **kontrola temperatury elementów zgrzewających**. W systemie pomiarowym stosowano **pięć czujników rezystancyjnych typu Pt100**, rozmieszczonych w taki sposób, aby monitorować temperaturę w pięciu punktach odpowiadających położeniu opakowań w jednym cyklu pracy maszyny. Takie rozmieszczenie zapewniało wysoką rozdzielczość przestrzenną pomiarów i umożliwiało wychwycenie lokalnych

odchylen temperaturowych mogących powodować nieszczelności. Każdy czujnik tworzył niezależny tor pomiarowy, a jego sygnał był przekazywany bezpośrednio do systemu rejestracji i wizualizacji. Zastosowano model **PTR 25** w wykonaniu przemysłowym, zgodnym z normą **PN-EN 60751**, z eksponowaną spoiną pomiarową i zakresem pracy od -40 do $500\text{ }^{\circ}\text{C}$. Kartę katalogową stosowanych czujników temperatury (DTR) przedstawiono w **Załączniku Z.3**. Aby zapewnić wiarygodność i powtarzalność pomiarów, w przedsiębiorstwie stosowano system **rotacyjnej kalibracji czujników**. Zakład dysponował dwoma kompletami:

- pierwszy komplet pracował w maszynie,
- drugi był wykorzystywany do okresowej kalibracji w laboratorium.

Kalibracja odbywała się w sposób naprzemienny, co umożliwiało utrzymanie **ciągłości monitoringu bez przestojów linii produkcyjnej**. Regularna kontrola poprawności wskazań gwarantowała, że uzyskiwane dane były rzetelne i mogły stanowić podstawę do dalszych analiz statystycznych oraz do weryfikacji wartości granicznych parametrów krytycznych w operacji pakowania. Tak przygotowane procedury pomiarowe stanowiły podstawę do przejścia na kolejny etap prac, obejmujący **cyfryzację i integrację danych** procesowych w czasie rzeczywistym, co pozwoliło na wdrożenie warstwy akwizycji w module nadzorowania.

1. Warstwa akwizycji miała zapewnić ciągłą rejestrację parametrów krytycznych z wysoką dokładnością, jednoznaczną identyfikowalność partii i synchronizację czasową obserwacji, prezentację bieżących wartości na panelach operatorskich HMI oraz bezpieczną archiwizację z możliwością eksportu do formatu raportowego. Wymagania te wynikały bezpośrednio z wyników przeprowadzonych eksperymentów czynnych i przyjętych procedur metrologicznych, które potwierdziły zestaw parametrów krytycznych oraz ich limity robocze. Zakres monitorowanych kluczowych zmiennych technologicznych zestawiono w **Tabeli 4.2**, obejmującej zarówno źródła danych, częstotliwość ich rejestracji, jak i przypisane progi alarmowe.

Tabela 4.2. Kluczowe parametry technologiczne monitorowane w module nadzorowania „nieszczelności II”.

Nazwa parametru	Jednostka	Zakres monitorowania	Zakres referencyjny (limity robocze)	Źródło pomiaru / rejestracji	Częstotliwość zapisu	Próg alarmowy
Temperatura zgrzewania	$^{\circ}\text{C}$	5–250	162,8–163,2	Czujnik Pt100 PTR 25, rejestracja przez OPC UA	co każdy cykl	wyjscie poza [162,8–163,2] $^{\circ}\text{C}$ w danym cyklu
Ciśnienie bezwzględne w komorze pakującej	mbar	0–1000	30–60	Przetwornik próżni, PLC, OPC UA	co każdy cykl	wyjscie poza [30; 60] mbar w danym cyklu

Wydajność linii	szt./min	0–60	0–30 (zakres badawczy / recepturowy)	Enkoder / licznik cykli w PLC	co każdy cykl	wyjscie poza [0–30] szt./min w danym cyklu
Zawartość tlenu resztkowego (O ₂)	%	0–21	0–1,0	Analizator OXY BABY (metoda niszcząca)	według planu próbkowania	> 1,0%

Opracowanie własne.

Przed wdrożeniem systemu dostęp do informacji procesowych był **ograniczony** do podglądu na panelach operatorskich, bez możliwości cyfrowej rejestracji danych i bez uruchomionych interfejsów transmisyjnych. Producent zastosował **zamknięte protokoły komunikacyjne**, które uniemożliwiały pobieranie sygnałów bezpośrednio ze sterownika maszyny. Konieczne było więc wypracowanie alternatywnej metody cyfryzacji danych w czasie rzeczywistym, z pominięciem ograniczeń producenckich. Ostatecznie przyjęto rozwiązanie oparte na komunikacji **OPC UA** pomiędzy sterownikami **PLC** a panelem operatorskim **HMI**, z wykorzystaniem **routera eWON** pełniącego funkcję serwera danych. Router ten gromadził i udostępniał w czasie rzeczywistym wartości kluczowych zmiennych procesowych, stanowiąc bufor integracyjny pomiędzy poziomem sterowania a systemem wizualizacji i archiwizacji. Infrastruktura systemu obejmowała dwie szafy sterownicze:

- pierwszą, wyposażoną w moduły PLC i układ akwizycji danych odpowiedzialny za sterowanie i zbieranie sygnałów z maszyny (**Rysunek 4.25**),



Rysunek 4.25. Szafa sterownicza systemu pakowania z modułami PLC i układem akwizycji danych (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

- drugą, zawierającą moduły komunikacyjne oraz router eWON współpracujący z HMI, umożliwiające integrację systemu i wymianę danych w czasie rzeczywistym (**Rysunek 4.26**).



Rysunek 4.26. Szafa sterownicza systemu pakowania z modułami komunikacyjnymi OPC UA i routerem eWON współpracującym z panelami HMI (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

Równolegle dane były przekazywane do interfejsu aplikacji poglądowej, który umożliwiał operatorom bieżącą ocenę stanu maszyny. Na ekranach HMI prezentowano aktualne wartości parametrów, takich jak temperatura, ciśnienie czy status cyklu. Rejestrowane dane były automatycznie archiwizowane lokalnie oraz na serwerze FTP, z możliwością eksportu do arkuszy Excel. Przykład ekranu archiwizacji przedstawiono na **Rysunku 4.27**.

2025-04-24 10:32:13

Food Makers - ProSeal Dania Gotowe

24/04/2025 CZW. 09:25:20

Nr	Data	Czas	ch.1	ch.2	ch.3	ch.4	ch.5
9293	2025/04/24	09:24:35	farch pa	0.0	25	18	1565
9292	2025/04/24	09:24:20	farch pa	27.4	25	18	1560
9291	2025/04/24	09:24:09	farch pa	21.7	25	18	1555

Nr	Data	Czas	ch.1	ch.2	ch.3	ch.4	ch.5	ch.6
9292	2025/04/24	09:24:35	163.0	162.9	162.9	162.8	162.8	162.9
9291	2025/04/24	09:24:20	163.0	163.0	163.0	162.9	163.0	162.9
9290	2025/04/24	09:24:09	163.0	162.9	162.9	162.8	162.9	162.9
9289	2025/04/24	09:23:58	163.0	163.0	163.0	163.0	163.0	163.0

Nr	Data	Czas	ch.1	ch.2	ch.3	ch.4	ch.5	ch.6
9293	2025/04/24	09:24:35	65.0	825.0	50.0	50	1.3	10
9292	2025/04/24	09:24:20	50.9	825.0	50.0	50	1.3	10
9291	2025/04/24	09:24:10	74.1	825.0	50.0	50	1.3	10
9290	2025/04/24	09:23:58	62.8	825.0	50.0	50	1.3	10

Nr	Data	Czas	ch.1	ch.2	ch.3	ch.4
9291	2025/04/24	09:24:35	2	10	1	1
9290	2025/04/24	09:24:20	2	10	1	1
9289	2025/04/24	09:24:10	2	10	1	1
9288	2025/04/24	09:23:58	2	10	1	1

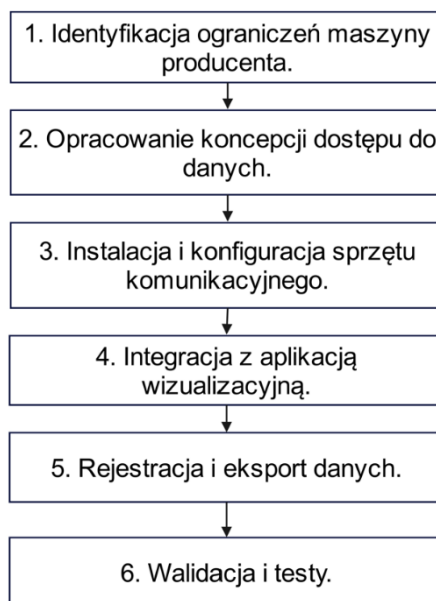
Receprtura:

farch papardelle

Rysunek 4.27. Ekran archiwizacji danych z funkcją eksportu do arkuszy Excel w module nadzorowania „nieszczelności II” (opracowanie własne).

kolumna	data_index	DateTime	rec_id	il_pak_min		u_pak		ogolna_min		liczba_wznow		data_index	time_timestamp	temp_ext		temp_gz1	tan
				kolumna	data_format_1	data_format_2	data_format_3	data_format_4	data_format_5	data_format_6	data_format_7						
25.11.2024 06:24:12	212009	1732515852	25.11.2024 06:24:12	0	0	1	17	fach papardelle	219337	1732515852	163	162,8000031					
25.11.2024 06:24:23	212010	1732515863	25.11.2024 06:24:23	25,773191336	0	2	21	farch papardelle	219338	1732515863	163	162,80000031					
25.11.2024 06:24:37	212013	1732515907	25.11.2024 06:24:37	22,091331241	20	2	27	farch papardelle	219339	1732515907	163	162,69999969					
25.11.2024 06:24:40	212012	1732515889	25.11.2024 06:24:40	25,421724894	20	2	31	farch papardelle	219340	1732515889	163	162,80000000					
25.11.2024 06:25:03	212013	1732515903	25.11.2024 06:25:03	21,362529828	20	3	37	farch papardelle	219341	1732515903	163	162,5					
25.11.2024 06:28:51	212014	1732516131	25.11.2024 06:28:51	0	15	2	44	farch papardelle	219342	1732516131	163	162,89999939					
25.11.2024 06:29:02	212015	1732516142	25.11.2024 06:29:02	0	15	2	47	farch papardelle	219343	1732516142	163	162,89999939					
25.11.2024 06:29:14	212016	1732516154	25.11.2024 06:29:14	25,929127614	15	3	53	farch papardelle	219344	1732516154	163	162,80000031					
25.11.2024 06:29:16	212017	1732516166	25.11.2024 06:29:16	25,231281287	20	3	57	farch papardelle	219345	1732516166	163	162,89999969					
25.11.2024 06:29:38	212018	1732516178	25.11.2024 06:29:38	24,81388900	20	3	63	farch papardelle	219346	1732516178	163	162,60000061					
25.11.2024 06:29:50	212019	1732516190	25.11.2024 06:29:50	25,73737999	20	4	68	farch papardelle	219347	1732516190	163	162,5					
25.11.2024 06:30:02	212020	1732516202	25.11.2024 06:30:02	0	20	4	72	farch papardelle	219348	1732516202	163	162,60000061					
25.11.2024 06:31:58	212021	1732516318	25.11.2024 06:31:58	0	20	4	76	farch papardelle	219349	1732516318	163	163,10000061					
25.11.2024 06:32:15	212022	1732516335	25.11.2024 06:32:15	17,34103066	20	4	82	farch papardelle	219350	1732516335	163	163					
25.11.2024 06:32:27	212023	1732516347	25.11.2024 06:32:27	25,21008492	20	4	86	farch papardelle	219351	1732516347	163	162,89999939					
25.11.2024 06:32:41	212024	1732516361	25.11.2024 06:32:41	22,04261589	20	4	92	farch papardelle	219352	1732516361	163	162,89999939					
25.11.2024 06:32:53	212025	1732516373	25.11.2024 06:32:53	25,10406472	20	5	97	farch papardelle	219353	1732516373	163	162,80000031					
25.11.2024 06:33:06	212026	1732516386	25.11.2024 06:33:06	22,22223238	20	5	102	farch papardelle	219354	1732516386	163	162,80000031					
25.11.2024 06:33:18	212027	1732516398	25.11.2024 06:33:18	25,519136376	20	5	108	farch papardelle	219355	1732516398	163	162,89999969					
25.11.2024 06:33:30	212028	1732516410	25.11.2024 06:33:30	25,445259152	25	6	114	farch papardelle	219356	1732516410	163	162,80000031					
25.11.2024 06:33:42	212029	1732516422	25.11.2024 06:33:42	25,27377999	25	5	118	farch papardelle	219357	1732516422	163	162,69999969					
25.11.2024 06:33:54	212030	1732516434	25.11.2024 06:33:54	25,25252342	25	6	124	farch papardelle	219358	1732516434	163	162,69999969					
25.11.2024 06:34:05	212031	1732516445	25.11.2024 06:34:05	25,668299515	25	6	12										

Etapy cyfryzacji i wdrożenia warstwy akwizycji danych przedstawiono syntetycznie na **Rysunku 4.29**. Schemat obejmuje pełny cykl od identyfikacji ograniczeń systemu producenta, przez instalację i integrację sprzętu komunikacyjnego, aż po uruchomienie rejestracji, eksportu danych i ich walidację w warunkach rzeczywistej eksploatacji.



2. Warstwa analityczna stanowiła kluczowy element modułu nadzorowania „nieszczelności II”, którego zadaniem było przetwarzanie danych procesowych zarejestrowanych w warstwie akwizycji oraz nadanie im **wartości predykcyjnej**. O ile akwizycja zapewniała ciągłe pozyskiwanie i archiwizację parametrów technologicznych, o tyle warstwa analityczna umożliwiała **identyfikację zależności**

między tymi wartościami a występowaniem nieszczelności. Jej zasadniczym celem było stworzenie narzędzia umożliwiającego **prognozowanie ryzyka powstawania wyrobów niezgodnych w czasie rzeczywistym**. Zastosowany model decyzyjny oparty na **regresji logistycznej** pozwalał nie tylko prognozować potencjalne defekty, ale także ilościowo oceniać wpływ poszczególnych zmiennych na ryzyko utraty szczelności.

Budowa modelu predykcyjnego w ramach modułu nadzorowania „nieszczelności II” wymagała zgromadzenia i uporządkowania danych procesowych w sposób zapewniający ich wiarygodność oraz reprezentatywność dla analizowanego zjawiska. Dane te zostały pozyskane w warstwie akwizycji, która umożliwiła bieżące monitorowanie pracy maszyny pakującej i rejestrację kluczowych parametrów technologicznych w czasie rzeczywistym. Integralnym elementem układu pomiarowego był analizator gazowy, wykorzystywany do niszczących pomiarów zawartości tlenu w opakowaniach. Wyniki tych badań stanowiły **etykiety referencyjne**, na podstawie których oceniano poprawność predykcji w warstwie analitycznej.

Łącznie zgromadzono **174 pełne obserwacje procesowe**, obejmujące zestawy wartości **krytycznych parametrów technologicznych** oraz odpowiadające im **wyniki pomiarów tlenu**. Fragment zestawu danych źródłowych przedstawiono w **Załączniku Z.5**. Zbiór danych został **podzielony na dwie części**:

- **80%** przeznaczono do budowy modelu predykcyjnego (zbiór treningowy),
- **20%** wykorzystano w celu weryfikacji skuteczności modelu (zbiór testowy).

W wyniku identyfikacji krytycznych parametrów procesu do konstrukcji modelu regresji logistycznej wybrano trzy zmienne niezależne.

- temperatura zgrzewania [$^{\circ}\text{C}$],
- ciśnienie bezwzględne w komorze pakującej [mbar],
- wydajność linii [szt./min].

Jako **zmienną zależną** przyjęto klasę wyrobu określającą jego zgodność jakościową:

- 0 – wyrób zgodny (OK)
- 1 – wyrób niezgodny, definiowany jako przekroczenie dopuszczalnej zawartości tlenu resztkowego na poziomie 1,0%. (NOK)

Tak przygotowany zbiór danych umożliwił przeprowadzenie analizy regresji logistycznej, której celem było wyznaczenie zależności między wartościami kluczowych parametrów procesu a prawdopodobieństwem wystąpienia nieszczelności opakowania. Opracowanie modelu predykcyjnego rozpoczęto od sformułowania klasycznej postaci funkcji regresji logistycznej, opisującej

prawdopodobieństwo wystąpienia zdarzenia binarnego w zależności od wartości zmiennych objaśniających. Ogólna postać modelu przyjmuje formę:

$$P(Y = 1|T, P, C) = \frac{\exp(\alpha_0 + \alpha_{\text{temp}}T + \alpha_{\text{pressure}}P + \alpha_{\text{capacity}}C)}{1 + \exp(\alpha_0 + \alpha_{\text{temp}}T + \alpha_{\text{pressure}}P + \alpha_{\text{capacity}}C)}$$

gdzie:

- Y=1 oznacza wystąpienie niezgodności (przekroczenie 1,0% O₂),
- Y=0 oznacza zgodny wyrób.

W analizie uwzględniono trzy główne zmienne niezależne:

- T – temperatura zgrzewania [°C],
- P – ciśnienie bezwzględne w komorze pakującej [mbar],
- C – wydajność linii [szt./min].

Do analizy wykorzystano środowisko obliczeniowe R. Wbudowane w środowisku funkcje umożliwiły zarówno budowę i dopasowanie modelu, jak i generowanie wskaźników jakości klasyfikacji. W ramach procedury walidacyjnej zwrócono szczególną uwagę na zdolność modelu do identyfikacji przypadków potencjalnych niezgodności, co miało kluczowe znaczenie w kontekście ograniczenia badań niszczących. Na podstawie danych treningowych oszacowano współczynniki modelu regresji logistycznej, które zestawiono w **Tabeli 4.3**.

Tabela 4.3. Parametry regresji logistycznej.

Zmienna	Wartość estymowana	Std. Error	z value	Pr(> z)
Intercept	-716.91	393.62539	-1.82129	0.06856
Temperatura	4.30312	2.41505	1.78179	0.07478
Ciśnienie	0.09620	0.03522	2.73123	0.00631
Wydajność	0.48815	0.10604	4.60334	0.00000

Opracowanie własne.

Interpretacja współczynników wskazała, że wszystkie trzy zmienne wykazują pozytywny wpływ na prawdopodobieństwo wystąpienia „nieszczelności II”. Fluktuacje w wartościach temperatury zgrzewania, ciśnienia w komorze pakującej oraz wydajności linii wiązały się ze wzrostem prawdopodobieństwa powstawania mikronieszczelności. Uzyskane wyniki potwierdziły, że przyjęty zestaw zmiennych jest adekwatny do opisu zjawiska i umożliwia skuteczną predykcję wyrobów niezgodnych na podstawie bieżących parametrów procesu. Ocena jakości opracowanego modelu regresji logistycznej została przeprowadzona na zbiorze testowym obejmującym 20% próbek. Proces walidacji polegał na porównaniu przewidywanej klasy wyrobu (zgodny/niezgodny) z faktycznym

wynikiem pomiaru resztkowego tlenu w opakowaniu. Na tej podstawie opracowano macierz pomyłek (**Tabela 4.4**). Ostatecznie w ocenie klasyfikacji wykorzystano 27 obserwacji.

Tabela 4.4. Macierz pomyłek – zbiór testowy.

	Rzeczywiste: zgodne	Rzeczywiste: niezgodne
Przewidziane: zgodne	13	3
Przewidziane: niezgodne	2	9

Opracowanie własne.


Analiza macierzy pomyłek pozwoliła stwierdzić, że model w znacznym stopniu prawidłowo rozróżnia wyroby zgodne i niezgodne, choć w części przypadków pojawiały się błędne klasyfikacje. Aby uzyskać pełniejszą ocenę jakości opracowanego modelu, obliczono zestaw miar statystycznych powszechnie stosowanych w ocenie modeli. Wskaźniki te obejmują zarówno dokładność ogólną, jak i parametry bardziej szczegółowe: czułość, swoistość, precyzję oraz wartość predykcyjną negatywną. Dzięki temu możliwe było nie tylko określenie odsetka poprawnie sklasyfikowanych obserwacji, lecz także ocena zdolności modelu do wykrywania przypadków niezgodnych, co z punktu widzenia nadzorowania jakości ma kluczowe znaczenie. **Tabela 4.5** przedstawia zestawienie uzyskanych wartości wskaźników jakości klasyfikacji.

Tabela 4.5. Wskaźniki jakości klasyfikacji.


Wskaźnik	Wynik	Charakterystyka
Accuracy (dokładność)	81,50%	Odsetek wszystkich przypadków poprawnie sklasyfikowanych przez model.
Sensitivity (czułość)	75,00%	Odsetek wyrobów niezgodnych wykrytych jako niezgodne
Specificity (swoistość)	86,70%	Odsetek wyrobów zgodnych rozpoznanych jako zgodne
Precision (precyzja)	81,80%	Odsetek przypadków zakwalifikowanych jako niezgodne, które faktycznie były niezgodne
Negative Predictive Value (NPV)	81,30%	Odsetek przypadków zakwalifikowanych jako zgodne, które faktycznie były zgodne

Opracowanie własne.


Uzyskane wyniki potwierdzają wysoką skuteczność predykcyjną modelu, szczególnie w zakresie identyfikacji wyrobów niezgodnych, co ma istotne znaczenie dla prognozowania mikronieszczelności. Dodatkowym uzupełnieniem analizy były **wykresy pudełkowe** obrazujące rozkład trzech kluczowych zmiennych niezależnych: temperatury zgrzewania, ciśnienia w komorze pakującej i wydajności linii w podziale na wyroby zgodne i niezgodne (**Rysunek 4.30-4.32**). Analiza wykresów wskazuje, że wystąpienie niezgodności jest skorelowane z **przekroczeniem górnych wartości kluczowych parametrów procesu**, przy czym najsilniejszą dyskryminację uzyskano dla zmiennej opisującej wydajność linii.



Rysunek 4.30. Zróźnicowanie względem ciśnienia bezwzględnego w komorze pakującej (opracowanie własne).




Rysunek 4.31. Zróźnicowanie ze względu na temperaturę zgrzewania (opracowanie własne).



Rysunek 4.32. Zróźnicowanie ze względu na wydajność linii (opracowanie własne).

Dla pogłębionej oceny jakości klasyfikacji wykorzystano **krzywą ROC (Receiver Operating Characteristic)**, której analiza pozwala na ocenę zdolności dyskryminacyjnej modelu przy zmieniających się progach decyzyjnych. Krzywa ROC opracowanego modelu znajduje się **powyżej linii losowej klasyfikacji**, a **pole pod krzywą (AUC)** osiągnęło wartość około **0,85**, co świadczy o wysokiej skuteczności w rozróżnianiu wyrobów zgodnych i niezgodnych (**Rysunek 4.33**).



Rysunek 4.33. Wykres ROC dla modelu regresji logistycznej (opracowanie własne).

3. W warstwie decyzyjnej ostatecznym rezultatem opracowania modelu regresji logistycznej było stworzenie narzędzia predykcyjnego umożliwiającego wczesną identyfikację zwiększonego ryzyka wystąpienia mikronieszczelności w procesie konfekcjonowania. Na podstawie oszacowanych parametrów modelu sformułowano równanie pozwalające obliczać prawdopodobieństwo wystąpienia niezgodności w zależności od bieżących wartości kluczowych zmiennych technologicznych:

$$P(Y = 1) = \frac{\exp(-716,91 + 4,30 \cdot T + 0,0962 \cdot P + 0,4882 \cdot C)}{1 + \exp(-716,91 + 4,30 \cdot T + 0,0962 \cdot P + 0,4882 \cdot C)}$$

gdzie:

- T – temperatura zgrzewania [°C],
- P – ciśnienie bezwzględne w komorze pakującej [mbar],
- C – wydajność linii [szt./min],
- P(Y=1) – prawdopodobieństwo zakwalifikowania wyrobu jako niezgodnego.

Dla celów operacyjnych równanie zostało zaimplementowane w arkuszu kalkulacyjnym, co pozwalało na szybkie obliczanie wartości **P(Y=1)** dla pojedynczych pomiarów procesowych. Ponadto opracowano funkcje w aplikacji systemu nadzorowania, który automatycznie przetwarza dane z linii pakującej w czasie rzeczywistym. Dzięki temu operatorzy otrzymują natychmiastowe powiadomienia o zwiększonym ryzyku niezgodności i mogą szybko podjąć działania korygujące np. w zakresie parametrów procesu. W analizowanym procesie kluczowe znaczenie miało przyjęcie odpowiedniego

progu decyzyjnego, który umożliwia rozróżnienie wyrobów zgodnych i potencjalnie niezgodnych. Na podstawie przeprowadzonych badań przyjęto, że wartość graniczna $P = 0,9$ zapewnia skuteczne rozdzielenie obu grup, a reguły decyzyjne przyjęto w postaci:

- $P \leq 0,9$ – wyrób traktowany jako zgodny, co pozwala na odstąpienie od badań niszczących zawartości tlenu.
- $P > 0,9$ – wyrób klasyfikowany jako potencjalnie niezgodny i kierowany do dodatkowej weryfikacji poprzez pomiar na zawartość tlenu, z uwagi na ryzyko wystąpienia mikronieszczelności prowadzącej do przekroczenia dopuszczalnego poziomu tlenu.

Tak skonstruowana warstwa decyzyjna umożliwiła praktyczne zastosowanie modelu predykcyjnego w warunkach przemysłowych.

4. Warstwa wizualizacyjna pełniła funkcję interfejsu pomiędzy systemem nadzorowania a operatorem linii pakującej oraz personelem działu utrzymania ruchu. Jej zadaniem było udostępnianie w czasie rzeczywistym informacji o stanie procesu, odchyleniach od wartości referencyjnych oraz wynikach analiz predykcyjnych. Dane gromadzone w warstwie akwizycji i przetwarzane w warstwie analitycznej były prezentowane na ekranach paneli operatorskich HMI. Interfejs aplikacji umożliwiał bieżący podgląd kluczowych parametrów procesu, takich jak:

- liczba wsadów i średnia wydajność linii [szt./min], prędkość przenośnika i parametry docisku,
- temperatura poszczególnych grzałek elementów zgrzewających wraz z wartością zadaną,
- ciśnienie bezwzględne w komorze pakującej, czas zgrzewania,
- parametry materiałowe, takie jak napięcie folii czy ustawienia programu.

Przykładowy ekran aplikacji poglądowej przedstawiono na **Rysunku 4.34**. Widoczny jest na nim zestaw parametrów prezentowanych w czasie rzeczywistym, co umożliwia operatorowi natychmiastową ocenę stanu linii i podjęcie działań korygujących w przypadku przekroczenia progów alarmowych.

2025-04-24 10:31:52			
Food Makers - ProSeal Dania Gotowe		24/04/2025 CZW. 09:24:59	
Liczba wsadów [il.]	1565	Temperatura Grzałka 1 [°C]	162.9
Ilość paczek na minute [szt/min]	0.0	Temperatura Grzałka 2 [°C]	163.0
Średnia paczek na min [szt/min]	25	Temperatura Grzałka 3 [°C]	162.9
Ogólna średnia na min [szt/min]	18	Temperatura Grzałka 4 [°C]	163.0
Prędkość przenośnika	2	Temperatura Grzałka 5 [°C]	162.9
Czas zatrzymania [s]	1	Temperatura Zadana [°C]	163.0
Czas pauzowania [s]	1	Cisnienie pakowania (PV) [mbar]	989.3
Prędkość zgrzewania []	10	Czas zgrzewania [s]	1.3
		Gaz ciśnienie (sp) [mbar]	825
Napięcie folii [%]	50	Próżnia ciśnienie (sp) [mbar]	50
Zwiększenie siły [%]	10	Receptura:	farch papardelle
Baza		Ustawienia	

Rysunek 4.34. Interfejs aplikacji systemu dla modułu nadzorowania „nieszczelności II” (opracowanie własne na podstawie danych udostępnionych przez przedsiębiorstwo).

Model wsparcia diagnostycznego


W wyniku prac nad modulem nadzorowania „nieszczelności II” oraz badań nad modelem predykcyjnym opartym na regresji logistycznej uzyskano **dotatkowy, nieprzewidywany na etapie planowania badań** rezultat w postaci opracowania **modelu wsparcia diagnostycznego**. Podczas szczegółowej analizy danych zarejestrowanych w warstwach akwizycji i analitycznej zaobserwowano rzadkie, lecz powtarzające się anomalie w przebiegach temperatur elementów zgrzewających. Zjawisko to skłoniło do pogłębionej analizy statystycznej, której celem było powiązanie stabilności temperaturowej z występowaniem nieszczelności opakowań. W ramach badań diagnostycznych przeprowadzono statystyczne opracowanie danych temperaturowych pięciu grzałek linii pakującej w odniesieniu do wyników pomiarów zawartości tlenu w opakowaniach. Dla każdej grzałki obliczono podstawowe parametry opisowe, obejmujące średnią, medianę, odchylenie standardowe oraz wartości skrajne (minimum i maksimum). Analogiczne wskaźniki określono dla wyników pomiarów tlenu, co umożliwiło powiązanie stabilności temperaturowej z jakością zgrzewania i szczelnością opakowań. Zestawienie kluczowych parametrów pracy grzałek oraz odpowiadających im wyników pomiarów resztkowej zawartości tlenu przedstawiono w **Tabeli 4.6**. Porównanie to stanowi podstawę do dalszej interpretacji zależności pomiędzy zmiennością temperatur a ryzykiem powstawania mikronieszczelności.

Tabela 4.6. Porównanie statystyczne parametrów temperatury grzałek i wyników zawartości tlenu.

Wskaźnik	Grzałka nr 1	Grzałka nr 2	Grzałka nr 3	Grzałka nr 4	Grzałka nr 5
Nastawa temperatury [°C]	163	163	163	163	163
Średnia temperatura [°C]	162,941	162,928	162,964	162,945	162,854
Odchylenie standardowe temp. [°C]	0,167	0,188	0,240	0,189	1,209
Mediana temperatury [°C]	163,000	163,000	163,000	163,000	163,000
Min. temperatura [°C]	162,400	162,300	162,100	162,300	140,400
Średnia resztki tlenowej [%]	0,647	0,816	0,803	0,826	1,114
Mediana resztki tlenowej [%]	0,610	0,805	0,770	0,810	0,750
Odchylenie standardowe resztki tlenowej [%]	0,241	0,318	0,259	0,219	2,669
Max. resztką tlenową [%]	1,330	1,500	1,410	1,500	19,500

Opracowanie własne.

Analiza danych zestawionych w **Tabeli 4.6** jednoznacznie wskazuje, że **grzałka nr 5** znacząco odbiega od pozostałych pod względem odchylenia standardowego temperatury oraz wartości minimalnej. Tak duża zmienność temperaturowa sugeruje okresową utratę stabilności cieplnej, która może być konsekwencją uszkodzenia elementu grzejnego lub nieprawidłowości w jego układzie sterowania. Jednocześnie zaobserwowano, że to właśnie grzałka nr 5 charakteryzuje się największym odchyleniem standardowym wyników resztkowej zawartości tlenu (2,669 %) oraz wartością maksymalną na poziomie 19,5 %. Wyniki te jednoznacznie potwierdzają występowanie anomalii jakościowych w operacji pakowania i wskazują na bezpośredni wpływ niestabilności temperaturowej na szczelność opakowań. Dla pełniejszej interpretacji zależności przygotowano wizualne zestawienie zmienności temperatury poszczególnych grzałek z odpowiadającymi im wynikami pomiarów resztkowej zawartości tlenu. Wyniki tej analizy przedstawiono na **Rysunku 4.35**, który umożliwia szybką identyfikację źródła nieprawidłowości i podkreśla wyraźny związek pomiędzy zakłóceniami stabilności cieplnej a ryzykiem powstawania mikronieszczelności.



Rysunek 4.35. Porównanie zmienności temperatury i zawartości tlenu w opakowaniu (opracowanie własne).

Analiza statystyczna wykazała, że **odchylenie standardowe** temperatury grzałek stanowi istotny wskaźnik diagnostyczny, pozwalający na identyfikację wczesnych symptomów niestabilności pracy elementów grzewczych. Sama wartość średnia lub pojedynczy wynik pomiaru nie są wystarczające do wykrycia incydentalnych spadków temperatury, które mogą skutkować utratą szczelności opakowań. W celu opracowania **modelu wsparcia diagnostycznego** zdefiniowano system progów decyzyjnych, zestawiony w **Tabeli 4.7**.

Tabela 4.7. Progi diagnostyczne odchylenia standardowego temperatury grzałek wraz z charakterystyką stanu procesu.

Próg	Wartość	Charakterystyka
Ostrzegawczy	0,5 °C	wartość odchylenia standardowego wskazująca na początek niestabilności temperaturowej.
Krytyczny	0,7 °C	wartość odchylenia standardowego, której przekroczenie świadczy o statystycznie istotnym odchyleniu od pracy nominalnej zgodnie z zasadą 3σ , stosowaną w analizie zmienności procesów.

Opracowanie własne.

Logika działania opracowanego algorytmu diagnostycznego została przedstawiona na **Rysunku 4.36** w formie pseudokodu. Algorytm realizuje następujące kroki:

1. Oblicza odchylenie standardowe temperatury grzałki w zadanym oknie czasowym.
2. Klasyfikuje stan grzałki na jeden z trzech poziomów:
 - Stabilny ($\sigma \leq 0,5 \text{ °C}$)
 - Ostrzegawczy ($0,5 \text{ °C} < \sigma \leq 0,7 \text{ °C}$),
 - Krytyczny ($\sigma > 0,7 \text{ °C}$).

3. Reaguje w zależności od klasyfikacji:

- rejestracja stanu w logach systemowych,
- generowanie powiadomień dla operatora i działu UR,
- w przypadku stanu krytycznego: inicjacja procedury diagnostycznej w celu weryfikacji grzałki lub czujnika temperatury.

```
DANE_WEJŚCIOWE:
- temperatura[grzałka_X]
- wyniki_02[partia]
- numer_grzałki

OBLICZ:
- odchylenie_temp = STD(temperatura)
- odchylenie_02 = STD(wyniki_02)
- średnia_02 = MEAN(wyniki_02)

JEŚLI odchylenie_temp <= 0.5:
  status = "STABILNY"
  reakcja = "Brak działań"

ELSE JEŚLI 0.5 < odchylenie_temp <= 0.7:
  status = "OSTRZEŻENIE"
  reakcja = "Zalecana kontrola techniczna"
  POWIADOM_UR(status)

ELSE JEŚLI odchylenie_temp > 0.7 I (odchylenie_02 > 1.5 LUB średnia_02 > 1.0):
  status = "KRYTYCZNY"
  reakcja = "Natychmiastowa interwencja UR"
  POWIADOM_UR(status)

ZAPISZ_DO_LOGU(numer_grzałki, status, reakcja)
```

Rysunek 4.36. Logika działania modelu wsparcia diagnostycznego (opracowanie własne).

Zrealizowane prace potwierdziły, że mikronieszczelności stanowią krytyczne ryzyko jakościowe w operacji pakowania, a ich skuteczna kontrola wymaga połączenia podejścia eksperymentalnego, cyfryzacji danych i analityki. Przeprowadzone eksperymenty czynne pozwoliły wytypować trzy parametry krytyczne oraz wyznaczyć ich limity robocze, co stało się podstawą do zaprojektowania warstwy akwizycji zapewniającej pełną rejestrację, identyfikowalność i archiwizację danych procesowych. Na tej bazie opracowano w warstwie analitycznej model predykcji mikronieszczelności oparty na regresji logistycznej, którego skuteczność potwierdzono na zbiorze testowym i za pomocą krzywej ROC. W warstwie decyzyjnej wdrożono praktyczny próg interpretacyjny oraz mechanizm obliczania prawdopodobieństwa w systemie nadzorowania, co umożliwiło ograniczenie liczby badań niszczących i skrócenie czasu reakcji na odchylenia. Warstwa wizualizacyjna udostępnia wyniki w czasie rzeczywistym w postaci czytelnych ekranów HMI, wspierając operatorów i służby UR w pracy bieżącej. Dodatkowym rezultatem, powstałym w toku analiz, jest model wsparcia diagnostycznego oparty na zmienności temperatury grzałek, który zwiększa niezawodność nadzoru poprzez wczesne wykrywanie symptomów niestabilności procesu. Całość modułu tworzy spójne rozwiązanie, przenoszące kontrolę szczelności z poziomu wyrywkowych badań niszczących na poziom predykcyjnej oceny ryzyka opartej na danych rzeczywistych.

4.4. Moduł nadzorowania etykiet i ich treści

Operacja etykietowania jako ostatnia operacja procesu konfekcjonowania, ma kluczowe znaczenie dla zapewnienia identyfikowalności oraz zgodności wyrobu z wymaganiami prawnymi, jakościowymi i logistycznymi. Analiza reklamacji potwierdziła, że najczęściej występujące problemy to brak etykiety, błędne lub niepełne dane oraz obniżona jakość nadruku i kodów kreskowych, co utrudnia automatyczną identyfikację partii.

W przeciwieństwie do wcześniejszych modułów, w których konieczne było opracowanie dedykowanych modeli analitycznych, tutaj wystarczające okazało się wykorzystanie sprawdzonych narzędzi wizyjnych. Ich wybór uzasadniała prostota integracji, możliwość pracy w czasie rzeczywistym oraz zgodność z obowiązującymi normami jakości. Zastosowanie technik **OCR** do rozpoznawania znaków alfanumerycznych, analizy kodów i metod segmentacyjnych umożliwiło jednoznaczną weryfikację treści i położenia etykiet bez potrzeby rozwijania bardziej złożonych algorytmów.

Od modułu oczekiwano pełnej automatyzacji procesu weryfikacji etykiet w trzech obszarach: obecności etykiety, poprawności nadruku oraz jakości kodów. Celem było zastąpienie ręcznej kontroli wyrywkowej, ograniczenie ryzyka reklamacji oraz stworzenie bazy danych do analiz skuteczności procesu drukowania i aplikacji etykiet.

1. Warstwa akwizycji w module nadzorowania etykiet i treści została oparta na **tej samej infrastrukturze wizyjnej**, której szczegółowy opis przedstawiono w podrozdziale 4.2 dotyczącym nadzorowania „nieszczelności I” (Rysunek 4.6 oraz Tabela 4.1). **Stanowisko wizyjne**, zintegrowane z linią konfekcjonowania, umożliwiało jednoczesną rejestrację obrazów służących zarówno do kontroli szczelności, jak i do weryfikacji etykiet. **Kamery przemysłowe** wraz z dedykowanym oświetleniem LED zapewniały stabilne warunki akwizycji obrazu oraz synchronizację z transporterem, co gwarantowało rejestrację każdej jednostki wyrobu w sposób powtarzalny i jednoznaczny. W kontekście modułu etykietowania pozyskiwane dane obejmowały przede wszystkim **obrazy obszarów etykiety** zdefiniowane jako **ROI (Region of Interest)**. Dla każdego wyrobu rejestrowano **fragmenty nadruku z numerem partii i terminem przydatności, kody**, a także **poła nadruku** wykorzystywane do analizy kompletności i poprawności położenia etykiety. Każdy obraz otrzymywał **znacznik czasu** i przypisanie do **partii produkcyjnej**, co umożliwiało pełną identyfikowalność w dalszych etapach analizy. Zgromadzone dane były nie tylko podstawą do **bieżącej inspekcji jakości**, lecz także **archiwizowano je w centralnym repozytorium** systemu nadzorowania. Tworzyło to źródło materiału porównawczego do **badan statystycznych** nad skutecznością procesu drukowania i aplikacji etykiet oraz stanowiło **bazę danych do dalszych analiz rozwojowych systemu**.

2. W warstwie analitycznej modułu nadzorowania etykiet i treści zastosowano zestaw wyspecjalizowanych **narzędzi inspekcji wizyjnej**, umożliwiających jednoczesną ocenę obecności


etykiety, poprawności nadruku oraz jakości kodów kreskowych. Konfiguracja narzędzi została dostosowana do specyfiki procesu i obejmowała trzy główne komponenty:

- **OCR (Optical Character Recognition)** – narzędzie do rozpoznawania znaków alfanumerycznych nadrukowanych na etykiecie, takich jak numer partii czy data przydatności do spożycia. Analiza prowadzona była w zdefiniowanych polach **ROI**, w których system segmentował znaki i oceniał ich czytelność na podstawie parametrów kontrastu i jasności. Rezultaty przykładowej konfiguracji przedstawiono na **Rysunku 4.37**.




Rysunek 4.37. Interfejs konfiguracji narzędzia OCR do odczytu oznaczeń alfanumerycznych z etykiety wyrobu (opracowanie własne).

- **2D Code Analysis** – narzędzie do odczytu i oceny jakości kodów dwuwymiarowych (DataMatrix, QR). Oprócz poprawności odczytu system umożliwiał raportowanie wskaźników jakości zgodnie z normą **ISO/IEC 15415**, co miało istotne znaczenie zarówno dla praktycznej oceny stabilności nadruku, jak i walidacji procesu w kontekście wymagań normatywnych. Konfigurację przykładowego pola detekcji zaprezentowano na **Rysunku 4.38**.



Rysunek 4.38. Konfiguracja narzędzia 2D Code Analysis do odczytu i weryfikacji kodów DataMatrix na etykiecie (opracowanie własne).

- **Blob Finder** – algorytm do detekcji obecności i poprawności położenia nadrukowanej treści. Segmentacja obrazu na obszary o jednorodnym kontraście umożliwiała identyfikację przesunięć, obrotów lub częściowych braków nadruku. Narzędzie to sprawdzało się szczególnie przy wykrywaniu ubytków lub deformacji znaków. Przykład działania przedstawiono na **Rysunku 4.39**.



Rysunek 4.39. Wykorzystanie narzędzia Blob Finder do oceny jakości i ciągłości nadruku znaków na opakowaniu (opracowanie własne).

3. W warstwie decyzyjnej modułu nadzorowania etykiet i treści zdefiniowano **jednoznaczną logikę klasyfikacji wyrobów**, opartą na trzech kryteriach jakościowych:

- obecności etykiety,
- poprawności treści OCR,
- jakości kodu 2D.

Wyroby kwalifikowano jako **zgodny (OK)** wyłącznie wtedy, gdy wszystkie kryteria zostały spełnione. Niespełnienie któregośkolwiek z nich skutkowało klasyfikacją jako **NOK** i przekazaniem sygnału do układu odrzutu. Schemat logiki działania modułu zaprezentowano na **Rysunku 4.40**.

```

INPUT:
- KOD_OK: wynik analizy kodu 2D (True/False)
- OCR_OK: wynik analizy treści (True/False)
- ETYKIETA_WYKRYTA: True jeśli wykryto etykietę

ALGORITHM:
IF NOT ETYKIETA_WYKRYTA:
    sygnał = "ODRZUT"
ELSE IF KOD_OK AND OCR_OK:
    sygnał = "ZATWIERDŻONY"
ELSE:
    sygnał = "ODRZUT"

OUTPUT:
sygnał + aktualizacja statystyk

```

Rysunek 4.40. Schemat logiki działania modułu kontroli etykiet (opracowanie własne).

W przypadku klasyfikacji **NOK** system automatycznie generował sygnał na wyjściu cyfrowym sterującym modulem odrzutu. Zastosowano deterministyczny podział funkcji portów:

- **IO3**: sygnał dla wyrobu zgodnego (All passed),
- **IO5**: sygnał aktywowany przy dowolnej niezgodności (Any fail),
- **IO4, IO6**: linie pomocnicze, pełniące rolę sygnałów informacyjnych o zakończeniu inspekcji.

Przykładową konfigurację wyjść cyfrowych przedstawiono na **Rysunku 4.41**.

Port	Enabled	Result	Deactivate after	State
IO3	☒	All passed	☒ - 10 + ms	ms ●
IO4	☐	Result ready	☒ - 10 + ms	ms ●
IO5	☒	Any fail	☒ - 10 + ms	ms ●
IO6	☐	Result ready	☒ - 10 + ms	ms ●

Rysunek 4.41. Konfiguracja wyjść cyfrowych dla modułu analizy etykiet (opracowanie własne).

Tak zdefiniowana warstwa decyzyjna umożliwiała zamknięcie pętli jakościowej od rejestracji obrazu, poprzez analizę treści etykiety, aż po deterministyczną decyzję o przekazaniu wyrobu do dalszego etapu lub jego eliminacji z procesu.

4. Warstwa wizualizacyjna modułu nadzorowania etykiet i treści została zaprojektowana w taki sposób, aby zapewnić operatorowi **natychmiastowy dostęp do wyników inspekcji w czasie rzeczywistym** oraz umożliwić pełną kontrolę nad procesem. Aplikacja operatorska prezentowała nie tylko rezultat analizy każdej jednostki, lecz także zestawienia statystyczne, obejmujące liczbę wyrobów zgodnych i niezgodnych, wskaźnik skuteczności (Passing Rate) oraz historię wyników dla danej partii.

System wizualizacji umożliwiał **podgląd obszarów analizy ROI** wraz z zaznaczonymi polami inspekcji OCR i kodów 2D, co ułatwiało identyfikację przyczyny decyzji NOK. Interfejs wyposażono w sygnalizację kolorystyczną (zielony oznacza wyrób zgodny, czerwony oznacza wyrób niezgodny) oraz funkcje konfiguracyjne pozwalające operatorowi dostosować parametry detekcji.

Przykładowy ekran aplikacji operatorskiej przedstawiono na **Rysunku 4.42**. Widoczny jest na nim panel z obrazem kontrolowanego wyrobu, zaznaczonym polem etykiety oraz zestawieniem liczbowym obejmującym całkowitą liczbę próbek, liczbę wyrobów zgodnych i odrzuconych, a także procentowy wskaźnik skuteczności procesu.



Rysunek 4.42. Interfejs wizualizacji wyników inspekcji etykiet (opracowanie własne).

Dzięki takiej organizacji warstwy wizualizacyjnej operator miał możliwość **szybkiego podejmowania decyzji korygujących**, a równocześnie system automatycznie gromadził dane w repozytorium, co zapewniało podstawę do analiz retrospektywnych i raportów jakościowych.

4.5. Moduł nadzorowania odrzutu wyrobów niezgodnych


Moduł odrzutu stanowi ostatni element zintegrowanego systemu nadzorowania i odpowiada za **fizyczne usuwanie z linii produkcyjnej wyrobów niezgodnych**. W przeciwieństwie do poprzednich modułów, które koncentrują się na wykrywaniu określonych niezgodności w poszczególnych operacjach (naważanie, pakowanie, etykietowanie), odrzutnik obejmuje swoim działaniem **wyniki wszystkich operacji procesu konfekcjonowania**. Oznacza to, że każda jednostka zaklasyfikowana jako **NOK**, niezależnie od rodzaju stwierdzonej wady, musi zostać automatycznie wyeliminowana z dalszego strumienia produkcyjnego. Odrzut jest kluczowy, ponieważ nawet skuteczna inspekcja nie gwarantuje skuteczności, jeżeli wadliwy wyrób nie zostanie odseparowany od wyrobów zgodnych. **Zidentyfikowany problem** dotyczył sytuacji, w których pomimo poprawnej klasyfikacji, wyroby niezgodne mogły trafiać do dalszych etapów procesu logistycznego, powodując reklamacje, straty materiałowe i zakłócenia dystrybucji. Stąd konieczne było wdrożenie mechanizmu deterministycznego, zapewniającego pełną powtarzalność reakcji na sygnały z wcześniejszych modułów.

Spośród rozważanych technologii odrzutu (m.in. systemy powietrzne, układy mechaniczne, manipulatory) zdecydowano się na **układ pneumatyczny z siłownikami szybkiego działania**. Rozwiązania wykorzystujące sprężone powietrze, choć stosowane w liniach wysokowydajnych, okazały się w analizowanym środowisku mniej korzystne z kilku powodów:

- generowały wysoki poziom hałasu i dodatkowe zapotrzebowanie na medium energetyczne,
- wymagały częstej konserwacji dysz i filtrów,
- charakteryzowały się mniejszą precyzją w przypadku wyrobów o zróżnicowanej masie i kształcie.

Zastosowanie **siłownika pneumatycznego** zapewniło natomiast szybki czas reakcji, wysoką powtarzalność i odporność na zmienne warunki pracy w środowisku wdrożeniowym.

1. W warstwie akwizycji modułu odrzutu kluczowe znaczenie miało **zapewnienie jednoznacznej synchronizacji działania siłownika pneumatycznego z pozycją tacki na przenośniku**. W tym celu zastosowano **czujniki obecności oraz czujniki pozycjonujące**, które umożliwiały precyzyjne wykrywanie momentu, w którym wyrób zaklasyfikowany jako NOK osiągał pozycję odrzutnika. Dane z tych czujników były następnie przekazywane do sterownika **PLC Mitsubishi FX5U**, stanowiącego podstawę układu sterowania. Integralnym elementem stanowiska była konstrukcja wykonana ze stali nierdzewnej, zgodna z wymogami higienicznymi branży. Widok stanowiska odrzutu przedstawiono na **Rysunku 4.43**.



Rysunek 4.43. Widok stanowiska odrzutu wyrobów niezgodnych z siłownikiem pneumatycznym (opracowanie własne).

W ramach warstwy akwizycji rejestrowano również dane eksploatacyjne dotyczące liczby wyrobów przekazanych do dalszego etapu oraz liczby odrzuconych jednostek. Informacje te były zapisywane w systemie nadzorowania i wykorzystywane w kolejnych warstwach. Dodatkowo, aby zapewnić pełną kontrolę nad poprawnością procesu, układ akwizycji został powiązany z **czujnikiem zapelnienia pojemnika odrzutowego**, który generował sygnał ostrzegawczy w przypadku osiągnięcia jego maksymalnej pojemności. Fragment dokumentacji elektrycznej systemu odrzutu przedstawiono w **Załączniku Z.4**.

2. Warstwa analityczna w module odrzutu miała charakter pomocniczy i sprowadzała się do scalania sygnałów z poprzedzających modułów nadzorowania oraz do ich synchronizacji z danymi z czujników obecności i pozycjonowania opakowania. W ten sposób każdemu wyrobowi przypisywano status jakościowy OK lub NOK, który następnie przekazywano do sterownika PLC. Zadaniem tej warstwy było więc przygotowanie jednoznacznej informacji wejściowej dla warstwy decyzyjnej, bezpośrednio odpowiedzialnej za sterowanie siłownikiem pneumatycznym.

3. Warstwa decyzyjna przekształca przygotowany w warstwie analitycznej **status jednostki (OK/NOK)**, zsynchronizowany z informacją o **położeniu tacki**, w **deterministyczne działanie wykonawcze**. Zasada jest jednoznaczna:

- **OK** → brak akcji wykonawczej, wyrób kontynuuje przepływ,
- **NOK** → wygenerowanie **impulsu sterującego z PLC** i uruchomienie **siłownika pneumatycznego** odrzucającego wyrób na tor odrzutowy.

Logikę tę przedstawiono na **Rysunku 4.44**.

```
INPUT:
- KAMERA1_OK: True/False
- KAMERA2_OK: True/False
- KAMERA3_OK: True/False

ALGORITHM:
IF NOT (KAMERA1_OK AND KAMERA2_OK AND KAMERA3_OK):
    sygnal = "ODRZUT"
ELSE:
    sygnal = "ZATWIERDZONY"

OUTPUT:
- Sterowanie siłownikiem pneumatycznym
- Aktualizacja liczników i statystyk

ALARMY:
- Alarm bezpieczeństwa → czerwone światło
- Brak potwierdzenia odrzutu → żółte pulsujące + brzęczyk
- Zapelnienie odrzutu → żółte stałe + brzęczyk
- Różnica liczników → czerwone pulsujące światło
```


Rysunek 4.44. Schemat logiki działania modułu odrzutu wyrobów niezgodnych (opracowanie własne).

Aby zapewnić **powtarzalność i bezpieczeństwo działania**, decyzja wykonawcza jest uzależniona od spełnienia warunków pomocniczych:

- potwierdzonej **obecności wyrobu w strefie odrzutu** (czujnik pozycjonujący),
- **okna czasowego** skorelowanego z prędkością przenośnika,
- braku aktywnych sygnałów **E-Stop** oraz **przepełnienia pojemnika odrzutowego** (w takich przypadkach następuje **blokada impulsu** i sygnał alarmowy do operatora).

4. **Warstwa wizualizacyjna** modułu odrzutu pełniła funkcję interfejsu pomiędzy systemem a operatorem, zapewniając **bieżący podgląd pracy oraz pełną diagnostykę procesu odrzutu** (Rysunek 4.45). W ramach tej warstwy operator otrzymywał informacje o:

- liczbie wyrobów zaklasyfikowanych jako **OK** i **NOK**,
- aktualnym stanie pracy siłownika,
- statusach bezpieczeństwa (np. aktywacja przycisku **E-Stop**, otwarcie osłon),
- sygnale czujnika zapełnienia pojemnika odrzutowego,
- komunikatach alarmowych w przypadku braku synchronizacji lub opóźnienia sygnału decyzyjnego



Rysunek 4.45. Panel webowy modułu odrzutu wyrobów niezgodnych (opracowanie własne).

Wizualizacja była realizowana za pośrednictwem **panelu HMI oraz interfejsu webowego**, które umożliwiały zarówno **monitorowanie online**, jak i dostęp do danych archiwalnych. Operator mógł w prosty sposób przeanalizować historię odrzuconych wyrobów wraz z przyczynami decyzji, co zwiększało transparentność systemu i wspierało działania korygujące. Na **Rysunku 4.46** przedstawiono przykładowe widoki aplikacji operatorskiej, ukazujące sygnały diagnostyczne.

Diagnostyka	
Bezpieczeństwo	●
Kontrola odrzutu	●
Dostępność odrzutu	●
Liczenie tacek	●

Rysunek 4.46. Ekran diagnostyczny modułu odrzutu (opracowanie własne).

Tak zorganizowana warstwa wizualizacyjna zapewniała operatorom i służbom utrzymania ruchu **natychmiastową informację zwrotną** o skuteczności odrzutu, ułatwiała podejmowanie decyzji oraz umożliwiała dokumentowanie skuteczności eliminacji wyrobów niezgodnych w czasie rzeczywistym.

4.6. Cyberbezpieczeństwo systemu

Efektywność opracowanego systemu nadzorowania nad procesem konfekcjonowania wyrobów zależy nie tylko od skuteczności poszczególnych modułów, lecz także od **bezpiecznego gromadzenia, archiwizacji i ochrony danych procesowych**. Z uwagi na wielowarstwową budowę rozwiązania obejmującą cyfryzację procesu pakowania i naważania, rejestrację danych z maszyn, analizę szczelności opakowań, kontrolę etykietowania oraz obsługę odrzutów opracowano **zintegrowaną politykę akwizycji i zabezpieczenia danych**, obejmującą warstwę sprzętową i programową.

W trakcie realizacji projektu konieczna była **rozbudowa serwerowni oraz infrastruktury bazodanowej**, co umożliwiło archiwizację obrazów z kamer wizyjnych, parametrów technologicznych pakowania, wyników pomiarów wagowych, logów alarmowych i klasyfikacji wyrobów. Dane zapisywane były w sieci wewnętrznej, odizolowanej od Internetu, co minimalizowało ryzyko nieautoryzowanego dostępu. Wdrożono także **harmonogram kopii zapasowych** oraz **politykę retencji danych**, co ogranicza ryzyko utraty informacji i wspiera audyt zgodności.

W systemie zastosowano zestaw zabezpieczeń fizycznych i logicznych, obejmujących m.in.:

- **zasilanie awaryjne UPS**;
- **firewall sprzętowy i programowy** realizujący segmentację sieci;
- **ograniczenie dostępu na podstawie ról użytkowników** (operator, kierownik zmiany, utrzymanie ruchu, administrator IT);
- **autoryzację adresów IP i rejestrację zdarzeń systemowych**, co umożliwiało prowadzenie audytów bezpieczeństwa.

Dodatkowo ograniczenia dostępu konfigurowano **na poziomie każdego modułu**, tak aby operator mógł jedynie nadzorować bieżącą pracę, kierownik produkcji analizować wskaźniki, a administrator miał pełen dostęp do infrastruktury i konfiguracji. Przegląd uprawnień użytkowników realizowano **okresowo**, a w przypadku zmian personalnych stosowano procedurę **natychmiastowego cofnięcia uprawnień**. Tak zaprojektowany model akwizycji i ochrony danych wpisuje się w wymagania nowoczesnych systemów nadzorowania, łącząc **niezawodność rejestracji danych z wysokim poziomem zabezpieczenia przed utratą i ingerencją zewnętrzną**.

5. Walidacja i ocena działania systemu

Walidacja i ocena działania stanowią kluczowy etap badań, umożliwiającą obiektywne potwierdzenie poprawności implementacji inteligentnego systemu nadzorowania procesu konfekcjonowania oraz określenie jego przydatności w warunkach przemysłowych. Walidacja modułowa obejmowała weryfikację działania pięciu modułów funkcjonalnych: nadzorowania masy porcji, nadzorowania „nieszczelności I”, nadzorowania „nieszczelności II”, nadzorowania etykiet i ich treści oraz odrzutu wyrobów niezgodnych. Ocenie poddano również modele analityczne opracowane w ramach implementacji: model inspekcji wizyjnej oparty na głębokim uczeniu, model predykcji mikronieszczelności opakowań oparty na regresji logistycznej oraz model wsparcia diagnostycznego bazujący na analizie zmienności temperatury grzałek.

Ocena całościowa systemu została przeprowadzona na rzeczywistych danych operacyjnych z linii konfekcjonowania. Analiza obejmowała porównanie wskaźników jakościowych i efektywnościowych (m.in. DPMO, OEE, wydajność linii) przed i po wdrożeniu systemu, co pozwoliło jednoznacznie określić jego wpływ na stabilność procesu oraz redukcję niezgodności. Uzupełnieniem walidacji była analiza SWOT, umożliwiająca identyfikację mocnych i słabych stron systemu, a także ocenę szans i zagrożeń związanych z jego eksploatacją i możliwością dalszej adaptacji w innych liniach technologicznych.

5.1. Weryfikacja modułów i modeli

Dla **modułu nadzorowania masy porcji** walidację przeprowadzono ze szczególnym uwzględnieniem poprawności działania i dokładności technicznej urządzeń pomiarowych. **Specyfikacja producenta zakłada dokładność pomiarową na poziomie 1 g**, co zostało zweryfikowane w ramach kalibracji przy użyciu legalizowanych odważników referencyjnych, zgodnych z wymaganiami Ustawy z dnia 7 maja 2009 r. o towarach paczkowanych (Dz.U. 2009 nr 91 poz. 740). Legalizację odważników potwierdzono w **Załącznikach Z.6 i Z.7**. W ramach walidacji wykonano serię prób kalibracyjnych, które wykazały, że odchylenia od wartości wzorcowych mieściły się w granicach błędu metrologicznego urządzenia. Sprawdzone również **ciągłość i spójność ścieżki danych**, weryfikując, czy wartości rejestrowane na **urządzeniu pomiarowym, panelu operatorskim HMI oraz w raportach systemowych są zgodne i zsynchronizowane w czasie**. Nie odnotowano rozbieżności przekraczających granicę dokładności pomiarowej, co potwierdziło prawidłowe działanie toru akwizycji i rejestracji danych. Dodatkowo walidację przeprowadzono w różnych warunkach eksploatacyjnych, przy zmianach prędkości linii, różnych obciążeniach stanowisk i wariantach receptur. Moduł zachował stabilność pracy oraz odporność na czynniki zakłócające, takie jak wibracje transportera czy zmiany temperatury otoczenia.

Dla **modułu nadzorowania „nieszczelności I”** walidację rozpoczęto od **testów konfiguracji układu wizyjnego**. Sprawdzano wpływ kluczowych parametrów technicznych kamer przemysłowych

jak czasu ekspozycji, kontrastu, jasności oraz pola widzenia na jakość rejestrowanych obrazów (Rysunek 4.7). Celem było uzyskanie stabilnych i powtarzalnych zdjęć opakowań, niezależnych od warunków oświetleniowych i zmienności procesu. Kolejnym etapem była **walidacja zapisu obrazów**, obejmująca:

- kontrolę poprawności formatu i rozdzielczości plików,
- weryfikację integralności zapisu w bazie danych,
- sprawdzenie czy system nie pomija pojedynczych zdjęć przy maksymalnej wydajności linii,
- testy w warunkach krytycznych (naprzemienne podstawianie opakowań zgodnych i niezgodnych, praca na największej prędkości przenośnika).

Następnie walidacji poddano **algorytmy analizy obrazu**. W pierwszej fazie testowano pierwotne wersje klasyfikatora, dla których uzyskano wysoką skuteczność na zbiorze treningowym, lecz niższą stabilność na zbiorze walidacyjnym. **Model ostateczny oparty na konwolucyjnej sieci neuronowej (CNN)** osiągnął:

- **dokładność 100% na zbiorze treningowym, 97% na zbiorze walidacyjnym przy progu ufności 90%,**
- **czułość 95% i precyzję 100% dla klasy NOT OK**, co potwierdziło minimalną liczbę fałszywych alarmów.

Wyniki ewolucji modeli przedstawiono na podstawie **funkcji straty (loss function)** dla zbioru treningowego i walidacyjnego. Analiza przebiegu wskazała na stabilne dopasowanie modelu ostatecznego, bez oznak przeuczenia, co potwierdzono poprzez utrzymywanie niskiej wartości funkcji straty dla obu zbiorów (strata na zbiorze walidacyjnym utrzymywała się w granicach **0,2–0,4**). Dla pełnej oceny przygotowano **macierze pomyłek** zarówno dla modeli pierwotnych, jak i modelu ostatecznego. Macierz dla modelu ostatecznego potwierdziła bardzo wysoką skuteczność klasyfikacji i szczególnie dobrą zdolność rozpoznawania klasy „NOT OK”. Odrębną częścią walidacji były **próby w warunkach rzeczywistych**. Przeprowadzono dwa scenariusze:

- test funkcjonalny z podstawianiem próbek wadliwych, gdzie z 10 opakowań niezgodnych 9 sklasyfikowano poprawnie (**90% skuteczności**),
- test symulacji produkcji obejmujący **~900 próbek**, który potwierdził stabilność działania systemu, spójność zapisu danych oraz odporność na zmienne warunki oświetleniowe. **99% poprawnych klasyfikacji** w serii ponad 880 próbek

W obu scenariuszach monitorowano także **czas akwizycji i przetwarzania obrazu**, który średnio nie przekraczał **250 ms**. Wartość ta zapewniała pełną synchronizację z przenośnikiem i nie generowała opóźnień w systemie nadrzędnym, co było kluczowe dla integracji modułu wizyjnego z pozostałymi elementami systemu nadzorowania. Moduł jako całość, potwierdził odporność na zakłócenia i stabilność zapisu danych w bazie.

Dla modułu nadzorowania „nieszczelności II” walidację rozpoczęto od **weryfikacji akwizycji danych procesowych**, które stanowiły podstawę dla dalszych analiz diagnostycznych i predykcyjnych.

Sprawdzono poprawność odczytów kluczowych zmiennych jak **temperatury zgrzewania, ciśnienie bezwzględne w komorze pakującej pakującej oraz wydajności linii**, porównując wartości wyświetlane na panelach operatorskich HMI z zapisami w raportach systemowych oraz w plikach przygotowanych jako dane wejściowe dla modelu predykcyjnego. Szczególną uwagę poświęcono **aspektowi metrologicznemu**. Do pomiaru temperatury zastosowano pięć czujników rezystancyjnych Pt100 w wykonaniu przemysłowym, zgodnym z normą PN-EN 60751. Każdy tor pomiarowy był poddawany **rotacyjnej kalibracji**, jeden komplet czujników pracował w maszynie, a drugi poddawano okresowej kalibracji laboratoryjnej. **Kartę katalogową czujników temperatury (DTR)** dodano w Załączniku Z.3. Integralną częścią układu walidacyjnego był również **analizator gazowy OXY BABY**, stosowany do niszczących pomiarów zawartości tlenu w opakowaniach. Urządzenie było regularnie kalibrowane zgodnie z procedurami zakładowymi, a **świadczenia wzorcowania i protokoły kalibracyjne przedstawiono w Załącznikach Z.9 i Z.10**. Pomiary zawartości tlenu traktowano jako **etykiety referencyjne** (ground truth) w ocenie szczelności i skuteczności modelu predykcyjnego. Próbkę niszczących pomiarów tlenu łączono z obserwacjami procesowymi poprzez znacznik czasu i identyfikator partii oraz numer gniazda w cyklu, z uwzględnieniem stałego przesunięcia czasowego między zakończeniem zgrzewania a pomiarem. Zakres monitorowanych parametrów oraz odpowiadające im progi alarmowe zestawiono w Tabeli 4.2.

Na podstawie zgromadzonego zbioru danych (174 obserwacje procesowe) opracowano i zwalidowano **model predykcji mikronieszczelności oparty na regresji logistycznej**. Do walidacji wykorzystano klasyczny podział na zbiór treningowy i testowy. Na zbiorze testowym uzyskano następujące wyniki:

- **dokładność 81,5%, czułość 75,0%,**
- **swoistość 86,7%, precyzja 81,8%,**
- **NPV 81,3%,**
- **AUC = 0,85.**

Wartość progu **P=0,9** wyznaczono na podstawie analizy krzywej ROC jako kompromis maksymalizujący sumę czułości i swoistości przy preferencji ograniczenia fałszywych alarmów. Przyjęty próg decyzyjny **P = 0,9** umożliwił skuteczne rozróżnianie wyrobów zgodnych i potencjalnie niezgodnych, co pozwoliło na **redukcję liczby badań niszczących** i wczesną identyfikację partii obciążonych ryzykiem nieszczelności.

Dodatkowym efektem walidacji danych było wykrycie **anomalii temperaturowych w pracy elementów zgrzewających**. Szczegółowa analiza wykazała, że **grzałka nr 5** znacząco odbiegała od pozostałych pod względem stabilności cieplnej a jej **odchylenie standardowe temperatury wynosiło 1,209 °C**, podczas gdy dla pozostałych mieściło się w przedziale 0,167–0,240 °C. Jednocześnie przypisane do niej próbki charakteryzowały się podwyższonym odchyleniem resztkowej zawartości tlenu (**2,669%**) oraz wartością maksymalną na poziomie **19,5%**. Wyniki te stanowiły podstawę do opracowania **modelu wsparcia diagnostycznego**, opartego na analizie zmienności temperatury grzałek

i progach diagnostycznych: **0,5 °C (ostrzeżenie)** i **0,7 °C (krytyczny)**. Ich przekroczenie pozwalało na **wczesną identyfikację symptomów niestabilności**, umożliwiając skierowanie działań serwisowych jeszcze przed wystąpieniem istotnych niezgodności jakościowych.

Dla modułu nadzorowania etykiet i treści walidację rozpoczęto od weryfikacji działania systemu wizyjnego w zakresie rejestracji obrazów etykiet i kodów. Szczegółowe testy konfiguracji kamer obejmujące dobór czasu ekspozycji, kontrastu, jasności oraz pól detekcji zostały wcześniej przeprowadzone przy okazji walidacji modułu „nieszczelności I”, co pozwoliło na opracowanie stabilnych ustawień, zapewniających wysoką jakość zdjęć także w przypadku inspekcji etykiet. Weryfikacja w module etykietowania dotyczyła więc przede wszystkim poprawności zapisu obrazów, ich rozdzielczości, formatu oraz ciągłości rejestracji przy pracy z maksymalną wydajnością linii. Potwierdzono, że system nie pomija próbek, a wszystkie obrazy były jednoznacznie tagowane i archiwizowane. Kolejnym elementem walidacji była ocena jakości kodów kreskowych. W tym celu przeprowadzono badania w laboratorium **Lukasiewicz – ILiM**, które pozwoliły na niezależną weryfikację klasy czytelności kodów zgodnie z wymaganiami normy **ISO/IEC 16022**. Wyniki uzyskane w badaniach laboratoryjnych zestawiono z interpretacją stosowaną przez oprogramowanie systemu nadzorowania, co potwierdziło ich zgodność i wiarygodność działania. Dokumentację z badań stanowi **Załącznik Z.8**. W ramach walidacji przygotowano także celowo zmodyfikowane próbki etykiet: brak etykiety, celowo zdeformowane kody, brak lub modyfikacja daty przydatności, pojedyncze zmiany liter lub cyfr imitujące typowe błędy pracownicze. System skutecznie identyfikował większość z przygotowanych niezgodności. W trakcie walidacji ujawniono jednak problem rozróżniania litery „O” i cyfry „0”. Po zdiagnozowaniu tego ograniczenia przeprowadzono dodatkowe douczenie algorytmu OCR na nowym zestawie danych, obejmujących alternatywne czcionki. Po tej modyfikacji system prawidłowo klasyfikował także przypadki wcześniej błędnie interpretowane. Dodatkowo monitorowano czas zapisu i analizy obrazu, **nie przekraczał on 250 ms**, co było kluczowe dla zapewnienia pełnej synchronizacji z przenośnikiem i modułem odrzutu. W testach laboratoryjnych moduł osiągnął **100% skuteczności**, natomiast w warunkach przemysłowych Passing Rate wyniósł **99,3%** (716 poprawnych odczytów na 721, 5 błędów)

Dla modułu nadzorowania odrzutu wyrobów niezgodnych walidacja modułu odrzutu obejmowała w pierwszej kolejności **weryfikację poprawności synchronizacji układu pneumatycznego z prędkościami transporterów** oraz współpracę z enkoderem odpowiedzialnym za detekcję pozycji produktu na linii produkcyjnej. Kluczowym elementem było sprawdzenie czy odrzutnik aktywuje się dokładnie w momencie, gdy niezgodny produkt znajduje się w strefie wyrzutu, niezależnie od aktualnej prędkości pracy linii. Równolegle sprawdzano poprawność działania **czujników obecności i pozycji wyrobu**, których zadaniem było inicjowanie sekwencji odrzutu. Testy walidacyjne wykazały, że sygnały były stabilne i powtarzalne, a ich czas reakcji nie powodował błędów synchronizacyjnych ani pominięć produktów. Kolejnym etapem była **weryfikacja funkcjonalna w warunkach kontrolowanych**. W ramach walidacji podstawiano na przenośniku zarówno wyroby

zgodne (OK), jak i niezgodne (NOK), w różnych konfiguracjach przestrzennych i czasowych. Analiza obejmowała:

- naprzemienne podstawianie próbek zgodnych i niezgodnych,
- sekwencje kilku kolejnych wyrobów NOK,
- rozmieszczenie niezgodnych próbek na początku, w środku i na końcu serii,
- pracę przy maksymalnej wydajności linii, symulując najtrudniejsze warunki eksploatacyjne.

W każdej z konfiguracji system zapewnił poprawną interpretację próbek: 100% wyrobów zgodnych przepuszczono, a 100% wyrobów niezgodnych skierowano do odrzutu.

Walidacja poszczególnych modułów oraz modeli wymagała znaczącego nakładu pracy operacyjnej i metrologicznej w środowisku produkcyjnym. Zgodnie z przyjętą strategią **moduły i modele wdrażano sekwencyjnie**, co umożliwiało iteracyjne dopracowanie algorytmów i procedur. **Największym wyzwaniem okazała się cyfryzacja danych procesowych z maszyny pakującej**, a więc **weryfikacja, walidacja i synchronizacja** tych danych z odczytami referencyjnymi; prace te stanowiły **fundament dla modelu predykcyjnego**. W module wizyjnym konieczna była **rozbudowa bazy danych i wielokrotne cykle uczenia**, ponieważ **modele pierwotne** nie zapewniały satysfakcjonujących wyników; dopiero **kolejne iteracje** przyniosły stabilny model końcowy. W module etykietowania rozwiązano problem OCR „O” vs „0” poprzez **douczenie na nowej czcionce**. **Z każdego etapu walidacyjnego sporządzono raport zgodny z praktyką wdrożeniową**, a dla każdego modułu opracowano **pilotażową instrukcję eksploatacyjną**. Podsumowując, walidacja została przeprowadzona zgodnie z założeniami, a **wyniki potwierdzają przydatność i skuteczność** poszczególnych modułów oraz modeli w warunkach przemysłowych.

5.2. Walidacja całościowa na danych operacyjnych

W niniejszym podrozdziale przedstawiono wyniki walidacji całościowej, obejmującej działanie zintegrowanego systemu nadzorowania procesu konfekcjonowania w warunkach przemysłowych. Oceny dokonano na podstawie danych operacyjnych, zestawionych w formie **kluczowych wskaźników efektywności (KPI)** oraz **wskaźników jakościowych** odnoszących się do poszczególnych operacji procesu konfekcjonowania. Analiza porównawcza objęła okres bazowy (2021–2022) oraz okres po implementacji systemu (2023–2025), co pozwoliło jednoznacznie określić jego wpływ na jakość, stabilność i efektywność linii produkcyjnej. W dalszej części ujęto również aspekt ekonomiczny wdrożenia, a końcowe zestawienie wskaźników w formie tabelarycznej umożliwia bezpośrednie porównanie wartości parametrów procesowych i KPI przed i po wdrożeniu.

Walidację **modułu nadzorowania masy porcji** przeprowadzono w oparciu o dane operacyjne z okresu bazowego (2021–2022) oraz z okresu po implementacji systemu (2023–2024). Analizie poddano wskaźniki jakości naważania, stabilność procesu, a także wpływ na straty surowca. Dane historyczne jednoznacznie wskazują na poprawę procesu po wdrożeniu zaawansowanych wag


platformowych. Jak przedstawiono w **Tabeli 5.1**, odsetek niedowag spadł z **2,56%** (2021) do **0,36%** (2024), natomiast przeważenia zmniejszyły się z **4,60%** do **2,10%**.

Tabela 5.1. Wyniki walidacji procesu naważania: liczba opakowań, masa surowca oraz odsetek niedowag i przeważen w latach 2021–2024.

Rok produkcji	Czas produkcji (min)	Zaakceptowane opakowania (szt.)	Niedowagi (szt.)	Masa całkowita (kg)	Masa przeważona (kg)	Niedowagi (%)	Przeważenie (%)
2021	51088	764828	19556	275981	12724	2,56%	4,60%
2022	107281	1627838	28736	606096	24191	1,77%	4,00%
2023	68368	870093	7363	335923	7092	0,85%	2,10%
2024	91678	1351397	4811	532215	11389	0,36%	2,10%


Opracowanie własne.

Na **Rysunku 5.1** przedstawiono zmiany w procentowych wartościach przeważen i niedowag w analizowanym okresie czterech lat. Widoczny jest wyraźny trend spadkowy dla obu wskaźników.




Rysunek 5.1. Wykres zmian odsetka przeważen i niedowag w latach 2021–2024 (opracowanie własne).

W celu oceny stabilności procesu wykorzystano raporty produkcyjne z lat 2022 i 2024. Analiza histogramów rozkładu masy naważania dla badanego wyrobu pozwoliła na dokładne porównanie jakości i powtarzalności procesu w tych latach. Raport z 2022 roku wskazuje, że średnia masa produktu wynosiła **421,85 g** a odchylenie standardowe osiągnęło poziom **18,07 g** (**Rysunek 5.2**). Minimalna masa w próbie wyniosła **376,80 g** a maksymalna **495,00 g** co świadczy o dużym rozrzucie wartości względem masy nominalnej wynoszącej **400 g**. Zarejestrowano **81** opakowań niedoważonych oraz **32** przeważone, przy czym przeważenia stanowiły **5,18%** całkowitej masy.



Rysunek 5.2. Histogram rozkładu masy wyrobów: dane z 2022 roku (opracowanie własne).


W roku 2024 stabilność procesu uległa znacznej poprawie. Średnia masa wyniosła **403,31 g** a odchylenie standardowe spadło do **6,71 g**. Minimalna masa wyniosła **382,20 g** a maksymalna **446,20 g** co oznacza, że rozrzut danych został znacznie zawężony. Nie odnotowano przypadków opakowań niedoważonych. Histogram przedstawiony na **Rysunku 5.3.** pokazuje wyraźne skupienie mas wokół wartości docelowej, co świadczy o wysokiej powtarzalności i precyzji modelu nadzorowania masy porcji.



Rysunek 5.3. Histogram rozkładu masy wyrobów: dane z 2024 roku (opracowanie własne).


Analiza **wskaźnika strat surowca**, rozumianego jako ubytek materiału w procesie naważania, stanowi istotny element oceny efektywności technologicznej i gospodarności wykorzystania surowców. Zastosowanie **zaawansowanych wag platformowych** pozwoliło na wyraźne ograniczenie strat materiałowych, poprawę powtarzalności oraz zwiększenie stabilności dozowania. W szczególności:

- **Surowiec 1** charakteryzował się początkowo bardzo wysokimi ubytkami, przekraczającymi **20–30%** (Rysunek 5.4). Na przełomie lat 2022 i 2023 odnotowano gwałtowny spadek poziomu strat do wartości poniżej **10%**. Obserwowany trend świadczy o zwiększonej stabilności operacji oraz skuteczniejszym wykorzystaniu surowca dzięki zastosowaniu nowoczesnych technologii wagowych.




Rysunek 5.4. Wskaźnik strat surowca 1 na przestrzeni miesięcy (2021–2023) (opracowanie własne).

- **Surowiec 2** przed wdrożeniem systemu wykazywał wyraźnie **dodatnie wskaźniki strat**, oznaczające nadmiarowy ubytek materiału (Rysunek 5.5). Po implementacji systemu wartości te uległy obniżeniu, osiągając wartości ujemne. Taki wynik może wskazywać na wyeliminowanie nadmiernych przeważań oraz dokładniejsze naważanie.




Rysunek 5.5. Wskaźnik strat surowca 2 na przestrzeni miesięcy (2021–2023) (opracowanie własne).

- **Surowiec 3** w fazie początkowej generował ubytki przekraczające 10% (**Rysunek 5.6**). Po wdrożeniu systemu nastąpiła stabilizacja wskaźnika w zakresie 2–3%.




Rysunek 5.6. Wskaźnik strat surowca 3 na przestrzeni miesięcy (2022–2023) (opracowanie własne).

- **Surowiec 4** został wprowadzony do produkcji w trakcie implementacji systemu, dlatego nie dysponowano danymi porównawczymi z okresu wcześniejszego (**Rysunek 5.7**). Już od początku eksploatacji wskaźnik strat utrzymywał się na stabilnym poziomie w okolicach 0%.



Rysunek 5.7. Wskaźnik strat surowca 4 na przestrzeni miesięcy (2022–2023) (opracowanie własne).

Implementacja **modułu nadzorowania masy porcji** miała bezpośredni wpływ na eliminację problemów zidentyfikowanych, dotyczących niezgodności wyrobów ze specyfikacją, w szczególności niedoborów i nadmiarów składników w opakowaniach wynikających z błędów w procesie naważania. W badanym środowisku produkcyjnym nieprawidłowości te stanowiły jedną z głównych przyczyn strat surowcowych. Wdrożony moduł, integrujący cyfrowe stanowiska wagowe z systemem rejestracji i analizy danych, pozwolił na bieżące monitorowanie masy porcji, automatyczną klasyfikację jednostek oraz archiwizację wyników w systemie nadzorowania. Na **Rysunku 5.8** przedstawiono zmiany we wskaźniku DPMO - masa dla lat 2021–2024.



Rysunek 5.8. Zmiany wskaźnika DPMO - masa w latach 2021–2024 (opracowanie własne).

W roku 2021 wartość wskaźnika **DPMO – masa** wynosiła **7,6**. W 2022 roku nastąpił wzrost do poziomu **12,6**, co wskazywało na większą liczbę niezgodności związanych z procesem naważania. W latach 2023 i 2024 zaobserwowano wyraźny trend spadkowy a wskaźnik DPMO obniżył się kolejno do **3,9** oraz **1,4**, co potwierdza skuteczność wdrożonego modułu nadzorowania masy porcji i jego wpływ na poprawę stabilności procesu. Ocena działania zintegrowanego systemu nadzorowania procesu konfekcjonowania w ujęciu całościowym obejmowała analizę wskaźników **DPMO** w czterech kategoriach (masa, etykieta, opakowanie oraz pozostałe), a także wskaźników wydajności linii, **OEE** i **wydajności pracy**. Analizie poddano dane z okresu bazowego (2021–2022) oraz po wdrożeniu systemu (2023–2024), co umożliwiło jednoznaczną ocenę jego wpływu na jakość i efektywność procesu. Szczegółowe wyniki zestawiono w **Tabeli 5.2**, która przedstawia wartości DPMO w poszczególnych kategoriach jakościowych w latach 2021–2024.


Tabela 5.2. Wskaźnik DPMO w poszczególnych operacjach procesu konfekcjonowania (2021–2024).

DPMO	2021	2022	2023	2024
DPMO – masa	7,6	12,6	3,9	1,4
DPMO - etykieta	25,8	15,6	26,3	8,4
DPMO - opakowanie	27,4	37,9	32,2	9,1
DPMO - pozostałe	19,8	13,6	9,7	7,0
DPMO - ogółem	80,6	79,7	73,1	30,2

Opracowanie własne.

Wskaźnik DPMO ogółem, wyliczony dla liczby defektów na milion szans, spadł z poziomu **80,6** w 2021 roku do **30,2** w roku 2024, co świadczy o znaczącej poprawie jakości końcowego produktu. Należy zwrócić uwagę, że wdrożenie poszczególnych modułów systemu następowało etapowo. Moduł nadzorowania masy porcji został w pełni uruchomiony na początku 2023 roku, co znalazło odzwierciedlenie w gwałtownym spadku liczby niezgodności wagowych już w danych z 2023 roku.

Z kolei pozostałe moduły zostały wdrożone w drugiej połowie 2023 roku, dlatego największą poprawę w zakresie DPMO dla etykiet i opakowania zaobserwowano dopiero w roku 2024, kiedy system pracował w pełnym, zintegrowanym trybie. Zmiany wartości DPMO w poszczególnych kategoriach w latach 2021–2024 zilustrowano na **Rysunku 5.9**.




Rysunek 5.9. Zmiany wskaźników DPMO dla różnych kategorii w latach 2021–2024 (opracowanie własne).

Rysunek 5.10 prezentuje zmienność dziennej wydajności linii konfekcjonowania w okresie od maja 2022 roku do 2025 roku. Wydajność została wyrażona w jednostkach [szt./min], co umożliwia jednoznaczną ocenę tempa pracy niezależnie od długości zmian czy liczby godzin produkcyjnych. Pomimo naturalnych wahań charakterystycznych dla specyfiki branży, widoczna jest wyraźna tendencja wzrostowa. Średnie roczne wartości wydajności potwierdzają ten trend:

- 2022: 13,44 szt./min
- 2023: 13,69 szt./min
- 2024: 15,04 szt./min
- 2025: 15,99 szt./min

Systematyczny wzrost wydajności obserwowany w analizowanym okresie można uznać za wynik wdrożenia inteligentnego systemu nadzorowania. Rozwiązanie to umożliwiło bardziej efektywne zarządzanie procesem produkcyjnym, lepsze wykorzystanie dostępności maszyn oraz ograniczenie zakłóceń operacyjnych. Wzrost wydajności koreluje z poprawą wartości wskaźnika OEE i jego składowych, a także stanowi istotny czynnik wpływający na dalszy wzrost wydajności pracy.



Rysunek 5.10. Zmiany wydajności linii produkcyjnej w latach 2022–2025 [szt./min] (opracowanie własne).


W kontekście wskaźnika **OEE (Overall Equipment Effectiveness)**, możliwe było precyzyjne wyznaczenie trzech składowych wskaźnika OEE: **dostępności, wydajności i jakości**, opartych na rzeczywistych danych produkcyjnych. Warto zaznaczyć, że dane które pozwoliły wyznaczyć OEE były rejestrowane dopiero od 2022 roku, co ogranicza możliwość porównań z wcześniejszym okresem, w przeciwieństwie do wskaźników związanych ze składowymi DPMO, które były rejestrowane już od 2021 roku. **Tabela 5.3.** prezentuje wartości trzech składowych OEE oraz wartość właściwą wskaźnika dla lat 2022–2025. Dane te potwierdzają wyraźną tendencję wzrostową: od **51,37%** w 2022 roku do **67,96%** w 2025 roku, co stanowi poprawę o ponad **16** punktów procentowych.

Tabela 5.3. Zmiany wartości wskaźników OEE oraz jego składowych: jakości, dostępności i efektywności w latach 2022–2025.

Rok	Jakość	Dostępność	Efektywność	OEE
2022	93,55%	81,71%	67,20%	51,37%
2023	98,42%	80,63%	68,45%	54,32%
2024	98,72%	85,63%	75,02%	63,42%
2025	98,72%	86,10%	79,95%	67,96%

Opracowanie własne.

Zaobserwowane zmiany wskazują, że największy wpływ na poprawę wskaźnika OEE miało zwiększenie dostępności linii oraz stabilizacja tempa pracy. Wysoki i utrzymujący się na stałym poziomie wskaźnik jakości potwierdza skuteczność wdrożonych modułów systemu nadzorowania, które ograniczyły liczbę wyrobów niezgodnych. Tendencję wzrostową wszystkich składowych oraz wartości OEE w latach 2022–2025 przedstawiono na **Rysunku 5.11.**



Rysunek 5.11. Zmiany wskaźników składowych oraz wartości OEE w latach 2022–2025 (opracowanie własne).

Końcowym elementem oceny działania systemu nadzorowania procesu konfekcjonowania jest analiza wskaźnika wydajności pracy, który przedstawiono w **Tabeli 5.4**. Wskaźnik ten pozwala na ocenę efektywności wykorzystania czasu pracy operacyjnego w ujęciu jednostkowym i jest wprost zależny od stopnia automatyzacji, stabilności procesu oraz poziomu ingerencji manualnej. Wskaźnik wydajności pracy, wyrażony jako liczba wyprodukowanych jednostek na jedną roboczogodzinę, przedstawiono w tabeli dla lat 2021–2024. W analizowanym okresie zaobserwowano wyraźną i systematyczną poprawę od **60,4 szt./rb.** w 2021 roku do **76,5 szt./rb.** w 2024 roku. Oznacza to wzrost efektywności wykorzystania czasu pracy o ponad **26%**. Poprawa ta świadczy o tym, że każda przepracowana godzina została lepiej spożytkowana w stosunku do lat ubiegłych. Kluczowy wpływ miały tu usprawnione operacje procesu konfekcjonowania, które ograniczyły konieczność ręcznej kontroli i interwencji operatorskich. Mniej czynności manualnych przekładało się bezpośrednio na zwiększoną produktywność jednostek roboczych, co jest zgodne z innymi wskaźnikami efektywności zaprezentowanymi wcześniej.

Tabela 5.4. Zmiany wskaźnika wydajności pracy procesu konfekcjonowania w latach 2021–2024

Rok	Wynik	Jednostka
2021	60,4	szt./rb.
2022	63,5	szt./rb.
2023	68,7	szt./rb.
2024	76,5	szt./rb.

Opracowanie własne.

Podsumowując przeprowadzoną walidację modułów i całego systemu, należy podkreślić, że uzyskane wyniki jednoznacznie potwierdzają skuteczność wdrożonych rozwiązań. Każdy z modułów od **nadzorowania masy porcji**, przez **nadzorowania szczelności I i II**, **nadzorowanie etykiet i ich treści**, aż po **moduł odrzutu** przyczynił się do eliminacji problemów zidentyfikowanych w pracy. Ich integracja w ramach czterowarstwowej architektury (akwizycja, analiza, decyzja, wizualizacja) zapewniła spójny przepływ danych i deterministyczne podejmowanie decyzji w czasie rzeczywistym. Efektem jest nie tylko redukcja wskaźników DPMO w każdej kategorii jakościowej, ale także znacząca poprawa stabilności procesu, zwiększenie wydajności linii, wzrost wskaźnika OEE oraz lepsze wykorzystanie czasu pracy. Zmniejszenie strat surowcowych potwierdza, że system spełnił zarówno cele jakościowe, jak i ekonomiczne. **Tabela 5.5.** prezentuje syntetyczne podsumowanie wszystkich mierników walidacyjnych, obejmujących zarówno wskaźniki jakościowe (niedoważenia, przeważenia, ubytki surowcowe, wartości DPMO w poszczególnych kategoriach), jak i wskaźniki efektywności operacyjnej (wydajność linii, dostępność, efektywność i OEE), a także rezultaty modeli predykcyjnych i systemów wizyjnych (dokładność, czułość, precyzja, skuteczność detekcji). Tak kompleksowe zestawienie umożliwia całościową ocenę wpływu wdrożonego systemu na stabilność, niezawodność i ekonomiczną efektywność procesu konfekcjonowania.

Tabela 5.5. Zestawienie wyników walidacji.

Obszar	Wskaźnik	Opis	Przed wdrożeniem	Po wdrożeniu	Różnica	Jednostka
Naważanie	Średnia masa jednostkowa	Średnia masa opakowania z próby 1000 szt. (2022 vs 2024)	421,85	403,31	-18,54	g
	Odchylenie standardowe masy	Zmienność masy opakowań (2022 vs 2024, próba 1000 szt.)	18,07	6,71	-11,36	g
	Odsetek niedoważeń	Udział procentowy opakowań poniżej masy deklarowanej (2021/22 vs 2023/24)	2,02	0,55	-1,47	%
	DPMO – masa	Liczba defektów wagowych na milion jednostek (2022 vs 2024)	12,6	1,4	-11,2	szt.
	Łączna masa przeważeń	Suma masy surowca w opakowaniach powyżej nominalnej (średnia 2021/22 vs 2023/24)	36 915	18 481	-18 434	kg
	Udział przeważeń	Procentowy udział przeważeń (2021/22 vs 2023/24)	4,19	2,13	-2,06	%
	Ubytki surowcowe – surowiec 1	Odsetek strat surowca 1	20	10	-10	%
	Ubytki surowcowe – surowiec 2	Odsetek strat surowca 2	5	0	-5	%
	Ubytki surowcowe – surowiec 3	Odsetek strat surowca 3	10	3	-7	%
	Ubytki surowcowe – surowiec 4	Odsetek strat surowca 4	n.d.	0	n.d.	%
Pakowanie	Wydajność linii	Średnia liczba zapakowanych opakowań na godzinę (2022 vs 2024)	13,44	15,04	1,6	szt./min
	Wydajność linii	Średnia liczba zapakowanych opakowań na godzinę (2023 vs 2025)	13,69	15,99	2,3	szt./min
	Efektywność	Stosunek rzeczywistej wydajności linii do wydajności teoretycznej	67,2	79,95	12,75	%
	Dostępność	Procent czasu, w którym system był gotowy do pracy	81,71	86,1	4,39	%
	Jakość	Procent wyrobów spełniających wymagania jakościowe	93,55	98,72	5,17	%
	OEE	Złożony wskaźnik efektywności (iloczyn dostępności, efektywności i jakości)	51,37	67,96	16,59	%
	Regresja logistyczna – Accuracy	Dokładność modelu predykcji mikronieszczelności	n.d.	81,5	-	%
	Regresja logistyczna – Sensitivity	Czułość modelu	n.d.	75	-	%
	Regresja logistyczna – Specificity	Swoistość modelu	n.d.	86,7	-	%
	Regresja logistyczna – Precision	Precyzja modelu	n.d.	81,8	-	%
	Regresja logistyczna – NPV	Wartość predykcyjna negatywna	n.d.	81,3	-	%
	Regresja logistyczna – ROC	Pole pod krzywą ROC	n.d.	0,85	-	-
	DPMO – opakowanie	Liczba defektów technologicznych (opakowania) na milion jednostek (2022 vs 2024)	37,9	9,1	-28,8	szt.
	Walidacja – pakowanie	Skuteczność detekcji wad pakowania w warunkach produkcyjnych	n.d.	90	-	%
Etykietowanie	DPMO – etykieta	Liczba defektów etykietowych na milion jednostek (2022 vs 2024)	15,6	8,4	-7,2	szt.
	Dokładność klasyfikatora	Dokładność klasyfikatora obrazu na zbiorze walidacyjnym	n.d.	97	-	%
	Czułość klasyfikatora	Wartość czułości z macierzy pomyłek	n.d.	95	-	%
	Precyzja klasyfikatora	Wartość precyzji z macierzy pomyłek	n.d.	100	-	%
	Walidacja – etykieta	Skuteczność detekcji etykiet w warunkach produkcyjnych	n.d.	99	-	%
Ogólne	Wydajność pracy	Średnia liczba opakowań na 1 roboczogodzinę (2021 vs 2024)	60,4	76,5	16,1	szt./rb.

Opracowanie własne.

Wdrożenie zintegrowanego systemu nadzorowania procesu konfekcjonowania przyniosło także **wymierne korzyści finansowe**, wynikające przede wszystkim z redukcji przeważen surowca oraz możliwości ograniczenia liczby badań niszczących na zawartość tlenu.

Po pierwsze, zastosowanie **zaawansowanych wag platformowych** znacząco poprawiły dokładność i powtarzalność operacji naważania, co przełożyło się na wyraźną redukcję strat surowcowych. Na potrzeby kalkulacji wyznaczono dwa okresy:

- Przed wdrożeniem (2021–2022):
 - Łączna liczba wyprodukowanych opakowań: 2 392 666 szt.
 - Łączna masa przeważen: 36,9 t
- Po wdrożeniu (2023–2024):
 - Łączna liczba wyprodukowanych opakowań: ok. 2 221 490 szt.
 - Łączna masa przeważen: 18,4 t

Różnica w poziomie przeważenia wyniosła **18,43 tony**, co stanowi redukcję o prawie 50% względem okresu wcześniejszego. Przy założonej cenie surowca na poziomie 10 zł/kg, daje to łączną oszczędność rzędu: $18\,434\text{ kg} \times 10\text{ zł/kg} = \mathbf{184\,340\text{ zł}}$. Oszczędności te osiągnięto przy jednoczesnej poprawie jakości i stabilności procesu, co zostało potwierdzone spadkiem wartości wskaźnika DPMO - masa.

Po drugie, opracowano model predykcji mikronieszczelności opakowań oparty na regresji logistycznej, umożliwiający prognozowanie ryzyka przekroczenia dopuszczalnej zawartości tlenu w atmosferze ochronnej opakowań. Zastosowanie tego rozwiązania pozwala na ograniczenie liczby badań niszczących, które w standardowej procedurze przeprowadza się dla:

- 2 próbek na początku partii,
- 2 próbek co godzinę,
- 2 próbek na zakończenie.

Przykładowo, dla partii trwającej 4 godziny daje to 8 prób, co przy wartości jednostkowej produktu 8 zł oznacza koszt 64 zł na partię.

- Praca w trybie 1 zmiany (8 godzin dziennie):
 - 16 prób dziennie → 128 zł/dzień
 - 2 688 zł/miesiąc
 - 32 256 zł/rok

Analiza danych predykcyjnych wykazała, że dla ok. 75% partii prawdopodobieństwo przekroczenia progu resztki tlenu wynosiło $P \leq 0,9$, co pozwalałoby na pominięcie badań niszczących bez ryzyka utraty jakości. W związku z powyższym można założyć, że szacowane roczne oszczędności wynosić mogą: **ok. 24 192 zł** (przy produkcji dwuzmianowej: do 50 000 zł/rok).

W przedstawionych obliczeniach przyjęto uproszczone założenia, zaokrąglenia i uśrednienia, dlatego **wyniki mogą być obarczone istotnym błędem oszacowania**. Celem kalkulacji było jednak **wskazanie rzędu wielkości** korzyści ekonomicznych w dwóch kluczowych obszarach: ograniczenia

przeważań surowca oraz potencjalnego zmniejszenia liczby badań niszczących. Łączne efekty finansowe wynikają zarówno z bezpośrednich oszczędności surowcowych, jak i z potencjalnego ograniczenia kosztów badań niszczących. Wyniki te jednoznacznie potwierdzają, że wdrożenie zintegrowanego systemu nadzoru łączy aspekt jakościowy z ekonomicznym i przekłada się na wymierne korzyści dla przedsiębiorstwa.

5.3. Analiza SWOT implementacji

Dla pełniejszej oceny opracowanego i wdrożonego inteligentnego systemu nadzorowania procesu konfekcjonowania wyrobów przeprowadzono analizę **SWOT** (ang. Strengths, Weaknesses, Opportunities, Threats) (**Tabela 5.6**). Podejście to pozwala na identyfikację zarówno mocnych i słabych stron rozwiązania, jak i szans rozwojowych oraz potencjalnych zagrożeń w kontekście jego eksploatacji, skalowalności oraz zgodności ze standardami branżowymi. Analiza została oparta na wynikach testów, walidacji oraz obserwacjach z rzeczywistego środowiska produkcyjnego (Wysocki, 2007; Szmítka, 2015).

Tabela 5.6. Analiza SWOT wdrożonego systemu nadzorowania procesu konfekcjonowania.

CZYNNIKI	POZYTYWNE	NEGATYWNE
WEWNĘTRZNE	Mocne strony (Strengths)	Słabe strony (Weaknesses)
	Kompleksowa cyfryzacja operacji naważania, pakowania, etykietowania.	Wysoki poziom złożoności systemu i konieczność utrzymania infrastruktury IT
	Integracja wielomodułowa: moduł nadzorowania masy proci, moduły nadzorowania szczelności I i II, moduł etykiet i treści, moduł odrzutu oraz modele predykcyjne i diagnostyczne	Wysokie koszty wdrożenia i potrzeba stopniowej amortyzacji inwestycji
	Ciągły monitoring i rejestracja danych w czasie rzeczywistym, pełna identyfikowalność wyrobów	Wymagania proceduralne w zakresie kalibracji wag, czujników i aktualizacji algorytmów
	Redukcja wskaźnika DPMO (z 80,6 do 30,2)	Konieczność specjalistycznych szkoleń personelu w obsłudze modułów predykcyjnych i systemów wizyjnych
	Poprawa OEE (z 51,37% do 67,96%) i wzrost wydajności linii z 13,44 do 15,99 szt./min	Czasowe ryzyko przestojów w przypadku awarii krytycznych modułów (system wizyjny, odrzut, serwer)
	Redukcja przeważań surowca o 18,43 t i oszczędności ok. 184 tys. zł rocznie	

ZEWNETRZNE	Szanse (Opportunities)	Zagrożenia (Threats)
	Rozszerzenie funkcji predykcyjnych – ograniczenie badań niszczących i dalsza redukcja kosztów jakości	Ryzyko awarii sprzętu i związanych z tym przestojów produkcyjnych
	Integracja systemu z ERP i systemami planowania produkcji	Konieczność zapewnienia ciągłej aktualizacji oprogramowania i modeli predykcyjnych
	Dalsza poprawa efektywności poprzez automatyzację reakcji na odchylenia procesowe	Potencjalne braki kompetencyjne personelu w zakresie analizy danych i obsługi systemów predykcyjnych
	Wzmocnienie pozycji konkurencyjnej poprzez spełnienie wymogów Przemysłu 4.0	Zależność od sprawności infrastruktury IT oraz skuteczności zabezpieczeń cybernetycznych
	Zwiększenie satysfakcji klientów dzięki redukcji reklamacji i wyrobów niezgodnych	

Opracowanie własne.

Mocne strony systemu jednoznacznie dominują nad zidentyfikowanymi słabościami i zagrożeniami. Walidacja przeprowadzona w rozdziale 5 potwierdziła znaczącą poprawę stabilności procesu i jakości wyrobów, czego dowodem jest spadek wskaźnika DPMO, wzrost OEE czy redukcja przeważeń surowca co przełożyło się na relatywne oszczędności finansowe. Szanse rozwojowe wynikają głównie z możliwości pełnego wykorzystania modułów predykcyjnych, dalszego ograniczenia badań niszczących i automatyzacji reakcji na odchylenia procesowe. System jest w pełni zgodny z ideą Przemysłu 4.0, a jego wielomodułowa architektura zapewnia elastyczność w rozbudowie i integracji z innymi rozwiązaniami IT. Zagrożenia i słabości mają przede wszystkim charakter eksploatacyjny i organizacyjny i mogą być skutecznie minimalizowane poprzez regularną konserwację, aktualizacje oprogramowania, utrzymanie kompetencji personelu oraz rozwój infrastruktury IT. W rezultacie wdrożony system można uznać za stabilny, ekonomicznie uzasadniony i gotowy do dalszego rozwoju, a jego przewagi funkcjonalne wyraźnie przeważają nad ograniczeniami.

6. Podsumowanie i wnioski

6.1. Najważniejsze rezultaty badań i efektów wdrożenia

Realizacja rozprawy doprowadziła do opracowania i wdrożenia w przedsiębiorstwie Mróz S.A. **inteligentnego systemu nadzorowania zautomatyzowanego procesu konfekcjonowania wyrobów**, którego skuteczność została potwierdzona w warunkach przemysłowych. Najważniejsze rezultaty badań koncentrują się wokół dwóch obszarów: **opracowania modelu predykcyjnego mikronieszczelności opakowań opartego na regresji logistycznej oraz modelu inspekcji wizyjnej bazującego na konwolucyjnych sieciach neuronowych, w którym zastosowano klasyfikatory umożliwiające skuteczne rozróżnianie jednostek zgodnych i niezgodnych**. Oba modele zostały zweryfikowane i wdrożone w środowisku produkcyjnym, dostarczając zarówno wartości poznawczych, jak i praktycznych.

Proces badawczy obejmował budowę i sukcesywne rozszerzanie bazy obrazów wyrobów zgodnych i niezgodnych, przygotowanie i augmentację zbiorów treningowych, wielokrotne cykle trenowania i testowania modeli oraz **opracowanie i rozwój klasyfikatora** wizyjnego opartego na konwolucyjnych sieciach neuronowych. Kolejne iteracje procesu obejmowały jego optymalizację, w tym redukcję liczby klas w celu osiągnięcia ustalonego progu ufności. Ostateczny model osiągnął na zbiorze walidacyjnym **dokładność klasyfikacji (accuracy) na poziomie 97%**, przy **czułości (sensitivity) 95%** oraz **precyzji (precision) 100%** dla klasy wyrobów niezgodnych, natomiast w warunkach przemysłowych **wskaźnik poprawnych klasyfikacji (passing rate) wyniósł 99%**. Wyniki te jednoznacznie potwierdziły, że inspekcja wizyjna wsparta metodami głębokiego uczenia umożliwia **kontrolę 100% strumienia wyrobów**, znacząco przewyższając skuteczność tradycyjnych metod.

Drugim kluczowym obszarem badań było **opracowanie modelu predykcyjnego mikronieszczelności opakowań**. Na podstawie serii eksperymentów czynnych zidentyfikowano trzy **parametry krytyczne: temperaturę zgrzewania, ciśnienie w komorze pakującej i wydajność linii**. W ramach eksperymentu zmierzone parametry zestawiono z odpowiednimi wynikami badań na zawartość tlenu w opakowaniu, co pozwoliło uzyskać dane oznaczone etykietami jakościowymi, wykorzystane do budowy modelu decyzyjnego i analiz statystycznych pozwalających uzyskać **wartości nominalne, tolerancje i progi alarmowe** oraz określić ich odpowiedzialności za odchylenia jakościowe. Walidacja w warunkach przemysłowych zbudowanego **modelu regresji logistycznej**, wykazała **dokładność klasyfikacji na poziomie 81,5%, czułość 75%, swoistość 86,7%, precyzję 81,8%, a wartość pola pod krzywą ROC (AUC) wyniosła 0,85**. Tak wysokie wyniki potwierdzają zdolność modelu do skutecznego rozróżniania wyrobów zgodnych i niezgodnych oraz otwierają możliwość istotnego ograniczenia liczby badań niszczących.

Efekty wdrożenia systemu w przedsiębiorstwie jednoznacznie potwierdzają jego wartość aplikacyjną. W warunkach przemysłowych odnotowano:

- zmniejszenie **odchylenia standardowego masy porcji z 18,07 g do 6,71 g**,

- redukcję **przeważań surowca o 18,4 t** w ciągu dwóch lat,
- wzrost **średniej wydajności linii z 13,44 do 15,99 szt./min**,
- poprawę **OEE z 51,37% do 67,96%**,
- spadek **DPMO (ogółem) z 80,6 do 30,2**,
- znaczące ograniczenie **liczby reklamacji jakościowych**.

Uzyskane wyniki jednoznacznie **dowodzą, że cel pracy doktorskiej**, którym było opracowanie koncepcji oraz weryfikacja w warunkach przemysłowych inteligentnego systemu nadzorowania zautomatyzowanego procesu konfekcjonowania wyrobów, wykorzystującego metody zaawansowanej analityki danych i sztucznej inteligencji, został osiągnięty.

6.2. Wnioski poznawcze

Wnioski płynące z przeprowadzonych badań i wdrożenia inteligentnego systemu nadzorowania odnoszą się bezpośrednio do sformułowanego problemu badawczego oraz trzech pytań badawczych,

Odpowiedzią na pierwsze pytanie badawcze – *jakie czynniki determinują efektywność i stabilność procesu konfekcjonowania oraz charakterystyki jakościowe wyrobów* – było przeprowadzenie analizy zarówno **czynników technologicznych, organizacyjnych, informacyjnych jak i środowiskowych**. Badania wykazały, że w przypadku procesów konfekcjonowania kluczowe znaczenie miała skuteczna kontrola parametrów technologicznych, utrzymanie stabilności maszyn i urządzeń oraz bieżące monitorowanie w czasie rzeczywistym. Na poziomie organizacyjnym istotne okazało się wprowadzenie procedur i instrukcji ograniczających ryzyko błędów ludzkich, a także zapewnienie powtarzalności poprzez monitorowanie i raportowanie parametrów krytycznych. W obszarze informacyjnym opracowany system umożliwił integrację danych pochodzących z wielu źródeł (wag, czujników, systemów wizyjnych i modułów etykietowania) i ich wykorzystanie do wsparcia decyzyjnego. Czynniki ludzkie, związane z kompetencjami operatorów, zostały częściowo zneutralizowane dzięki automatyzacji i zastosowaniu sztucznej inteligencji, która przejęła zadania wymagające wysokiej precyzji i szybkiej reakcji. W konsekwencji uzyskano pełniejsze rozumienie procesu, a przeprowadzone badania pozwoliły zidentyfikować powiązania między poszczególnymi obszarami, wzbogacając wiedzę na temat uwarunkowań stabilności i jakości w konfekcjonowaniu.

Drugie pytanie badawcze – *jakie dane procesowe są kluczowe dla skutecznego identyfikowania niezgodności w zautomatyzowanym procesie konfekcjonowania* – zostało rozstrzygnięte poprzez przeprowadzenie serii **eksperymentów czynnych**, w których celowo modyfikowano wartości różnych zmiennych technologicznych, a następnie analizowano ich wpływ na stabilność procesu i jakość wyrobów. Początkowo rozważano szeroki zestaw parametrów, obejmujący wiele potencjalnych czynników procesowych, lecz dopiero ich systematyczne zestawianie z wynikami badań niszczących (zawartość tlenu) pozwoliło na wyłonienie zmiennych o największym znaczeniu. Badania wykazały jednoznacznie, że **temperatura zgrzewania, ciśnienie bezwzględne w komorze pakującej oraz wydajność linii** są parametrami krytycznymi, których utrzymanie w wąskich granicach tolerancji

warunkuje szczelność opakowań i minimalizację resztkowej zawartości tlenu. W wyniku analiz porównawczych wielu wariantów pracy maszyny i kombinacji wartości parametrów to właśnie te trzy zmienne zostały uznane za decydujące dla stabilności procesu i jakości wyrobu, podczas gdy pozostałe badane czynniki nie wносиły istotnej wartości diagnostycznej. Dla operacji naważania kluczowym danym proces, potwierdzonym zarówno analizą danych historycznych, jak i eksperymentami, była **masa porcji**, której stabilność warunkuje jednocześnie zgodność z wymaganiami prawnymi dotyczącymi masy jednostkowej oraz ograniczenie strat surowcowych wynikających z przeważeń. Uzupełniając istotne okazały się również **dane z systemów wizyjnych i modułów OCR**, umożliwiające wykrywanie błędów etykietowania, jakości nadruku oraz czytelności kodów. Synchronizacja wszystkich źródeł danych w ramach spójnej architektury oraz ich bieżąca analiza pozwoliły na identyfikację odchyleń w czasie rzeczywistym i precyzyjne określenie granic stabilnej pracy procesu.

Trzecie pytanie badawcze – *jakie narzędzia i metody będą w sposób skuteczny wspierać nadzorowanie parametrów procesu konfekcjonowania* – zostało rozstrzygnięte poprzez zastosowanie zarówno klasycznych rozwiązań analitycznych, jak i metod sztucznej inteligencji. W pierwszej grupie znalazły się metody o charakterze **analitycznym i statystycznym**, które umożliwiały identyfikację trendów i odchyleń w danych procesowych. Istotną rolę odegrały także rozwiązania oparte na **przetwarzaniu i analizie obrazów**. W module etykietowania wdrożono narzędzia OCR, Blob Finder i 2D Code Analysis, które umożliwiły pełną automatyzację weryfikacji treści etykiet, czytelności kodów kreskowych i ich pozycjonowania. Drugą grupę stanowią metody oparte na **sztucznej inteligencji**, których wybór był dostosowany do specyfiki poszczególnych operacji. W przypadku wykrywania „**nieszczelności I**” wysoką skuteczność zapewniły rozwiązania bazujące na **konwolucyjnych sieciach neuronowych (CNN)**. W fazie uczenia wykorzystano metody augmentacji danych oraz monitorowano przebieg funkcji straty i dokładność klasyfikacji. Walidacja przemysłowa potwierdziła, że opracowany klasyfikator osiągnął 97% skuteczności, co pozwoliło na w pełni automatyczne i wiarygodne wykrywanie defektów niewidocznych dla tradycyjnej inspekcji wizualnej. Dla „**nieszczelności II**”, zastosowano podejście predykcyjne oparte na **regresji logistycznej**. Model ten został zbudowany w oparciu o dane procesowe zestawione z wynikami badań niszczących, co umożliwiło przypisanie etykiet jakościowych do każdej obserwacji. Walidacja przeprowadzona w warunkach przemysłowych wykazała skuteczność klasyfikacji na wysokim poziomie co potwierdziło użyteczność tego podejścia w nadzorze procesów. Łączne zastosowanie metod analitycznych, narzędzi przetwarzania obrazu oraz rozwiązań AI umożliwiło zbudowanie systemu, który pokrywa pełne spektrum ryzyk związanych z procesem konfekcjonowania od błędów związanych z masą i parametrami technologicznymi, przez mikronieszczelności, aż po defekty etykiet i oznakowania.

6.3. Wnioski uylitarne

Z perspektywy wdrozeniowej i praktycznej przeprowadzone badania oraz implementacja systemu nadzorowania przyniosły szereg istotnych wniosków.

Po pierwsze, doświadczenia z realizacji pracy jednoznacznie dowiodły, że **pełna cyfryzacja akwizycji danych** procesowych jest warunkiem koniecznym do skutecznego nadzorowania procesu konfekcjonowania. Dopiero ciągła rejestracja wartości parametrów, ich jednoznaczna identyfikacja oraz synchronizacja czasowa pozwoliły uzyskać kompletny obraz przebiegu procesu i stworzyć podstawy do implementacji narzędzi analitycznych i predykcyjnych.

Po drugie, wdrożenie architektury opartej na **podziale na warstwy i moduły** okazało się rozwiązaniem efektywnym zarówno od strony organizacyjnej, jak i technicznej. Warstwowość zapewniła przejrzyste rozdzielanie zadań pomiędzy poziom akwizycji, analizy, decyzji i wizualizacji, natomiast modułowość umożliwiła jednoznaczne przypisanie funkcji do poszczególnych obszarów procesu. Taka struktura sprawdziła się w praktyce, a jej transparentność ułatwiła zarówno etap budowy, jak i późniejszą eksploatację.

Po trzecie, integracja narzędzi **sztucznej inteligencji** w procesie nadzorowania dowiodła, że ich wykorzystanie nie wymaga od użytkowników końcowych szczegółowej znajomości algorytmów działania stosowanych metod. Wystarczające jest zrozumienie istoty ich działania. Choć etap budowy modeli (np. klasyfikatora CNN czy regresji logistycznej) wymagał prac badawczych i wiedzy specjalistycznej, to w codziennej praktyce obsługa systemu sprowadzała się do korzystania z intuicyjnych interfejsów HMI. Jest to ważne z punktu widzenia upowszechniania takich rozwiązań w przedsiębiorstwach, które często obawiają się bariery kompetencyjnej.

Po czwarte, wdrożenie systemu umożliwiło **przejsie od nadzorowania reaktywnego do predykcyjnego**, co przyniosło wymierne efekty: spadek wskaźnika DPMO, redukcję strat surowca oraz istotny wzrost wskaźnika OEE i średniej wydajności linii. Takie rezultaty potwierdzają, że implementacja inteligentnych narzędzi nadzorowania wprost przekłada się na poprawę stabilności, jakości i efektywności procesu.

6.4. Ograniczenia badań i napotkane problemy

Opracowanie i wdrożenie **inteligentnego systemu nadzorowania procesu konfekcjonowania** zakończyło się sukcesem, jednak realizacja badań nie była wolna od ograniczeń i trudności. Miały one zarówno charakter **środowiskowy**, jak i **techniczno-organizacyjny**, a ich przewyciężenie wymagało **elastycznego podejścia** oraz dostosowania metod badawczych do uwarunkowań przemysłowych.

Pierwszym istotnym czynnikiem były zakłócenia związane z **pandemią COVID-19**. W początkowej fazie pracy dostęp do infrastruktury badawczej był ograniczony, a linie produkcyjne podlegały okresowym wyłączeniom. Spowodowało to **przesunięcia w harmonogramie** i konieczność zmiany kolejności realizacji części zadań.

Kolejne trudności wynikały z **ograniczeń technicznych**. Szczególnym wyzwaniem okazał się **brak dostępu do danych procesowych maszyny pakującej typu tray sealer**. Zamknięta struktura sterownika PLC uniemożliwiała bezpośrednią akwizycję danych i wymagała opracowania **alternatywnych metod pozyskiwania informacji**. Dodatkowo, w początkowej fazie testów systemu wizyjnego obserwowano problemy z wydajnością przetwarzania obrazów i synchronizacją z układem odrzutu, które udało się wyeliminować poprzez optymalizację infrastruktury IT oraz parametrów algorytmów.

Pewne ograniczenia miały również charakter **organizacyjny**. **Niedobór specjalistów** w obszarze automatyki i programowania wymagał realizacji części zadań własnymi siłami oraz przy wsparciu partnerów zewnętrznych, co zwiększało obciążenie organizacyjne i wpływało na tempo badań. W fazie implementacji modułu inspekcji etykiet wystąpiły też **problemy z rozpoznawaniem znaków o zbliżonym kształcie** oraz z **nadmierną złożonością architektury klasyfikatora**, które powodowały spadek skuteczności. Dopiero **uproszczenie struktury modelu** pozwoliło na przywrócenie wysokiej jakości klasyfikacji.

Ostatnim ograniczeniem było wdrożenie modułu predykcyjnego opartego na regresji logistycznej. Mimo wysokiej skuteczności modelu, **pełne zastąpienie badań niszczących** nie było możliwe ze względu na **obowiązujące normy jakościowe i wymagania odbiorców**, co ograniczyło pełny potencjał praktycznego wykorzystania tej części systemu choć w sposób znaczący ograniczyło liczbę pomiarów niszczących.

Doświadczenia zebrane w trakcie prac wskazują, że implementacja inteligentnych systemów nadzorowania w środowisku przemysłowym wymaga nie tylko opracowania **zaawansowanych algorytmów**, lecz także rozwiązania szeregu **problemów technicznych, organizacyjnych i normatywnych**. Ostatecznie jednak wszystkie napotkane ograniczenia zostały skutecznie przezwyciężone, a uzyskane wnioski mają charakter uniwersalny i mogą stanowić wskazówkę dla przyszłych wdrożeń tego typu systemów.

6.5. Rekomendacje i kierunki dalszych badań

Na podstawie przeprowadzonych prac badawczo-wdrożeniowych oraz doświadczeń zdobytych podczas projektowania, implementacji i walidacji inteligentnego systemu nadzorowania procesu konfekcjonowania sformułowano rekomendacje dotyczące dalszego rozwoju rozwiązania oraz potencjalnych kierunków **badan uzupełniających i rozszerzających** przedstawioną koncepcję. Propozycje te mają charakter zarówno praktyczny, związany z doskonaleniem systemu w środowisku przemysłowym, jak i **naukowy**, ukierunkowany na pogłębianie wiedzy w obszarze cyfryzacji i automatyzacji procesów produkcyjnych.

Pierwszym kierunkiem jest **adaptacja systemu do innych linii i zakładów**. Opracowane rozwiązanie, dzięki **modułowej architekturze** oraz **uniwersalnemu podejściu do rejestracji, analizy i klasyfikacji danych**, może zostać przeniesione do innych linii produkcyjnych w zakładzie Mróz S.A.

oraz do przedsiębiorstw o zbliżonym profilu procesowym. Skalowalność systemu umożliwia jego dostosowanie do odmiennych typów produktów, układów technologicznych i warunków eksploatacyjnych.

Drugim obszarem rozwoju powinno być **rozszerzenie badań w kierunku utrzymania ruchu i predykcji awarii**. Dotychczas prace koncentrowały się głównie na nadzorze jakościowym i stabilności procesu. Aspekt związany z predykcją awarii został jedynie zarysowany, dlatego rekomenduje się jego pogłębienie poprzez rozbudowę modułów analitycznych o **funkcje diagnostyczne i prognostyczne**, umożliwiające wczesne wykrywanie symptomów zużycia lub zakłóceń pracy urządzeń. Szczególne znaczenie mają tu **maszyny pakujące i systemy wizyjne**, które determinują stabilność procesu. Dalsze badania powinny obejmować identyfikację wskaźników diagnostycznych, rozszerzoną analizę trendów anomalii oraz opracowanie algorytmów predykcyjnych umożliwiających wdrożenie strategii **predictive maintenance** w rzeczywistych warunkach przemysłowych.

Trzecim zaleceniem jest **integracja systemu z nadrzędnymi systemami IT**. Powiązanie inteligentnego systemu nadzorowania z centralnym systemem zarządzania (np. Comarch ERP) pozwoliłoby na **automatyczne przekazywanie danych produkcyjnych** dotyczących wydajności, jakości, statusu partii i zdarzeń alarmowych. Taka integracja zwiększy **spójność informacji w skali całego zakładu**, pogłębi cyfryzację procesów zarządczych oraz umożliwi podejmowanie **decyzji strategicznych w oparciu o dane produkcyjne dostępne w czasie rzeczywistym**.

Czwartym kierunkiem jest **rozszerzenie zastosowania sztucznej inteligencji na inne obszary produkcji**. Algorytmy uczenia maszynowego i głębokiego mogą wspierać **planowanie produkcji, analizę przyczyn przestojów, zarządzanie zużyciem energii czy optymalizację logistyki wewnętrznej**. Skalowalność opracowanego systemu oraz rosnąca dostępność narzędzi AI sprzyjają stopniowemu podnoszeniu poziomu autonomii i adaptacyjności systemów produkcyjnych, zgodnie z ideą **Przemysłu 4.0**.

Podsumowując, realizacja powyższych rekomendacji może przyczynić się do dalszego zwiększenia efektywności produkcji, redukcji kosztów operacyjnych oraz pogłębienia cyfryzacji procesów końcowych, a jednocześnie stanowi naturalną kontynuację badań naukowych podjętych w ramach niniejszej rozprawy doktorskiej.

ZAŁĄCZNIKI



Specyfikacja techniczna

Model: folia CX-P AHB 55 AF / CX-P AHB 55 AF peel

Własności	Jednostka miary	Wartości	Norma	
Ogólne				
Typ	-	górna, zgrzewalna		
Powierzchnia	-	z antifog		
		CX-P AHB 55 AF	CX-P AHB 55 AF peel	
Grubość	mikrometry (my)	55 ± 8%	55 ± 8%	
Gramatura	g / m²	51,7 ± 8%	51,7 ± 8%	
Wydajność	m² / kg	19,3 ± 8%	19,7 ± 8%	
Nawoje	mb	250 – 1 000		
Barierowe				
O₂	cm³ / m² x 24h	1	94,8	ASTM D-3985
H₂O	g / m² x 24 h	3,5	5,5	ASTM F-1249
Mechaniczne				
Siła zgrzewu	N / 15mm / 230N, 1s, 140°C	6 ± 2		
Parametry pracy (standardowe)	Standardowa temperatura zgrzewania dla AHB 50 AF 140-160°C, czas: 1-1,5 s. Standardowa temperatura zgrzewania dla AHB 50 AF peel 160-165°C, czas: 1-1,5 s. Powyższe parametry mogą odbiegać od proponowanych w zależności od stosowanej maszyny pakującej, produktu i warunków pakowania. Należy wykonać testy w zakładzie.			
Okres i warunki przechowywania / przydatności	Okres gwarancji dla folii wynosi 12 miesięcy (właściwości antifog 3 miesiące) od daty konfekcji. W przypadku przewożenia lub przechowywania folii poniżej 15°C przed dalszym przetwórstwem zaleca się sezonować folię w temperaturze powyżej 20°C przez minimum 24 godziny. W przypadku przewożenia lub przechowywania folii poniżej 5°C należy wydłużyć czas sezonowania do minimum 48 godzin. Przestrzeganie powyższego gwarantuje prawidłowe przetwórstwo folii i zachowanie wskazanych właściwości.			
Identyfikacja produktu	Rolki folii oznaczone są etykietami zamieszczonymi wewnątrz tulei tekturowych oraz na zewnątrz nawojów. Etykiety identyfikacyjne zawierają następujące informacje: logo oraz nazwę dostawcy; nazwę produktu, datę konfekcjonowania; wymiary tacek; model i numer partii oraz znaki graficzne „wyrób przeznaczony do kontaktu z żywnością” oraz tworzywo z jakiego je wykonano.			

	Imię i nazwisko	Podpis
Opracował	Katarzyna Ciechomska	
Zatwierdził	Wioletta Hojczyk Pełnomocnik ds. Jakości	

Piaseczno, 15.03.2023

Wartości parametrów zawarte w niniejszej specyfikacji są wynikiem badań i zdobytej wiedzy Food Pack Sp. z o.o. opartej na analizie średnich wartości produkowanych folii. Informacje podane w specyfikacji należy jedynie traktować jako wskazówki w zakresie doboru folii do jej finalnego zastosowania. Firma Food Pack Sp. z o.o. nie ponosi odpowiedzialności za niesatysfakcjonujące wyniki przetwórstwa, ponieważ warunki procesów są poza naszą kontrolą. W celu doboru parametrów produktu i jego przetwórstwa zaleca się przeprowadzenie prób.

Wersja 01
Strona 1 z 1

Załącznik Z.1. Specyfikacja techniczna model: folia CX-P AHB 55 AF / CX-P AHB 55 AF peel (źródło: dokumentacja techniczna producenta).



Referencja :	W1/602
Opis :	W1/602(187/137/50) 850ML
Rodzina:	MAPTIPACK
Kod kreskowy :	5903424320738
Kod taryfy celnej :	39231090

CHARAKTERYSTYKA PRODUKTU

	Długość	Szerokość	Wysokość	Średnica
Wymiaryzew. : (mm)	187	137	50	
Wymiarywew. : (mm)				

Komentarz :

Pojemność :	850	(ml)	
Waga netto :	15,40	(gr)	(+/- 5 %)
Surowiec :	PP		
Kolor :	TRANSPARENT		
Zakres temperatur :	Do gorącego: -20/+120	Do zimnego: -10/+80	(°C)
Anty-fog :			

CHARAKTERYSTYKA WORKA

Kod kreskowy :	
Ilość sztuk w worku :	640

CHARAKTERYSTYKA KARTONU

Ilość sztuk w kartonie :	640		
Wymiary kartonu :	598 x 398 x 561	(mm)	(+/- 10mm)
Objętość kartonu :	0,13	(m3)	(+/- 10%)
Waga brutto kartonu :	10,869	(kg)	(+/- 10%)

CHARAKTERYSTYKA PALETY

Typ palety : Euro - 800 x 1200 mm

Ilość kartonów na warstwie :	4		
Ilość warstw :	3		
Ilość kartonów na palecie :	12		
Ilość szt. wyrobu na palecie :	7 680		
Waga brutto palety :	150	(kg)	(+/- 10%)
Wysokość palety :	1,833	(m)	(+/- 10%)

WARUNKI PRZECHOWYWANIA I TRANSPORTU


- W suchym i czystym magazynie, na paletach, zabezpieczone folią stretch przed kurzem, zanieczyszczeniami mechanicznymi i zawilgoceniem.
- W odległości co najmniej 1m od czynnych urządzeń grzewczych.
- Z dala od bezpośredniego nasłonecznienia.
- Nie piętrować palet.
- Zalecana temperatura magazynowania(-10) - (+50)°C.
- W przypadku nie spełnienia warunku temperatury w magazynie, zaleca się sezonowanie pojemników w kartonach, bez folii stretch, w temperaturze otoczenia produkcji przez okres 24h przed użyciem.
- Okres przechowywania nie określa się - zalecany 24 miesiące.
- Okres gwarancji 6 miesięcy od daty sprzedaży.
- Przewozić krytymi środkami transportu.

-17/06/2022-

Załącznik Z.2. Karta techniczna opakowanie W1/602(187/137/50) 850M (źródło: dokumentacja techniczna producenta).

Typ czujnika	Materiał osłony	Zakres pomiarowy	Sposób mocowania (standardowy)	Średnica osłony
TT...E-391	–	-40÷400°C	–	przewód ze spoiną
TOPE-408	1.4541	-50÷250°C	gwint wewnętrzny G $\frac{1}{8}$	ø3,6
T...E-462	1.4541	-50÷400°C (RTD) -40÷400°C (TC)	króciec gwintowany bagnet	ø6, ø8
T...E-621	1.4541	-40÷300°C	obrotowy króciec z gw. UNF $\frac{1}{2}$ " 20 zwł"	owal 5x7,8
TT...E-698	1.4541	-40÷250°C	UG-3	ø3
TOPE-L0384	1.4541	-50÷180°C	króciec gwintowany M10x1	ø3.5
T...WO-1	1.4541	-50÷400°C (RTD) -40÷400°C (TC)	UG-3 lub króciec gwintowany spawany M8 do M20	ø5; peszel SS jako dodatkowa osłona przew.
T...WO-2			króciec gwintowany M12x1 bagnet	
T...E-6	1.4541	-50÷400°C (RTD) -40÷400°C (TC)	wkręt M4	ø6
PTR-24	spoina eksp.	-40÷500°C	z rękojeścią	spec. końcówka ø16
PTR-25	spoina eksp.	-40÷500°C	2 nakrętki M22x1	gwint M22x1, długość 50 mm
T...E-86	spoina eksp.	-40÷400°C	wkręt M4, M5	kończówka oczkowa
T...E-87	spoina eksp.	-40÷400°C	klej, opaska, docisk	blaszka gr. 1 mm
TOPE-88	taśma teflonowa	-40÷200°C	klej	20x40x2
TOPE-89	epoksy w kosz. tefl.	-40÷200°C	pod uzwojenia	8x50x2.5
TT...E-306	pierścień SS	40÷400°C	wkręt	–
TOPE-116	1.4541	-50÷200°C	opaską, na rurze ø15, 22, 27, 34 mm	ø6
TOPE-243	1.4541	-50÷400°C (RTD) -40÷400°C (TC)	opaska SS ø16÷200 mm	–
TO...E-244	mosiądz	-50÷400°C (RTD) -40÷400°C (TC)	opaska Ms na rurze ø15÷100 mm	ø5,8
T...-AL2	1.4541	-50÷400°C (RTD) -40÷400°C (TC)	magnes	ø5
TOPWE-1	1.4541	-50÷180°C	z rękojeścią	ø6 - perforowana
TOP-231 TOP-172	mosiądz	-50÷180°C	dodatkowa osłona z wkrętem	ø5,2
TOPA-1	1.4541	-50÷150°C	gwint M5	ø3
TOPE-413	1.4541	-50÷200°C	z rękojeścią	ostra ø4, ø6
TOPE-414	1.4541	-50÷200°C	z rękojeścią	ostra ø4
TOPE-142	teflon	-50÷250°C	z rękojeścią	ø6
TOPSZE-157	szkło	0÷180°C	UG	ø10, ø15
TOPCVE-142	1.4541	0÷100°C	UG	ø9, ø11 + koszulka PVC

Załącznik Z.3. Karta katalogowa czujników temperatury (DTR) (źródło: dokumentacja techniczna producenta).



Załącznik Z.4. Fragment dokumentacji elektrycznej systemu odrzutu – schemat sterowania sterownikiem PLC Mitsubishi FX5U (źródło: dokumentacja techniczna firmy BALDYGA Automatyka).

	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	AK	AL	AM	AN	AO	AP
1	Data	Numer tacki	Numer tacki	Numer tacki	Numer tacki	Numer tacki	Cykl	Wydajność	Nastaw temp	Temperatura	Temperatura gr	Temperatura gr	Temperatura gr	Temperatura gr	Numer tacki	Wynik resztki	cisn_pakow	gaz_cisn	proznia	napiecie_f	czas_zgrze	zwiek_sily
2	25.lis	1631690	1631691	1631692	1631693	1631694	1	5	163	162,80	162,90	163,00	162,90	162,80	1631690		32,75	800	50	50	1,4	10
3	25.lis	1631695	1631696	1631697	1631698	1631699	2	10	163	162,80	162,90	163,10	162,90	162,80		0,20	34,64	800	50	50	1,4	10
7	25.lis	1631715	1631716	1631717	1631718	1631719	6	20	163	162,90	162,90	163,10	163,10	163,00			34,26	800	50	50	1,4	10
8	25.lis	1631720	1631721	1631722	1631723	1631724	7	20	163	162,90	163,00	163,30	163,10	163,00			33,88	800	50	50	1,4	10
9	25.lis	1631725	1631726	1631727	1631728	1631729	8	20	163	162,80	162,90	163,20	162,90	162,90			31,23	800	50	50	1,4	10
14	25.lis	1631750	1631751	1631752	1631753	1631754	13	20	163	163,10	163,20	163,20	163,10	163,20			30,85	800	50	50	1,4	10
15	25.lis	1631755	1631756	1631757	1631758	1631759	14	20	163	163,00	163,10	163,20	163,00	163,10			40,33	800	50	50	1,4	10
16	25.lis	1631760	1631761	1631762	1631763	1631764	15	20	163	162,90	163,10	163,20	163,00	163,00			37,29	800	50	50	1,4	10
17	25.lis	1631765	1631766	1631767	1631768	1631769	16	20	163	162,90	162,90	163,10	162,80	162,90			33,88	800	50	50	1,4	10
18	25.lis	1631770	1631771	1631772	1631773	1631774	17	20	163	162,80	162,80	162,90	162,80	162,80			35,78	800	50	50	1,4	10
19	25.lis	1631775	1631776	1631777	1631778	1631779	18	20	163	162,80	162,80	162,80	162,80	162,80			33,50	800	50	50	1,4	10
21	25.lis	1631785	1631786	1631787	1631788	1631789	20	20	163	162,80	162,80	162,70	162,80	162,70	1631786	0,61	33,13	800	50	50	1,4	10
29	25.lis	1631825	1631826	1631827	1631828	1631829	28	20	163	162,80	162,80	162,70	162,80	162,70			34,64	800	50	50	1,4	10
31	25.lis	1631835	1631836	1631837	1631838	1631839	30	20	163	162,80	162,80	162,60	162,80	162,70			35,78	800	50	50	1,4	10
33	25.lis	1631845	1631846	1631847	1631848	1631849	32	20	163	162,80	162,80	162,80	162,80	162,70			32,75	800	50	50	1,4	10
34	25.lis	1631850	1631851	1631852	1631853	1631854	33	20	163	162,80	162,80	162,90	162,80	162,80			40,33	800	50	50	1,4	10
35	25.lis	1631855	1631856	1631857	1631858	1631859	34	20	163	162,80	162,80	162,90	162,80	162,80			32,37	800	50	50	1,4	10
36	25.lis	1631860	1631861	1631862	1631863	1631864	35	20	163	162,90	162,90	162,90	162,90	162,80			35,40	800	50	50	1,4	10
37	25.lis	1631865	1631866	1631867	1631868	1631869	36	20	163	162,80	162,80	162,90	162,80	162,80			43,36	800	50	50	1,4	10
38	25.lis	1631870	1631871	1631872	1631873	1631874	37	20	163	162,90	162,90	162,90	162,80	162,80			33,13	800	50	50	1,4	10
39	25.lis	1631875	1631876	1631877	1631878	1631879	38	20	163	162,90	162,90	162,90	162,90	162,80			32,75	800	50	50	1,4	10
40	25.lis	1631880	1631881	1631882	1631883	1631884	39	20	163	162,80	162,90	162,90	162,90	162,80			33,50	800	50	50	1,4	10
41	25.lis	1631885	1631886	1631887	1631888	1631889	40	20	163	162,90	163,00	162,80	163,00	162,90	1631887	0,62	40,33	800	50	50	1,4	10
42	25.lis	1631890	1631891	1631892	1631893	1631894	41	20	163	162,90	163,00	162,80	162,90	162,90			36,16	800	50	50	1,4	10
43	25.lis	1631895	1631896	1631897	1631898	1631899	42	20	163	163,00	163,00	162,80	162,90	162,90			32,75	800	50	50	1,4	10
44	25.lis	1631900	1631901	1631902	1631903	1631904	43	20	163	162,90	162,90	162,80	162,80	162,90			36,54	800	50	50	1,4	10
45	25.lis	1631905	1631906	1631907	1631908	1631909	44	20	163	163,00	163,00	162,90	162,90	163,00			33,13	800	50	50	1,4	10
46	25.lis	1631910	1631911	1631912	1631913	1631914	45	20	163	162,90	162,90	163,00	162,90	162,90			41,08	800	50	50	1,4	10
47	25.lis	1631915	1631916	1631917	1631918	1631919	46	20	163	162,90	162,90	162,90	162,90	162,90			35,02	800	50	50	1,4	10
48	25.lis	1631920	1631921	1631922	1631923	1631924	47	20	163	163,00	162,90	163,00	163,00	163,00			34,26	800	50	50	1,4	10
49	25.lis	1631925	1631926	1631927	1631928	1631929	48	20	163	163,00	162,90	162,90	162,90	163,00			36,92	800	50	50	1,4	10
50	25.lis	1631930	1631931	1631932	1631933	1631934	49	20	163	163,00	163,00	162,90	163,00	163,00			35,02	800	50	50	1,4	10
51	25.lis	1631935	1631936	1631937	1631938	1631939	50	20	163	163,00	162,90	162,90	162,90	163,00			34,26	800	50	50	1,4	10
52	25.lis	1631940	1631941	1631942	1631943	1631944	51	20	163	163,00	163,00	162,90	162,90	163,00			41,46	800	50	50	1,4	10
53	25.lis	1631945	1631946	1631947	1631948	1631949	52	20	163	163,00	163,00	163,00	163,00	163,00			40,33	800	50	50	1,4	10
54	25.lis	1631950	1631951	1631952	1631953	1631954	53	20	163	163,00	162,90	163,00	163,00	163,00			35,40	800	50	50	1,4	10
55	25.lis	1631955	1631956	1631957	1631958	1631959	54	20	163	163,10	163,00	163,00	163,00	163,10			34,64	800	50	50	1,4	10
56	25.lis	1631960	1631961	1631962	1631963	1631964	55	20	163	163,00	162,90	162,80	162,90	163,00			39,19	800	50	50	1,4	10
57	25.lis	1631965	1631966	1631967	1631968	1631969	56	20	163	163,10	163,00	163,00	163,00	163,00			35,40	800	50	50	1,4	10
58	25.lis	1631970	1631971	1631972	1631973	1631974	57	20	163	163,00	162,90	163,00	162,90	163,00			37,29	800	50	50	1,4	10

Załącznik Z.5. Fragment zbioru danych wykorzystanych w opracowaniu regresji logistycznej (źródło: opracowanie własne).



"TOPS" S.C.
Krzysztof Ziomek, Piotr Sierek
Laboratorium Pomiarowe Masy
ul. Legionów 239a, 43- 502 Czechowice-Dziedzice
e-mail: laboratorium@tops.pl
tel/fax: +48 (32) 215-51-81, +48 (33) 812-20-86

Laboratorium wzorujące akredytowane przez
Polskie Centrum Akredytacji, sygnatariusza porozumień EA MLA i ILAC MRA
dotyczących wzajemnego uznawania świadectw wzorcowania.
Nr akredytacji AP 093.



AP 093



ŚWIADECTWO WZORCOWANIA

Data wydania: 14 września 2022 r.

Nr świadectwa: W/2022/919

Strona 1/2

OBIEKT WZORCOWANIA	WZORCE MASY Komplet (skrzynka): 50 g, 100 g, 2x200 g, 1 kg, 2x2 kg Nr fabr.: 9040 Materiał: Stal nierdzewna	Oznaczone: M ₁ Rok prod.: 2011
ZGŁASZAJĄCY	SensorWag ul. Przeskok 53 63-400 Ostrów Wlkp.	
UŻYTKOWNIK	Mróz S.A. ul. Koźmińska 5a 63-810 Borek Wlkp.	
MIEJSCE WZORCOWANIA	"TOPS" S.C. Krzysztof Ziomek, Piotr Sierek Laboratorium Pomiarowe Masy ul. Legionów 239a 43-502 Czechowice-Dziedzice	
METODA WZORCOWANIA	Procedura Wzorcowania PTW-03, Wydanie 11 z dnia 14-01-2022 "Wzorcowanie wzorców masy, odważników klas dokładności F ₁ , F ₂ , M ₁ , M ₂ , M ₃ , obciążników"	
WARUNKI ŚRODOWISKOWE	Temperatura otoczenia: (20,1 + 20,2) °C Wilgotność względna: (53,4 + 53,7) % Ciśnienie atmosferyczne: (1007,7 + 1007,8) hPa	
DATA WYKONANIA WZORCOWANIA	14 września 2022 r.	
SPÓJNOŚĆ POMIAROWA	Świadectwo jest wydane w ramach porozumienia EA MLA w zakresie wzorcowania i potwierdza spójność wyników pomiarów z jednostkami miar Międzynarodowego Układu Jednostek Miar (SI) poprzez wzorcowanie wyposażenia pomiarowego w akredytowanych laboratoriach wzorujących	
WYNIKI WZORCOWANIA	Podano na stronie 2 niniejszego świadectwa wraz z wartościami niepewności pomiaru	
NIEPEWNOŚĆ POMIARU	Niepewność pomiaru została określona zgodnie z dokumentem EA-4/02 M:2022. Podana rozszerzona niepewność pomiaru jest wyznaczona jako iloczyn standardowej niepewności pomiaru i współczynnika rozszerzenia $k = 2$, co dla rozkładu normalnego jest równoznaczne z prawdopodobieństwem rozszerzenia wynoszącym w przybliżeniu 95 %	
ZGODNOŚĆ Z WYMAGANIAMI	Wyniki wzorcowania wzorców masy potwierdzają zgodność z wymaganiami metrologicznymi ustalonymi w Zaleceniu Międzynarodowym OIML R 111-1 Weights of classes E ₁ , E ₂ , F ₁ , F ₂ , M ₁ , M ₁₋₂ , M ₂ , M ₂₋₃ and M ₃ (2004 r.) [pkt. 5.3, Tabela 1] w zakresie błędów dopuszczalnych dla wzorców masy klasy dokładności M ₁	



KIEROWNIK
Laboratorium Pomiarowe Masy
mgr Krzysztof Ziomek

Niniejsze świadectwo może być okazywane lub kopiowane tylko w całości

Formularz PT-07/2 Wersja 16/17-05-2022 "TOPS" S.C. Laboratorium Pomiarowe Masy

PRP 625/22

Załącznik Z.6. Dokument potwierdzający legalizację odważników referencyjnych – część 1 (źródło: dokumentacja legalizacyjna Urzędu Miar).

PW/45/04/2022

Poznań, 28.04.2022

Foodmakers Sp. z o.o.
Al. Niepodległości 31
61-714 Poznań
Pan Maciej Mendyka

W odpowiedzi na Pana zamówienie z dnia 25.04.2022r. dokonałem weryfikacji i oceny jakości dostarczonych próbek kodów kreskowych.

Poniżej przedstawiam wyniki oceny jakości dostarczonych próbek kodów kreskowych:

Dane zakodowane w kodzie GS1 DataBar	Nazwa produktu	Ocena jakości kodu kreskowego
(01)059030689567 06(17)220503(10)L 16C(21)0000031	Pappardele z sosem szpinakowym, łososiem i suszonymi pomidorami 400 g	Kod GS1 DataBar Rozszerzony Spiętrzony uzyskał pozytywną ocenę jakości: B (2,9) według metody ANSI/ISO weryfikacji jakości kodów kreskowych. Kod ten jest zgodny ze „Specyfikacjami ogólnymi GS1” i będzie odczytywany przez czytniki kodów kreskowych. UWAGA Pozytywne oceny jakości kodu to (w kolejności od najwyższej do najniższej): A (3,5 ÷ 4,0), B (2,5 ÷ 3,4), C (1,5 ÷ 2,4). Oceny negatywne: D (0,5 ÷ 1,4), F (poniżej 0,5).
(01)059030689566 45(17)220503(10)L 16C(21)0000355	Gołąbek w sosie pomidorowym i ziemniakami 400 g	Kod GS1 DataBar Rozszerzony Spiętrzony uzyskał pozytywną ocenę jakości: B (3,0) według metody ANSI/ISO weryfikacji jakości kodów kreskowych. Kod ten jest zgodny ze „Specyfikacjami ogólnymi GS1” i będzie odczytywany przez czytniki kodów kreskowych.

Do niniejszego pisma załączam „Raporty z weryfikacji kodów kreskowych GS1”. Formularz tych raportów jest obowiązującym w całym ogólnosiwiatowym systemie GS1 szablonem zapisu wyników weryfikacji jakości kodów kreskowych.


Weryfikacja wykonana przez Sieć Badawczą Łukasiewicz- Poznański Instytut Technologiczny
na zlecenie GS1 Polska

Fundacja GS1 Polska

ul. E. Estkowskiego 6, 61-755 Poznań tel./fax + 48 61 851 77 54 gs1pl@gs1pl.org REGON: 363569948 NIP: 7831736664
KRS: 0000598394 Sąd Rejonowy Poznań – Nowe Miasto i Wilda w Poznaniu VIII Wydział Gospodarczy KRS

www.gs1pl.org

Załącznik Z.8. Raport z weryfikacji jakości kodów kreskowych GS1 DataBar wykonanej w laboratorium Łukasiewicz – Poznański Instytut Technologiczny (źródło: laboratorium Łukasiewicz – Poznański Instytut Technologiczny).

Protokół serwisowy						
Urządzenie	Naprawa:	Gwarancyjna		Serwisowa	V	Urządzenie: Oxybaby 6i O2/CO2
	Klient:	FOOD MAKERS Sp. z o. o.			Rok produkcji:	Z7
	Adres:	Karolew 9A1 63-810 Borek Wielkopolski			Nr seryjny:	945784
Informacje serwisowe	Wykonane czynności serwisowe:					
	Wymiana części.					
	Kalibracja analizatora.					
	Sprawdzenie poprawności pracy urządzenia.					
	Czas pracy	1 h	Kosztorys nr 240913103 / FOOD MAKERS			
	Wykorzystane części zamienne					
	Lp.	Nazwa części		Numer katalogowy		Ilość
	1.	Akumulatory bateryjne – 6.0, 6i, M		850.011100		1
	2.	Sensor tlenowy		800.515101		1
	3.	Filtr wlotowy		800.462800		1
4.						
5.						
6.						
7.						
8.						
9.						
10.						
	Data przyjęcia	Data zakończenia	Podpis serwisanta		„WITT POLSKA” Sp. z o.o. TECHNIK SERWISU <i>Bartosz Stepien</i> ul. Bulwar Dedala 16a, 54-130 Wrocław tel. +48 71 3522856 mobil: +48 607224274 e-mail: bartosz.steplen@wittgas.com Pieczęć firmowa Witt Polska	
	13.09.2024	13.09.2024				

Witt Polska Sp. z o. o. ul. Bulwar Dedala 16a 54-130 Wrocław Tel. +48(071)3522856 www.wittgas.com

Załącznik Z.9. Świadectwo kalibracji analizatora do pomiarów resztek tlenowych - część 1. (źródło: laboratorium kalibracyjne producenta analizatora).

Certyfikat kalibracji urządzenia


Informacje o urządzeniu

Moduł	Typ	Dane urządzenia			
Czujnik ciśnienia / moduł DSP	G6-01.09.01	Nazwa klienta	FOOD MAKERS Sp. z o. o.		
Pompa / Moduł LDP	L3-05.02.06	Nazwa urządzenia	Oxybaby 6i O2/CO2		
Moduł CO ₂	D5-02.02.05	Rok produkcji	Z7	Nr seryjny	945784
Numer katalogowy	-	Nr seryjny	Wartość		Wartość
Wersja oprogramowania	B6-09.02.08	945784	znormalizowana		rzeczywista
Czujnik O ₂	800.515100	49170416074	8.0 - 13.0 mV		10.3 mV
Czujnik O ₂ (PA)	956.439700	-----	8.0 - 13.0 mV		-----

Sprawdzenie poprawności pracy

Lp.	Funkcja	Żądane wartości		Wartości uzyskane		OK
1.	Ciśnienie punktu zerowego	900	mbar	900	mbar	V
2.	Ciśnienie punktu końcowego	1100	mbar	1100	mbar	V
3.	Zasilanie	-----	-----	-----	-----	V
4.	Archiwizacja danych	-----	-----	-----	-----	V
5.	Przepływ tryb wyrwykowy	5 - 10	ml	8 / 12	ml / s	V
6.	Gaz balansowy	N ₂ / Ar		N ₂		V
7.	O ₂ 20,90% - pkt.	20,70 – 21,10% O ₂		20,93 % O ₂		V
8.	O ₂ 0,80% - pkt.	0,70 – 0,95% O ₂		0,74 % O ₂		V
8.	O ₂ 0% - pkt.	0,00 – 0,20% O ₂		0,03 % O ₂		V
9.	CO ₂ 100% - pkt.	98,5 - 100% CO ₂		99,4 % CO ₂		V
10.	CO ₂ 80% - pkt.	78,5 - 81,5% CO ₂		80,9 % CO ₂		V
11.	CO ₂ 60% - pkt.	59,0 - 61,0% CO ₂		60,4 % CO ₂		V
12.	CO ₂ 30% - pkt.	29,0 - 31,0% CO ₂		29,5 % CO ₂		V
13.	CO ₂ 0% - pkt.	0,0 - 1,0% CO ₂		0,5 % CO ₂		V

Informacje dodatkowe

Data następnego przeglądu:	09.2025
Zalecana częstotliwość kalibracji:	przynajmniej raz w tygodniu
Data wystawienia certyfikatu	13.09.2024
 Podpis osoby sprawdzającej	„WITT POLSKA” Sp. z o.o. TECHNIK SERWISU Bartosz Stepien ul. Bulwar Dedala 16a, 54-130 Wrocław tel. +48 71 3522856 mobil: +48 607224274 e-mail: bartosz.stepen@wittgas.com Pieczęć firmowa Witt Polska

Załącznik Z.10. Świadcstwo kalibracji analizatora do pomiarów resztek tlenowych - część 2 (źródło: laboratorium kalibracyjne producenta analizatora).

SPIS RYSUNKÓW

Rysunek 2.1. Funkcje inteligentnych systemów nadzorowania	19
Rysunek 2.2. Piramida systemów nadzorowania procesów produkcyjnych według standardu ISA-95	20
Rysunek 2.3. Warstwy architektury inteligentnego systemu nadzorowania	25
Rysunek 2.4. Klasyfikacja wskaźników efektywności (KPI) w inteligentnym nadzorowaniu procesów	30
Rysunek 3.1. Zakład produkcyjny Foodmakers Sp. z o.o. (Grupa Mróz S.A.)	48
Rysunek 3.2. Schemat organizacji przepływów w hali produkcyjnej	49
Rysunek 3.3. Schemat przebiegu procesu produkcyjno-logistycznego w zakładzie – stan wyjściowy (2021 r.) ...	50
Rysunek 3.4. Schemat linii konfekcjonowania z oznaczeniem urządzeń i stanowisk	51
Rysunek 3.5. Przebieg procesu konfekcjonowania w badanym środowisku oraz zidentyfikowane niezgodności	57
Rysunek 3.6. Koncepcja systemu nadzorowania procesu konfekcjonowania wyrobów	59
Rysunek 3.7. Architektura warstwowa inteligentnego systemu nadzorowania procesu konfekcjonowania wyrobów	65
Rysunek 4.1. Stanowisko wagowe z panelem operatorskim HMI	67
Rysunek 4.2. Logika modułu nadzorowania masy porcji	68
Rysunek 4.3. Interfejs aplikacji: konfiguracja i monitoring operacji naważania	68
Rysunek 4.4. Interfejs aplikacji: kartoteka towarów i surowców	69
Rysunek 4.5. Interfejs aplikacji – raport z modułu nadzorowania masy porcji	69
Rysunek 4.6. Stanowisko modułu nadzorowania „nieszczelności I”	71
Rysunek 4.7. Interfejs kamery w module nadzorowania „nieszczelności I” – podgląd próbki i parametry akwizycji obrazu	71
Rysunek 4.8. Baza danych obrazów z wstępną kategoryzacją defektów	74
Rysunek 4.9. Przykładowe obrazy opakowań w module nadzorowania „nieszczelności I”	75
Rysunek 4.10. Dokładność pierwotnej klasyfikacji modelu w procesie trenowania – przebieg dla zbioru treningowego i walidacyjnego (6 klas)	77
Rysunek 4.11. Przebieg pierwotnej funkcji straty (loss) w procesie uczenia modelu – skala logarytmiczna	77
Rysunek 4.12. Przebieg pierwotnej funkcji straty (loss) w procesie uczenia modelu – skala liniowa	78
Rysunek 4.13. Dokładność ostatecznej klasyfikacji modelu w procesie trenowania – przebieg dla zbioru treningowego i walidacyjnego (3 klasy)	78
Rysunek 4.14. Przebieg ostatecznej funkcji straty (loss) w procesie uczenia modelu – skala logarytmiczna	79
Rysunek 4.15. Przebieg ostatecznej funkcji straty (loss) w procesie uczenia modelu – skala liniowa	79
Rysunek 4.16. Macierze pomyłek dla pierwotnych wersji modelu inspekcji wizyjnej w module nadzorowania „nieszczelności I”	80
Rysunek 4.17. Macierz pomyłek dla ostatecznej wersji modelu inspekcji wizyjnej w module „nieszczelności I”	81
Rysunek 4.18. Statystyki walidacji modelu inspekcji wizyjnej w module nadzorowania „nieszczelności I” – testy w warunkach produkcyjnych	82
Rysunek 4.19. Widok klasyfikatora AI w module nadzorowania „nieszczelności I” – wynik klasyfikacji z wartością confidence	83
Rysunek 4.20. Konfiguracja wyjść cyfrowych dla logiki decyzyjnej w module nadzorowania „nieszczelności I”	83

Rysunek 4.21. Uproszczony pseudokod logiki decyzyjnej w module nadzorowania „nieszczelności I”	84
Rysunek 4.22. Plan badań w module nadzorowania „nieszczelności II”	86
Rysunek 4.23. Układ eksperymentalny: warianty parametrów technologicznych operacji pakowania	87
Rysunek 4.24. Stanowisko do pomiaru zawartości tlenu w opakowaniach	88
Rysunek 4.25. Szafa sterownicza systemu pakowania z modułami PLC i układem akwizycji danych	90
Rysunek 4.26. Szafa sterownicza systemu pakowania z modułami komunikacyjnymi OPC UA i routerem eWON współpracującym z panelami HMI	91
Rysunek 4.27. Ekran archiwizacji danych z funkcją eksportu do arkuszy Excel w module nadzorowania „nieszczelności II”	91
Rysunek 4.28. Zarchiwizowane dane operacji pakowania w formacie umożliwiającym analizę statystyczną i walidacyjną w module nadzorowania „nieszczelności II”	92
Rysunek 4.29. Etapy cyfryzacji i wdrożenia warstwy akwizycji danych w module nadzorowania „nieszczelności II”	92
Rysunek 4.30. Zróznicowanie względem ciśnienia bezwzględnego w komorze pakującej	96
Rysunek 4.31. Zróznicowanie ze względu na temperaturę zgrzewania	96
Rysunek 4.32. Zróznicowanie ze względu na wydajność linii	96
Rysunek 4.33. Wykres ROC dla modelu regresji logistycznej	97
Rysunek 4.34. Interfejs aplikacji systemu dla modułu nadzorowania „nieszczelności II”	99
Rysunek 4.35. Porównanie zmienności temperatury i zawartości tlenu w opakowaniu	101
Rysunek 4.36. Logika działania modelu wsparcia diagnostycznego	102
Rysunek 4.37. Interfejs konfiguracji narzędzia OCR do odczytu oznaczeń alfanumerycznych z etykiety wyrobu	104
Rysunek 4.38. Konfiguracja narzędzia 2D Code Analysis do odczytu i weryfikacji kodów DataMatrix na etykiecie	104
Rysunek 4.39. Wykorzystanie narzędzia Blob Finder do oceny jakości i ciągłości nadruku znaków na opakowaniu	105
Rysunek 4.40. Schemat logiki działania modułu kontroli etykiet	105
Rysunek 4.41. Konfiguracja wyjść cyfrowych dla modułu analizy etykiet	106
Rysunek 4.42. Interfejs wizualizacji wyników inspekcji etykiet	107
Rysunek 4.43. Widok stanowiska odrzutu wyrobów niezgodnych z siłownikiem pneumatycznym	108
Rysunek 4.44. Schemat logiki działania modułu odrzutu wyrobów niezgodnych	109
Rysunek 4.45. Panel webowy modułu odrzutu wyrobów niezgodnych	110
Rysunek 4.46. Ekran diagnostyczny modułu odrzutu	110
Rysunek 5.1. Wykres zmian odsetka przeważań i niedowag w latach 2021–2024	117
Rysunek 5.2. Histogram rozkładu masy wyrobów: dane z 2022 roku	118
Rysunek 5.3. Histogram rozkładu masy wyrobów: dane z 2024 roku	118
Rysunek 5.4. Wskaźnik strat surowca 1 na przestrzeni miesięcy (2021–2023)	119
Rysunek 5.5. Wskaźnik strat surowca 2 na przestrzeni miesięcy (2021–2023)	119
Rysunek 5.6. Wskaźnik strat surowca 3 na przestrzeni miesięcy (2022–2023)	120
Rysunek 5.7. Wskaźnik strat surowca 4 na przestrzeni miesięcy (2022–2023)	120

Rysunek 5.8. Zmiany wskaźnika DPMO - masa w latach 2021–2024	121
Rysunek 5.9. Zmiany wskaźników DPMO dla różnych kategorii w latach 2021–2024	122
Rysunek 5.10. Zmiany wydajności linii produkcyjnej w latach 2022–2025	123
Rysunek 5.11. Zmiany wskaźników składowych oraz wartości OEE w latach 2022–2025	124

SPIS TABEL

Tabela 2.1. Porównanie systemów SCADA, MES i ERP	22
Tabela 2.2. Przegląd metod i technologii AI wykorzystywanych w systemach nadzorowania	24
Tabela 2.3. Kluczowe wskaźniki efektywności (KPI) w inteligentnym nadzorowaniu procesów	31
Tabela 2.4. Przegląd systemów konfekcjonowania – charakterystyka i zastosowanie	34
Tabela 2.5. Metody konfekcjonowania w wybranych branżach	36
Tabela 2.6. Przegląd metod oraz narzędzi nadzorowania procesów konfekcjonowania w literaturze	41
Tabela 3.1. Najczęściej występujące zdarzenia techniczne w kluczowych operacjach procesu (2021–2022)	52
Tabela 3.2. Zakłócenia organizacyjne w kluczowych operacjach procesu (2021–2022)	53
Tabela 3.3. Najczęściej występujące reklamacje jakościowe (2021–2022)	53
Tabela 3.4. Zestawienie wskaźników DPMO w latach 2021–2022	54
Tabela 3.5. Analiza rozważanych metod kontroli masy porcji (naważanie)	61
Tabela 3.6. Analiza rozważanych metod kontroli szczelności opakowań (nieszczelności I)	62
Tabela 3.7. Analiza rozważanych metod kontroli mikronieszczelności (nieszczelności II)	62
Tabela 3.8. Powiązanie modułów funkcjonalnych z operacjami procesu, problemami jakościowymi, warstwami architektury oraz funkcjami systemu	64
Tabela 4.1. Aparatura wykorzystana w budowie modułu nadzorowania „nieszczelności I”	72
Tabela 4.2. Kluczowe parametry technologiczne monitorowane w module nadzorowania „nieszczelności II” ...	89
Tabela 4.3. Parametry regresji logistycznej	94
Tabela 4.4. Macierz pomyłek – zbiór testowy	95
Tabela 4.5. Wskaźniki jakości klasyfikacji	95
Tabela 4.6. Porównanie statystyczne parametrów temperatury grzałek i wyników zawartości tlenu	100
Tabela 4.7. Progi diagnostyczne odchylenia standardowego temperatury grzałek wraz z charakterystyką stanu procesu	101
Tabela 5.1. Wyniki walidacji procesu naważania: liczba opakowań, masa surowca oraz odsetek niedowag i przeważen w latach 2021–2024	117
Tabela 5.2. Wskaźnik DPMO w poszczególnych operacjach procesu konfekcjonowania (2021–2024)	121
Tabela 5.3. Zmiany wartości wskaźników OEE oraz jego składowych: jakości, dostępności i efektywności w latach 2022–2025	123
Tabela 5.4. Zmiany wskaźnika wydajności pracy procesu konfekcjonowania w latach 2021–2024	124
Tabela 5.5. Zestawienie wyników walidacji	126
Tabela 5.6. Analiza SWOT wdrożonego systemu nadzorowania procesu konfekcjonowania	128

SPIS ZAŁĄCZNIKÓW

Załącznik Z.1. Specyfikacja techniczna model: folia CX-P AHB 55 AF / CX-P AHB 55 AF peel	139
Załącznik Z.2. Karta techniczna opakowanie W1/602 (187/137/50) 850 ml	140
Załącznik Z.3. Karta katalogowa czujników temperatury (DTR)	141
Załącznik Z.4. Fragment dokumentacji elektrycznej systemu odrzutu – schemat sterowania sterownikiem PLC Mitsubishi FX5U	142
Załącznik Z.5. Fragment zbioru danych wykorzystanych w opracowaniu regresji logistycznej	143
Załącznik Z.6. Dokument potwierdzający legalizację odważników referencyjnych – część 1	144
Załącznik Z.7. Dokument potwierdzający legalizację odważników referencyjnych – część 2	145
Załącznik Z.8. Raport z weryfikacji jakości kodów kreskowych GS1 DataBar wykonanej w laboratorium Łukasiewicz – Poznański Instytut Technologiczny	146
Załącznik Z.9. Świadectwo kalibracji analizatora do pomiarów resztek tlenowych – część 1	147
Załącznik Z.10. Świadectwo kalibracji analizatora do pomiarów resztek tlenowych – część 2	148

BIBLIOGRAFIA

- Aksel de Vries. (2021). *Industry 4.0 Technology Battles In Manufacturing Operations Management Non-Technical Dominance Factors For Iiot & Mes*.
<https://doi.org/https://repository.tudelft.nl/record/uuid:b25f5133-7710-4a2c-abd8-3e4a5d929a97>
- Altemimi, A. B., Awlqadr, F. H., Al-Hatim, R. R., Qadir, S. A., Saeed, M. N., Faraj, A. M., Salih, T. H., Mahmood, H. S., Hesarinejad, M. A., & Cacciola, F. (2025). AI-Powered Advancements in Food Analysis and Safety: Ensuring Quality, Protection, and Precision in Modern Food Systems: A Review. *W eFood* (T. 6, Numer 4). John Wiley and Sons Inc.
<https://doi.org/https://doi.org/10.1002/efd2.70076>
- Antony Satya, & Vivek Vardhan Akisetty. (2024). AI Driven Quality Control Using Logistic Regression and Random Forest Models. *International Research Journal of Modernization in Engineering Technology and Science*. <https://doi.org/10.56726/irjmets16032>
- Awotidebe, M. (2025). *Comparative Analysis Of Serverless Vs. Traditional Data Engineering Architectures*. <https://www.researchgate.net/publication/390625711>
- Ayvaz, S., & Alpay, K. (2021). Predictive maintenance system for production lines in manufacturing: A machine learning approach using IoT data in real-time. *Expert Systems with Applications*, 173. <https://doi.org/10.1016/j.eswa.2021.114598>
- Baines, T. (2006). *State-of-the-art in Lean Design Engineering; a Literature Review on White Collar Lean*. <https://doi.org/DOI:10.1243/09544054JEM613>
- Banus, N., Boada, I., Bardera, A., & Toldra, P. (2021). A Deep-Learning Based Solution to Automatically Control Closure and Seal of Pizza Packages. *IEEE Access*, 9, 167267–167281. <https://doi.org/10.1109/ACCESS.2021.3135973>
- Barmpalexis, P., Partheniadis, I., Mitra, K. S., Toskas, M., Papadopoulou, L., & Nikolakakis, I. (2020). Application of multiple linear regression and artificial neural networks for the prediction of the packing and capsule filling performance of coated and plain pellets differing in density and size. *Pharmaceutics*, 12(3). <https://doi.org/10.3390/pharmaceutics12030244>
- Bazen, J., Ugolnikova, O., & Bazen, I. (2022). *Development of Industry 4.0: A Practical Case Study from the Netherlands* (s. 267–277). https://doi.org/10.1007/978-3-031-14410-3_28
- Bazydło, P. (2015). *An Integrated Dynamic Weighing System Based On Scada*. <https://doi.org/10.5277/ord150201>
- Belmonte, F., Boulanger, J. L., Schön, W., & Berkani, K. (2006). Role of supervision systems in railway safety. *WIT Transactions on the Built Environment*, 88, 129–138. <https://doi.org/10.2495/CR060131>
- Berić, D., Stefanović, D., & Lalić, B. (2018). The Implementation of ERP and MES Systems as a Support to Industrial Management Systems Ilija Ćosić. *International Journal of Industrial Engineering and Management (IJIEM)*, 9(2), 77–86. www.iim.ftn.uns.ac.rs/ijiem_journal.php
- Biji, K. B., Ravishankar, C. N., Mohan, C. O., & Srinivasa Gopal, T. K. (2015). Smart packaging systems for food applications: a review. *W Journal of Food Science and Technology* (T. 52, Numer 10, s. 6125–6135). Springer India. <https://doi.org/10.1007/s13197-015-1766-7>
- Cao, K., Liu, Y., Meng, G., & Sun, Q. (2020). An Overview on Edge Computing Research. *W IEEE Access* (T. 8, s. 85714–85728). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2020.2991734>

- Cate, M., Ben, J., & Kate, J. (2025). *Revolutionizing Factory Floor Operations: Intelligent Workflow Automation With Camstar Mes, Rpa, And Power Automate*.
- Chang, Y. S., & Tu, L. Y. (2023). Use of IoT Sensors to Build an Intelligent Monitoring and Control System for Poultry House Environment. *Sensors and Materials*, 35(1–12), 3997–4012. <https://doi.org/10.18494/SAM4582>
- Chen, J., Wu, G., Jian, X., Cai, L., Chen, S., & Chen, R. (2022). Research on State Monitoring System of Intelligent Disconnecting Switch Based on Sensing Technology. *Frontiers in Energy Research*, 10. <https://doi.org/10.3389/fenrg.2022.895301>
- Cheng, C. Y., Pourhejazy, P., Hung, C. Y., & Yuangyai, C. (2021). Smart monitoring of manufacturing systems for automated decision-making: A multi-method framework. *Sensors*, 21(20). <https://doi.org/10.3390/s21206860>
- Chisenga, S. M., Tolesa, G. N., & Workneh, T. S. (2020). Biodegradable food packaging materials and prospects of the fourth industrial revolution for tomato fruit and product handling. W *International Journal of Food Science* (T. 2020). Hindawi Limited. <https://doi.org/10.1155/2020/8879101>
- Chiu, S. W., Ting, C. K., & Chiu, Y. S. P. (2007). Optimal production lot sizing with rework, scrap rate, and service level constraint. *Mathematical and Computer Modelling*, 46(3–4), 535–549. <https://doi.org/10.1016/j.mcm.2006.11.031>
- Chohan, B. S., Xu, X., & Lu, Y. (2022). MES Dynamic interoperability for SMEs in the Factory of the Future perspective. *Procedia CIRP*, 107, 1329–1335. <https://doi.org/10.1016/j.procir.2022.05.153>
- Chou, P.-H., Hsu, Y.-L., Lee, W.-L., Kuo, Y.-C., Chang, C.-C., Cheng, Y.-S., Chang, H.-C., Lin, S.-L., Yang, S.-C., & Lee, H.-H. (2017). Development of a smart home system based on multi-sensor data fusion technology. *2017 International Conference on Applied System Innovation (ICASI)*, 690–693. <https://doi.org/10.1109/ICASI.2017.7988519>
- Chowdhury, A., & Nuruzzaman, Md. (2023). Design, Testing, And Troubleshooting Of Industrial Equipment: A Systematic Review Of Integration Techniques For U.S. Manufacturing Plants. *Review of Applied Science and Technology*, 02(01), 53–84. <https://doi.org/10.63125/893et038>
- Coles R, McDowell, Derek., & Coles, Richard. (2003). *Food packaging technology*. Blackwell ; CRC. <https://doi.org/10.1002/9781444392180>
- Colombo, A. W. . (2014). *Industrial cloud-based cyber-physical systems : the IMC-AESOP approach*. Springer. <https://doi.org/10.1007/978-3-319-05624-1>
- Czerwińska, K., Pacana, A., & Ostasz, G. (2025). A Model for Sustainable Quality Control Improvement in the Foundry Industry Using Key Performance Indicators. *Sustainability (Switzerland)*, 17(4). <https://doi.org/10.3390/su17041418>
- Dobrucka, R. (2013). The future of active and intelligent packaging industry. *LogForum*, 9(2), 103–110.
- Dodke, F. (2025). Pharmaceutical Packaging: A Review of Current Technologies and Future Innovations. *Int. J. of Pharm. Sci*, 3, 236–251. <https://doi.org/10.5281/zenodo.14801314>
- Elmadhoun, B., Alsaidalani, R., & Burczynski, F. (2025). Quality Risk Management in the Final Operational Stage of Sterile Pharmaceutical Manufacturing: A Case Study Highlighting the Management of Sustainable Related Risks in Product Sterilization, Inspection, Labeling, Packaging, and Storage Processes. *Sustainability (Switzerland)*, 17(4). <https://doi.org/10.3390/su17041670>

- Esther, D. (2024). *Integration of SCADA and MES for Seamless Data Flow*.
<https://www.researchgate.net/publication/387504085>
- Fang, X., Song, Q., Li, Z., Wang, X., Ma, H., & Liu, Z. (2025). Intelligent monitoring system for production lines in smart factories: A hybrid method integrating Transformer and Kalman filter. *Journal of Manufacturing Systems*, 79, 27–47. <https://doi.org/10.1016/J.JMSY.2024.12.014>
- Fantozzi, I. C., Di Luozzo, S., & Schiraldi, M. M. (2023). Industrial Performance Measurement Systems Coherence: A Comparative Analysis of Current Methodologies, Validation and Introduction to Key Activity Indicators. *Applied Sciences (Switzerland)*, 13(1).
<https://doi.org/10.3390/app13010235>
- Farah-Alva, M., Montaña-Vaez, S., & Quiroz-Flores, J. C. (2024). Enhancing Productivity in Agricultural Packing Operations through TPM and Lean Manufacturing: A Case Study of Asparagus Processing in Peru. *SSRG International Journal of Mechanical Engineering*, 11(11), 1–14. <https://doi.org/10.14445/23488360/IJME-V11I11P101>
- Fung, F., Wang, H. S., & Menon, S. (2018). Food safety in the 21st century. W *Biomedical Journal* (T. 41, Numer 2, s. 88–95). Elsevier B.V. <https://doi.org/10.1016/j.bj.2018.03.003>
- Gao, Y., Gu, H., & Ma, Y. (2025). Exploration and future prospects of intelligent supervision technology and system development in biological laboratories. *Scientific Reports*, 15(1).
<https://doi.org/10.1038/s41598-025-98669-7>
- García-Jiménez, R. (2021). Packaging process optimization in multihead weighers with double-layered upright and diagonal systems. *Mathematics*, 9(9). <https://doi.org/10.3390/math9091039>
- Gil L., & Ruiz P., Font G, Manyes L. (2017). *A decade of Food Safety Management System based on ISO 22000 A global overview*.
https://doi.org/https://www.researchgate.net/publication/329684141_A_decade_of_food_safety_management_system_based_on_ISO_22000_A_GLOBAL_overview
- Gomaa, A. H. (2025). Advancing Manufacturing Excellence in the Industry 4.0 Era: A Comprehensive Review and Strategic Integrated Framework. *Supply Chain Research*, 2(2).
<https://doi.org/10.59429/scr.v2i2.10220>
- Gopang, M. A. (2024). *Exploring Trends of Overall Equipment Effectiveness (OEE) Implementation in Manufacturing Organizations*. <https://www.researchgate.net/publication/384930736>
- Gordon L. Robertson. (2012). *Food Packaging Third Edition Principles and Practice*.
<https://doi.org/https://doi.org/10.1201/b21347>
- Groover M. (2010). *Fundamentals of Modern Manufacturing Materials Processes and Systems 4th Edition*.
https://doi.org/https://www.academia.edu/21992929/Fundamentals_of_Modern_Manufacturing
- Gunia, G. (2019). Zintegrowane Systemy Informatyczne Przedsiębiorstw W Kontekście Przemysłu 4.0. *Zarządzanie Przedsiębiorstwem*. *Enterprise Management*, 22(2), 7–12.
<https://doi.org/10.25961/ent.manag.22.02.02>
- Guo, E. (2023). Perception System of Garment Machinery Production Line Based on the Internet of Things. W *International Journal of Mechatronics and Applied Mechanics*.
- Habib, M. A., Rizvan, R., & Ahmed, S. (2023). Implementing lean manufacturing for improvement of operational performance in a labeling and packaging plant: A case study in Bangladesh. *Results in Engineering*, 17. <https://doi.org/10.1016/j.rineng.2022.100818>

- Hallmann, M., Schleich, B., Heling, B., Aschenbrenner, A., & Wartzack, S. (2018). Comparison of different methods for scrap rate estimation in sampling-based tolerance-cost-optimization. *Procedia CIRP*, 75, 51–56. <https://doi.org/10.1016/j.procir.2018.01.005>
- Han, J. W., Ruiz-Garcia, L., Qian, J. P., & Yang, X. T. (2018). Food Packaging: A Comprehensive Review and Future Trends. W *Comprehensive Reviews in Food Science and Food Safety* (T. 17, Numer 4, s. 860–877). Blackwell Publishing Inc. <https://doi.org/10.1111/1541-4337.12343>
- Harshitkumar j Ghelani. (2021). Advances in Lean Manufacturing: Improving Quality and Efficiency in Modern Production Systems. *International Journal of Scientific Research and Management*, 9(06), 604–610. <https://doi.org/10.18535/ijsrcm/v9i06.ec01>
- Hector, I., & Panjanathan, R. (2024). Predictive maintenance in Industry 4.0: a survey of planning models and machine learning techniques. *PeerJ Computer Science*, 10, 1–50. <https://doi.org/10.7717/peerj-cs.2016>
- Henok, H. /, & Meskel. (2024). *Design and Development of TPM model for plastic manufacturing industry: A case study on OK plastic factory*. <http://dspace.orghttp://ir.bdu.edu.et/handle/123456789/16377>
- Huaman-Monzon, E., & Villegas-Rodriguez, F. F. (2024, wrzesień 24). Enhancing Operational Efficiency in Flexographic SMEs through Lean Manufacturing: A Case Study. *Proceedings of the International Conference on Industrial Engineering and Operations Management*. <https://doi.org/10.46254/AU03.20240071>
- Hui, T. K. L., Mohammed, B., Donyai, P., McCrindle, R., & Sherratt, R. S. (2020). Enhancing pharmaceutical packaging through a technology ecosystem to facilitate the reuse of medicines and reduce medicinal waste. *Pharmacy*, 8(2), 1–18. <https://doi.org/10.3390/pharmacy8020058>
- Jacek Wysocki. (2007). *Wykorzystanie analizy SWOT przy wyborze strategii na przykładzie firmy Vistula SA*. <https://doi.org/http://hdl.handle.net/20.500.12182/901>
- Jacobs D. (2024). *Designing a new performance management system for the packing process in vidaXL's e-commerce warehouse*. <https://doi.org/https://research.tue.nl/en/studentTheses/designing-a-new-performance-management-system-for-the-packing-pro>
- Ji, T., & Xu, X. (2025). Exploring the Integration of cloud manufacturing and cyber-physical systems in the era of industry 4.0 – An OPC UA approach. *Robotics and Computer-Integrated Manufacturing*, 93. <https://doi.org/10.1016/j.rcim.2024.102927>
- Kałkowska, J. (2020). *Inteligentne wyzwania technologii i organizacji procesów wytwarzania maszyn*. <https://doi.org/http://hdl.handle.net/11089/32928>
- Kamali, A. (2018). The way to optimize On-Time Delivery (OTD) in Logistics-Firms in Bahrain. W *Article in CiiT International Journal of Biometrics and Bioinformatics*. <https://www.researchgate.net/publication/329253375>
- Kang, N., Zhao, C., Li, J., & Horst, J. A. (2016). A Hierarchical structure of key performance indicators for operation management and continuous improvement in production systems. *International Journal of Production Research*, 54(21), 6333–6350. <https://doi.org/10.1080/00207543.2015.1136082>
- Kim, S., Park, J., Jeong, Y., & Lee, S. E. (2023). Intelligent Monitoring System with Privacy Preservation Based on Edge AI. *Micromachines*, 14(9). <https://doi.org/10.3390/mi14091749>

- Kliment, M., Trebuna, P., Pekarcikova, M., Straka, M., Trojan, J., & Duda, R. (2020). Production efficiency evaluation and products' quality improvement using simulation. *International Journal of Simulation Modelling*, 19(3), 470–481. <https://doi.org/10.2507/IJSIMM19-3-528>
- Komeil Esmaeilzadeh. (2021). *Remote Monitoring And Control Of Industrial Equipment Through OpCua And Cloud Computing*. <https://doi.org/https://urn.fi/URN:NBN:fi:tuni-202105165031>
- Kukushkin, K., Ryabov, Y., & Borovkov, A. (2022). Digital Twins: A Systematic Literature Review Based on Data Analysis and Topic Modeling. *Data*, 7(12). <https://doi.org/10.3390/data7120173>
- Kumar, I., Rawat, J., Mohd, N., & Husain, S. (2021). Opportunities of Artificial Intelligence and Machine Learning in the Food Industry. *Journal of Food Quality*, 2021. <https://doi.org/10.1155/2021/4535567>
- Kumar, Y., Marchena, J., Awlla, A. H., Li, J. J., & Abdalla, H. B. (2024). The AI-Powered Evolution of Big Data. *Applied Sciences (Switzerland)*, 14(22). <https://doi.org/10.3390/app142210176>
- Lang, L., & Huemer, C. (2020). *A Graphical Toolkit for ISA-95 Empowering End Users to Develop Bridges between ERP and MES Business Informatics*. www.tuwien.at
- Lee, J. (2007). *The quest for zero downtime*. <http://machinedesign.com/print/archive/quest-zero-downtime>
- Leśniewski, A., Plaszczyk, J., Karchut, P., Kiljan, A., Politechnika, E. J., Wydział, Ś., & Technologiczny, M. (2023). *Wpływ wybranych czynników na polepszenie wskaźnika OEE na wybranym odcinku procesu produkcyjnego*. www.dsr.com.pl
- Lidong, W., & Guanghui, W. (2016). Big Data in Cyber-Physical Systems, Digital Manufacturing and Industry 4.0. *International Journal of Engineering and Manufacturing*, 6(4), 1–8. <https://doi.org/10.5815/ijem.2016.04.01>
- Liu, W. (2022). Beer filling precision control technology based on fuzzy neural network. *Food and Machinery*, 38(4), 104–108. <https://doi.org/10.13652/j.spjx.1003.5788.2022.90126>
- Lu, K., & Song, X. (2025). Research on Intelligent Monitoring System for Special Vehicles Based on Cloud Computing and Internet of Things. *Proceedings of 2025 3rd International Conference on Communication Networks and Machine Learning, CNML 2025*, 456–462. <https://doi.org/10.1145/3728199.3728275>
- Luzzo, S. Di, Starnoni, F., & Schiraldi, M. M. (2023). On the relationship between human factor and overall equipment effectiveness (OEE): An analysis through the adoption of analytic hierarchy process and ISO 22400. *International Journal of Engineering Business Management*, 15. <https://doi.org/10.1177/18479790231188548>
- Mahalik, N. (2014b). Advances in Packaging Methods, Processes and Systems. *Challenges*, 5(2), 374–389. <https://doi.org/10.3390/challe5020374>
- Majstorovic, V., Stojadinovic, S., Lalic, B., & Marjanovic, U. (2020). *Distributed under a Creative Commons Attribution 4.0 International License ERP in Industry 4.0 Context*. 287–294. https://doi.org/10.1007/978-3-030-57993-7_33i
- Mantravadi, S., Srail, J. S., & Møller, C. (2023). Application of MES/MOM for Industry 4.0 supply chains: A cross-case analysis. *Computers in Industry*, 148. <https://doi.org/10.1016/j.compind.2023.103907>
- Matuszek. (2012). Analiza Przebiegu Procesu Naważania Wybranych Składników Paszy. *Z*, 2(137), 193–201. <http://www.ptir.org>

- Mayasari, D., & Arman, A. A. (2023). SUPERVISION TRANSFORMATION IN GOVERNMENT INSTITUTIONS. *Journal of Theoretical and Applied Information Technology*, 15(23). www.jatit.org
- McGuire, J. T., Sefcik, D. A., Minnich, L. B., Chavez Baucom, I., & Lippa, K. A. (2025). *Checking the net contents of packaged goods* : <https://doi.org/10.6028/NIST.HB.133-2025>
- Mendes, C. R. (2020). The Digitalization of Manufacturing: A Case Study. *International Journal of Advanced Engineering Research and Science*, 7(6), 100–106. <https://doi.org/10.22161/ijaers.76.13>
- Mendis, E., & Rajapakse, N. (2009). *GMP AND HACCP A Handbook for Small and Medium Scale Food Processing Enterprises The Ceylon Chamber of Commerce in collaboration with the Sri Lanka Food Processors Association written by.*
- Meredyk, K. (2003). *Efektywność i czynniki efektywności. Copyright © by Wydział Ekonomiczny Uniwersytetu w Białymstoku Białystok 2003.* <https://doi.org/http://hdl.handle.net/11320/13692>
- Milewska, E. (2020). Integration of it systems supporting production management. *Scientific Papers of Silesian University of Technology – Organization and Management Series*, 2020(148), 497–509. <https://doi.org/10.29119/1641-3466.2020.148.36>
- Mirzaraxmedova, A. X., & Fozilova, M. M. (2019). *Analysis of Prospects of Technology of Intelligent Monitoring Systems.* 1–8. <https://doi.org/10.1109/ICISCT47635.2019.9011845>
- Mohita Thakur. (2025). Importance of In-Process Quality Control for Product Safety and Integrity in Pharmaceutical Packaging. *Current Pharmaceutical Research*, 116–124. <https://doi.org/10.63785/cpr.2025.1.2.225232>
- Mosconi, E. M., Colantoni, A., & Tarantino, M. (2024). *Strategies for Enhancing the Efficiency of Packaging and Managing Packaging Waste in Compliance with Regulations.*
- Mouhib, Z., Gallab, M., Merzouk, S., Soulhi, A., & Di Nardo, M. (2025). Total Productive Maintenance and Industry 4.0: A Literature-Based Path Toward a Proposed Standardized Framework. *Applied System Innovation*, 8(4), 98. <https://doi.org/10.3390/asi8040098>
- Narayan Biswas, A. (2024). *Master's Programme in Manufacturing Application of Lean Six Sigma Strategies for Process Optimization during the Implementation Phase of Customer Onboarding: Case Study of a SaaS Organization.*
- Negnevitsky, M. N. (2005). *Artificial Intelligence A Guide to Intelligent Systems Artificial Intelligence Artificial Intelligence A Guide to Intelligent Systems Second Edition Second Edition Second Edition.* www.pearsoned.co.uk
- Ngadiman, Y., Hussin, B., Aziati Abd Hamid, N., Ramlan, R., Kai Boon, L., Tun Hussein Onn Malaysia, U., Raja, P., & Pahat, B. (2016). *Relationship between Human Errors in Maintenance and Overall Equipment Effectiveness in Food Industries.*
- Nowicki, M. (2016). *Six Sigma. Kompendium metod i technik zarządzania.* <https://www.researchgate.net/publication/302929521>
- Nugraha, E., Sari, R. M., Kurniawan, A., & Guslan, D. (2024). Analysis and implementation of the dmaic six sigma method as an effort to control weaving fabric production defects: Industrial textile case study. *Edelweiss Applied Science and Technology*, 8(5), 701–707. <https://doi.org/10.55214/25768484.v8i5.1734>

- Olalere, I. O., & Olanrewaju, O. A. (2020). Optimising Production through Intelligent Manufacturing. *E3S Web of Conferences*, 152. <https://doi.org/10.1051/e3sconf/202015203012>
- Omisola, J. O., Shiyabola, J. O., & Osho, G. O. (2023). A KPI-Driven Decision Intelligence Model: Using Integrated Dashboards to Enhance Strategic Operational Control in Advanced Manufacturing. *Journal of Frontiers in Multidisciplinary Research*, 4(1), 93–103. <https://doi.org/10.54660/ijfmr.2023.4.1.93-103>
- Oyekanlu, E. A., Smith, A. C., Thomas, W. P., Mulroy, G., Hitesh, D., & Ramsey, M. (2020). A review of recent advances in automated guided vehicle technologies: Integration challenges and research areas for 5G-based smart manufacturing applications. W *IEEE Access* (T. 8, s. 202312–202353). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2020.3035729>
- Pang, Y., & Jia, S. (2018). Design of intelligent monitoring system for hazardous chemicals based on internet of things technology. *Chemical Engineering Transactions*, 71, 199–204. <https://doi.org/10.3303/CET1871034>
- Pantoja-Benavides, G., Giraldo, D., Montes, A., García, A., Rodríguez, C., Marín, C., & Álvarez-Martínez, D. (2024). Comprehensive Review of Robotized Freight Packing. W *Logistics* (T. 8, Numer 3). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/logistics8030069>
- Paul, C. (2024). *The Role of OPC-UA in Industrial Communication and Data Management*. <https://www.researchgate.net/publication/387503984>
- Pavel, M.-D., & Stamatescu, G. (2024). *Flexible Manufacturing System for Enhanced Industry 4.0 and Industry 5.0 Applications*. <https://doi.org/10.1109/DCOSS-IoT61029.2024.00077>
- Połomski, Z. (2016). *Zastosowanie systemów wizyjnych w kontroli procesu technologicznego na przykładzie etykietowania wyrobów* *The use of vision systems in technological process control on the example of product labeling*. <https://doi.org/10.17814/mechanik.2016.570>
- Pop, L. D. (2020). Digitalization of the system of data analysis and collection in an automotive company. *Procedia Manufacturing*, 46, 238–243. <https://doi.org/10.1016/j.promfg.2020.03.035>
- Popa, A., Hnatiuc, M., Paun, M., Geman, O., Hemanth, D. J., Dorcea, D., Son, L. H., & Ghita, S. (2019). An intelligent IoT-based food quality monitoring approach using low-cost sensors. *Symmetry*, 11(3). <https://doi.org/10.3390/sym11030374>
- Popescu, V. F., & Scarlat, C. (2022). Supervisory Control and Data Acquisition (SCADA) Systems for Industrial Automation and Control Systems in Industry 4.0. *Land Forces Academy Review*, 27(4), 309–315. <https://doi.org/10.2478/raft-2022-0039>
- Pyszka. (2015). *Istota Efektywności. Definicje I Wymiary*. Uniwersytet Ekonomiczny w Katowicach. <https://cejsh.icm.edu.pl/cejsh/element/bwmeta1.element.desklight-177c5f71-9957-453a-9f93-3d805a0510a5>.
- Qi, Q., & Tao, F. (2019). A Smart Manufacturing Service System Based on Edge Computing, Fog Computing, and Cloud Computing. *IEEE Access*, 7, 86769–86777. <https://doi.org/10.1109/ACCESS.2019.2923610>
- Qu, H. M., & Tao, X. S. (2013). Application of Internet of Things in Monitoring System of Intelligent Building. *Applied Materials and Technologies for Modern Manufacturing*, 423, 2832–2836. <https://doi.org/10.4028/www.scientific.net/AMM.423-426.2832>

- Rahman, M. A., Shahrior, M. F., Iqbal, K., & Abushaiba, A. (2025). *Enabling Intelligent Industrial Automation: A Review of Machine Learning Applications with Digital Twin and Edge AI Integration*. <https://doi.org/10.20944/preprints202506.2041.v1>
- Ramesh, K., Deshmukh, S., Ray, T., & Parimi, C. (2025). Enhancing manufacturing process accuracy: A multidisciplinary approach integrating computer vision, machine learning, and control systems. *Journal of Manufacturing Processes*, 142, 453–467. <https://doi.org/10.1016/j.jmapro.2025.03.112>
- Ramezani, R., Iranmanesh, S., Naeim, A., & Benharash, P. (2025). Editorial: Bench to bedside: AI and remote patient monitoring. W *Frontiers in Digital Health* (T. 7). Frontiers Media SA. <https://doi.org/10.3389/fdgth.2025.1584443>
- Rane, N. L., Kaya, Ö., & Rane, J. (2024). Artificial Intelligence, Machine Learning, and Deep Learning for Sustainable Industry 5.0. W *Artificial Intelligence, Machine Learning, and Deep Learning for Sustainable Industry 5.0*. Deep Science Publishing. <https://doi.org/10.70593/978-81-981271-8-1>
- Rezaei, S., Daeichian, A., Hedayati, A., & Karamali, A. H. (2025). 2025 Wind Power Forecasting with a Hybrid Deep Learning Approach including LSTM and Attention Mechanism POWER. *CONTROL AND DATA PROCESSING SYSTEMS*, 2(2), 2025. <https://doi.org/10.30511/pcdp.2025.2060381.1023>
- Riccetti, S. (2013). Designing Food Safety and Equipment Reliability Through Maintenance Engineering. W *Designing Food Safety and Equipment Reliability Through Maintenance Engineering*. <https://doi.org/10.1201/b15754>
- Rohée, B., & Riera, B. (2009). Advanced supervisory control for manufacturing systems: from concepts to a separated monitoring system. *International Journal of Intelligent Systems Technologies and Applications*, 6(3–4), 381–401. <https://doi.org/10.1504/IJISTA.2009.024266>
- Roslan, S. N., Abdullah, B., Saad, H., Hassan, R., & Alias, S. K. (2024). PROCESS SIMULATOR FOR MANUAL HANDLING PESTICIDE PACKAGING ASSEMBLY LINE. *Malaysian Journal of Computing*, 9(2), 1867–1878. <https://doi.org/10.24191/mjoc.v9i2.26549>
- Ruben, R., & Verhagen, J. (2019). *Towards Sustainable Global Food Systems: Conceptual and Policy Analysis of Agriculture, Food and Environment Linkages*. www.mdpi.com/journal/sustainability
- Ruchi Patel. (2023). Optimizing Communication Protocols in Industrial IoT Edge Networks: A Review of State-of-the-Art Techniques. *International Journal of Advanced Research in Science, Communication and Technology*, 503–514. <https://doi.org/10.48175/ijarsct-11979b>
- Rymarczyk, T., Król, K., Zawadzki, A., Oleszek, M., & Kłosowski, G. (2021). An intelligent sensor platform with an open architecture for monitoring and controlling cyber-physical. *Przegląd Elektrotechniczny*, 97(3), 141–145. <https://doi.org/10.15199/48.2021.03.27>
- Sai Avvaru, V., Bruno, G., Chiabert, P., & Traini, E. (2020). *Integration of PLM, MES and ERP Systems to Optimize the Engineering, Production and Business*. 70–82. https://doi.org/10.1007/978-3-030-62807-9_7i
- Sajin, Devaraj, A., Kurian, S., & George, J. (2025). *Efficiency Improvement of Glass Bottle Filler Machine Using Autonomous Maintenance-A Case Study*.
- Salunke SB, Wasmate DN, & Bawage SB. (2022). AUTOMATION IN PHARMACEUTICAL INDUSTRY. *Certified Journal | Salunke et al. World Journal of Pharmaceutical Research*, 11, 1864. <https://doi.org/10.20959/wjpr20223-23191>

- Sani, M. S., & Aziz, F. A. (2013). Advanced manufacturing systems in food processing and packaging industry. *IOP Conference Series: Materials Science and Engineering*, 46(1). <https://doi.org/10.1088/1757-899X/46/1/012042>
- Seifi, M. R., Alimardani, R., Mohtasebi, S. S., Mobli, H., & Firouz, M. S. (2023b). A Supervisory Control System for Automation of Horizontal Form-Fill-Seal Packaging Plant Based on Modified Atmosphere Technology. *Acta Mechanica et Automatica*, 17(3), 423–434. <https://doi.org/10.2478/ama-2023-0049>
- Shafi, I., Mazhar, M. F., Fatima, A., Alvarez, R. M., Miró, Y., Espinosa, J. C. M., & Ashraf, I. (2023). Deep Learning-Based Real Time Defect Detection for Optimization of Aircraft Manufacturing and Control Performance. *Drones*, 7(1). <https://doi.org/10.3390/drones7010031>
- Shrivastava, G., & Bindewari, S. (2025). *PLC Programming for Industrial Automation: A Beginner's Guide*. <https://www.researchgate.net/publication/394073623>
- Sifiso Phenyane, S. (2023). *Designing an AI-based Predictive Maintenance Framework to Improve OEE for an Automotive Manufacturer in South Africa*.
- Singh, J., Singh, A., Singh, H., & Doyon-Poulin, P. (2024). Implementation and evaluation of a smart machine monitoring system under industry 4.0 concept. *Journal of Industrial Information Integration*, 43, 100746.
- Soon, J. M., & Abdul Wahab, I. R. (2021). Global food recalls and alerts associated with labelling errors and its contributory factors. W *Trends in Food Science and Technology* (T. 118, s. 791–798). Elsevier Ltd. <https://doi.org/10.1016/j.tifs.2021.11.001>
- Stall. (2025). Embracing Industry 5.0: human-centric design of IIoT enabled digital twins in the printing industry. *Scientific Papers of Silesian University of Technology Organization and Management Series*, 2025(223). <https://doi.org/10.29119/1641-3466.2025.223.32>
- Sundar, P. S., Chowdhury, C., & Kamarthi, S. (2024). Industrial Internet of Things Enabled Kata Methodology of Assembly Line Productivity Improvement: Insights from a Case Study. *Processes*, 12(11). <https://doi.org/10.3390/pr12112611>
- Sundaram, S., & Zeid, A. (2023). Artificial Intelligence-Based Smart Quality Inspection for Manufacturing. *Micromachines*, 14(3). <https://doi.org/10.3390/mi14030570>
- Sverko, M., Grbac, T. G., & Mikuc, M. (2022). SCADA Systems With Focus on Continuous Manufacturing and Steel Industry: A Survey on Architectures, Standards, Challenges and Industry 5.0. *IEEE Access*, 10, 109395–109430. <https://doi.org/10.1109/ACCESS.2022.3211288>
- Szmitka S. (2015). *Analiza Swot Jako Narzędzie Oceny Innowacyjności Przedsięwzięcia Biznesowego. Wyższa Szkoła Informatyki i Ekonomii TWP, Olsztyn*.
- Thirupathi Vasuki, M., Kadirvel, V., & Pejavara Narayana, G. (2023). Smart packaging—An overview of concepts and applications in various food industries. W *Food Bioengineering* (T. 2, Numer 1, s. 25–41). John Wiley and Sons Inc. <https://doi.org/10.1002/fbe2.12038>
- Thoben, K. D., Wiesner, S. A., & Wuest, T. (2017). “Industrie 4.0” and smart manufacturing-a review of research issues and application examples. W *International Journal of Automation Technology* (T. 11, Numer 1, s. 4–16). Fuji Technology Press. <https://doi.org/10.20965/ijat.2017.p0004>
- Trzmiel, G., Łopatka, M., & Kurz, D. (2018). The use of the SCADA system in the monitoring and control of the performance of an autonomous hybrid power supply system using renewable energy sources. *E3S Web of Conferences*, 44. <https://doi.org/10.1051/e3sconf/20184400180>

- Turner, C., Oyekan, J., Garn, W., Duggan, C., & Abdou, K. (2022). Industry 5.0 and the Circular Economy: Utilizing LCA with Intelligent Products. *Sustainability (Switzerland)*, 14(22). <https://doi.org/10.3390/su142214847>
- Ucar, A., Karakose, M., & Kırımça, N. (2024). Artificial Intelligence for Predictive Maintenance Applications: Key Components, Trustworthiness, and Future Trends. W *Applied Sciences (Switzerland)* (T. 14, Numer 2). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/app14020898>
- Vaclavova, A., Strelec, P., Horak, T., Kebisek, M., Tanuska, P., & Huraj, L. (2022). Proposal for an iiot device solution according to industry 4.0 concept. *Sensors*, 22(1). <https://doi.org/10.3390/s22010325>
- Van der Pas, M., Dijkman, R., Akçay, A., Adan, I., & Walker, J. (2025). *A Reference Model and Patterns for Production Event Data Enrichment*. <http://arxiv.org/abs/2506.11502>
- Vijayakumar, A., Vairavasundaram, S., Koilraj, J. A. S., Rajappa, M., Kotecha, K., & Kulkarni, A. (2024). Real-time visual intelligence for defect detection in pharmaceutical packaging. *Scientific Reports*, 14(1). <https://doi.org/10.1038/s41598-024-69701-z>
- Wang, G., Xiong, X., Ma, Y., & Xu, X. (2024). Application of a Digital Twin Model in the Packaging Process of the Panel Furniture Industry. *Forest Products Journal*, 74(1), 98–106. <https://doi.org/10.13073/FPJ-D-24-00001>
- Wei, S., Bai, Y., Xu, L., Mu, H., Liu, K., & Wang, X. (2020). Integration Framework of MES Toward Data Security Interoperation. *Lecture Notes in Business Information Processing*, 382 LNBIP, 41–52. https://doi.org/10.1007/978-3-030-49165-9_4
- Weichert, D., Link, P., Stoll, A., Rüping, S., Ihlenfeldt, S., & Wrobel, S. (2019). A review of machine learning for the optimization of production processes. *International Journal of Advanced Manufacturing Technology*, 104(5–8), 1889–1902. <https://doi.org/10.1007/s00170-019-03988-5>
- Windmann, A., Wittenberg, P., Schieseck, M., & Niggemann, O. (2024). *Artificial Intelligence in Industry 4.0: A Review of Integration Challenges for Industrial Systems*. <https://doi.org/10.1109/INDIN58382.2024.10774364>
- Xia, Y., Chen, J., Lu, X., Wang, C., & Xu, C. (2016). Big traffic data processing framework for intelligent monitoring and recording systems. *Neurocomputing*, 181, 139–146. <https://doi.org/10.1016/J.NEUCOM.2015.07.140>
- Xu, H., & Fan, G. (2020). *Design of Safety Production Supervision and Data Management System Based on Cloud Platform* (s. 584–591). https://doi.org/10.1007/978-3-030-25128-4_72
- Xu, Y., Qamsane, Y., Puchala, S., Januszczak, A., Tilbury, D., & Barton, K. (2024). A data-driven approach toward a machine- and system-level performance monitoring digital twin for production lines. *Computers in Industry*, 157–158, 104086. <https://doi.org/10.1016/j.compind.2024.104086>
- Yan, M. R., Hsieh, S., & Ricacho, N. (2022). Innovative Food Packaging, Food Quality and Safety, and Consumer Perspectives. W *Processes* (T. 10, Numer 4). MDPI. <https://doi.org/10.3390/pr10040747>
- Yang. (2024). *Industrial expert systems review: a comprehensive analysis of typical applications*. 2169–3536. <https://doi.org/10.1109/ACCESS.2024.3419047>

- Zhang, W., Bao, X., Hao, X., & Gen, M. (2025). Metaheuristics for multi-objective scheduling problems in industry 4.0 and 5.0: a state-of-the-arts survey. *Frontiers in Industrial Engineering*, 3. <https://doi.org/10.3389/fieng.2025.1540022>
- Zhong, R. Y., Xu, C., Chen, C., & Huang, G. Q. (2017). Big Data Analytics for Physical Internet-based intelligent manufacturing shop floors. *International Journal of Production Research*, 55(9), 2610–2621. <https://doi.org/10.1080/00207543.2015.1086037>
- Zhu, Y., & Yang, G. (2012). Design of coal mine ventilator intelligent monitoring system. *IET Conference Publications*, 2012, 853–855. <https://doi.org/10.1049/cp.2012.1109>