

mgr Janusz Zemła¹

Helvoet Polska Sp. z o.o.

WDROŻENIE SYSTEMU WIZYJNEGO OPARTEGO NA SZTUCZNEJ INTELIGENCJI W KONTROLI JAKOŚCI PRODUKTU – STUDIUM PRZYPADKU Z HELVOET POLSKA

IMPLEMENTATION OF AN ARTIFICIAL INTELLIGENCE-BASED VISION SYSTEM IN PRODUCT QUALITY CONTROL: A CASE STUDY OF HELVOET POLAND

Streszczenie

Celem rozdziału jest przedstawienie wyników wdrożenia systemu wizyjnego opartego na sztucznej inteligencji AI (ang. *AI-based vision* – system wizyjny oparty na sztucznej inteligencji) w kontroli jakości wyrobu wulkanizowanego w Helvoet Polska. We wstępie uzasadniono ekonomiczne i operacyjne przesłanki zmiany (koszty jakości, ograniczenia kontroli manualnej) oraz porównano klasyczne systemy regulowe z podejściem zintegrowanym z PLC (ang. *programmable logic controller* – programowalny sterownik logiczny). Następnie zaprezentowano kontekst procesu oraz metodykę studium przypadku z porównaniem przed-po w dwóch porównywalnych oknach czasowych. Rdzeń rozdziału obejmuje opis architektury (kamera-optyka-oświetlenie-PLC), przebieg wdrożenia (ROI, szkolenia, uruchomienie, walidacja) oraz wyniki, w tym spadek poziomu braków. Każdy z analizowanych okresów obejmował cztery

¹ e-mail: janusz.zemla@helvoet.nl

Zemła, J. (2026). Wdrożenie systemu wizyjnego opartego na sztucznej inteligencji w kontroli jakości produktu – studium przypadku z Helvoet Polska. W: A. Siedlecka, M. Pyra (red.), *AI 360°: innowacje i zastosowania sztucznej inteligencji w gospodarce, społeczeństwie i nauce* (s. 119-134). Biała Podlaska: Akademia Bialska im. Jana Pawła II. https://doi.org/10.29316/9788368103366_7

tygodnie produkcji, co pozwoliło na porównanie wyników w zbliżonych warunkach operacyjnych, jednak relatywnie krótki czas obserwacji stanowi ograniczenie badania. Dyskusja identyfikuje czynniki sukcesu (stabilne warunki optyczne, poziom kontroli) i obszary do poprawy (krawędzie 3D, próg adaptacyjny, diagnostyka zabrudzeń optyki). W zakończeniu omówiono ograniczenia (jedno gniazdo, jeden wyrób) i sformułowano implikacje dla skalowania rozwiązania.

Słowa kluczowe: AI-vision, kontrola jakości, wizja maszynowa, edge learning

Abstract

The aim of this chapter is to present the results of implementing an AI-based vision system in the quality control of a vulcanized product at Helvoet Poland. The introduction outlines the economic and operational rationale for the change (quality-related costs, limitations of manual inspection) and compares classical rule-based systems with an approach integrated with a PLC (programmable logic controller). The following section presents the process context and the case-study methodology, including a “before-after” comparison across two comparable time windows. The core of the article covers the system architecture (camera-optics-lighting-PLC), the implementation workflow (ROI, training, commissioning, validation), and the results, including a reduction in defect rates. The discussion identifies success factors (stable optical conditions, inspection coverage) and areas for improvement (3D edges, adaptive thresholding, optical contamination diagnostics). The conclusion addresses limitations (single station, single product) and formulates implications for scaling the solution.

Keywords: AI vision, quality control, machine vision, edge learning

Wstęp

Rosnąca złożoność wyrobów i skracające się cykle życia produktów windują koszty jakości CoQ (ang. *cost of quality* – łączny koszt jakości: prewencja, ocena oraz koszty niezgodności wewnętrznych i zewnętrznych), w szczególności koszty niezgodności wewnętrznej (braki, przeróbki) i zewnętrznej (reklamacje). CoQ obejmuje jednak nie tylko straty bezpośrednie, lecz także komponenty prewencji i oceny, które rosną nieliniowo wraz ze wzrostem wariantowości i złożoności portfolio. Kontrola manualna, choć elastyczna, jest podatna na zmęczenie, różnice percepcyjne i trudna do ścisłej standaryzacji przy subtelnych defektach powierzchniowych; typowy jest też dryf kryteriów akceptacji między zmianami i operatorami, co ujawniają badania MSA (ang. *measurement*

system analysis – analiza systemu pomiarowego) poprzez podwyższony udział %GRR (ang. *gage repeatability & reproducibility* – procentowy udział powtarzalności i odtwarzalności w całkowitej zmienności). W praktyce człowiek jako detektor manualny bywa wąskim gardłem stabilności jakości i źródłem zmienności decyzyjnej, a obciążenie poznawcze i monotonia pracy skutkują spadkiem czułości detekcji po kilku godzinach zmiany oraz wzrostem ryzyka błędów. Podejście to koresponduje z teorią ograniczeń, wskazującą na konieczność eliminacji wąskich gardeł w przepływie procesu (Goldratt, Cox, 2021). Dodatkowo, rosnące oczekiwania audytorów klienta oraz niezależnych audytorów zewnętrznych w zakresie śladu decyzyjnego i replikowalności oceny jakości stawiają pod znakiem zapytania skalowalność wyłącznie manualnych inspekcji w środowisku produkcji wielowariantowej. Coraz częściej to właśnie wymogi zgodności i śledzalności stają się katalizatorem inwestycji w automatyczną inspekcję, bo przejście z decyzji subiektywnych na mierzalne kryteria pozwala ograniczyć spory reklamacyjne i skracać cykl.

Klasyczne systemy wizyjne opierają się na ręcznie definiowanych cechach i progach. Są przewidywalne, lecz wrażliwe na zmiany oświetlenia, drobne odchylenia pozycjonowania, starzenie oprzyrządowania czy tolerancje materiałowe, przez co każda zmiana środowiska wymusza ręczny zwrot lub powrót i podnosi TCO (ang. *total cost of ownership* – całkowity koszt posiadania/utrzymania) oraz ryzyko błędów konfiguracyjnych. Systemy AI-vision (wizyjna kontrola jakości oparta na sztucznej inteligencji), w tym *edge learning* zastosowany w kamerze wykorzystywanej w Helvoet Polska, uczą się na przykładach OK/NOK (wyrób zgodny/niezgodny), co zwiększa odporność na naturalną zmienność procesu i umożliwia ponowne uczenie po pojawieniu się nowych wariantów defektów. W ostatnich latach rozwój przemysłowych systemów wizyjnych jest silnie powiązany z koncepcją *edge computing*, w której analiza obrazu realizowana jest bezpośrednio na urządzeniu pomiarowym lub w jego bezpośrednim otoczeniu. Takie podejście pozwala ograniczyć opóźnienia przetwarzania, zwiększyć niezawodność działania systemu oraz ułatwia integrację z systemami sterowania produkcją. Rozwiązania edge-AI są obecnie szeroko stosowane w architekturach Industry 4.0, szczególnie w obszarze automatycznej kontroli jakości i monitorowania procesów produkcyjnych (Shi i in., 2016; Lee i in., 2015).

Modele trenowane na reprezentatywnych próbkach lepiej absorbują zmienność, ale pozostają wrażliwe na dryf danych i niezbilansowanie klas; dlatego konieczne jest budowanie przekrojowych zbiorów walidacyjnych w czasie oraz stały monitoring. Zastosowane podejście do trenowania modeli edge wpisuje się w fundamenty współczesnego uczenia głębokiego, opartego na reprezentacjach hierarchicznych i odporności na zmienność danych (Goodfellow i in., 2016). W praktyce przemysłowej sprawdza się architektura hybrydowa: warstwa AI do klasyfikacji złożonych wzorców co minimalizuje ryzyko fałszywie ujemnych decyzji na obszarach bezpieczeństwa i funkcjonalności. Z perspektywy sterowania procesem kluczowa jest integracja z PLC (ang. *programmable logic controller* – programowalny sterownik linii/maszyny): sygnały OK/NOK, triggery, blokady bezpieczeństwa oraz reakcji międzystanowiskowych. Równolegle konieczne jest logowanie metadanych (czas, ID stanowiska, wynik), co zapewnia audytowalność i umożliwia analizy przyczynowe. Integrację warto uzupełnić mechanizmami *fail-safe* (bezpieczne zachowanie przy błędzie, np. domyślne odrzucenie) i kontrolowaną degradacją do logiki regulowej, gdy pewność klasyfikacji spada poniżej ustalonego progu zaufania. Logowane metadane muszą spełniać wymagania *traceability* (identyfikowalności decyzji i partii) i bezpieczeństwa informacji; ich systematyczna analiza SPC (ang. *statistical process control* – statystyczne sterowanie procesem) powinna zasilać cykle 8D (ośmiostopniowe rozwiązywanie problemów)/PDCA (ang. *plan-do-check-act* – cykl doskonalenia) oraz standaryzację pracy.

Praktyczne wdrożenia wymagają jasnych CTQ, stabilnych warunków optycznych (kamera-optyka-oświetlenie), procedur etykietowania danych, polityki wersjonowania modeli oraz zdefiniowanej roli właściciela modelu. Warunkiem skalowalności jest konsekwentna kontrola środowiska optycznego (kalibracja ekspozycji, czystość optyki, stabilizacja pozycjonowania), ponieważ każdy regres w tych obszarach bezpośrednio obniża jakość inferencji. Dodatkowo rekomenduje się okresowe „re-kwalifikacje” modelu (np. kwartalne) na zestawie złotych próbek i świeżych danych produkcyjnych, pracę w trybie *shadow-mode* (równoległa praca modelu bez wpływu na decyzje) przed wdrożeniem nowej wersji oraz formalny *change control* (kontrolę zmian) obejmujący warstwy IT (technologia informacyjna – środki i procedury przetwarzania oraz przechowywania informacji) i OT (ang. *operational technology*

– technologia operacyjna sterująca maszynami i procesami), wraz z procedurą *rollback* (powrotu do poprzedniej wersji) i kopiami zapasowymi.

Mechanizmy adaptacyjnego dostrajania progów decyzyjnych oraz iteracyjne usprawnianie działania klasyfikatora wpisują się w logikę uczenia ze wzmocnieniem, opartego na ciągłym reagowaniu na informację zwrotną z procesu (Sutton, Barto, 2018). Z perspektywy finansowej, uzasadnienie biznesowe powinno łączyć redukcję scrapu i FR (ang. *false reject* – fałszywe odrzucenia wyrobów dobrych) z kosztami reklamacji i przestojów, a także uwzględniać efekt uczenia organizacyjnego (krótszy rozruch po przebrojeniach i szybsza reakcja na odchylenia). Integracja systemu AI-vision z mechanizmami *fail-safe* i kontrolą wersji odzwierciedla współczesne podejście do bezpiecznej sztucznej inteligencji, akcentujące potrzebę nadzoru i przewidywalności działania modeli (Russell, 2019). Wreszcie, skuteczność rozwiązania jest tak samo techniczna, jak organizacyjna: niezbędne są szkolenia operatorów i UR (Utrzymania Ruchu – służb odpowiedzialnych za dostępność i niezawodność parku maszynowego), jasne role w modelu „*human-in-the-loop*” (zatwierdzanie przypadków granicznych) oraz polityka etyczna i prawna przetwarzania obrazów (retencja, dostęp, zgodność z wymaganiami klienta i regulacjami).


Kontekst Helvoet i metodyka badania własnego

Firma Helvoet wytwarza precyzyjne komponenty polimerowe i elastomerowe dla branż o wysokich wymaganiach jakościowych, w tym OEM (ang. *original equipment manufacturer* – producenci wyrobów finalnych). Analizowane gniazdo dotyczyło detalu formowanego wtryskowo z krytycznymi powierzchniami funkcyjnymi; typowe wady: zadziór, niedolew, wtrącenia, mikropęknięcia, przebarwienia. W portfolio Helvoet znajdują się m.in. uszczelnienia, elementy prowadzące, gniazda zaworowe i precyzyjne wkładki dla automotive oraz komponenty o podwyższonej czystości dla sektorów medycznego i technologicznego, co implikuje wysokie wymagania co do stabilności barwy, geometrii i chropowatości powierzchni.

Specyfika materiałowa (np. elastomery napełniane, mieszanki o zróżnicowanej reologii) sprzyja subtelnym artefaktom powierzchniowym, których detekcja bywa trudna dla ludzkiego oka przy zmiennej iluminacji i różnicach połysku. Zastosowane podejście do akwizycji i przetwarzania obrazu odpowiada

klasycznym zasadom komputerowego rozpoznawania wzorców, obejmującym stabilizację oświetlenia, geometrii i jakości sygnału wejściowego (Chmielewski, Trawiński, 2004). Dodatkowym wyzwaniem jest wrażliwość niektórych gatunków tworzyw na starzenie termiczne i ślady demontażu, co podnosi ryzyko defektów późnych. Wymagania klientów w zakresie PPM (ang. *parts per million* – liczba niezgodności na milion sztuk) i *traceability* (identyfikowalność partii i decyzji) powodują, że kontrola musi identyfikować wady rzędu minimum dziesiątek mikrometrów, a więc na granicy percepcji manualnej. W takich warunkach klasy kontrolne muszą być jednoznaczne OK/NOK (zgodny/niezgodny) lub *rework* (do poprawy), a reguły decyzji odtwarzalne niezależnie od zmiany i obciążenia poznawczego operatora.

Z perspektywy SPC (ang. *statistical process control* – statystyczne sterowanie procesem) krytyczne jest szybkie sprzężenie zwrotne do parametrów procesu (temperatury, ciśnienia, czasu docisku), aby minimalizować długość serii wadliwej po wystąpieniu dryfu procesu. Do czasu wdrożenia systemu wizyjnego (ang. *AI-based vision* – system wizyjny oparty na sztucznej inteligencji) kontrola jakości była realizowana manualnie przez operatorów, wsparta wzorcami referencyjnymi i instrukcjami obrazkowymi lub filmowymi nagrywanymi i tworzonymi przez inżynierów procesu. Weryfikacja odbywała się na dedykowanym przyrządzie z wielogniazdową płytą odkładczą; operator układał detale, oceniał geometrię i czystość powierzchni przy świetle stanowiskowym, po czym zamykał pokrywę dociskową stabilizującą pozycję elementów na czas dalszych operacji. Rozwiązanie, choć elastyczne, generowało zmienność oceny między zmianami i nie tworzyło cyfrowego śladu decyzyjnego (Rysunek 1).




Rysunek 1. Przyrząd do manualnej kontroli wizualnej detali przed zamknięciem pokrywy stanowiska, kontrolnego

Źródło: opracowanie własne (Helvoet Polska).

Audyty MSA (ang. *measurement system analysis* – analiza systemu pomiarowego) wykazywały istotny udział % GRR (ang. *gage repeatability & reproducibility* – procentowy wkład powtarzalności i odtwarzalności) w całkowitej zmienności dla cech wizualnych, a wskaźniki zgodności międzyoceniającej spadały wraz z upływem czasu zmiany. W praktyce prowadziło to do fluktuacji FR (ang. *false reject* – fałszywy odrzut wyrobu dobrego) oraz incydentalnych przepuści FA (ang. *false accept* – fałszywa akceptacja wyrobu wadliwego), co generowało zarówno straty jakości, jak i koszty nadkontroli.

Z kolei na Rysunku 2 przedstawiono trend spadku wskaźnika braków produkcyjnych (scrapu) w ujęciu tygodniowym. Zaznaczony punkt między tygodniem 25 a 30 wskazuje moment wdrożenia systemu wizyjnego Cognex In-Sight 8900 Series, który stanowił kluczowy element modernizacji procesu kontroli jakości. Od momentu implementacji zauważalny jest kilkuprocentowy spadek odsetka złomowanych sztuk, będący efektem znacznie dokładniejszego wykrywania defektów przez nowy system AI-vision.



Rysunek 2. Zmiana poziomu braków produkcyjnych przed i po wdrożeniu systemu AI-vision

Źródło: opracowanie własne na podstawie danych produkcyjnych Helvoet Polska.

Zastosowano studium przypadku z porównaniem przed-po, obejmujące dwa porównywalne czterotygodniowe okresy: fazę bazową (przed wdrożeniem) oraz fazę po stabilizacji ustawień systemu AI-vision. Zbiór danych obejmował łącznie 1240 obrazów detali produkcyjnych, w tym próbki wyrobów zgodnych (OK) oraz niezgodnych (NOK). Dane pochodziły z procesu produkcyjnego realizowanego w analizowanym gnieździe kontrolnym. W analizie uwzględniono 620 detali poddanych inspekcji w okresie przed wdrożeniem oraz 620 detali po wdrożeniu systemu AI-vision.

W drugiej fazie wykorzystano kamerę Cognex In-Sight 8900 Series do automatycznej inspekcji wizualnej (Cognex Corporation, 2023), umożliwiającej detekcję niezgodności na poziomie mikroszczegółów oraz natychmiastowe reagowanie na odchylenia procesowe. W efekcie wdrożenia uzyskano nie tylko redukcję scrapu, ale również spadek wskaźnika *false reject* (FR) po kalibracji optyki i ponownym uczeniu modelu na przypadkach granicznych. Zmniejszenie liczby fałszywych odrzuceń pozwoliło na ograniczenie nadkontroli, stabilizację procesu i lepsze wykorzystanie mocy produkcyjnych, co potwierdza skuteczność integracji systemu wizyjnego z koncepcją zarządzania jakością w duchu *lean manufacturing*. Etykietowanie danych zostało przeprowadzone manualnie przez inżyniera jakości na podstawie obowiązujących kryteriów kontroli wizualnej oraz wzorców referencyjnych stosowanych w procesie produkcyjnym.

Każdy obraz został przypisany do jednej z klas: OK (wyrób zgodny) lub NOK (wyrób niezgodny). Model klasyfikacyjny został wytrenowany z wykorzystaniem funkcji Edge Learning dostępnej w systemie Cognex In-Sight 8900 (Rysunek 3). Proces trenowania obejmował iteracyjne dodawanie przykładów OK/NOK oraz walidację wyników klasyfikacji. Parametry decyzyjne modelu zostały dostrojone poprzez kalibrację progu klasyfikacji (*confidence threshold*) oraz analizę przypadków granicznych.

In-Sight® 8900 Series **Reference Manual**



Rysunek 3. Kamera przemysłowa Cognex In-Sight 8900 zastosowana w systemie automatycznej kontroli jakości

Źródło: opracowanie własne (Helvoet Polska).

Stosowane mechanizmy klasyfikacji i walidacji modelu odpowiadają fundamentom rozpoznawania wzorców i uczenia maszynowego, obejmującym kontrolę jakości danych, separację zbiorów oraz analizę miar precyzji i czułości (Bishop, 2006). Kryterium gotowości do uruchomienia ustalono jako $F1$ (średnia harmoniczna precyzji i czułości) $\geq 0,95$ dla klas krytycznych oraz AUROC (ang. *area under ROC* – pole pod krzywą ROC) $\geq 0,98$ dla modelu binarnego OK/NOK. Proces uczenia modeli *edge* odwołuje się do fundamentalnych zasad działania sieci neuronowych, w których kluczową rolę odgrywa iteracyjne

kształtowanie reprezentacji poprzez propagację błędu (Nielsen, 2015). Dane treningowe podzielono na zbiory: 70% *train*, 15% *validation* i 15% *test*, co umożliwiło niezależną ocenę jakości klasyfikacji.

Architektura rozwiązania:

1. kamera przemysłowa z modulem *Edge Learning* (uczenie/inferencja na urządzeniu brzegowym) typ: In-Sight 8900,
2. optyka dobrana do wymaganej rozdzielczości przestrzennej i głębi ostrości,
3. kopułowe oświetlenie nad płytą maszynową eliminujące refleksy,
4. interfejs z PLC (*programmable logic controller* – sterownik linii/maszyny): cyfrowe I/O (wejścia/wyjścia) + kanał protokołu dla metadanych,
5. repozytorium obrazów i raportów klasyfikacji.

Integracja z PLC obejmowała sygnały OK/NOK, zatrzymania zabezpieczające (interlocki) oraz przekaz progu zaufania (*confidence threshold*) w celu warunkowego przekierowania sztuk do weryfikacji ręcznej (tryb kontroli zdegradowanej). Implementacja logiki sterującej oraz wymiana sygnałów OK/NOK między kamerą a sterownikiem odzwierciedlają fundamentalne zasady projektowania układów opartych na PLC (Broel-Plater, 2015). Pipeline danych rejestrował obrazy źródłowe, co spełnia wymagania *traceability*, tzn. zachowania obrazu, czyli fototeki zdjęć. Stabilność środowiska optycznego zapewniono dzięki kontrolowanej geometrii chwytu detali w formie pośredniej i ekranowaniu od światła zewnętrznego i okresowej kalibracji ekspozycji. Zbiór danych został oznaczony manualnie przez inżyniera jakości i operatorów procesu w klasach OK/NOK, na podstawie wzorców referencyjnych stosowanych w kontroli jakości. Na potrzeby UR (utrzymanie ruchu – służby odpowiedzialne za dostępność i niezawodność parku maszynowego) zdefiniowano rolę właściciela modelu oraz procedury ponownego uczenia po zmianach narzędziowych (np. po piaskowaniu formy). W warstwie zarządczej zastosowano kontrolę zmian i mechanizmy powrotu do wcześniejszej wersji, czyli tzw. Backupu programowego, jeśli obecna wersja uległaby uszkodzeniu.

Wynik badania własnego, czyli wdrożenie systemu wizyjnego opartego na AI na przykładzie Helvoet Polska

Badanie wskazuje, że implementacja systemu AI-vision w gnieździe kontroli końcowej przyniosła poprawę kluczowych metryk jakościowych, nie wpływając negatywnie na takt linii produkcyjnej. Istotność statystyczną różnicy poziomu braków przed i po wdrożeniu oceniono przy użyciu testu t-Studenta, przy poziomie istotności $p < 0,05$. W analizowanym okresie odnotowano spadek średniego poziomu braków (scrap), a na wykresie od momentu wdrożenia systemu widoczna jest 3% procentowa redukcja odsetka złomowanych sztuk, wynikająca z wyraźnie lepszego wykrywania defektów.

Z perspektywy analitycznej wskazuje to, że system AI-vision nie tylko pełni funkcję efektywnego narzędzia inspekcyjnego, ale również przyczynia się do obniżenia wariancji procesu, stabilizując go na wyższym poziomie dojrzałości operacyjnej. W konsekwencji organizacja przechodzi w bardziej ustrukturyzowany, oparty na danych model działania, w którym decyzje jakościowe są podejmowane z mniejszą podatnością na zmienność ludzkiej percepcji.

Wdrożenie systemu AI-vision wpisuje się w logikę ciągłego usprawniania na poziomie gemba, gdzie kluczowe jest eliminowanie źródeł strat bez nadmiernych kosztów i przy maksymalnym wykorzystywaniu wiedzy operacyjnej zespołów (Imai, 2018). Ponadto uzyskana redukcja poziomu scrapu sugeruje wystąpienie efektu synergii między automatyczną inspekcją a dotychczas stosowanymi procedurami jakościowymi. W ujęciu strategicznym wdrożenie to wpisuje się w koncepcję inteligentnych operacji, w ramach której linia produkcyjna ewoluuje z funkcji reaktywnej do roli proaktywnej, predykcyjnej i wspieranej rozwiązaniami cyfrowymi (Tabela 1).

Tabela 1. Metryki klasyfikacji systemu AI-vision

Metryka	Wartość
Precision	0.96
Recall	0.94
F1-score	0.95

Źródło: opracowanie własne (Helvoet Polska).

Wyniki wskazują na wysoką skuteczność klasyfikacji systemu AI-vision w identyfikacji defektów produkcyjnych. Z perspektywy biznesowej polepszyła

się również efektywność. Dodatkową wartością okazała się audytowalność: repozytorium obrazów i metadanych usprawniło analizy PDCA i przyspieszyło domykanie działań korygujących. Wymagania dotyczące jakości danych uczących oraz standaryzacji procesu etykietowania są spójne z praktykami inżynierii uczenia maszynowego, w których kluczową rolę odgrywa kontrola zmienności i budowa stabilnego środowiska danych (Géron, 2019). Jednocześnie potwierdzono ograniczenia: pojedyncze gniazdo i jeden typ wyrobu w fazie badania, konieczność utrzymania dyscypliny danych (etykietowanie, re-kwalifikacje modeli) oraz wrażliwość na degradację środowiska optycznego. Całościowo, wyniki wskazują, że przy spełnieniu wymogów CTQ i *governance* modelu, AI-vision stanowi realną dźwignię poprawy jakości i stabilności procesu w warunkach produkcji wielowariantowej.

Wdrożenie zrealizowano we współpracy z dostawcą, firmą Cognex. Partner najpierw przeprowadził audyt aplikacyjny gniazda (produkt/proces), następnie przygotował demonstrację koncepcji POC (ang. *proof-of-concept* – demonstracja wykonalności i wartości rozwiązania) i uruchomił miesięczny pilotaż na wybranym stanowisku Helvoet oraz na bezpośredniej maszynie wtryskowej. Zakres prac obejmował dobór i kalibrację kamery/optyki/oświetlenia, integrację z PLC (ang. *programmable logic controller* – sterownik maszyny/linii) poprzez cyfrowe I/O (ang. *inputs/outputs* – wejścia/wyjścia sygnałowe) oraz kanał do przekazywania metadanych, przygotowanie zbiorów referencyjnych OK/NOK (zgodny/niezgodny), wstępne trenowanie modeli edge (ang. *edge learning* – uczenie/inferencja na urządzeniu brzegowym) oraz parametryzację progów decyzyjnych i sygnałów bezpieczeństwa. Koordynacja wdrożenia, obejmująca integrację systemu, testy, walidację oraz kontrolę wersji, odpowiada dobrym praktykom zarządzania projektami IT (Wodecki, 2014).

Równolegle firma Cognex przeprowadziła szkolenia dla operatorów, inżynierów procesu oraz automatyków utrzymania ruchu, a także przekazała dane dotyczące akwizycji obrazu, etykietowania danych (OK/NOK), uruchamiania i dogrywania modeli interpretacji metryk oraz podstawowego utrzymania czyli czyszczenie optyki, kontrola ekspozycji na dane wejścia i wyjścia PLC. Wdrożenie systemu AI-vision posiada także charakter minimalnego aczkolwiek planowanego wdrożenia projektu informatycznego przy wykorzystania AI czyli wymagającego planowania, kontroli zmian oraz koordynacji zasobów zgodnie z zasadami zarządzania projektami IT (Głodziński i in., 2025).

Operacyjnie zestrojono ekspozycję i balans oświetlenia, ustandaryzowano pozycjonowanie detalu oraz dodano check-listy optyczne do instrukcji pracy. Od strony mechanicznej, czyli utrzymania ruchu, tzw. przepływ decyzyjny funkcjonuje jako deterministyczny łańcuch: trigger z PLC (wyzwolenie) → akwizycja obrazu → inferencja edge (wnioskowanie na kamerze) → decyzja OK/NOK → akcja PLC (wypchnięcie NOK, alarm, ewentualny bezpieczny stop). Testy na partiach z kontrolowanymi defektami potwierdziły wymaganą czułość przy jednoczesnej redukcji FR (ang. *false reject* – fałszywy odrzut wyrobu dobrego). Integracja systemu wizyjnego z układem sterowania oraz synchronizacja akwizycji obrazu z ruchem maszyny odzwierciedlają podstawowe zasady automatyki i robotyki przemysłowej (Zdanowicz, 2017).

W ujęciu biznesowym odnotowano spadek scrapu, mniej reklamacji oraz krótszy rozruch serii oraz, co istotne, pozytywne wyniki 4-tygodniowego pilotażu przełożyły się na decyzję zakupową na kontrolowanym produkcie odnotowano dodatkowo ~3 % redukcji scrapu względem inspekcji wyłącznie wzrokowej.

Docelowo za utrzymanie rozwiązania odpowiada wspólny zespół jakości i UR (konserwacja optyki, kalibracje), przy wsparciu dostawcy w formule II linii wsparcia (aktualizacje, konsultacje jakości danych). Po stronie Helvoet powołano rolę opiekuna dla danych/modelu w osobie inżyniera procesu oraz inżyniera automatyki w Helvoet odpowiedzialnych za przygotowanie zbiorów, walidację oraz kontrola zmian sztuk OK i NOK i możliwość powrotu do poprzedniej wersji przed publikacją kamery na maszynie.

Dyskusja i ograniczenia

Uzyskane wyniki wskazują na pozytywny wpływ wdrożenia systemu AI-vision na stabilność procesu kontroli jakości oraz na redukcję poziomu braków produkcyjnych. Automatyzacja inspekcji wizualnej umożliwiła bardziej powtarzalną ocenę jakości detali oraz ograniczenie zmienności wynikającej z czynnika ludzkiego. Zastosowanie systemu wizyjnego opartego na sztucznej inteligencji pozwoliło również na szybszą identyfikację defektów produkcyjnych oraz usprawnienie procesu podejmowania decyzji jakościowych w środowisku produkcyjnym.

Należy jednak uwzględnić ograniczenia przeprowadzonego badania. Analiza została wykonana dla jednego gniazda produkcyjnego oraz jednego typu wyrobu, co ogranicza możliwość bezpośredniej generalizacji uzyskanych wyników na inne procesy produkcyjne lub inne typy produktów. Różnice w charakterystyce materiałów, geometrii detali czy warunkach oświetleniowych mogą wpływać na skuteczność działania systemów wizyjnych i wymagają indywidualnego dostosowania konfiguracji oraz procesu uczenia modelu.

Dodatkowym ograniczeniem jest stosunkowo krótki okres obserwacji po wdrożeniu systemu. Analiza obejmowała ograniczony horyzont czasowy produkcji, co utrudnia pełną ocenę długoterminowej stabilności działania systemu oraz jego wpływu na zmienność procesu w dłuższej perspektywie. W przyszłych badaniach zasadne byłoby przeprowadzenie długookresowej analizy danych produkcyjnych, obejmującej większą liczbę partii produkcyjnych oraz różne warianty detali.

Kierunkiem dalszych prac może być również rozszerzenie wdrożenia systemu AI-vision na inne stanowiska produkcyjne oraz inne referencje produktowe, co pozwoliłoby na ocenę skalowalności rozwiązania w warunkach produkcji wielowariantowej. Dodatkowo warto rozważyć integrację danych z systemów wizyjnych z narzędziami analizy procesowej, takimi jak SPC (*statistical process control*), co mogłoby umożliwić jeszcze wcześniejsze wykrywanie odchyleń procesowych i dalsze doskonalenie systemu zarządzania jakością.

Wnioski

Po miesięcznym teście pilotażowym podjęto decyzję o zakupie systemu; wyniki pozytywnie zaskoczyły dla kontrolowanego wyrobu odnotowano spadek scrapu (odsetek braków) o 3%. względem kontroli wzrokowej. Czas cyklu gniazda nie uległ pogorszeniu latencja inferencji *edge* (czas wnioskowania na urządzeniu brzegowym) pozostawała poniżej taktu. Zmienność międzypartyjna zmalała, co przełożyło się na stabilność planu i mniejszą liczbę problemów jakościowych. Realizowane działania wpisują się w nowoczesne podejście do zarządzania jakością, akcentujące rolę danych, stabilności procesów oraz systemowego monitorowania odchyleń (Borys, 2009). Dodatkowo odnotowano spójniejszy rozruch po starcie maszyny.

Wpływ na kulturę operacyjną był istotny. Kryteria akceptacji wsparte danymi z repozytorium zwiększyły zaufanie do systemu i przyspieszyły podejmowanie decyzji o reakcji procesowej (np. korekta parametrów wtrysku gumy). Transformacja procesu kontroli jakości jest spójna z zasadami organizacji uczącej się, w której stabilność, transparentność i odpowiedzialność zespołów stanowią fundament ciągłego doskonalenia (Blikle, 2014).

AI-vision (ang. *artificial intelligence vision* – system wizyjny oparty na sztucznej inteligencji), przy spełnieniu warunków optycznych i dyscyplinie danych stanowi dźwignię poprawy jakości i stabilności procesu. Integracja z PLC (ang. *programmable logic controller* – programowalny sterownik logiczny) domyka pętlę sterowania w czasie rzeczywistym, a repozytorium obrazów/metryk umożliwia audyt i organizacyjne uczenie się. Rekomenduje się kontrolowane skalowanie rozwiązania na pokrewne produkty wytwarzane na tej samej maszynie: dla każdej nowej referencji/produktu przeprowadzić kwalifikację optyki/oświetlenia, przygotować zestaw „golden sample”, wykonać MSA (ang. *measurement system analysis* – analiza systemu pomiarowego) klasyfikatora, ustalić progi dopuszczenia (*confidence*) oraz włączyć referencję do planu kalibracji i re-treningu. Kierunek jest korzystny strategicznie dla Helvoet: ogranicza złom (*scrap*), stabilizuje jakość przy rosnącej wariantowości i wzmacnia pozycję kosztową oraz reputacyjną w łańcuchu dostaw. Ograniczeniem badania jest analiza jednego gniazda produkcyjnego oraz jednego typu wyrobu, co może ograniczać bezpośrednią generalizację wyników na inne procesy produkcyjne. Dodatkowym ograniczeniem badania jest stosunkowo krótki okres obserwacji procesu po wdrożeniu systemu, dlatego dalsze analizy powinny obejmować dłuższy horyzont czasowy produkcji.

Literatura

1. Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer. <https://doi.org/10.1007/978-0-387-45528-0>
2. Blikle, A. J. (2014). *Doktryna jakości. Rzecz o turkusowej samoorganizacji*. Onepress.
3. Borys, T. (2009). *Zarządzanie jakością. Teoria i praktyka*. PWE.
4. Broel-Plater, B. (2015). *Układy wykorzystujące sterowniki PLC*. Wydawnictwo Naukowe PWN.

5. Chmielewski, L., Trawiński, D. (2004). *Komputerowe przetwarzanie i rozpoznawanie obrazów*. Akademicka Oficyna Wydawnicza EXIT.
6. Cognex Corporation. (2023). *In-Sight 8900 Series Vision System – Technical Documentation*.
7. Géron, A. (2019). *Uczenie maszynowe z użyciem Scikit-Learn i TensorFlow* (wyd. 2). Helion.
8. Głodziński, E., Swacha, J., Woźniak, M. (2025). *Zarządzanie projektami informatycznymi*. Wydawnictwo Naukowe PWN.
9. Goldratt, E. M., Cox, J. (2021). *Cel I: Doskonałość w produkcji*. Mint Books.
10. Goodfellow, I., Bengio, Y., Courville, A. (2016). *Deep learning*. MIT Press. <https://doi.org/10.7551/mitpress/10243.001.0001>
11. Imai, M. (2018). *Gemba Kaizen: Zdroworozsądkowe, niskokosztowe podejście do zarządzania*. MT Biznes.
12. Lee, J., Bagheri, B., Kao, H.-A. (2015). A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*, 3, 18-23. <https://doi.org/10.1016/j.mfglet.2014.12.001>
13. Nielsen, M. (2015). *Neural networks and deep learning*. Determination Press.
14. Russell, S. (2019). *Human compatible: Artificial intelligence and the problem of control*. Viking.
15. Shi, W., Cao, J., Zhang, Q., Li, Y., Xu, L. (2016). Edge computing: vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637-646. <https://doi.org/10.1109/JIOT.2016.2579198>
16. Sutton, R. S., Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.
17. Wodecki, A. (2014). *Zarządzanie projektami informatycznymi: metodyki, narzędzia, przykłady*. Wydawnictwo Naukowe PWN.
18. Zdanowicz, R. (2017). *Podstawy robotyki*. Wydawnictwo Politechniki Śląskiej.