

Zautomatyzowana kontrola jakości wkładów ceramicznych za pomocą systemów wizyjnych i głębokich sieci neuronowych

Rafał Dębniak, Wiktor Łęczek, Jakub Wójcik

MV CENTER Systemy Wizyjne Sp. z o.o., Krakowska 50 Str., 32-083 Balice

Streszczenie: W artykule zaprezentowano modułowy, zautomatyzowany system inspekcji wkładów ceramicznych stosowanych w procesie filtracji spalin DPF i GPF. System integruje skanowanie 3D oparte na świetle strukturalnym oraz obrazowanie 2D z wykorzystaniem optyki telecentrycznej. Zastosowane hybrydowe algorytmy detekcji, łączące głębokie sieci neuronowe z klasycznymi metodami przetwarzania obrazu, umożliwiają identyfikację zamknięcia komórek wkładu ceramicznego oraz wad powierzchni. Przekształcenie chmur punktów do reprezentacji 2D pozwala na efektywne wykorzystanie konwolucyjnych sieci neuronowych, upraszcza proces oznaczania wad na obrazach oraz redukuje wymagania obliczeniowe. Przeprowadzone testy potwierdziły skuteczność detekcji przy zachowaniu krótkich czasów inspekcji, zgodnych z wymaganiami środowiska przemysłowego. Modułowa architektura oraz pełna automatyzacja procesu inspekcyjnego umożliwiają elastyczną adaptację systemu do zróżnicowanych linii produkcyjnych.

Słowa kluczowe: DPF, GPF, optyczna kontrola jakości, skanowanie 3D, emisja spalin, filtracja spalin

1. Wprowadzenie

W ostatnich latach obserwuje się dynamiczne zaostrzenie norm emisji spalin w sektorze motoryzacyjnym, wynikające z polityki klimatycznej oraz środowiskowej prowadzonej przez Unię Europejską. Kolejne etapy regulacji – od norm Euro 5 i Euro 6 po planowaną normę Euro 7 – nakładają na producentów pojazdów coraz bardziej restrykcyjne limity emisji cząstek stałych PM (ang. *Particulate Matter*) oraz liczby cząstek PN (ang. *Particle Number*), zarówno w silnikach wysokoprężnych, jak i benzynowych z bezpośrednim wtryskiem paliwa. W konsekwencji filtry cząstek stałych, takie jak DPF (ang. *Diesel Particulate Filter*) oraz GPF (ang. *Gasoline Particulate Filter*), stały się kluczowymi elementami układów oczyszczania spalin we współczesnych pojazdach.

Centralnym komponentem filtrów DPF/GPF jest ceramiczny wkład filtracyjny (monolit) o strukturze plastra miodu z naprzemiennie zaślepienymi kanałami, tzw. komórkami. Wady produkcyjne w postaci ubytków powierzchni zewnętrznych oraz wady zaślepień (niezamknięte komórki) mogą prowadzić do obniżenia efektywności filtracji.

Autor korespondujący:

Rafał Dębniak, rafal.debniak@mv-center.com

Artykuł recenzowany

nadesłany 24.11.2025 r., przyjęty do druku 04.03.2026 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 4.0 Int.

Rosnące wymagania legislacyjne oraz presja rynkowa wymuszają znaczące zwiększenie poziomu kontroli jakości wkładów ceramicznych już na etapie produkcji. Tradycyjne metody kontroli, oparte na inspekcji wizualnej, wrywkowych badaniach niszczących lub pomiarach parametrów przepływowych, okazują się niewystarczające w warunkach produkcji wielkoseryjnej, gdzie kluczowe znaczenie ma powtarzalność, szybkość oraz pełna identyfikowalność komponentów.

W zautomatyzowanych procesach produkcyjnych szeroko stosowane są systemy wizyjne do kontroli produkcji. Najpowszechniej stosowanymi systemami są te oparte na obrazowaniu 2D za pomocą kamer matrycowych lub linijkowych. Jednak w przypadku konieczności zobrazowania całego modelu, w celu kontroli geometrii czy wykrycia wad o zadanej głębokości, dobrym podejściem będzie wykorzystanie obrazowania trójwymiarowego. W procesach produkcyjnych mogą być stosowane różne metody obrazowania 3D takie jak TOF (ang. *Time of Flight*), stereowizja, SFF (ang. *Shape from Focus*), triangulacja laserowa czy obrazowanie z użyciem światła strukturalnego [1, 2]. Wybór technologii zazwyczaj wynika z zapotrzebowania kontroli oraz wymagań procesu produkcji. Badania porównawcze technik digitalizacji pokazują, że skanowanie światłem strukturalnym gwarantuje dobry kompromis między dokładnością pomiaru a czasem akwizycji danych powierzchniowych [3].

Celem omawianego projektu było opracowanie zautomatyzowanego systemu inspekcyjnego przeznaczonego do automatycznej kontroli jakości wkładów ceramicznych stosowanych w samochodowych układach filtracji spalin typu DPF oraz GPF. W proponowanym systemie zastosowano metody przetwarzania obrazu, w tym algorytmy głębokiego uczenia (ang. *deep learning*), umożliwiające automatyczną detekcję wad niezależnie od geometrii oraz wymiarów analizowanych wkładów.

Do wizualizacji oraz analizy zidentyfikowanych wad wykorzystano techniki obrazowania 2D i 3D.

Zakres kontroli obejmuje wkłady o wymiarach od 70 mm × 70 mm × 50 mm do 250 mm × 250 mm × 400 mm. Inspekcji podlegają komórki filtracyjne i powierzchnie zewnętrzne: czołowe oraz boczne. Każda komórka jest kanałem, który zamknięty jest z jednej strony (kanały są nieprzelotowe). Kontrola polega na analizie stopnia zamknięcia każdej z komórek, gdzie za wadę uznaje się występowanie otworu przelotowego o zadanej minimalnej powierzchni, która wynosi 0,081 mm². W kontekście powierzchni zewnętrznych, defektem uznaje się występowanie ubytków, takich jak: dziury, pęknięcia lub lokalne zagłębienia przekraczające ustalone progi tolerancji. Mniejsze wady, nieprzekraczające tych progów, nie wpływają istotnie na skuteczność pracy filtra. W odniesieniu do ubytków powierzchniowych, progiem granicznym dla najbardziej krytycznych obszarów – powierzchni bocznych – jest defekt o powierzchni co najmniej 0,25 mm² i głębokości odpowiadającej grubości ścianki bocznej. Tego typu wady mają charakter przelotowy i prowadzą do nieszczelności wkładu.

Kluczowymi wymaganiami stawianymi przed systemem kontroli są wysoka skuteczność wykrywania wad ($\geq 98\%$) o zdefiniowanych powyżej wielkościach oraz możliwie krótki czas inspekcji, odpowiadający warunkom przemysłowym. Ze względu na dużą różnorodność typów wkładów ceramicznych dostępnych na rynku oraz różnice w procesach ich wytwarzania, system ma konstrukcję modułową. Dzięki temu możliwa jest adaptacja rozwiązania zarówno do pełnej inspekcji (zamknięcie komórek + powierzchnia), jak i do kontroli wyłącznie wybranych cech produktu. Modularność przekłada się również na elastyczne dostosowanie czasu cyklu do wymagań linii produkcyjnej.

2. Metody obrazowania i proces kontroli

Projektowane stanowisko inspekcyjne składa się z kilku modułów funkcjonalnych, z których każdy realizuje określony etap procesu kontroli jakości. W prezentowanej konfiguracji zastosowano układ pełny, zawierający wszystkie dostępne moduły kontrolne. Kompletny model stanowiska wraz z rozmieszczeniem poszczególnych modułów przedstawiono na rys. 1

Proces inspekcji rozpoczyna się, gdy wkład ceramiczny dotrze na transporter do modułu wejściowego. Moduł ten pełni dwie funkcje: stanowi pierwsze stanowisko kontrolne oraz odpowiada za wyznaczenie pozycji wkładu na transporterze,


co umożliwia poprawne ustawienie chwytaka robota podczas operacji pobrania.

Pierwsza kontrola realizowana jest za pomocą skanera 3D wykorzystującego technologię światła strukturalnego. Skanowana jest powierzchnia górna nieruchomego detalu, a uzyskany wynik zapisywany jest w postaci chmury punktów. Przykład przedstawiono na rys. 2, gdzie ubytki na powierzchni oznaczono kolorem czerwonym, odpowiadającym najniższym wartościom współrzędnej Z. Następnie dane te są przekształcane do postaci obrazu 2D (projekcja ortogonalna), który poddawany jest analizie metodami głębokiego uczenia oraz klasycznych algorytmów przetwarzania obrazu. Szczegóły etapu przetwarzania chmury punktów oraz inspekcji na podstawie kontroli pobocznic przedstawiono w rozdziale 4.


Po zakończeniu inspekcji powierzchni czołowej detal przemieszcza się na transporterze pod kamerę 2D wyposażoną w klasyczną optykę oraz oświetlacz typu czołowego (ang. *front-light*). W oparciu o uprzednio uzyskane dane z inspekcji 3D, układ ten automatycznie reguluje swoją pozycję w osi Z względem powierzchni detalu w celu zapewnienia stałego dystansu roboczego (ang. *working distance*). W dalszej kolejności wykonywany jest obraz 2D, na podstawie którego wyznaczany jest układ współrzędnych wkładu oraz określana jest pozycja wkładu na transporterze w osiach X i Y oraz pozycja kątowa wzdłuż osi Z. Przykład wyznaczonego układu współrzędnych przedstawiono na rys. 3. Układ odniesienia dla tej analizy jest stały i zdefiniowany względem punktu głównego kamery, tj. punktu przecięcia osi optycznej z płaszczyzną obrazu. Informacje o położeniu detalu w przestrzeni (X, Y, Z) są następnie przekazywane do robota odpowiedzialnego za pobranie detalu.

W zależności od wyniku inspekcji górnej powierzchni, detal kierowany jest przez robota na osobny transporter dla elementów niezgodnych (NG) lub przekazywany do kolejnego modułu kontroli 2D. W przypadku uznania detalu za zgodny, robot ustawia go współosiowo z osią optyczną modułu inspekcyjnego, składającego się z obiektywu telecentrycznego oraz oświetlacza telecentrycznego.

Na tym etapie wykonywana jest seria obrazów cyfrowych z kamery mająca na celu wykrycie nieprawidłowości takich jak nieprawidłowe zamknięcie komórek oraz uszkodzenia powierzchni czołowych (górnej i dolnej). W tym przypadku wykorzystano kamerę z sensorem o przekątnej 35 mm i rozdzielczości 7920 × 6004 pikseli. Przy zakładanym polu widzenia 260 mm dla krótszego boku matrycy uzyskujemy rozdzielczość rzędu ok. 0,0433 mm/px. Biorąc pod uwagę wadę o minimalnej powierzchni 0,081 mm² i zakładanym minimalnym boku wady




Rys. 1. Model stanowiska kontroli ze wszystkimi modułami
Fig. 1. Model of the inspection station with all modules



Rys. 2. Przykład chmury punktów powierzchni czołowej w reprezentacji kolorystycznej

Fig. 2. Example of a point cloud of the front surface in a color representation



Rys. 3. Obraz z kamery z wyznaczonym układem współrzędnych wkładu

Fig. 3. Camera image with the insert coordinate system determined

o długości 0,284 mm uzyskuje się reprezentację wady w postaci około 6 pikseli w każdej z osi. Taka liczba pikseli jest wystarczająca do obrazowania wady, gdyż przyjmuje się, że wystarczającą i poprawną reprezentacją są 2–4 piksele w każdej z osi.

W ten sposób realizowane jest sześć akwizycji obrazu, gdzie pięć kolejnych obrazów z wykorzystaniem oświetlenia telecentrycznego typu tylnego (ang. *backlight*), a jedno z oświetleniem typu czołowego. Pozycje inspekcyjne dla pięciu kolejnych obrazów, czyli pozycje wkładu względem obiektywu są automatycznie wyznaczane na podstawie geometrii oraz wysokości detalu uzyskanej na etapie modułu wejściowego. Przy każdym kolejnym ujęciu teoretyczna oś wkładu ustawiana jest pod pewnym kątem względem płaszczyzny obiektywu.

Analiza obrazów przeprowadzana jest dzięki połączeniu metod głębokiego uczenia oraz klasycznych technik przetwarzania obrazu, co pozwala na zwiększenie skuteczności detekcji przy zachowaniu wymagań czasowych dla przemysłowego cyklu produkcyjnego. Proces kontroli został opisany w rozdziale 3. Po zakończeniu całego procesu inspekcyjnego realizowanego przez moduł kontroli 2D, wynik inspekcji zostaje zapisany.

Kolejnym etapem procesu inspekcji jest transfer wkładu za pomocą robota do modułu kontroli 3D. W przypadku negatywnego wyniku weryfikacji w module 2D wkład zostaje natychmiast skierowany na transporter wyrobów niezgodnych (NG), co eliminuje potrzebę dalszej kontroli i skraca czas cyklu. Jeżeli wynik inspekcji w module 2D jest pozytywny, obiekt poddawany jest analizie w module 3D.

W module kontroli 3D stosowane są skanery światła strukturalnego, co w połączeniu z obrotowym stolikiem pomiarowym umożliwia uzyskanie pełnego zestawu danych przestrzennych dla wszystkich powierzchni wkładu, z wyłączeniem tej, która została skontrolowana w module wejściowym. Na podstawie uzyskanych chmur punktów przeprowadzana jest rekonstrukcja trójwymiarowa obiektu. Następnie dane 3D są przetwarzane do postaci obrazu 2D, optymalnego dla algorytmów detekcji defektów powierzchniowych. Szczegółowy opis metod detekcji zawarto w rozdziale 4.

W rozwiązaniu zastosowano układ czterech skanerów. Pole widzenia dla każdego skanera obejmowało wycinek o maksymalnych wymiarach ok. szerokość 300 mm × wysokość 220 mm × głębokość 100 mm. Każdy skaner jest wyposażony w kamerę

o rozdzielczości 2064 × 1544 (3,2 Mpx). Przy założonym polu widzenia rozdzielczość w osiach XY wynosi ok. 0,145 mm/px. Zakładając minimalny bok wady lub średnicę o długości 0,5 mm, odwzorowanie wynosi co najmniej 3 piksele w osiach X i Y. Dodatkowym parametrem dla skanerów 3D jest rozdzielczość w osi Z. Parametr ten informuje, jaką najmniejszą zmianę wysokości (różnicę w głębokości), skaner może wykryć między dwoma punktami. W przypadku dobrego rozwiązania wartość ta wynosi ok. 0,03 mm.


Po analizie wkład klasyfikowany jest jako zgodny (OK) lub niezgodny (NG). Moduł 3D wyposażony jest w zautomatyzowany układ transportujący z chwytakiem zamontowanym na przesuwach liniowych. Umożliwia on ruch w układzie kartezjańskim, kierując obiekt na odpowiedni transporter – NG w przypadku wykrycia defektów lub OK w przypadku potwierdzenia zgodności. Proces inspekcji w module 3D realizowany jest równolegle z bieżącą kontrolą kolejnych wkładów ceramicznych w module wejściowym oraz w module 2D, co zapewnia ciągłość pracy systemu i minimalizuje czas cyklu.


3. Kontrola zamknięcia komórek filtracyjnych

W przypadku kontroli zamknięcia komórek największym wyzwaniem jest prawidłowe zobrazowanie defektów zarówno w obszarze komórek centralnych, jak i brzegowych. Na widoczność wad wpływają m.in.: minimalny wymiar defektu podlegającego detekcji, proporcja wymiaru pojedynczej komórki do całkowitych gabarytów wkładu, budowa wkładu ceramicznego oraz nieregularny kształt komórek brzegowych. W kontekście budowy istotnym parametrem jest tolerancja kształtu – maksymalna odchyłka geometryczna między powierzchniami (warstwami) D1, D2 i D3 (rys. 4), która może wynosić do 2,5 mm.

W przypadku komórek brzegowych głównym wyzwaniem jest prawidłowe wykrycie i sklasyfikowanie wady, która ze względu na swój charakter może przyjmować różne kształty i charakteryzować się zmienną widocznością. W celu rozwiązania tych problemów zastosowano układ złożony z kamery monochromatycznej z optyką telecentryczną, co pozwoliło zniwelować problem perspektywy oraz zniekształcenie paralaksy [4, 5]. Jako oświetlenie użyto światło skolimowane typu tylnego, które zminimalizowało efekty rozproszenia światła na krawędziach i ścianach komórek oraz zwiększyło ilość światła docierającego bezpośrednio do obiektywu. Takie podejście umożliwiło prawidłowe zobrazowanie większości występujących wad. Jednak ze względu na tolerancję kształtu wkładu oraz specyfikę wad przy krawędziach, nie wszystkie defekty były widoczne na wykonanym obrazie. W celu prawidłowego zobrazowania wspomnianych defektów oraz zniwelowania wpływu geometrii wkładu zastosowano analizę kilku obrazów cyfrowych tego samego wkładu, ale z różnych ujęć. Wszystkie ujęcia obrazowały wkład ceramiczny ustawiony pod różnymi kątami (rys. 5) względem osi optycznej układu kamera – obiektyw – oświetlacz. Dla zmniejszenia czasu cyklu oraz zapewnienia dowolności pozycji wkładu dla kolejnych zdjęć, system kontroli bazuje na 6-osiowym robocie.

Rys. 4. Schematyczne przedstawienie warstw wkładu ceramicznego
Fig. 4. Schematic illustration of the layers in a ceramic insert






Rys. 5. Trzy obrazy przedstawiające ten sam wkład ustawiony pod różnymi kątami względem osi kamery; przykładowe wady zostały oznaczone czerwonym okręgiem

Fig. 5. Three images showing the same insert positioned at different angles relative to the camera axis; example defects are marked with a red circle

Kolejnym krokiem jest analiza obrazu. W tym przypadku na podstawie testów i analiz zdecydowano się na podejście hybrydowe, które łączyło uczenie maszynowe z podejściem klasycznym. W przypadku uczenia maszynowego zastosowano metodę głębokiego uczenia, opartą na wielowarstwowych sieciach neuronowych. W przypadku podejścia klasycznego zastosowano m.in. analizę obszarów typu BLOB (ang. *Binary Large Object*). Ze względu na brak powtarzalności cech wad, tj. wielkości, kształtów oraz jasności, głębokie uczenie pozwala na określenie obszarów, w których potencjalnie może występować wada. Na tej podstawie wykonywana jest klasyfikacja wad na pewne oraz prawdopodobne, gdzie algorytm klasyfikacyjny wykorzystuje tzw. wskaźniki pewności klasyfikacji (ang. *confidence scores*), które określane są na podstawie probabilistycznego rozkładu wygenerowanego przez model klasyfikacyjny sieci neuronowych. Empirycznie przyjęto wskaźnik pewności na poziomie 80 %. Poniżej tej wartości wada klasyfikowana jest jako prawdopodobna i podlega dalszej analizie obrazu.

Proces tworzenia modelu sieci neuronowej rozpoczął się od wyboru reprezentatywnych zdjęć referencyjnych, na których przeprowadzono ręczne oznaczanie wad. Model trenowany był iteracyjnie, przy czym każdy krok optymalizacji (iteracja) zwiększał dokładność klasyfikacji na zbiorze treningowym i walidacyjnym.

Kryterium zakończenia procesu uczenia było osiągnięcie dokładności walidacyjnej na poziomie co najmniej 99,9 %. Po spełnieniu tego warunku trening był automatycznie zatrzymywany, co miało na celu ograniczenie ryzyka przeuczenia (ang. *overfitting*). Na rys. 6 przedstawiono przykładowy wykres dokładność klasyfikacji modelu sieci neuronowej w funkcji liczby epok (iteracji) dla widocznych wad. Wyraźnie widoczna




Rys. 6. Wykres dokładności klasyfikacji modelu sieci neuronowej – wykrywanie wad typu „niezamknięta komórka filtracyjna”

Fig. 6. Classification accuracy chart of the neural network model – detection of “unclogged cell” defects


jest szybka konwergencja zarówno dokładności treningowej (linia niebieska), jak i walidacyjnej (linia pomarańczowa), co świadczy o skuteczności procesu uczenia oraz odpowiednio dobranym zbiorze danych.

Wynikiem przeprowadzonej analizy obrazu za pomocą głębokich sieci neuronowych jest tzw. mapa ciepła (ang. *heatmap*) (rys. 7). Mapę można interpretować jako narzędzie wizualizacyjne przedstawiające graficznie prawdopodobieństwo wykrycia wady w każdym pikselu zadanego regionu.



Rys. 7. Mapa ciepła wykrytych wad wraz z poziomem pewności detekcji, przedstawiona w skali RGB

Fig. 7. Heatmap of detected defects with detection confidence levels, shown in RGB scale



Rys. 8. Reprezentacja mapy ciepła w skali szarości

Fig. 8. Heatmap representation in grayscale

Dla uproszczenia przestrzennej reprezentacji aktywacji sieci, kolorowa mapa ciepła (RGB) została zredukowana do obrazu jednokanałowego w skali szarości na podstawie średniej ważonej wartości kanałów R, G i B. Uzyskany w ten sposób obraz pełni funkcję mapy pewności (ang. *confidence map*), gdzie jasność każdego piksela odzwierciedla poziom zgodności z daną klasą defektu. Przykład mapy w skali szarości przedstawia rys. 8.

Dzięki zastosowaniu sieci neuronowej oraz podejścia hybrydowego, wady niepoprawnie otwartych cel oznaczane były podczas testów ze skutecznością 99 %. Wynik ten jest pozytywny względem przyjętych początkowych założeń dla kontroli 2D, które określały skuteczność wykrywania wad na poziomie większym lub równym 98 %.

4. Kontrola wad powierzchni czołowych oraz bocznych

Ze względu na konieczność zapewnienia odpowiedniej skuteczności filtracji cząstek stałych, kontrola jakości wkładów ceramicznych obejmuje również ocenę stanu ich powierzchni bocznych (pobocznic), a także powierzchni czołowych. Uszkodzenia lub ubytki w obrębie tych powierzchni mogą istotnie obniżyć integralność strukturalną wkładu, prowadząc do nieszczelności i niespełnienia wymagań normatywnych dotyczących efektywności filtracji. Podczas konsultacji z producentami wkładów ceramicznych przyjęto minimalny ubytek, który należy oznaczyć jako wadę. Dla pobocznic przyjęto wadę o powierzchni $0,25 \text{ mm}^2$ i głębokości równej grubości ścianki zewnętrznej wkładu – otwór przelotowy. W przypadku powierzchni czołowych jest to wada o powierzchni równej wielkości jednej komórki i głębokości około $0,5 \text{ mm}$.

W wyniku przeprowadzonych testów, oraz biorąc pod uwagę konieczność kontroli wad, których gabaryty określone są w trzech osiach X, Y, Z, zastosowano skanowanie 3D. Skanery 3D światła strukturalnego stanowią narzędzie pomiarowe stosowane do rekonstrukcji geometrii powierzchni obiektów. Technologia ta polega na projekcji znanych wzorców świetlnych, takich jak pasma lub siatki na badaną powierzchnię. Deformacje tych wzorców, wynikające z topografii obiektu, są rejestrowane przez jedną lub więcej kamer, a następnie analizowane za pomocą triangulacji w celu uzyskania trójwymiarowego modelu powierzchni [6, 7].

Proces skanowania całego wkładu ceramicznego realizowany jest przy użyciu skalibrowanego systemu pomiarowego, składającego się z czterech skanerów 3D rozmieszczonych wokół zintegrowanego stołu obrotowego. Kalibracja układu wykonywana jest za pomocą dedykowanej płyty kalibracyjnej, która umożliwia zestrojenie lokalnych układów współrzędnych każdego z urządzeń w jeden wspólny, globalny układ odniesienia. Punkt odniesienia układu globalnego zdefiniowany jest centralnie, w obrębie płyty kalibracyjnej, co pozwala na spójną rekonstrukcję geometrii skanowanego obiektu niezależnie od pozycji względnej skanerów.


Założeniem systemu jest możliwość detekcji wad dla wkładów ceramicznych o dowolnym kształcie powierzchni bocznej. Takie podejście jest istotne ze względu na mnogość produkowanych wariantów, gdzie wkład może mieć kształt cylindra z poboczną w kształcie elipsy lub być cylindrem o całkowicie nieregularnej poboczniczy ze zmiennym promieniem wzdłuż osi podłużnej (rys. 9).

W wyniku przeprowadzonych analiz przyjęto, że optymalnym rozwiązaniem będzie kontrola pobocznic w postaci jej rozwinięcia. Takie podejście znacząco ułatwia przekształcenie chmury punktów w płaski 8-bitowy obraz 2D, który następnie jest analizowany za pomocą konwulucyjnych sieci neuronowych CNN (ang. *Convolutional Neural Network*). Powierzchnie czołowe nie wymagają takiego podejścia, gdyż są płaskie. Skan 3D wkładu cylindrycznego przedstawiono w dwóch przykładach na rys. 10, gdzie (a) jest wizualizacją górnej powierzchni wkładu w postaci chmury punktów XYZRGB, natomiast (b) to uproszczony model całego wkładu w formie walca. W przykładzie (a) kolory punktów odpowiadają wartościom współrzędnej Z (wysokości) zgodnie ze skalą barwną

przedstawioną na rysunku. Widoczne lokalne zmiany koloru (m.in. obszary zielone) wskazują na odchylenia wysokości względem powierzchni referencyjnej, które w dalszej analizie mogą być interpretowane jako potencjalne defekty. Przykład (b) przedstawia uproszczony model, w którym zastosowano podobną skalę barw do odwzorowania wartości współrzędnej Z dla całego wkładu.


W ramach projektu opracowano algorytm umożliwiający rozwinięcia powierzchni o dowolnym kształcie i jego konwersję na obraz, którego schemat blokowy przedstawiono na rys. 11. Po uzyskaniu zeskanowanego modelu 3D w postaci chmury punktów, wyznaczana jest pozycja detalu za pomocą filtracji punktów o najwyższych współrzędnych Z oraz wyznaczenia minimalnego okręgu opisującego wszystkie wyznaczone punkty. Wyznaczenie płaszczyzny odniesienia w tym wypadku płaszczyzny podstawy zostało zrealizowane z wykorzystaniem metody dopasowania płaszczyzny za pomocą M-estymatora. Technika ta minimalizuje wpływ punktów odstających, co pozwala na stabilne określenie orientacji płaszczyzny w chmurze punktów [8].

Kolejnym krokiem jest wyznaczenie krzywej zamkniętej, opisanej na obwodzie oraz wyznaczenie punktów krawędzi. Punkty te zostały wyznaczone na podstawie jednostkowych wektorów normalnych, obliczonych zgodnie z lokalną gęstością próbkowania wynikającą z rzeczywistej rozdzielczości skanera. Następnie analizowano zmiany kierunków tych wektorów w celu identyfikacji istotnych różnic w orientacji, charakterystycznych dla krawędzi geometrycznych. W celu otrzymania rozwinięcia płaszczyzny konieczna jest zmiana współrzędnych wszystkich punktów w otrzymanej chmurze




Rys. 9. Przykłady wkładów ceramicznych o zróżnicowanych kształtach

Fig. 9. Examples of ceramic inserts with various shapes



Rys. 10. Skan 3D wkładu ceramicznego uzyskany za pomocą skanera światła strukturalnego, gdzie: (a) wizualizacja chmury punktów górnej powierzchni, (b) uproszczony model całego wkładu

Fig. 10. 3D scan of a ceramic insert obtained using a structured light scanner, where: (a) point cloud visualization of the upper surface; (b) simplified cylindrical model of the entire insert



Rys. 11. Schemat blokowy algorytmu przekształcającego zeskanowany obraz 3D wkładu w obraz płaski


Fig. 11. Block diagram of the algorithm converting a scanned 3D image of the insert into a flat image

punktów. Zmiana obejmuje współrzędne X, Y, Z, które przekształcane są za pomocą zależności (1).

$$\begin{aligned}
 X &= \frac{\text{Res} \cdot \text{Alfa} \cdot \text{Liczba punktów na obwodzie}}{360} \\
 Y &= Z0 \\
 Z &= Li - Lr
 \end{aligned}
 \quad (1)$$


gdzie: X, Y, Z – współrzędne po przekształceniu; Res – rozdzielczość; Alfa – orientacja kątowa wektora normalnego względem środka; Z0 – współrzędna Z danego punktu w pierwotnej chmurze punktów; Li – odległość punktu idealnego od środka; Lr – odległość punktu rzeczywistego od środka.

W celu redukcji lokalnych fluktuacji i wygładzenia powierzchni reprezentowanej przez chmurę punktów, zastosowano filtrację przestrzenną opartą na rozmyciu Gaussowskim (ang. *Gaussian smoothing*). Operacja polega na aproksymacji powierzchni lokalnej za pomocą sąsiedztwa punktów, przy czym wpływ poszczególnych punktów ważony jest funkcją Gaussa, zależną od ich odległości od punktu centralnego. Efektem jest wygładzona (niemal płaska) powierzchnia w miejscach o niewielkiej krzywiźnie, przy jednoczesnym zachowaniu struktury geometrycznej obiektu [9–11]. Rozwi-



Rys. 12. Rozwinięcie poboczniczy wkładu ceramicznego w postaci chmury punktów XYZRGB po przetworzeniu przez algorytm

Fig. 12. Expansion of the ceramic insert sidewall represented as an XYZRGB point cloud after algorithm processing



Rys. 13. Fragment 8-bitowego obrazu przedstawiający widoczną wadę po przetworzeniu przez cały algorytm

Fig. 13. A fragment of an 8-bit image showing a visible defect after processing by the algorithm

nięcie poboczniczy wkładu ceramicznego w postaci chmury punktów XYZRGB po przetworzeniu przez algorytm przedstawiono na rys.12. Kolory punktów w skali RGB odpowiadają wartościom współrzędnej Z, co umożliwia wizualną analizę wysokości.

Otrzymana chmura punktów została przekształcona w obraz dwuwymiarowy za pomocą projekcji ortogonalnej. Współrzędne X i Y punktów w przestrzeni 3D zostały bezpośrednio odwzorowane na płaszczyznę obrazu, natomiast informacja o głębokości (Z) została przeskalowana i odwzorowana jako intensywność piksela w zakresie [0, 255], zgodnie z 8-bitową reprezentacją. Przed konwersją zastosowano również normalizację wartości głębokości. Tak przygotowany obraz (rys. 13) służy zarówno jako dane uczące podczas trenowania sieci neuronowej, jak i jako dane wejściowe podczas właściwej inspekcji. W procesie detekcji zastosowano podejście hybrydowe: w pierwszym etapie, z wykorzystaniem sieci głębokiego uczenia (ang. *Deep Learning*), wyznaczano potencjalne obszary występowania wad. W kolejnym kroku analizowano te fragmenty obrazu metodą analizy blobów, w wyniku której wyznaczano powierzchnię defektu w pikselach.

Na podstawie znanej rozdzielczości układu, wynik został przeliczony na jednostki rzeczywiste (mm²) przy użyciu (2). Jeżeli obliczona powierzchnia przekraczała ustaloną wartość progową, dany detal klasyfikowano jako wadliwy.

$$A_{\text{mm}^2} = N_{\text{px}} \cdot R_x \cdot R_y \quad (2)$$

gdzie: A_{mm^2} – powierzchnia, N_{px} – liczba pikseli należących do obszaru wady, R_x , R_y – fizyczne rozdzielczości obrazu w kierunku poziomym i pionowym (mm/piksel)

Przekształcenie danych 3D (np. chmury punktów) do postaci dwuwymiarowego obrazu przynosi istotne korzyści w kontekście zastosowań metod głębokiego uczenia, zwłaszcza opartych na konwolucyjnych sieciach neuronowych CNN (ang. *Convolutional Neural Networks*). Modele CNN zostały pierwotnie zaprojektowane do analizy obrazów 2D, dlatego technologia ta osiągnęła znacznie wyższy poziom dojrzałości w porównaniu do rozwiązań przetwarzających dane 3D. Zaletą podejścia 2D jest również uproszczony proces oznaczania wad na obrazie oraz możliwość zastosowania zaawansowanych technik augmentacji, takich jak skalowanie, translacja czy filtracja, co przekłada się na lepszą generalizację modeli. Ponadto analiza obrazów 2D wymaga mniejszych zasobów obliczeniowych, co umożliwia implementację systemów detekcji wad na mniej wydajnych, a przez to bardziej ekonomicznych platformach sprzętowych, co ma kluczowe znaczenie w zastosowaniach przemysłowych.

5. Podsumowanie

W pracy przedstawiono kompletny, modułowy system inspekcji wkładów ceramicznych stosowanych w filtrach DPF i GPF, łączący analizę danych pochodzących ze skanowania 3D z kontrolą wizyjną 2D. Zastosowane podejście hybrydowe, obejmujące algorytmy głębokiego uczenia oraz metody klasyczne, umożliwiło detekcję wad zarówno w strukturze komórek, jak i na powierzchniach bocznych oraz czołowych. Szczególną zaletą opracowanego rozwiązania jest wysoka skuteczność wykrywania wad, przekraczająca 98 %, przy zachowaniu krótkiego czasu cyklu, istotnego w warunkach produkcji przemysłowej.

Opracowana architektura modułowa umożliwia elastyczną konfigurację stanowiska w zależności od wymagań użytkownika końcowego, co pozwala na optymalizację czasu inspekcji oraz kosztów wdrożenia. Wykorzystanie konwersji chmury punktów do postaci obrazów 2D pozwoliło na zastosowanie dojrzałych technologii CNN, uproszczenie procesu oznaczania wad oraz efektywniejszą augmentację danych.

Wyniki potwierdzają, że integracja metod 3D i 2D w jednym procesie inspekcji zwiększa niezawodność detekcji wad w porównaniu z rozwiązaniami opartymi wyłącznie na jednej z tych technologii. Dalsze prace mogą koncentrować się na zwiększeniu automatyzacji procesów przygotowania danych, optymalizacji czasu cyklu jak również ulepszaniu algorytmów detekcji wad, których celem jest zwiększenie odporności systemu na zakłócenia oraz minimalizacja liczby fałszywych odrzuceń.

Podziękowania

Projekt POIR. 01.01.01-00-0366/20 „Opracowanie stanowiska inspekcyjnego przeznaczonego do precyzyjnej i zautomatyzowanej wizyjnej kontroli jakościowej wkładów ceramicznych z wykorzystaniem nowych algorytmów opartych o sieci głębokie” współfinansowany przez Unię Europejską ze środków Europejskiego Funduszu Rozwoju Regionalnego w ramach Programu Inteligentny Rozwój 2014-2020. Projekt realizowany w ramach konkursu Narodowego Centrum Badań i Rozwoju: 1/1.1.1/2020 Szybka Ścieżka.

Bibliografia

1. Kraszewski T., Piwowar A., Frączek R., Świszcz P., Bis Ł., *Visual defect detection methods overview*, „Przegląd Elektrotechniczny”, T. 98, Nr 11, 2022, 269–272, DOI: 10.15199/48.2022.11.55.
2. Sioma A., Kowal J., Karwat B., *Methods of 3D imaging used in quality inspection systems in manufacturing*, „Journal of Machine Construction and Maintenance | Problemy Eksploatacji”, 2017, No. 1(104), 2017, 9–17.
3. Kowalik P., Pelowski M., Lipowiecki P., *Test and comparison of different digitalization techniques for objects with surfaces difficult to scan*, „Advances in Science and Technology Research Journal”, Vol. 19, No. 2, 2025, DOI: 10.12913/22998624/194997.
4. Watanabe M., Nayar S.K., *Telecentric optics for constant-magnification imaging*, Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 1996.
5. Cao Y., Yao Y., Lu L., *Design of a double-telecentric machine vision lens with continuously adjustable magnification*, „Applied Optics”, Vol. 64, No. 13, 2025, 3456–3464, DOI: 10.1364/AO.557850.
6. Geng J., *Structured-light 3D surface imaging: A tutorial*, „Advances in Optics and Photonics”, Vol. 3, No. 2, 2011, 128–160, DOI: 10.1364/AOP.3.000128.
7. Salvi J., Fernandez S., Pribanic T., Llado X., *A state of the art in structured light patterns for surface profilometry*, „Pattern Recognition”, Vol. 43, No. 8, 2010, 2666–2680, DOI: 10.1016/j.patcog.2010.03.004.
8. Huber P.J., Ronchetti E.M., *Robust Statistics*, 2nd ed. Hoboken, NJ, USA: Wiley, 2009.
9. Pauly M., Gross M., Kobbelt L.P., *Efficient simplification of point-sampled surfaces*, Proceedings of IEEE Visualization 2002, 163–170, DOI: 10.1109/VISUAL.2002.1183771.
10. Rusu R.B., Cousins S., *3D is here: Point Cloud Library (PCL)*, Proceedings of the IEEE International Conference on Robotics and Automation (ICRA), Shanghai, China, 2011, DOI: 10.1109/ICRA.2011.5980567.
11. Levin D., *Mesh-independent surface interpolation*, [In:] *Geometric Modeling for Scientific Visualization*, Brunnett G., Hamann B., Müller H., Linsen L. (Eds.) Berlin, Germany: Springer, 2004, 37–49, DOI: 10.1007/978-3-662-07443-5_3.

Automated Quality Control of Ceramic Inserts Using Vision Systems and Deep Neural Networks

Abstract: The article presents a modular, automated inspection system for ceramic inserts used in DPF and GPF filters. The system integrates 3D scanning based on structured light with 2D imaging using telecentric optics. The applied hybrid detection algorithms, combining deep neural networks with classical image processing methods, enable the identification of cell blockage within the ceramic insert as well as defects on its external surface. Converting point clouds into 2D representations allows for the effective use of convolutional neural networks, simplifies the defect labeling process on images, and reduces computational requirements. The conducted tests confirmed high detection accuracy while maintaining short inspection times consistent with industrial constraints. The modular architecture and full automation of the inspection process enable flexible adaptation of the system to diverse production lines .

Keywords: DPF, GPF, optical quality inspection, 3D scanning, exhaust gas filtration, exhaust emissions

mgr inż. Rafał Dębniak

rafal.debniak@mv-center.com
ORCID: 0009-0003-6209-9093

Absolwent kierunku Automatyka i Robotyka ze specjalnością Robotyka i Mechatronika na Wydziale Inżynierii Mechanicznej i Robotyki Akademii Górniczo-Hutniczej w Krakowie. Specjalizuje się w szeroko pojętej wizji maszynowej. W swojej karierze kierownik projektów wdrożeniowych w przemyśle oraz prac badawczo-rozwojowych związanych z systemami wizyjnymi 2D oraz 3D.



mgr inż. Wiktor Łęczek

wiktor.leczek@mv-center.com
ORCID: 0009-0000-4060-8123

Absolwent kierunku Automatyka i Robotyka na Wydziale Inżynierii Mechanicznej i Robotyki Akademii Górniczo-Hutniczej w Krakowie. Specjalizuje się w systemach wizyjnych 2D i 3D oraz klasycznych algorytmach przetwarzania obrazów, jak również nowoczesnych rozwiązaniach opartych na sztucznej inteligencji i głębokim uczeniu . Posiada bogate doświadczenie w uruchamianiu oraz wdrożeniach rozwiązań u wiodących dystrybutorów oprogramowania i sprzętu z zakresu wizji maszynowej. Aktywnie realizuje projekty wdrożeniowe oraz badawczo-rozwojowe związane z automatyzacją procesów i integracją nowoczesnych systemów wizyjnych w przemyśle.



mgr inż. Jakub Wójcik

jakub.wojcik@mv-center.com
ORCID: 09-0007-5620-1628

Absolwent Akademii Górniczo-Hutniczej na kierunku Automatyka i Robotyka na wydziale Inżynierii Mechanicznej i Robotyki. Pracownik firmy MV Center zajmującej się realizacją indywidualnych wdrożeń. Kierownik projektów oraz inżynier z 15 letnim doświadczeniem. Specjalizuje się w systemach wizyjnych opartych o rozwiązania obrazowania z wykorzystaniem technologii skanowania 3D oraz w systemach pomiarowych.

