

Piotr STRUMIŃSKI, Oskar ZIELIŃSKI, Rafał TOMCZYK
TK-Systems sp z o.o.

PROCESY ETYKIETOWANIA PRODUKTÓW I WERYFIKACJI ZGODNOŚCI DANYCH IDENTYFIKUJĄCYCH Z WYKORZYSTANIEM SZTUCZNEJ INTELIGENCJI (SSN)

Streszczenie. W pracy przedstawiono proces etykietowania wyrobów wraz z automatyczną weryfikacją zgodności danych identyfikujących, ujęty jako proces dyskretno-zdarzeniowy z warstwą decyzyjną opartą na konwolucyjnej sieci neuronowej. Omówiono strukturę zdarzeń i stanów procesu, miejsce klasyfikatora SSN w pętli sterowania linią oraz sposób przygotowania zbiorów danych. Zasadniczą część stanowią badania eksperymentalne dotyczące relacji między licznością zbioru uczącego a skutecznością detekcji niezgodności. Wyniki uzyskane w warunkach laboratoryjnych oraz w czterech zakładach produkcyjnych (przemysł spożywczy, meblarski, opakowań drewnianych i motoryzacyjny) wskazują, że przy zastosowaniu sieci wstępnie wytrenowanej, o wymaganej liczności zbioru decyduje nie skala produkcji, lecz zmienność zadania walidacyjnego. Dla zadań o niskiej zmienności wystarczający okazał się zbiór rzędu kilkudziesięciu obrazów, przy skuteczności odczytu danych na poziomie 100%.

PRODUCT LABELING AND IDENTIFICATION DATA COMPLIANCE VERIFICATION PROCESSES USING ARTIFICIAL INTELLIGENCE (ANN)

Summary. This paper presents a product labeling process—incorporating automatic verification of identifying data—modeled as a discrete-event process with a decision-making layer based on a convolutional neural network. The study discusses the process's event and state structure, the role of the ANN classifier within the production line control loop, and the methodology for dataset preparation. A key component of the work is an experimental analysis of the relationship between the size of the training dataset and the effectiveness of non-conformity detection. Results obtained in both laboratory settings and four manufacturing plants (representing the food, furniture, wooden packaging, and automotive industries) indicate that, when using a pre-trained network, the required dataset size is determined not by the production scale, but by the variability of the validation task. For tasks with low variability, a dataset comprising a few dozen images proved sufficient, achieving a 100% data reading success rate.

1. Wprowadzenie

Znakowanie i etykietowanie są podstawowymi elementami procesów logistycznych, integrujący logistykę zaopatrzenia, produkcji, magazynowania i dystrybucji. Etykieta jest nośnikiem danych identyfikujących wyrób: numeru partii, składu, daty przydatności, danych zlecenia, kodów kreskowych i dwuwymiarowych a w wielu branżach także informacji wymaganych przepisami prawa. Praktyka serwisowa wskazuje, że dominującym problemem eksploatacyjnym nie jest awaryjność urządzeń drukująco-aplikujących, lecz jakość i poprawność naniesionych danych. Nieczytelny kod kreskowy powoduje konieczność ręcznego wprowadzania danych na kolejnych stanowiskach, a błędna etykieta na wyrobie gotowym oznacza dla producenta kosztowne wycofanie partii. Źródła niezgodności są zróżnicowane: zużycie głowicy drukującej, przesunięcie wstęgi etykiet, zagięcia i fałdy powstające przy aplikacji, zeskosowanie etykiety, wreszcie niezgodność treści etykiety ze zleceniem produkcyjnym. Kontrola prowadzona przez operatora jest przy tym obciążona istotną zmiennością subiektywną [10].

Automatyzacja inspekcji wizyjnej jest przedmiotem badań od dziesięcioleci, a w ostatnich latach zdominowały ją metody uczenia głębokiego [2, 3]. Prace dotyczące inspekcji druku zmiennego i druku offsetowego [5, 6] koncentrują się jednak na samej poprawności nadruku. Celem opisywanych prac było opracowanie systemu weryfikującego etykietę kompleksowo – pod kątem czytelności fizycznej, poprawności odczytu kodu, zgodności danych z bazą zleceń oraz poprawności aplikacji na wyrób – przy czym decyzja o zgodności ma bezpośrednio oddziaływać na sterowanie linią produkcyjną.

Niniejsza praca dotyczy jednego zagadnienia wyodrębnionego z szerszego projektu badawczo-rozwojowego: doboru liczności zbioru uczącego dla klasyfikatora neuronowego pełniącego rolę elementu decyzyjnego procesu. Zagadnienie to ma bezpośrednie znaczenie wdrożeniowe, ponieważ czas dostępny na przygotowanie danych w środowisku klienta jest w praktyce zasobem najbardziej ograniczonym [7, 8].

2. Proces etykietowania i walidacji jako proces dyskretny

Rozpatrywany proces ma charakter dyskretno-zdarzeniowy. W rozumieniu przyjętym w [1]: zmiany stanu systemu następują skokowo, w chwilach wystąpienia zdarzeń, a nie w sposób ciągły w czasie. Sekwencję zdarzeń dla pojedynczego wyrobu można zapisać następująco:

1. **e_1 – detekcja wyrobu** w strefie roboczej;
2. **e_2 – pobranie danych** ze zlecenia produkcyjnego;
3. **e_3 – zakończenie druku i kodowania** etykiety;
4. **e_4 – zakończenie aplikacji** etykiety na wyrób;
5. **e_5 – akwizycja obrazu** przez moduł walidatora;
6. **e_6 – decyzja klasyfikatora:** zgodność albo niezgodność;
7. **e_7 – zwolnienie wyrobu** do dalszej części linii albo **e_8 – zatrzymanie posuwu** i sygnalizacja.

Stan systemu jest opisany trójką: pozycja wyrobu, stan modułu aplikującego oraz wynik walidacji. Istotną cechą struktury jest pętla sprzężenia zwrotnego: wystąpienie zdarzenia e_8 powoduje powrót do e_3 – etykieta jest drukowana i aplikowana powtórnie, a wyrób nie opuszcza stanowiska do czasu uzyskania wyniku pozytywnego. Detekcja niezgodności jest zatem nie tylko funkcją kontrolną, ale zdarzeniem sterującym przepływem materiału.

Na warstwę dyskretną nałożona jest warstwa ciągła, co czyni układ hybrydowym. Należą do niej: adaptacyjny układ oświetlenia, regulujący płynnie natężenie i barwę światła na podstawie obrazu wstępnego, optoelektroniczno-mechatroniczny układ adaptacji wizyjnej, dostosowujący odległość toru optycznego do gabarytu wyrobu, oraz układ pneumatyczny ramienia aplikującego. Zastosowano trzy zestawy diod o barwie neutralnej i kącie świecenia 120° , skalibrowane dla obiektów bliskich, średnio oddalonych i odległych, co eliminuje efekt prześwietlenia planu pierwszego przy jednoczesnym niedoświetleniu obszarów dalszych – jakość wizualizacji wady jest bowiem warunkiem koniecznym skutecznej detekcji [2].

Zdarzenie e_6 jest tym punktem struktury, w którym ulokowano klasyfikator neuronowy. Jego jakość przekłada się bezpośrednio na dwa rodzaje kosztów: przeoczenie niezgodności (wyrób wadliwy opuszcza linię) oraz fałszywy alarm (zbędne zatrzymanie posuwu). To uzasadnia szczegółową analizę warunków, w jakich klasyfikator osiąga wymaganą skuteczność.

3. Warstwa decyzyjna oparta na SSN

3.1. Wybór architektury i uczenie modelu

Do klasyfikacji obrazów etykiet wybrano konwolucyjną sieć neuronową (CNN), co uzasadnia struktura danych wejściowych oraz zdolność warstw konwolucyjnych do wykrywania lokalnych wzorców – krawędzi, tekstur, deformacji – bez ręcznego projektowania cech, co w zadaniach inspekcji przemysłowej daje przewagę nad metodami opartymi na cechach definiowanych ręcznie [4]. Sieć zbudowano z naprzemiennych warstw konwolucyjnych i łączących (max-pooling 2×2), zakończonych warstwami w pełni połączonymi, z funkcją aktywacji ReLU. Uczenie prowadzono metodą nadzorowaną z wykorzystaniem algorytmu propagacji wstecznej. Jako kryterium przerwania treningu przyjęto zatrzymanie lub wzrost błędu walidacyjnego przy dalszym spadku błędu uczącego; zachowano również balans klas w każdej z części zbioru.

3.2. Przygotowanie zbiorów danych

Podstawą był zestaw około 500 fizycznych próbek etykiet – poprawnych oraz obarczonych różnymi typami niezgodności – zebranych w toku prac serwisowych i eksperymentów laboratoryjnych. Na ich podstawie, przy użyciu modułu walidatora, wykonano zbiór obrazów w warunkach odpowiadających docelowym.

W badaniach laboratoryjnych wykorzystano zbiór 600 obrazów, podzielony losowo w proporcji 70% / 20% / 10% odpowiednio na część uczącą, walidującą i testową. Obrazy poddano wstępnemu przetworzeniu i redukcji rozdzielczości,

a następnie augmentacji obejmującej odbicia lustrzane, obroty oraz zmiany jasności [9]. Implementację zrealizowano w języku Python z wykorzystaniem bibliotek TensorFlow oraz PyTorch – wybór ten wynikał z wcześniejszej decyzji o zastosowaniu Pythona jako środowiska dla oprogramowania układowego modułów, co upraszcza integrację warstwy decyzyjnej ze sterowaniem.

3.3. Zakres klasyfikacji

Klasyfikator wykrywa dwie grupy niezgodności. Pierwsza dotyczy poprawności aplikacji: przesunięcia etykiety względem położenia nominalnego, zeskosowania, fałdy powstałe podczas klejenia, podwinięte narożniki, uszkodzenia mechaniczne. Druga dotyczy poprawności danych: czytelności i zawartości pola tekstowego (OCR), położenia i czytelności kodu 2D oraz zgodności odczytanej treści z rekordem zlecenia produkcyjnego.

Kryteria oceny jakości nadruku kodów przyjęto zgodnie z normami ISO/IEC 15416 i ISO/IEC 15415 [11]. W badaniach laboratoryjnych odczyt zawartości kodów kreskowych osiągnął 100% poprawności. W odczycie OCR odnotowano nieliczne pomyłki dotyczące znaków o zbliżonym kształcie – pary „O”/„0” oraz „B”/„8” – co rozwiązano przez dotrenowanie sieci oraz zmianę kroju czcionki na etykietach.

4. Badania eksperymentalne – wpływ liczności zbioru uczącego

4.1. Sformułowanie problemu

W warunkach wdrożeniowych przygotowanie obszernego zbioru uczącego jest zwykle niewykonalne. Odbiorca udostępnia środowisko produkcyjne na ograniczony czas, a zebranie reprezentatywnych próbek niezgodności wymaga celowego generowania wad, co koliduje z bieżącą produkcją. Ograniczenie nakładu na etykietowanie danych stanowi obecnie odrębny nurt badań [7, 8].

Postawiono zatem pytanie: jaka liczność zbioru uczącego jest wystarczająca, jeżeli dysponuje się siecią wstępnie wytrenowaną, i od czego ta liczność zależy?

Badania przeprowadzono w warunkach laboratoryjnych oraz w czterech zakładach produkcyjnych, przy zróżnicowanym czasie dostępnym na przygotowanie danych. We wszystkich przypadkach przemysłowych punktem wyjścia była sieć wstępnie wytrenowana na zbiorach z wcześniejszych etapów prac, dotrenowywana na danych z konkretnego środowiska.

4.2. Wyniki

Tabela 1

Zestawienie warunków i wyników uzyskanych w poszczególnych środowiskach

Środowisko / branża	Wersja systemu	Czas na dane	Liczność zbioru	Zmienność zadania	Skuteczność detekcji
Laboratorium	stacjonarna i mobilna	nieograniczony	600 obrazów (70/20/10)	wysoka – 3 gabaryty, wiele formatów	kody 100%; OCR bliski 100%
Przemysł spożywczy	stacjonarna	2 tygodnie	ok. 200 etykiet	średnia	detekcja na granicy 100%
Przemysł meblarski	stacjonarna	10 dni roboczych	dotrenowanie zbioru bazowego	wysoka – 25×70 mm, Datamatrix + RFID	ok. 98%
Opakowania drewniane	mobilna	ograniczony	50 etykiet	niska – stały format i miejsce aplikacji	OCR 100%; poprawna detekcja wad aplikacji
Motoryzacja	stacjonarna	4 dni	sieć wstępnie wytrenowana	wysoka – folia PP 15×90 mm, podłoże metalowe	98–100% sprawności

4.3. Interpretacja

Zestawienie prowadzi do wniosku, który przeczy intuicji „im więcej danych, tym lepiej” w jej prostej postaci. Najmniejszy zastosowany zbiór (50 etykiet), dał najwyższy wynik odczytu danych. Przypadek ten dotyczył jednak zadania o najniższej zmienności: etykieta miała stały rozmiar i była aplikowana zawsze w tym samym miejscu wyrobu, na skrzyniach drewnianych o powtarzalnych gabarytach 240×80 cm przemieszczających się ze stałą prędkością około 0,2 m/s. Przestrzeń możliwych obrazów wejściowych była więc wąska, a niewielki zbiór wystarczał do jej pokrycia.

Odwrotnie w przypadku wdrożenia motoryzacyjnego, gdzie mimo dysponowania siecią wstępnie wytrenowaną skuteczność zatrzymała się w przedziale 98-100%. Zadanie charakteryzowało się wysoką zmiennością warunków akwizycji: etykieta z cienkiej folii PP o wymiarach 15×90 mm, wykonana z materiału kruszącego się przy próbie usunięcia, aplikowana na powierzchnię metalową generującą silne odbłyски. Odbłyски zakłócały inspekcję mimo poprawnej pracy adaptacyjnego układu oświetlenia i wymagały dodatkowego filtrowania obrazu przed podaniem go na wejście klasyfikatora.

Wnioskiem o znaczeniu praktycznym jest zatem stwierdzenie, że o wymaganej liczności zbioru uczącego decyduje zmienność zadania walidacyjnego, a nie skala produkcji ani liczba weryfikowanych sztuk. Parametrami różnicującymi są przede wszystkim: liczba formatów etykiety, zmienność miejsca aplikacji, właściwości optyczne podłoża oraz stabilność warunków oświetleniowych. Tam, gdzie wszystkie cztery parametry są ustalone, kilkadziesiąt obrazów uzupełnionych augmentacją pozwala osiągnąć skuteczność akceptowalną produkcyjnie. Rozszerzenie zakresu walidacji o parametry dodatkowe: określony wzorzec graficzny, rodzaj opakowania, kolorystykę wymaga budowy zbiorów od podstaw i istotnie wydłuża proces przygotowania.

Należy zaznaczyć, że porównywane wdrożenia różniły się jednocześnie wieloma czynnikami, a przedstawiona zależność ma charakter obserwacji z praktyki przemysłowej, nie zaś eksperymentu z jedną kontrolowaną zmienną. Weryfikacja tej zależności w układzie z kontrolowaną licznnością zbioru na jednym, ustalonym zadaniu stanowi przedmiot dalszych prac.

5. Weryfikacja w warunkach produkcyjnych

Wyniki uzyskane w środowiskach docelowych potwierdzono przy pełnym obciążeniu. System pracował w trybie w pełni automatycznym tam, gdzie możliwa była integracja z sygnałami sterującymi linii oraz w trybie półautomatycznym, wyzwalanym przez operatora, tam gdzie złożoność stanowiska uniemożliwiała integrację w dostępnym czasie. Uzyskano wydajność do 20 wyrobów na minutę bez oznak degradacji jakości inspekcji.

Na stanowisku laboratoryjnym z przenośnikiem rolkowym o długości 370 cm wykonano około 10 000 aplikacji przy wymiennie stosowanych modułach drukująco-kodujących i dyspenserach. Powtarzalność miejsca naniesienia etykiety utrzymywała się w granicach 1 mm. W próbie obejmującej ponad sto etykiet celowo obciążonych wadami moduł walidatora wykrył niezgodność w każdym przypadku i spowodował zatrzymanie posuwu wraz z sygnalizacją – czyli poprawnie wygenerował zdarzenie es opisane w rozdziale 2.

Odnotowano również przypadek integracji rozszerzonej: w linii pakowania frontów meblarskich zawartość kodu Datamatrix zapisywana była równolegle do znacznika RFID, a zgodność obu nośników z rekordem zlecenia warunkowała wystawienie sygnału zwalniającego wyrób do stanowiska paletyzującego.

6. Podsumowanie

Przedstawiony proces etykietowania z automatyczną weryfikacją danych identyfikujących stanowi układ hybrydowy, w którym warstwa dyskretno-zdarzeniowa steruje przepływem materiału, a warstwa ciągła odpowiada za warunki akwizycji obrazu. Klasyfikator neuronowy ulokowany w punkcie decyzyjnym procesu pozwolił osiągnąć skuteczność detekcji niezgodności na poziomie 98-100% w czterech różnych branżach.

Zasadniczy wynik badań dotyczy doboru zbioru uczącego. Przy zastosowaniu sieci wstępnie wytrenowanej licznność zbioru wymaganego do wdrożenia zależy przede

wszystkim od zmienności zadania walidacyjnego. Dla zadań ustabilizowanych wystarczy zbiór rzędu kilkudziesięciu obrazów, co skraca czas wdrożenia w środowisku odbiorcy z tygodni do dni. Obserwacja ta ma bezpośrednie przełożenie na organizację procesu wdrożeniowego: przed zebraniem danych zasadne jest oszacowanie zmienności zadania i – o ile to możliwe – jej celowe ograniczenie przez ujednolicenie formatu etykiety i miejsca aplikacji.

Dalsze prace obejmą rozszerzenie zakresu walidacji o parametry graficzne i kolorystyczne oraz badanie stabilności klasyfikatora w dłuższym horyzoncie eksploatacji.

Podziękowania. Praca zrealizowana w ramach projektu „Wielomodułowy zintegrowany system etykietowania produktów i weryfikacji zgodności danych identyfikujących z wykorzystaniem sztucznej inteligencji (SSN)”. [Nr wniosku o dofinansowanie: RPDS.01.02.01-02-0011/20, nabór nr RPDS.01.02.01-IP.01-02-372/19, Działanie: 1.2 Innowacyjne przedsiębiorstwa].

LITERATURA

1. Jin Q., Chen L.: A survey of surface defect detection of industrial products based on a small number of labeled data. arXiv:2203.05733, 2022. <https://doi.org/10.48550/arXiv.2203.05733>
2. ISO/IEC 15416:2016 oraz ISO/IEC 15415:2011 - Bar code print quality test specification: linear symbols / two-dimensional symbols.
3. Krassnig P.J., Haselmann M., Kremnitzer M., Gruber D.P.: Efficient surface defect detection in industrial screen printing with minimized labeling effort. Integr. Comput.-Aided Eng., 32(1), 2025, s. 3-23. <https://doi.org/10.3233/ICA-240742>
4. Kujawińska A., Vogt K.: Human factors in visual quality control. Manag. Prod. Eng. Rev., 6(2), 2015, s. 25-31. <https://doi.org/10.1515/mper-2015-0013>
5. Prunella M., Scardigno R.M., Buongiorno D. i in.: Deep Learning for Automatic Vision-Based Recognition of Industrial Surface Defects: A Survey. IEEE Access, 11, 2023, s. 43370-43423. <https://doi.org/10.1109/ACCESS.2023.3271748>
6. Ren Z., Fang F., Yan N. i in.: State of the Art in Defect Detection Based on Machine Vision. Int. J. of Precis. Eng. and Manuf.-Green Tech. 9, 661-691, 2022. <https://doi.org/10.1007/s40684-021-00343-6>
7. Shorten C., Khoshgoftaar T.M.: A survey on Image Data Augmentation for Deep Learning. J. Big Data, 6, 2019, 60. <https://doi.org/10.1186/s40537-019-0197-0>
8. Weimer D., Scholz-Reiter B., Shpitalni M.: Design of deep convolutional neural network architectures for automated feature extraction in industrial inspection. CIRP Annals, 65(1), 2016, s. 417-420. <https://doi.org/10.1016/j.cirp.2016.04.072>
9. Vans M., Schein S., Staelin C. i in.: Automatic visual inspection and defect detection on variable data prints. J. Electron. Imaging, 20(1), 2011, 013010. <https://doi.org/10.1117/1.3537837>
10. Zhang E., Chen Y., Gao M. i in.: Automatic Defect Detection for Web Offset Printing Based on Machine Vision. Applied Sciences, 9(17), 2019, 3598. <https://doi.org/10.3390/app9173598>