



Sztuczna inteligencja w badaniach tektury falistej – wsparcie czy alternatywa dla klasycznych testów?

Artificial Intelligence in corrugated board testing – support or alternative to classical methods?

TOMASZ GARBOWSKI, IFFAT NAZIR

DOI: 10.15199/54.2026.5.1

Klasyczne badania laboratoryjne od dziesięcioleci stanowią podstawę oceny jakości papieru i tektury falistej. Testy, takie jak: ECT, BCT, SCT, RCT, pomiary gramatury czy odporności na działanie wilgoci umożliwiają kontrolę parametrów materiałowych oraz projektowanie bezpiecznych opakowań. Współczesny rynek wymaga jednak coraz szybszych decyzji technologicznych, większej elastyczności produkcji oraz ograniczania kosztów badań. W tym kontekście rośnie zainteresowanie wykorzystaniem sztucznej inteligencji jako narzędzia wspierającego lub częściowo zastępującego tradycyjne testowanie. W artykule przedstawiono możliwości zastosowania metod uczenia maszynowego w branży papierniczej, ze szczególnym uwzględnieniem prognozowania wyników badań wytrzymałościowych na podstawie danych procesowych, parametrów surowców oraz warunków środowiskowych. Omówiono potencjał algorytmów AI w zakresie przewidywania parametrów ECT i BCT, wykrywania anomalii jakościowych, optymalizacji doboru papierów oraz monitoringu produkcji w czasie rzeczywistym. Wskazano jednocześnie ograniczenia tego podejścia, wynikające z jakości danych, potrzeby walidacji modeli, problemu interpretowalności oraz konieczności zachowania klasycznych badań referencyjnych. Wnioskiem pracy jest stwierdzenie, że sztuczna inteligencja nie zastąpi całkowicie laboratoriów papierniczych, lecz może istotnie zmienić ich rolę, ograniczając liczbę badań rutynowych i przyspieszając podejmowanie decyzji technologicznych.

Słowa kluczowe: sztuczna inteligencja, tektura falista, papiernictwo, ECT, BCT, uczenie maszynowe, kontrola jakości, laboratorium cyfrowe

Classical laboratory testing has formed the foundation of paper and corrugated board quality assessment for decades. Tests such as ECT, BCT, SCT, RCT, grammage measurements, and moisture resistance evaluations enable material control and safe packaging design. However, the modern market increasingly demands faster technological decisions, greater production flexibility, and reduced testing costs. In this context,

growing attention is being given to artificial intelligence as a tool supporting or partially replacing conventional testing procedures. This paper discusses the potential use of machine learning methods in the paper industry, with particular focus on predicting strength-test results based on process data, raw-material parameters, and environmental conditions. The capabilities of AI algorithms in forecasting ECT and BCT values, detecting quality anomalies, optimizing paper selection, and enabling real-time production monitoring are presented. At the same time, the limitations of this approach are highlighted, including data quality issues, the need for model validation, interpretability challenges, and the necessity of maintaining classical reference testing. It is concluded that artificial intelligence will not fully replace paper-testing laboratories, but it may significantly transform their role by reducing routine testing and accelerating technological decision-making.

Keywords: artificial intelligence, corrugated board, paper industry, ECT, BCT, machine learning, quality control, digital laboratory

Wprowadzenie

Badania laboratoryjne od wielu lat stanowią fundament funkcjonowania przemysłu papierniczego oraz sektora opakowań z tektury falistej. To właśnie dzięki standaryzowanym testom możliwa jest ocena jakości papierów, porównywanie partii produkcyjnych, projektowanie bezpiecznych opakowań oraz spełnianie wymagań odbiorców. Parametry, takie jak: ECT, BCT, SCT, RCT, gramatura, grubość i odporność na działanie wilgoci należą dziś do podstawowego języka technicznego branży. Klasyczne testowanie ma jednak swoje naturalne ograniczenia. Wymaga czasu, przygotowania próbek, aparatury, personelu oraz odpowiedniej organizacji pracy laboratorium. Wynik badania często opisuje jedynie konkretną próbkę w określonym momencie, podczas gdy współczesna produkcja charakteryzuje

Dr hab. inż. **T. Garbowski**, prof. UPP (tomasz.garbowski@up.poznan.pl), Uniwersyteckie Centrum Ekomateriałów, Uniwersytet Przyrodniczy w Poznaniu; mgr inż. **I. Nazir** (iffat.nazir@gmail.com), Department of Plant Breeding and Genetics, University of Agriculture, Faisalabad



się dużą zmiennością surowców, wysoką dynamiką zamówień oraz rosnącą liczbą wariantów konstrukcyjnych. Rynek oczekuje coraz szybszych odpowiedzi niż rytm tradycyjnego laboratorium. Równolegle rozwija się sztuczna inteligencja, a szczególnie metody uczenia maszynowego, zdolne do wykrywania zależności ukrytych w dużych zbiorach danych [11]. W wielu gałęziach przemysłu algorytmy AI przewidują awarie, wspierają kontrolę jakości, optymalizują procesy technologiczne i skracają czas podejmowania decyzji. Naturalnym kierunkiem badań stało się więc przeniesienie podobnych rozwiązań do sektora papierniczego. Pierwsze praktyczne przykłady wykorzystania sztucznej inteligencji w prognozowaniu parametrów opakowań z tektury falistej oraz ich właściwości wytrzymałościowych zostały już opisane w literaturze [6, 7].

W przypadku tektury falistej potencjał jest znaczący. Zakłady produkcyjne dysponują coraz większą liczbą danych dotyczących surowców, parametrów linii, warunków klimatycznych, wyników badań oraz reklamacji klientów. Dane te mogą stać się podstawą modeli przewidujących jakość materiału lub nośność opakowania jeszcze przed wykonaniem części testów fizycznych. Rozwój takich narzędzi wpisuje się w szerszy trend cyfryzacji procesów projektowych, produkcyjnych i jakościowych obserwowany w branży opakowaniowej [7].

Pojawia się zatem pytanie zawarte w tytule artykułu: czy sztuczna inteligencja może zastąpić klasyczne testy tektury? Odpowiedź nie jest zero-jedynkowa. W niektórych zastosowaniach AI może pełnić rolę szybkiego doradcy technologicznego, w innych pozostanie jedynie

narzędziem wspierającym, a w części przypadków tradycyjne badania nadal będą niezastąpione.


Celem niniejszego artykułu jest przedstawienie realnych możliwości oraz ograniczeń wykorzystania sztucznej inteligencji w obszarze badań papieru i tektury falistej, a także wskazanie kierunku rozwoju laboratoriów przyszłości, w których algorytmy i aparatura będą współpracować zamiast ze sobą konkurować.

Ogólną architekturę współpracy laboratoriów i algorytmów przedstawiono na rysunku 1. W praktyce przemysłowej pojawiają się już pierwsze udane wdrożenia modeli predykcyjnych wspierających ocenę wytrzymałości opakowań papierowych oraz prognozowanie ich zachowania eksploatacyjnego [6, 7].

Czym dziś jest klasyczne testowanie tektury?

Klasyczne badania laboratoryjne od dziesięcioleci stanowią kręgosłup techniczny branży papierniczej. To dzięki nim możliwe jest obiektywne porównywanie materiałów, kontrola jakości produkcji, rozwój nowych wyrobów oraz zapewnienie bezpieczeństwa opakowań w praktyce logistycznej. W świecie, w którym miliony pudełek codziennie podejmują cichą pracę ochrony produktów, laboratorium pozostaje miejscem, gdzie ta praca jest zawczasu oceniana.

System testowania tektury falistej opiera się na zestawie metod znormalizowanych, pozwalających mierzyć różne aspekty zachowania materiału. Do najważniejszych należą: badania odporności na zgniatanie



Rys. 1. Synergia klasycznych badań laboratoryjnych i sztucznej inteligencji w nowoczesnym systemie kontroli jakości tektury falistej



nie krawędziowe (ECT), odporności na nacisk statyczny pudła (BCT), odporności na ściskanie przy krótkim wpięciu (SCT), odporności na zginięcie pierścieniowe (RCT), pomiary gramatury, grubości, sztywności zginania oraz właściwości związanych z absorpcją wody, takich jak test Cobb. Każdy z tych parametrów opisuje inny fragment prawdy o materiale. Zależność między wynikami badań laboratoryjnych a rzeczywistą nośnością opakowań była wielokrotnie przedmiotem analiz eksperymentalnych oraz numerycznych opisanych w literaturze [2].

W praktyce przemysłowej testy pełnią kilka równoległych funkcji. Po pierwsze, umożliwiają **kontrolę bieżącej produkcji**, pozwalając wychwycić odchylenia jakościowe zanim materiał trafi do klienta. Po drugie, wspierają **projektowanie opakowań**, dostarczając danych wejściowych do doboru konstrukcji i papierów. Po trzecie, są narzędziem **potwierdzania zgodności** z wymaganiami kontraktowymi, normami lub specyfikacjami odbiorców. Po czwarte, stanowią ważny element **rozstrzygnięcia sporów jakościowych**, gdy pojawiają się reklamacje.

Największą siłą klasycznych metod jest ich **materiałna wiarygodność**. Badanie wykonywane jest na rzeczywistej próbce, przy użyciu aparatury mierzącej rzeczywistą odpowiedź materiału. To kontakt bezpośredni, a nie prognoza. Właśnie dlatego wyniki laboratoryjne pozostają fundamentem zaufania między producentem a odbiorcą.

Jednocześnie tradycyjne testowanie posiada naturalne ograniczenia. Po pierwsze, wymaga czasu: pobrania próbek, przygotowania materiału, kondycjonowania w kontrolowanych warunkach klimatycznych, przeprowadzenia pomiaru i opracowania wyników. Po drugie, generuje koszty związane z personelem, aparaturą, przestrzenią laboratoryjną i utrzymaniem systemów jakości. Po trzecie, wynik ma często charakter punktowy: opisuje konkretną partię i konkretny moment, podczas gdy produkcja jest procesem ciągłym.

Istotnym wyzwaniem jest także rosnąca liczba wariantów produktów. Krótsze serie, personalizacja opakowań, częste zmiany zamówień i presja czasu sprawiają, że pełne przebadanie każdej konfiguracji staje się coraz trudniejsze. Laboratorium bywa wtedy strażnikiem jakości, ale także wąskim gardłem procesu decyzyjnego.

Warto zauważyć, że klasyczne testy najczęściej mierzą skutek, a nie zawsze przyczynę. Gdy wynik ECT spada, wiadomo, że parametr się pogorszył, lecz nie zawsze od razu wiadomo dlaczego: czy zawinił surowiec, wilgotność, ustawienia linii, proces klejenia, czy warunki magazynowania. Tu zaczyna się przestrzeń dla narzędzi cyfrowych.

Mimo tych ograniczeń laboratorium pozostaje niezastąpione. Jest sądem pierwszej instancji dla jakości materiału. Jednak świat produkcji przyspiesza, a liczba decyzji rośnie szybciej niż liczba godzin w dobie. To właśnie dlatego obok klasycznych testów pojawia się pytanie o nowe wsparcie, nie po to, by laboratorium obalić, lecz by je wzmocnić.

Czym byłaby sztuczna inteligencja w piapiernictwie?

Sztuczna inteligencja w piapiernictwie nie oznacza humanoidalnego robota spacerującego po hali produkcyjnej i oceniającego pudełka wzrokiem eksperta. W praktyce chodzi o zestaw metod analitycznych, które potrafią uczyć się zależności na podstawie danych, rozpoznawać

wzorce oraz przewidywać przyszłe wyniki szybciej niż pozwala na to klasyczny proces laboratoryjny. To raczej matematyczny współpracownik niż futurystyczna maszyna.

Najważniejszym obszarem zastosowań są **modele uczenia maszynowego**. Algorytmy tego typu analizują dane historyczne, takie jak parametry surowców, wyniki badań laboratoryjnych, ustawienia linii produkcyjnej, warunki klimatyczne czy reklamacje klientów, a następnie budują zależności pomiędzy wejściem a oczekiwanym rezultatem. Jeśli model nauczy się tych relacji poprawnie, może prognozować wyniki nowych partii materiału jeszcze przed wykonaniem pełnego zestawu testów. Podejście to zostało skutecznie zastosowane m.in. do predykcji wytrzymałości opakowań [6].

W praktyce oznacza to możliwość przewidywania takich parametrów jak ECT, BCT, SCT, sztywność arkusza czy ryzyko zawilgocenia opakowania. Zamiast czekać na wynik badania, technolog może otrzymać szybki sygnał ostrzegawczy lub rekomendację jeszcze na etapie produkcji. To zmiana z trybu „sprawdź po fakcie” na tryb „reaguj zawczasu”.

Drugim ważnym zastosowaniem jest **wykrywanie anomalii jakościowych**. Algorytmy potrafią rozpoznawać nietypowe kombinacje danych, które mogą świadczyć o problemie procesowym. Na przykład niewielka zmiana wilgotności papieru w połączeniu z określoną prędkością linii i temperaturą klejenia może historycznie prowadzić do pogorszenia parametrów. Człowiek może tego wzorca nie zauważyć, lecz model wychwyci subtelne ostrzeżenie.

Sztuczna inteligencja może także wspierać **optymalizację doboru surowców**. W branży, gdzie każdy gram papieru ma znaczenie ekonomiczne, system może proponować takie kombinacje linerów i flutingu, które spełnią wymagania jakościowe przy możliwie niskim koszcie. To nie tylko automatyzacja decyzji, lecz także nowa forma inżynierii materiałowej.

Coraz większe znaczenie ma również **analiza obrazów i systemy wizyjne**. Kamery wspierane algorytmami AI mogą wykrywać uszkodzenia powierzchni, błędy nadruku, deformacje wykrojów, nierówności krawędzi lub lokalne wady arkuszy w czasie rzeczywistym. Oko ludzkie bywa doskonałe, ale nie patrzy jednocześnie na tysiące metrów materiału na godzinę.

Warto jednak podkreślić, że sztuczna inteligencja nie „rozumie papieru” w taki sposób, jak doświadczony technolog. Model nie zna intuicyjnie mechaniki włókien ani znaczenia wilgotnej jesieni dla magazynu klienta. Rozpoznaje zależności statystyczne obecne w danych. Jeśli dane są dobre, model bywa bardzo skuteczny. Jeśli dane są chaotyczne, algorytm może produkować eleganckie błędy.

Dlatego najbardziej realistycznym obrazem AI w piapiernictwie jest rola **asystenta decyzyjnego**. System wskazuje ryzyko, przewiduje wynik, podpowiada warianty, ale człowiek podejmuje decyzję końcową. Technolog wnosi doświadczenie, kontekst i odpowiedzialność, a algorytm szybkość, pamięć i zdolność dostrzegania ukrytych wzorców.

Można więc powiedzieć, że sztuczna inteligencja w piapiernictwie nie ma zastąpić ekspertów. Ma dać im drugą parę oczu, trzecią rękę i pamięć większą niż archiwum całego zakładu.



Jakie dane mogłyby zastąpić część testów?

Sztuczna inteligencja nie działa w próżni. Jej skuteczność zależy nie tyle od modnych algorytmów, ile od jakości danych, na których została zbudowana. W branży papierniczej pytanie nie brzmi więc wyłącznie „czy AI może zastąpić część testów?”, lecz przede wszystkim „jakimi danymi można zasilić model, aby robił to wiarygodnie?”. To właśnie dane stają się nowym surowcem obok papieru, skrobi i energii. Odpowiednio uporządkowane i analizowane zasoby informacyjne mogą mieć dziś wartość porównywalną z tradycyjnymi zasobami produkcyjnymi, co podkreśla literatura dotycząca cyfryzacji branży [7]. Przykładowe grupy danych wymaganych do budowy skutecznych modeli predykcyjnych zestawiono w tabeli 1.

Pierwszą grupą są **dane materiałowe surowców**. Obejmują: gramaturę papierów, grubość, wilgotność, gęstość pozorną, parametry wytrzymałościowe linerów i medium, skład włóknisty oraz udział surowca wtórnego. Jeśli historycznie wiadomo, jakie kombinacje tych cech prowadziły do określonych wyników ECT lub BCT, model może nauczyć się przewidywać podobne zależności dla nowych partii.

Drugim filarem są **dane procesowe z produkcji**. Nowoczesne linie tekturowe rejestrują prędkość pracy, temperatury sekcji grzewczych, ilość kleju, dociski, wilgotność wejściową i wyjściową, odchylenia wymiarowe oraz wiele innych parametrów technologicznych. To niezwykle cenne informacje, ponieważ często właśnie proces decyduje o różnicy między materiałem poprawnym a znakomitym.

Kolejną kategorię stanowią **dane geometryczne produktu**. Typ fali, liczba warstw, grubość tektury, układ warstw, konstrukcja pudełka, wymiary, obecność perforacji, otworów wentylacyjnych czy specyficznych linii bigowania mogą istotnie wpływać na zachowanie gotowego opakowania. Model AI może uwzględniać te cechy przy prognozowaniu BCT lub innych parametrów użytkowych. W przypadku pudeł z tektury wielowarstwowej wykazano również, że lokalne uszkodzenia materiału mogą istotnie obniżyć końcową nośność konstrukcji [5].

Bardzo ważne są także **dane środowiskowe**. Temperatura i wilgotność hali produkcyjnej, magazynu oraz warunków przechowywania materiału często pozostają niedocenianym źródłem zmienności jakościowej. Tektura nie jest materiałem obojętnym klimatycznie, dlatego algorytm ignorujący otoczenie widzi tylko część obrazu. Istotny wpływ temperatury i wilgotności na parametry mechaniczne materiału potwierdzono m.in. w badaniach przedstawionych w [3].

Następna warstwa to **wyniki badań laboratoryjnych z przeszłości**. To one stanowią złoty standard uczenia modeli. Im większa i lepiej uporządkowana baza wyników: ECT, BCT, SCT, Cobb, gramatury, powiązana z danymi produkcyjnymi, tym większa szansa na zbudowanie trafnych prognoz. Laboratorium nie znika z równania, lecz staje się nauczycielem algorytmu.

Coraz cenniejsze stają się również **dane eksploatacyjne i reklamacyjne**. Informacje o uszkodzeniach w transporcie, zawilgoceniach, deformacjach palet i reklamacjach klientów pokazują, jak materiał zachowuje się poza laboratorium. To bezcenne źródło wiedzy, bo rzeczywistość bywa bardziej wymagająca niż norma testowa.

W praktyce część testów mogłyby zastępować także **dane online z czujników**. Pomiar grubości w czasie rzeczywistym, monitoring wilgotności, systemy wizyjne wykrywające defekty czy analiza dźwięku pracy maszyny mogą sygnalizować jakość bez konieczności każdorazowego pobierania próbki.

Trzeba jednak pamiętać, że nie każde dane są użyteczne. Dane niekompletne, niespójne lub błędnie opisane mogą nauczyć model złych nawyków szybciej niż dobrych. Cyfrowy bałagan skaluje się również skutecznie jak cyfrowa wiedza.

Można więc powiedzieć, że przyszłość częściowego zastępowania testów nie zależy wyłącznie od AI, lecz od tego, czy zakład potrafi zamienić codzienny strumień informacji w uporządkowaną pamięć procesu. Algorytm jest kucharzem, ale to dane decydują, co znajdzie w garnku.


Co AI może przewidywać już dziś?

Debata o sztucznej inteligencji często oscyluje między przesadnym entuzjazmem a przesadnym sceptycyzmem. Tymczasem najważniejsze pytanie brzmi praktycznie: **co AI potrafi zrobić już teraz**, przy dostępnych danych i realiach przemysłowych? Odpowiedź jest bardziej konkretna niż mogłoby się wydawać. W wielu obszarach algorytmy nie są wizją przyszłości, lecz narzędziem gotowym do wdrożenia. Najbardziej perspektywiczne kierunki zastosowań AI w branży przedstawiono na rysunku 2.

Jednym z najbardziej naturalnych zastosowań jest **prognozowanie parametrów ECT**. Mechaniczne podstawy tych zależności analizowano m.in. z wykorzystaniem modeli równoważnych oraz badań eksperymentalnych [1, 2]. Zależności między geometrią, materiałem

Tabela 1. Główne kategorie danych wykorzystywanych do budowy modeli sztucznej inteligencji wspierających kontrolę jakości i optymalizację procesów w branży papierniczej

Typ danych	Przykłady	Źródło	Znaczenie dla AI
Materiałowe	Gramatura, wilgotność, grubość, ECT, SCT	Laboratorium QC	Uczenie zależności właściwości
Procesowe	Prędkość linii, temperatura kleju, nacisk	SCADA / MES	Wpływ procesu na jakość
Geometryczne	Typ fali, liczba warstw, format	ERP / CAD	Różnicowanie konstrukcji
Środowiskowe	Temperatura hali, RH, sezon	Czujniki IoT	Korekta modeli
Jakościowe	Reklamacje, odrzuty, audyty	CRM / QA	Detekcja ryzyka



Rys. 2. Przykładowe obszary zastosowania sztucznej inteligencji w branży papierniczej możliwe do wdrożenia już dziś

i nośnością zostały szeroko udokumentowane zarówno w badaniach numerycznych, jak i eksperymentalnych [1, 2]. Odporność na zgniatanie krawędziowe zależy od właściwości papierów składowych, geometrii fali, jakości połączeń oraz warunków produkcji, zatem modele uczące się na danych historycznych mogą z dużą skutecznością szacować wynik jeszcze przed wykonaniem testu. Nie oznacza to eliminacji badania referencyjnego, lecz możliwość szybkiego wstępnego oszacowania jakości partii.

Podobnie wygląda sytuacja w przypadku **BCT**, czyli wytrzymałości pudełka na ściskanie. Jest to parametr bardziej złożony, ponieważ zależy nie tylko od tektury, lecz także od geometrii opakowania, wymiarów, otworów, jakości składania i warunków klimatycznych. Mimo to dobrze przygotowane modele mogą wspierać szybkie porównywanie wariantów konstrukcyjnych oraz identyfikację ryzykownych konfiguracji.

AI może skutecznie wspierać także **wykrywanie anomalii jakościowych**. Jeśli linia produkcyjna zaczyna generować materiał odbiegający od normalnego wzorca, system może zauważyć subtelne symptomy wcześniej niż człowiek. Niewielkie odchylenie wilgotności, zmiana temperatury klejenia i specyficzna kombinacja parametrów procesu mogą stanowić sygnał nadchodzącego problemu.

Kolejnym praktycznym obszarem jest **predykcja wpływu wilgoci i warunków klimatycznych**. Modele mogą szacować spadek sztywności lub nośności opakowania po określonym czasie magazynowania

w danym środowisku. To szczególnie cenne dla eksportu, logistyki sezonowej i branż wrażliwych na zawiłogocenie.

Duży potencjał posiada **optymalizacja doboru papierów**. Algorytm może analizować setki wcześniejszych realizacji i proponować kombinacje linerów oraz flutingu, spełniające wymagania przy niższym koszcie. W świecie milionowych nakładów nawet niewielka oszczędność gramatury zamienia się w bardzo realne pieniądze.

Coraz skuteczniejsze są również systemy **computer vision**. Kamery wspierane AI mogą identyfikować uszkodzenia krawędzi, nierówności fal, błędy nadruku, deformacje wykrojów czy problemy z klejeniem. Takie systemy pracują bez zmęczenia i patrzą tam, gdzie człowiek nie zdąży spojrzeć.

Warto jednak zachować realizm. AI najlepiej radzi sobie tam, gdzie istnieje **dużo powtarzalnych danych historycznych**. Jeśli pojawia się całkowicie nowy typ konstrukcji, nowy materiał lub rzadki scenariusz awarii, skuteczność modeli może spaść. Algorytm dobrze zna to, co już widział. Gorzej czuje się w krainie niespodzianek. Dlatego najuczciwsze podsumowanie brzmi: sztuczna inteligencja już dziś potrafi przewidywać wiele parametrów ważnych dla branży, szczególnie w obszarach rutynowych, powtarzalnych i bogatych w dane. Nie zastępuje rzeczywistości, ale potrafi ją coraz trafniej uprzedzać. Można powiedzieć, że laboratorium mierzy terazniejszość, a AI próbuje zajrzeć kilka kroków do przodu. Największa wartość pojawia się wtedy, gdy obie perspektywy spotykają się przy jednym stole.



Gdzie AI nie wystarczy?

Choć możliwości sztucznej inteligencji rosną dynamicznie, uczciwa analiza wymaga wskazania obszarów, w których algorytmy nie są i długo jeszcze nie będą samodzielnym rozwiązaniem. AI potrafi przewidywać, klasyfikować i optymalizować, ale nie każdy problem jakościowy da się sprowadzić do wzorca w danych. W wielu sytuacjach klasyczne testy fizyczne pozostają niezastąpione. Dotyczy to szczególnie walidacji nowych konstrukcji opakowań i nietypowych scenariuszy obciążenia [4]. Szczególne znaczenie ma to w przypadku rozwiązań niestandardowych, gdzie konieczne jest równoczesne wykorzystanie badań eksperymentalnych oraz symulacji MES [4].

Pierwszym takim obszarem jest **certyfikacja i zgodność formalna**. Odbiorcy, normy branżowe, audyty jakościowe czy spory handlowe wymagają wyników uzyskanych zgodnie z uznanymi procedurami badawczymi. Prognoza modelu, nawet bardzo trafna, nie zastąpi oficjalnego raportu laboratoryjnego. Algorytm może podpowiadać, ale pieczęć jakości wciąż należy do testu.

Drugim ograniczeniem są **nowe konstrukcje i nowe materiały**, dla których brakuje danych historycznych. Jeśli firma wprowadza innowacyjny układ warstw, nietypowy wykrojek, nowy rodzaj papieru lub opakowanie do niestandardowego zastosowania, model AI nie ma jeszcze doświadczenia, z którego mógłby czerpać. W takich sytuacjach laboratorium staje się pionierem, a algorytm dopiero przyszłym uczniem.

Kolejnym wyzwaniem są **ekstremalne lub rzadkie scenariusze eksploatacyjne**. Długotrwała ekspozycja na wysoką wilgotność, nietypowe przeciążenia transportowe, kontakt z agresywnym środowiskiem czy złożone mechanizmy uszkodzeń występują często zbyt rzadko, by stworzyć bogaty zbiór uczący. Tam, gdzie brakuje przykładów, model może zgadywać z nadmierną pewnością siebie.

Istotny problem stanowi również **jakość danych wejściowych**. Jeśli zakład gromadzi dane niespójnie, z błędami, lukami lub bez zachowania identyfikowalności partii, AI może wyciągać błędne wnioski. Algorytm nie odróżni prawdy od chaosu, jeśli oba zostaną zapisane w tej samej tabeli.

W wielu przypadkach potrzebna jest także **interpretowalność przyczynowa**. Gdy wynik ECT spada, technolog chce wiedzieć nie tylko że parametr jest gorszy, ale dlaczego tak się stało. Niektóre modele działają jak czarna skrzynka: dają trafną odpowiedź, lecz słabo tłumaczą mechanizm. W środowisku przemysłowym to często za mało.

AI nie zastąpi również **oceny eksperckiej i intuicji procesowej**. Doświadczony technolog potrafi połączyć dane z kontekstem. Wie, że zmienił się dostawca, była awaria sekcji suszącej, przyszła wilgotna dostawa lub klient używa opakowania inaczej niż deklarował. Człowiek rozumie historię zdarzeń, model widzi głównie liczby.

Warto wspomnieć o odpowiedzialności. Jeśli decyzja projektowa skutkuje dużymi stratami logistycznymi lub reklamacją, ktoś musi wziąć odpowiedzialność za wybór. Obecnie odpowiedzialność biznesowa i techniczna pozostaje po stronie ludzi oraz organizacji, nie algorytmów. Dlatego najrozsądniejszy wniosek brzmi: AI nie jest

zamiennikiem laboratorium, lecz narzędziem o określonych granicach zastosowania. Tam, gdzie dane są bogate i problem powtarzalny, potrafi błyszczeć. Tam, gdzie pojawia się nowość, ryzyko lub konieczność formalnego potwierdzenia, nadal potrzebne są badania fizyczne i doświadczenie ekspertów. Można powiedzieć, że sztuczna inteligencja świetnie pływa w znanych wodach, ale gdy zaczyna się sztorm albo nieoznaczona mapa, warto mieć na pokładzie człowieka i solidne laboratorium.

Model przyszłości: AI + laboratorium, nie AI zamiast laboratorium

Najbardziej realistyczny scenariusz rozwoju branży papierniczej nie polega na zastąpieniu laboratoriów algorytmami, lecz na ich ściślejszej współpracy. Sztuczna inteligencja i klasyczne testy reprezentują dwa różne typy przewagi. Laboratorium daje wiarygodność, kontakt z rzeczywistym materiałem i formalne potwierdzenie jakości. AI oferuje szybkość, zdolność analizy ogromnych zbiorów danych oraz prognozowanie zanim problem stanie się widoczny. Połączenie tych światów tworzy model znacznie silniejszy niż każdy z nich osobno. Szczególnie obiecujące są systemy łączące wiedzę mechaniczną, homogenizację materiału oraz algorytmy uczące się na danych produkcyjnych [7, 9]. Zestawienie najmocniejszych stron obu podejść pokazano na rysunku 3.


W takim układzie laboratorium pozostaje **źródłem prawdy referencyjnej**. To ono wykonuje badania ECT, BCT, SCT, Cobb czy inne testy zgodnie z normami, dostarczając danych o wysokiej jakości. Wyniki te nie tylko służą bieżącej kontroli, ale również stają się materiałem uczącym dla modeli AI. Można powiedzieć, że laboratorium wychowuje algorytm.

Sztuczna inteligencja przejmuje natomiast znaczną część **zadań rutynowych i predykcyjnych**. Zamiast badać każdą partię w pełnym zakresie, system może wskazywać, które partie są typowe i niskiego ryzyka, a które wymagają pilnej uwagi. Dzięki temu zasoby laboratoryjne można kierować tam, gdzie przynoszą największą wartość.

Drugim ważnym obszarem współpracy jest **wczesne ostrzeżenie**. Algorytm analizujący dane produkcyjne w czasie rzeczywistym może zauważyć symptomy pogorszenia jakości jeszcze przed pojawieniem się słabego wyniku testu. Laboratorium wchodzi wtedy do gry szybciej, wykonując badania potwierdzające i pomagając skorygować proces zanim problem urośnie.

Model hybrydowy sprawdza się także w **projektowaniu nowych opakowań**. AI może szybko przesiać wiele wariantów materiałowych i konstrukcyjnych, wskazując najbardziej obiecujące rozwiązania. Następnie laboratorium oraz testy fizyczne potwierdzają najlepsze opcje. To skraca czas rozwoju produktu i ogranicza liczbę kosztownych iteracji.

W przyszłości laboratoria mogą ewoluować w kierunku **centrów wiedzy procesowej**, a nie wyłącznie miejsc wykonywania testów. Oprócz aparatury pojawią się dashboardsy danych, modele predykcji-



Rys. 3. Komplementarne kompetencje sztucznej inteligencji i klasycznego laboratorium w ocenie jakości tektury falistej

ne, analizy trendów, systemy ostrzegania i cyfrowe archiwa jakości. Diagnostyka będzie mniej reaktywna, a bardziej strategiczna.

Istotną korzyścią jest także **lepsze wykorzystanie kompetencji ludzi**. Specjaliści laboratoryjni zamiast poświęcać większość czasu na powtarzalne pomiary mogą koncentrować się na analizie przyczyn problemów, walidacji nowych materiałów, rozwoju metod badawczych i wspieraniu decyzji technologicznych. To przesunięcie od czynności manualnych ku wiedzy eksperckiej.

Nie oznacza to oczywiście prostego wdrożenia. Potrzebne będą dobre dane, integracja systemów IT, zaufanie do modeli oraz odpowiednie szkolenia personelu. Jednak kierunek wydaje się naturalny: mniej konfliktu między człowiekiem a algorytmem, więcej współpracy. Można powiedzieć, że laboratorium i AI nie są rywalami walczącymi o ten sam fotel. Są jak dwa skrzydła jednego samolotu. Jedno daje stabilność, drugie prędkość. Dopiero razem pozwalają wznieść jakość na wyższy poziom.

Barier wdrożenia

Choć wizja współpracy sztucznej inteligencji z laboratorium wydaje się logiczna i atrakcyjna, praktyczne wdrożenie takich rozwiązań rzadko bywa proste. W wielu przedsiębiorstwach przeszkodą nie jest brak algorytmów, lecz codzienna rzeczywistość organizacyjna, technologiczna i kulturowa. AI łatwiej zbudować na konferencyjnym

slajdzie niż na hali produkcyjnej (tabela 2). Praktyczne wdrożenia wymagają bowiem nie tylko samych modeli obliczeniowych, ale także wiarygodnych danych, integracji systemów oraz zaufania organizacji, co podkreślają doświadczenia opisane w literaturze [7].

Najczęściej wskazywaną barierą jest **jakość danych**. Wiele zakładów posiada ogromne ilości informacji, lecz są one rozproszone pomiędzy systemami ERP, arkuszami kalkulacyjnymi, raportami laboratoryjnymi, notatkami operatorów i lokalnymi bazami. Część danych ma różne formaty, część nie jest kompletna, a część trudno powiązać z konkretną partią produkcyjną. Model uczony na takim materiale może odziedziczyć chaos zamiast wiedzy.

Drugim problemem jest **brak ciągłości i standaryzacji pomiarów**. Jeśli metody badawcze, sposób opisu wyników lub procedury pobierania próbek zmieniały się w czasie, historyczne dane mogą być trudne do porównania. AI bardzo lubi konsekwencję, a przemysł bywa bardziej pragmatyczny niż uporządkowany.

Istotną przeszkodą pozostaje również **integracja systemów IT**. Dane produkcyjne mogą znajdować się w jednym środowisku, wyniki laboratoryjne w drugim, a reklamacje klientów w trzecim. Bez połączenia tych źródeł trudno budować modele widzące pełny obraz procesu. W praktyce więcej czasu zajmuje często spięcie danych niż samo trenowanie algorytmu.

Kolejna bariera ma charakter ludzki: **zaufanie do modeli**. Technolodzy i kierownicy produkcji chętnie korzystają z narzędzi, które



rozumieją. Jeśli system podaje rekomendację bez jasnego uzasadnienia, może budzić opór. Nikt nie chce podejmować kosztownych decyzji na podstawie cyfrowej wyroczni, która mówi „bo tak wyszło”.

Ważnym zagadnieniem są także **kompetencje kadrowe**. Skuteczne wdrożenie wymaga współpracy specjalistów od procesu papierniczego, laboratoriów, IT, analityki danych i zarządzania. Tymczasem te światy nie zawsze mówią tym samym językiem. Jeden zespół myśli w gramaturach, drugi w bazach danych, trzeci w budżetach.

Nie można pominąć kwestii **kosztów inwestycyjnych**. Czujniki, infrastruktura danych, integracja systemów, licencje oprogramowania, szkolenia oraz czas wdrożenia wymagają nakładów. Dla dużych grup przemysłowych może to być naturalna inwestycja strategiczna, dla mniejszych firm decyzja bywa trudniejsza.

Pojawia się również problem **utrzymania modeli w czasie**. Nawet dobry algorytm starzeje się, jeśli zmieniają się surowce, dostawcy, park maszynowy lub portfolio produktów. Model wymaga okresowej aktualizacji, monitoringu jakości predykcji i ponownego uczenia. AI nie jest urządzeniem typu „kup i zapomnij”.

Mimo tych trudności większość barier ma charakter przejściowy. Dane stają się coraz lepiej zbierane, systemy informatyczne dojrzewają, a narzędzia analityczne są coraz bardziej dostępne. Firmy, które zaczną porządkować fundamenty już dziś, jutro będą gotowe na szybszy start. Można powiedzieć, że największą przeszkodą dla AI nie jest brak inteligencji maszyn, lecz bałagan ludzi. Gdy procesy zostaną uporządkowane, algorytmy zwykle znajdują drogę do pracy.

Czy branża jest gotowa?

Pytanie o gotowość branży papierniczej na wdrożenie sztucznej inteligencji nie ma jednej uniwersalnej odpowiedzi. Sektor opakowań z tektury falistej jest zróżnicowany pod względem skali działania, poziomu automatyzacji, dojrzałości cyfrowej oraz kultury organizacyjnej. Oznacza to, że dla jednych przedsiębiorstw AI jest naturalnym kolejnym krokiem, a dla innych nadal odległą perspektywą.

Najlepiej przygotowane są zwykle **duże zakłady produkcyjne i międzynarodowe grupy kapitałowe**. Dysponują one rozbudowanymi systemami ERP i MES, własnymi laboratoriami, wysokim poziomem automatyzacji oraz znaczną liczbą danych historycznych. Mają także zasoby finansowe pozwalające inwestować w cyfryzację,

integrację systemów i zespoły analityczne. W ich przypadku wdrożenie AI może szybko przynieść wymierne korzyści w postaci redukcji strat, szybszego projektowania i lepszego wykorzystania surowców.

W korzystnej sytuacji znajdują się również firmy średniej wielkości, które są **bardziej elastyczne organizacyjnie**. Choć często dysponują mniejszym budżetem, potrafią szybciej podejmować decyzje i wdrażać zmiany bez rozbudowanej biurokracji. Jeśli posiadają dobrze uporządkowane dane i otwartość kadry zarządzającej, mogą stać się zaskakująco skutecznymi pionierami.

Większym wyzwaniem może być transformacja w przedsiębiorstwach, gdzie dominują **rozproszone procesy, niski poziom cyfryzacji i tradycyjny model zarządzania**. Tam sztuczna inteligencja bywa postrzegana jako modny dodatek zamiast narzędzia biznesowego. W takich warunkach wdrożenie powinno zaczynać się nie od algorytmów, lecz od uporządkowania danych, procedur i odpowiedzialności.

Warto zauważyć, że gotowość branży nie zależy wyłącznie od technologii. Kluczowe znaczenie ma **mentalność organizacji**. Firmy otwarte na eksperymenty, analizę danych i kulturę ciągłego doskonalenia zwykle szybciej adaptują nowe rozwiązania. Tam, gdzie decyzje opierają się wyłącznie na przyzwyczajeniu, nawet najlepsze narzędzia mogą pozostać niewykorzystane.

Coraz silniejszym impulsem do zmian jest także **presja rynkowa**. Klienci oczekują krótszych terminów realizacji, stabilnej jakości, lżejszych opakowań i konkurencyjnych cen. Jednocześnie rosną wymagania środowiskowe oraz potrzeba raportowania efektywności materiałowej. AI może stać się odpowiedzią na te oczekiwania, ponieważ pomaga podejmować decyzje szybciej i precyzyjniej.

Istotnym czynnikiem będzie również **pokolenie nowych specjalistów** wchodzących do branży. Inżynierowie i technolodzy coraz częściej poruszają się swobodnie zarówno w świecie procesów produkcyjnych, jak i danych. To oni mogą stać się pomostem między tradycyjnym papiernictwem a cyfrową przyszłością.

Najbardziej prawdopodobny scenariusz na najbliższe lata to nie rewolucja, lecz **ewolucja etapami**. Najpierw pojawią się systemy wspierające kontrolę jakości, później predykcja parametrów, następnie optymalizacja produkcji i bardziej zaawansowane modele decyzyjne. Branża nie musi przeskoczyć całej drogi jednym skokiem. Można więc stwierdzić, że branża papiernicza jest gotowa częściowo, nierównomiernie i coraz bardziej. Nie wszyscy startują z tej samej

Tabela 2. Najczęściej spotykane bariery wdrażania systemów sztucznej inteligencji w przedsiębiorstwach sektora papierniczego wraz z przykładowymi sposobami ich ograniczania

Bariera	Opis	Możliwe rozwiązanie
Jakość danych	Braki, niespójność, ręczne wpisy	Standaryzacja danych
Integracja IT	Oddzielne systemy produkcji i laboratoriów	Połączenie baz/API
Zaufanie personelu	Obawa przed automatyzacją	Model wspierający decyzje
Koszt wdrożenia	Czujniki, IT, integracja	Pilotaż etapowy
Starzenie modelu	Zmiany surowców i procesu	Ciągłe douczanie modeli
Cyberbezpieczeństwo	Ryzyko utraty danych	Polityki bezpieczeństwa



linii, ale kierunek jest już wyraźny. Ci, którzy ruszą wcześniej, mogą zamienić dane w przewagę konkurencyjną, zanim inni zaczną dopiero porządkować archiwa.

Wnioski

Sztuczna inteligencja staje się jednym z najważniejszych kierunków rozwoju współczesnego przemysłu, a branża papiernicza nie pozostaje poza tym procesem. W sektorze opakowań z tektury falistej rośnie liczba danych dotyczących surowców, parametrów produkcji, wyników badań laboratoryjnych oraz jakości wyrobów w praktyce logistycznej. Dane te tworzą naturalny fundament do budowy narzędzi analitycznych wspierających podejmowanie decyzji technologicznych.

Przeprowadzona analiza wskazuje, że AI może już dziś skutecznie wspomagać prognozowanie parametrów takich jak ECT czy BCT, wykrywanie anomalii jakościowych, optymalizację doboru papierów oraz monitoring procesów produkcyjnych w czasie rzeczywistym. Potwierdzają to zarówno badania stricte predykcyjne, jak i prace dotyczące mechanicznych podstaw zachowania tektury [1, 6]. W zastosowaniach rutynowych, powtarzalnych i bogatych w dane algorytmy mogą znacząco skrócić czas reakcji oraz ograniczyć liczbę części badań wykonywanych tradycyjnie.

Jednocześnie sztuczna inteligencja posiada wyraźne granice zastosowania. Certyfikacja jakości, walidacja nowych konstrukcji, ocena nietypowych problemów technologicznych czy formalne rozstrzyganie sporów nadal wymagają klasycznych badań laboratoryjnych. Laboratorium pozostaje źródłem referencyjnej wiedzy o materiale, którego nie zastąpi sama predykcja statystyczna.

Najbardziej realistycznym kierunkiem rozwoju nie jest więc model „AI zamiast laboratorium”, lecz **AI razem z laboratorium**. Podobne podejście hybrydowe wskazywane jest jako naturalny kierunek rozwoju nowoczesnych systemów jakości [7]. Klasyczne testy dostarczają wiarygodnych danych, a algorytmy przekształcają je w szybsze prognozy, systemy ostrzegania i narzędzia optymalizacyjne. Takie podejście pozwala lepiej wykorzystać zarówno aparaturę badawczą, jak i kompetencje specjalistów.

Największym wyzwaniem wdrożeniowym pozostają obecnie nie same algorytmy, lecz jakość danych, integracja systemów informatycznych, kompetencje kadrowe oraz zaufanie organizacji do nowych metod pracy. Firmy, które wcześniej uporządkują te fundamenty, będą mogły szybciej korzystać z przewag płynących z cyfryzacji.

Można więc odpowiedzieć na pytanie zawarte w tytule w sposób wyważony: **nie, sztuczna inteligencja nie zastąpi klasycznych testów tektury całkowicie, ale zdecydowanie zmieni sposób ich wykonywania i znaczenie laboratoriów w przyszłości**. Równolegle rozwój geometrii materiałów, modeli homogenizacyjnych oraz analizy

uszkodzeń będzie poszerzał zakres zastosowań narzędzi cyfrowych [8-10]. Testów może być mniej, lecz będą lepiej zaplanowane, bardziej celowe i silniej wspierane danymi.

Laboratorium przyszłości prawdopodobnie nie zniknie. Zamiast tego stanie się mądrzejsze, szybsze i bardziej cyfrowe.

Artykuł recenzowany

LITERATURA

- [1] Biancolini M.E. 2005. "Evaluation of equivalent stiffness properties of corrugated board". *Composite Structures* 69 (3) : 322-328. DOI: 10.1016/j.compstruct.2004.07.014.
- [2] Biancolini M.E., Brutti C. 2003. "Numerical and experimental investigation of the strength of corrugated board packages". *Packaging Technology and Science* 16 (2) : 47-60. DOI: 10.1002/pts.609.
- [3] Cornaggia A., Gajewski T., Knitter-Piątkowska A., Garbowski T. 2023. "Influence of humidity and temperature on mechanical properties of corrugated board - numerical investigation". *BioResources* 18 (4) : 7490-7509. DOI: 10.15376/biores.18.4.7490-7509.
- [4] Di Russo F., Desole M., Gisario A., Genovesi A., Barletta M. 2024. "Study and design of corrugated cardboard trays with microwaves by experimental analysis (EA) and finite element methods (FEM)". *Packaging Technology and Science* 37 (9) : 857-874. DOI: 10.1002/pts.2827.
- [5] Gajewski T., Garbowski T., Staszak N., Kuca M. 2021. "Crushing of double-walled corrugated board and its influence on the load capacity of various boxes". *Energies* 14 (14) : 4321. DOI: 10.3390/en14144321.
- [6] Gajewski T., Grabski J.K., Cornaggia A., Garbowski T. 2024. "On the use of artificial intelligence in predicting the compressive strength of various cardboard packaging". *Packaging Technology and Science* 37 (2) : 97-105. DOI: 10.1002/pts.2783.
- [7] Garbowski T. 2024. "Revolutionizing corrugated board production and optimization with artificial intelligence". *BioResources* 19 (2) : 2003-2006. DOI: 10.15376/biores.19.2.2003-2006.
- [8] Garbowski T. 2025. "Exploring the future of novel flute shapes and their mechanical benefits". *BioResources* 20 (2) : 2483-2486. DOI: 10.15376/biores.20.2.2483-2486.
- [9] Garbowski T., Gajewski T. 2021. "Determination of transverse shear stiffness of sandwich panels with a corrugated core by numerical homogenization". *Materials* 14 (8) : 1976. DOI: 10.3390/ma14081976.
- [10] Garbowski T., Gajewski T., Mrówczyński D., Jędrzejczak R. 2021. "Crushing of single-walled corrugated board during converting: Experimental and numerical study". *Energies* 14 (11) : 3203. DOI: 10.3390/en14113203.
- [11] Garbowski T. 2023. "Zastosowanie sztucznej inteligencji do optymalizacji produkcji tektury falistej"/The use of artificial intelligence for the optimal production of corrugated board. *Przegląd Papierniczy* 79 (5) : 279-288. DOI: 10.15199/54.2023.5.2.