

Sławomir ORZECOWSKI<sup>1</sup>, Maciej MICHALAK<sup>2</sup>, Jakub BANAS<sup>3</sup>

Opiekun naukowy: Paweł ZIOBRO<sup>4</sup> Dorota WIĘCEK<sup>5</sup>

## UCZENIE MASZYNOWE I KORZYŚCI ZASTOSOWANIA W PRZEMYŚLE PRODUKCYJNYM

**Streszczenie:** W artykule przedstawiono techniki uczenia maszynowego. Zaprezentowano cele i wykorzystanie sztucznej inteligencji w produkcji. Opisano w jaki sposób można ulepszyć procesy produkcyjne. Podano efekty szybszej analiza danych. Przedstawiono korzyści diagnostyki i monitorowania maszyn produkcyjnych i opisano optymalizację obrabiarki, narzędzia skrawającego i warunków obróbki.

**Słowa kluczowe:** uczenie maszynowe, zastosowanie, przemysł produkcyjny

## MACHINE LEARNING - BENEFITS OF APPLICATION IN THE PRODUCTION INDUSTRY

**Summary:** In the list of technical solutions for used machines. The goals presented and the use of artificial intelligence in production. Described how to improve production processes. The effects of faster data analysis are given. Benefits of diagnostics and monitoring of production machines were presented and optimization of the machine tool, cutting tool and machining conditions was described.

**Keywords:** machine learning, application, manufacturing industry

### 1. Wprowadzenie

Uczenie maszynowe to gorący temat w przemyśle i badaniach, a nowe metodologie są cały czas opracowywane: regresja, klasyfikacja, grupowanie, redukcja wymiarów, metody zespołowe, sieci neuronowe i głębokie uczenie się, uczenie

---

<sup>1</sup> Akademia Techniczno-Humanistyczna w Bielsku-Białej, Wydział Budowy Maszyn i Informatyki, Inżynieria Zarządzania Produkcją, slawomir.orzechowski.95@gmail.com

<sup>2</sup> Akademia Techniczno-Humanistyczna w Bielsku-Białej, Wydział Budowy Maszyn i Informatyki, Inżynieria Zarządzania Produkcją, maciek9559@gmail.com

<sup>3</sup> Akademia Techniczno-Humanistyczna w Bielsku-Białej, Wydział Budowy Maszyn i Informatyki, Inżynieria Zarządzania Produkcją, banaskuba@interia.pl

<sup>4</sup> Właściciel firmy ZPT Paweł Ziobro, pawel.ziobro@zp-team.pl

<sup>5</sup> dr inż., Akademia Techniczno-Humanistyczna w Bielsku-Białej, Wydział Budowy Maszyn i Informatyki, dwiecek@ath.bielsko.pl

transferowe, nauka przez wzmocnienie, przetwarzanie języka naturalnego, osadzenie słów [1]. To zaledwie kilka przykładów metod uczenia maszynowego. Szybkość i złożoność tej dziedziny sprawia, że nadążanie za nowymi technikami jest trudne nawet dla ekspertów, nie mówiąc o początkujących. Aby wyjaśnić, a raczej trochę przybliżyć pojęcie jakim jest uczenie maszynowe umieszczam krótką definicję. Uczenie maszynowe to nauka polegająca na zmuszaniu komputerów do uczenia się i działania tak, jak robią to ludzie, oraz doskonalenia ich uczenia się w czasie w sposób autonomiczny, poprzez dostarczanie im danych i informacji w formie obserwacji i interakcji w świecie rzeczywistym[2].

## 2. Podstawowe pojęcia uczenia maszynowego

Istnieje ogromna ilość różnych rodzajów algorytmów uczenia maszynowego, z setkami publikowanymi każdego dnia i są one z reguły pogrupowane według stylu uczenia się (tj. uczenia nadzorowanego, uczenia bez nadzoru, uczenia częściowo nadzorowanego), podobieństwa w formie albo funkcji (tj. regresja, klasyfikacja, drzewo decyzyjne, głębokie uczenie się, grupowanie itp.). Wszystkie kombinacje algorytmów uczenia maszynowego niezależnie od funkcji lub stylu uczenia się obejmują: reprezentację, ocenę i optymalizację (Tabela 1).

Tabela 1. Trzy elementy algorytmów uczenia się [2]

Reprezentacja	Ocena	Optymalizacja
zestaw klasyfikatorów lub język zrozumiały dla komputera	inaczej funkcja celu/punktacji	metoda wyszukiwania; często na przykład klasyfikator o najwyższym wyniku; istnieją zarówno gotowe metody optymalizacji, jak i niestandardowe

Jeśli chodzi o podstawowy cel algorytmów uczenia maszynowego to jest to uogólnienie poza próbki szkoleniowe, tj. z powodzeniem interpretuje dane, których wcześniej jeszcze nie widział.

Ponadczasowym celem produkcyjnym jest wytwarzanie produktów wysokiej jakości przy minimalnych kosztach. Teraz Fabryka 4.0 demonstruje swoją wartość, umożliwiając producentom osiągnięcie tej misji bardziej niż kiedykolwiek, a jedną z podstawowych technologii napędzających tę nową falę ultra-automatyzacji jest uczenie maszynowe i sztuczna inteligencja.

Dane stały się cennym zasobem. Przechowywanie i ich przechwytywanie jest tańsze niż kiedykolwiek. Dzięki zastosowaniu sztucznej inteligencji, w szczególności opartego na procesach uczenia maszynowego, producenci mogą wykorzystywać dane, aby z korzyścią wpłynąć na swoje wyniki finansowe poprawiając jakość produktów, wydajność produkcji i bezpieczeństwo pracowników.

Uczenie maszynowe można podzielić przede wszystkim na dwie główne techniki - uczenie maszynowe nadzorowane i bez nadzoru.

## 2.1. Nadzorowane uczenie maszynowe

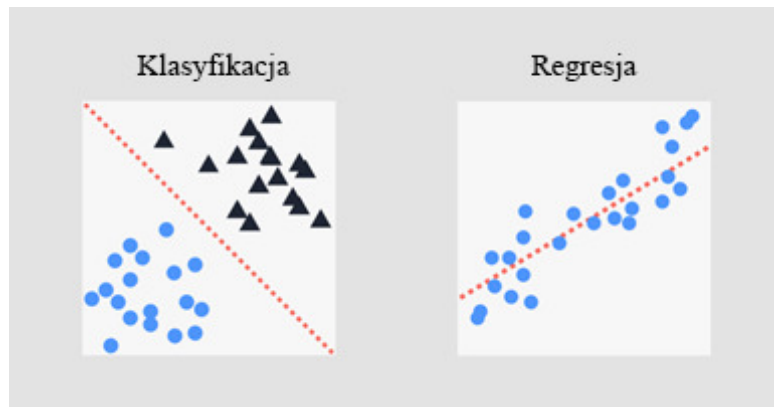
Uczenie maszynowe nadzorowane w użyciu mając na myśli produkcję jest najczęściej stosowaną techniką, ponieważ prowadzi do predefiniowanego celu: mamy dane wejściowe, wyjściowe i chcemy zmapować funkcję łączącą obie zmienne. Nadzorowane uczenie maszynowe wymaga ogromnego poziomu zaangażowania - wprowadzania danych, definiowania i wyboru algorytmów, szkolenia danych, wizualizacji danych itd. Cel to zbudowanie funkcji mapowania z poziomem dokładności, który pozwala przewidywać wyniki, gdy nowe dane wejściowe są wprowadzane do systemu.

Na początku algorytm jest zasilany ze zbioru danych szkoleniowych, a w późniejszych etapach poprzez iteracje stale poprawia swoją wydajność dążąc do osiągnięcia satysfakcjonującego wyniku. Proces uczenia kończy się, gdy algorytm osiąga akceptowalny poziom dokładności. W produkcji jednym z najpotężniejszych przypadków użycia uczenia maszynowego jest konserwacja predykcyjna, którą można wykonać przy użyciu dwóch podejść do uczenia nadzorowanego: klasyfikacji i regresji. Te dwa podejścia mają ten sam cel: odwzorowanie związku między danymi wejściowymi (z procesu produkcyjnego), a danymi wyjściowymi (znane możliwe wyniki, takie jak awaria części, przegrzanie itp.)[3].

Pierwszym podejściem do uczenia nadzorowanego jest klasyfikacja. Klasyfikację można zastosować jeśli dane istnieją w ściśle określonych kategoriach. Algorytm filtrowania wiadomości e-mail jest przykładem znanej klasyfikacji. Decyduje on o tym czy wiadomość e-mail powinna zostać wysłana do naszego folderu ze spamem, czy nie. Klasyfikacja ogranicza się do odpowiedzi wartości logicznej, ale może być bardzo przydatna, bo do uzyskania wysokiego poziomu dokładności potrzeba niewielkiej ilości danych. Konserwacja predykcyjna wykorzystuje klasyfikację wielu klas, ponieważ istnieje wiele możliwych przyczyn awarii komponentów lub maszyn. Są to możliwe wyniki, które zostały sklasyfikowane jako potencjalne problemy ze sprzętem, obliczone przy użyciu wielu zmiennych, w tym stanu maszyn, realnych przyczyn nieprawidłowego działania i poziomów ryzyka.

Drugim podejściem do uczenia nadzorowanego jest regresja wykorzystywana, gdy dane istnieją w rozpiętości (np. temperatura, waga), co często ma miejsce w przypadku danych zebranych z czujników. W produkcji można wykorzystać regresję

do obliczenia, oszacowania pozostałego okresu użytkowania zasobu (RUL). To prognoza tego, ile cykli czy dni mamy przed awarią następczej maszyny/komponentu/systemu. Regresja liniowa jest najczęściej stosowanym algorytmem uczenia maszynowego w przypadku regresji. Jest on dość szybki i prosty do wdrożenia, a wyniki łatwe do interpretacji. Ze względu na to, że temperatura jest wartością ciągłą z oszacowaniem, które można łatwo wytrenować to przykładem regresji liniowej mógłby być system przewidujący jej wysokość (Rysunek 1).



Rysunek 1. Klasyfikacja i regresja.[3]

## 2.2. Uczenie maszynowe bez nadzoru

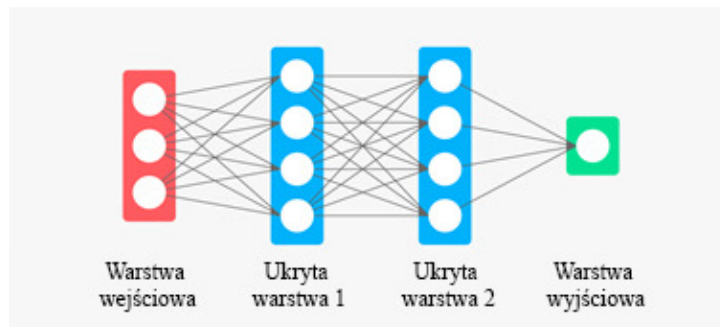
Uczenie maszynowe z nadzorem pozwala rozpocząć od pracy z oczekiwanym rezultatem i odpowiednio szkolić algorytm. Natomiast brak nadzoru jest odpowiednie w przypadkach, gdy wynik nie jest jeszcze znany.

Jeśli chodzi o metodę grupowania to w niektórych przypadkach nie będzie znany zarówno wynik, jak i informacje opisujące dane (etykiety danych). Tworząc klastry punktów danych wejściowych, które mają konkretne atrybuty, algorytm może wykryć wzorce bazowe.

Grupowanie można także wykorzystać w celu zmniejszenia szumu (nieistotne parametry w danych) w przypadku ogromnej liczby zmiennych.

Drugą metodą w technice uczeniu bez nadzoru są sztuczne sieci neuronowe. Sztuczne sieci neuronowe w sektorze produkcyjnym okazują się niezwykle skutecznym narzędziem uczenia się bez nadzoru do różnorodnych zastosowań, w tym do predykcyjnej analizy jakości i symulacji procesów produkcyjnych.

Ludzki mózg przetwarza informacje za pomocą swojej sieci około 100 miliardów neuronów. Struktura Sztucznej Sieci Neuronowej działa podobnie, a to pozwala na niezwykle złożone i wszechstronne rozwiązywanie problemów (Rysunek 2).



*Rysunek 2. Podstawowy schemat sprężonej sztucznej sieci neuronowej. Każdy węzeł w jednej warstwie jest połączony z każdym węzłem w następnym. W zależności od złożoności problemu można dodawać ukryte warstwy.[3]*

Zdolność do przetwarzania tak dużej liczby parametrów umożliwia sztucznym sieciom neuronowym przydatność w produkcji. Są one bowiem idealne dla bogatych w zmienne i ciągle zmieniających się procesów. Ponadto, Sztuczna Sieć Neuronowa po odpowiednim przeszkoleniu, może wykazywać wysoki poziom dokładności umożliwiając obniżenie kosztów surowców poprzez tworzenie prognoz dotyczących właściwości mechanicznych przetwarzanych produktów

### 3. Konserwacja predykcyjna z uczeniem maszynowym

Uczenie maszynowe może dostarczyć znacznie bardziej precyzyjnych i co ważne ewoluujących zaleceń dotyczących konserwacji, aby pomóc kierowcom w ochronie inwestycji w pojazdach oraz bezpieczeństwu. Zamiast aktualizowanego kilka razy w roku statycznego harmonogramu konserwacji zastosować model analizy predykcyjnej. Może on uczyć się na podstawie tysięcy punktów danych dotyczących wydajności zebranych od usługodawców, dostawców, zakładów produkcyjnych, a także rzeczywistych pojazdów na drodze. Branża jest na dobrej drodze do całkowicie spersonalizowanych ciągle ewoluujących z biegiem czasu harmonogramów konserwacji. Dąży się do tego by były one coraz bardziej dostosowane do indywidualnych kierowców i pojazdów, a nawet do zmieniających się warunków i nowych informacji o wydajności.

Konserwacja predykcyjna pomaga zwiększyć reputację marki i satysfakcję klienta, jak również poprawia zgodność z zalecaną konserwacją. Jako usługa o wartości dodanej może być też źródłem dodatkowych dochodów dla producentów samochodów. Te same technologie umożliwiają konserwację predykcyjną zarządzania flotą, chroniąc zwrot z inwestycji w każdym pojeździe i oszczędzając na większych naprawach. Konserwacja predykcyjna może też pomóc utrzymać systemy produkcyjne na optymalnym poziomie wydajności pomagając zapewnić jakość i bezpieczeństwo, chroniąc wydajność jednocześnie oszczędzając czas i pieniądze.

Konserwacja to znacząca część kosztów każdej operacji produkcyjnej. Stała się ona zatem wspólnym celem producentów oferując im wiele korzyści, w tym znaczne ograniczenie wpływu sześciu dużych strat. Tradycyjnie robiono to z wykorzystaniem systemów SCADA skonfigurowanych z progami kodowanymi przez człowieka, konfiguracjami i regułami alarmowymi. To półautomatyczne podejście nie bierze pod

uwagę danych kontekstowych dotyczących całego procesu produkcyjnego ani bardziej złożonych dynamicznych wzorców zachowań maszyny. Przykładem może tutaj być czujnik w maszynie produkcyjnej wykrywający nagły wzrost temperatury. System statyczny oparty na regułach nie bierze pod uwagę faktu, iż maszyna przechodzi sterylizację i w rezultacie uruchamia alarm fałszywie dodatni. W przeciwieństwie do algorytmów uczenia maszynowego podawane są dane OT (z hali produkcyjnej: sterowniki PLC, czujniki, SCADA), dane IT (dane kontekstowe: MES, ERP, jakość itp.) jak również informacje o procesie produkcyjnym opisujące synchronizację między tempem przepływu produkcji i maszyną.

Proces znany jako „szkolenie” w sztucznej inteligencji umożliwia algorytmom ML testowanie korelacji podczas wyszukiwania wzorców w różnorodnych źródłach danych i wykrywanie anomalii. Siłą uczenia maszynowego jest zdolności do analizowania bardzo dużych ilości danych w czasie rzeczywistym co daje możliwość proponowania praktycznych odpowiedzi na pojawiające się problemy. Zachowanie i stan każdego systemu i zasobu są stale oceniane, pogorszenie komponentów jest identyfikowane przed awarią, a spostrzeżenia wizualizowane na cyfrowym bliźniaku.

Uczenie maszynowe dzięki zoptymalizowanym harmonogramom konserwacji i zapobieganiu awariom służy do ograniczenia nieplanowanych przestoju.

#### **4. Kontrola i analiza jakości za pomocą uczenia maszynowego**

Wykrywanie anomalii i rozpoznawanie obrazu to rodzaje algorytmów uczenia maszynowego, które mogą szybko wykrywać, a następnie eliminować wadliwe części nim trafią do obiegu produkcyjnego. Aby zidentyfikować wszelkie wady producenci części mogą przechwytywać obrazy każdego komponentu opuszczającego linię montażową i automatycznie odtwarzać je a wszystko dzięki modelowi uczenia maszynowego. Super dokładne algorytmy wykrywania anomalii mogą wykrywać problemy nawet z ułamkiem milimetra, a analizy predykcyjne można wykorzystać do oceny, czy wadliwą część należy złomować czy można ją jeszcze przerobić. Przerabianie wadliwych części lub ich eliminacja w tym momencie jest znacznie mniej kosztowna niż wykrywanie i konieczność ich późniejszej naprawy. Oszczędzić można tutaj na droższych problemach związanych z produkcją i zmniejsza się ryzyko wycofań które są kosztowne. Pomaga także zapewnić satysfakcję i utrzymanie klienta oraz bezpieczeństwo.

Aby wdrożyć model rozpoznawania obrazów i analizy, producent potrzebuje dokładny zestaw danych zawierający setki, a nawet tysiące zdjęć części, z których każdy jest oznaczony takimi informacjami, jak: niepowodzenie, zaliczenie, wydanie A /B/C itp. Osoba zajmująca się tworzeniem modelu musi posiadać specjalistyczną wiedzę

w zakresie potencjalnego wpływu różnych wad na działanie i bezpieczeństwo oraz dopuszczalnych tolerancji. To samo podejście można zastosować do wszystkich elementów produkcji, a także do całej linii montażowej pojazdu. Modele rozpoznawania obrazu i analizy mogą odgrywać wiele ról w całym łańcuchu wartości w branży motoryzacyjnej - na przykład rozpoznawanie i ocena niewielkich różnic w wzorach zużycia bieżnika, aby pomóc w opracowaniu nowych i wydajniejszych opon, zapewniając kontrolę jakości lakieru i innych wykończeń oraz uzdolnienie zaawansowanych systemów wspomagania kierowcy (ADAS) i autonomicznych systemów jazdy. Z tego powodu wiele organizacji zdałoby sobie sprawę z większej

wartości z platformy do analizy danych w przedsiębiorstwie, niż z punktowego rozwiązania zaprojektowanego dla pojedynczego przypadku użycia.[4]

Jakość produkcji ma kluczowe znaczenie, a dzięki uczeniu maszynowemu pogorszenie jakości produktu można przewidzieć. Wiedza o tym, że jakość wytwarzanych detali spadnie jest bardzo ważna, ponieważ można temu w porę zapobiec. W ten sposób nie marnuje się surowców i oszczędza się cenny czas produkcji.

Z punktu widzenia produkcji zdolność do skutecznej analizy i przechwytywania dużych zbiorów danych może poprawić tradycyjne systemy jakości i wydajności. Podstawowym celem analizy i generowania dużych zbiorów danych w aplikacjach przemysłowych jest osiągnięcie bezawaryjnych (wolnych od wad) procesów wykorzystując inteligentne systemy kontroli nadzorczej. Strategia procesu uczenia się (LP) i rozpoznawania wzorców (PR) dla ISCS opartego na wiedzy (KB), ma na celu wykrycie rzadkich zdarzeń jakościowych z systemów produkcyjnych[8].

Aby zwiększyć zdolność przewidywania klasyfikatora i skrócić czas szkolenia, zestaw danych został wstępnie przetworzony w dwuetapowym podejściu: (1) algorytm ReliefF zastosowano do wyeliminowania nieistotnych cech i (2) zastosowano algorytm HCR w celu wyeliminowania zbędnych funkcji. Proponowane podejście można dostosować i szeroko zastosować w procesach produkcyjnych w celu zwiększenia wydajności tradycyjnych metod jakości oraz potencjalnie przesunąć standardy jakości do przodu.

## **5. Przełomowe zalety uczenia maszynowego i sztucznej inteligencji w produkcji**

Co godzinę około 1 TB danych jest wytwarzanych przez producentów samochodów w branży motoryzacyjnej, a ich liczba rośnie do 1 GB w przyszłości w samochodach z napędem własnym w każdej sekundzie[5]. Z racji tego przemysł motoryzacyjny intensywnie szuka metod do obsługi i analizy tej ogromnej ilości danych. Wprowadzenie uczenia maszynowego i sztucznej inteligencji do przemysłu to ogromna zmiana. Korzyści jakie można dzięki temu osiągnąć wykraczają poza poprawę wydajności i otwierają drzwi do nowych możliwości.

W obszarach takich jak produkcja lub logistyka proponowane są rozwiązania w celu poprawy konserwacji maszyn (poprzez zastosowanie modeli konserwacji predykcyjnej i sensoryzacji) lub wydajności dystrybucji (na przykład poprzez optymalizację korelacji między potrzebami transportowymi wielu przedsiębiorstw)[9].

Korzyści uczenia maszynowego w produkcji to:

- Wykorzystanie konserwacji predykcyjnej do redukcji kosztów co prowadzi do mniejszej liczby czynności konserwacyjnych, a to oznacza niższe koszty pracy, marnotrawstwa materiałów i zmniejszenie zapasów.
- Przewidywanie pozostałego okresu użytkowania (RUL). Wiedza o zachowaniu urządzeń i maszyn daje możliwość do stworzenia warunków, które zachowują ich kondycję, a poprawiając wydajność. Prognozowanie RUL eliminuje nieplanowane przestoje, które powodują „nieprzyjemne niespodzianki”.
- Lepsze sterowanie łańcuchem dostaw przez dobrze monitorowany i zsynchronizowany przepływ produkcji i wydajne zarządzanie zapasami.

- Ulepszona kontrola jakości z praktycznymi spostrzeżeniami, aby stale podnosić jakość produktu.
- Poprawiona współpraca człowiek-robot, która zwiększa bezpieczeństwo pracowników i poprawia ogólną wydajność
- Produkcja zorientowana na konsumenta – w momencie zmiany popytu na rynku daje możliwość szybkiej reakcji

Jeśli chodzi o ulepszenia procesów i produktów w całym łańcuchu wartości w branży motoryzacyjnej i nie tylko to uczenie maszynowe ma niesamowity potencjał.

## 6. Analiza przyczyny pierwotnej

Gdy pojawia się problem w jakimś momencie cyklu życia produktu – nie ważne czy jest to coś znalezionego na wczesnym etapie procesu produkcyjnego, czy problem dotyczy wielu pojazdów w terenie - organizacje starają się ustalić sposób jego rozwiązania i dokładną przyczynę. Stawka to reputacja marki, a nawet bezpieczeństwo konsumenta.

Identyfikacja pierwotnej przyczyny problemu podczas fazy produkcyjnej to długi i żmudny proces. Analiza przyczyn pierwotnych wykorzystuje ogromne ilości danych testowych, parametry producenta, pomiary czujników i wiele innych. Niezwykle trudny, gdy jest wykonywany tradycyjnymi metodami.

Analiza przyczyn pierwotnych problemów w terenie wcale nie jest łatwiejsza. Dzisiejsze pojazdy są bardzo złożone, a co kierowca to unikalne czynności konserwacyjne, warunki jazdy i zachowanie.

Coś co może konkretnie przyspieszyć analizę przyczyn źródłowych i szybkość ich rozwiązywania to techniki uczenia maszynowego. Algorytmy wykrywania anomalii mogą efektywnie analizować olbrzymie ilości danych systemowych i sterowników. W porównaniu z tradycyjnymi metodami mogą przeprowadzać analizę przy użyciu dodatkowych typów danych i w znacznie większych ilościach.

Na przykład na etapie produkcji wykorzystanie zapisanego obrazu jako danych wejściowych do analizy pierwotnych przyczyn pomaga organizacjom zsynchronizować tryby awarii z możliwymi wadami w podstawowych procedurach produkcyjnych.

W przypadku problemów pojawiających się w terenie rozpoznawanie i przetwarzanie tekstu w języku naturalnym umożliwiają usługodawcy włączenie notatek

do procesu analizy. Każde z tych podejść może ujawnić konkretne przyczyny pierwotne o kilka miesięcy wcześniej niż analiza tradycyjna, a ponadto często diagnozuje problemy, których w żaden inny sposób nie można odkryć.

## 7. Diagnostyka i monitorowanie stanu maszyn

Rośnie zainteresowanie opracowywaniem nowych technologii w celu przewyższenia problemów w monitorowaniu stanu i diagnostyce złożonych zastosowań maszyn przemysłowych, które dotychczas nie zostały rozwiązane. Daje to doskonałe możliwości ciągłego rozwoju technologii sztucznej inteligencji z szybkim wzrostem inteligentnych informacji, czujników i możliwości akwizycji



danych, w połączeniu z szybkim postępem w technikach inteligentnego przetwarzania sygnałów.

Obecnie rośnie zapotrzebowanie na zaawansowane narzędzia analizy. Uczeni badali wykrywanie i diagnostykę wielu usterek stosując różne metody.

Niektóre mają zdolność reagowania na wzorce wejściowe w pożądanym sposobie po fazie uczenia się. Wcześniejsze badania wykazały, że ich wydajność może przewidywać wady procesów obróbki. Okazuje się to bardzo przydatne, ponieważ może być stosowane w automatyce przemysłowej w bardziej elastyczny sposób. Zastosowanie to diagnostyka zdrowotna przekładni mechanicznych, łożysk i maszyn wirujących przez wykorzystanie większej ilości funkcji z sygnałów wibracyjnych, a mniej z sygnałów akustycznych.

Inne modele były skuteczne w przewidywaniu grubości filmu olejowego na podstawie sygnału emisji akustycznej i temperatury, a ta sugerowana technika osiągnęła 99,9% sukcesu w prognozowaniu i klasyfikacji przy dużej prędkości podczas treningu. Architektura i topologia sieci poprzez określone systemy mogą być wykorzystane do monitorowania online grubości filmu olejowego i do przewidywania wszelkich przyczyn awarii działania przekładni czołowej[6].

## 8. Obrabiarka, narzędzie skrawające i warunki obróbki

Duże zbiory danych charakteryzują się dużą różnorodnością, dużą objętością i dużą prędkością. W przypadku obróbki skrawaniem obrabiarki związane są z ich strukturami, błędami i sztywnością. Narzędzie tnące obejmuje geometrie narzędzia, materiał z jakiego został zrobiony oraz dopasowanie geometrii do materiału. Warunki obróbki obejmują rodzaje chłodziwa, parametry cięcia, położenie narzędzia i jego mocowanie. Czynniki wydajności związane z siłą, ciepłem i odkształcaniem podczas obróbki obejmują dynamikę obróbki, kontrolę wiórów, zużycie narzędzia i pęknięcie. Końcowe części są również sprawdzane pod względem jakości i dokładności. Biorąc pod uwagę złożoność obróbki, dane w tym procesie mają ogromne rozmiary. Procesy obróbki są ściśle powiązane ze stanami obrabiarki i narzędzia skrawającego. Zbieranie danych w czasie rzeczywistym jest potrzebne do monitorowania procesów obróbki, a regularna aktualizacja danych jest też niezbędna do korekty stanu obrabiarki[7].

Na wydajność, jakość i koszt produkcji wpływa wybór obrabiarki, narzędzia skrawającego i określenie warunków obróbki. Proponowana metoda polega na rozwiązaniu problemu optymalizacji obróbki z perspektywy dużych zbiorów danych, w której wszystkie zasoby obróbki są uważane za wyczerpujące. W konwencjonalnych sposobach optymalizacji obrabiarka, narzędzie skrawające i warunki obróbki są ustalane osobno, a to może prowadzić do nieoptymalnych lub kompromisowych rozwiązań. Zaproponowana koncepcja oparta na analizie dużych zbiorów danych łączy optymalizację tych trzech elementów jako całość. Każdy zasób obróbki jest reprezentowany przez atrybuty danych, co umożliwia wydobycie wzorców między zasobami za pomocą algorytmów uczenia maszynowego. Hybrydowy algorytm pozwala optymalnie dobrać obrabiarkę i narzędzie skrawające biorąc pod uwagę również warunki obróbki.

**LITERATURA**

1. Strona internetowa korporacji Medium <https://towardsdatascience.com/10-machine-learning-methods-that-every-data-scientist-should-know-3cc96e0eee9>, 31.10.2019.
2. Strona internetowa firmy Emerj <https://emerj.com/ai-glossary-terms/what-is-machine-learning/>, 30.10.2019.
3. Strona internetowa firmy Seebo <https://www.seebo.com/machine-learning-ai-manufacturing/>, 30.10.2019.
4. Strona internetowa firmy Anaconda <https://www.anaconda.com/4-machine-learning-use-cases-automotive/>, 31.10.2019.
5. MEINZER S., JENSEN U., THAMM A., HORNEGGER J., ESKOFIER BJÖRN M.: Can machine learning techniques predict customer dissatisfaction? A feasibility study for the automotive industry. *Badania sztucznej inteligencji* s.80.
6. YASIR HASSAN A.: Artificial Intelligence Application in Machine Condition Monitoring and Fault Diagnosis. 2018.
7. JI WEI, YIN SHUBIN, WANG LIHUI: A big data analytics based machining optimisation approach, 2018.
8. ESCOBAR CARLOS A., MORALES-MENENDEZ R.: Machine learning techniques for quality control in high conformance manufacturing environment, 2018.
9. CALVO J., GUZMÁN A.M., RAMOS D.: Machine Learning, a key component in business model transformation., 2018.