

ANDRZEJ KAMIŃSKI¹

Analiza i ocena możliwości zastosowania systemów inteligentnych w diagnostyce procesów przemysłowych

1. Wstęp

W artykule zostały omówione zagadnienia syntezy różnych metod, technik i narzędzi sztucznej inteligencji w celu komputerowego wspomagania procedur diagnostycznych. W ujęciu szczegółowym, przedstawiono: analizę wybranych regulacji dotyczących diagnostyki procesów przemysłowych, ocenę możliwości zastosowania systemów eksperckich oraz sztucznych sieci neuronowych we współczesnym ekosystemie produkcyjnym oraz przykłady praktycznych rozwiązań aplikacyjnych.

Rozwój nowoczesnej produkcji oznacza stały wzrost jej złożoności, który przejawia się w rosnącej różnorodności technologii wytwarzania, wdrażaniu innowacji technicznych oraz ciągłej modernizacji i automatyzacji linii produkcyjnych. Diagnostyka przemysłowa jest integralną częścią tego procesu.

Termin diagnoza w odniesieniu do funkcji zarządzania przedsiębiorstwem przemysłowym definiowany jest jako proces „rozpoznawania i osądzania stanu funkcjonowania danego przedsiębiorstwa na podstawie aktualnych prawidłowości i zasad określonych dziedzin wiedzy”². Badania i diagnostyka maszyn, urządzeń technicznych i stanowisk pracy to integralny element procesu zarządzania przedsiębiorstwem przemysłowym w zakresie szeroko rozumianej inżynierii produkcji, technologii wytwarzania, organizacji linii produkcyjnych, a także normowania i wartościowania stanowisk pracy.

Diagnostyka techniczna definiowana jest jako dziedzina obejmująca całokształt zagadnień teoretycznych i praktycznych związanych z obiektem technicznym, ujmowanym w otoczeniu, w jakim on występuje, w celu identyfikacji jego stanu³.

¹ Szkoła Główna Handlowa w Warszawie, Kolegium Analiz Ekonomicznych, Instytut Informatyki i Gospodarki Cyfrowej.

² W. Jaworski, *Metoda diagnostyki przemysłowej*, WNT, Warszawa 1969.

³ PN-90-N-04002 – *Diagnostyka techniczna. Terminologia ogólna*.

Zastosowanie metod diagnostyki technicznej jest niezbędne w celu wczesnej identyfikacji powstających awarii i uszkodzeń oraz docelowo zapewnienia bezpiecznej, ekonomicznej i ekologicznej eksploatacji maszyn oraz urządzeń przemysłowych. Celem stosowania metod i technik diagnostyki technicznej jest możliwie wczesna detekcja usterki, co umożliwi zapewnienie wysokiego poziomu niezawodności i bezpieczeństwa złożonych systemów produkcyjnych⁴.

Wyróżniamy następujące główne typy powstawania awarii i uszkodzeń⁵:

- konstrukcyjne – uszkodzenia powstałe wskutek błędów projektowania i konstruowania obiektu, najczęściej przy nieuwzględnieniu obciążeń ekstremalnych, tzn. wartości, które w istotny sposób przekraczają obciążenia nominalne, prowadząc wprost do uszkodzeń;
- produkcyjne (technologiczne) – uszkodzenia powstałe wskutek błędów i niedokładności procesów technologicznych (brak tolerancji wymiarów, gładkości powierzchni, obróbki termicznej itp.) lub też będące wynikiem zastosowania wadliwych materiałów;
- eksploatacyjne – uszkodzenia powstałe w wyniku nieprzestrzegania obowiązujących zasad eksploatacji lub na skutek oddziaływań czynników zewnętrznych nieprzewidzianych dla warunków użytkowania danego obiektu, co prowadzi do osłabienia, przedwczesnego zużycia i osiągnięcia stanu granicznego;
- starzeniowe – uszkodzenia powstałe w wyniku produkcyjnej eksploatacji obiektów i będące rezultatem nieodwracalnych zmian prowadzących do pogorszenia wytrzymałości.

Zadaniem diagnostyki procesów przemysłowych jest wczesne wykrywanie i dokładne rozpoznawanie (rozdzielanie) powstających uszkodzeń, rozumianych jako wszelkiego rodzaju zdarzenia wpływające destrukcyjnie na przebieg procesu⁶. Podstawowymi technikami diagnostycznymi są detekcja i lokalizacja uszkodzeń. W fazie detekcji następuje pomiar poszczególnych wartości sygnałów diagnostycznych oraz określenie symptomów, które świadczą o powstaniu uszkodzenia w badanym komponencie technologicznym. W fazie lokalizacji, na podstawie analizy wartości sygnałów diagnostycznych identyfikowane jest miejsce powstałej awarii oraz określany jest zakres i poziom złożoności uszkodzeń.

⁴ J. Blata, J. Juraszek, *Metody diagnostyki technicznej teoria i praktyka*, VŠB – Technická univerzita Ostrava Fakulta strojní, Katedra výrobních strojů a konstruování, Ostrava 2013, s. 4.

⁵ B. Żółtowski, *Bezpieczeństwo systemów w ujęciu diagnostyki*, Miesięcznik naukowo-techniczny „Napędy i Sterowanie” 2011, nr 4, s. 83.

⁶ M. Kościelny, *Praktyczne problemy diagnostyki procesów przemysłowych*, „Pomiary Automatyka Robotyka” 2010, 2.

Zadania, jakie mogą być wspomagane w toku przeprowadzania tzw. diagnostyki przemysłowej, można sprowadzić co najmniej do sześciu podstawowych grup⁷.

1. Opracowanie wzorców określających stan pożądany (punkt odniesienia).
2. Ustalenie miejsc powstawania odchyłeń w diagnozowanym systemie.
3. Identyfikacja przyczyn odchylenia od stanu uznanego za normatywny.
4. Ocena, na ile szkodliwe („niebezpieczne”) są skutki odchyłeń badanego obiektu (grupy obiektów), w odniesieniu do funkcjonowania przedsiębiorstwa.
5. Rozstrzygnięcie, czy trzeba koniecznie reagować na powstałe odchylenia.
6. Wyznaczenie kierunków działań korygujących, prowadzących do usunięcia odchyłeń badanego obiektu (komponentu systemu).

Opracowanie i wdrożenie procedur diagnostycznych dotyczy pełnego cyklu życia obiektu technicznego. Procedury te powinny być stosowane na etapie opracowywania konstrukcji maszyny, testowania prototypu w warunkach laboratoryjnych, a następnie przemysłowej eksploatacji. Przystępując do opracowania procedur kontroli stanu maszyny oraz technik detekcji i lokalizacji uszkodzeń, należy w szczególności rozważyć⁸:

- 1) czy zbiór parametrów diagnostycznych jednoznacznie opisuje stan maszyny, czy jest skorelowany ze zmianą stanu maszyny, czy zawiera odpowiedni zakres informacji o stanie maszyny;
- 2) czy zbiór parametrów diagnostycznych jest stabilny, czy też wykazuje istotne zmiany, a jeżeli tak, to jaki jest charakter tych zmian w zależności od czynników wynikających z eksploatacji maszyn;
- 3) w jaki sposób na konstrukcję procedur kontroli stanu oraz techniki detekcji i lokalizacji uszkodzeń wpływają: podatność maszyn na uszkodzenia, organizacja postępowania diagnostycznego (w szczególności kompetencje i doświadczenie zawodowe ekspertów), zmienne warunki eksploatacji oraz zmienna niezawodność podzespołów maszyny.

Rolą informatycznego wsparcia w procesach diagnostyki przemysłowej jest detekcja i lokalizacja uszkodzeń, a następnie planowanie działań naprawczych. Realizacja powyższych zadań jest bardzo trudna ze względu na złożoność diagnozowanych systemów produkcyjnych. Systemy te złożone są z setek, a nawet tysięcy maszyn, urządzeń i stanowisk pracujących częstokroć w trudnych i zmiennych warunkach technologicznych i środowiskowych. Niewątpliwie złożoność

⁷ J. Gołuchowski, T. Kajstura, *Perspektywy konstruowania efektywnych strategii sterujących w zadaniach diagnozy ekonomicznej*, Business Information Systems'07, Poznań 2007.

⁸ H. Tylicki, *Metodyka wyznaczania procedury diagnozowania stanu maszyny*, „Diagnostyka” 2005, vol. 33, Olsztyn, s. 180.

procesów produkcyjnych przekłada się na stosunkowo dużą liczbę potencjalnych awarii i uszkodzeń. Zasadne jest podjęcie prac badawczych mających na celu opracowanie nowej generacji systemów sztucznej inteligencji na potrzeby współczesnej diagnostyki procesów przemysłowych.

2. Koncepcja zastosowania systemów inteligentnych w procesach diagnostyki przemysłowej

Badania przeprowadzone przez firmę doradczą McKinsey wskazują, że zastosowanie narzędzi sztucznej inteligencji w ekosystemie produkcji prowadzi do uzyskania licznych korzyści ekonomicznych. Przykładowo, zastosowanie nowej generacji algorytmów prognostycznych z wykorzystaniem technologii uczenia maszynowego umożliwia planowanie produkcji z uwzględnieniem przewidywanych trendów rynkowych. Wdrożenie wymienionej technologii przekłada się na uzyskanie realnych oszczędności – 65% redukcji kosztów związanych z opóźnieniami w procesie zaopatrzenia, przy jednoczesnej redukcji zapasów o 20–50%⁹.

Rozwój tej kategorii systemów wpisuje się w strategię „Europejska Agenda Cyfrowa”. Zgodnie z cytowanym dokumentem programowym, ważną rolę w rozwoju polskich przedsiębiorstw będzie odgrywać efektywne wykorzystanie technologii komputerowych, technik komunikacyjnych, a także inteligentnych systemów wspomagających zarządzanie produkcją przemysłową.

Obecny program badań Unii Europejskiej w dziedzinie ICT obejmuje dwa kluczowe obszary¹⁰.

1. Robotyka – badania przemysłowe i rozwój technologii w zakresie produkcji robotów oraz opracowania nowej kategorii usług w tym zakresie. Światowy rynek robotyki jest wart 15,5 mld euro rocznie. Rynek robotyki UE – 3 mld euro rocznie. Udział UE w światowym rynku robotyki przemysłowej wynosi 25%, a w sektorze robotyki usługowej – 50%.
2. Komponenty i systemy informatyczne – wsparcie dla elektroniki, systemów cyber-fizycznych, technologii obliczeniowych, inteligentnych systemów produkcji, systemów oświetleniowych, fotoniki i innych.

⁹ H. Bauer, M. Breunig, *Smartening up with Artificial Intelligence (AI) – What's in it for Germany and its Industrial Sector?*, McKinsey & Company, 2017, s. 9.

¹⁰ *Europejska Agenda Cyfrowa Luksemburg*, Urząd Publikacji Unii Europejskiej, 2014, s. 6.

Zastosowanie systemów inteligentnych może stanowić efektywną metodę komputerowego wsparcia procedur diagnostycznych w procesie sterowania produkcją, bezpieczeństwem i środowiskiem pracy. W dalszej części artykułu przedstawione zostaną możliwości praktycznego zastosowania systemów eksperckich oraz sztucznych sieci neuronowych w procesie diagnostyki przemysłowej. Wskazane zostaną zalety oraz ograniczenia wymienionych rozwiązań.

2.1. Systemy eksperckie

System ekspercki to program komputerowy, który w ściśle określonej dziedzinie sugeruje rozwiązania pewnych problemów w sposób tak kompetentny jak człowiek – ekspert, a przy tym może wyjaśniać zasady uzyskania tej ekspertyzy oraz korzystać z informacji, niedokładnych, niepełnych lub niepewnych zarówno numerycznych, jak i symbolicznych¹¹. Głównym celem projektowania systemów eksperckich jest rozwiązywanie problemów poprzez porównanie bieżącej sytuacji ze zgromadzoną i usystematyzowaną wiedzą ekspertów na temat problemu o podobnych symptomach, mającego miejsce w przeszłości oraz wnioskowanie, na tej podstawie, o możliwościach jego rozwiązania.

Istotny problem o charakterze ekonomiczno-społecznym stanowi proces budowy bazy wiedzy systemu eksperckiego. Akwizycja specjalistycznej wiedzy eksperckiej stanowi proces długotrwały oraz wiąże się ze znacznym nakładem środków finansowych. Osobny problem stanowi niepewność, niepełność i niedokładność pozyskanej wiedzy, potrzeba aktualizacji reguł wnioskowania oraz przede wszystkim – konieczność adaptacji systemu do zmiennych warunków otoczenia.

Systemy eksperckie nie znalazły dotychczas szerszego zastosowania w procesie komputerowego wspomaganie produkcji przemysłowej¹². Spowodowane jest to m.in. dynamiką oraz złożonością branży, co bezpośrednio przekłada się na problemy z akwizycją i aktualizacją baz wiedzy, ograniczonymi możliwościami tej kategorii systemów w zakresie automatycznej analizy dużych wolumenów danych przemysłowych, a także brakiem wsparcia bieżących procesów decyzyjnych związanych z organizacją i sterowaniem produkcją, diagnostyką obiektów technicznych oraz kontrolą jakości wyrobów.

¹¹ *Problemy sztucznej inteligencji*, W. Traczyk (red.), Wiedza i Życie, Warszawa 1995.

¹² G. Johnsen, *Expert Systems, Knowledge Systems – in Your Supply Chain Control Tower?*, Supply Chain Digest 2010, http://www.scdigest.com/assets/Experts/GTNexus_10-09-15.php (dostęp: 12.10.2018).

Należy zwrócić uwagę, że koncentracja uwagi projektantów systemów eksperckich na logice pierwszego stopnia (dwuwartościowej) oraz symbolicznym przetwarzaniu wiedzy nie pozwala na rozwiązywanie złożonych zadań natury inżyniersko-ekonomicznej, które wymagają stosowania metod matematycznych.

Generalnie, autonomiczność klasycznych systemów eksperckich, złożoność baz wiedzy oraz specyfika metod, technik i języków programowania stanowią naturalne przeszkody uniemożliwiające szersze ich zastosowanie w przemyśle.

2.2. Sztuczne sieci neuronowe

Alternatywnym rozwiązaniem jest zastosowanie systemów uczenia maszynowego z wykorzystaniem sztucznych sieci neuronowych.

Sieć neuronowa to system przeznaczony do przetwarzania informacji, którego budowa i zasada działania są w pewnym stopniu wzorowane na funkcjonowaniu fragmentów rzeczywistego (biologicznego) systemu nerwowego. Najbardziej znaną cechą sieci neuronowej jest jej zdolność uczenia się na podstawie przykładów i możliwość automatycznego uogólniania zdobytej wiedzy (generalizacja)¹³.

Sieć neuronowa składa się z dużej liczby (od kilkuset do kilkudziesięciu tysięcy) jednostek elementarnych (neuronów) przetwarzających informację. Neurony są powiązane w sieć za pomocą połączeń o parametrach (tak zwanych wagach) modyfikowanych w trakcie procesu uczenia. Topologia połączeń oraz ich parametry determinują algorytm działania sieci, zaś sygnały pojawiające się na jej wyjściach, w odpowiedzi na określone sygnały wejściowe, są rozwiązaniami stawianych jej zadań¹⁴. Innymi słowy, proces uczenia sieci neuronowej polega na automatycznym wyznaczeniu wartości odpowiednich wag w możliwie najkrótszym czasie. Wagi w sieciach neuronowych wskazują, w jakim stopniu dany neuron kształtuje wynik w każdej z warstw. Waga mieści się w przedziale $\langle 0, 1 \rangle$. Neurony o wadze 0 są „martwe” i nie mają wpływu na wynik. Proces uczenia przebiega w sposób iteracyjny, jest powtarzany aż do momentu znalezienia przez sieć możliwie najlepszego rozwiązania określonego zdania algorytmicznego.

Wyróżniamy metodę uczenia nadzorowanego (ang. *supervised learning*) oraz uczenia nienadzorowanego (ang. *unsupervised learning*). Metoda uczenia

¹³ R. Tadeusiewicz, M. Szaleniec, *Leksykon sieci neuronowych*, Wydawnictwo Fundacji „Projekt Nauka”, Wrocław 2015.

¹⁴ R. Tadeusiewicz, *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993, s. 13.

nadzorowanego jest stosowana, gdy istnieje możliwość weryfikacji poprawności rozwiązań wyznaczonych przez sieć neuronową. Oznacza to, że dla każdego wektora wejściowego jest znana odpowiednia wartość wektora wyjściowego (wzorec rozwiązania). Z kolei uczenie nienadzorowane stosowane jest, gdy nie znamy dokładnego, a nawet przybliżonego rozwiązania¹⁵.

Sieci neuronowe znajdują zastosowanie w obszarach: rozpoznawania obrazów, analizie danych medycznych, ekstrakcji sygnałów dźwiękowych, prognozowaniu długookresowych trendów rynkowych, a także inteligentnego sterowania autonomicznymi robotami przemysłowymi.

Zastosowanie technologii sztucznych sieci neuronowych stwarza możliwość automatyzacji procesu akwizycji wiedzy (tzw. mechanizm trenowania sieci). Sieci neuronowe odznaczają się tolerancją na nieciągłości, przypadkowe zaburzenia lub wręcz braki w zbiorze danych trenujących, przygotowanym na potrzeby procesu uczenia.

Kosztym tego rozwiązania jest istotne ograniczenie w zakresie interpretacji uzyskanych wyników – wyjaśnienie proponowanego rozwiązania jest trudne lub wręcz niemożliwe.

Można zatem wnioskować, że integracja w obrębie szeroko rozumianej sztucznej inteligencji stwarza możliwość wzajemnego uzupełniania i pełniejszego wykorzystania różnych metod. W kolejnym rozdziale zostanie podjęta próba udowodnienia tezy, że projektowanie i implementacja współczesnych systemów diagnostyki procesów przemysłowych mogą być efektywnie realizowane na drodze integracji różnych metod i technik sztucznej inteligencji.

3. Integracja w obszarze systemów sztucznej inteligencji

W badaniach związanych z rozwojem inteligentnych systemów diagnostyki przemysłowej można umownie wyróżnić dwa zasadnicze kierunki prac.

1. Badania związane z integracją kilku metod i technik sztucznej inteligencji – system ekspercki + sieć neuronowa, np. system ekspercki może przejmować dane wychodzące z sieci neuronowej i przedstawiać (na podstawie posiadanej bazy wiedzy) rozszerzony opis badanego zjawiska.

¹⁵ A. Mestres, *Knowledge-Defined Networking*, „ACM SIGCOMM Computer Communication Review” 2017, vol. 47, s. 3.

Przykładowo, tej kategorii rozwiązania aplikacyjne mogą znaleźć liczne zastosowania w przemyśle spożywczym, m.in. w przedsiębiorstwie będącym producentem warzyw i owoców. W modelowym przedsiębiorstwie proces sortowania warzyw i owoców, pakowania i spedycji odbywa się w pełni automatycznie. System zdalnie sterowanych linii produkcyjnych umożliwia pełną automatyzację operacji sortowania, mycia i pakowania produktów, natomiast operacje pomocnicze związane z załadunkiem realizowane są przez roboty przemysłowe. Z kolei zintegrowany system informatyczny klasy MES/SCADA sprawuje pełną kontrolę nad prawidłowym przebiegiem procesów produkcyjnych i logistycznych. Jednakże należy zwrócić uwagę, że klasyczne pakiety MES/SCADA oferują wsparcie na poziomie operacyjnym w zakresie: planowania i optymalizacji produkcji, monitorowania i nadzoru nad realizacją procesów głównych i pomocniczych, a także wizualizacji i raportowania.

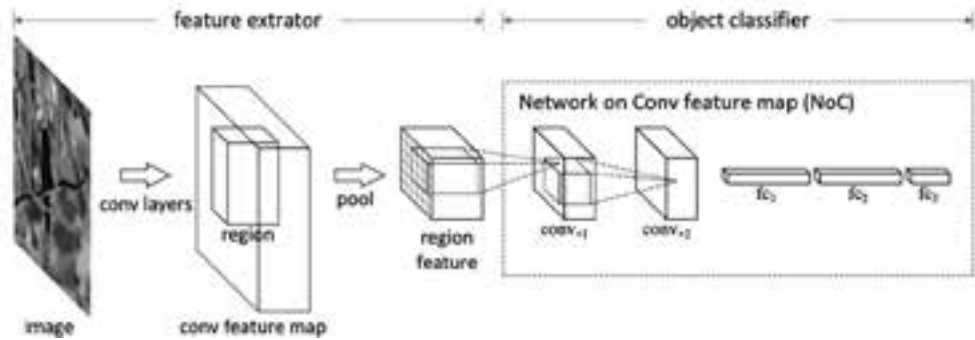
W badanym przedsiębiorstwie tzw. wąskim gardłem w procesie produkcyjnym jest kontrola jakości wyrobów spożywczych. Istotny problem stanowi ocena jakości produktów spożywczych, ich klasyfikacja na podstawie cech fizycznych (m.in. kształt, rozmiar, kolor) oraz wykrywanie produktów nieprzydatnych do spożycia.

Specyfika i złożoność procesu kontroli jakości produktów spożywczych wymaga zastosowania rozwiązań łączących możliwość automatycznego rozpoznawania cech fizycznych badanych obiektów oraz odpowiedniej klasyfikacji produktów na podstawie uprzednio zdefiniowanych reguł decyzyjnych. W tym celu zasadne jest opracowanie rozwiązania łączącego technologię konwolucyjnej sieci neuronowej oraz systemu eksperckiego.

Konwolucyjna sieć neuronowa będzie umożliwiła automatyczne rozpoznawanie obrazu. Ideą sieci konwolucyjnych jest wyuczenie parametrów filtru (cech) bądź zestawu filtrów, które najlepiej wyekstrahują informacje z analizowanego obrazu. Warstwa łącząca (ang. *pool*) służy do progresywnej redukcji rozmiaru przestrzennego obiektu, a tym samym ograniczenia liczby cech oraz złożoności sieci. W uproszczeniu, proces rozpoznawania obrazu inicjuje wyodrębnienie badanego obiektu z tła na podstawie wykrycia jego krawędzi. Następnie wykrywane są proste kształty geometryczne. W kolejnych iteracjach identyfikowane i klasyfikowane są złożone elementy, których prawidłowe rozpoznanie i scale nie prowadzi do osiągnięcia rezultatu badania (rysunek 1).

Istotną rolę w procesie uczenia sieci neuronowej odgrywa jakość oraz ilość ukierunkowanych danych trenujących. Przykładowo, praktyczne zastosowanie technologii konwolucyjnych sieci neuronowych w badaniu detekcji

twarzy wymagało przygotowania zbioru 12 880 zdjęć, na których pojawiało się 15 942 różnych twarzy¹⁶.



Rysunek 1. Model konwolucyjnej sieci neuronowej

Źródło: S. Ren, K. He, R. Girshick, X. Zhang, J. Sun, *Object Detection Networks on Convolutional Feature Maps*, IEEE Transactions on Pattern Analysis and Machine Intelligence 2017, vol. 39, s. 2.

W omawianym przykładzie, technologię sztucznych sieci neuronowych można efektywnie zastosować na potrzeby identyfikacji i rozpoznawania fizycznych cech badanych produktów spożywczych. Klasyfikacja produktu, analiza i ocena walorów jakościowych oraz określenie dalszego przeznaczenia wymaga zastosowania wiedzy eksperckiej z dziedziny technologii spożywczej. System ekspercki umożliwi automatyzację procesu wnioskowania na podstawie uprzednio opracowanych baz wiedzy oraz reguł wnioskowania. Należy podkreślić, że bazy wiedzy powinny być na bieżąco aktualizowane na podstawie norm, katalogów oraz innych dokumentów branżowych.

Konkludując powyższe rozważania, można powiedzieć, że ocena jakościowa badanego produktu spożywczego wymaga rozpoznania i identyfikacji określonych symptomów diagnostycznych (sieć neuronowa), a następnie inteligentnej analizy i oceny wybranych cech na podstawie sformalizowanych reguł wnioskowania (system ekspercki).

2. Badania związane z integracją systemów inżynierii wiedzy oraz systemów wspomagających wielowymiarową analizę danych gospodarczych (Business Intelligence) – interpretacja wskaźników oraz porównanie uzyskanych wyników (określenie odchyłeń i dystansu) z innymi podobnymi przedsiębiorstwami lub stanem uznanym za normatywny.

¹⁶ H. Jiang, E. Learned-Miller, *Face Detection with the Faster R-CNN*, University of Massachusetts, 2016, s. 2.

Przykładowo, w procesach diagnostyki przemysłowej może zostać efektywnie wdrożone rozwiązanie bazujące na technologii systemów eksperckich oraz aplikacji klasy Business Intelligence.

Misją systemu wspomagającego procedury diagnostyki procesów przemysłowych jest analiza i ocena poziomu jakości maszyn, urządzeń technicznych i stanowisk pracy, badanie związków przyczynowo-skutkowych w skali zakładu, wydziału, przedsiębiorstwa, rekomendacja działań modernizacyjno-korygujących oraz planowanie średnio- i długookresowych przeglądów, napraw i remontów.

Badania przemysłowe związane z opracowaniem koncepcji, założeń funkcjonalnych, architektury technicznej oraz implementacji prototypu oprogramowania komputerowego zostały zrealizowane w ramach projektu POIG.01.03.01-14-059/12.

Komputeryzacja procedur diagnostycznych w przedsiębiorstwie jest niewątpliwie w pełni ekonomicznie uzasadniona. Jednakże zastosowanie klasycznych metod diagnostyki technicznej w większości znanych przypadków sprowadza się do obliczenia wskaźników oraz graficznej prezentacji wyników. Rozwiązanie alternatywne może stanowić zastosowanie technologii systemów eksperckich w konstrukcji systemów informatycznych wspomagających realizację procedur diagnostycznych.

Na potrzeby opracowania wielowymiarowego systemu informacji diagnostycznej została wykorzystana platforma Business Intelligence. Istotą proponowanego rozwiązania jest transformacja statycznych wolumenów danych diagnostycznych pochodzących z list kontrolnych, formularzy i arkuszy ocen na model wielowymiarowy, umożliwiający ich przetwarzanie, analizę i prezentację w ujęciu dynamicznym w odniesieniu do uprzednio zdefiniowanej struktury przedsiębiorstwa przemysłowego. Przykładowo, rozwiązanie to umożliwia określenie wymiernych, ekonomicznych strat wynikających z absencji chorobowej, spowodowanej niekorzystnymi warunkami pracy (hałas, oświetlenie, mikroklimat).

W procesie komputerowego wspomaganie analizy danych przemysłowych moduł ekspercki można efektywnie zastosować w celu uzyskania rozszerzonego opisu badanego zjawiska. Moduł ekspercki umożliwi: sformułowanie oceny jakościowej (słownej) dla obliczonych agregatów (wartości statystycznych oraz wskaźników przemysłowych), interpretację znaczenia, identyfikację powiązań i zależności pomiędzy różnymi kategoriami danych przemysłowych (na podstawie informacji uzyskanej na drodze dialogu systemu eksperckiego z użytkownikiem) oraz rozszerzony opis wpływu badanych parametrów technologicznych i środowiskowych na funkcjonowanie procesu produkcyjnego.

4. Podsumowanie

Badania przemysłowe związane z rozwojem systemów sztucznej inteligencji wpisują się w strategię Przemysł 4.0. Strategia ta dotyczy bowiem informatyzacji procesów produkcyjnych z wykorzystaniem rozwiązań bazujących na autonomicznych robotach przemysłowych, a także zautomatyzowanych liniach produkcyjnych i centrach obróbczych monitorowanych i nadzorowanych za pomocą inteligentnych systemów sterujących.

W artykule zostały przedstawione rezultaty programu badań przemysłowych, których celem było praktyczne zastosowanie i integracja systemów eksperckich, sztucznych sieci neuronowych oraz technologii Business Intelligence na potrzeby współczesnej diagnostyki przemysłowej. Niewątpliwie rozwiązania te cechuje zwiększony potencjał intelektualny, ponieważ korzystają one z pozytywnych właściwości każdego z wymienionych narzędzi. Stają się przy tym bardziej autonomicznymi, adaptacyjnymi i bardziej wiarygodnymi przez możliwość doskonalenia i korygowania wiedzy.

Bibliografia

- Bauer H., Breunig M., *Smartening up with Artificial Intelligence (AI) – What’s in it for Germany and its Industrial Sector?*, McKinsey & Company, 2017.
- Błata J., Juraszek J., *Metody diagnostyki technicznej teoria i praktyka*, VŠB – Technická univerzita Ostrava Fakulta strojní, Katedra výrobních strojů a konstruování, Ostrava 2013.
- Europejska Agenda Cyfrowa*, Luksemburg Urząd Publikacji Unii Europejskiej, 2014.
- Gołuchowski J., Kajstura T., *Perspektywy konstruowania efektywnych strategii sterujących w zadaniach diagnozy ekonomicznej*, Business Information Systems’07, Poznań 2007.
- Jaworski W., *Metoda diagnostyki przemysłowej*, WNT, Warszawa 1969.
- Jiang H., Learned-Miller E., *Face Detection with the Faster R-CNN*, University of Massachusetts, 2016.
- Johnsen G., *Expert Systems, Knowledge Systems – in Your Supply Chain Control Tower?*, Supply Chain Digest 2010, http://www.scdigest.com/assets/Experts/GTNexus_10-09-15.php (dostęp: 12.10.2018).
- Kościelny M., *Praktyczne problemy diagnostyki procesów przemysłowych*, „Pomiary Automatyka Robotyka” 2010, 2.

Mestres, *Knowledge-Defined Networking*, „ACM SIGCOMM Computer Communication Review” 2017, vol. 47.

PN-90-N-04002 – *Diagnostyka techniczna. Terminologia ogólna*.

Problemy sztucznej inteligencji, W. Traczyk (red.), Wiedza i Życie, Warszawa 1995.

Ren S., He K., Girshick R., Zhang X., Sun J., *Object Detection Networks on Convolutional Feature Maps*, IEEE Transactions on Pattern Analysis and Machine Intelligence 2017, vol. 39.

Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa 1993.

Tadeusiewicz R., Szaleniec M., *Leksykon sieci neuronowych*, Wydawnictwo Fundacji „Projekt Nauka”, Wrocław 2015.

Tylicki H., *Metodyka wyznaczania procedury diagnozowania stanu maszyn*, „Diagnostyka” 2005, vol. 33.

Żółtowski B., *Bezpieczeństwo systemów w ujęciu diagnostyki*, Miesięcznik naukowo-techniczny „Napędy i Sterowanie” 2011, nr 4.

* * *

Analysis and evaluation of using intelligent systems in the diagnosis of industrial processes

Abstract

The article presents the concept of synthesis of various methods, techniques and tools of artificial intelligence on the example of an integrated information system project supporting multicriteria diagnostics of technical objects. The theoretical considerations are illustrated by two practical examples. The first example presents a solution that integrates an expert system and a neural network to support the process of recognizing and assessing the quality of food products. The second concerns the concept of integration of expert systems and Business Intelligence for the needs of analysis and assessment of the quality level of machines, equipment and workplaces. The article was prepared basing on the results of project POIG.01.03.01–14–059/12.

Keywords: Industry 4.0, industrial diagnosis, expert systems, neural networks, Business Intelligence