

WYKORZYSTANIE SZTUCZNEJ INTELIGENCJI W APLIKACJI ET INSPEKTOR



MGR INŻ. BARTŁOMIEJ SIEDMIOGRODZKI

Specjalista Urzędzeń Ciśnieniowych
Oddział w Łodzi
Urząd Dozoru Technicznego



MGR INŻ. EWELINA MALCZYK-KUŚMIERCZYK

Starszy Inspektor Urzędzeń Ciśnieniowych
Oddział w Łodzi
Urząd Dozoru Technicznego



MGR INŻ. MATEUSZ KULESZA

Specjalista Urzędzeń Ciśnieniowych
Oddział w Łodzi
Urząd Dozoru Technicznego

Kolejna publikacja nawiązująca do systemów sztucznej inteligencji (AI, Artificial Intelligence) z innej perspektywy pokazuje jej rozwój i obecne możliwości wykorzystania. Również na wstępie przypominamy początki jej rozwoju, a następnie wskazujemy jak algorytmy AI mogą pomóc w diagnozowaniu problemów w czasie rzeczywistym oraz przewidywaniu awarii w przemyśle.

Autorska aplikacja ET Inspektor wspomaga ocenę stanu technicznego urządzeń kluczową przy modernizacjach i inwestycjach. Algorytmy AI w aplikacji ET Inspektor dostarczają cennych informacji o pracy urządzeń.


Sztuczna inteligencja (AI) odgrywa coraz większą rolę w różnych sektorach przemysłu, przynosząc innowacje i zwiększając efektywność. Zastosowanie AI obejmuje szeroki zakres działań, od automatyzacji procesów produkcyjnych po zaawansowaną analizę danych, co pozwala firmom na lepsze zarządzanie zasobami i zwiększenie konkurencyjności na rynku. Co najważniejsze, AI staje się ważnym elementem w poprawie bezpieczeństwa w różnych sektorach przemysłu.

Sztuczna inteligencja może być klasyfikowana na różne sposoby, w zależności od jej zdolności, zakresu zastosowań i poziomu zaawansowania. Powszechnie przyjmuje się podział na sztuczną inteligencję wąską, ogólną i superinteligencję.

Obecnie znajdujemy się na etapie rozwoju wąskiej sztucznej inteligencji (ANI), która jest zaprojektowana do wykonywania konkretnych, wyspecjalizowanych zadań. Inteligencja taka nie posiada samoświadomości ani zdolności do generalizowania wiedzy poza swoje wąsko zdefiniowane zadanie.

SZTUCZNA INTELIGENCJA KIEDYŚ A DZIŚ

Sztuczna inteligencja początkowo znalazła swoje zastosowanie w przemyśle do opracowywania systemów eksperckich. Systemy te były projektowane do symulowania decyzji podejmowanych przez ludzkich ekspertów, co pozwalało na automatyzację diagnostyki technicznej oraz optymalizację procesów produkcyjnych.



Rys. 1. Oś czasu – rozwój sztucznej inteligencji w przemyśle

Pierwotnie AI bazowała głównie na systemach opartych na regułach t.j. programiści ręcznie definiowali zbiór reguł i warunków, według których komputer mógł podejmować decyzje. Jednak obecnie dominujące są podejścia oparte na danych, co oznacza, że algorytmy AI uczą się na podstawie dużej ilości danych wejściowych. Zmiana ta nastąpiła wskutek kilku czynników niżej wymienionych.

```

while (istnieje reguła, którą można zastosować do bieżącej wiedzy) do
    wybierz regułę;
    wykonaj regułę;
    uaktualnij wiedzę;
end
  
```

Rys. 1. Cykl silnika wnioskowania systemu eksperckiego jako przykład systemu opartego na regułach

CZYNNIKI, KTÓRE WPŁYNĘŁY NA ZMIANĘ I ROZWÓJ SYSTEM AI
<ul style="list-style-type: none"> • ZŁOŻONOŚĆ PROBLEMÓW <p>Zadania, które stawiane są przed AI, stają się coraz bardziej skomplikowane. Regułowe podejścia mogą okazać się niewystarczające, aby dokładnie i efektywnie rozwiązywać tak złożone problemy.</p>
<ul style="list-style-type: none"> • DOSTĘPNOŚĆ DANYCH <p>Wraz z rozwojem technologii internetowej i cyfrowej gromadzenie, przechowywanie i udostępnianie danych stało się znacznie łatwiejsze. Istnieje teraz ogromna ilość danych dostępnych dla algorytmów AI do nauki.</p>
<ul style="list-style-type: none"> • POSTĘP W ALGORYTMACH UCZENIA MASZYNOWEGO <p>W ostatnich latach dokonał się znaczny postęp w algorytmach uczenia maszynowego, które pozwalają na efektywne wykorzystanie dużych zbiorów danych do uczenia się wzorców i podejmowania decyzji.</p>
<ul style="list-style-type: none"> • ELASTYCZNOŚĆ I SKALOWALNOŚĆ <p>Algorytmy oparte na danych są zwykle bardziej elastyczne i skalowalne niż podejścia oparte na regułach. Mogą one dostosowywać się do zmieniających się warunków i sytuacji oraz obsługiwać duże ilości danych.</p>
<ul style="list-style-type: none"> • EFEKTYWNOŚĆ I DOKŁADNOŚĆ <p>W wielu przypadkach podejścia oparte na danych wykazują wyższą efektywność i dokładność w porównaniu do tradycyjnych metod opartych na regułach.</p>

W dekadzie 2010–2020 AI oparta na danych stała się integralną częścią Przemysłu 4.0, automatyzując i optymalizując całe linie produkcyjne oraz wspierając zrównoważony rozwój. Dzisiaj AI jest kluczowym elementem cyfrowej transformacji przemysłu, zwiększając wydajność, redukując koszty i poprawiając jakość produktów.

SKĄD WZIĄŁ SIĘ BOOM W DZIEDZINIE AI?

Boom w dziedzinie sztucznej inteligencji obserwowany w ostatnich latach wynika z kilku kluczowych czynników, które współdziałając, stworzyły idealne warunki dla dynamicznego rozwoju tej technologii. Główne powody tego fenomenu można ująć w kilku grupach czynników od indywidualnych, przez inżynierskie, społeczne, finansowe, aż po gospodarcze oraz inwestycyjne. Nie sposób tu pominąć wątków bezpieczeństwa.

Wzrost mocy obliczeniowej

Dostęp do zaawansowanych procesorów i jednostek przetwarzania graficznego (GPU) znacząco zwiększył możliwości obliczeniowe, co jest kluczowe dla trenowania skomplikowanych modeli AI. Rozwój chmury obliczeniowej umożliwił również firmom i badaczom dostęp do tych zasobów bez konieczności inwestowania w drogie infrastruktury.

Dostępność. dużych zbiorów danych

W erze cyfrowej ilość generowanych danych wzrosła eksponencjalnie, dostarczając „paliwa” dla algorytmów AI. Dane te pozwalają na trenowanie modeli z większą dokładnością i w różnych dziedzinach, od rozpoznawania mowy po przetwarzanie języka naturalnego.

Postępy w badaniach nad AI

W ostatnich latach dokonano znaczących przełomów w dziedzinie uczenia maszynowego i głębokiego uczenia, co pozwoliło na rozwój bardziej zaawansowanych i efektywnych algorytmów. Publikacje otwartego dostępu i współpraca między naukowcami przyspieszyły ten postęp.

Rozwój aplikacji i usług opartych na AI

Szeroka gama aplikacji, od rozpoznawania obrazu i przetwarzania języka naturalnego po autonomiczne pojazdy i personalizowane rekomendacje, pokazała potencjalne korzyści płynące z implementacji AI. To zwiększyło popyt na rozwiązania AI w różnych sektorach gospodarki.

Świadomość społeczna i kulturowa

Szerzenie wiedzy na temat AI i jej potencjalnych zastosowań w mediach, edukacji i popkulturze zwiększyło świadomość i akceptację technologii w społeczeństwie.

Globalizacja i cyfryzacja

Globalizacja i cyfryzacja biznesu i życia codziennego stworzyły zapotrzebowanie na automatyzację i inteligentne systemy zdolne do przetwarzania i analizy danych na dużą skalę. AI jest kluczową technologią umożliwiającą taką transformację.

Společno - polityczne i gospodarcze motywacje

Kraje i regiony na całym świecie rozpoznały strategiczne znaczenie AI dla przyszłego wzrostu gospodarczego i bezpieczeństwa narodowego. To skłoniło rządy do zwiększenia wsparcia dla badań nad AI oraz kształcenia specjalistów w tej dziedzinie.

Zwiększone finansowanie i inwestycje

Wzrost zainteresowania AI zarówno w sektorze publicznym, jak i prywatnym, przyciągnął znaczne inwestycje. Start-upy i duże korporacje inwestują miliardy dolarów w badania i rozwój technologii AI, co dodatkowo napędza innowacje.

W kontekście przyszłości AI w przemyśle oczekuje się dalszego postępu w integracji sztucznej inteligencji z nanotechnologią, biotechnologią i materiałoznawstwem, co będzie miało przełomowy wpływ na energetykę i wiele innych dziedzin przemysłowych. Te zaawansowane technologie mogą prowadzić do odkryć, które zmienią sposób, w jaki podchodzimy do zarządzania zasobami energetycznymi i produkcji materiałów.

Sztuczna inteligencja umożliwia tworzenie zaawansowanych systemów automatyzacji, które mogą wykonywać skomplikowane zadania z większą precyzją i efektywnością niż ludzie. Obejmuje to wszystkie procesy, od produkcji po logistykę. Dzięki temu możliwe jest wykonywanie złożonych operacji przy mniejszym ryzyku błędów i niższych kosztach. Algorytmy sztucznej inteligencji mogą analizować dane produkcyjne w czasie rzeczywistym, przewidując awarie urządzeń, minimalizując przestoje i optymalizując procesy produkcyjne, co przekłada się na znaczącą redukcję kosztów i zwiększenie wydajności. Taka optymalizacja pozwala na bardziej efektywne zarządzanie zasobami i utrzymanie wysokiej jakości produkcji. Systemy AI mogą monitorować warunki pracy i zachowania pracowników w celu identyfikacji potencjalnych zagrożeń, aby zwiększyć bezpieczeństwo pracy. Dzięki zaawansowanej analizie danych możliwe jest szybkie reagowanie na groźne sytuacje i zapobieganie wypadkom, zwiększając ochronę pracowników i poprawiając warunki pracy.

13 marca 2024 r. Parlament Europejski zatwierdził AI Act [1] mający na celu stworzenie zharmonizowanych przepisów dotyczących AI w Unii Europejskiej. Rozporządzenie zakłada klasyfikację systemów AI według poziomu ryzyka i wprowadza odpowiednie wymogi dla poszczególnych kategorii. Jego celem jest zminimalizowanie ryzyka związanego z AI, zapewnienie bezpieczeństwa użytkowników oraz ochrona podstawowych praw w kontekście wykorzystania sztucznej inteligencji.

Szybki rozwój i implementacja modeli AI w różnych dziedzinach życia stają się coraz bardziej powszechne, co rodzi liczne etyczne i technologiczne pytania dotyczące przyszłości sztucznej inteligencji. W kontekście przemysłu AI wprowadza innowacje i znaczące zmiany, które mogą zrewolucjonizować wiele aspektów produkcji i zarządzania.

Nieuregulowana jest dotychczas kwestia własności intelektualnych, która w kontekście sztucznej inteligencji jest złożona i nadal się rozwija, gdyż dotyka wielu aspektów prawa, technologii i etyki. W kontekście przemysłu kluczowym aspektem są dane oraz trening, ponieważ AI często wymaga dużych zbiorów danych do nauki i rozwijania swoich zdolności. Prawa do tych danych, zwłaszcza jeśli zawierają one materiały chronione prawem autorskim, mogą być przedmiotem sporów. Użycie danych bez odpowiedniej licencji lub zgody może naruszać prawa autorskie.

ZASTOSOWANIE AI W PRZEMYŚLE – PRZYKŁADY

W ramach AI wyróżnia się kilka kluczowych podobszarów.

Uczenie maszynowe (Machine Learning, ML) jest jedną z najbardziej dynamicznie rozwijających się dziedzin AI, która koncentruje się na tworzeniu algorytmów uczących się na podstawie danych.

Uczenie głębokie (Deep Learning, DL), będące podzbiorem uczenia maszynowego, wykorzystuje wielowarstwowe sieci neuronowe do analizy i przetwarzania złożonych danych, co umożliwia osiągnięcie wysokiej precyzji w takich zadaniach, jak rozpoznawanie obrazów i mowy.




Rys. 2. Podział sztucznej inteligencji

Obecnie w rozwiązaniach dla przemysłu zdecydowanie króluje uczenie maszynowe. Algorytm ML to zestaw instrukcji dla komputera, jak przekształcić dane wejściowe na oczekiwane dane wyjściowe. Dobór algorytmu zależy od problemu, który próbujemy rozwiązać, rodzaju danych i ich ilości. Zanim dane wejdą do modelu, często wymagają wstępnej obróbki, w tym czyszczenia, selekcji funkcji i transformacji. W fazie uczenia algorytm analizuje dane treningowe i uczy się na ich podstawie. Po wytrenowaniu model jest weryfikowany przy użyciu nowych danych, aby ocenić jego dokładność.

Warto podkreślić olbrzymią rolę w ML danych treningowych, które są fundamentem dla każdego modelu uczenia maszynowego. To na ich podstawie model uczy się rozpoznawać wzorce i dokonywać prognoz. Równie istotny jest również dobór funkcji, czyli wybór cech, które będą używane do treningu modelu; jest to kluczowy aspekt skuteczności modelu.

Jednym z dobrych przykładów algorytmów uczenia maszynowego jest algorytm K-Nearest Neighbors (KNN). To popularny algorytm uczenia maszynowego wykorzystywany do klasyfikacji i regresji.

Jest prosty do zrozumienia i stosunkowo łatwy do zaimplementowania. Idea algorytmu KNN polega na przypisaniu nowego punktu danych do klasy na podstawie najbliższych mu punktów w zbiorze treningowym. Algorytm KNN nie wymaga fazy treningowej, co oznacza, że cały czas działania jest poświęcony na przetwarzanie nowych danych. Jednakże jego wydajność może być obniżona w przypadku dużych zbiorów danych, ponieważ wymaga obliczania odległości między nowym punktem a wszystkimi punktami w zbiorze treningowym.



Rys 3. W przypadku $k = 3$ (mniejszy okrąg) zielona kropka zostanie zakwalifikowana do czerwonych trójkątów. W przypadku $k = 5$ (większy okrąg) – do niebieskich kwadratów [2]

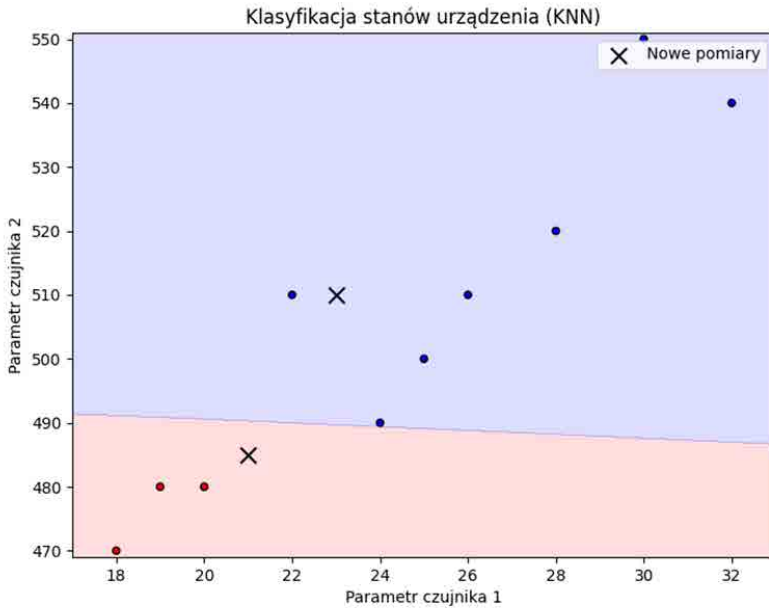
Jak algorytm KNN może pomóc w diagnozowaniu problemów w czasie rzeczywistym oraz przewidywaniu awarii poprzez analizę danych z czujników pomiarowych?

Rozważmy prosty przypadek. W tym celu przygotowaliśmy przykładowe dane do analizy. Są one opisane, ponieważ algorytm KNN należy do uczenia maszynowego nadzorowanego.

Tabela 1. Przykładowe dane do analizy – algorytm KNN

Dane pomiarowe z czujnika nr 1	Dane pomiarowe z czujnika nr 2	Etykiety (0 – awaria, 1 – normalny)
25	500	1
30	550	1
20	480	0
22	510	1
28	520	1
18	470	0
24	490	1
32	540	1
26	510	1
19	480	0

Dla powyższych danych zastosowano metodę KNN. Na wykresie została zaznaczona granica decyzyjna, która oddziela obszary przypisane do klasy „awaria” (kolor czerwony) od obszarów przypisanych do klasy „normalny” (kolor niebieski). Obszary te zostały podzielone na podstawie wartości parametrów czujników.




Rys. 4. Klasyfikacja stanów urządzenia – algorytm KNN

Model klasyfikacji KNN, po wytrenowaniu na dostępnych danych, jest w stanie dokonywać predykcji na nowych, nieznanym wcześniej danych. Wyniki te mogą być przydatne w procesie monitorowania i diagnozowania stanu urządzeń na podstawie danych z czujników.


Innym przykładem dla tego przypadku może być algorytm Random Forest, czyli „las losowy”, który jest popularnym modelem uczenia maszynowego wykorzystującym technikę Ensemble Learning, czyli uczenie zespołowe.

Jest to metoda wykorzystująca wiele drzew decyzyjnych do przewidywania lub klasyfikacji danych. Random Forest może skutecznie przewidywać klasy lub wartości dla nowych danych, jednocześnie zapobiegając nadmiernemu dopasowaniu (*overfitting*) i radząc sobie z różnorodnymi typami danych.



Rys. 5. Schemat działania algorytmu Random Forest [3]

Analogicznie jak dla danych treningowych z algorytmu KNN, zastosowano metodę Random Forest, w wyniku czego otrzymano wykres jak poniżej. Można na nim dostrzec, że granica decyzyjna jest bardziej złożona i nieregularna, co wynika z natury algorytmu, który tworzy wiele drzew decyzyjnych i łączy ich wyniki.



Rys. 6. Klasyfikacja stanów urządzenia (Random Forest)

Należy zauważyć, że aby ocenić rzeczywistą skuteczność obu modeli, konieczne jest ich przetestowanie na bardziej zróżnicowanych i reprezentatywnych danych oraz ewentualne dostosowanie parametrów modelu.

Innym przykładem zastosowania sztucznej inteligencji w przemyśle może być analiza asocjacyjna. Ma ona szerokie zastosowanie w dziedzinach takich, jak analiza rynku, rekomendacje produktów, analiza koszyka zakupowego oraz analiza korzyści i reguł biznesowych. Analiza asocjacyjna pozwala wykrywać wzorce i zależności w danych, które mogą pomóc w podejmowaniu decyzji biznesowych, optymalizacji procesów oraz personalizacji oferty dla klientów.

Jak analiza asocjacyjna może być wykorzystana w innych branżach?


Rozważmy przypadek urządzeń transportu bliskiego (UTB).

Załóżmy, że mamy dane pozyskane dla różnych modeli pewnego typu urządzenia z branży UTB – jak poniżej.

Tabela 2. Przykładowe dane dla różnych modeli pewnego typu urządzenia z branży UTB

Model A	zdeformowana konstrukcja stalowa
Model B	nieszczelny układ hydrauliczny
Model B	nieszczelny układ hydrauliczny, niesprawny układ hamulcowy
Model A	zdeformowana konstrukcja stalowa
...	
Model C	nieszczelny układ hydrauliczny, niesprawny układ hamulcowy
Model C	zdeformowana konstrukcja stalowa, nieszczelny układ hydrauliczny
Model A	niesprawny układ hamulcowy
Model B	niesprawny układ hamulcowy

Do analizy użyjemy metody Apriori, która jest wykorzystywana do znalezienia częstych zestawów zdarzeń związanych z awariami, które występują razem w transakcjach z co najmniej 10-procentowym wsparciem. Każdy zestaw zawiera zdarzenia związane z awariami wraz z modelem urządzenia, którego dotyczyła dana awaria. W wyniku analizy otrzymamy graf (rys. 7).



Rys. 7. Graf – analiza metodą Apriori

Dzięki grafowi można w prosty sposób zobaczyć, które elementy są ze sobą powiązane i jak silne są te powiązania. Przejrzysty i czytelny graf może pozwolić na bardziej intuicyjną i szybszą interpretację danych. Dzięki takiej analizie możemy dostrzec korelacje między konkretnymi usterekami a modelami urządzeń, co może przyczynić się do zapobiegania niepożądanym zdarzeniom oraz skuteczniejszego dobierania odpowiednich planów diagnostycznych.

ET INSPEKTOR

ET Inspektor to autorska aplikacja wspomagająca ocenę stanu technicznego urządzeń, kluczową przy modernizacjach i inwestycjach. Wykorzystuje modele matematyczne oparte na normie PN-EN 12952:2011 [4] i wiedzy eksperckiej UDT do prognozowania zużycia elementów instalacji na podstawie pomiarów online

Ocena degradacji instalacji energetycznych po długotrwałej eksploatacji wymaga specjalistycznych badań, zależnych od warunków pracy i dostępu do elementów. Algorytmy AI w aplikacji ET Inspektor nie wyznaczają bezpośrednio zużycia, ale dostarczają cennych informacji o pracy urządzenia.

Technologia AI stosowana do analizy danych i wykrywania anomalii opiera się na zaawansowanych algorytmach ML, które uczą się wzorców w danych i są w stanie identyfikować nietypowe odchylenia, które mogą wskazywać na potencjalne problemy.

Wykres poniżej ilustruje przykład wykrywania anomalii za pomocą sztucznej inteligencji. Czerwona linia reprezentuje normalne wartości temperatury pary świeżej, które przez większość czasu utrzymują się na stabilnym poziomie około 540°C. Jednak pod koniec analizowanego czasookresu na wykresie widoczny jest nagły i gwałtowny spadek wartości.

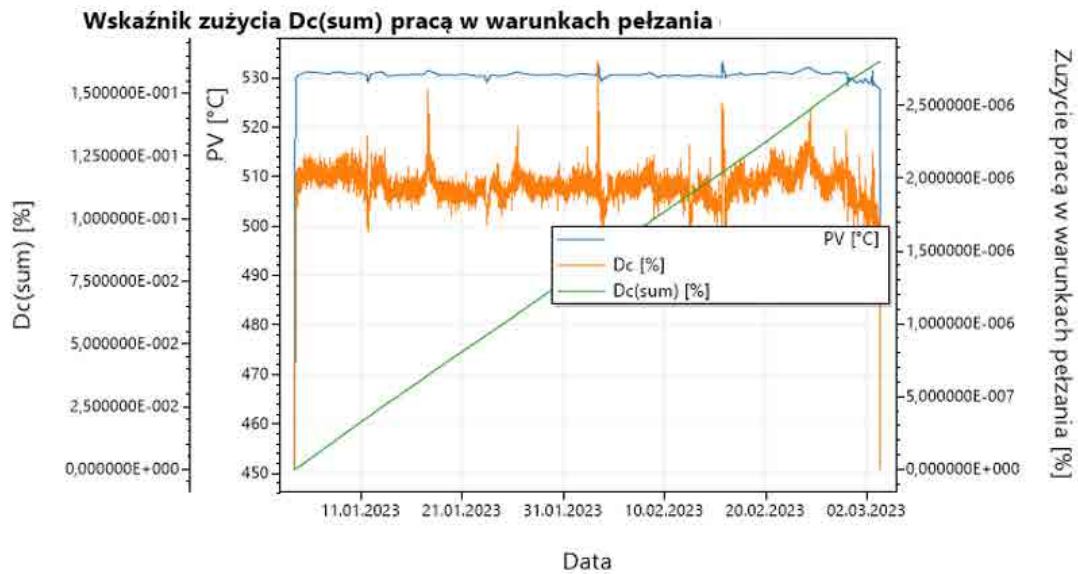
Żółte punkty na wykresie symbolizują wykryte anomalie, czyli odchylenia od normalnego zakresu temperatury. Ich wykrywanie za pomocą AI jest kluczowe, ponieważ pozwala na szybką reakcję na potencjalne problemy techniczne, które mogą prowadzić do poważnych awarii lub strat w procesach przemysłowych.



Rys. 8. Przykładowy wykres wykrywania anomalii za pomocą AI z zastosowaniem aplikacji ET Inspektor

Poprzez zastosowanie modeli matematycznych opartych na normie PN-EN 12952:2011 [4], użycie metod sztucznej inteligencji oraz wykorzystanie wiedzy eksperckiej UDT aplikacja ET Inspektor umożliwiła prognozowanie zużycia elementów instalacji na podstawie pomiarów online, a także ocenianie ich dalszej przydatności do eksploatacji. Narzędzie to daje szereg możliwości wizualizacji pozyskiwanych danych. Poniżej znajduje się przykładowy wykres dotyczący zużycia prac w warunkach pełzania.






Rys. 9. Przykładowy wykres zużycia pracą w warunkach pełzania

Na wykresie kolorem niebieskim oznaczono przebieg temperatury w czasie, pomarańczowym – wskaźnik Dc, czyli chwilowy pomiar zużycia pracą w warunkach pełzania, natomiast kolorem zielonym – Dc(sum) wizualizujący sumowanie zużycia od początku do końca analizowanego czasookresu.

Dodatkowo Aplikacja ET Inspektor dzięki zaimplementowaniu odpowiednich algorytmów pozwala na identyfikację cykli obciążeń z zastosowaniem metody Rainflow. Przykładowy wykres przedstawiono poniżej.



Rys. 10. Przykładowy wykres ilustrujący identyfikację cykli obciążenia metodą Rainflow

APLIKACJA PRZYSZŁOŚCI

Dzięki ET Inspektorowi, połączeniu norm umożliwiających obliczanie zużycia oraz mechanizmom uczenia maszynowego możliwe jest wielotorowe spojrzenie na pracę urządzenia. Aplikacja pomaga zapobiegać awariom, układać lepiej dopasowane plany badań diagnostycznych oraz optymalizować eksploatację urządzenia, aby minimalizować jego zużycie.

Literatura:

1. European Commission, „Artificial Intelligence Act: A European approach to excellence and trust” <https://artificialintelligenceact.eu/> [Dostęp: 06.2024]
2. K najbliższych sąsiadów – Wikipedia, wolna encyklopedia [Dostęp: 06.2024] https://pl.wikipedia.org/wiki/K_najbli%C5%BCszych_s%C4%85siad%C3%B3w
3. E. Grabowska „Jak udoskonalić algorytm drzew decyzyjnych?” [dostęp 06.2024] <https://predictivesolutions.pl/jak-udoskonalic-algorytm-drzew-decyzyjnych>
4. PN-EN 12952:2011 Kotły wodnorurowe i urządzenia pomocnicze