



Toruń 23–24.10.2025

Rola sztucznej inteligencji (AI) w diagnostyce olejowej

Jakub Chłodek

ECOL 2025






Diagnostyka olejowa



- Informacje o :
 - Środka smarnym
 - Zanieczyszczeniach
 - Kondycji technicznej urządzenia
- Trendy:
 - automatyzacja
 - digitalizacja
 - diagnostyka on-line
 - predykcja
- BIG DATA



Diagnostyka olejowa



Badania laboratoryjne:

- ✓ czasochłonne
- ✓ szerokie spektrum badawcze
- ✓ stosunkowo duża ilość materiału badawczego – zużycie odczynników + odpady



Diagnostyka olejowa



- Trudne i czasochłonne wnioskowanie z dużej liczby parametrów i faktów eksploatacyjnych
- Subiektywność interpretacji wyników – ocena oparta na wiedzy i doświadczeniu diagnosty
- Trudna predykcja – analiza historii („po fakcie”)

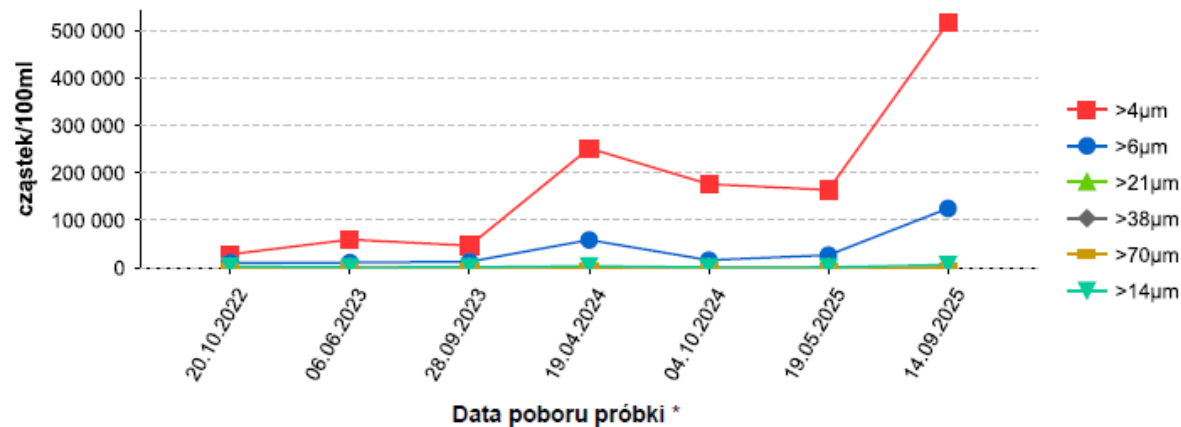
Diagnostyka olejow

Raport diagnostyczny

GRAFICZNE PRZEDSTAWIENIE TRENDÓW

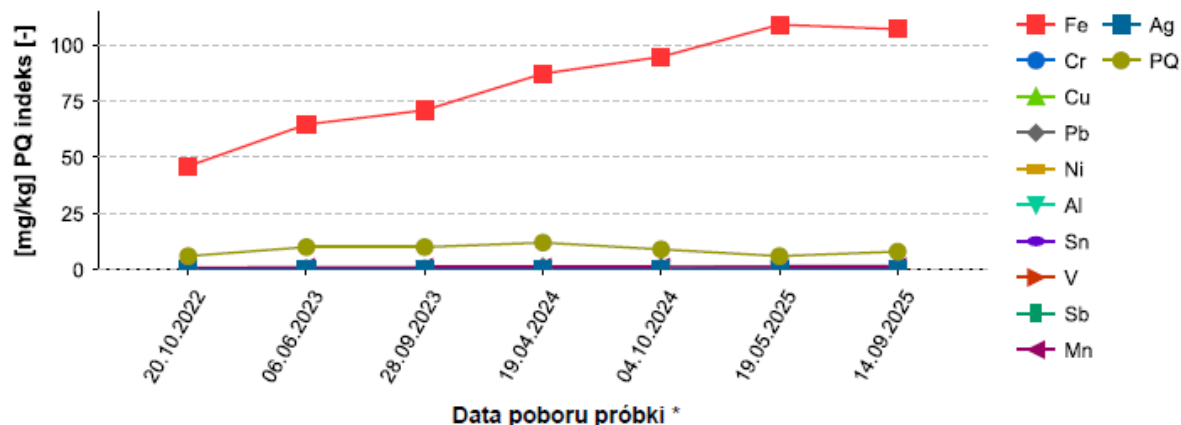


Klasa czystości - zliczenie cząstek



Data wymiany oleju *:
Czas pracy urządzenia od wymiany oleju * [h]: b.d.
Całkowity czas pracy urządzenia * [h]: 50103

Metale zużyciowe, PQ indeks

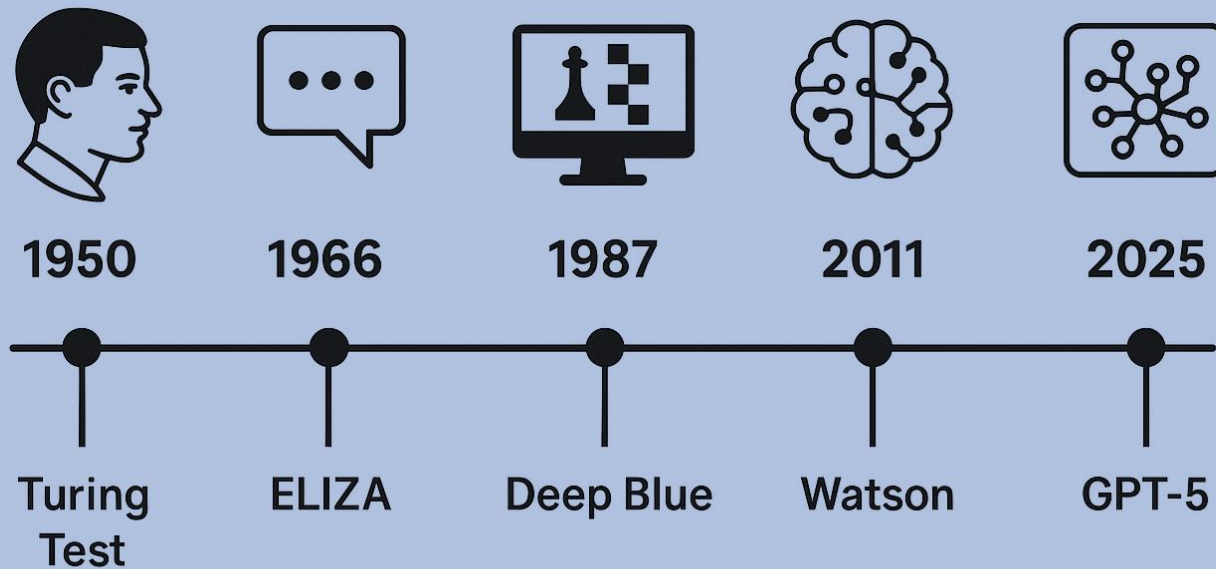


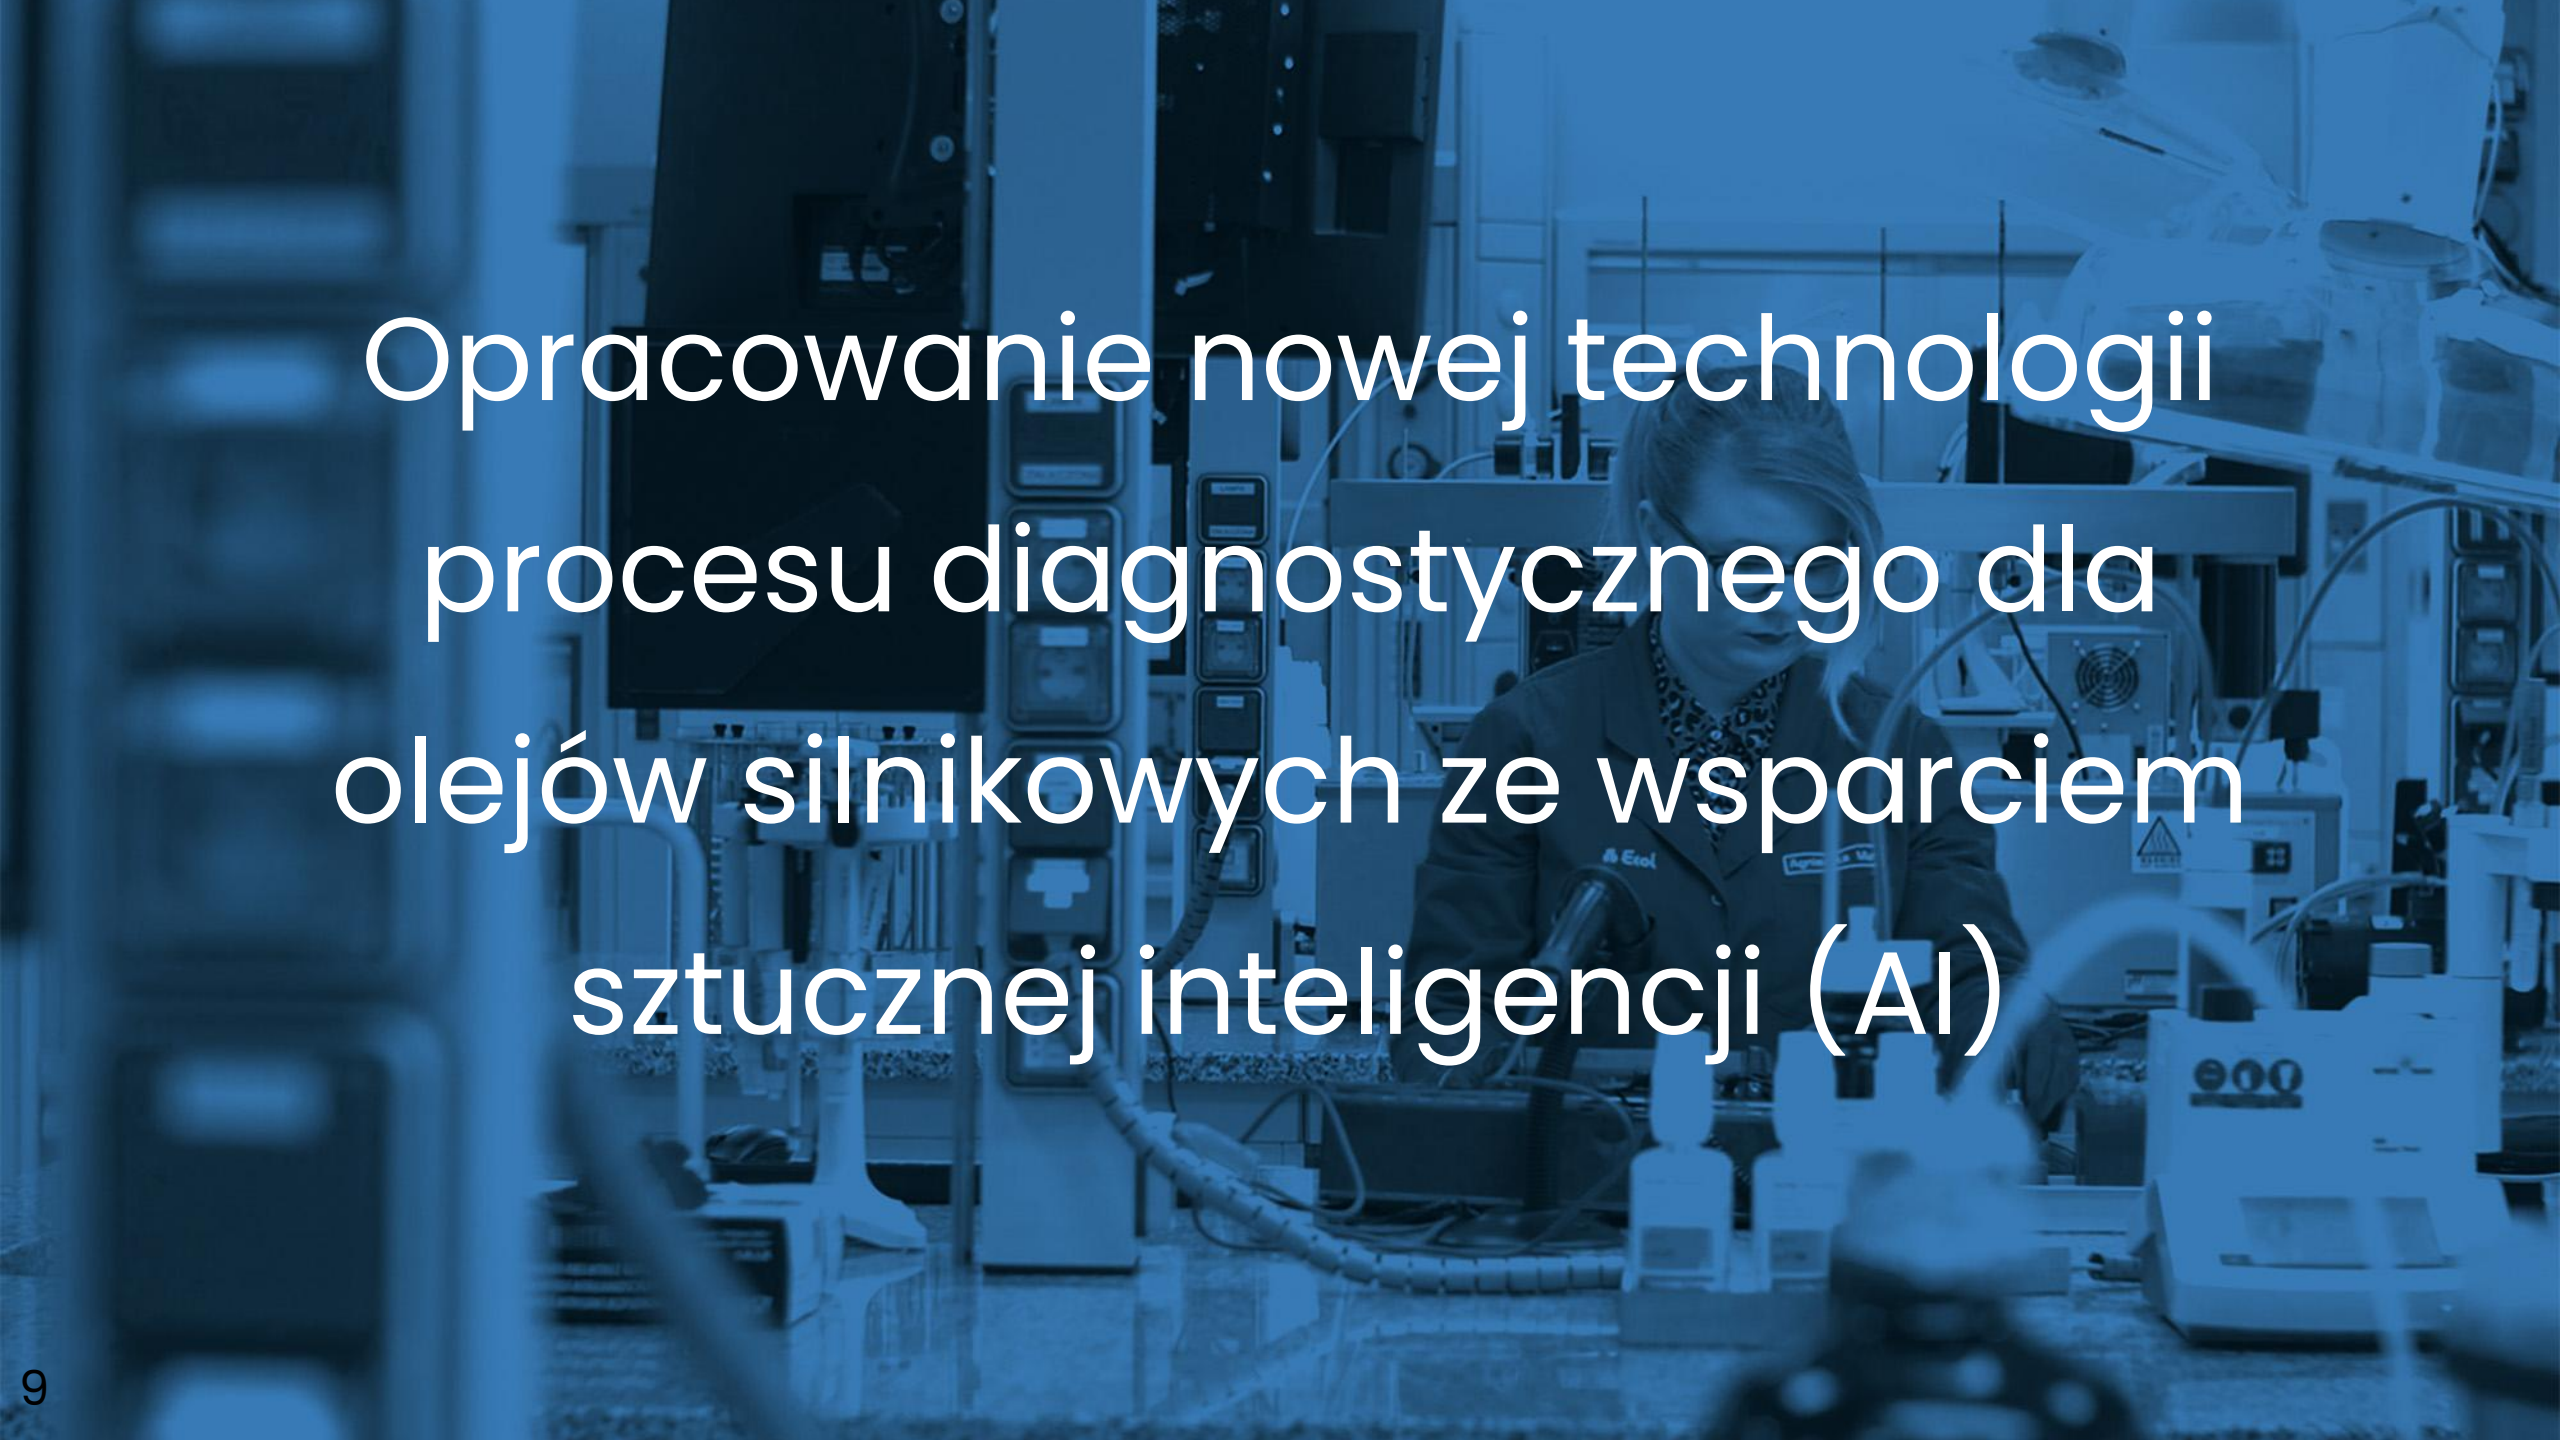
Data wymiany oleju *:
Czas pracy urządzenia od wymiany oleju * [h]: b.d.
Całkowity czas pracy urządzenia * [h]: 50103

Sztuczna Inteligencja – AI – czym jest?



Milestones in the Development of AI



A woman in a dark lab coat is working in a laboratory. She is looking down at a piece of equipment on a table. The lab is filled with various scientific instruments, including a large piece of machinery with a screen and buttons, and a smaller piece of equipment with a fan. The background shows shelves with various containers and equipment. The entire image has a blue tint.

Opracowanie nowej technologii
procesu diagnostycznego dla
olejów silnikowych ze wsparciem
sztucznej inteligencji (AI)

Cele i założenia projektu



Fundusze Europejskie
dla Śląskiego



Rzeczpospolita
Polska

Dofinansowane przez
Unię Europejską




Województwo
Śląskie

Start projektu: maj 2024


Finansowanie – ŚCP – ścieżka SMART

Wartość projektu: **8 565 609,52 PLN**

Dofinansowanie: **4 577 903,58 PLN**



Cele i założenia projektu



Opracowanie nowej technologii poprzez:

- ✓ Automatyzacja i optymalizacja procesu
- ✓ Skrócenie czasu realizacji
- ✓ Opracowanie efektywnych, rekomendowanych zakresów badawczych
- ✓ Wyeliminowanie błędów
- ✓ Obniżenie kosztów
- ✓ Aspekt ekologiczny
- ✓ Sprawność modeli powyżej 90%
- ✓ Predykcja

Kamienie milowe projektu



- Współpraca z podwykonawcą – Aigorythmics
- Zakup dodatkowego sprzętu laboratoryjnego
- POC – proof of concept
 - Przekazano dane z lat 2013 -2020:
 - 70% dane treningowe
 - 30% dane testowe
 - Recall (sprawność): 70% – 86%
 - Potwierdzono zasadność i możliwość wykorzystania AI

Kamienie milowe projektu



- 2 zadania:
 - Prace badawcze:
 - ETAP 1
 - 1.1 Badanie olejów silnikowych w maksymalnie szerokim zakresie badawczym
 - 1.2 Opracowanie bazy wiedzy
 - 1.3 Badania możliwości automatyzacji oceny ogólnej próbek z wykorzystaniem AI

Kamienie milowe projektu



- ETAP 2
 - 2.1 Budowa systemów wizyjnych i opracowanie modeli analizy obrazu za pomocą metod computer vision



Keyence, Ecol

Kamienie milowe projektu



- ETAP 3
 - 3.1 Inżyniera cech
 - 3.2 Badania różnych metod AI – modele

Kamienie milowe projektu



- ETAP 4

4.1 Weryfikacja dokładności i analiza błędów w każdej kategorii,
badanie metod poprawy skuteczności

4.2 Analiza wrażliwości – sprawdzanie jak zmiany poszczególnych
parametrów wpływają na zmianę oceny



Kamienie milowe projektu


- Prace rozwojowe:
 - ETAP 1
 - 1.1 Stworzenie reguł eksperckich wspierających tworzenie modelu AI
 - 1.2 Analiza dostępnych modeli językowych LLM– no open source
 - 1.3 Badania nad opracowaniem optymalnego modelu językowego
 - ETAP 2
 - 2.1 Retrening modeli z wdrożeniem metody SHAP
 - 2.2 Badania nad modułem automatyzacji kalibracji – cyklicznego retreningu modeli i iteracji
 - 2.3 Integracja z bazą danych Ecol wraz z wdrożeniem GUI (wraz z API)

Wyzwania



- Wysokie koszty wdrożenia (IT, szkolenia)
- Potrzeba dużej ilości danych ("czystych" danych) do trenowania AI
- Możliwe błędy modeli, halucynacje
- Reterening, kolejne iteracje modeli
- Brak standaryzacji i konieczność certyfikacji (w zakresie akredytacji)
- Akceptacja rynku i przyzwyczajenie klientów

Rezultaty projektu




- ✓ Automatyzacja i optymalizacja procesu
- ✓ **Wyeliminowanie błędów** – ograniczenie błędów
- ✓ Skrócenie czasu realizacji – z 4 dni do max 2
- ✓ Opracowanie efektywnych, rekomendowanych zakresów badawczych
- ✓ Obniżenie kosztów
- ✓ Aspekt ekologiczny
- ✓ Sprawność modeli powyżej 90%
- ✓ Predykcja

Perspektywy rozwoju



- Rozszerzenie technologii na inne płyny eksploatacyjne
- Intergacja:
 - IoT
 - Czujniki on-line
- Modele predykcyjne
- Modele autonomiczne

The Future is Now



Fot. Zade Rosenthal

Dziękuję za uwagę



Jakub Chłodek

*Dyrektor Zakładu Diagnostyki
Olejowej, MLA II*

KONTAKT

+48 604 865 579

j.chlodek@ecol.eu



ECOL.EU

