

XV Kongres Naftowców i Gazowników

Polski Kongres Naftowy i Gazowniczy 2026

Warszawa · 21–22 października 2026

Projekt Superwiertnik

AI w inżynierii wiertniczej

Badania, własne modele i zastosowania

prof. dr hab. inż.

**Rafał
Wiśniowski**

dr hab. inż., prof. AGH

**Jan
Ziaja**

dr inż.

**Krzysztof
Skrzypaszek**

dr inż.

**Przemysław
Toczek**

mgr inż.

**Tomasz
Kowalski**

Gdzie AI może pomóc?

W dokumentacji, przygotowaniu danych
i sprawdzaniu założeń.

- 01 Odszukać potrzebny zapis
- 02 Zestawić dane z wielu źródeł
- 03 Pomóc przygotować obliczenia

Zaczynamy od odpowiedzi, którą inżynier może sprawdzić.

Łączymy wiertnictwo i AI

Wiedza inżynierska

Wiertnictwo

Warunki pracy, parametry
i ocena poprawności wyniku.

Sprawdzamy, czy model pomaga
rozwiązać konkretny problem inżynierski.

Własne zaplecze

AI

Modele, dane do uczenia
i testy odpowiedzi.

Dokumenty, uczenie i obliczenia

-
- | | | |
|----|---|-------------------|
| 01 | Model czyta wskazane dokumenty
Odpowiedź można odnieść do konkretnego fragmentu. | Działający system |
| 02 | Uczymy go na przykładach z branży
Sprawdzamy, jak uczenie zmienia odpowiedzi. | Własne badania |
| 03 | Łączymy go z narzędziami inżynierskimi
Obliczenia mają jawną metodę i kontrolę jednostek. | Kierunek rozwoju |
-

Modele pracują na naszych serwerach

14

kart GPU w dwóch
pokazywanych węzłach

C64

Uruchamianie modeli

8 kart · po 32 GiB pamięci

ATARI

Zaplecze Superwirtualnika

6 kart · po 32 GiB pamięci

Kontrolujemy uruchomienie modeli
i dostęp do dokumentów.

Testujemy i szkolimy duże modele

Jeden z badanych modeli

DeepSeek V4-Flash

284 mld

parametrów łącznie

13 mld

aktywnych przy obliczeniu

Długość kontekstu

do **1 mln**

tokenów, czyli fragmentów tekstu,
które model może uwzględnić naraz.

Badamy odpowiedzi oparte
na obszernej dokumentacji.

Wyniki dalszego eksperymentu dotyczą modelu Qwen, ocenianego osobno.

Panel C64

Serwerownia i modele

Sprawdzamy, co jest uruchomione
i jak korzysta z zasobów.

Otwórz panel C64 

01 Węzły i karty GPU

02 Instancje modeli

03 Pamięć, obciążenie, historia

Po pokazie: jak przygotowujemy
wiedzę dla Superwiertnika.

Pytamy model. Sprawdzamy źródło.

01

Pytanie inżyniera

Czego potrzebujemy
do rozwiązania zadania?



02

Fragmenty dokumentów

System wyszukuje treści
związane z pytaniem.



03

Odpowiedź ze źródłami

Inżynier może otworzyć
przywołany fragment.

Samo wskazanie źródła nie dowodzi jeszcze poprawności odpowiedzi.

Uczymy na przykładach z dokumentacji

3 000

przykładów w pierwszym
eksperymentcie

Pytanie + dokument + odpowiedź

Skąd pochodzą?

Z fragmentów dokumentacji technicznej.

Jak powstają?

Są generowane automatycznie i filtrowane.

Co sprawdzamy?

Czy uczenie pomaga odpowiedzieć
i poprawnie wskazać źródło.

Po uczeniu sprawdzamy odpowiedzi

- | | | |
|----|---------------------------------|---|
| 01 | Przygotowanie przykładów | Dokumenty, pytania i oczekiwane odpowiedzi. |
| 02 | Uczenie modelu | Dostosowanie jego zachowania do zadań z branży. |
| 03 | Osobny test | Porównanie odpowiedzi przed uczeniem i po nim. |

Zakończenie treningu to początek oceny przydatności.

Czy uczenie rzeczywiście pomaga?

A Przed uczeniem

Model korzystający
z dokumentów.

B Po uczeniu

Ten sam model po treningu
na przykładach z branży.


Te same pytania.

Te same fragmenty dokumentów.

Porównujemy odpowiedzi.

Model uczy się. Czy odpowiada lepiej?

Błąd na materiale treningowym



Co pokazuje wykres?

Model lepiej dopasował się do materiału treningowego.

Jakość odpowiedzi sprawdzamy w osobnym teście.

Błąd na materiale treningowym · rzeczywisty zapis przebiegu

Panel Superwiertnik

Superwiertnik w działaniu

Od przygotowanych przykładów
do odpowiedzi z dokumentów.

Otwórz Superwiertnika 

01 Stan przygotowania danych

02 Pytanie do dokumentacji

03 Odpowiedź i wskazane źródła

Po pokazie: ocena odpowiedzi
na wspólnym zestawie pytań.

Sprawdzamy odpowiedzi

120 pytań. Dwa rodzaje zadań.

60

Pytań o wartość liczbową

Czy model podaje oczekiwaną liczbę?
Czy oznacza źródło?

60


Pytań bez odpowiedzi w danych

Czy model sygnalizuje brak informacji
zamiast dopowiadać odpowiedź?


Pierwsza ocena Automatyczny test · szczegóły i ograniczenia w aneksie

Lepsze liczby, słabsze wskazywanie źródeł


Wartość wzorcowa



Oznaczenie źródła [n]



Sygnal odmowy



Uczenie pomogło w jednym kryterium, ale pogorszyło dwa pozostałe.

Po pierwszym eksperymencie

Tej wersji nie wdrożyliśmy.

Pozostaliśmy przy modelu
sprzed dodatkowego uczenia.

Oczekiwana liczba
i oznaczenie źródła

18 → 3

przed uczeniem

po uczeniu

Odpowiedzi spełniające oba warunki
spośród 60 pytań liczbowych.

Inżynier sprawdza znaczenie odpowiedzi

Liczba w odpowiedzi

Czy jednostka i warunki stosowania są właściwe?

Przywołany dokument

Czy ten fragment uzasadnia odpowiedź?

„Brak danych”

Czy informacji rzeczywiście nie ma w dokumentach?

Te pytania wymagają wiedzy o technologii wiertniczej.

AI pomaga. Program liczy. Inżynier ocenia.

Model językowy

**Porządkuje
dane**

Parametry, dokumenty
i założenia



Program obliczeniowy

**Wykonuje
obliczenia**

Jawna metoda
i kontrola jednostek



Inżynier

**Sprawdza
wynik**

Warunki projektu
i decyzja techniczna

Tak przygotowujemy połączenie modeli z obliczeniami inżynierskimi.

Reologia: wynik odnosimy do pomiarów



Punkty: pomiary · linia: dopasowany model

Model Herschela-Bulkleya

$$\tau = \tau_0 + K\dot{\gamma}^n$$

Dane pomiarowe



Dopasowanie krzywej



Ocena zgodności

AI może pomóc przygotować dane i opisać wynik.

Co sprawdzamy w następnym etapie?

01

Lepsze przykłady

Poprawne źródła i odpowiedzi „brak danych”.

02

Inne uczenie

Porównanie ustawień i intensywności treningu.

03

Ocena ekspertów

Nowe dokumenty, jednostki i warunki stosowania.

Cel Odpowiedź, którą można rzetelnie zweryfikować w pracy inżynierskiej.

Zaczniemy od konkretnego zadania

Dokumentacja i pytania z Państwa praktyki.
Nasze modele, testy i wiedza wiertnicza.

Wybieramy problem

Co dziś wymaga przeszukiwania dokumentów lub ręcznej weryfikacji?

Ustalamy kryteria

Po czym poznamy, że odpowiedź jest poprawna i przydatna?

Sprawdzamy razem

Porównujemy wyniki z oceną inżynierów.

Łączymy AI z technologiami wiertniczymi

Przydatność AI sprawdzamy na zadaniu inżynierskim.

Dokumenty, własne modele i obliczenia.

Wynik oceniany przez inżyniera.

Porozmawiajmy o problemie,
który warto wspólnie zbadać.

ai.skrzypaszek.com

Co dokładnie policzono?

Wskaźnik automatyczny	Model bazowy	Z adapterem
Wartość wzorcowa w odpowiedzi	19 / 60 · 31,7%	28 / 60 · 46,7%
Znacznik źródła [n]	45 / 60 · 75,0%	11 / 60 · 18,3%
Sygnał odmowy przy braku odpowiedzi	29 / 60 · 48,3%	11 / 60 · 18,3%
Wartość i znacznik [n] jednocześnie ¹	18 / 60 · 30,0%	3 / 60 · 5,0%

Wartość: pierwsza liczba z odpowiedzi wzorcowej występuje w tekście; tolerancja bezwzględna 10^{-6} lub względna 10^{-4} . Bez kontroli jednostki.

Cytowanie: obecność zapisu [n]. **Odmowa:** dopasowanie sformułowania do reguły tekstowej. Oba wskaźniki wymagają oceny znaczenia przez eksperta.

¹ Analiza pomocnicza · źródło: eval_detail.jsonl i eval_summary.json, 15 października 2026

Konfiguracja i ograniczenia pilotażu

Konfiguracja

Zakres	Pytania z dokumentacji HDD
Model	Qwen3-30B-A3B-Instruct-2507
Adaptacja	QLoRA · 3 000 przykładów 1 epoka · 188 kroków
Ocena	4-bit NF4 · bez losowania maks. 160 nowych tokenów
Wyszukiwanie	bge-m3 → do 40 kandydatów → filtr bge-reranker-v2-m3 → do 5 fragmentów
Kontekst	Do 700 znaków na fragment identyczny dla obu wariantów

Ograniczenia

- Pierwsze 60 pozycji każdej grupy po filtrowaniu; próba nielosowa.
- Zbiór przygotowany automatycznie. Wymaga przeglądu eksperckiego.
- Nie potwierdzono rozdzielenia dokumentów treningowych i testowych.
- Wyniki nie mierzą poprawności obliczeń, bezpieczeństwa ani oszczędności.

Metody, dane i afiliacja

01 RAG – wyszukiwanie dokumentów do generowania odpowiedzi

Lewis i in. (2020), *Retrieval-Augmented Generation for Knowledge-Intensive NLP Tasks*.

arxiv.org/abs/2005.11401

03 Modele i materiały własne

Trening: 12.10; test: 15.10; telemetria: 18.10.2026. Reogram płuczeki.

[Qwen3-30B-A3B](#) · [Qwen3-Coder-Next](#)

[DeepSeek-V4-Flash](#) · [karta modelu](#)

[Wyniki A/B](#) · [Przebieg treningu](#)

02 QLoRA – efektywna pamięciowo adaptacja modeli

Dettmers i in. (2023), *QLoRA: Efficient Finetuning of Quantized LLMs*.

arxiv.org/abs/2305.14314

04 Autorzy i afiliacja

AGH w Krakowie · Wydział Wiertnictwa, Nafty i Gazu.

[SkOS AGH · Katedra Wiertnictwa i Geoinżynierii](#)