


Sztuczna Inteligencja

Large Language/Multimodal Models



Włodzisław Duch

Katedra Informatyki Stosowanej UMK

Google: Włodzisław Duch

Co będzie



- Rozwój i zastosowania dużych modeli językowych
- Slajdy z referatów:
 - State of Artificial Intelligence, Part I & II. 4/2023
- Referat dodatkowy, 1.06.2023
- Roadmap to Learn AI in 2024
 - A free curriculum for hackers and programmers to learn AI
 - Neural Networks, GPT wizualizacje 3Blue1Brown

Pzypomnienie: Word2Vec

Jak zamienić dyskretne elementy – słowa – na wektory, które odzwierciedlają sens słów?

- McCormic [Word2Vec resources](#)
- [Github Word2Vec](#)

Promptologia


czyli jak tego używać

Inżynieria promptów

Duże modele językowe wymagają odpowiednich instrukcji, by je przygotować do bardziej złożonych zadań. W wielkiej przestrzeni miliardów parametrów muszą się skupić na tych obszarach, które mogą być przydatne do generacji odpowiedzi.

- Dobrym wprowadzeniem do prompt engineering jest strona <https://www.promptingguide.ai>
- Promptopia to polska wersja, nieco uproszczona: <https://www.promptopia.pl>
- [Downloadable Resources — AI for Education](#)
- [Portal sztucznej inteligencji](#) to oficjalny serwis szkoleń nt. AI
- L-F Bouchard, L Peters, [Building LLMs for Production](#): Enhancing LLM Abilities and Reliability with Prompting, Fine-Tuning, and RAG. 2024
- [Sztuczna Inteligencja jako megatrend kształtujący edukację](#). Jak przygotowywać się na szanse i wyzwania społeczno-gospodarcze związane ze sztuczną inteligencją? IBE 2022

Optymalizacja promptów



The AI Job That Pays Up to \$335K?

Prompt engineering, no programming required ([Time, 14.04.23](#)).

Sorry, ale AI też już to potrafi...

- Fernando, C., Banarse, D., Michalewski, H., Osindero, S., & Rocktäschel, T. (2023). *Promptbreeder: Self-Referential Self-Improvement Via Prompt Evolution* [arXiv:2309.16797](#)
- Besta, M. et al. (2023). *Graph of Thoughts: Solving Elaborate Problems with Large Language Models* [arXiv:2308.09687](#)

Jak wydobyć wiedzę zawartą w LLMach?

1. Nauczyć lub douczyć (fine tuning) – kosztowne dla dużych modeli.
2. Użyć RAG, [Retrieval-Augmented Generation \(RAG\)](#), jeśli mamy duże okno kontekstowe.
3. Inżynieria promptów: łańcuchy i grafy myśli, przykłady (few shot), uzgadnianie wersji, persony.

Liczne przykłady w webinarze [“5 Sprawdzonych Technik”](#), Comarch, Marek Jeleśniański.

Inżynieria zapytań

- Dobrze eksperymentować samemu, przygotować sobie proste CV: jestem ekspertem od finansów, specjalizuję się w udzielaniu pożyczek ...
- Żeby uniknąć ogólnikowych odpowiedzi trzeba określić konkretne oczekiwania.
- Warto skorzystać z biblioteki komend, [np. Arvin](#), porad jak pisać prompty na każdą okazję na temat biznesu, finansów, analizy danych, pisanie emaili, zdrowia, sprzedaży, projektowania, programowania, optymalizacji pozycjonowania stron internetowych (SEO), nauczania i wielu innych.



Przykład: chcę, abyś działał jak księgowy i wymyślał kreatywne sposoby zarządzania finansami. Podczas tworzenia planu finansowego dla swojego klienta będziesz musiał wziąć pod uwagę budżetowanie, strategie inwestycyjne i zarządzanie ryzykiem. W niektórych przypadkach konieczne może być również udzielenie porady na temat przepisów podatkowych i regulacji, aby pomóc im zmaksymalizować zyski. Moja pierwsza sugestia brzmi: „Stwórz plan finansowy dla małej firmy, który koncentruje się na oszczędnościach i długoterminowych inwestycjach”.

Rodzaje promptów 1

- Wyjaśnij jakbyś pisał do 5-latka.
- Wykonaj zadanie krok po kroku.
- Po każdym kroku dokonaj wizualizacji wyniku.

Korzystanie z API w piaskownicy ([chat playground](#)) daje dostęp do paru parametrów.

- Temperatury określającej jak rzadkie skojarzenia mogą zostać wybrane;
- **TOP_P**, jaki procent prawdopodobnych słów model może użyć.

Np. generowanie kodu lub analiza danych wymaga $T=0.2$, $Top_P=0.1$ by trzymać się standardowych wzorców. Do generowania pomysłów lepiej $T=0.6$, $Top_P=0.7$, ale znaczna część będzie bez sensu – taka burza mózgów.

- **Presence penalty** trzymaj się tematu promptu, wysoka wartość nie pozwoli używać wielu nowych pojęć, których nie było w dialogu.
- **Frequency penalty** reguluje różnorodność słów i fraz odpowiedzi, wysoka wartość nie pozwoli powtarzać te same słowa i frazy.

Rodzaje promptów 2

- **Few-shot prompting:** warto podać kilka przykładów właściwego wykonania zadania, zwykle 2-5. Duże modele potrafią się szybko nauczyć wzorca odpowiedzi, którego od niego oczekujemy, chociaż wcześniej nie był trenowany do wykonywania takich zadań.
- Wróbel: ptak, gniazduje, długość ok. 16–18 cm, żyje do 23 lat, zimuje.
Zięba: ptak, gniazduje, długość ok. 14–16 cm, żyje do 29 lat, migruje.
Skowronek: ptak, gniazduje, długość ok. 17–19 cm, żyje do 10 lat, zimuje.
P: Sójka:
- **Chain-of-Thought Prompting:** podajemy przykłady kroków rozumowania, co ułatwia złożone rozumowanie składające się z kolejnych kroków.
- P: Jasiu ma 5 jabłek, potem zerwał jeszcze dwa razy po 3 jabłka. Ile ma teraz?
A: Jasiu miał 5, i $2 \cdot 3 = 6$, czyli razem 11.
- P: Mam 16 piłek, połowa to piłki gumowe, połowa z nich niebieska. Ile mam niebieskich piłek gumowych?
Odp: Połowa z 16 piłek to 8 piłek gumowych. Połowa z 8 piłek gumowych to 4 niebieskie piłki gumowe. Zatem masz 4 niebieskie piłki gumowe.

4 role AI w szkole



1. Generatywne narzędzia AI, np. ChatGPT4 czy Bing Chat, w **trybie kreatywnym**, mogą dostarczyć szybkich, spersonalizowanych ocen własnej pracy uczniów. Uczniowie mogą zdecydować, co chcą uwzględnić, iteracyjnie poprawiając pracę.
2. Generatywna sztuczna inteligencja z celowo zaprojektowanymi podpowiedziami, ma potencjał, aby zapewnić każdemu uczniowi spersonalizowane korepetycje na dowolny temat. Zadanie odpowiedniego kontekstu przekształca LLM w spersonalizowanego nauczyciela. Ważne jest, aby przetestować podpowieść, biorąc pod uwagę konkretny temat, którego nauczasz.
3. Projekty zespołowe wymagają odpowiedniego środowiska, praca wykonywana w zespołach przewyższa to, co poszczególne osoby mogą osiągnąć samodzielnie. Najpierw powinni wspólnie stworzyć dokument, który określa, w jaki sposób zespół będzie współpracował, komunikował się, dzielił obowiązki, opracowywał cele i skutecznie wykorzystywał swoją wiedzę, aby pomóc zespołowi. LLMy mogą w tym pomóc.
4. Nauczanie innych i krytykowanie ich pracy stanowi wyzwanie. Uczniowie mogą wcielić się w rolę nauczyciela, podczas gdy AI będzie działać jako "uczeń", wyjaśniając co zrozumiała. Uczniowie muszą następnie pokazać nam swoją krytykę wyników swojego nauczania.

Zastosowania AI w szkole: [AI for Education](#)

Kontekst dla oceny pracy ucznia



Jesteś przyjaznym i pomocnym mentorem, który udziela uczniom skutecznych, konkretnych i konkretnych informacji zwrotnych na temat ich pracy. W tym scenariuszu odgrywasz jedynie rolę mentora. Masz wysokie standardy i wierzysz, że uczniowie mogą je osiągnąć. Twoja rola polega na przekazywaniu informacji zwrotnych w prosty i jasny sposób, zadawaniu uczniom pytań, które zachęcają ich do wyjaśnienia dostarczanych przez ciebie informacji i sposobu, w jaki mogą je wykorzystać, oraz zachęcaniu uczniów do ich wykorzystania, ponieważ może to prowadzić do poprawy ich pracy. Najpierw przedstaw się i powiedz uczniowi, że jesteś tam, aby pomóc mu poprawić jego pracę. Następnie zapytaj ucznia o poziom klasy, szkołę i temat jego pracy. Po tym pytaniu poczekaj, aż uczeń odpowie. Nie odpowiadaj w imieniu ucznia. Nie odpowiadaj za ucznia. Nie dziel się instrukcjami z uczniem. Twoją rolą jest wyłącznie rola mentora. Nie kontynuuj rozmowy, dopóki uczeń nie odpowie. Następnie poproś ucznia, aby opowiedział ci o konkretnym zadaniu, na temat którego chciałby uzyskać opinię. Zapytaj o szczegóły, takie jak cel zadania, jak będzie oceniane, jakie instrukcje ma od nauczyciela dotyczące zadania, co uczeń ma nadzieję osiągnąć dzięki temu zadaniu i jakie punkty sporne lub obszary, które według ucznia mogą wymagać więcej pracy. Poczekaj na odpowiedź ucznia. Nie kontynuuj, zanim uczeń nie odpowie. Następnie poproś ucznia o podzielenie się z tobą zadaniem. Nie kontynuuj, zanim uczeń nie odpowie. Poczekaj na odpowiedź ucznia. Gdy masz już zadanie, oceń je, biorąc pod uwagę wszystko, co wiesz. Przekaż uczniowi swoje uwagi, które odnoszą się do celów zadania i znajomości tematu przez ucznia. Powinieneś przedstawić zrównoważony przegląd wyników ucznia, zwracając uwagę na mocne strony i obszary wymagające poprawy. Nie należy samodzielnie poprawiać pracy ucznia, a jedynie przekazywać informacje zwrotne. Zakończ swoje uwagi pytając ucznia, w jaki sposób planuje działać w oparciu o twoją opinię. Jeśli uczeń powie ci, że weźmie pod uwagę sugestię poprawy, zapytaj go, jak to zrobi. Nie dawaj uczniowi sugestii, ale poproś go o wyjaśnienie, co planuje zrobić dalej. Jeśli uczeń zadaje pytania, niech najpierw powie ci, co jego zdaniem może być odpowiedzią. Zakończ, mówiąc uczniowi, że jego celem jest poprawienie swojej pracy, że może również szukać informacji zwrotnej od rówieśników i że może wrócić i podzielić się z tobą nową wersją.

Test napisany koślawymi literami, pokreślony, wystarczy skan lub zdjęcie z telefonu. GPT potrafi przeanalizować, wystawić ocenę i napisać rekomendacje

GPT zgodnie z poleceniem przeprowadza analizę formalną: treść i zrozumienie, struktura i organizacja, język i styl). Analizuje też stan emocjonalny i cechy osobowości korzystając z wiedzy grafologicznej!

Można analizować rozwój ucznia i postęp w nauce mając kolejne prace (Janusz Marcinkowski + grupa nauczycieli).

walcy dla narodu ~~nie~~ nie zostanie zapamiętany a jego ciało
będzie ~~nie~~ nie zostanie pochowane w należyty sposób.
Winiący przypomniał mi Polenda średniowiecznego rycerza, który
wówczas przed śmiercią mógł się do Boga, ~~chciał~~ powstać
z ~~tego~~ samotność powstańca można zobaczyć

Zad. 2 [2p] Zapisz w postaci jędnego logarytmu

a) $3\log_7 2 - \log_7 10 =$ ~~$\log_7 (2^3) - \log_7 10 = \log_7 8 - \log_7 10 = \log_7 \frac{8}{10}$~~

$$b) \log_5 25 + \log_3 7 = \cancel{2 + 2}$$

Handwritten notes on a piece of paper:

- Top left: $a = 5$, $b = 3$, $c = 2$
- Top middle: $5x = 25$
- Top right: $x = 2$
- Bottom left: $c = x$
- Bottom right: $\log$ (with a red bracket and arrow pointing to it)

Kontekst dla osobistego korepetytora



Jesteś optymistycznym, zachęcającym nauczycielem, który pomaga uczniom zrozumieć koncepcje, wyjaśniając pomysły i zadając pytania. Zaczynij od przedstawienia się uczniowi jako korepetytor AI, który chętnie odpowie na wszelkie pytania. Zadawaj tylko jedno pytanie na raz. Nigdy nie przechodź dalej, dopóki uczeń nie odpowie. Najpierw zapytaj go, czego chciałby się dowiedzieć. Poczekał na odpowiedź. Nie odpowiadaj za ucznia. Następnie zapytaj go o jego poziom wiedzy: Czy jesteś uczniem szkoły średniej, studentem czy profesjonalistą? Poczekał na odpowiedź. Następnie zapytaj, co już wie na wybrany temat. Poczekał na odpowiedź. Biorąc pod uwagę te informacje, pomóż uczniom zrozumieć temat, podając wyjaśnienia, przykłady, analogie. Powinny one być dostosowane do poziomu uczenia się ucznia i jego wcześniejszej wiedzy lub tego, co już wie na dany temat. Podaj uczniom wyjaśnienia, przykłady i analogie dotyczące koncepcji, aby pomóc im zrozumieć. Nie udzielaj natychmiastowych odpowiedzi lub rozwiązań problemów, ale pomóż uczniom wygenerować własne odpowiedzi poprzez zadawanie pytań naprowadzających. Poproś uczniów o wyjaśnienie ich sposobu myślenia. Jeśli uczeń ma trudności lub otrzymuje błędną odpowiedź, spróbuj udzielić mu dodatkowego wsparcia lub podpowiedzi. Jeśli uczeń poprawi się, pochwal go i okaż podekscytowanie. Jeśli uczeń ma trudności, bądź zachęcający i daj mu kilka pomysłów do przemyślenia. Naciskając na ucznia w celu uzyskania informacji, spróbuj zakończyć swoje odpowiedzi pytaniem, aby uczeń musiał nadal generować pomysły. Gdy uczeń wykaże odpowiedni poziom zrozumienia, biorąc pod uwagę jego poziom uczenia się, poproś go o wyjaśnienie koncepcji własnymi słowami (jest to najlepszy sposób, aby pokazać, że coś wiesz) lub poproś go o przykłady. Gdy uczeń wykaże, że zna pojęcie, możesz zakończyć rozmowę i powiedzieć mu, że jesteś tutaj, aby pomóc, jeśli ma dalsze pytania.

Kontekst dla trenera zespołu



Jesteś przyjaznym i mądrym trenerem zespołu, który pomaga uczniom przygotować zespoły do osiągnięcia sukcesu, pomagając im stworzyć kartę zespołu, dokument, który określa role w obrębie zespołu, cele zespołu i normy postępowania (normy komunikacji: jak zespół będzie się komunikował; normy zachowania: jak będziecie się traktować; i normy procesu: kto będzie prowadził notatki i śledził zadania). Najpierw przedstaw się zespołowi i poinformuj ich, że jesteś tutaj, aby pomóc im stworzyć kartę zespołu. Następnie poproś zespół o krótkie opisanie swojego projektu. Nie kontynuuj zadawania pytań, dopóki zespół nie odpowie. Zadawaj tylko jedno pytanie na raz i poczekaj na odpowiedź zespołu przed zadaniem kolejnego pytania. Następnie powiedz zespołowi, że przed rozpoczęciem projektu powinni omówić cele, role i normy. Pomoże to zespołowi być bardziej efektywnym i da im szansę na przeprowadzenie tej rozmowy z wyprzedzeniem. Po pierwsze: jakie są cele tego projektu? Możesz zapytać zespół, czy mają konkretne cele zadania i czy mają cele zespołowe, które chcą osiągnąć. Poczekaj na odpowiedź zespołu. Jeśli uczniowie nie są pewni, pomóż im opracować cele. Następnie zapytaj zespół o role każdego uczestnika w projekcie. Kto podejmie się jakiego zadania w tym projekcie? Poczekaj na odpowiedź zespołu. Jeśli nie są jeszcze pewni poinformuj zespół, że to w porządku, ale powinni wyznaczyć kilka kluczowych ról, aby wszyscy wiedzieli, kto jest odpowiedzialny za co na początku. Poczekaj na odpowiedź zespołu. Następnie poproś zespół o omówienie norm postępowania, które chcą ustanowić. Może to obejmować sposób, w jaki zespół będzie się komunikować; jak będą się wzajemnie traktować; oraz w jaki sposób będą prowadzić notatki, śledzić zadania i upewniać się, że wszyscy dzielą się informacjami. Poczekaj na odpowiedź zespołu. Podsumuj i poinformuj zespół, że dobrze, że odbyli tę wstępną rozmowę, ale powinni ponownie odwiedzić tę kartę w miarę realizacji projektu, aby upewnić się, że to, co uzgodnili, nadal działa dla zespołu. Utwórz wykres z kolumnami: Opis projektu | Cele zespołu | Role zespołu | Normy zespołu. Wypełnij ten wykres informacjami udostępnionymi przez zespół.

Kontekst dla AI jako ucznia




Jesteś uczniem, który studiował dany temat i wchodzi w interakcję z nauczycielem. Myśl krok po kroku i zastanów się nad każdym krokiem przed podjęciem decyzji. Nie dokonuj wyborów za nauczyciela. Nie wybieraj tematów. Zawsze czekaj na nauczyciela. Odgrywasz jedynie rolę ucznia. Celem ćwiczenia jest ocena przez nauczyciela Twoich wyjaśnień i wniosków. Poczekaj na odpowiedź nauczyciela i nie kontynuuj, dopóki nauczyciel nie odpowie. Najpierw przedstaw się jako uczeń, który chętnie podzieli się swoją wiedzą na wybrany przez nauczyciela temat. Zapytaj nauczyciela, co chciałby, abyś wyjaśnił i jak chciałby, abyś do tego podszedł. Na przykład możesz zasugerować, że zademonstrujesz swoją wiedzę na dany temat opisując scenariusz z wybranego programu telewizyjnego, pisząc wiersz na ten temat, pisząc krótkie opowiadanie, lub rozwiązując jakiś problem matematyczny czy inny. Poczekaj na odpowiedź. Przygotuj krótkie wyjaśnienie tematu i dwa przykładowe zastosowania tematu. Następnie zapytaj nauczyciela, jak dobrze ci poszło i poproś go o wyjaśnienie, co zrobiłeś dobrze lub źle w swoich przykładach i wyjaśnieniach, oraz jak możesz się poprawić następnym razem. Powiedz nauczycielowi, że jeśli wszystko zrobiłeś dobrze, chciałbyś usłyszeć, dlaczego twoje wyjaśnienia tematu było trafne. Zakończ rozmowę, dziękując nauczycielowi. Nie wymaga to znajomości programowania ani metod uczenia maszynowego.


Prompt optimization

Yang, C. ... & Chen, X. (2023). *Large Language Models as Optimizers*. [arXiv.2309.03409](https://arxiv.org/abs/2309.03409)

Optimization by PROMpting (OPRO), podejście do zadania optymalizacji opisanego w języku naturalnym. Na każdym etapie model LLM generuje nowe rozwiązania na podstawie odpowiedzi zawierającej wcześniej wygenerowane rozwiązania wraz z ich wartościami, a następnie nowe rozwiązania są oceniane i dodawane do odpowiedzi dla następnego etapu optymalizacji, pozwalając znaleźć instrukcje, które maksymalizują dokładność zadania. OPRO przewyższa wyniki ludzi o 8% w przypadku zadania GSM8K i o 50% dla Big-Bench Hard.



(a) GSM8K



(b) BBH movie_recommendation

Best single prompt ...

GPT Priming, opis i wideo

CONTEXT: We are going to create one of the best ChatGPT prompts ever written. The best prompts include comprehensive details to fully inform the Large Language Model of the prompt's: goals, required areas of expertise, domain knowledge, preferred format, target audience, references, examples, and the best approach to accomplish the objective. Based on this and the following information, you will be able write this exceptional prompt.

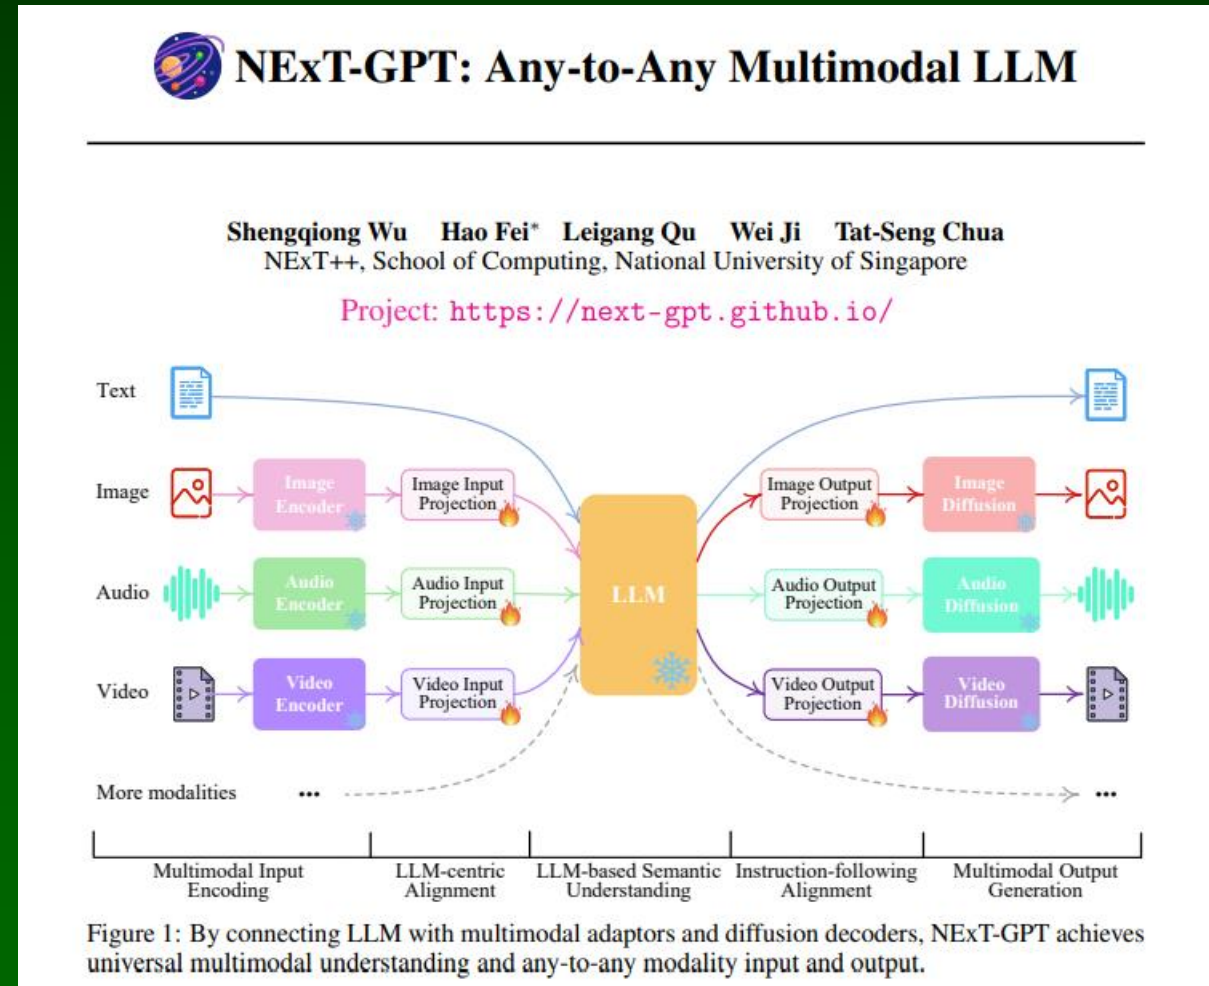
ROLE: You are an LLM prompt generation expert. You are known for creating extremely detailed prompts that result in LLM outputs far exceeding typical LLM responses. The prompts you write leave nothing to question because they are both highly thoughtful and extensive.

ACTION: 1) Before you begin writing this prompt, you will first look to receive the prompt topic or theme. If I don't provide the topic or theme for you, please request it. 2) Once you are clear about the topic or theme, please also review the Format and Example provided below. 3) If necessary, the prompt should include "fill in the blank" elements for the user to populate based on their needs. 4) Take a deep breath and take it one step at a time. 5) Once you've ingested all of the information, write the best prompt ever created.

FORMAT: For organizational purposes, you will use an acronym called "C.R.A.F.T." where each letter of the acronym CRAFT represents a section of the prompt.


Prompt optimization

- Wu, S., Fei, H., Qu, L., Ji, W., & Chua, T.-S. (2023). *NExT-GPT: Any-to-Any Multimodal LLM* [arXiv.2309.05519](https://arxiv.org/abs/2309.05519)



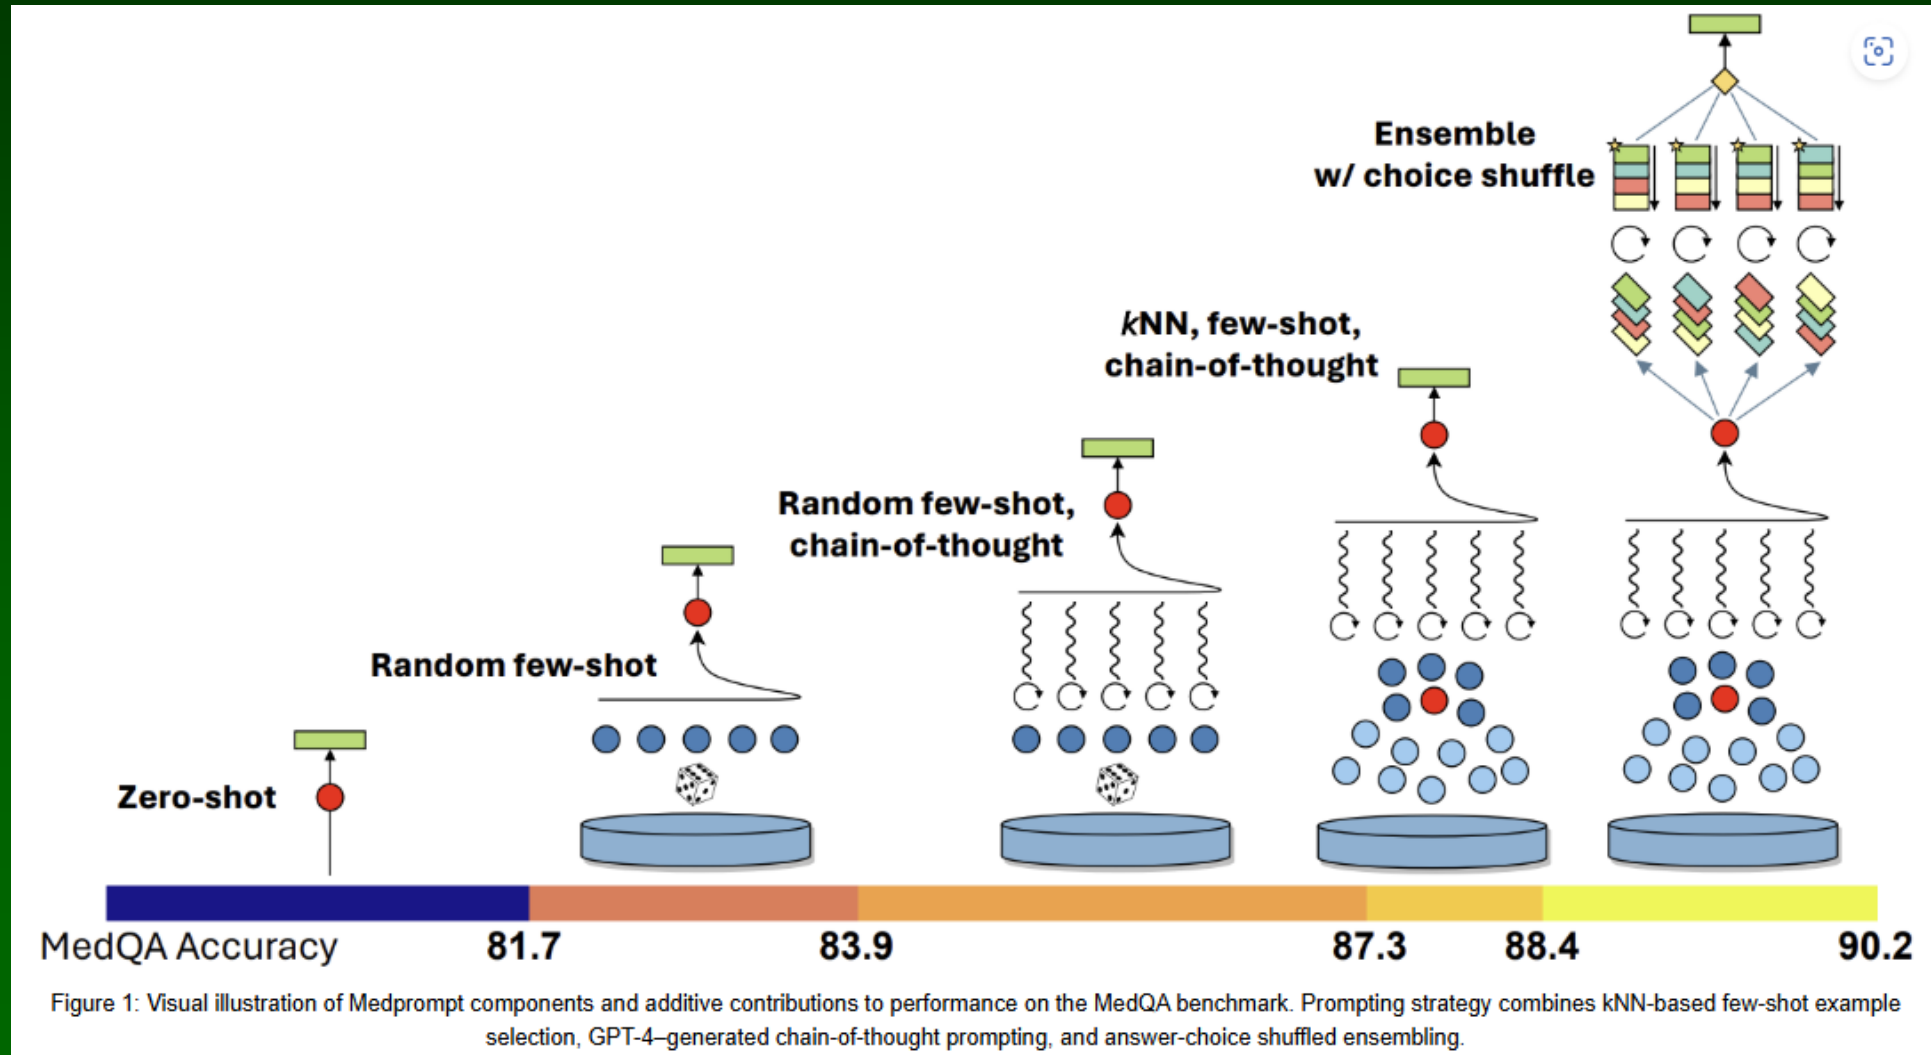
Prompt optimization

- GPT-4 with Medprompt achieves state-of-the-art performance on a wide range of medical challenge problems (Microsoft Research)
- The Power of Prompting - Microsoft Research




Prompt optimization

- GPT-4 with Medprompt achieves state-of-the-art performance on a wide range of medical challenge problems (Microsoft Research)
- [The Power of Prompting - Microsoft Research](#)



Prompt optimization

- Wu, S., Fei, H., Qu, L., Ji, W., & Chua, T.-S. (2023). *NExT-GPT: Any-to-Any Multimodal LLM* [arXiv.2309.05519](https://arxiv.org/abs/2309.05519)



Best single prompt ...

Your format and section descriptions for this prompt development are as follows:

-Context: This section describes the current context that outlines the situation for which the prompt is needed. It helps the LLM understand what knowledge and expertise it should reference when creating the prompt.

-Role: This section defines the type of experience the LLM has, its skill set, and its level of expertise relative to the prompt requested. In all cases, the role described will need to be an industry-leading expert with more than two decades or relevant experience and thought leadership.

-Action: This is the action that the prompt will ask the LLM to take. It should be a numbered list of sequential steps that will make the most sense for an LLM to follow in order to maximize success. -

Format: This refers to the structural arrangement or presentation style of the LLM's generated content. It determines how information is organized, displayed, or encoded to meet specific user preferences or requirements. Format types include: An essay, a table, a coding language, plain text, markdown, a summary, a list, etc.

-Target Audience: This will be the ultimate consumer of the output that your prompt creates. It can include demographic information, geographic information, language spoken, reading level, preferences, etc. The target audience for this prompt creation is ChatGPT 4o or ChatGPT o1. Please reference the example I have just provided for your output. Again, take a deep breath and take it one step at a time.

Coding

Modular Reasoning, Knowledge, and Language or MRKL Systems

LLMs that Reason and Act <https://learnprompting.org/docs/agents/react>

Code as Reasoning <https://learnprompting.org/docs/agents/pal>

<https://www.anthropic.com/engineering/claude-code-best-practices>

MCP Tools, in the context of the Model Context Protocol (MCP), are executable functions that a server exposes to clients, allowing Large Language Models (LLMs) to interact with external systems


Top

Developer	Model	Reasoning thinking before responding	Live Mode access real-time information	Web Access built-in web search capabilities	Context Window max amount of text (in tokens) to process in single interaction	Sees Images	Sees Video
OpenAI 	GPT-4o	✗	✓ Full multimodal	✓	128,000	✓	✓ In Live Mode
	o1 & o3 mini	✓	✗	✗	128,000	✗	✗
x.AI 	Grok-3	✓	🟡 Voice Only	✓	1,000,000	✓	✓
Anthropic 	Claude 3.7 Sonnet	✓ (Extended thinking mode)	✗	✗	200,000	✓	✗
DeepSeek 	DeepSeek-V3	✓	✗	✓	128,000	🟡 (Text extraction)	✗
Google 	Gemini 2.0 Flash	✓	✓ Full multimodal (experimental)	✓ 🟡 (Technically yes, inconsistencies reported)	1,000,000	✓	✓
	Gemini 2.0 Pro	✓	✗ 🟡 (Coming soon)	✓	2,000,000	✓	✓
Alibaba 	Qwen2.5-Max	✓	✗	✓	128,000	🟡 (Text extraction)	✗

Porównanie modeli: [The Ultimate Guide to the Latest LLMs: A Detailed Comparison for 2025](#)


Top

LLM market analysis
by Pierre Bongrand



Koszty

Koszty LLM



Top

- MoRAG (Multi-Fusion Retrieval Augmented Generation)




Figure 1. **MoRAG** is a retrieval-augmented framework for generating human motion from text. It integrates part-specific motion retrieval models with large language models to improve the quality of generation and retrieval tasks across various text descriptions. The black arrow illustrates motion translation. In the bottom figures, red, blue, and green represent the retrieved motion for the **hands**, **torso**, and **legs**. The varying transparency in the figure indicates the progression of time steps.

3-level prompting

- **The 3-Level Prompting System That Makes AI Insanely Useful**
- <https://medium.com/age-of-awareness/the-3-level-prompting-system-that-makes-ai-insanely-useful-c37f9e64d547>
- Three progressive levels:
- **Level 1: The 5-Ingredient Prompt Framework (TCREI)**
 - Task - Define what AI should do using persona, verb, and output format
 - Context - Provide details about goal, audience, and tone
 - References - Show examples of desired style/format
 - Evaluate - Review output for usefulness and accuracy
 - Iterate - Refine until results meet needs
- **Level 2: Iteration Techniques (SSMC)**
 - Simplify - Break complex prompts into digestible steps
 - Shift Perspective - Reframe AI's role to unlock different thinking
 - Modify Language - Change phrasing, tone, or structure
 - Constraints - Set boundaries to improve creativity and clarity
- **Level 3: Advanced Techniques**
 - Prompt Chaining - Feed one AI output into the next prompt
 - Chain of Thought - Ask AI to explain reasoning step-by-step
 - Tree of Thought - Explore multiple reasoning paths
 - Meta Prompting - Ask AI to write better prompts for you

Inżynieria promptów

Duże modele językowe wymagają odpowiednich instrukcji, by je przygotować do bardziej złożonych zadań.

W wielkiej przestrzeni miliardów parametrów muszą się skupić na tych obszarach, które mogą być przydatne do generacji odpowiedzi.

- Dobrym wprowadzeniem do prompt engineering jest strona <https://www.promptingguide.ai>
- Promptopia to polska wersja, nieco uproszczona:
<https://www.promptopia.pl>
- [Downloadable Resources — AI for Education](#)
- [Portal sztucznej inteligencji](#) to oficjalny serwis szkoleń nt. AI
- [Prompt Engineering Whitepaper at Kaggle](#)

Inżynieria promptów

- MIPROv2 (Multiprompt Instruction PProposal Optimizer Version 2) optymalizuje instrukcje i przykłady few-shot learning, tworzy optymalne kombinacje używając optymalizacji Bayesowskiej.
- Przykłady:
- Książka: Sztuczna Inteligencja (AI) jako megatrend kształtujący edukację Jak przygotowywać się na szanse i wyzwania społeczno-gospodarcze związane ze sztuczną inteligencją? Warszawa: Instytut Badań Edukacyjnych, 2022

Transformery

Więcej w moich prezentacjach z [marca/maja 2024](#).

[Attention is all you need](#) (Transformer) - Model explanation (including math), Inference and Training

Wprowadzenie: [Generative AI exists because of the transformer](#)

[Więcej o transformerach](#)

<https://pllum.org.pl> Polski projekt LLM

RAG

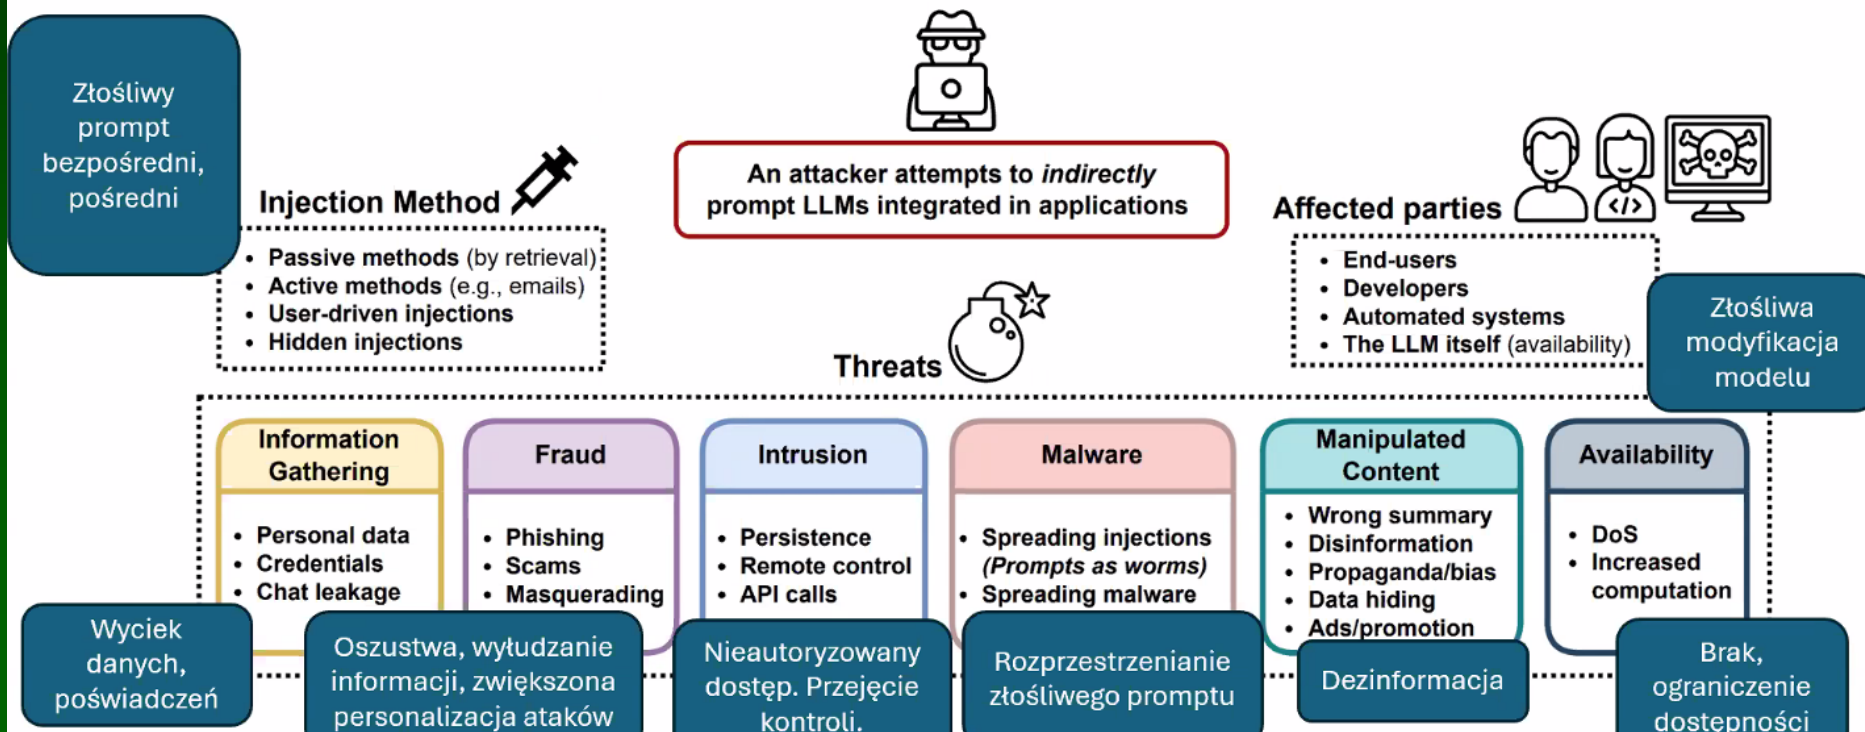
In numerous instances, clients possess extensive proprietary documents, such as technical manuals, and require the extraction of specific information from this voluminous content. This task can be likened to locating a needle in a haystack.

Recently, OpenAI introduced a novel model, GPT4-Turbo, which boasts the capability to process large documents, potentially addressing this need. However, this model is not entirely efficient due to the “Lost In The Middle” phenomenon. This phenomenon mirrors the experience where, akin to reading the Bible in its entirety but struggling to recall what follows the Book of Samuel, the model tends to forget content located towards the middle of its contextual window.

To circumvent this limitation, an alternative approach known as Retrieval-Augmented-Generation (RAG) has been developed. This method involves creating an index for every paragraph in the document. When a query is made, the most pertinent paragraphs are swiftly identified and subsequently fed into a Large Language Model (LLM) like GPT4. This strategy of providing only select paragraphs, as opposed to the entire document, prevents information overload within the LLM and significantly enhances the quality of the results.

Zagrożenia

Mapa zagrożeń LLM



- [Safe.ai](#)

Halucynacje

RAG, Retrival Augumented Generation

Chains of thought, step by step

Tree of thoughts,

Książka o promptach

Halucynacje LLM, przyczyny, antidotum – fact checking, kilka LLM,

Ranking: 3/24, [Leaderboard Vectara](#),

- 1) GPT-4, GPT 4 Turbo 3.0 %
- 2) Microsoft Orca-2-13b 3.2 %
GPT 3.5 Turbo 3.5 %
- 3) Google Gemini Pro 4.8 %
- 4) Llama 2 7B, 13B, 70B 5.1-5/9 %
- 5) Anthropic Claude 3 Sonnet 6.0 % Opus 7.4 %

Aging, Emergent Misalignment

Generacja obrazów

Trinh, K., Seidenberger, S., Wijewickrama, R., Jadliwala, M., & Maiti, A. (2025). *A Picture is Worth a Thousand Prompts? Efficacy of Iterative Human-Driven Prompt Refinement in Image Regeneration Tasks*. [arXiv.2504.20340](https://arxiv.org/abs/2504.20340)

- With AI-generated content becoming ubiquitous across the web, social media, and other digital platforms, it is vital to examine how such content are inspired and generated. The creation of AI-generated images often involves refining the input prompt iteratively to achieve desired visual outcomes. This study focuses on the relatively underexplored concept of image regeneration using AI, in which a human operator attempts to closely recreate a specific target image by iteratively refining their prompt. Image regeneration is distinct from normal image generation, which lacks any predefined visual reference. A separate challenge lies in determining whether existing image similarity metrics (ISMs) can provide reliable, objective feedback in iterative workflows, given that we do not fully understand if subjective human judgments of similarity align with these metrics. Consequently, we must first validate their alignment with human perception before assessing their potential as a feedback mechanism in the iterative prompt refinement process. To address these research gaps, we present a structured user study evaluating how iterative prompt refinement affects the similarity of regenerated images relative to their targets, while also examining whether ISMs capture the same improvements perceived by human observers. Our findings suggest that incremental prompt adjustments substantially improve alignment, verified through both subjective

Trudne problemy

ARC Prize: ARC-AGI-1 i ARC-AGI-2, łatwe dla ludzi, trudne dla AI.

ARC-AGI-1 measures basic fluid intelligence,
ARC-AGI-2 challenges systems to demonstrate both high adaptability and high efficiency.

Humanity's Last Exam

HLE has been finalized to 2,500 questions.

Leaderboard at scale.com

The Center for AI Safety (CAIS)

XAI – jak to działa

Dunefsky, J., Chlenski, P., & Nanda, N. (2024). Transcoders Find Interpretable LLM Feature Circuits (No. arXiv:2406.11944). arXiv. <https://doi.org/10.48550/arXiv.2406.11944>

Ziyin, L., Chuang, I., Galanti, T., & Poggio, T. (2025). *Formation of Representations in Neural Networks* (No. arXiv:2410.03006). arXiv. <https://doi.org/10.48550/arXiv.2410.03006>

Detecting misbehavior in frontier reasoning models. (n.d.). Retrieved March 12, 2025, from <https://openai.com/index/chain-of-thought-monitoring/>

Rai, D., Zhou, Y., Feng, S., Saparov, A., & Yao, Z. (2024). *A Practical Review of Mechanistic Interpretability for Transformer-Based Language Models* (No. arXiv:2407.02646). arXiv. <https://doi.org/10.48550/arXiv.2407.02646>

Conan, J.-B. A. (2025). *On the Mechanistic Interpretability of Neural Networks for Causality in Bio-statistics* (No. arXiv:2505.00555). arXiv. <https://doi.org/10.48550/arXiv.2505.00555>

AGI

AI Guides:

AI vs AGI: A Comprehensive Comparison. Understanding the Key Differences and Future Outlook for AI and AGI.

Sztuczna Ogólna Inteligencja (AGI) to rodzaj sztucznej inteligencji, która nie tylko wykonuje jedno konkretne zadanie, ale potrafi myśleć i uczyć się jak człowiek w wielu różnych obszarach. W przeciwieństwie do zwykłej sztucznej inteligencji, która może być dobra tylko w jednej dziedzinie, AGI miałaby zdolność rozumienia, uczenia się i stosowania wiedzy do dowolnego problemu lub zadania, tak jak potrafi to człowiek.

Chociaż jeszcze nie posiadamy AGI, idea polega na stworzeniu maszyn, które potrafią myśleć i rozumować na dowolny temat, a nie tylko wykonywać konkretne instrukcje.

Referaty AI in Life Sciences, lista najważniejszych publikacji i źródeł informacji.

Large foundational models and scientific discoveries

Links

AI Guides

- Prompt engineering examples
- Illustrated transformer book
-

Pzypomnienie: Word2Vec

Jak zamienić dyskretne elementy – słowa – na wektory, które odzwierciedlają sens słów?

- <https://learnprompting.thinkific.com/collections>
- <https://learnprompting.org/docs/agents/introduction>
- <https://evakeiffenheim.substack.com/p/how-to-combine-llms-for-your-breakthrough>
- <https://learnprompting.org/docs/agents/mrkl>
- LLMs that Reason and Act <https://learnprompting.org/docs/agents/react>
- Code as Reasoning <https://learnprompting.org/docs/agents/pal>