Standaardisatieraad

SURF

Npuls

Soevereine AI?

Visie AI

We want to get the most out of AI in a trustworthy way

Trustworthy staat voor voor wettige, ethische en robuuste oplossingen. We respecteren alle toepasselijke wet- en regelgeving, gebruiken en ontwerpen AI-systemen die gericht zijn op eerlijkheid, transparantie en veiligheid, met respect voor mensenrechten en ethische overwegingen.

SURF Npuls

Commerciële systemen bestaan uit drie lagen die als één product worden aangeboden

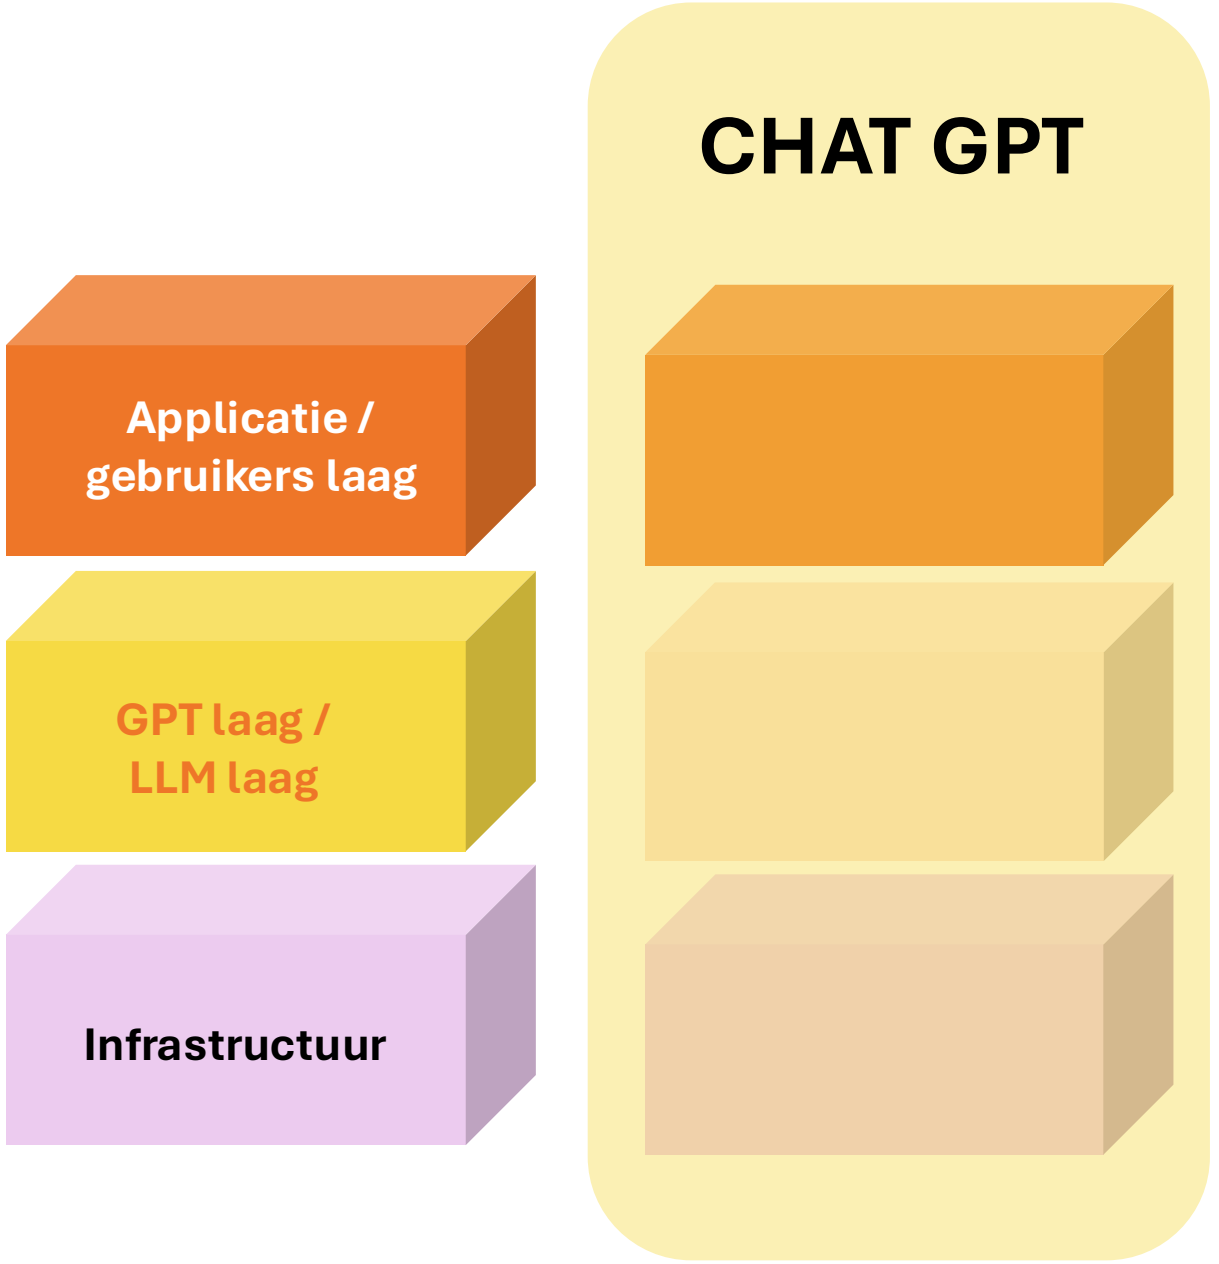

SURF Npuls

Daardoor is er geen invloed op de verschillende lagen

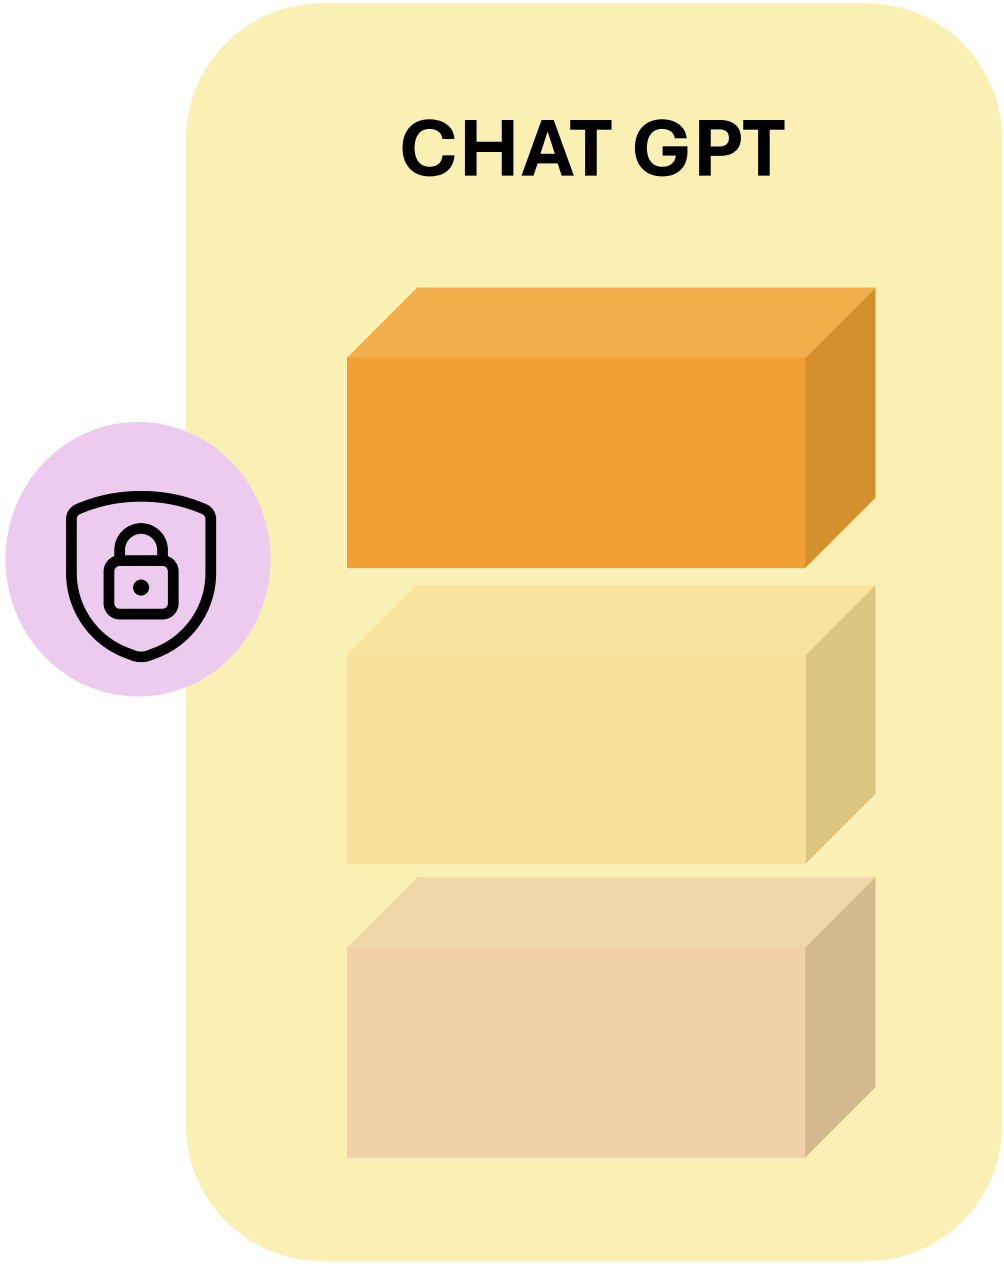

Dat breken we open met een tussenlaag: de AI hub

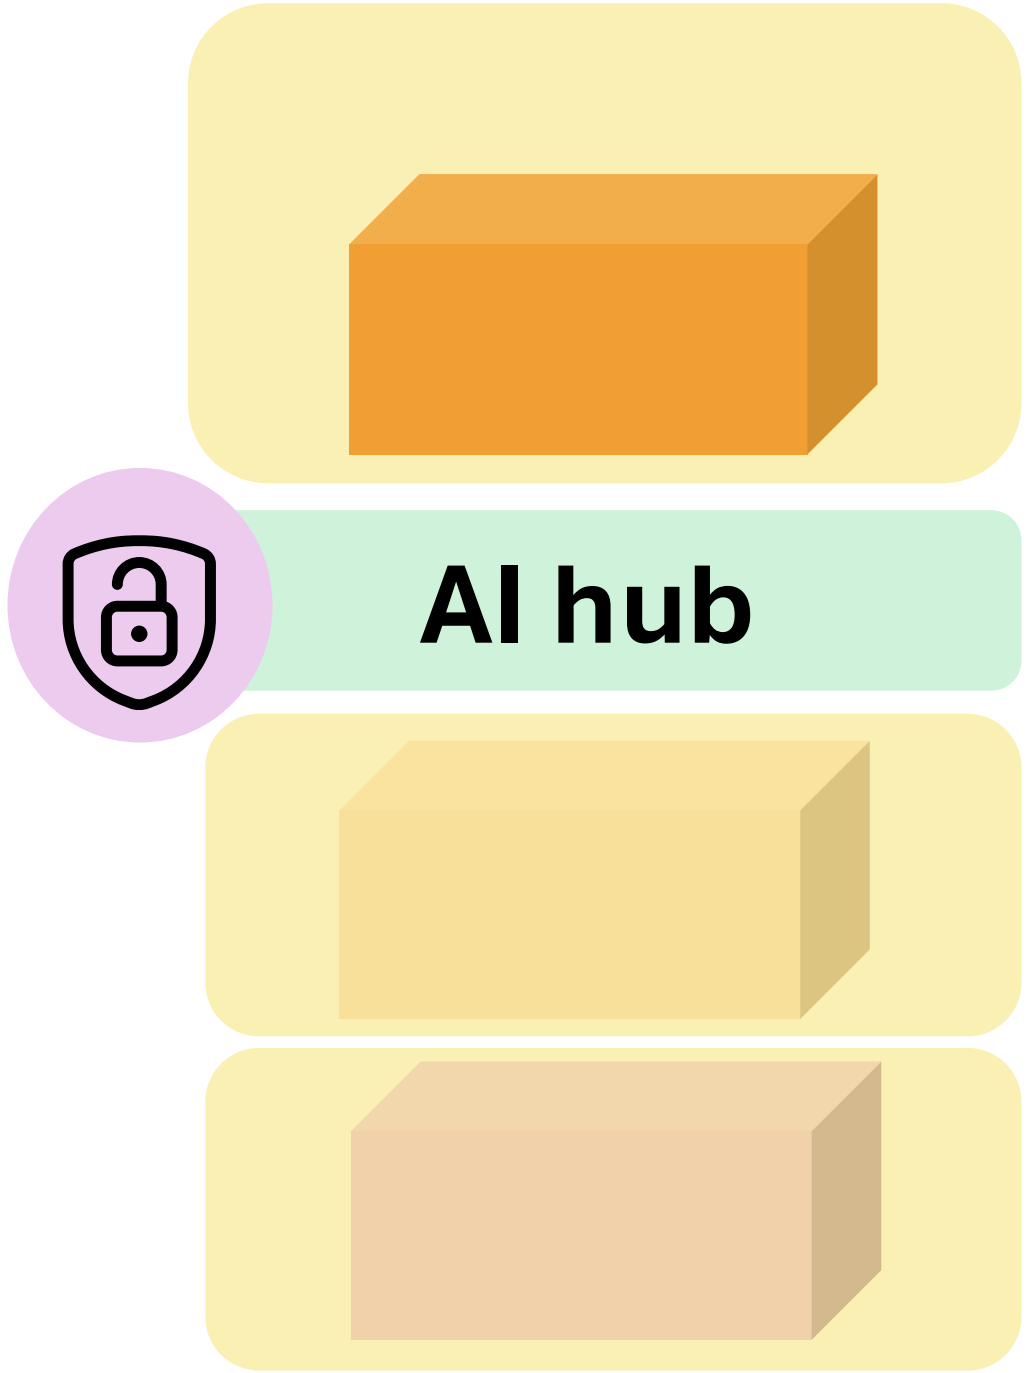

SURF Npuls

Hoe ziet dat eruit in de praktijk?

De AI hub is een vertrouwd koppelpunt op basis van gedeelde waarden, waar applicaties/gebruikers kunnen kiezen en koppelen met GPT en LLM

Dit betekent maximale flexibiliteit bij gebruikers en minimale macht bij aanbieders

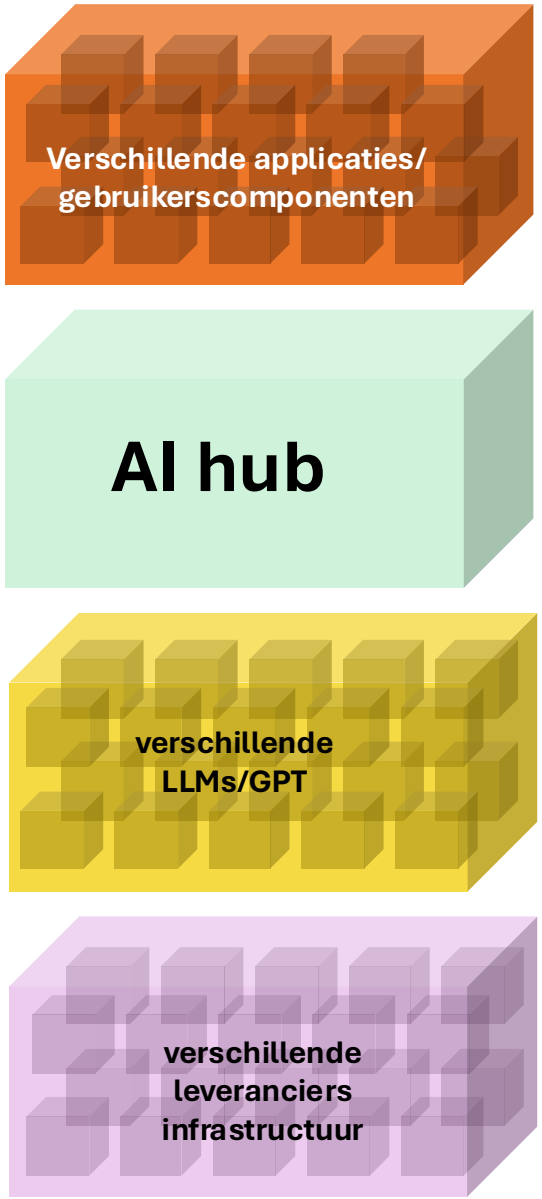

Bijvoorbeeld eduGenAI

Ontwikkeld door SURF/Npuls. Wordt open source

GPT-NL

Bijvoorbeeld GPT-NL

SURF Npuls

Wat zijn de uitdagingen zonder AI-Hub?

Afhankelijkheid van bigtech

Data Privacy

Onzekerheid over reproduceerbaarheid

Hoge investeringen in hardware

Tekort aan geschoold personeel

Efficiënt gebruik van resources

SURF Npuls

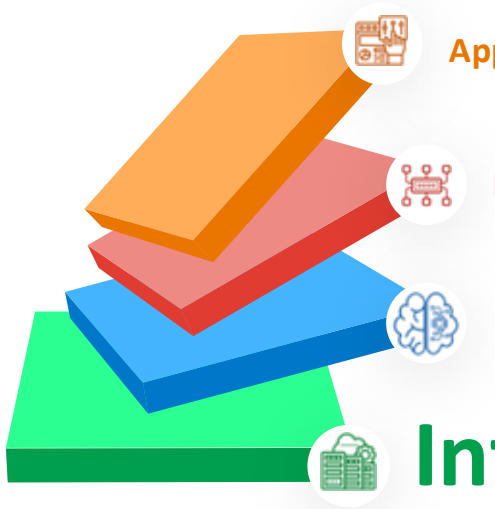

Applicatie laag / Gebruikers laag

Hub laag / Middleware laag

GPT laag / LLM laag

Infrastructuur

Latency

Latency mode

The API supports different latency modes.

Mode	latency	Models	Example use-cases
Always-on	< 10 sec	Only models marked with as always-on	Chat interfaces
On-demand	< 30 min	All models available to you	Playground
Batch	< 24 hrs	All models available to you	Research, automatic workflows

SURF Npuls

We geven inzicht in het energieverbruik door de leden

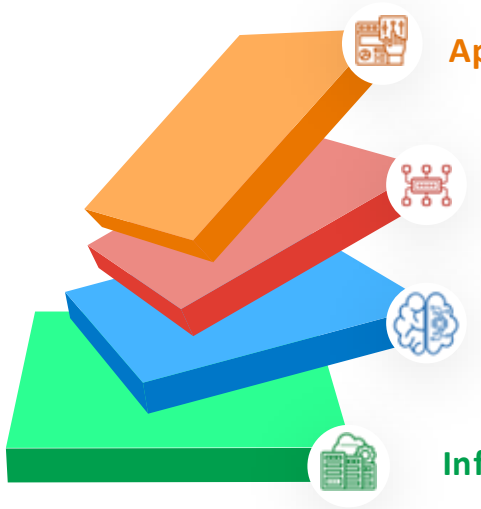

Applicatie laag / Gebruikers laag

Hub laag / Middleware laag

GPT laag / LLM laag

Infrastructuur

Normeren en controleren

Vraag: hoe doen we DPIA's op taalmodellen?

SURF Npuls

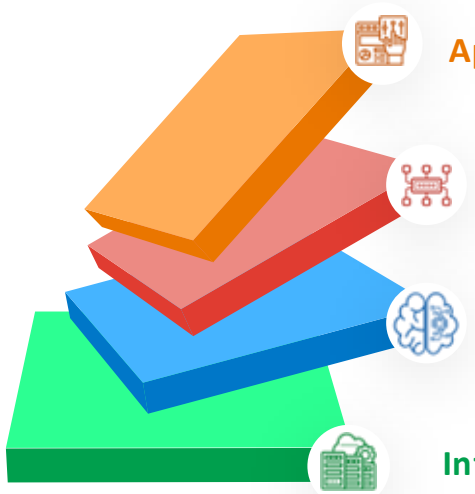

Applicatie laag / Gebruikers laag

Hub laag / Middleware laag

GPT laag / LLM laag

GPT-NL

Infrastructuur

GPT-NL Corpus	Content / Source Description
Collected Data (GPT-NL Curated)	
Openraadsinformatie	Municipal council documentation
Officiële bekend-makingen	Government announcements
Woogle	Open Dutch government documents
Koninklijke Biblio-theek	Public domain Dutch texts
De Rechtspraak	Judicial cases
Tweede Kamer	Dutch parliamentary documents
Nationaal Archief	Dutch archive
Belgian Journal	Belgian company bylaws (Flemish foc
Utrechts Archief	Dutch archive
Noord-Hollands Archief	Dutch archive
Zeeuws Archief	Dutch archive
Dienst Publiek en Communicatie	Dutch public communication docs
Wikiwijs	Dutch school content
PBL	Planbureau Leefomgeving docs
Naturalis	Biological publications
European Parliament	Multilingual EU documents
DANS-KNAW	Dutch archaeology descriptions
Auditdienst Rijk	Dutch audit publications

Towards a fair data value chain

- **We believe data artists, journalists and other creators should be paid for their work**
- We pay 50% of the revenue from the commercial license to the owners of the data.
- The other 50% will solely be used for **continuation** of GPT-NL

	Content
	Umbrella dutch media
	Dutch news medium
	Dutch news medium
	Student thesis'
	Financial documents
	Societal research
	ICT law documents
se Taal	Dutch linguistic research/data
	Social reports
r de	**Medical articles**
	Travel blogs
	Frysian linguistics

SURF Npuls

bron: https://gpt-nl.nl/publish/pages/8907/gptnl-pres-25-040-dnb-for_public_publication.pdf

Europees AI-bedrijf Mistral komt met nieuwe AI-modellen en maakt ze opensource

Door **Daan van Monsjou**
Nieuwsredacteur
Feedback • 02-12-2025 17:29 85 • submitter: Westpjotr

Het Franse AI-bedrijf Mistral komt met verschillende nieuwe Mistral 3-llm's. Daaronder valt een groot 'frontiermodel' dat multimodaal werkt en meerdere talen ondersteunt, naast een stel kleinere modellen die lokaal gedraaid kunnen worden. Ze komen allemaal opensource beschikbaar.

Mistral Large 3 wordt volgens de ontwikkelaars 'een van de beste openweightmodellen ter wereld'. De Franse start-up trainde het model zelf met 3000 Nvidia H200-gpu's. Het gaat om een mixture-of-experts-model dat bestaat uit 47 miljard actieve en 675 totale parameters.

Het nieuwe flagshipmodel kan volgens Mistral meekomen met andere populaire openweightmodellen zoals Kimi K2 en Deepseek V3.1. Daarnaast voegt het ook verschillende functies toe die al langer in gesloten AI-modellen zitten, zoals multimodale functies en ondersteuning voor meerdere talen. Het model komt beschikbaar onder een Apache 2.0-licentie.

Naast het Mistral Large 3-model komt Mistral ook met verschillende kleinere llm's. Deze krijgen de naam Ministral 3 en worden geleverd in modellen met 3, 8 en 14 miljard parameters. Van ieder model komen bovendien base-, instruct- en reasoningvarianten, ieder met de mogelijkheid om afbeeldingen te begrijpen. Volgens de makers zijn deze modellen bedoeld voor lokaal gebruik. Ook al deze varianten komen beschikbaar onder een Apache 2.0-licentie.

Behoefte aan framework om te bepalen wanneer modellen compliance zijn

Bron: https://tweakers.net/nieuws/242176/europees-ai-bedrijf-mistral-komt-met-nieuwe-ai-modellen-en-maakt-ze-opensource.html

Initiatief gemeente Amsterdam

Gemeente Amsterdam

EN | NL

LLM Overzicht in de Nederlandse Taal

Om het verantwoord gebruik van LLM's te bevorderen, bieden wij een overzicht van modellen die ingezet kunnen worden binnen de Nederlandse overheid.
Omdat modellen zich anders gedragen per taal, zijn alle experimenten direct in het Nederlands uitgevoerd.

Model	Aanbieder	Licentie	Training Data	Energieverbruik	Kosten	Bias	Feitelijkheid	Eerlijkheid
TinyLlama-1.1B-Chat-v1.0	StatNLP	Open	Open	0.63Wh	€0.01	? ?		
Phi-4-mini-instruct	Microsoft	Open	Beschreven	2.79Wh	€0.03			
SmolLM3-3B	HuggingFace	Open	Open	3.14Wh	€0.04			
c4ai-command-r7b-12-2024	Cohere	Beperkt	Beschreven	5.09Wh	€0.06			
Qwen3-8B	Alibaba Cloud	Open	Gesloten	5.71Wh	€0.07			
Llama-3.1-8B-Instruct	Meta	Beperkt	Gesloten	5.8Wh	€0.07			
Falcon3-7B-Instruct	TII	Beperkt	Gesloten	5.92Wh	€0.07			
Apertus-8B-Instruct-2509	Swiss National AI Institute	Open	Open	6.19Wh	€0.07			
EuroLLM-9B-Instruct	UTTER Project	Open	Open	6.33Wh	€0.08			
Mistral-7B-Instruct-v0.3	Mistral AI	Open	Gesloten	6.39Wh	€0.08			
gpt-oss-20b	OpenAI	Open	Gesloten	9.33Wh	€0.11	?		

SURF Npuls

Bron: https://amsterdam.github.io/grip-on-llms/nl/

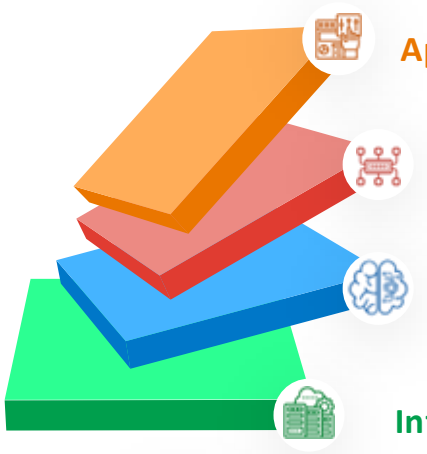

Applicatie laag / Gebruikers laag

Hub laag / Middleware laag

GPT laag / LLM laag

Infrastructuur

API-keys conform OpenAI standaard

1. Applicatie laag / Gebruikers laag

“de interface”

2. Hub laag / Middleware laag

SURF “Trusted AI HUB”

Pilots

AI HUB

3. GPT laag / LLM laag

Sandboxed

4. Infrastructuur

SURF Infrastructuur

In datacenter SURF onder beheer van SURF

Applicatie laag / Gebruikers laag

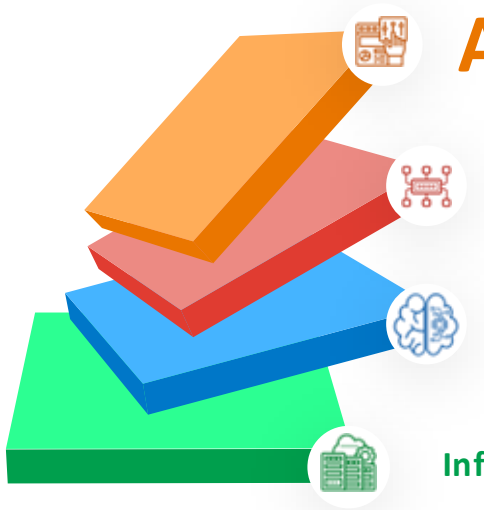

Hub laag / Middleware laag

GPT laag / LLM laag

Infrastructuur

EduGenAI

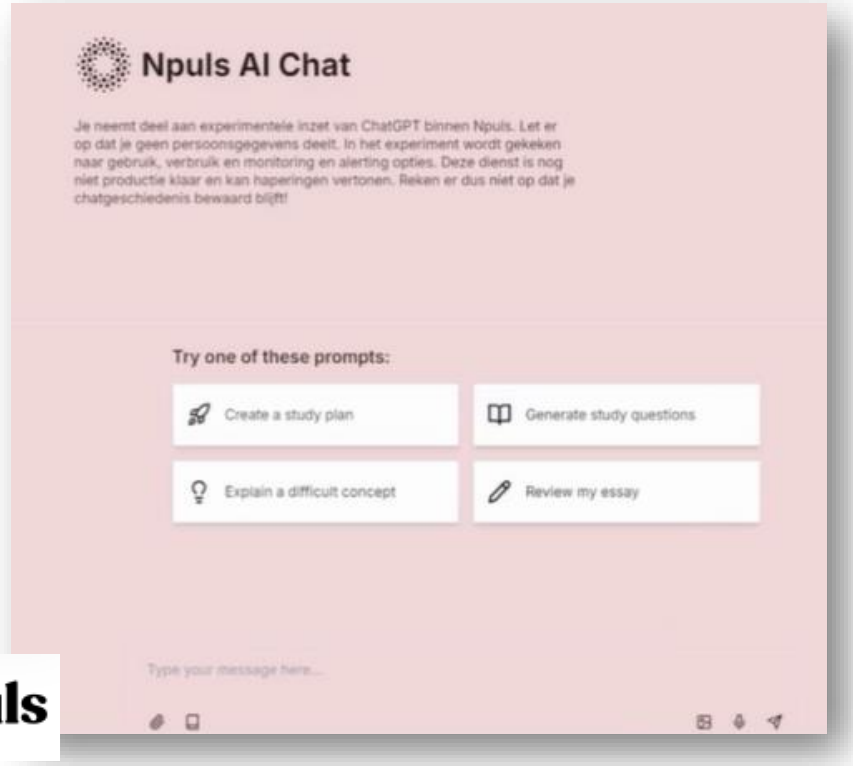

- ✓ Veilig gebruik van foundation modellen
- ✓ Userinterface voor het onderwijs (door Uva/HvA)
- ✓ Keuze uit verschillende LLM’S
- ✓ Chatten met eigen data/documenten
- ✓ Promptbibliotheek
- ✓ Persona’s gebruik in het onderwijs
- ✓ Leren over en met AI – verantwoorde inzet
- ✓ Ecosysteem van instellingen

SURF Npuls

Applicatie laag / Gebruikers laag

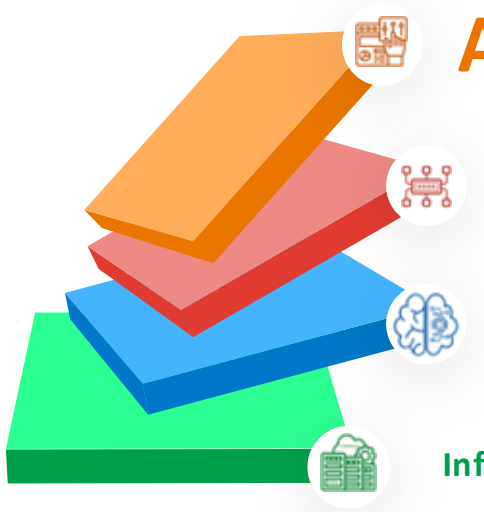

Hub laag / Middleware laag

GPT laag / LLM laag

Infrastructuur

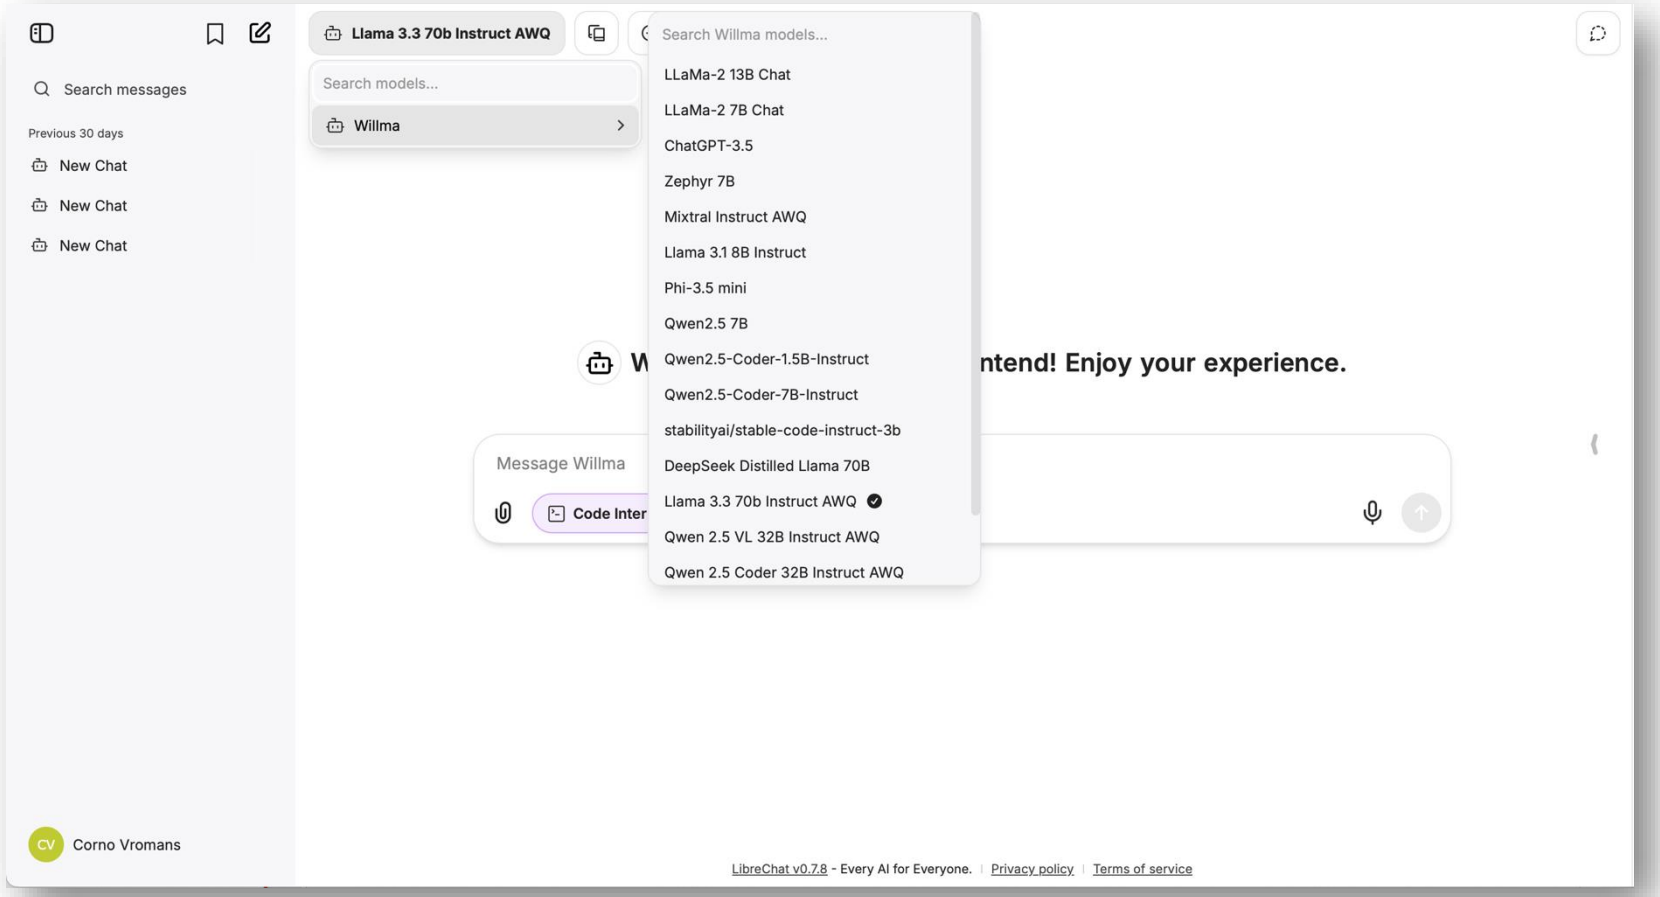

LibreChat

SURF Npuls

SURFice

Nextcloud en AI

Koppeling van AI assistent aan AI-hub gelukt! (op test omgeving)

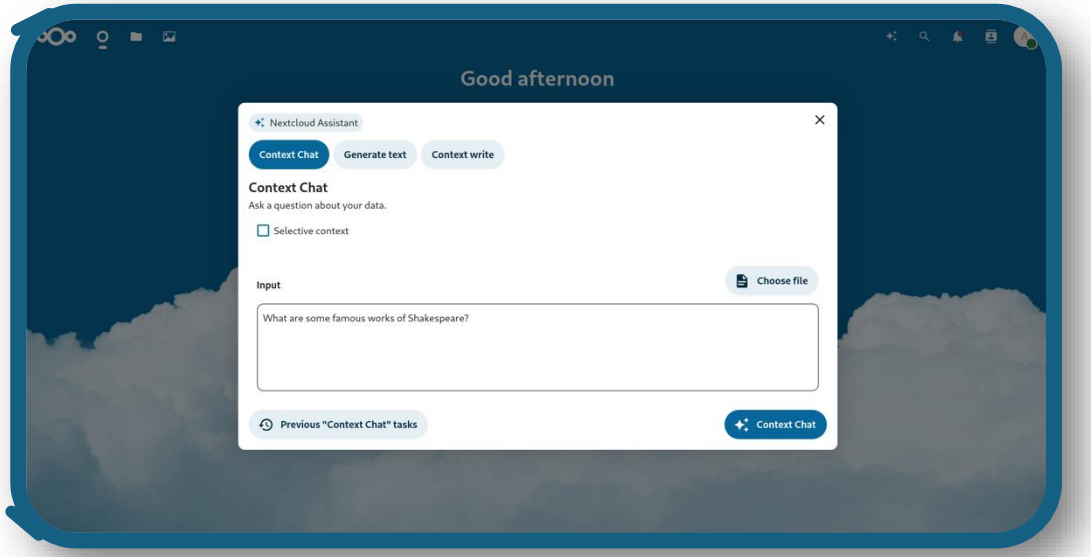

1. Applicatie laag / Gebruikers laag

“de interface”

Nextcloud

2. Hub laag / Middleware laag

SURF “Trusted AI HUB”

3. GPT laag / LLM laag

MISTRAL AI_ · ChatGPT · Claude · Copilot · perplexity · Gemini · GPT-NL · OPEN EURO LLM · WiLLMa · deepseek · LLaMA by Meta

Nplus SURF

Integratie met bestaande toepassingen

The AI-Hub can be used as a backend for various applications that support the OpenAI API standard. We have some documentation to get started, but it's up you to enroll this responsibly within your institute:

OpenWebUI: https://openwebui.com/ browser-based interface for running and managing local or remote large language models. > Getting started (behind login)	**Nvidia Nemo Guardrails:** https://github.com/NVIDIA-NeMo/Guardrails NeMo Guardrails is an open-source toolkit for easily adding programmable guardrails to LLM-based conversational applications. > Getting started (behind login)	**PyCharm**: https://www.jetbrains.com/pycharm/ A popular IDE from JetBrains designed specifically for Python development, with strong debugging and productivity tools. > Getting started (behind login)
Elastic: https://www.elastic.co/security Using the ai-hub as an inference prodiver, you can also use the Elastic Security AI Assistant. > Getting started	**LibreChat**: https://www.librechat.ai/ An open-source, self-hostable alternative to ChatGPT that lets you run and customize conversational AI. > Getting started (behind login)	

NextCloud has also successfully tested in an experimental setup, but you are welcome to try other integrations as well.

Development

The AI-Hub exposes an API to develop your applications or workflows against.

Onboarding Check our onboarding documentation to get from zero to your first successful request. > Onboarding	**Python code examples** Shows examples when using different modalities and functions such as tool calling. > Python code examples (behind login)	**API documentation** The API-documentation can be used for detailed information on the AI-Hub endpoints > API Swagger Documentation (behind login)

Ontwikkeling AI-Hub

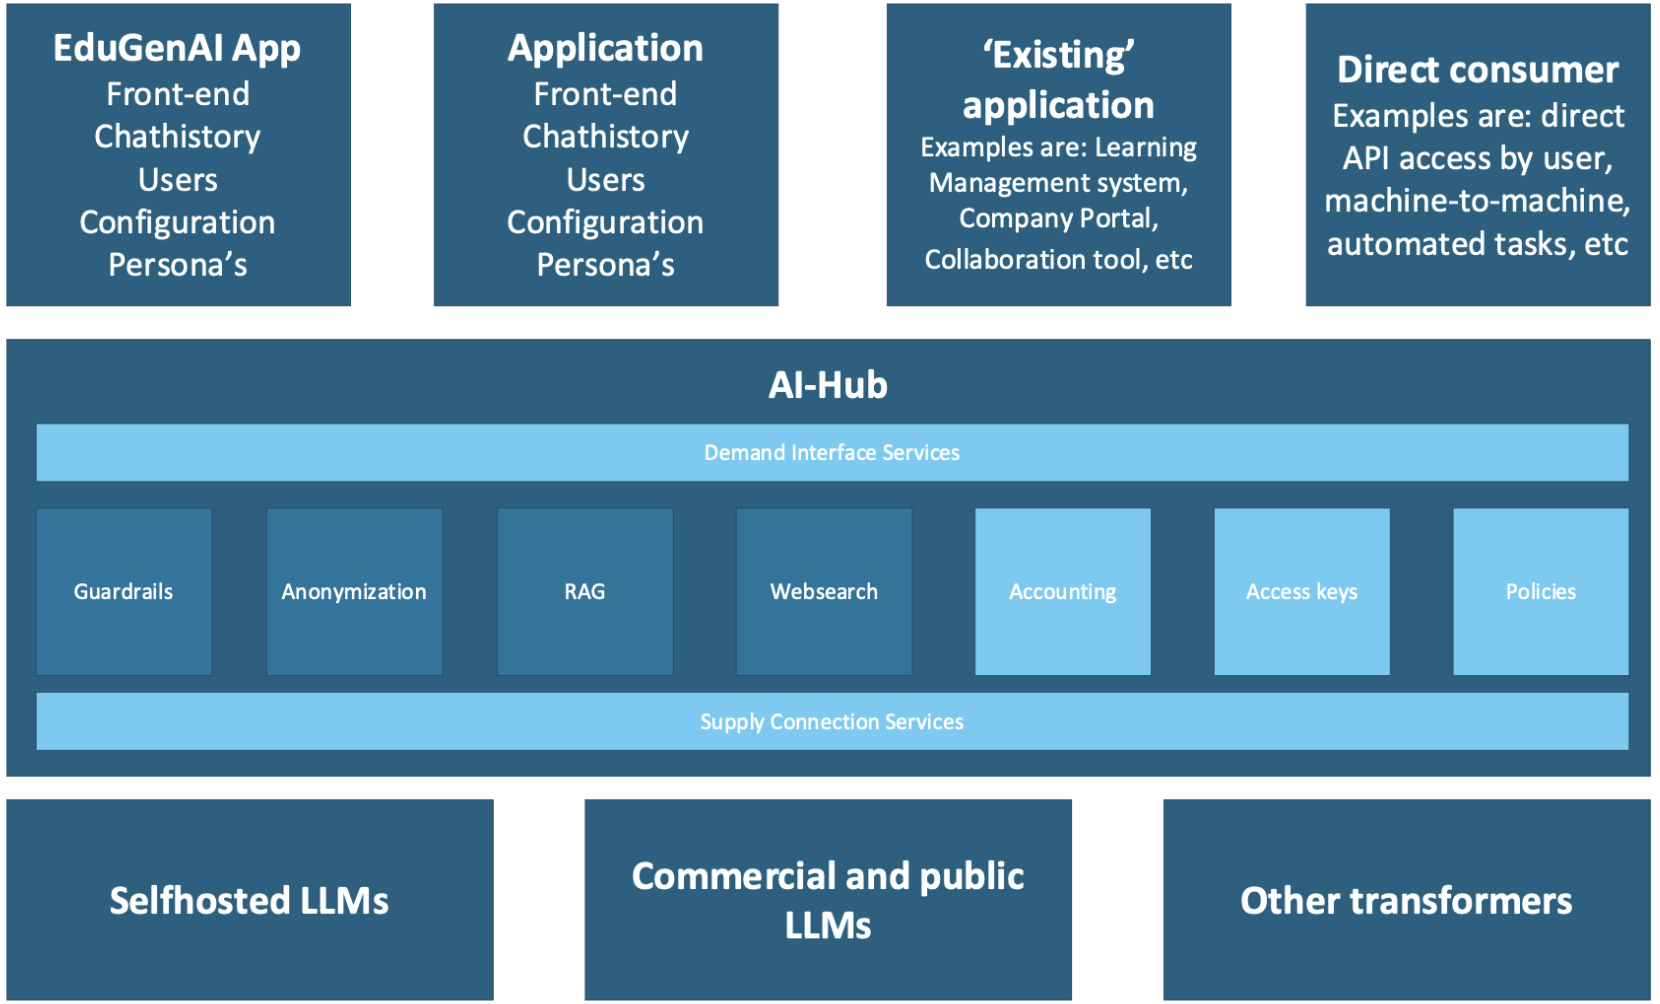

Integratie met andere systemen

MCP

Toetsen van guardrailsmodellen op Nederlands

Voorbeeld gebruik MCP (model context protocol)

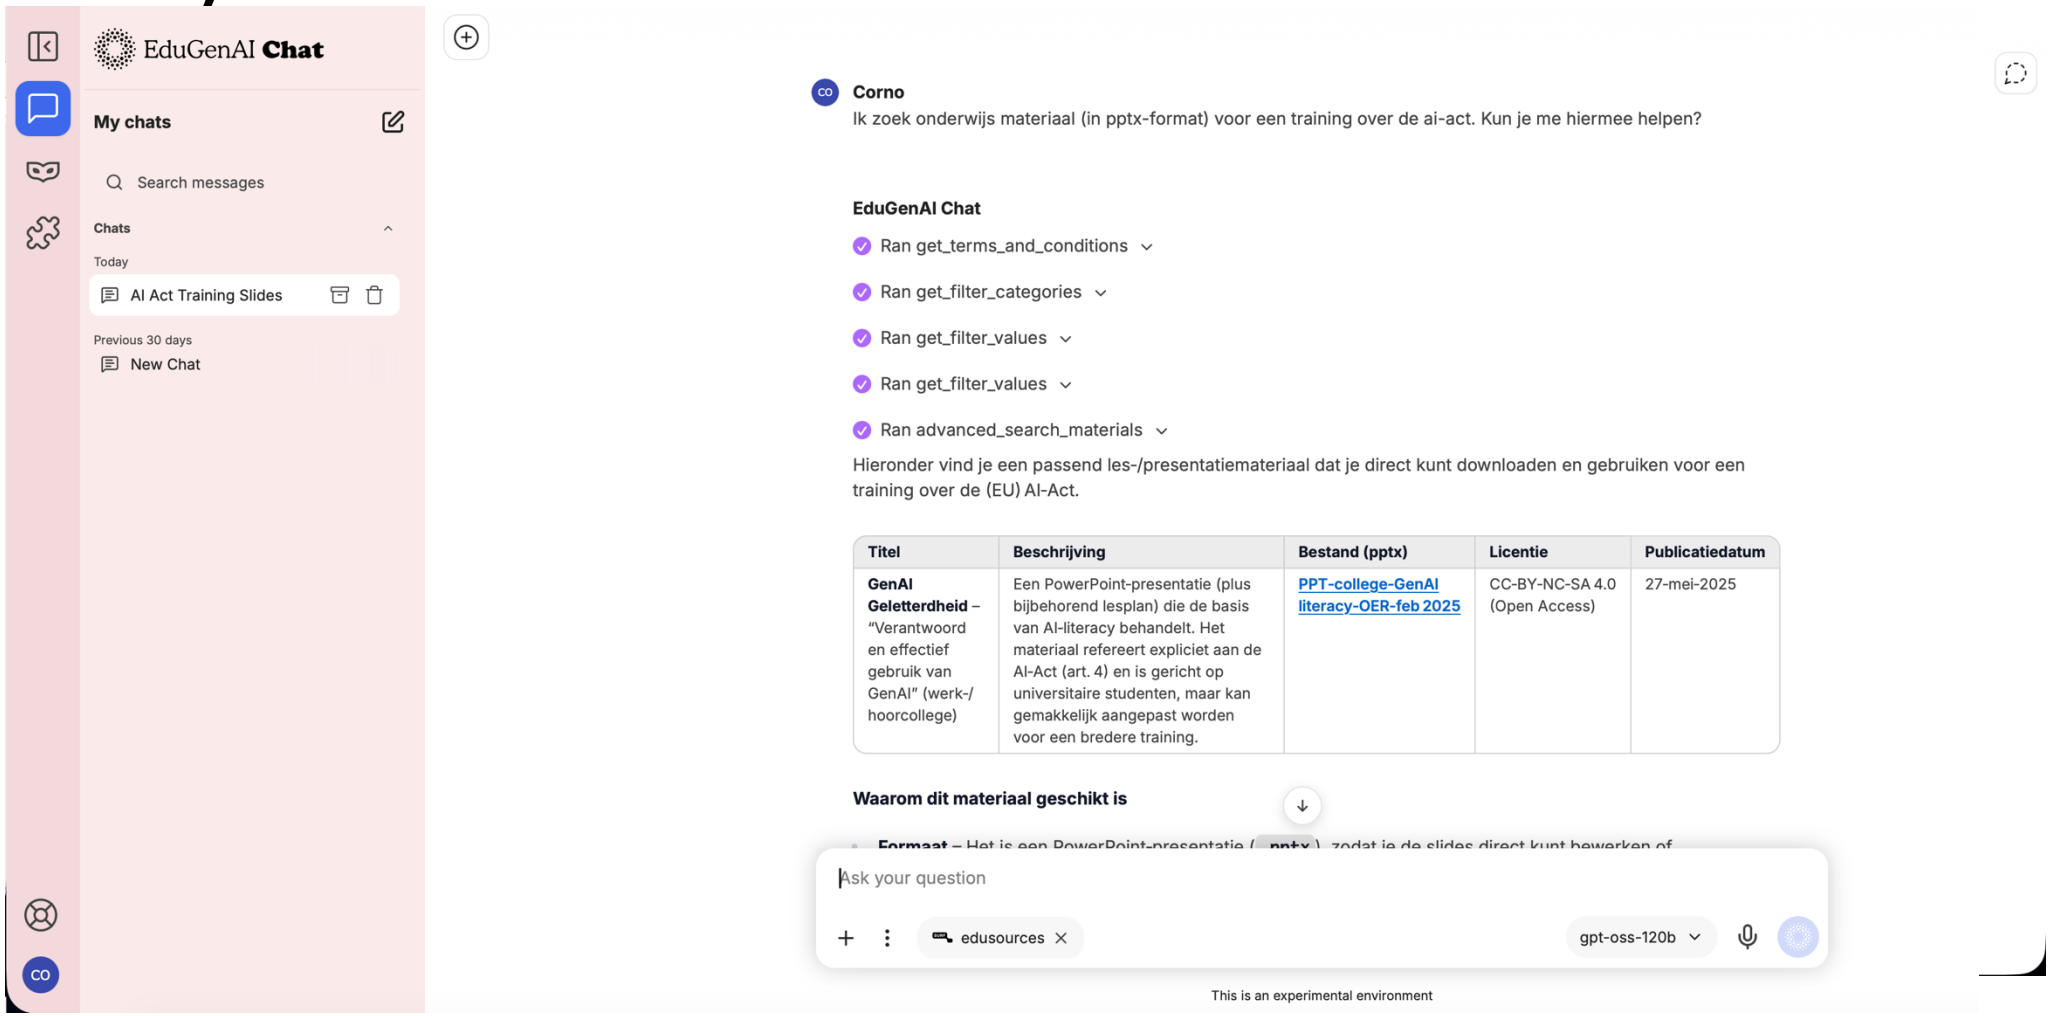

Regie bij de leden!