

# Coding agents

## Quels enjeux?

David Salinas. 20/01/2025. Grenoble Meetup.

# **Coding agent**

**On the rise**

# Coding agent

## On the rise

- Les coding agents se sont **dramatiquement** améliorés

# Coding agent

## On the rise

- Les coding agents se sont **dramatiquement** améliorés

I have a checkpoint into "checkpoint/", it is in litgpt format.

I want you to convert it to HuggingFace and write a script convert\_script.py.

The model used is described in checkpoint/model\_config.yaml, it is a Qwen model with ~50 parameters.

Please write code with the following interface:

```
def load_litgpt(path):
    ...

def convert_to_huggingface(path):
    ...

def do_inference_litgpt(context: list[int], litgpt_model):
    ... # returns logits or string

def do_inference_huggingface(context: list[int], litgpt_model):
    ... # returns logits or string

# make sure that the following codes run iterates with "uv run python
# convert_script.py" until it does
litgpt_model = load_litgpt("checkpoint/")
hf_model = convert_to_huggingface("checkpoint/")

random_context = ... # todo draw random context

# makes sure that predictions matches, something like this:
assert do_inference_litgpt(context, litgpt_model) ==
do_inference_huggingface(context, hf_model)
```

This example worked in one shot for instance (!)

# Coding agent

## On the rise

- Les coding agents se sont **dramatiquement** améliorés
- Leur utilisation devient une part croissante de l'utilisation de LLMs

I have a checkpoint into "checkpoint/", it is in litgpt format.

I want you to convert it to HuggingFace and write a script convert\_script.py.

The model used is described in checkpoint/model\_config.yaml, it is a Qwen model with ~50 parameters.

Please write code with the following interface:

```
def load_litgpt(path):
    ...

def convert_to_huggingface(path):
    ...

def do_inference_litgpt(context: list[int], litgpt_model):
    ... # returns logits or string

def do_inference_huggingface(context: list[int], litgpt_model):
    ... # returns logits or string

# make sure that the following codes run iterates with "uv run python
# convert_script.py" until it does
litgpt_model = load_litgpt("checkpoint/")
hf_model = convert_to_huggingface("checkpoint/")

random_context = ... # todo draw random context

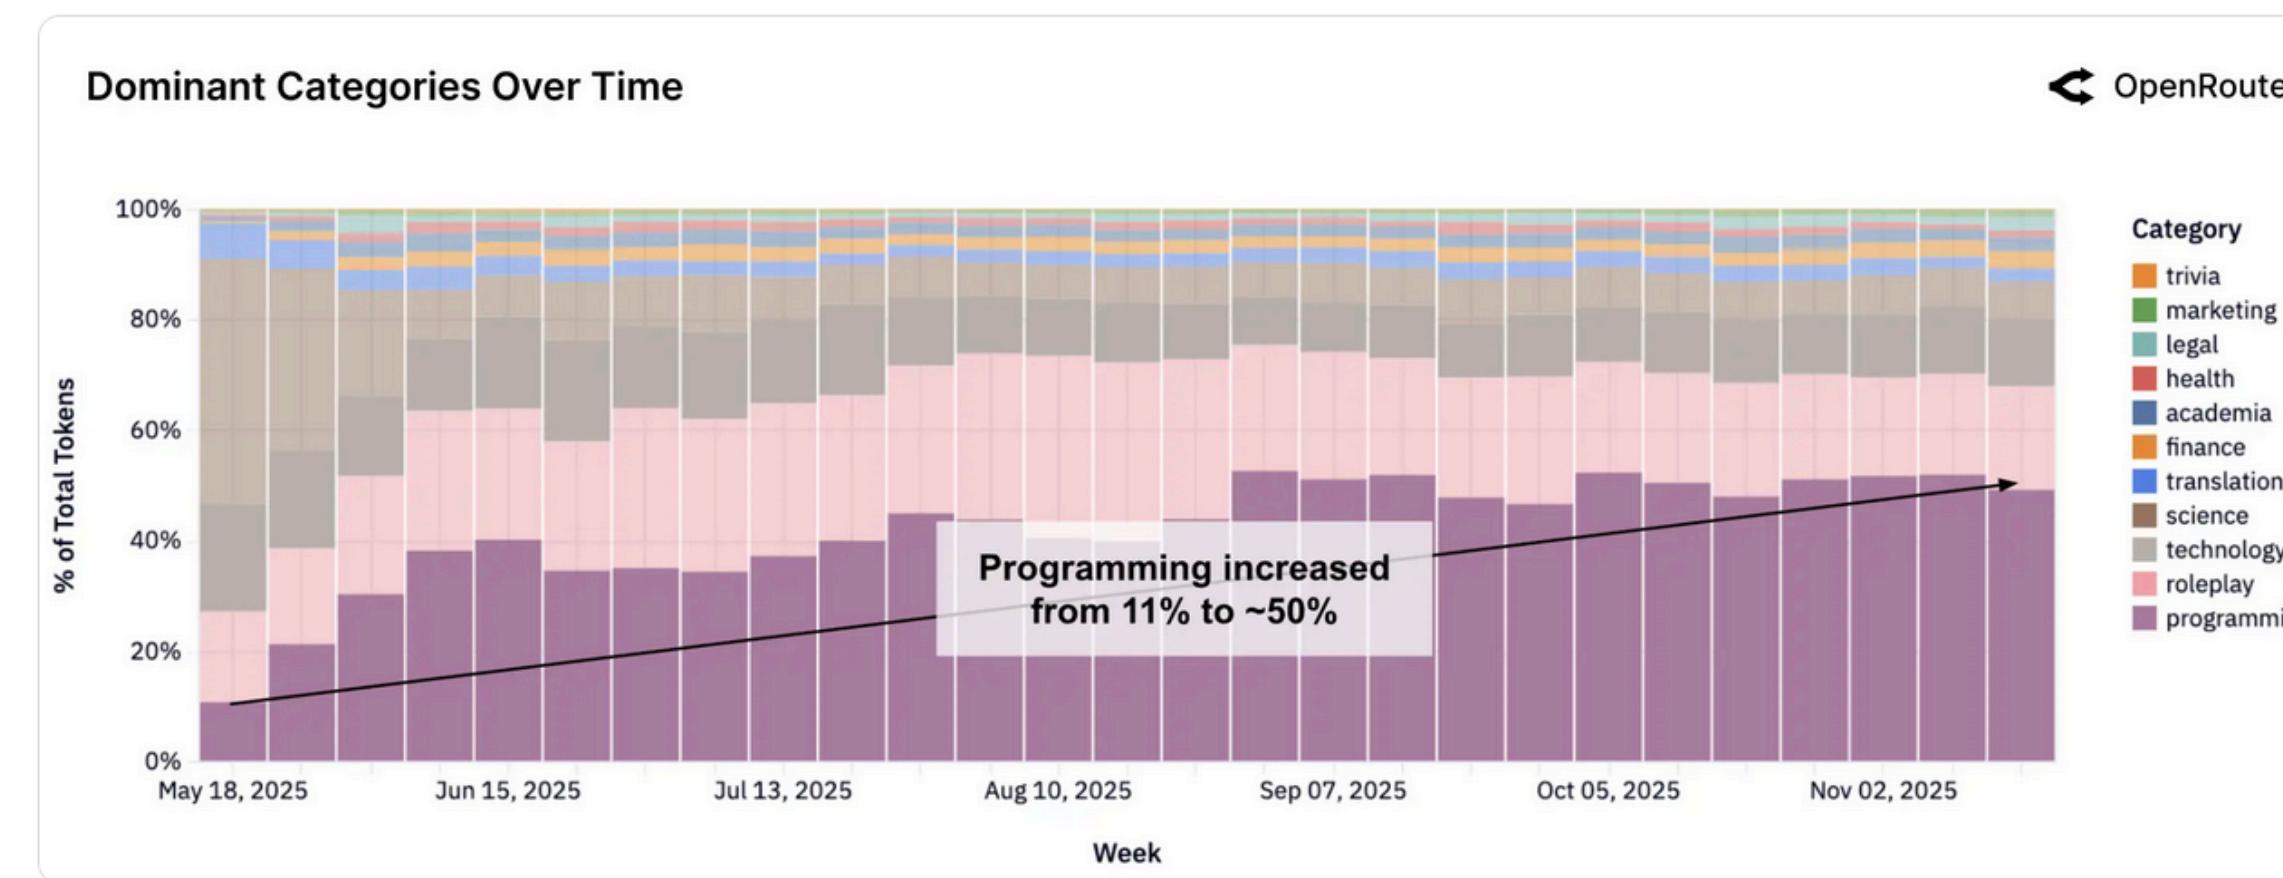
# makes sure that predictions matches, something like this:
assert do_inference_litgpt(context, litgpt_model) ==
do_inference_huggingface(context, hf_model)
```

This example worked in one shot for instance (!)

# Coding agent

## On the rise

- Les coding agents se sont **dramatiquement** améliorés
- Leur utilisation devient une part croissante de l'utilisation de LLMs



**Programming as a dominant and growing category.** The share of all LLM queries classified under programming has increased steadily, reflecting the rise of AI-assisted development workflows.

I have a checkpoint into "checkpoint/", it is in litgpt format.

I want you to convert it to HuggingFace and write a script convert\_script.py.

The model used is described in checkpoint/model\_config.yaml, it is a Qwen model with ~50 parameters.

Please write code with the following interface:

```
def load_litgpt(path):
    ...

def convert_to_huggingface(path):
    ...

def do_inference_litgpt(context: list[int], litgpt_model):
    ... # returns logits or string

def do_inference_huggingface(context: list[int], litgpt_model):
    ... # returns logits or string

# make sure that the following codes run iterates with "uv run python
# convert_script.py" until it does
litgpt_model = load_litgpt("checkpoint/")
hf_model = convert_to_huggingface("checkpoint/")

random_context = ... # todo draw random context

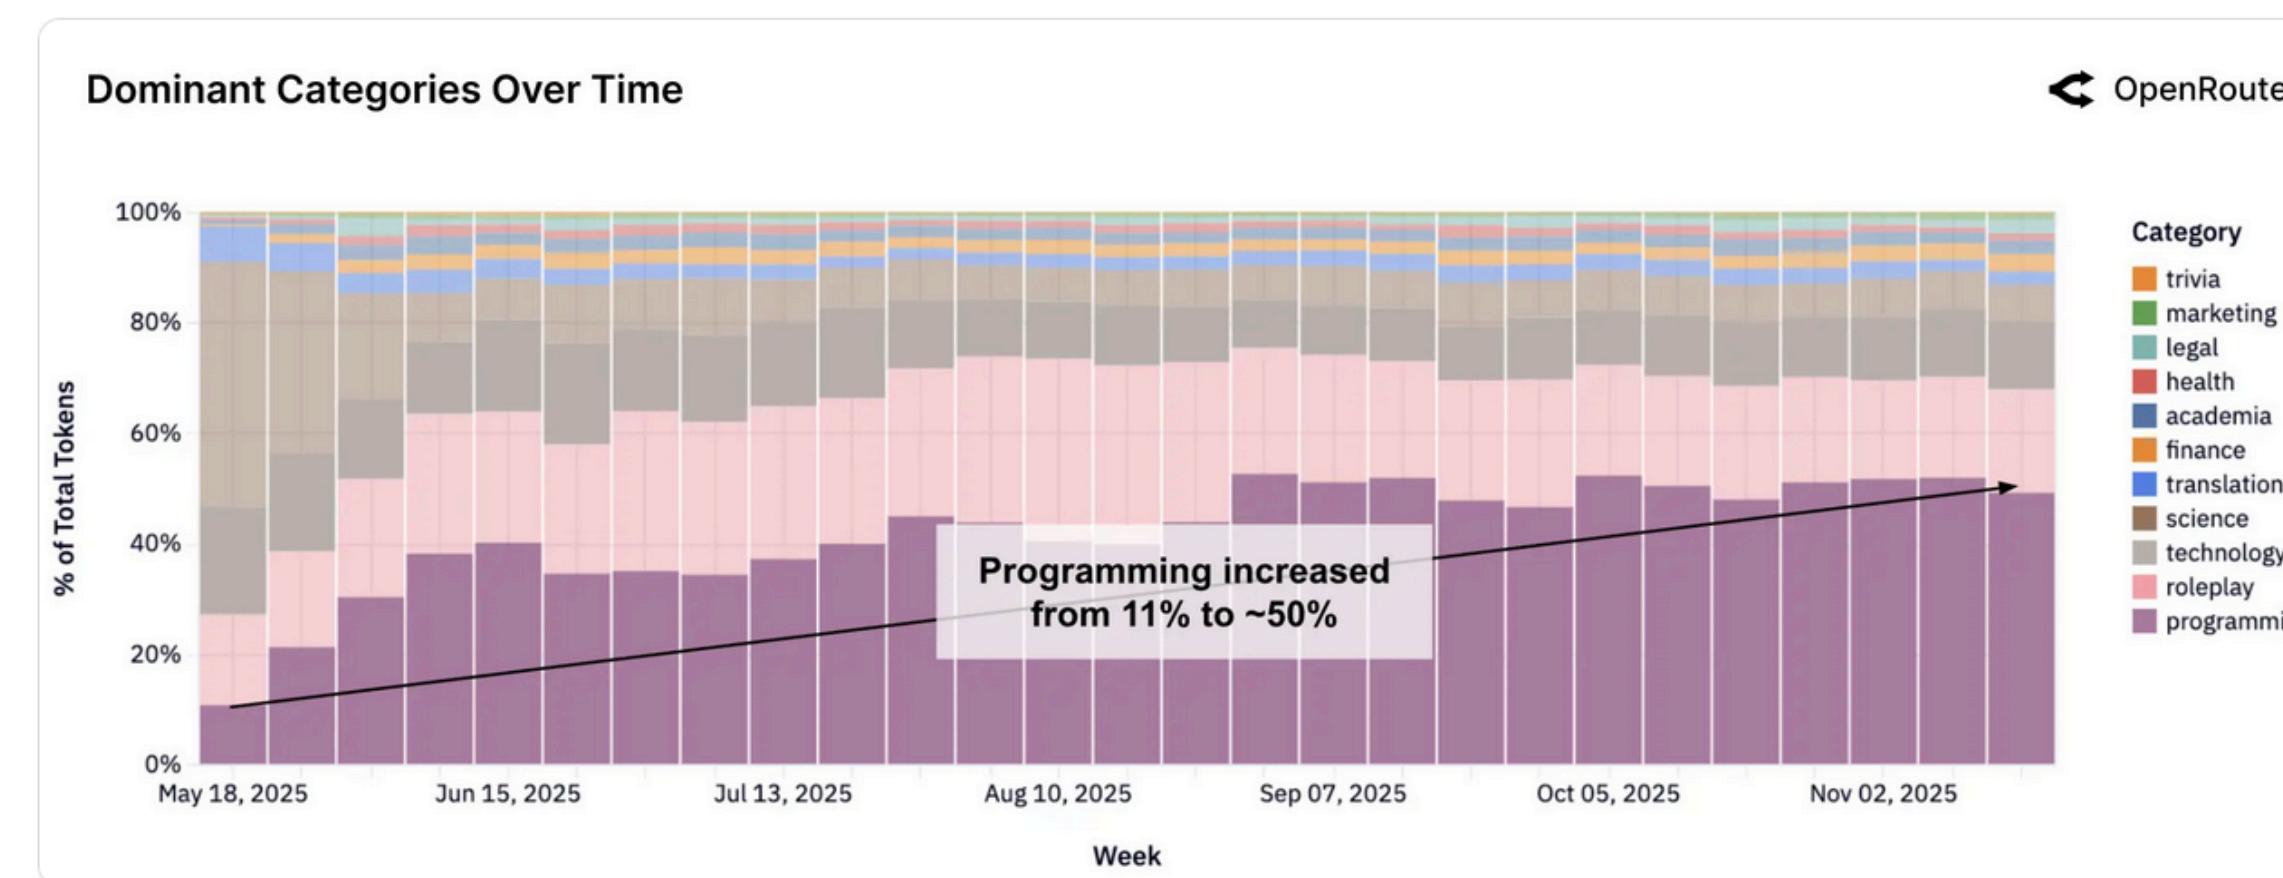
# makes sure that predictions matches, something like this:
assert do_inference_litgpt(context, litgpt_model) ==
do_inference_huggingface(context, hf_model)
```

This example worked in one shot for instance (!)

# Coding agent

## On the rise

- Les coding agents se sont **dramatiquement** améliorés
- Leur utilisation devient une part croissante de l'utilisation de LLMs
- Aussi potentiellement très profitable:



**Programming as a dominant and growing category.** The share of all LLM queries classified under programming has increased steadily, reflecting the rise of AI-assisted development workflows.

<https://openrouter.ai/state-of-ai>

I have a checkpoint into "checkpoint/", it is in litgpt format.

I want you to convert it to HuggingFace and write a script convert\_script.py.

The model used is described in checkpoint/model\_config.yaml, it is a Qwen model with ~50 parameters.

Please write code with the following interface:

```
def load_litgpt(path):
    ...

def convert_to_huggingface(path):
    ...

def do_inference_litgpt(context: list[int], litgpt_model):
    ... # returns logits or string

def do_inference_huggingface(context: list[int], litgpt_model):
    ... # returns logits or string

# make sure that the following codes run iterates with "uv run python
# convert_script.py" until it does
litgpt_model = load_litgpt("checkpoint/")
hf_model = convert_to_huggingface("checkpoint/")

random_context = ... # todo draw random context

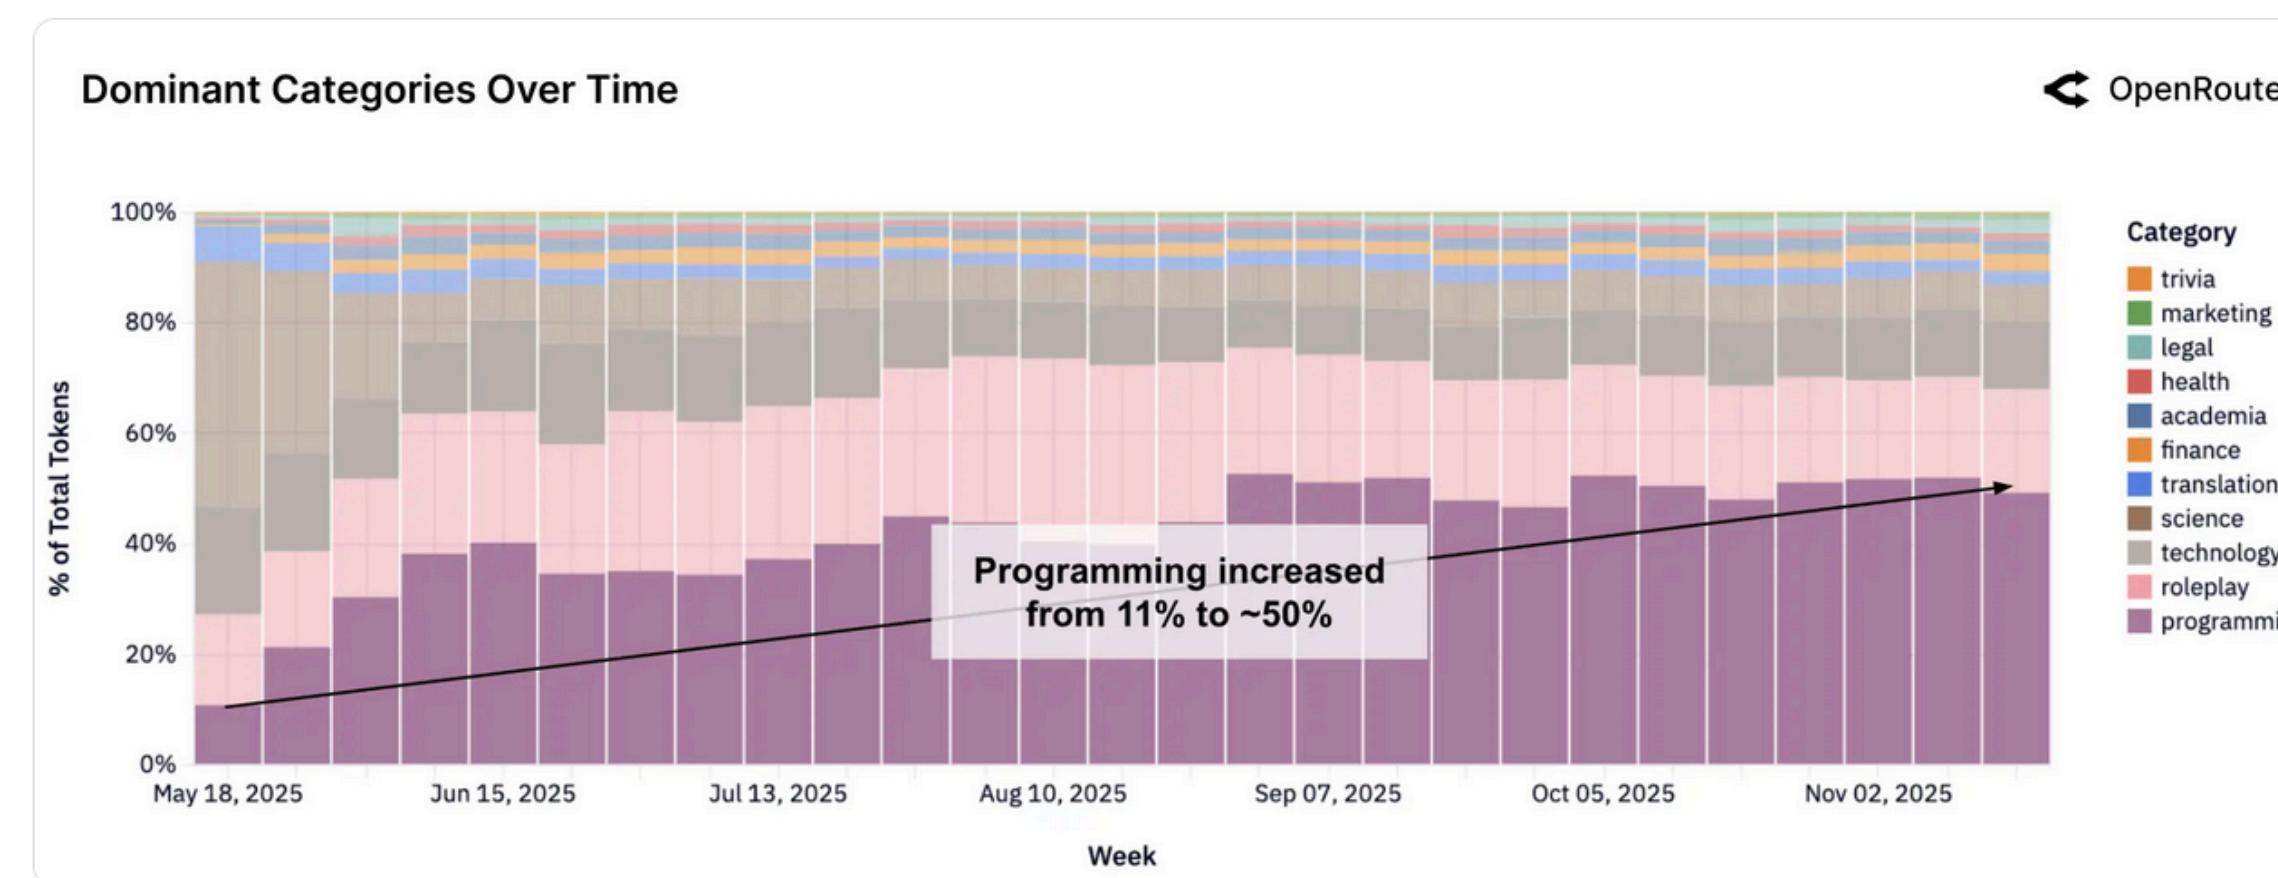
# makes sure that predictions matches, something like this:
assert do_inference_litgpt(context, litgpt_model) ==
do_inference_huggingface(context, hf_model)
```

This example worked in one shot for instance (!)

# Coding agent

## On the rise

- Les coding agents se sont **dramatiquement** améliorés
- Leur utilisation devient une part croissante de l'utilisation de LLMs
- Aussi potentiellement très profitable:
  - €200/mois pour un abonnement Claude max



**Programming as a dominant and growing category.** The share of all LLM queries classified under programming has increased steadily, reflecting the rise of AI-assisted development workflows.

I have a checkpoint into "checkpoint/", it is in litgpt format.

I want you to convert it to HuggingFace and write a script convert\_script.py.

The model used is described in checkpoint/model\_config.yaml, it is a Qwen model with ~50 parameters.

Please write code with the following interface:

```
def load_litgpt(path):  
    ...  
  
def convert_to_huggingface(path):  
    ...  
  
def do_inference_litgpt(context: list[int], litgpt_model):  
    ... # returns logits or string  
  
def do_inference_huggingface(context: list[int], litgpt_model):  
    ... # returns logits or string  
  
# make sure that the following codes run iterates with "uv run python  
convert_script.py" until it does  
litgpt_model = load_litgpt("checkpoint/")  
hf_model = convert_to_huggingface("checkpoint/")  
  
random_context = ... # todo draw random context  
  
# makes sure that predictions matches, something like this:  
assert do_inference_litgpt(context, litgpt_model) ==  
do_inference_huggingface(context, hf_model)
```

This example worked in one shot for instance (!)

# Enjeux des coding agents

- Security
- Open-source vs propriétaire
- Evaluation
- Souveraineté

# Security

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission *de lire des fichiers* (pour lire le code)

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission de *lire des fichiers* (pour lire le code)
  - Permission d'*écrire des fichiers* (pour écrire du code, des configurations, ...)

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission *de lire des fichiers* (pour lire le code)
  - Permission *d'écrire des fichiers* (pour écrire du code, des configurations, ...)
  - Permission *d'exécuter des processus* (exécuter Python, effectuer des opérations bash)

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission *de lire des fichiers* (pour lire le code)
  - Permission *d'écrire des fichiers* (pour écrire du code, des configurations, ...)
  - Permission *d'exécuter des processus* (exécuter Python, effectuer des opérations bash)
  - Permission *d'exécuter du code* provenant de serveurs MCP

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission de *lire des fichiers* (pour lire le code)
  - Permission d'*écrire des fichiers* (pour écrire du code, des configurations, ...)
  - Permission d'*exécuter des processus* (exécuter Python, effectuer des opérations bash)
  - Permission d'*exécuter du code* provenant de serveurs MCP

Question: Quelqu'un sait-il ce qu'est le YOLO mode? 🤔

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission de *lire des fichiers* (pour lire le code)
  - Permission d'*écrire des fichiers* (pour écrire du code, des configurations, ...)
  - Permission d'*exécuter des processus* (exécuter Python, effectuer des opérations bash)
  - Permission d'*exécuter du code* provenant de serveurs MCP
- YOLO = You only live once (on ne vit qu'une fois)

Question: Quelqu'un sait-il ce qu'est le YOLO mode? 🤔

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission de *lire des fichiers* (pour lire le code)
  - Permission d'*écrire des fichiers* (pour écrire du code, des configurations, ...)
  - Permission d'*exécuter des processus* (exécuter Python, effectuer des opérations bash)
  - Permission d'*exécuter du code* provenant de serveurs MCP
- YOLO = You only live once (on ne vit qu'une fois)
  - => Accorder toutes les permissions et lancer l'exécution

Question: Quelqu'un sait-il ce qu'est le YOLO mode? 🤔

# Security

- Exécuter un coding agent nécessite de régler de nombreuses permissions :
  - Permission de *lire des fichiers* (pour lire le code)
  - Permission d'*écrire des fichiers* (pour écrire du code, des configurations, ...)
  - Permission d'*exécuter des processus* (exécuter Python, effectuer des opérations bash)
  - Permission d'*exécuter du code* provenant de serveurs MCP
- YOLO = You only live once (on ne vit qu'une fois)
  - => Accorder toutes les permissions et lancer l'exécution
  - Mode très répandu et risque de sécurité énorme, y compris avec les modèles open-weights

Question: Quelqu'un sait-il ce qu'est le YOLO mode? 🤔

# **Security**

## **What to do**

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé
- Option 2 : Bien comprendre les risques, appliquer toutes les précautions recommandées

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé
- Option 2 : Bien comprendre les risques, appliquer toutes les précautions recommandées
  - N'activer que les serveurs MCP de confiance, n'autoriser l'accès qu'à des fichiers spécifiques, ...

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé
- Option 2 : Bien comprendre les risques, appliquer toutes les précautions recommandées
  - N'activer que les serveurs MCP de confiance, n'autoriser l'accès qu'à des fichiers spécifiques, ...
  - Même définir les permissions manuellement est probablement une mauvaise idée, de nombreuses erreurs sont commises, de nombreux systèmes sont compromis

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé
- Option 2 : Bien comprendre les risques, appliquer toutes les précautions recommandées
  - N'activer que les serveurs MCP de confiance, n'autoriser l'accès qu'à des fichiers spécifiques, ...
  - Même définir les permissions manuellement est probablement une mauvaise idée, de nombreuses erreurs sont commises, de nombreux systèmes sont compromis
- Développement de systèmes déployés “on-prem”

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé
- Option 2 : Bien comprendre les risques, appliquer toutes les précautions recommandées
  - N'activer que les serveurs MCP de confiance, n'autoriser l'accès qu'à des fichiers spécifiques, ...
  - Même définir les permissions manuellement est probablement une mauvaise idée, de nombreuses erreurs sont commises, de nombreux systèmes sont compromis
- Développement de systèmes déployés “on-prem”
  - Mistral, Cohere, Poolside

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé
- Option 2 : Bien comprendre les risques, appliquer toutes les précautions recommandées
  - N'activer que les serveurs MCP de confiance, n'autoriser l'accès qu'à des fichiers spécifiques, ...
  - Même définir les permissions manuellement est probablement une mauvaise idée, de nombreuses erreurs sont commises, de nombreux systèmes sont compromis
- Développement de systèmes déployés “on-prem”
  - Mistral, Cohere, Poolside
  - Restriction d'accès à internet, meilleure sécurité

# Security

## What to do

- Option 1 : Utiliser un bac à sable (sandbox), par exemple Claude Code peut être utilisé dans un navigateur dans un environnement isolé
- Option 2 : Bien comprendre les risques, appliquer toutes les précautions recommandées
  - N'activer que les serveurs MCP de confiance, n'autoriser l'accès qu'à des fichiers spécifiques, ...
  - Même définir les permissions manuellement est probablement une mauvaise idée, de nombreuses erreurs sont commises, de nombreux systèmes sont compromis
- Développement de systèmes déployés “on-prem”
  - Mistral, Cohere, Poolside
  - Restriction d'accès à internet, meilleure sécurité
  - => Gros marché

# Open-source vs proprietary

# Open-source vs proprietary

- Pour être clair:

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API
    - Example: GPT-4, Claude-Opus, Gemini, ...

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API
    - Example: GPT-4, Claude-Opus, Gemini, ...
  - *Open-weight*: modèle dont les paramètres sont disponible au téléchargement

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API
    - Example: GPT-4, Claude-Opus, Gemini, ...
  - *Open-weight*: modèle dont les paramètres sont disponible au téléchargement
    - Example: modèles Llama, Mistral, Deepseek, Qwen, GPT-OSS-120B

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API
    - Example: GPT-4, Claude-Opus, Gemini, ...
  - *Open-weight*: modèle dont les paramètres sont disponibles au téléchargement
    - Example: modèles Llama, Mistral, Deepseek, Qwen, GPT-OSS-120B
  - Open-Source: modèles dont le code et les données sont disponibles en plus des paramètres

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API
    - Example: GPT-4, Claude-Opus, Gemini, ...
  - *Open-weight*: modèle dont les paramètres sont disponibles au téléchargement
    - Example: modèles Llama, Mistral, Deepseek, Qwen, GPT-OSS-120B
  - Open-Source: modèles dont le code et les données sont disponibles en plus des paramètres
    - Example:

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API
    - Example: GPT-4, Claude-Opus, Gemini, ...
  - *Open-weight*: modèle dont les paramètres sont disponibles au téléchargement
    - Example: modèles Llama, Mistral, Deepseek, Qwen, GPT-OSS-120B
  - Open-Source: modèles dont le code et les données sont disponibles en plus des paramètres
    - Example:
      - Base: GPT-Neo-x, Bloom, MPT, Pythia, Falcon, Polythias, OLMo2, ...

# Open-source vs proprietary

- Pour être clair:
  - *Propriétaire*: modèle disponible à travers une API
    - Example: GPT-4, GPT-4, Claude-Opus, Gemini, ...
  - *Open-weight*: modèle dont les paramètres sont disponibles au téléchargement
    - Example: modèles Llama, Mistral, Deepseek, Qwen, GPT-OSS-120B
  - Open-Source: modèles dont le code et les données sont disponibles en plus des paramètres
    - Example:
      - Base: GPT-Neo-x, Bloom, MPT, Pythia, Falcon, Polythias, OLMo2, ...
      - Instruction-tuned: SmoILM, StarCoder, Olmo3, ...

# Open-source vs proprietary

## Un modèle pour tous n'est pas une bonne solution

Building out **17 gigawatts** of capacity would require the equivalent of about **17 nuclear power** plants, each of which takes at least a decade to build. The OpenAI team says talks are underway with hundreds of infrastructure providers across North America, but there are no firm answers yet.

The U.S. grid is already strained, gas turbines are sold out through 2028, nuclear is slow to deploy, and renewables are tied up in political roadblocks.

“I am extremely bullish about nuclear, advanced fission, fusion,” Altman said. “We should build more ... a lot more of the current generation of fission plants, given the needs for dense, dense energy.”

**Source:** <https://www.cnbc.com/2025/09/26/openai-big-week-ai-arms-race.html>

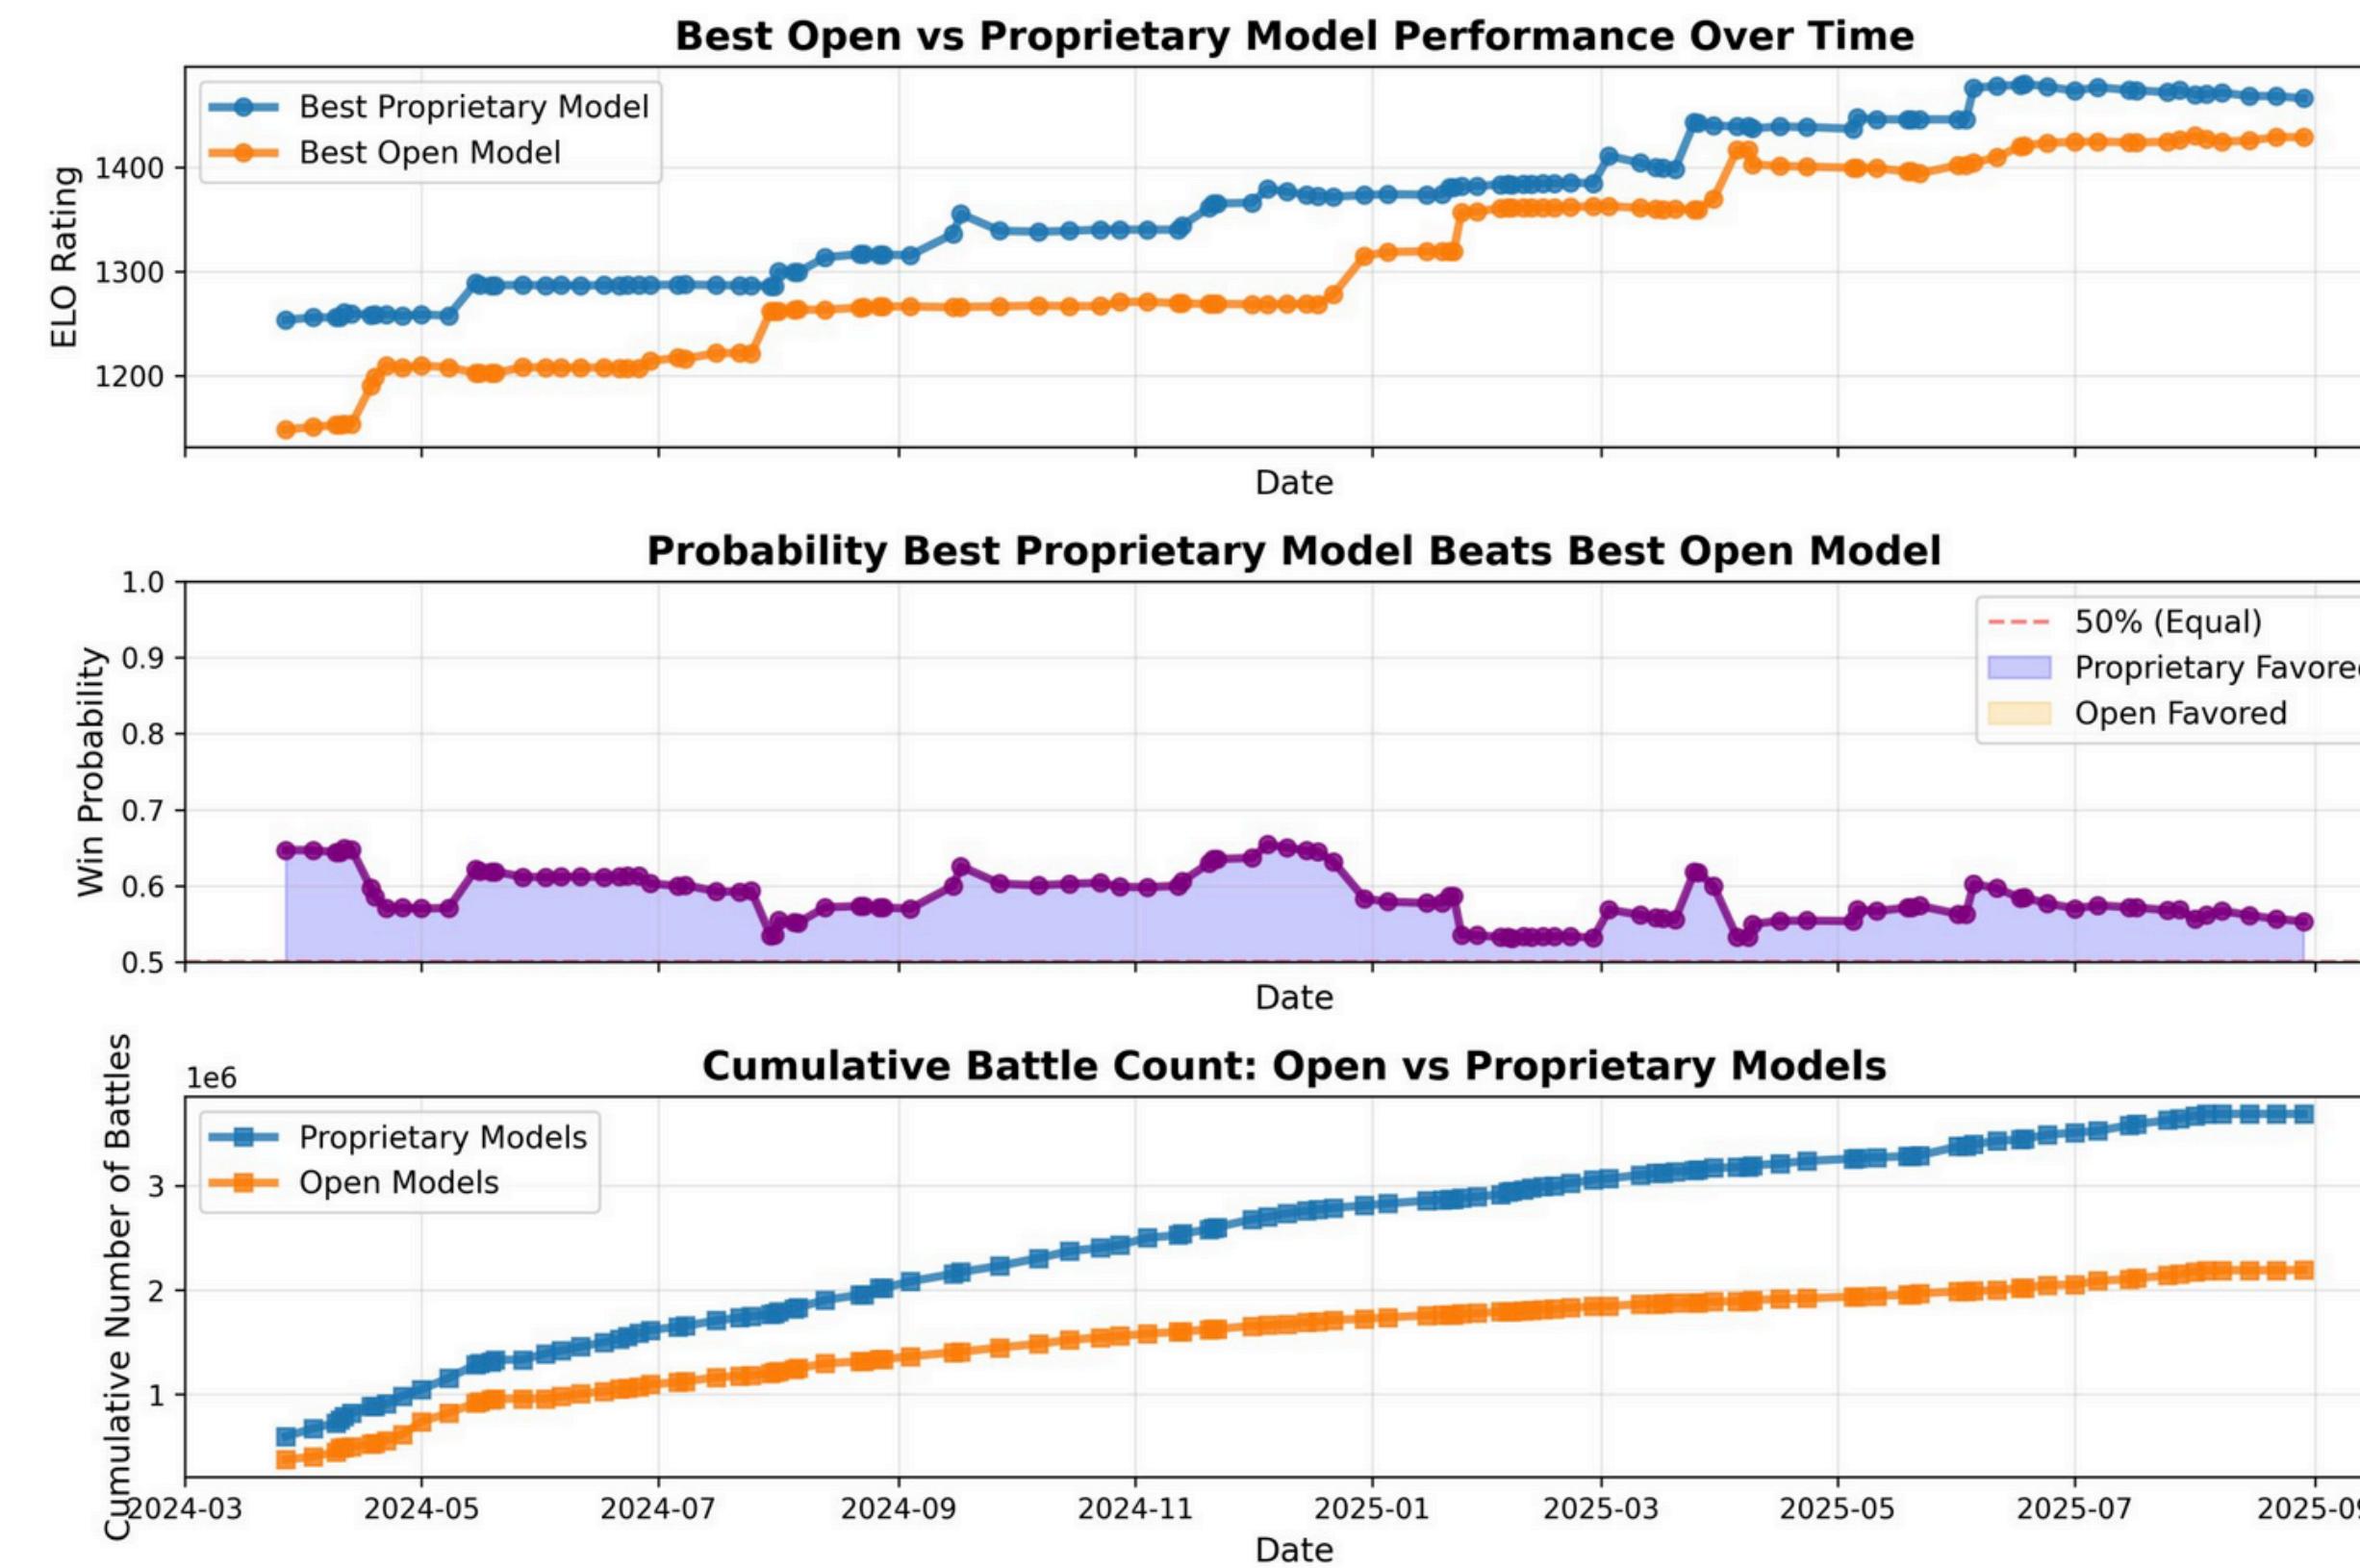
- Entrainer un modèle par entreprise serait un désastre
  - écologique
  - sociétal (concentration des pouvoirs)

# Open-source vs proprietary

Quel écart?

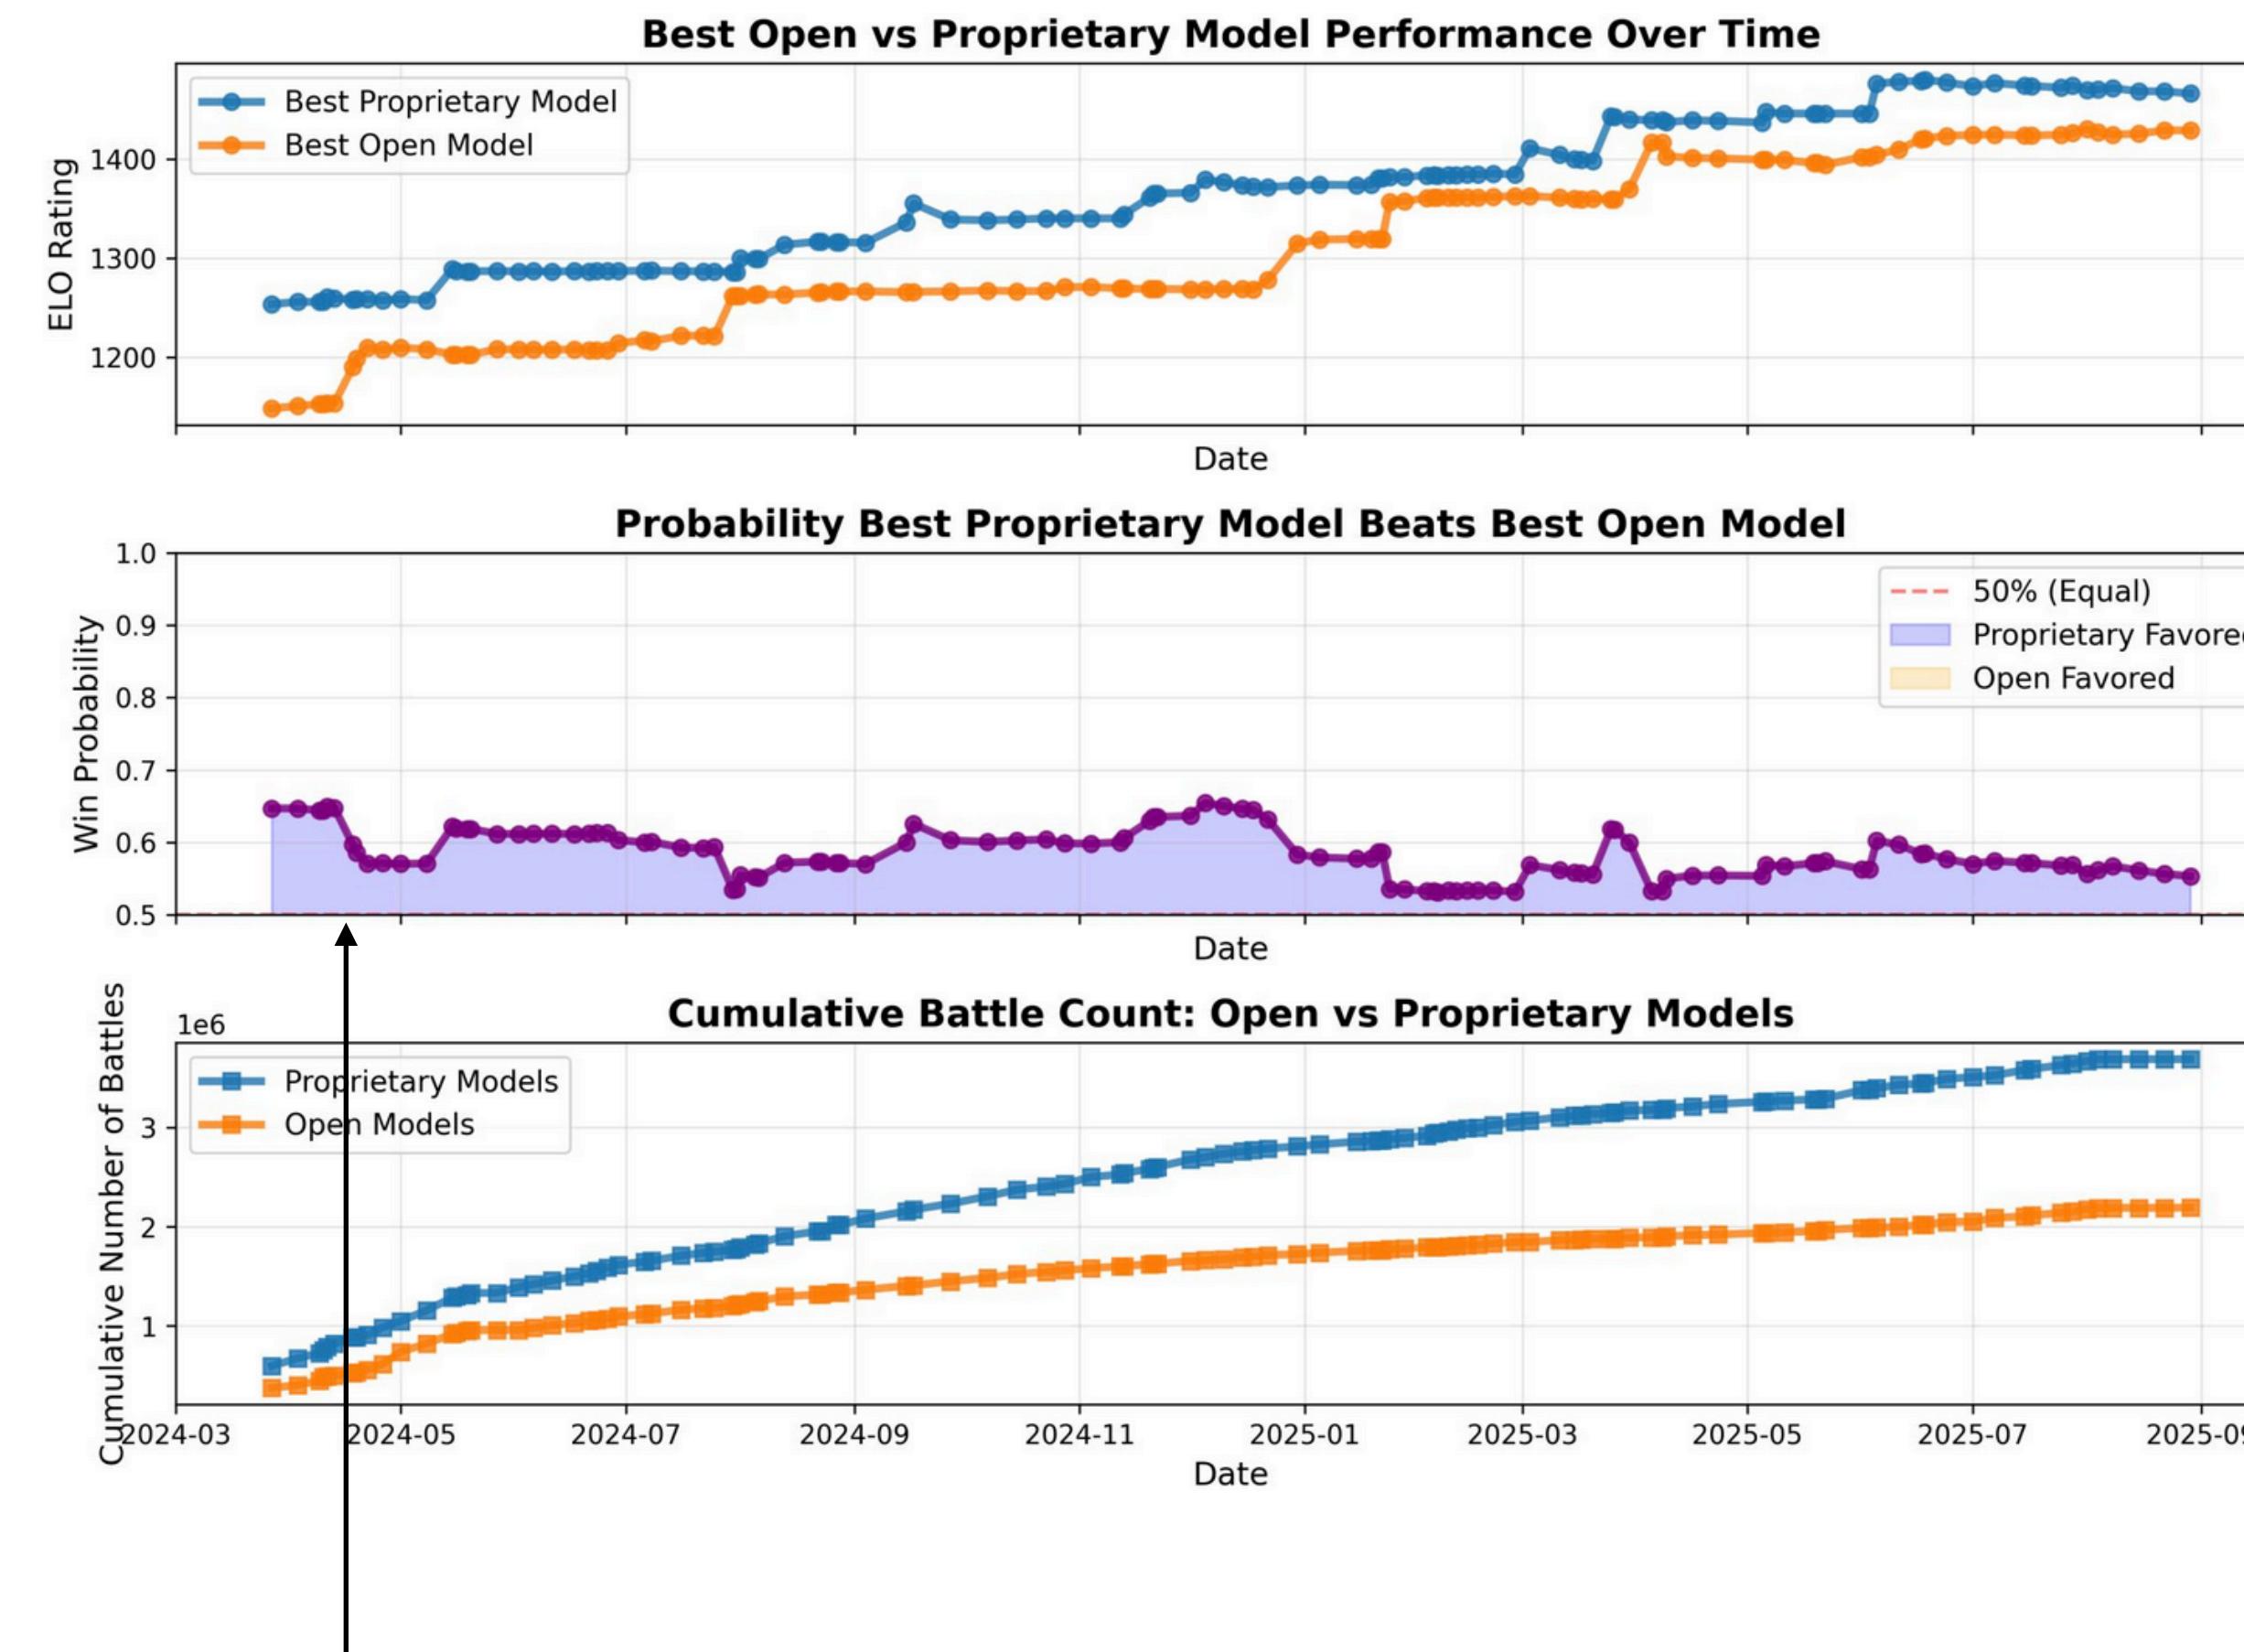
# Open-source vs proprietary

## Quel écart?



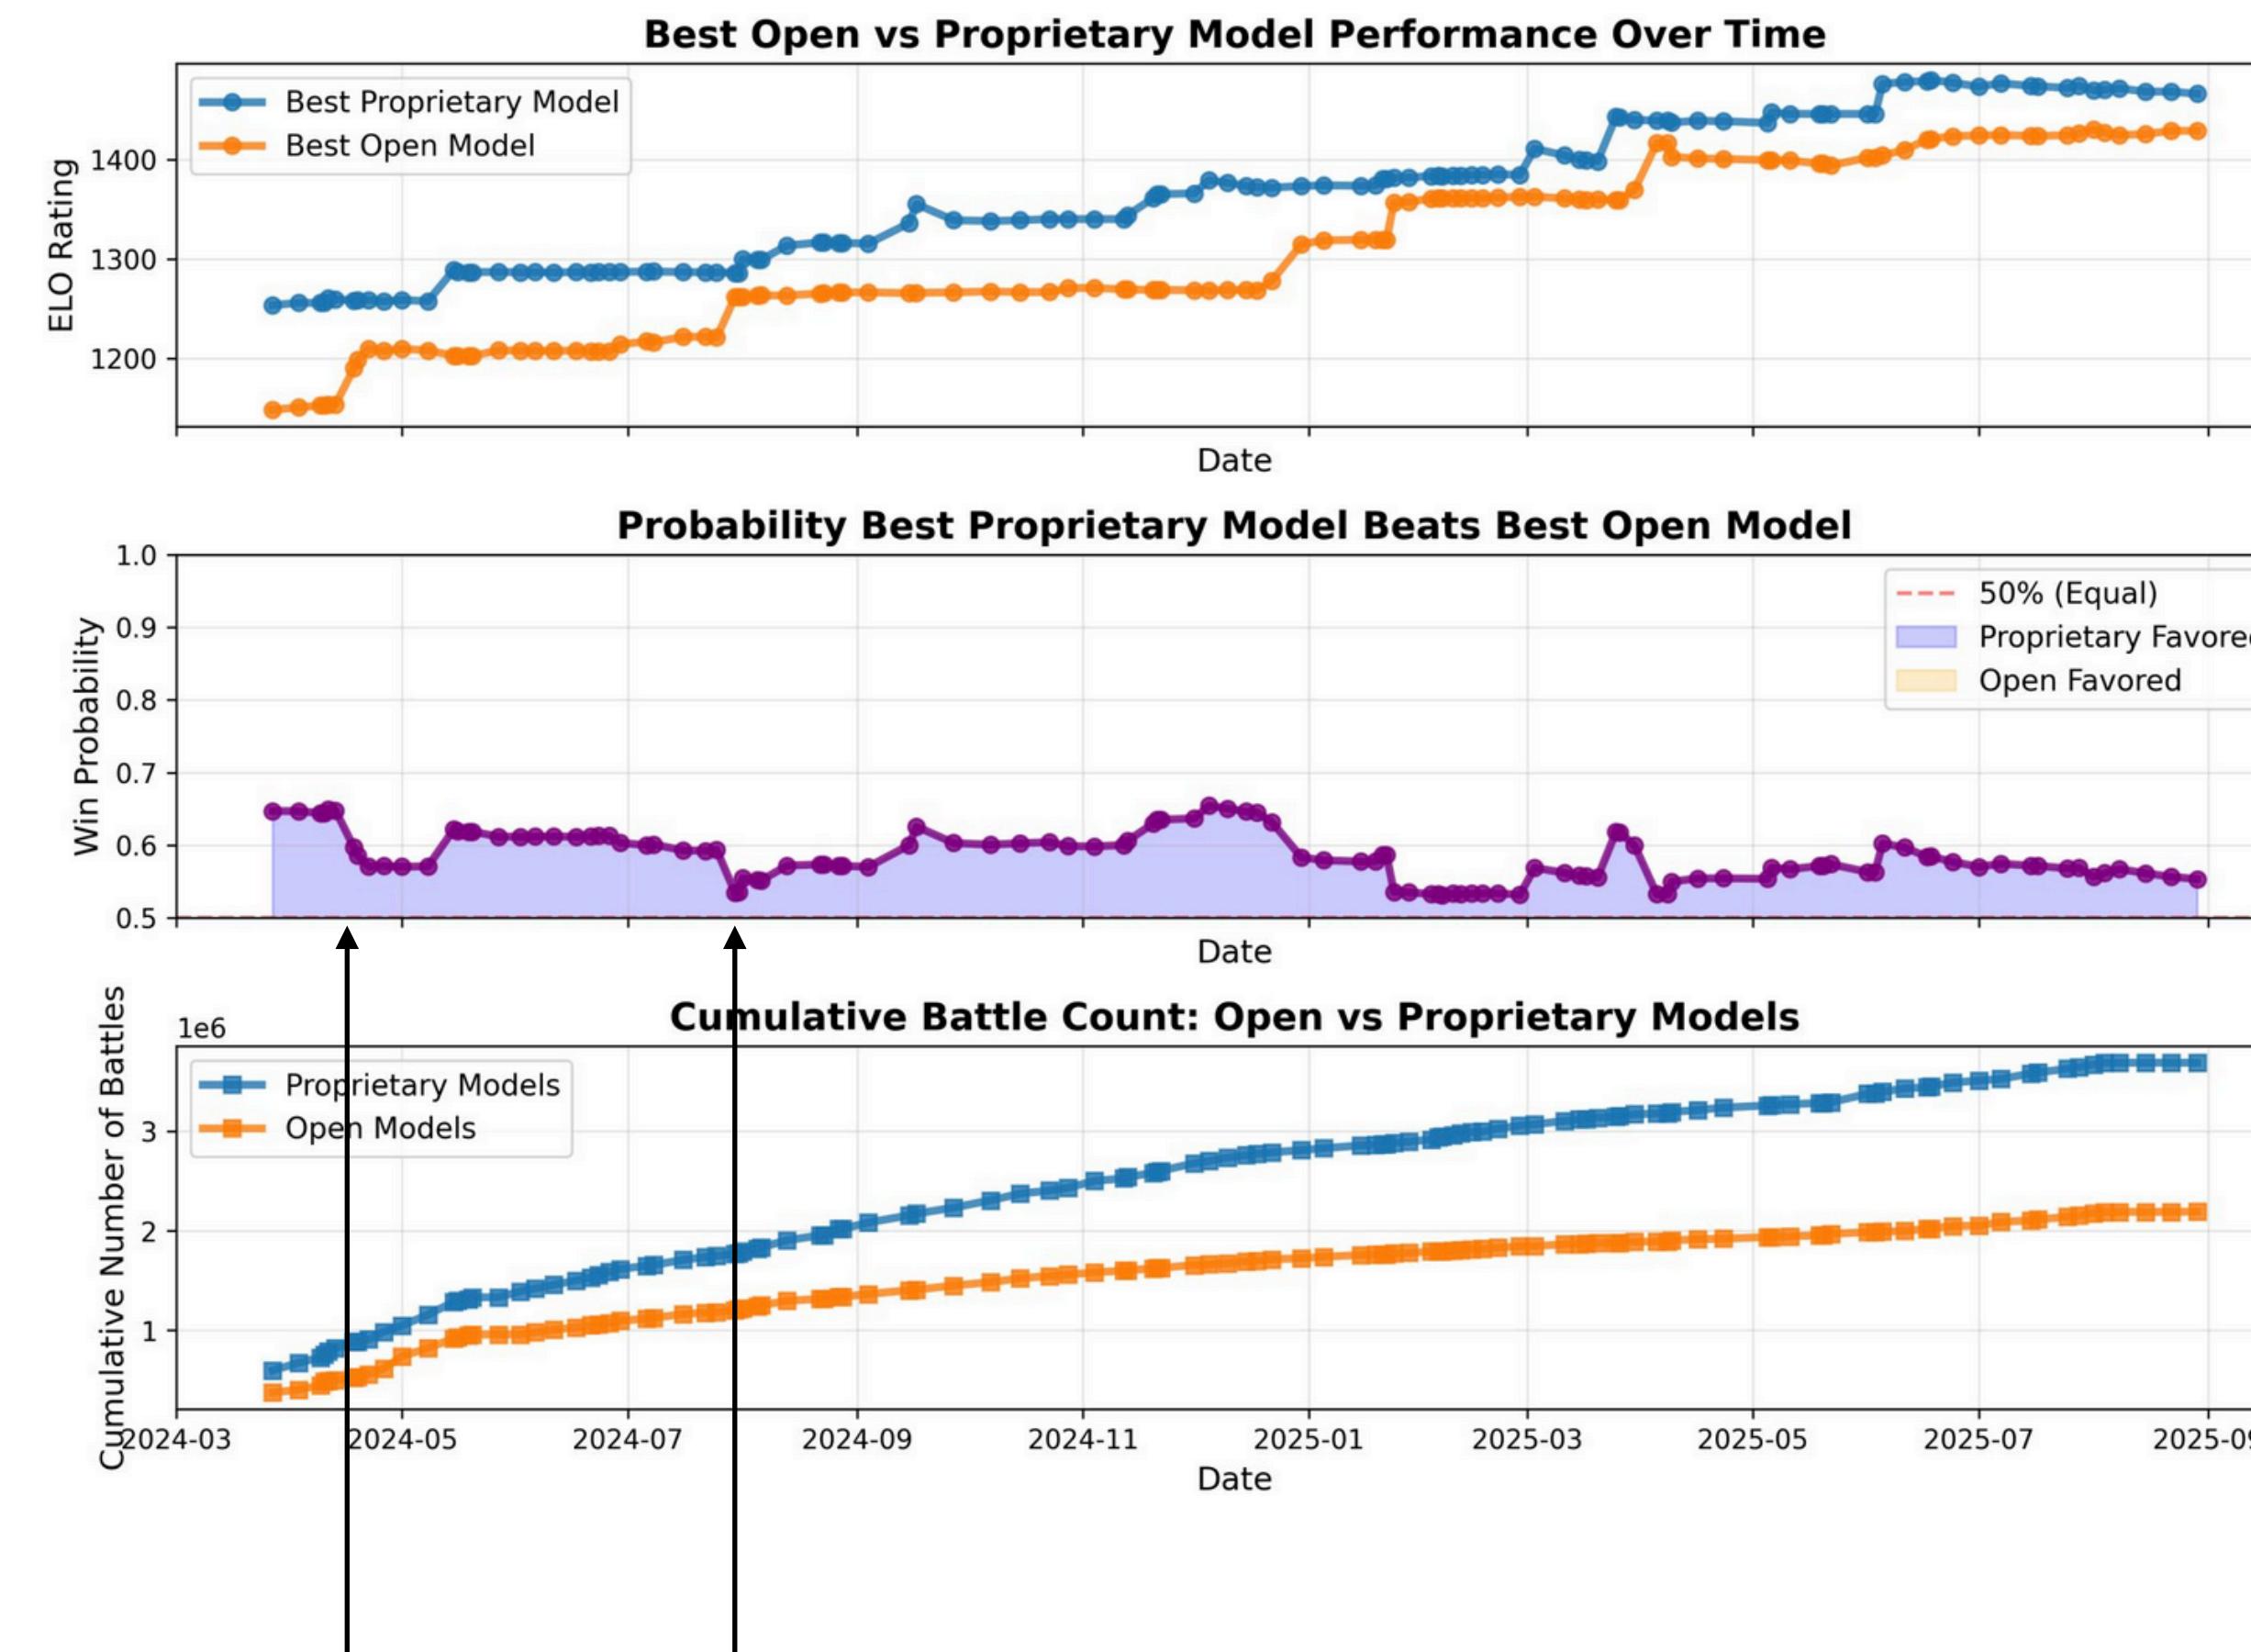
# Open-source vs proprietary

## Quel écart?



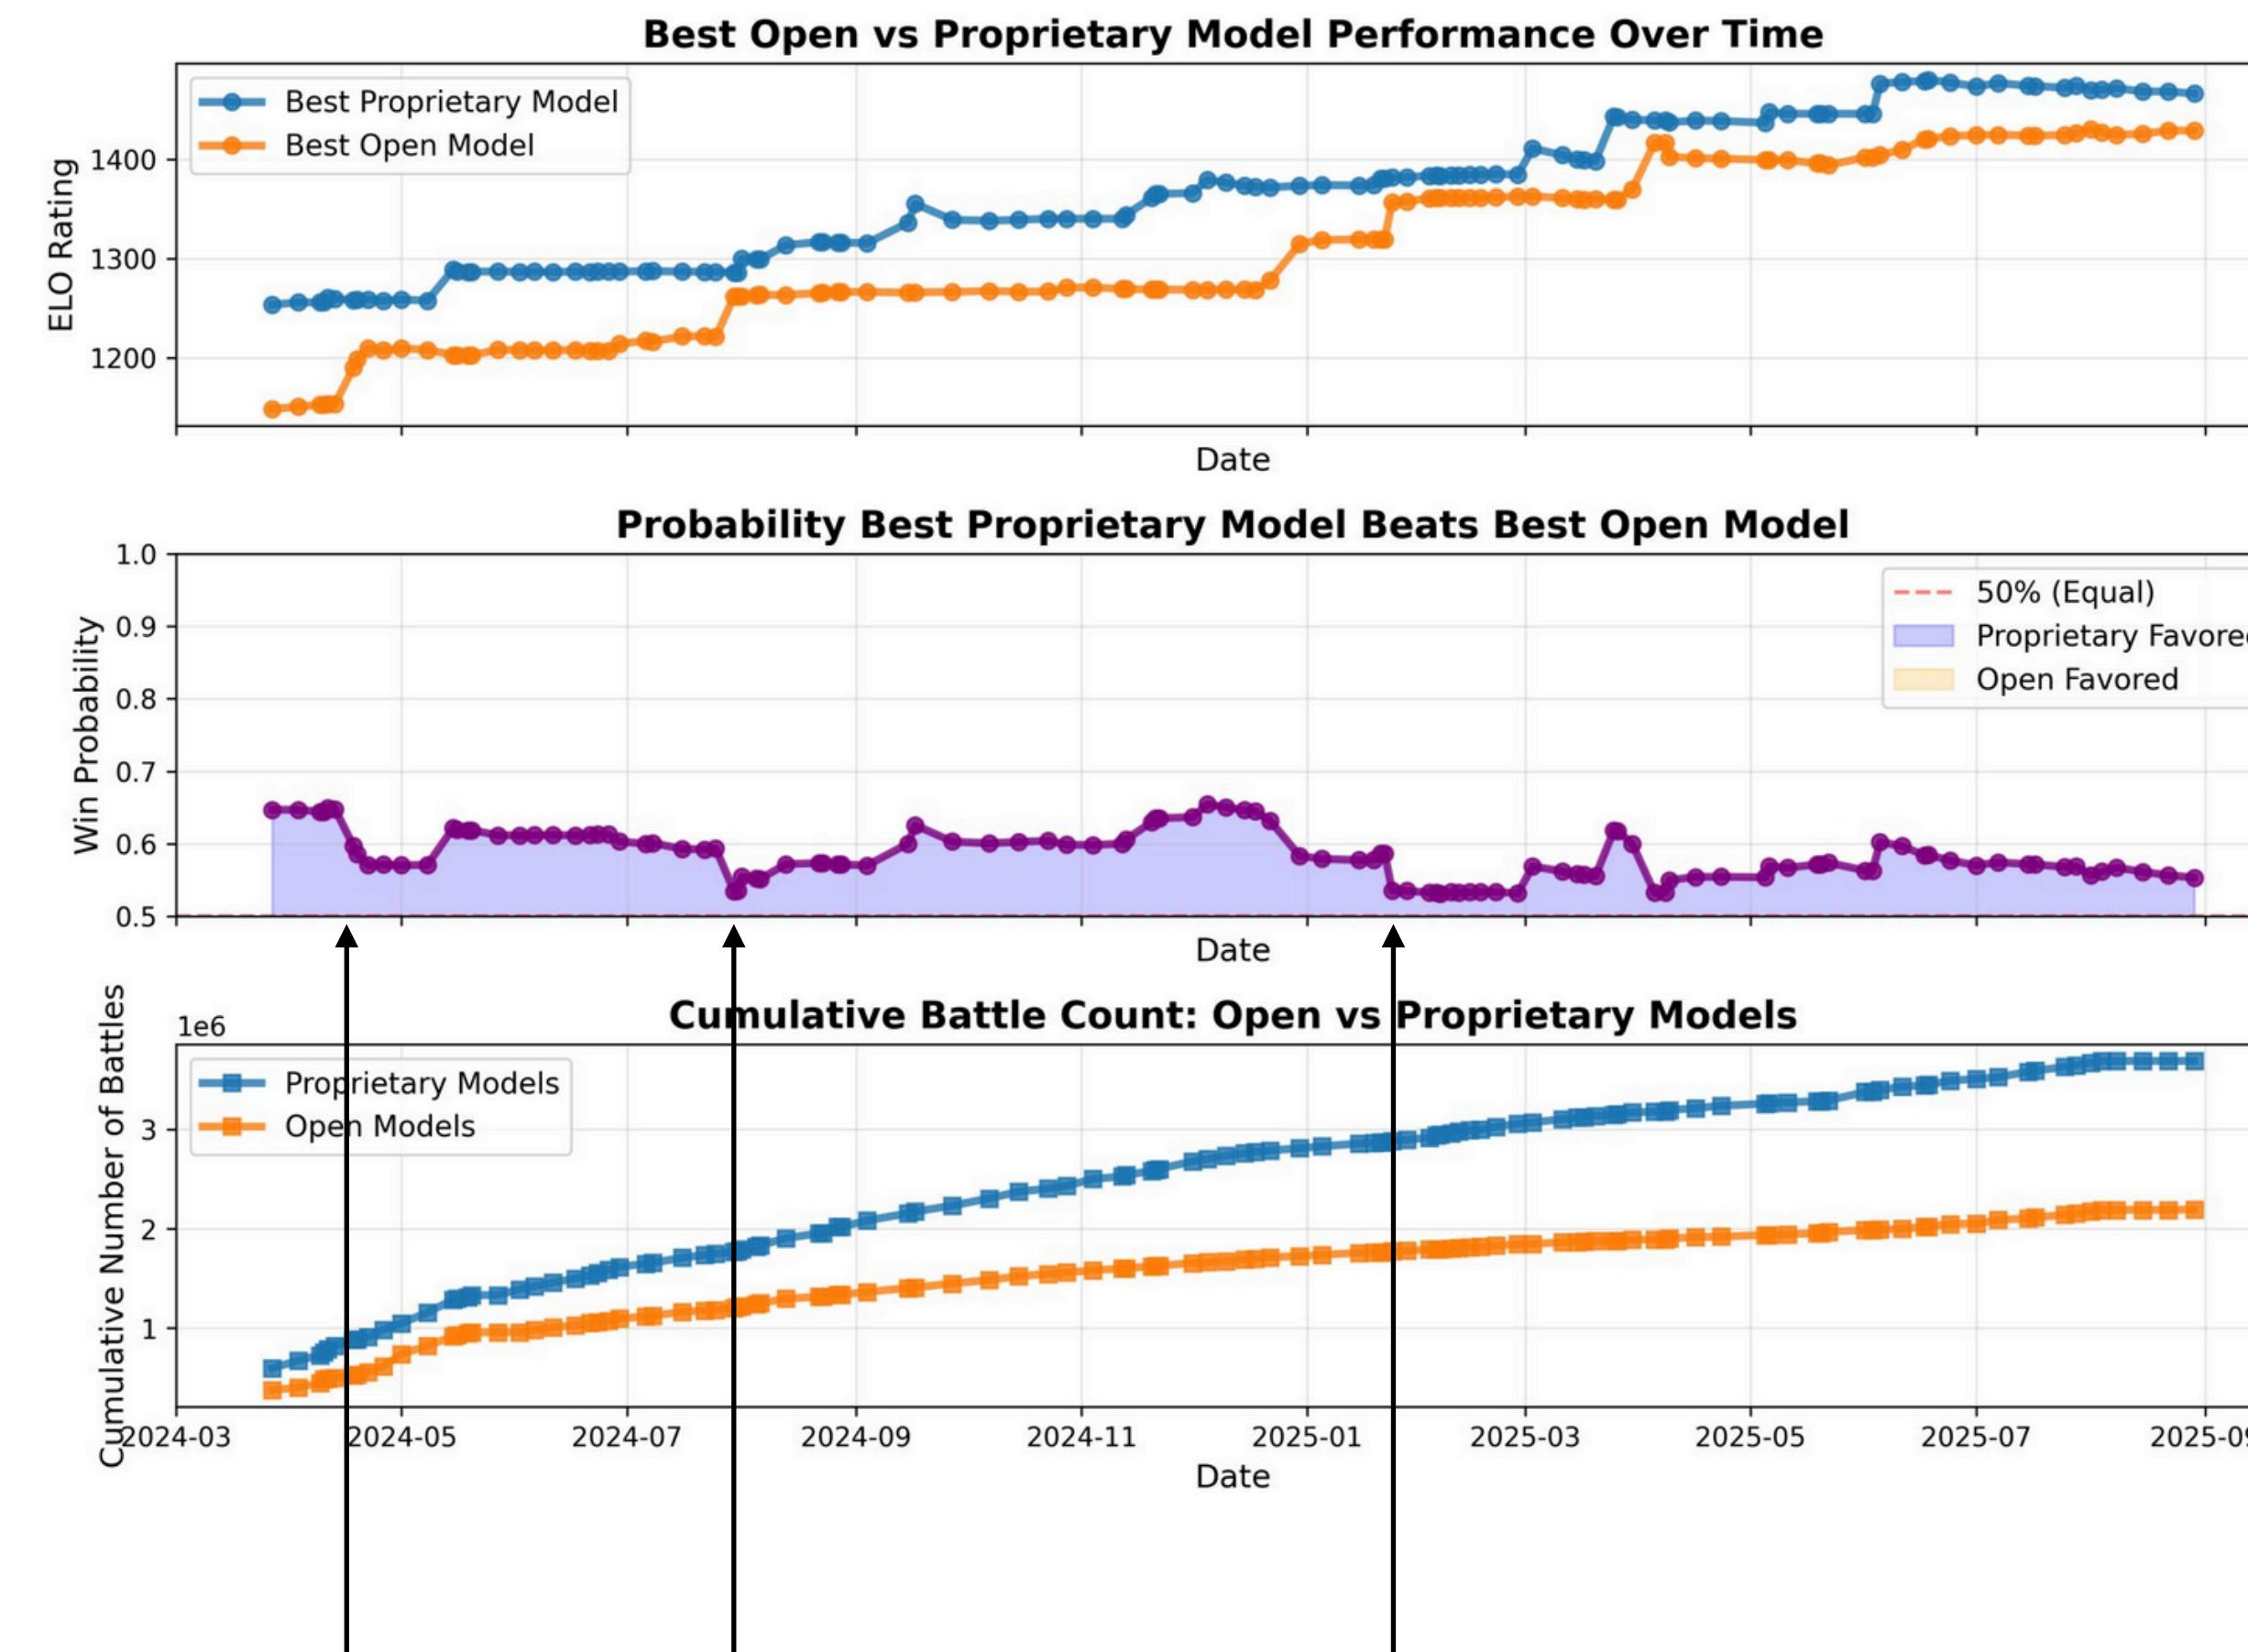
# Open-source vs proprietary

## Quel écart?



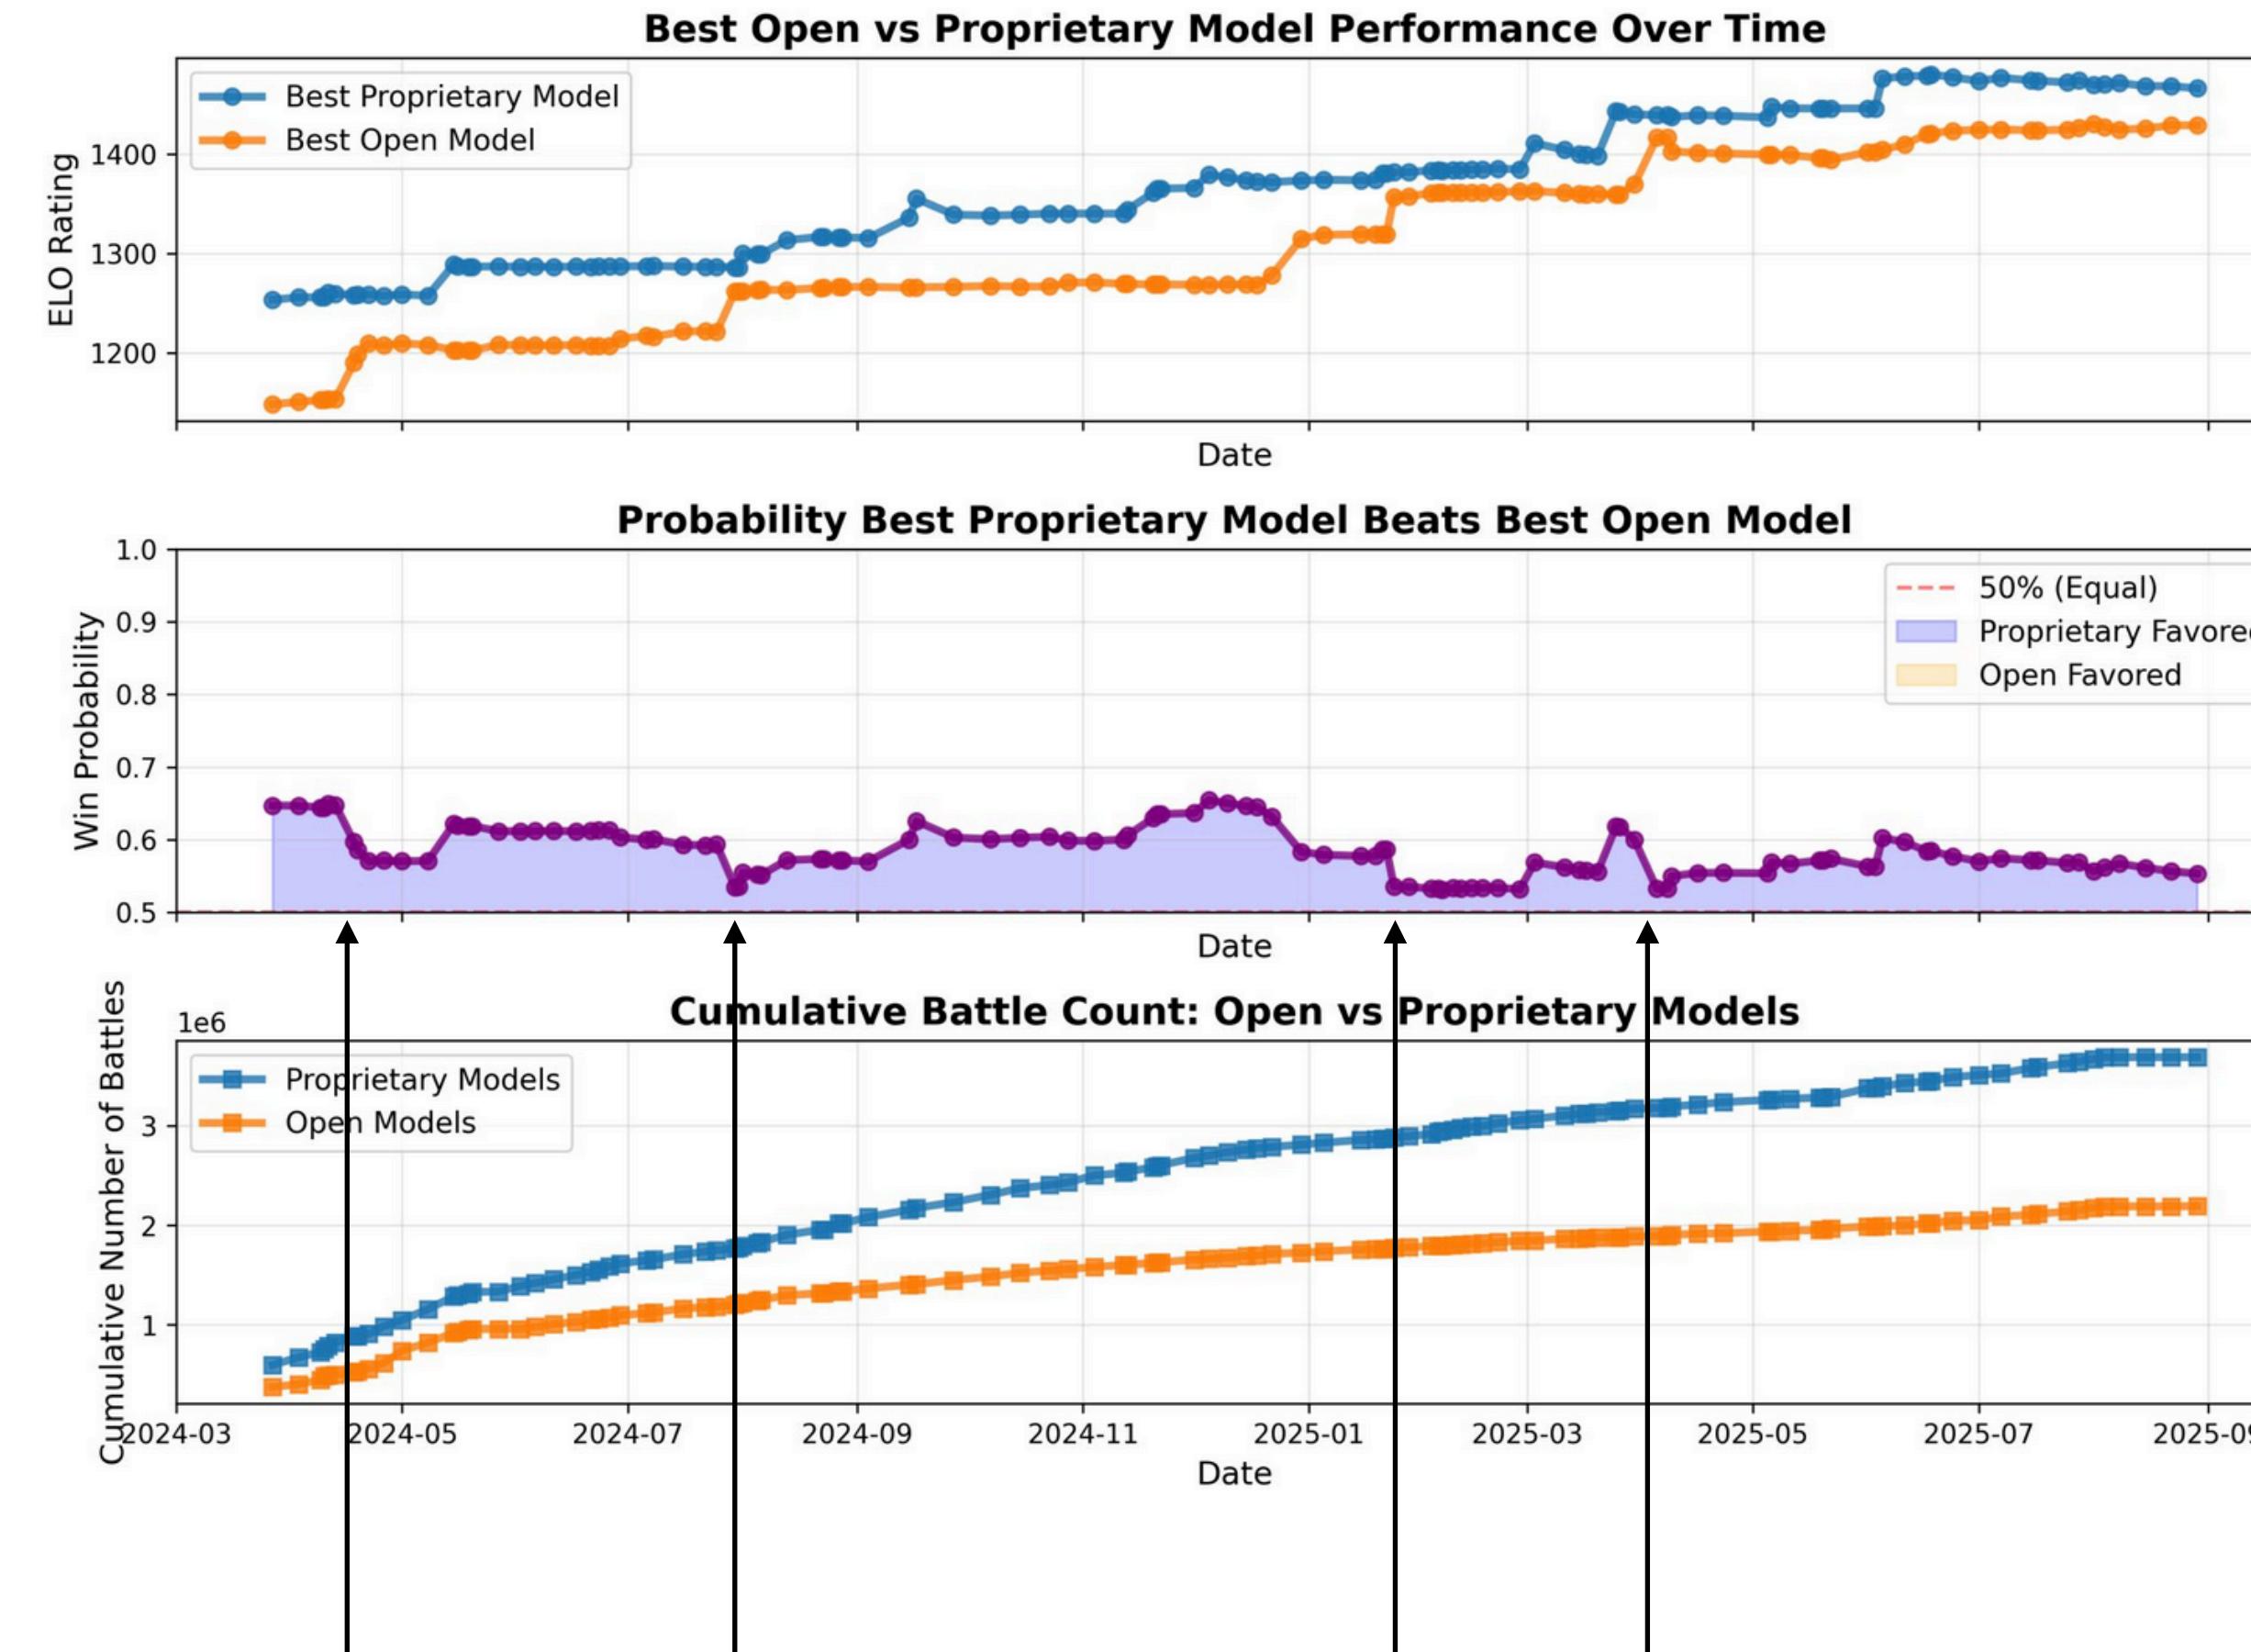
# Open-source vs proprietary

## Quel écart?



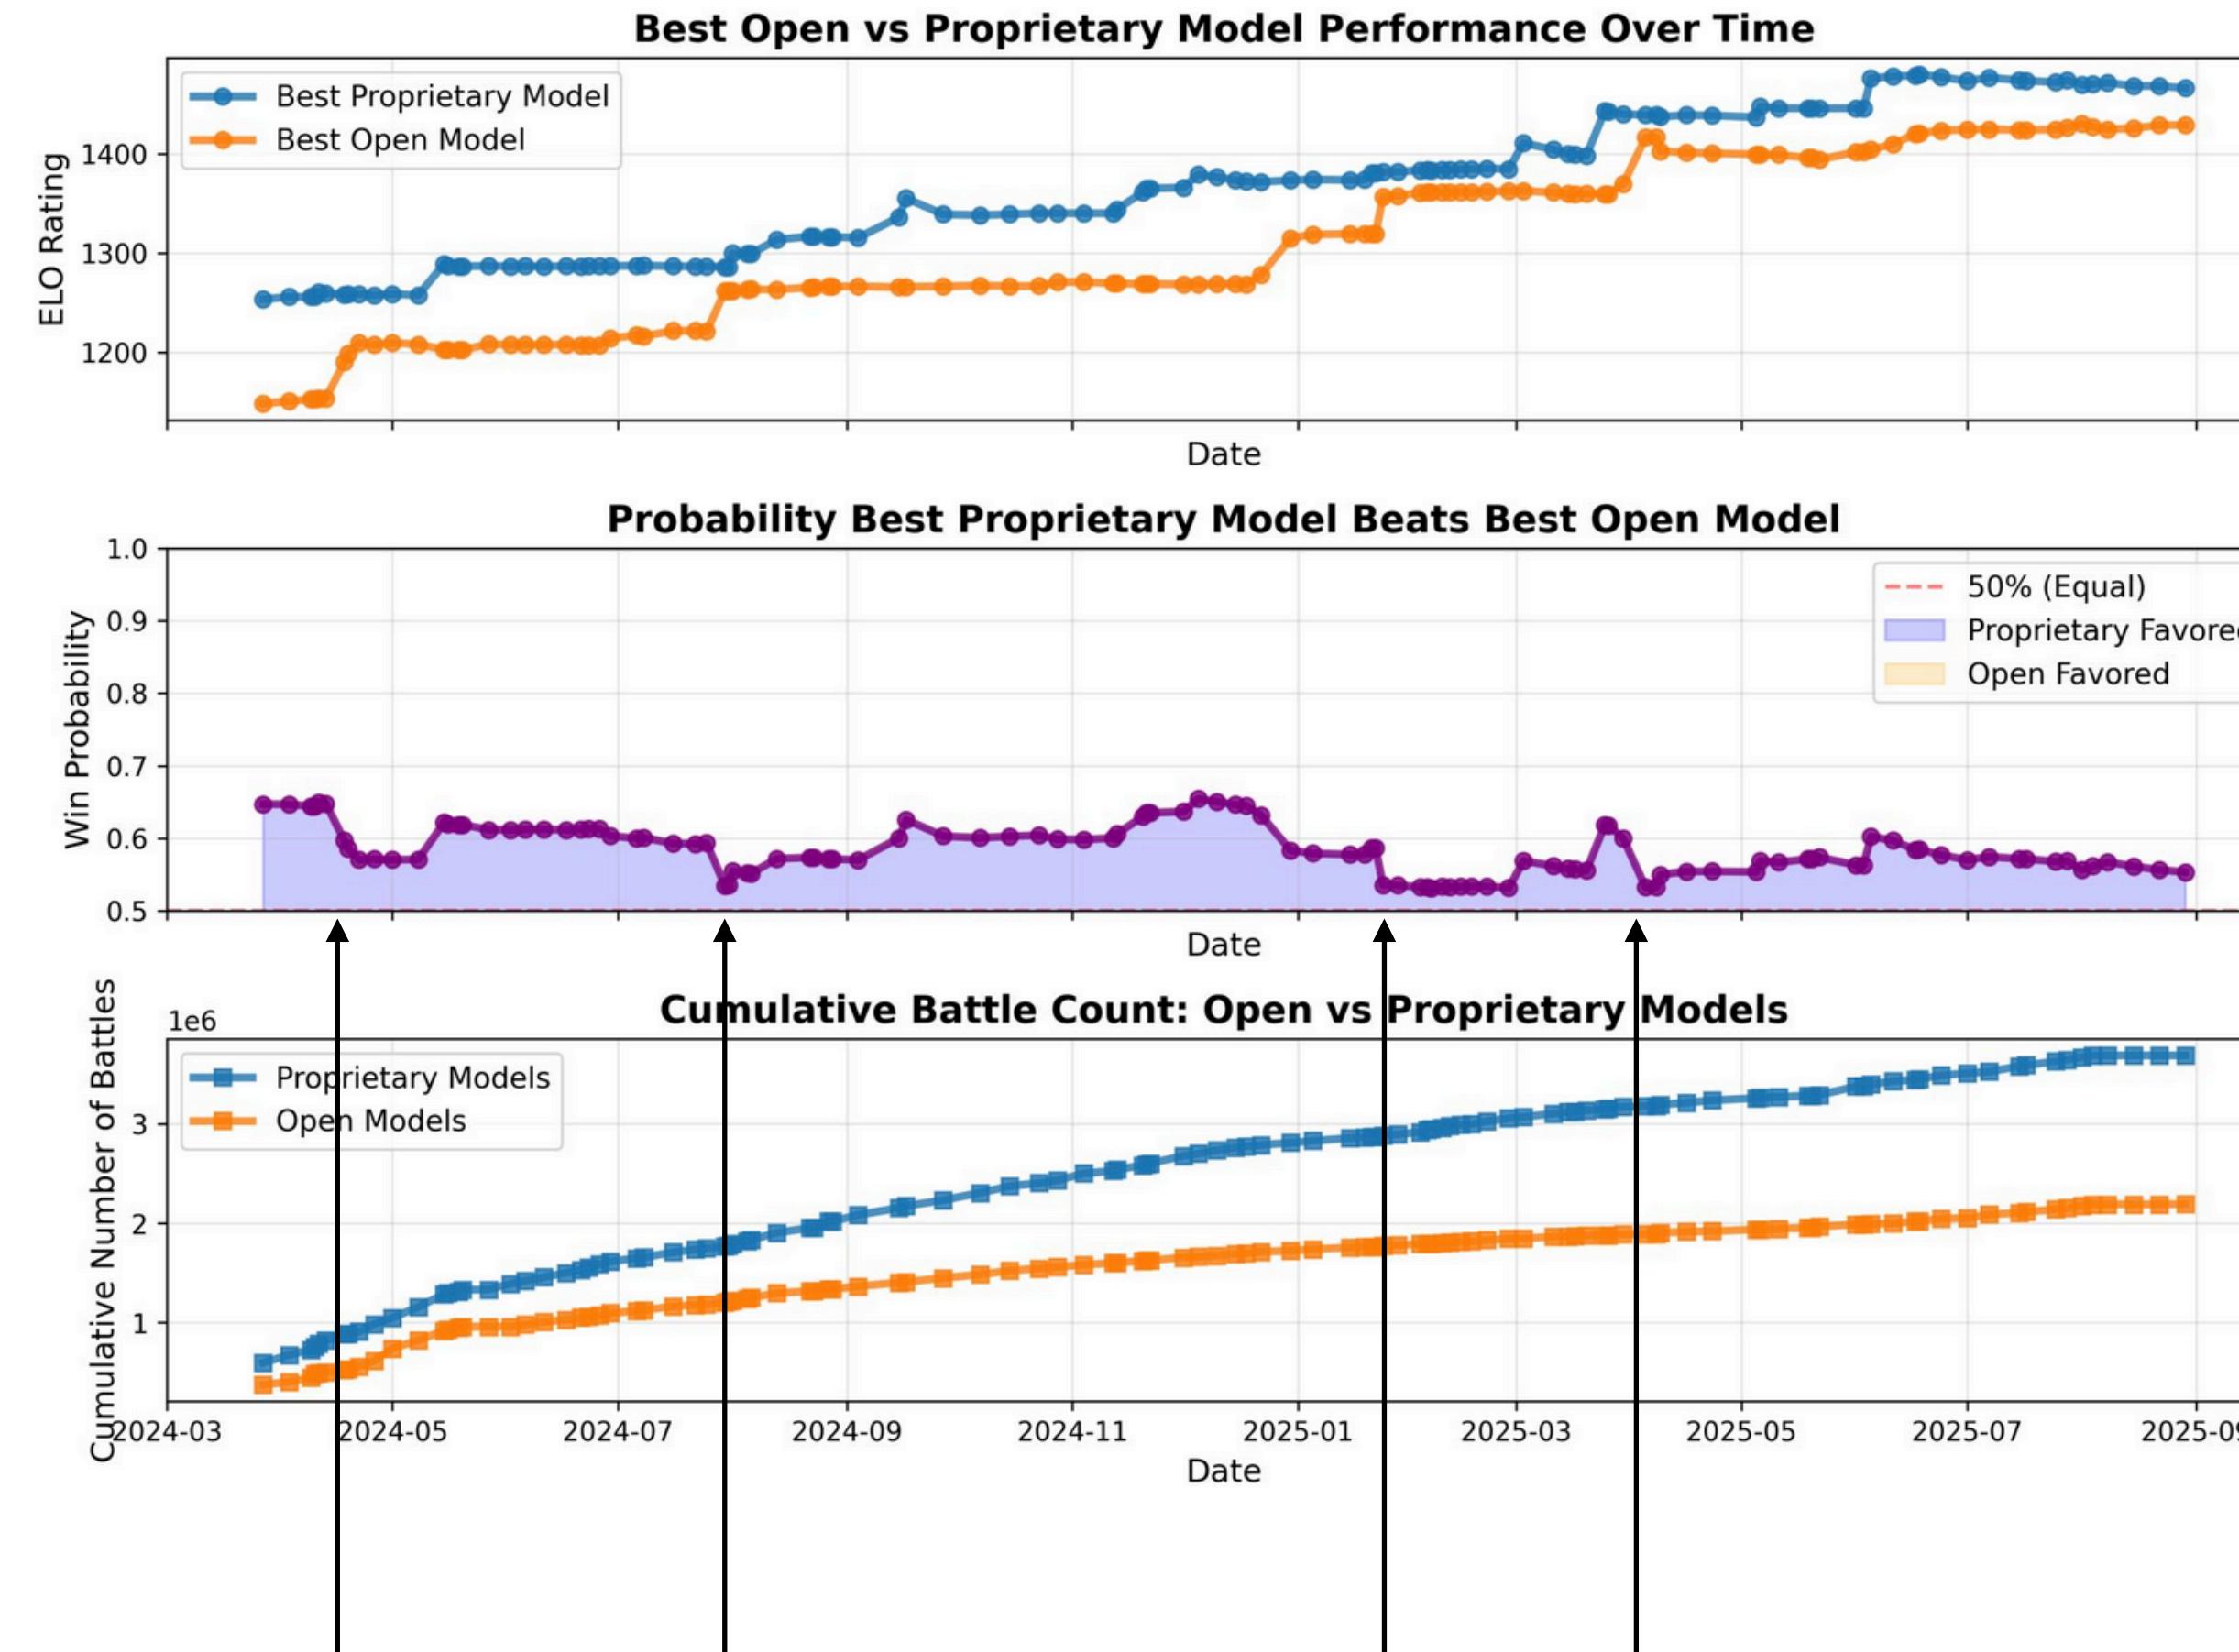
# Open-source vs proprietary

## Quel écart?



# Open-source vs proprietary

## Quel écart?



Savez-vous quels modèles ouverts ont réduit l'écart? 🤔

# **Open-source vs proprietary**

**Quel raisons pour l'écart?**

# **Open-source vs proprietary**

## **Quel raisons pour l'écart?**

- Ecart de moyens:

# **Open-source vs proprietary**

## **Quel raisons pour l'écart?**

- Ecart de moyens:
  - Humains:

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...
    - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:

- Humains:
  - Salaire & taille d'équipes
- GPUs:
  - Cluster gigantesques pour OpenAI, XAI, Google, ...
  - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:

- Humains:
  - Salaire & taille d'équipes
- GPUs:
  - Cluster gigantesques pour OpenAI, XAI, Google, ...
  - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
  - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:

- Humains:
  - Salaire & taille d'équipes
- GPUs:
  - Cluster gigantesques pour OpenAI, XAI, Google, ...
  - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
  - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)

- Ecart de règles:

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...
    - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
    - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)
- Ecart de règles:
  - Les modèles Open Source se doivent d'essayer de respecter toutes les réglementations

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...
    - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
    - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)
- Ecart de règles:
  - Les modèles Open Source se doivent d'essayer de respecter toutes les réglementations
  - Meta a utilisé un dataset de dump de livres piratés collectés sur Libgen (source: documents révélés lors du procès)

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...
    - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
    - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)
- Ecart de règles:
  - Les modèles Open Source se doivent d'essayer de respecter toutes les réglementations
  - Meta a utilisé un dataset de dump de livres piratés collectés sur Libgen (source: documents révélés lors du procès)
- Ecart structurel:

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...
    - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
    - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)
- Ecart de règles:
  - Les modèles Open Source se doivent d'essayer de respecter toutes les réglementations
  - Meta a utilisé un dataset de dump de livres piratés collectés sur Libgen (source: documents révélés lors du procès)
- Ecart structurel:
  - Modèles évalués principalement sur LMArena; plateforme devenue privée

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...
    - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
    - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)
- Ecart de règles:
  - Les modèles Open Source se doivent d'essayer de respecter toutes les réglementations
  - Meta a utilisé un dataset de dump de livres piratés collectés sur Libgen (source: documents révélés lors du procès)
- Ecart structurel:
  - Modèles évalués principalement sur LM Arena; plateforme devenue privée
  - Les modèles propriétaire ont accès à des quantités phénoménale de données pour post-entraîner leur modèle

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Open-source vs proprietary

## Quel raisons pour l'écart?

- Ecart de moyens:
  - Humains:
    - Salaire & taille d'équipes
  - GPUs:
    - Cluster gigantesques pour OpenAI, XAI, Google, ...
    - Mais ... clusters Européens significatifs dédiés à la recherche et aux startups 🤝
    - A relativiser avec XAI par exemple: 200,000 H100 reporté pour Colossus (!)
- Ecart de règles:
  - Les modèles Open Source se doivent d'essayer de respecter toutes les réglementations
  - Meta a utilisé un dataset de dump de livres piratés collectés sur Libgen (source: documents révélés lors du procès)
- Ecart structurel:
  - Modèles évalués principalement sur LM Arena; plateforme devenue privée
  - Les modèles propriétaire ont accès à des quantités phénoménale de données pour post-entraîner leur modèle
  - “If you don't pay you are the product”

Supercomputer	Country	Number of GPUs	GPU Type(s)
LUMI	Finland	~11,912	AMD MI250X
MareNostrum 5 (BSC)	Spain	4,480	NVIDIA H100 (Hopper)
JUPITER	Germany	~24,000	NVIDIA H100 (in GH200 Grace Hopper Superchips)
Leonardo	Italy	13,824	NVIDIA A100
Jean Zay	France	3,704	Mixed: 1,456 NVIDIA H100 + 416 NVIDIA A100 + 1,832 NVIDIA V100
Alps	Switzerland	10,752	NVIDIA H100 (in GH200 Grace Hopper Superchips)

European clusters 

# Un autre enjeu clé: la diversité linguistique

- Plutôt que LM Arena, considérez <https://comparia.beta.gouv.fr/>
  - Entièrement ouverte: code & données!
- Quel performance pour les modèles **ouverts**?
- Quel performance pour les modèles **Européens**?

Total modèles: 77	Total votes: 235 000	Mise à jour le 14/01/2026	Télécharger les données	Rechercher un modèle	Q	←	→
Rang	Modèle	Score de satisfaction BT	Confiance (±)	Total votes	Conso. moyenne (1000 tokens)	Taille (paramètres)	A
1	<a href="#">gemini-3-flash-preview</a>	1132	-9/+1	174	N/A	XL - (estimation)	P
2	<a href="#">mistral-large-2512</a>	1120	-3/+2	1442	50 Wh	XL - 675 Mds	M
3	<a href="#">mistral-medium-2508</a>	1115	-1/+2	5387	N/A	L - (estimation)	P
4	<a href="#">gemini-2.5-flash</a>	1104	-4/+1	3972	N/A	XL - (estimation)	P
5	<a href="#">gemini-3-pro-preview</a>	1104	-4/+3	1974	N/A	XL - (estimation)	P
6	<a href="#">qwen3-max-2025-09-23</a>	1103	-3/+3	2562	N/A	XL - (estimation)	P
7	<a href="#">gemini-2.0-flash</a>	1100	-2/+3	8684	N/A	XL - (estimation)	P
8	<a href="#">deepseek-v3-0324</a>	1091	-4/+2	4385	47 Wh	XL - 685 Mds	M
9	<a href="#">magistral-medium</a>	1088	-6/+3	2207	N/A	L - (estimation)	P
10	<a href="#">gpt-5.2</a>	1085	-10/+4	1080	N/A	L - (estimation)	P
11	<a href="#">gemma-3-27b</a>	1083	-5/+2	7688	6 Wh	S - 27 Mds	D
12	<a href="#">grok-4.1-fast</a>	1079	-10/+4	1461	N/A	XL - (estimation)	P
13	<a href="#">deepseek-chat-v3.1</a>	1079	-8/+4	1588	47 Wh	XL - 685 Mds	M
14	<a href="#">deepseek-v3-chat</a>	1078	-6/+4	5388	47 Wh	XL - 671 Mds	M
15	<a href="#">gpt-5.1</a>	1074	-8/+5	2202	N/A	L - (estimation)	P
16	<a href="#">claude-4-5-sonnet</a>	1073	-5/+4	5031	N/A	XL - (estimation)	P

# Enjeux de souveraineté

# Enjeux de souveraineté

- Les modèles Européens sont très loin en performance des modèles Chinois et Américain

# Enjeux de souveraineté

- Les modèles Européens sont très loin en performance des modèles Chinois et Américain
- ... à part Mistral

# Enjeux de souveraineté

- Les modèles Européens sont très loin en performance des modèles Chinois et Américain
- ... à part Mistral
- L'accès à cette technologie transformative dépend:

# Enjeux de souveraineté

- Les modèles Européens sont très loin en performance des modèles Chinois et Américain
- ... à part Mistral
- L'accès à cette technologie transformative dépend:
  - D'un seul acteur Européen

# Enjeux de souveraineté

- Les modèles Européens sont très loin en performance des modèles Chinois et Américain
- ... à part Mistral
- L'accès à cette technologie transformative dépend:
  - D'un seul acteur Européen
  - De deux pays potentiellement rivaux (l'accès à cette technologie peut être bloqué, cf l'Etats-Unis empêche l'export de GPU avancés vers la Chine)

# Enjeux de souveraineté

- Les modèles Européens sont très loin en performance des modèles Chinois et Américain
- ... à part Mistral
- L'accès à cette technologie transformative dépend:
  - D'un seul acteur Européen
  - De deux pays potentiellement rivaux (l'accès à cette technologie peut être bloqué, cf l'Etats-Unis empêche l'export de GPU avancés vers la Chine)
  - Projets Européen ayant pour but de développer des modèles ouverts et améliorer l'ecosystème Européen

# Enjeux de souveraineté

- Les modèles Européens sont très loin en performance des modèles Chinois et Américain
- ... à part Mistral
- L'accès à cette technologie transformative dépend:
  - D'un seul acteur Européen
  - De deux pays potentiellement rivaux (l'accès à cette technologie peut être bloqué, cf l'Etats-Unis empêche l'export de GPU avancés vers la Chine)
- Projets Européen ayant pour but de développer des modèles ouverts et améliorer l'ecosystème Européen
  - EuroLLM, Apertus, OpenEuroLLM

# OpenEuroLLM

# OpenEuroLLM

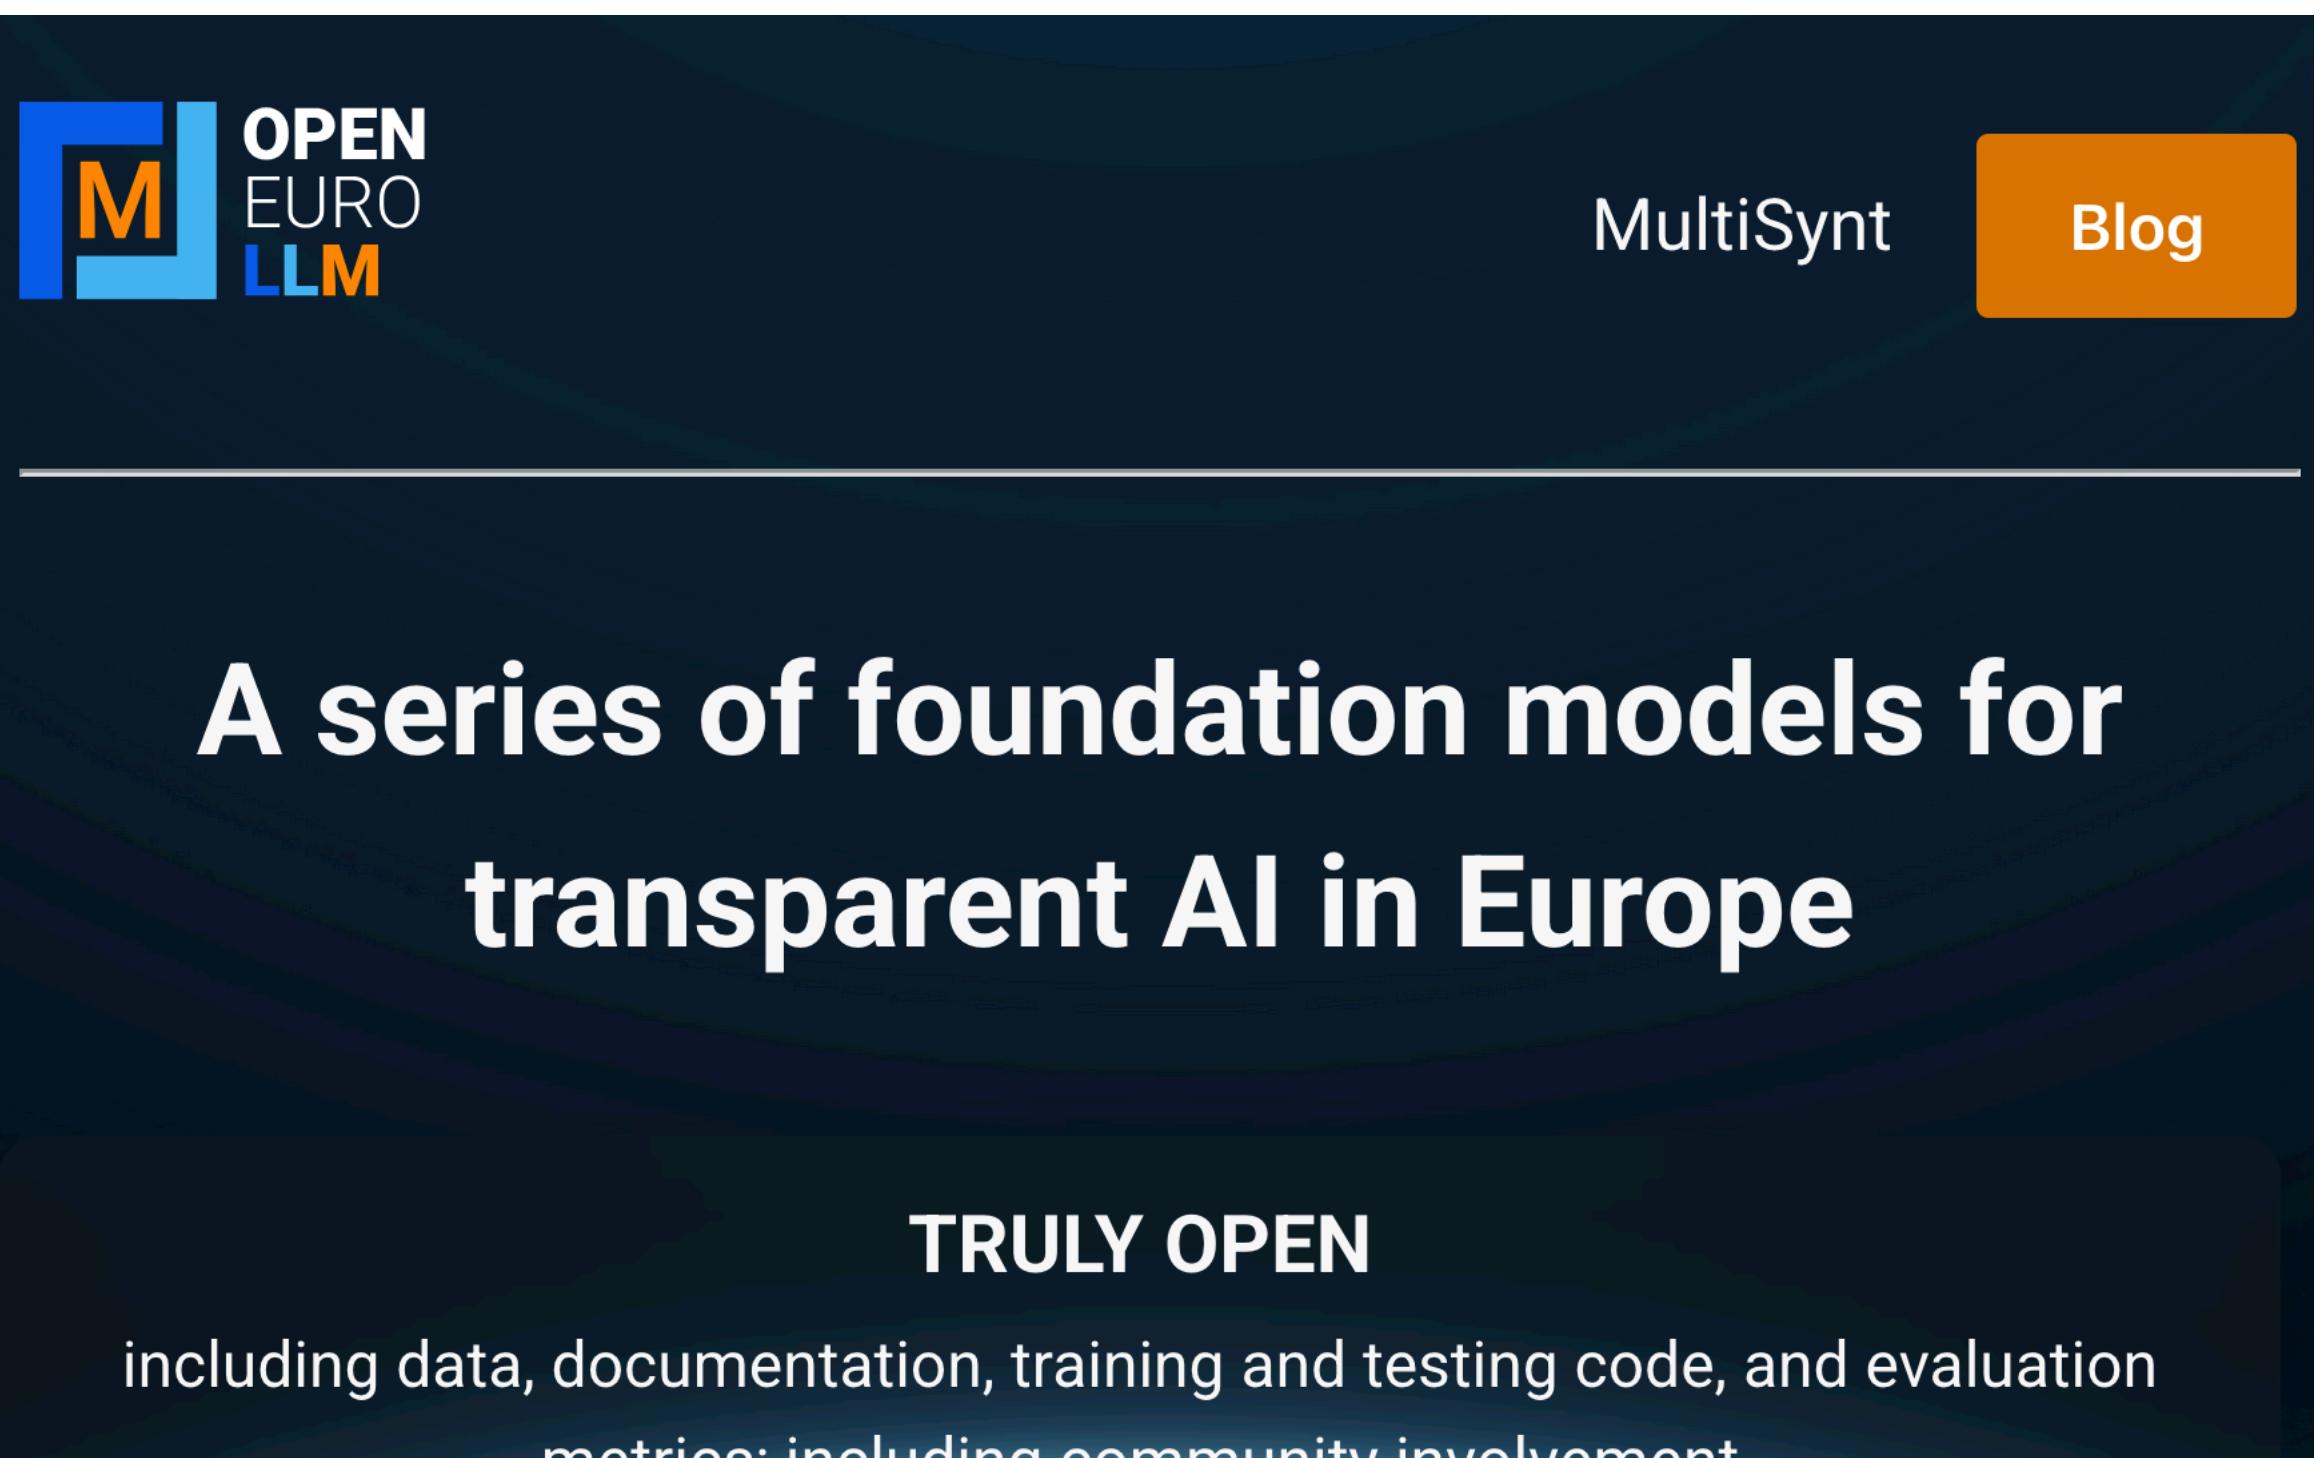
- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025

# OpenEuroLLM

- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>

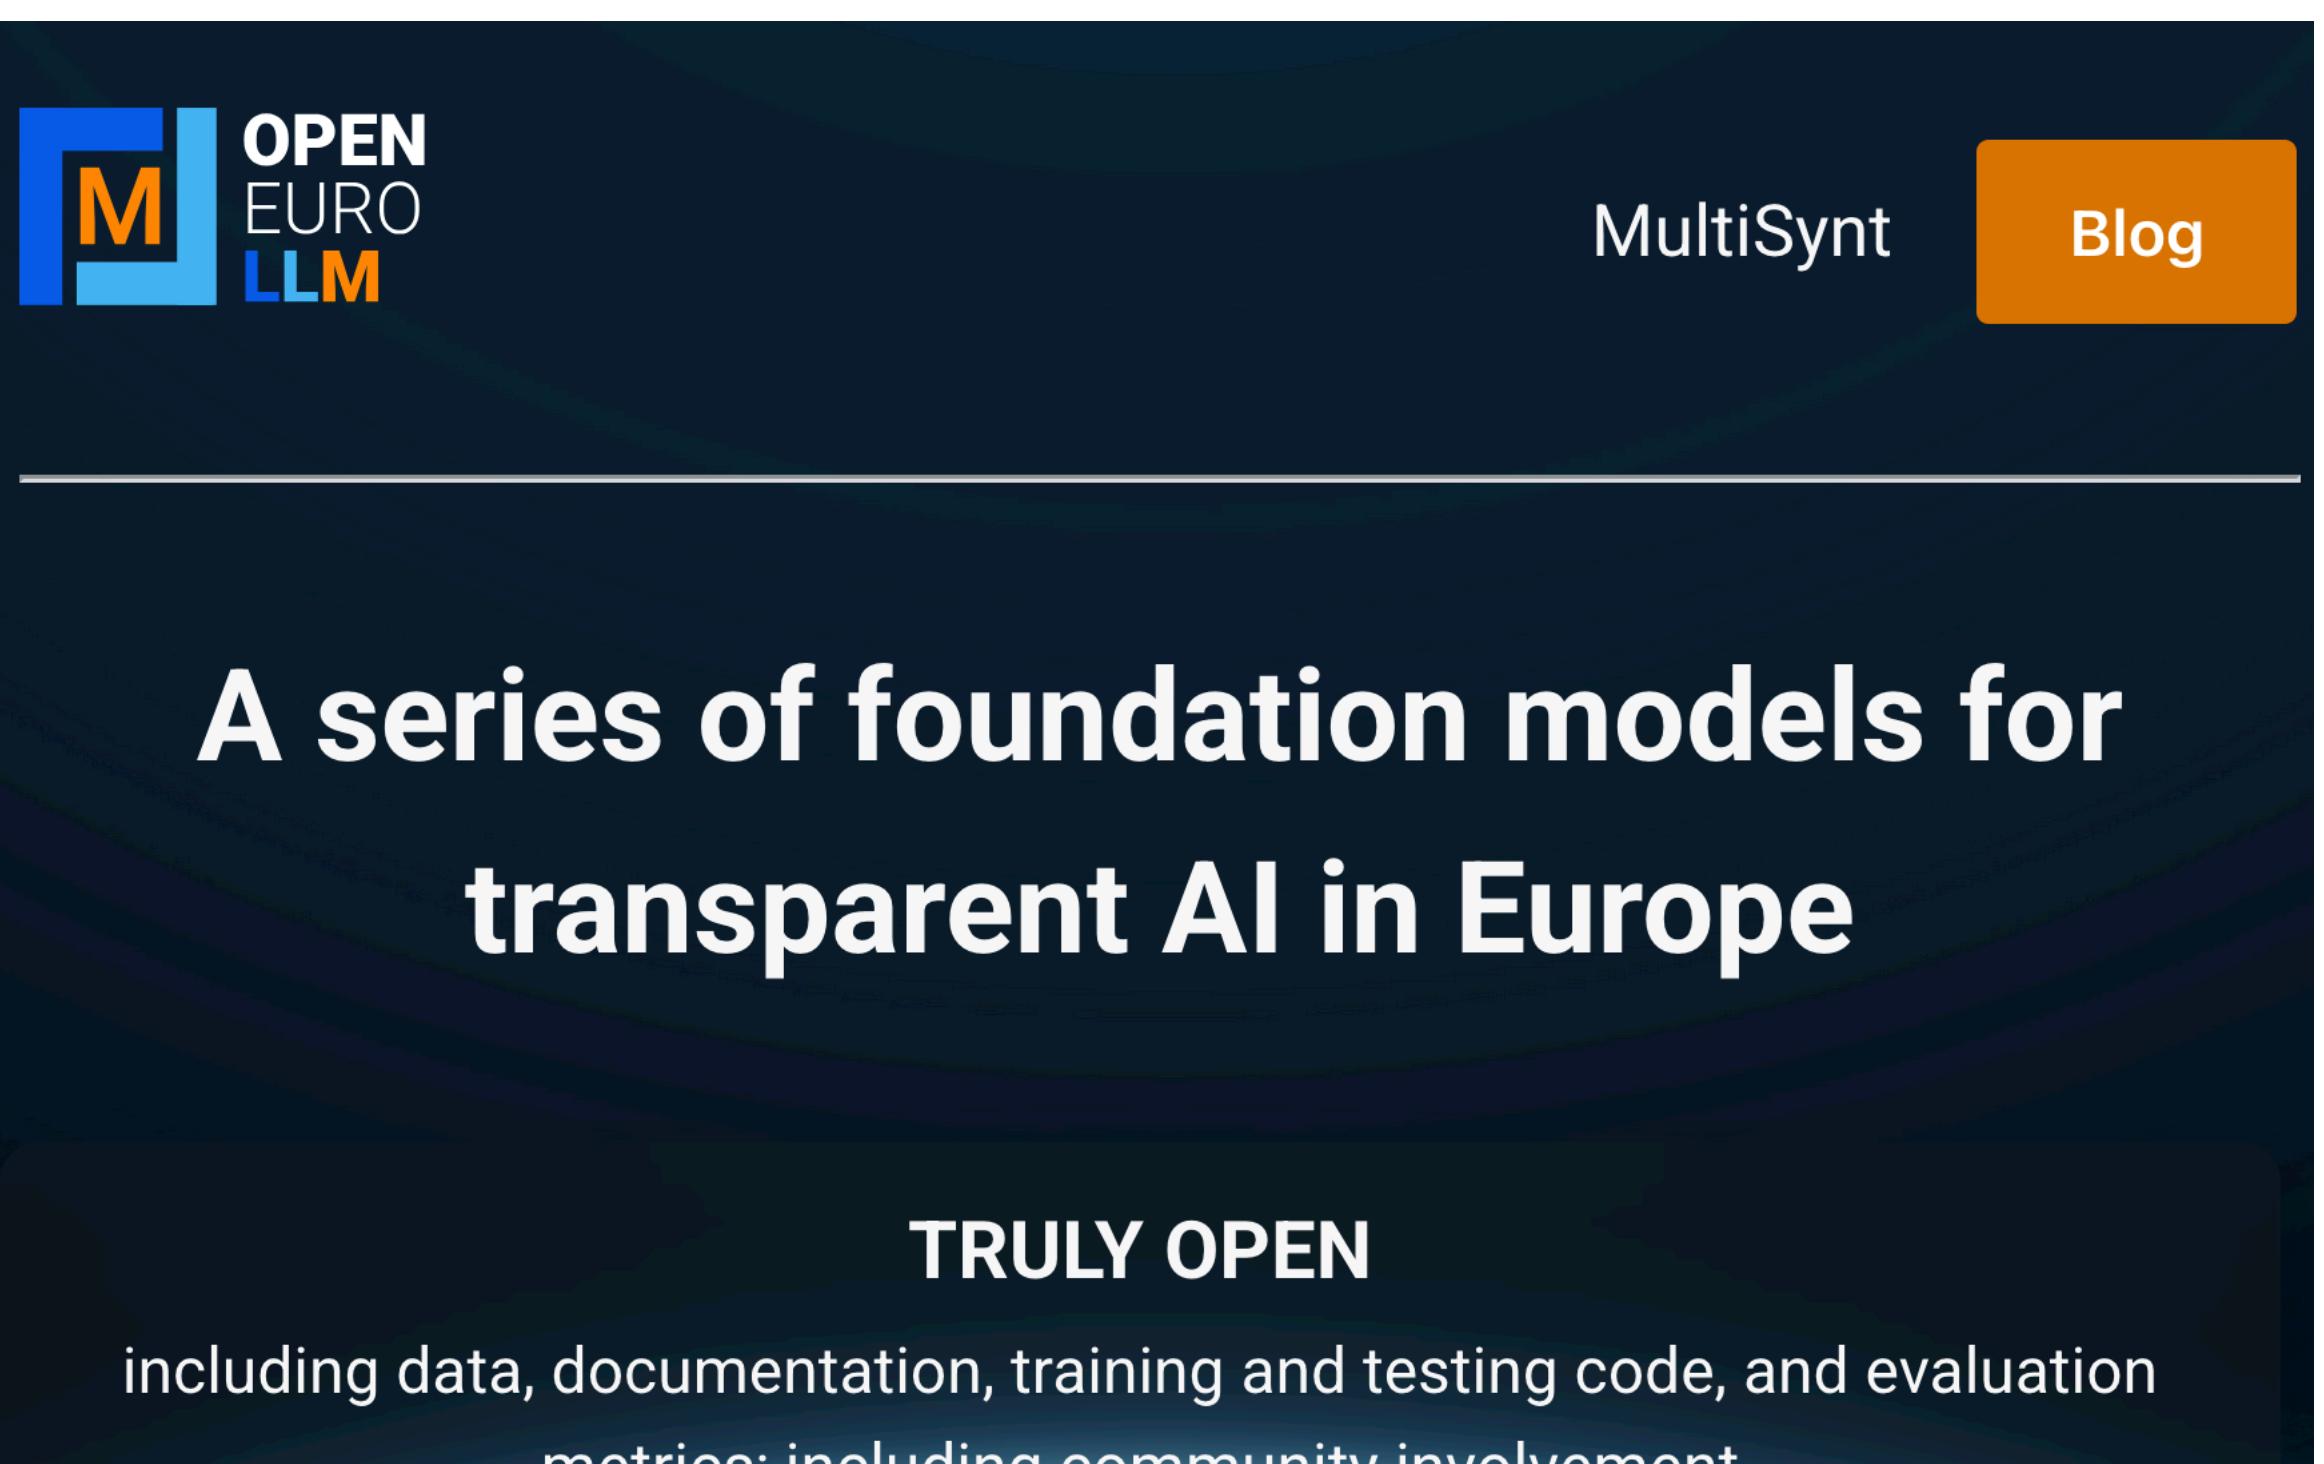
# OpenEuroLLM

- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>



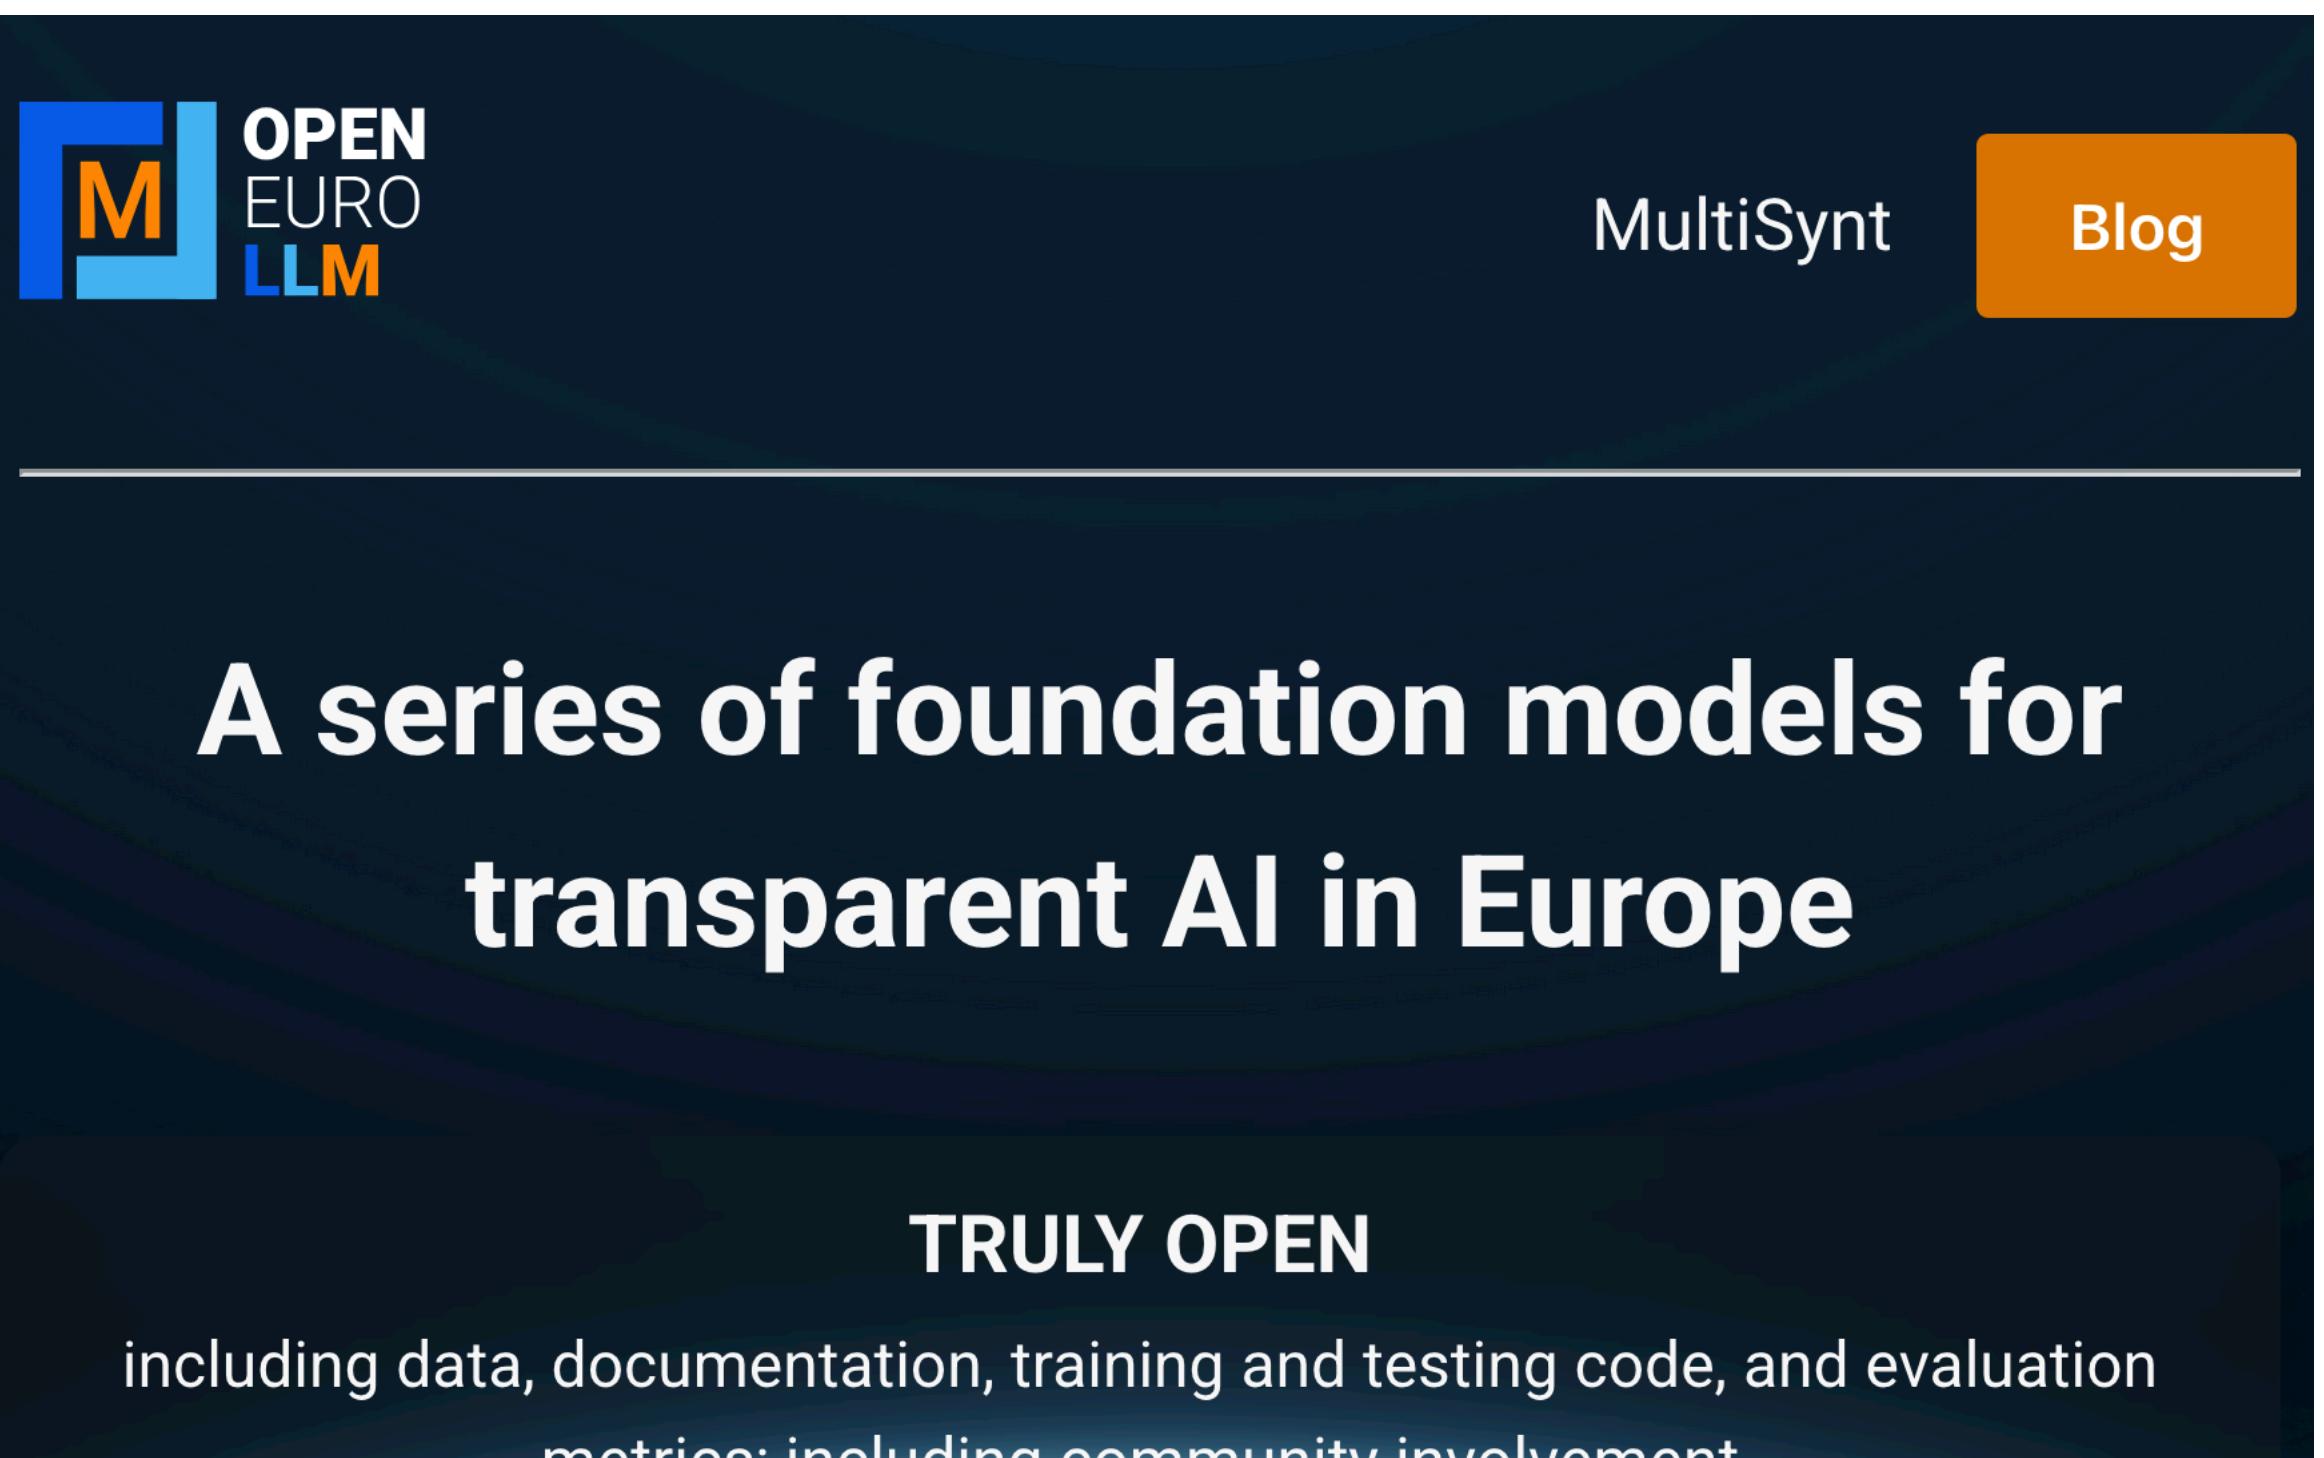
# OpenEuroLLM

- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes



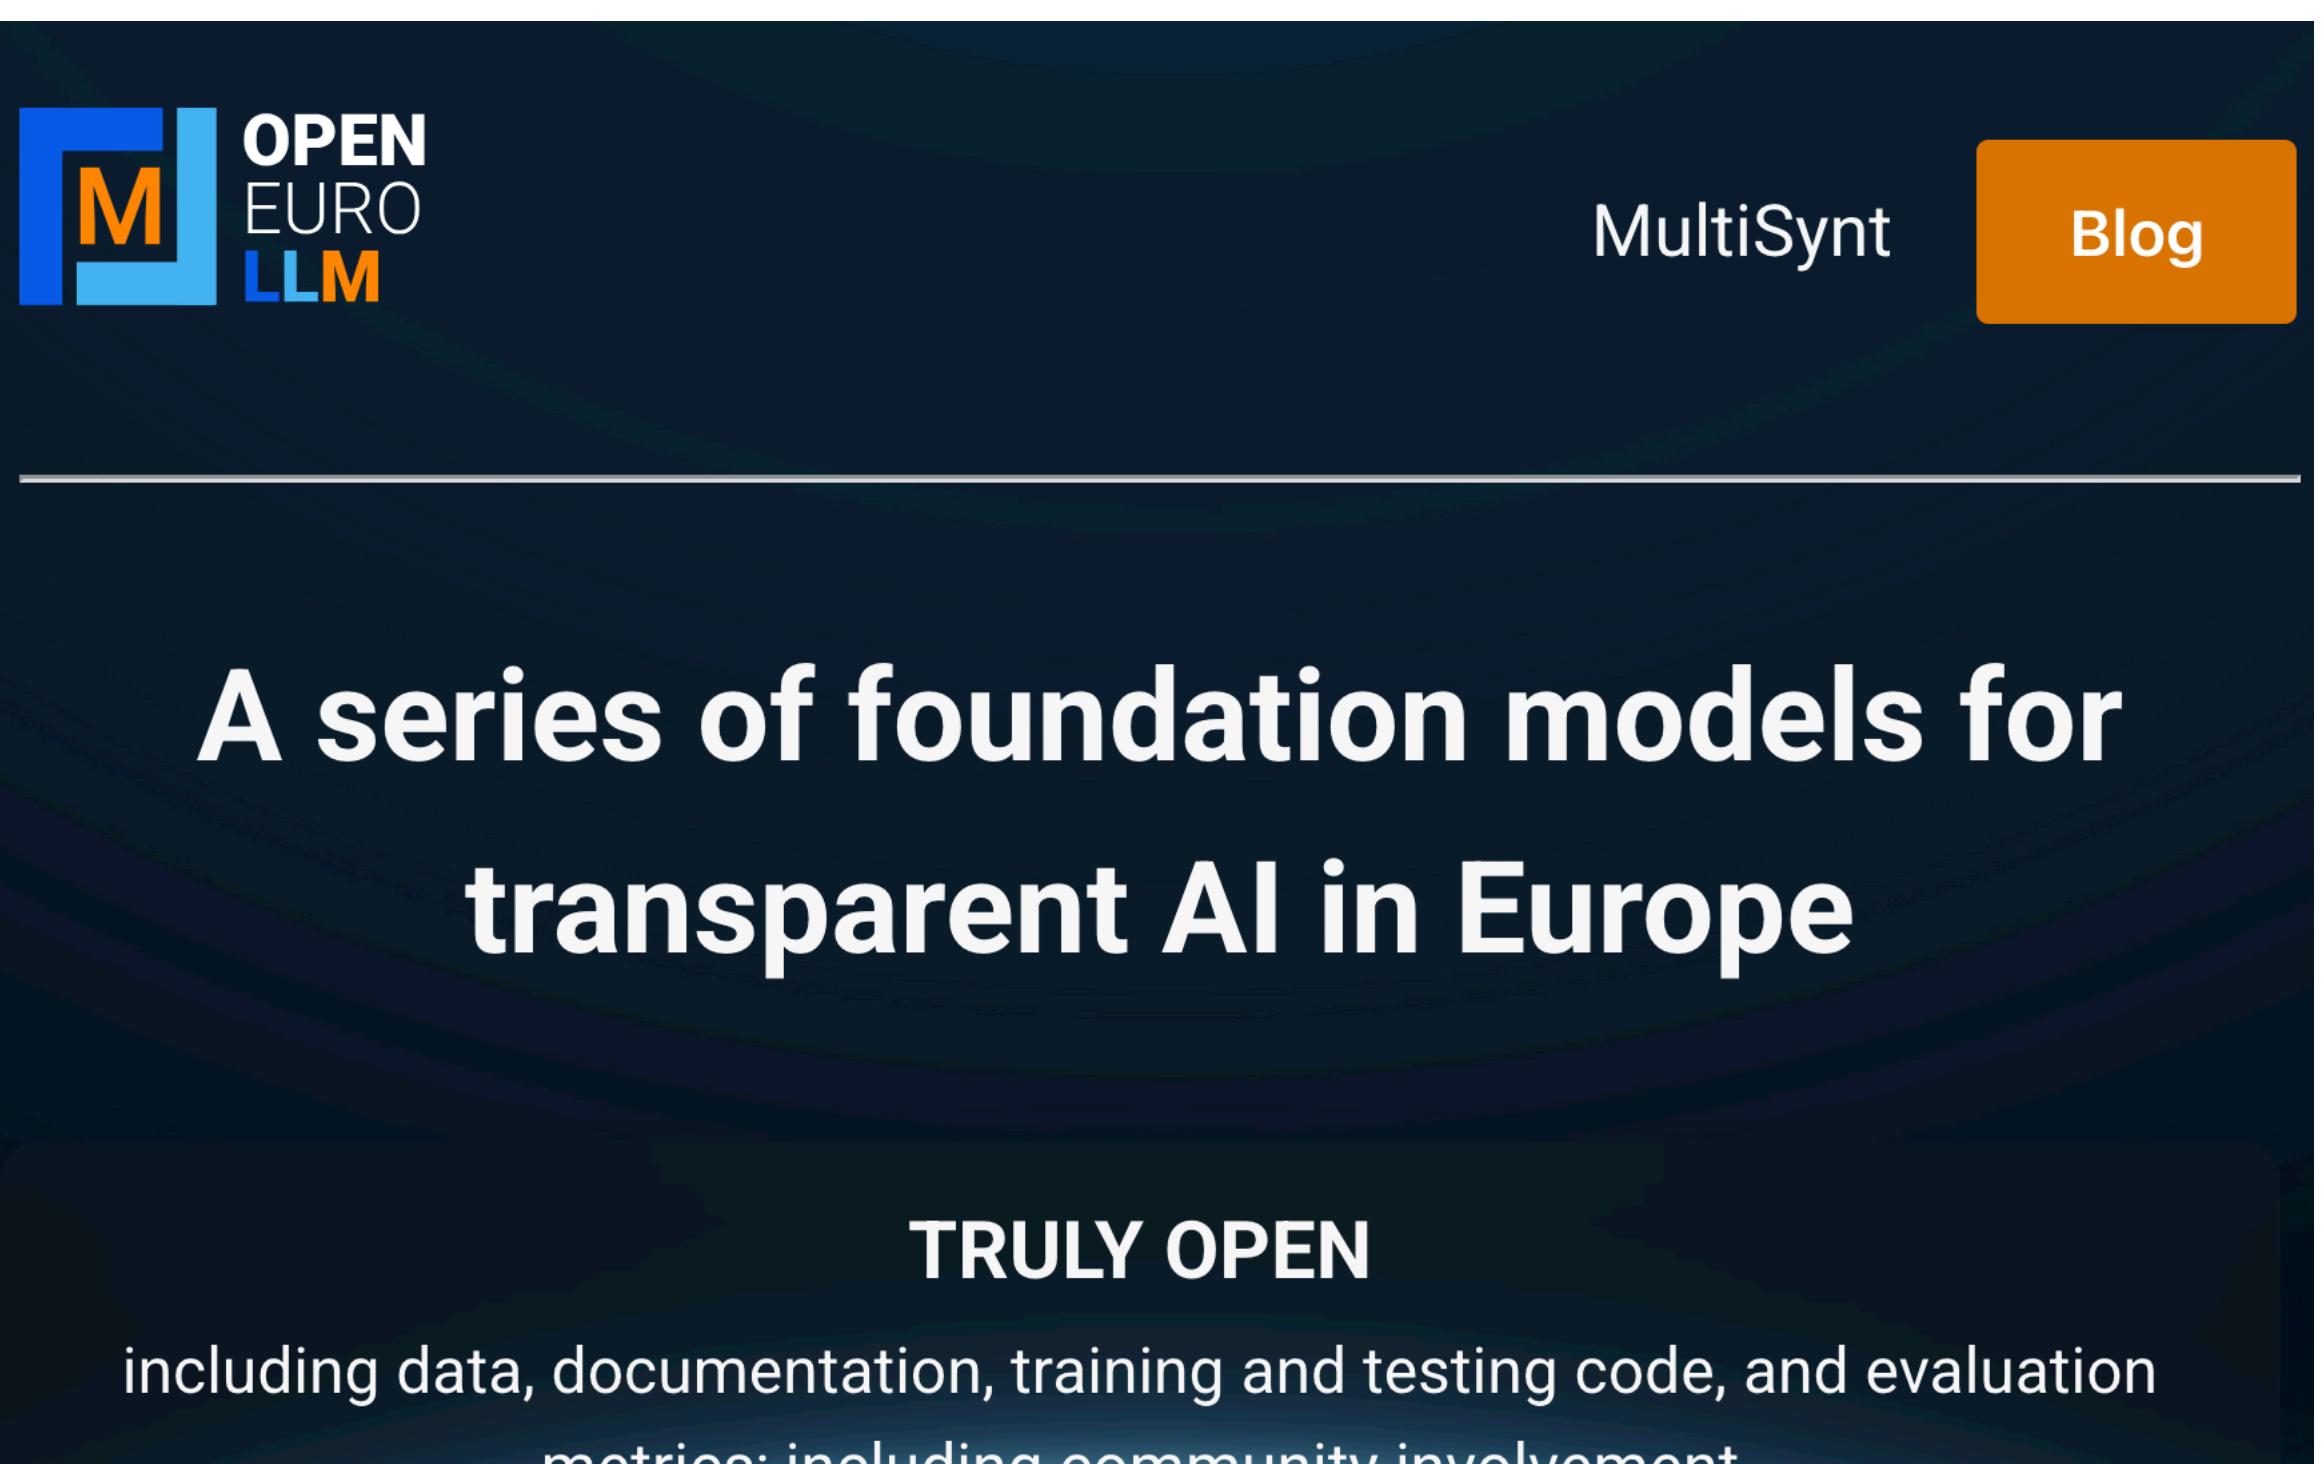
# OpenEuroLLM

- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes
- Entièrement ouvert : poids, code et données



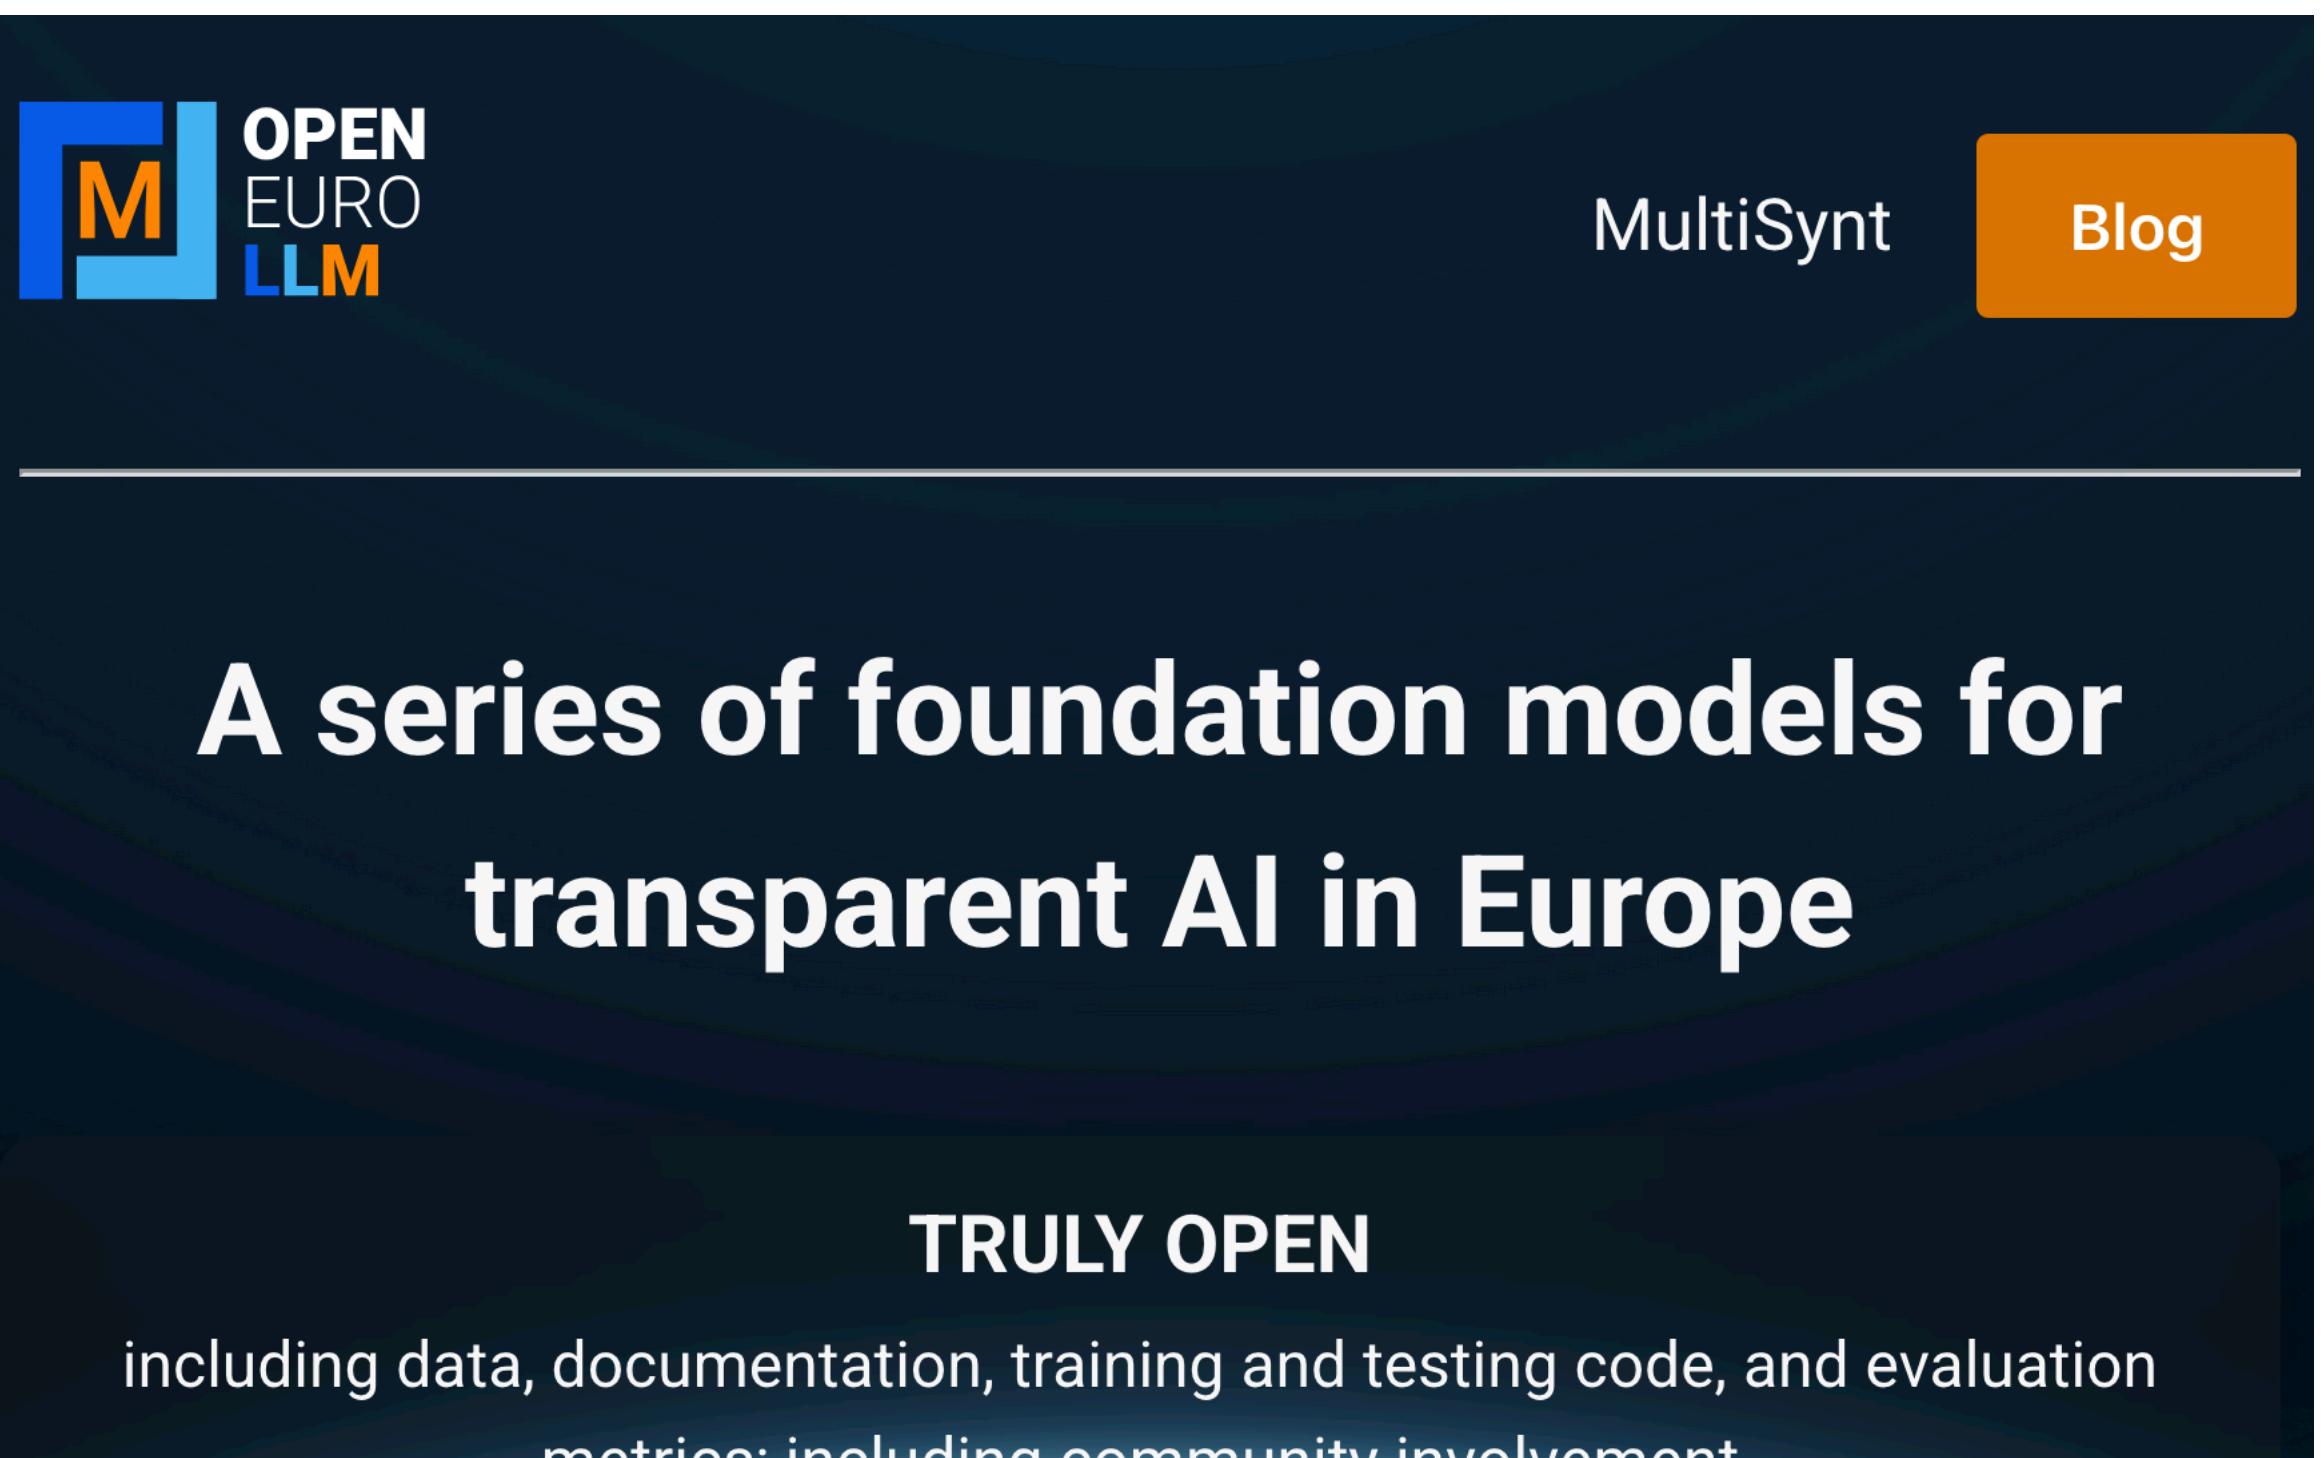
# OpenEuroLLM

- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes
- Entièrement ouvert : poids, code et données
- Financement de 37,4 millions d'euros, également plusieurs millions d'heures GPU sur EuroHPC



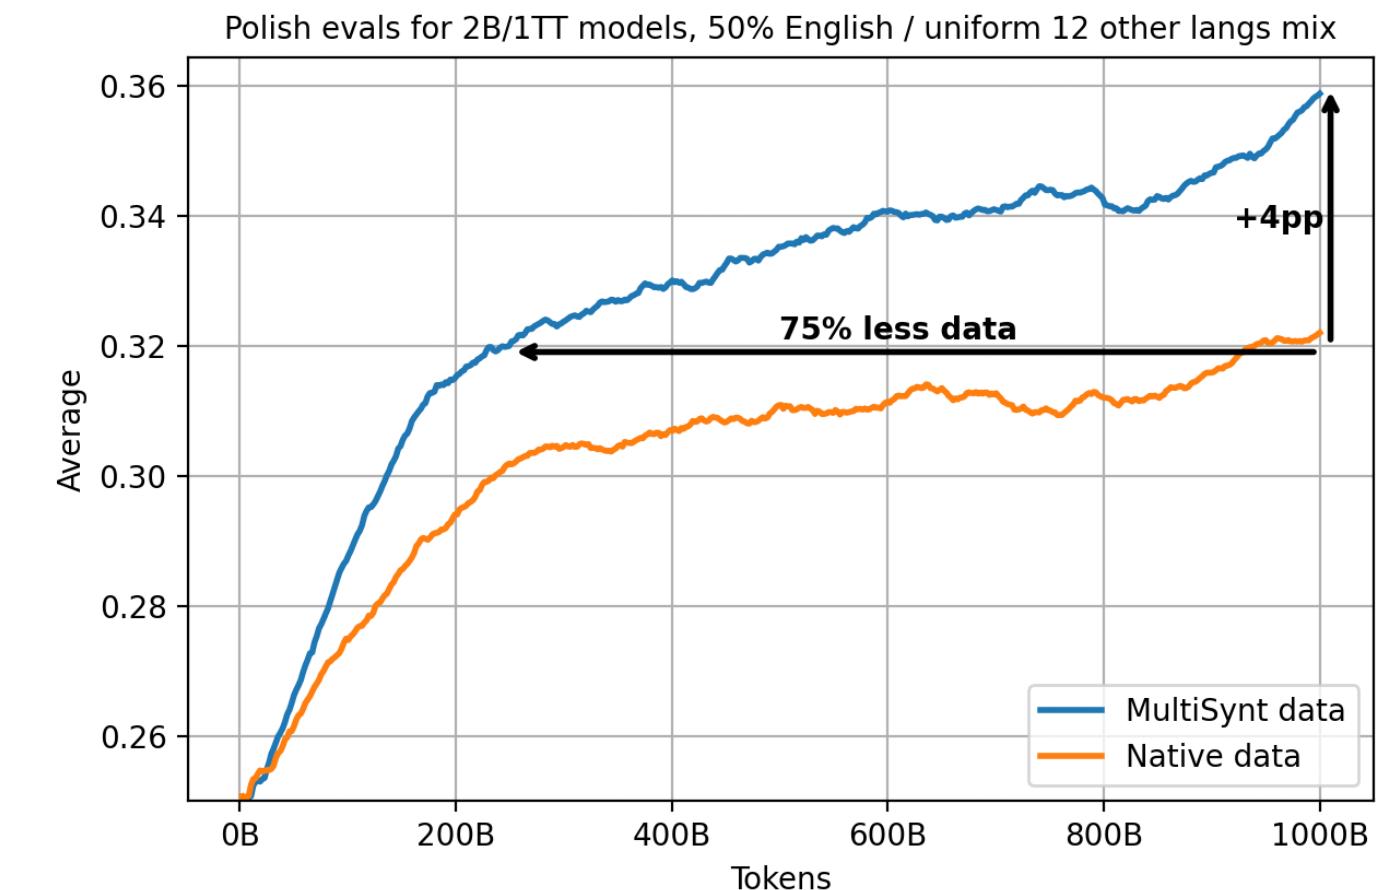
# OpenEuroLLM

- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes
- Entièrement ouvert : poids, code et données
- Financement de 37,4 millions d'euros, également plusieurs millions d'heures GPU sur EuroHPC
- Jusqu'ici modèle entraînés avec 2B paramètres, entraînement en cours d'un modèle 8B pour Mai prochain



# OpenEuroLLM

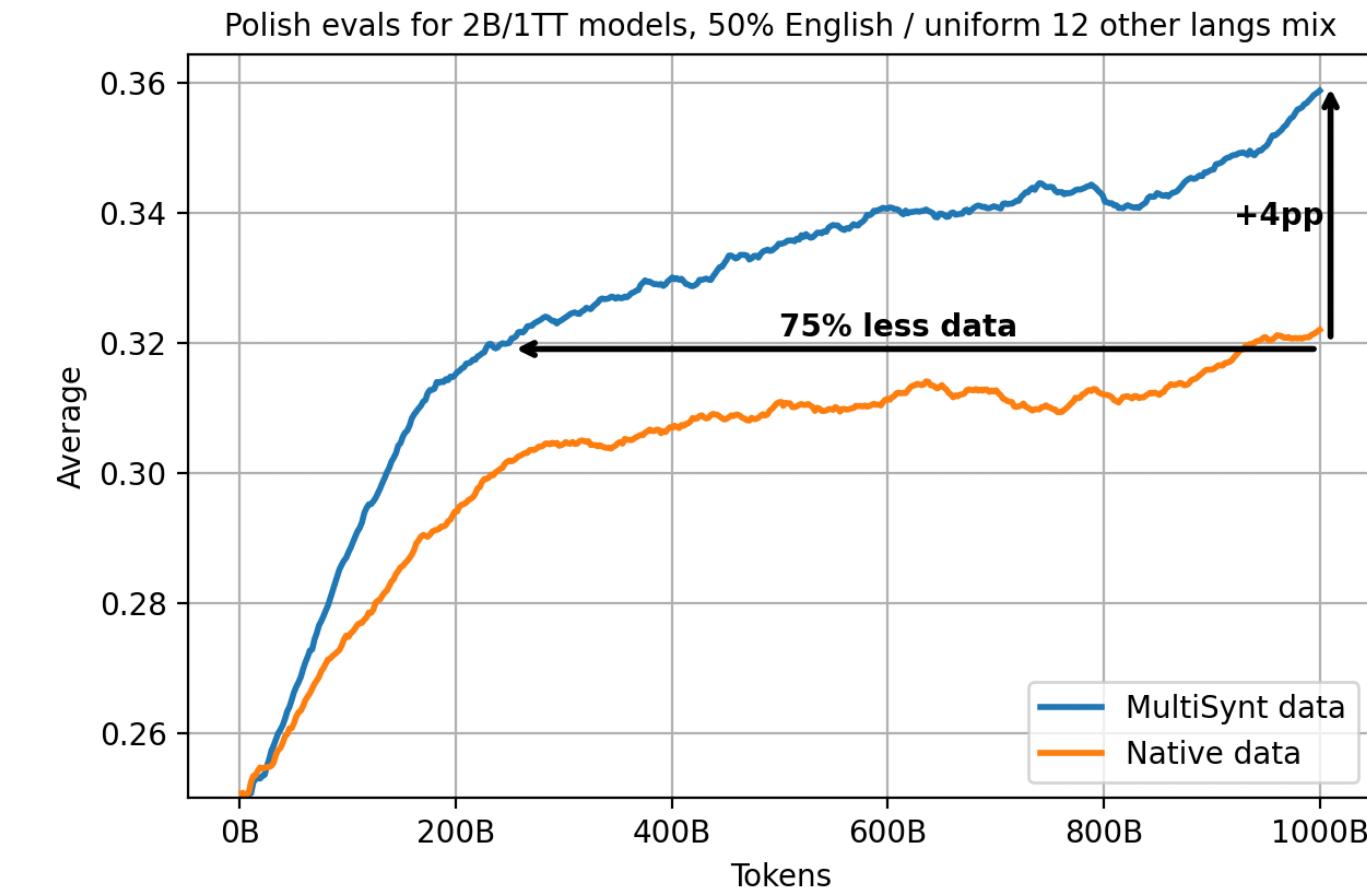
- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes
- Entièrement ouvert : poids, code et données
- Financement de 37,4 millions d'euros, également plusieurs millions d'heures GPU sur EuroHPC
- Jusqu'ici modèle entraînés avec 2B paramètres, entraînement en cours d'un modèle 8B pour Mai prochain



Utilisation de données synthétique pour les langues avec moins de ressources

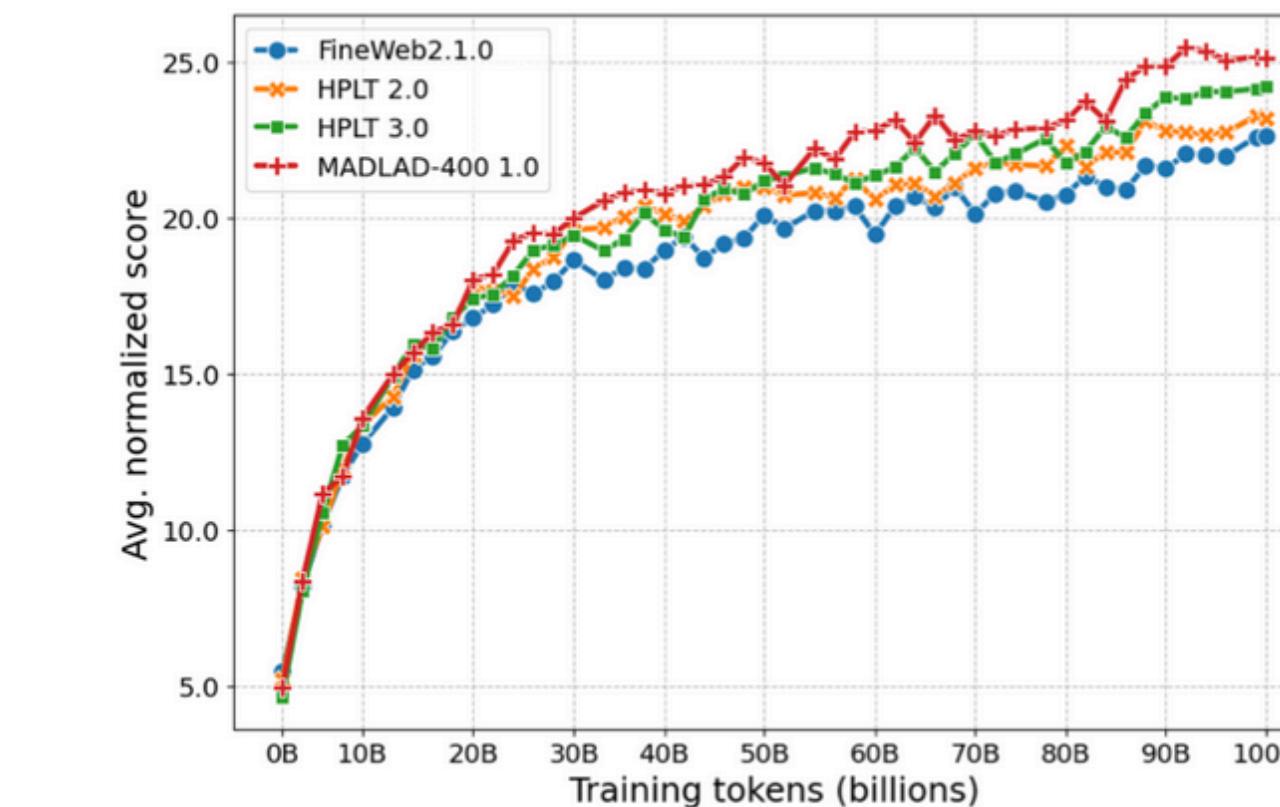
# OpenEuroLLM

- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes
- Entièrement ouvert : poids, code et données
- Financement de 37,4 millions d'euros, également plusieurs millions d'heures GPU sur EuroHPC
- Jusqu'ici modèle entraînés avec 2B paramètres, entraînement en cours d'un modèle 8B pour Mai prochain



Utilisation de données synthétique pour les langues avec moins de ressources

Average over belebele\_pol\_Latn\_cf|0, global\_mmlu\_all\_pol\_cf|0, lumi\_arc\_pol\_cf:challenge|0.

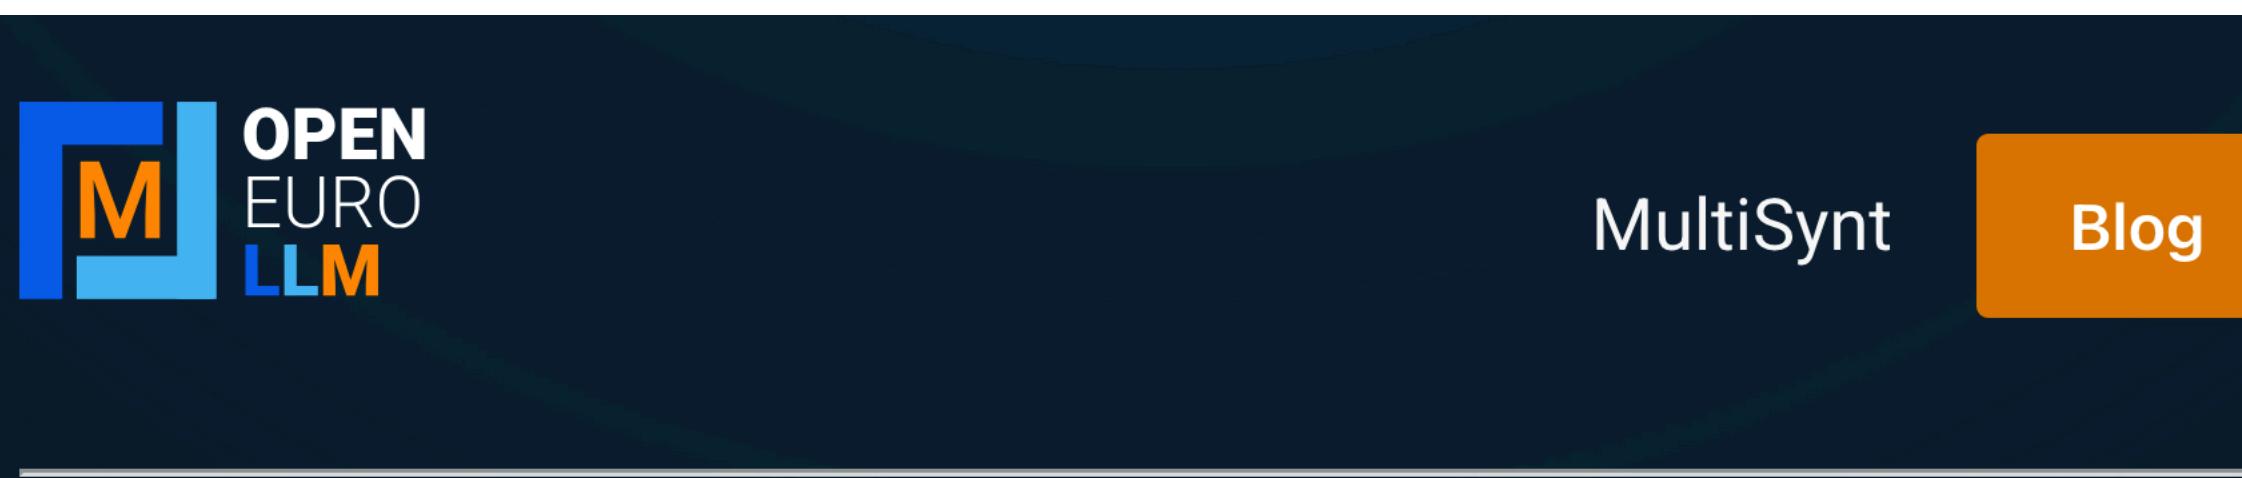


Acquisition (crawling) de jeux de données à grande échelle pour les langues Européennes

Figure 2: Comparison of models pretrained on FineWeb, HPLT 2.0, 3.0, and MADLAD-400.

# OpenEuroLLM

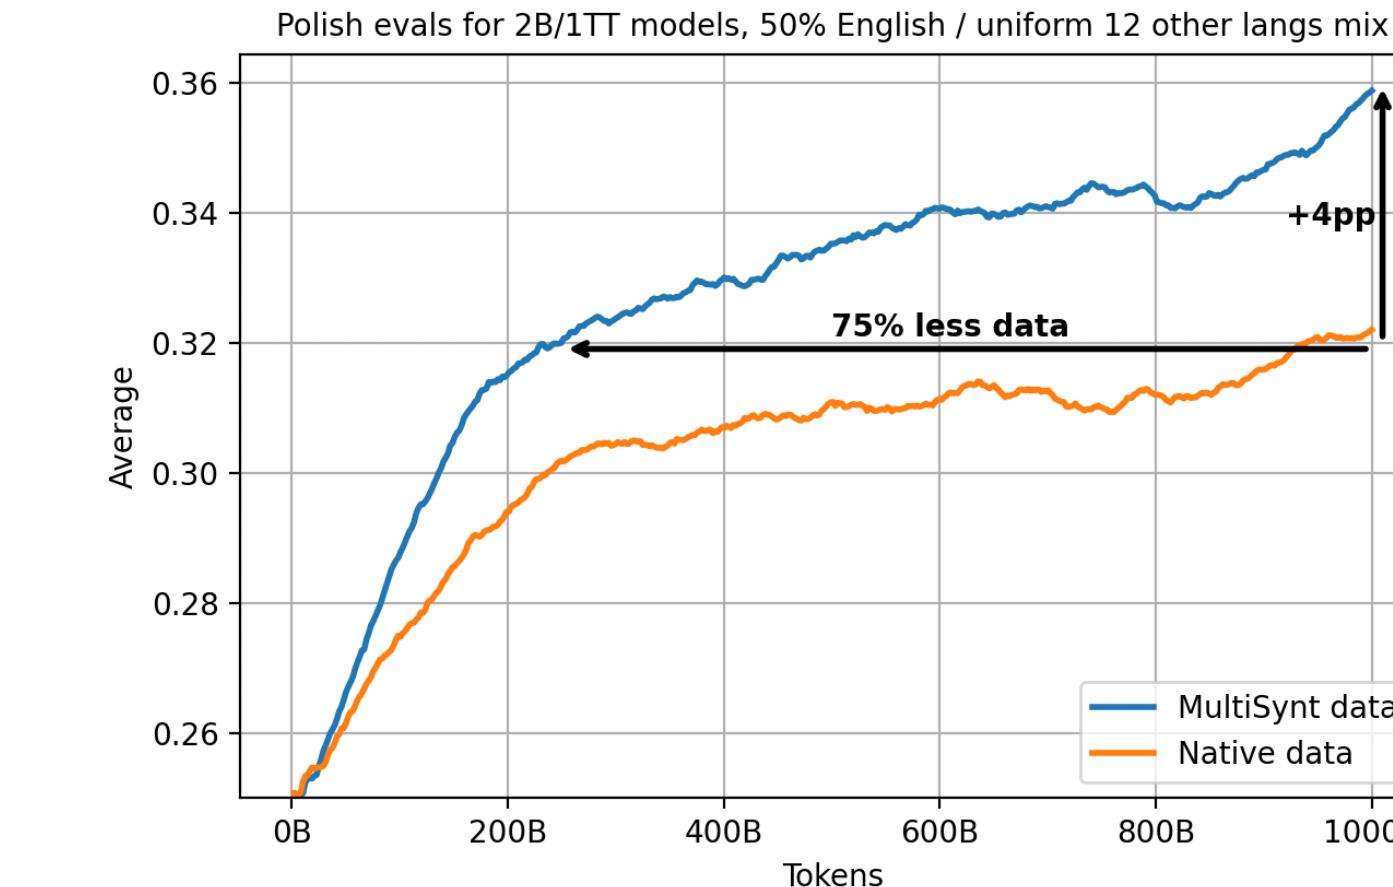
- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes
- Entièrement ouvert : poids, code et données
- Financement de 37,4 millions d'euros, également plusieurs millions d'heures GPU sur EuroHPC
- Jusqu'ici modèle entraînés avec 2B paramètres, entraînement en cours d'un modèle 8B pour Mai prochain



A series of foundation models for transparent AI in Europe

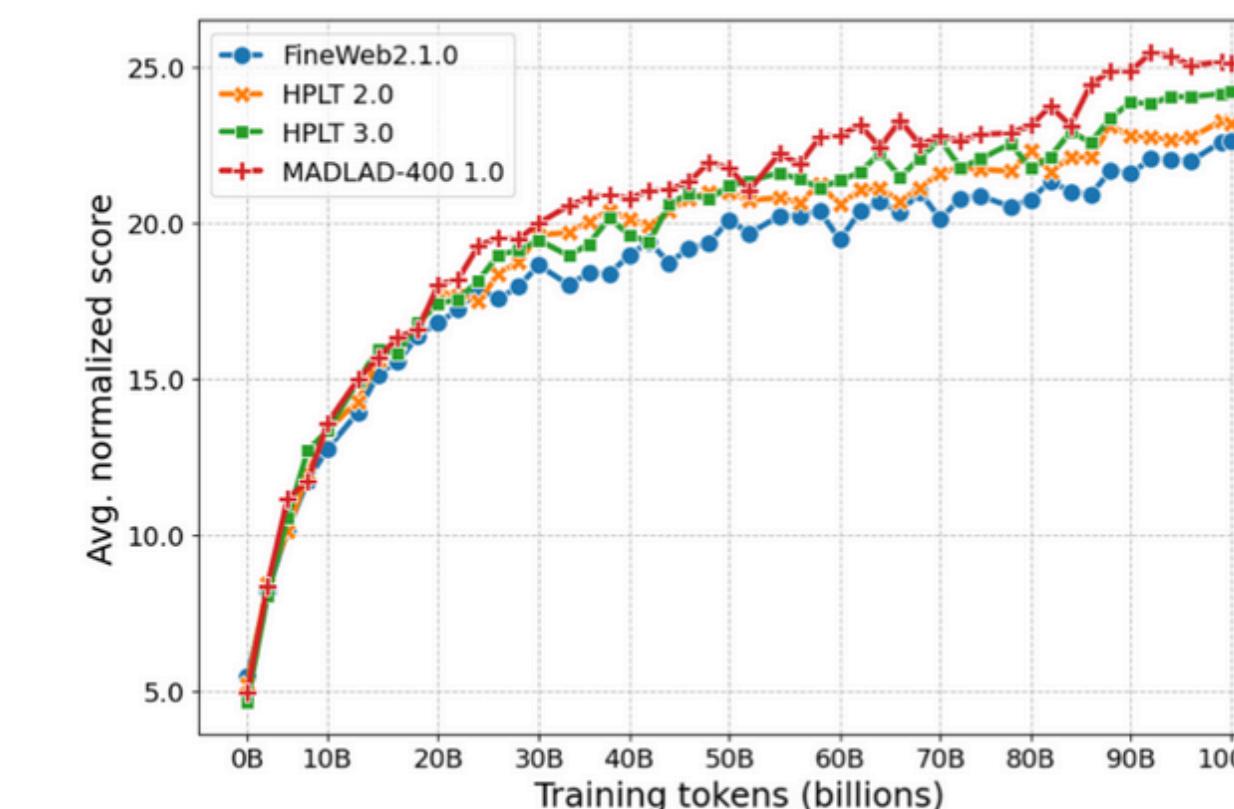
TRULY OPEN

including data, documentation, training and testing code, and evaluation

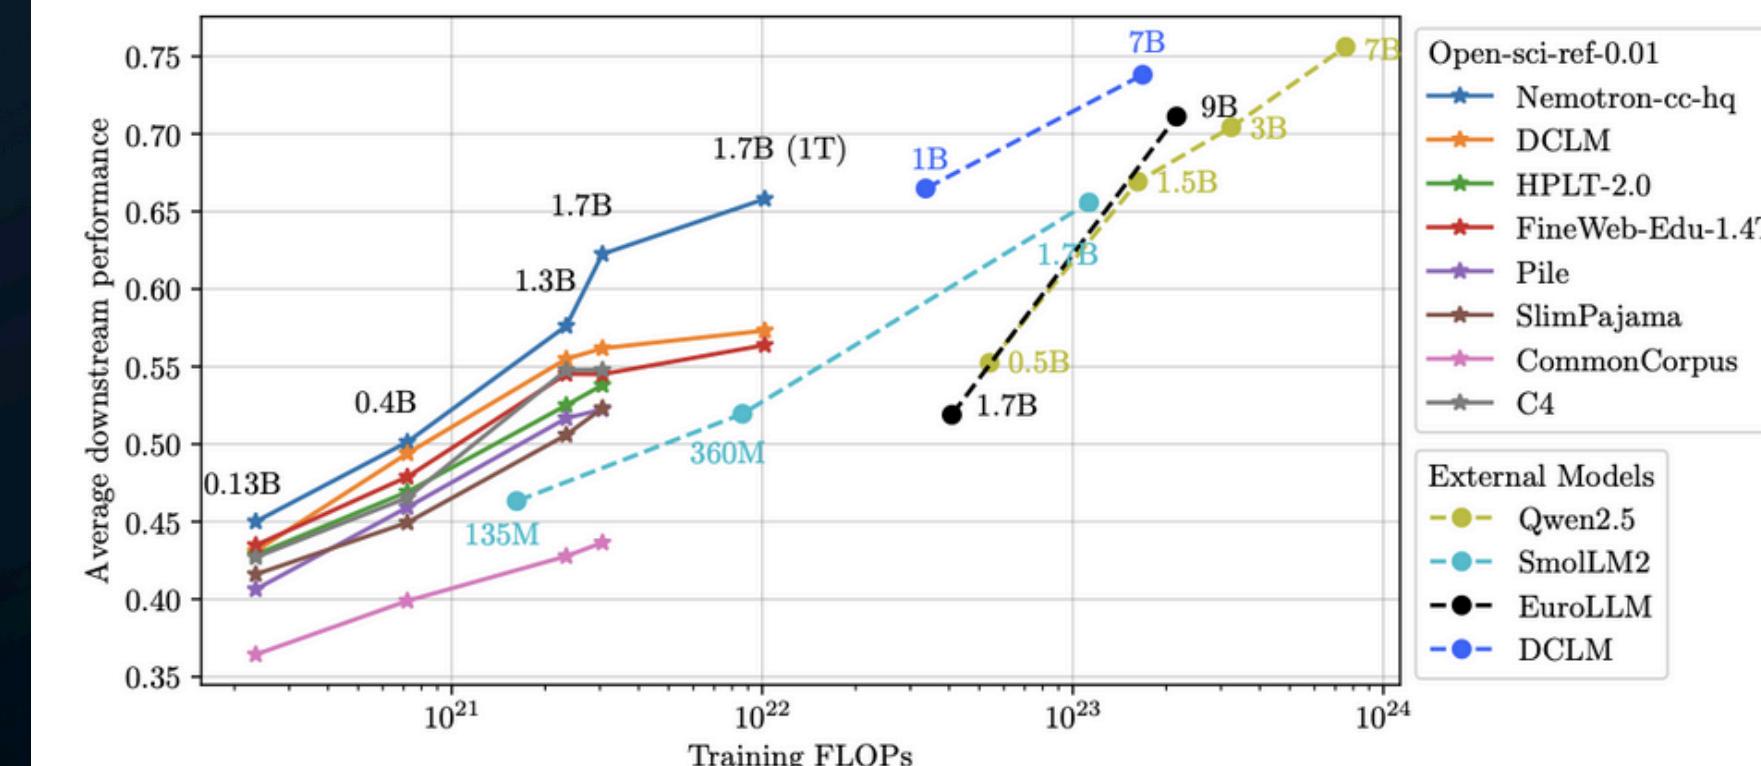


Utilisation de données synthétique pour les langues avec moins de ressources

Average over belebele\_pol\_Latn\_cf|0, global\_mmlu\_all\_pol\_cf|0, lumi\_arc\_pol\_cf:challenge|0.



Acquisition (crawling) de jeux de données à grandes échelle pour les langues Européennes

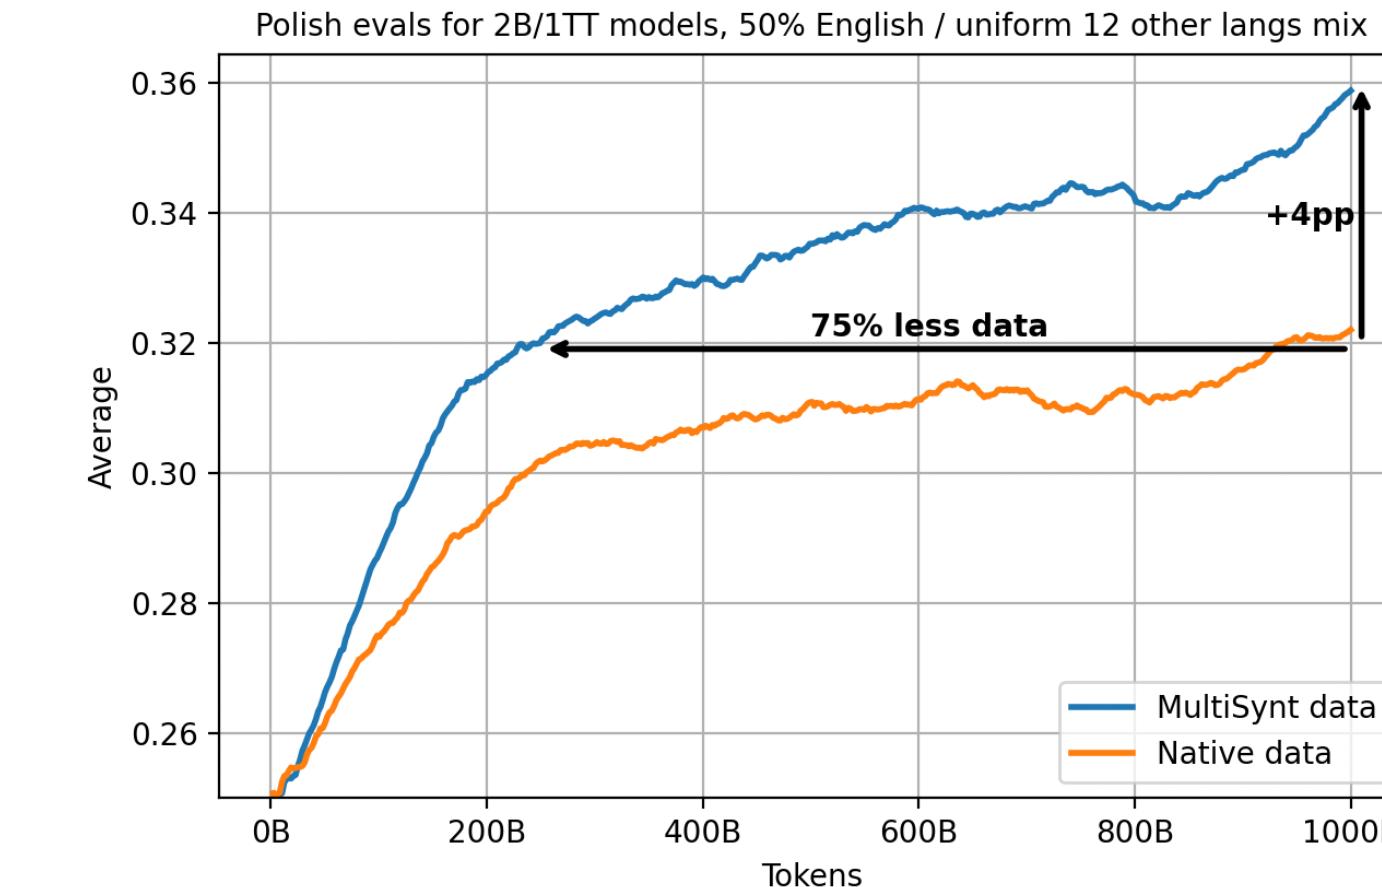


Scaling laws obtenues à petites échelles permettant de comparer des jeux de données.

# OpenEuroLLM

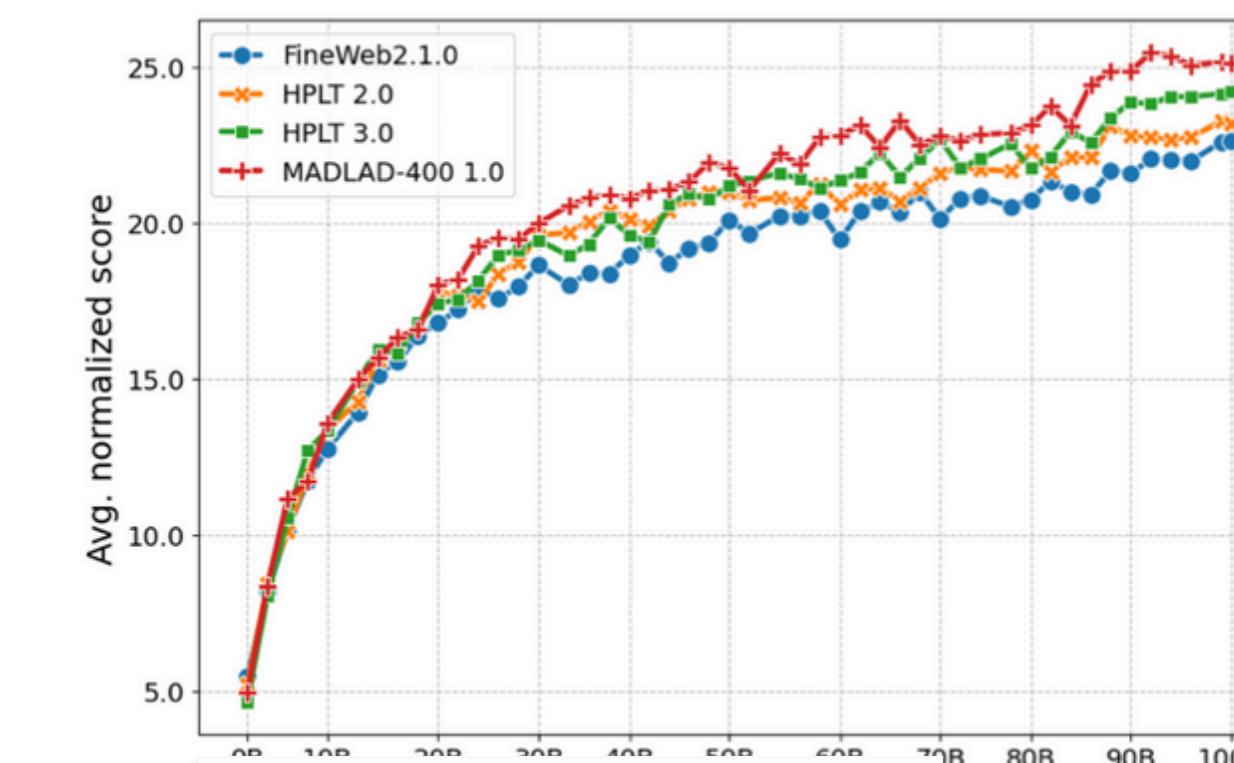
- Un effort pour construire des LLM multilingues à partir de zéro d'ici 2028, lancé en février 2025
- <https://openeurollm.eu/>
- Objectif : égaler l'état de l'art en anglais et améliorer significativement les performances sur les langues européennes
- Entièrement ouvert : poids, code et données
- Financement de 37,4 millions d'euros, également plusieurs millions d'heures GPU sur EuroHPC
- Jusqu'ici modèle entraînés avec 2B paramètres, entraînement en cours d'un modèle 8B pour Mai prochain

The screenshot shows the homepage of the OpenEuroLLM website. At the top left is the logo 'OPEN EURO LLM'. To the right are two buttons: 'MultiSynt' and 'Blog'. Below the logo, the text 'A series of foundation models for transparent AI in Europe' is displayed in large white font. At the bottom, the text 'TRULY OPEN' is followed by 'including data, documentation, training and testing code, and evaluation metrics: including community involvement'.

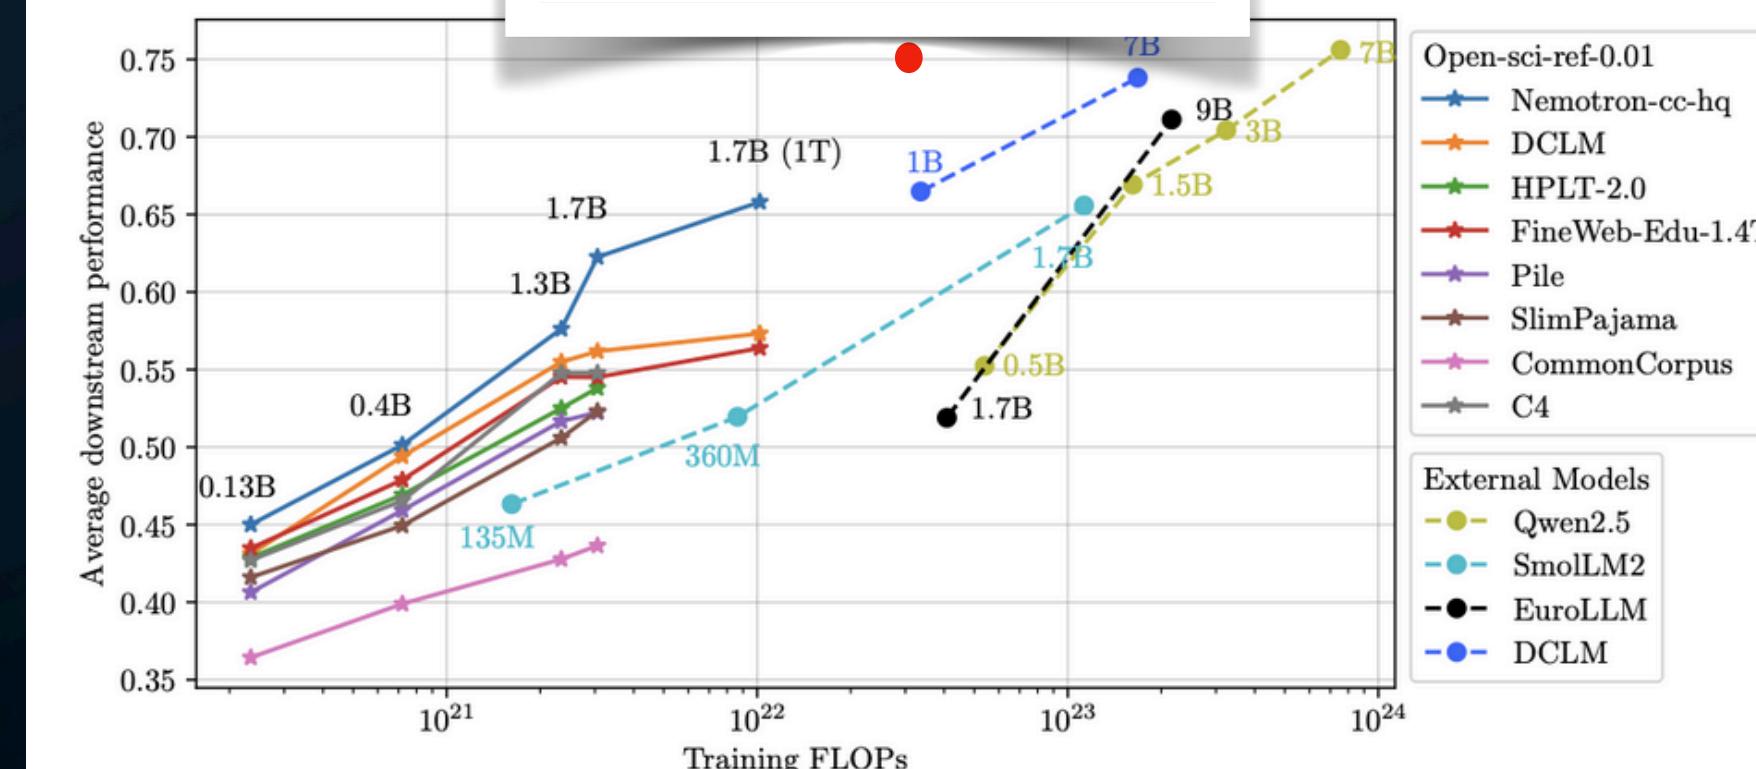


Utilisation de données synthétique pour les langues avec moins de ressources

Average over belebele\_pol\_Latn\_cf|0, global\_mmlu\_all\_pol\_cf|0, lumi\_arc\_pol\_cf:challenge|0.



Acquisition (crawling) de jeux de données à grandes échelle pour les langues Européennes



Scaling laws obtenues à petites échelles permettant de comparer des jeux de données.

# Conclusion

- Les agents de codage et les LLM : une technologie déjà transformative
- Enjeux critiques à adresser :
  - Sécurité : risques liés aux permissions et à l'exécution de code
  - Open vs propriétaire : transparence, contrôle, dépendance
  - Souveraineté : indépendance technologique européenne