

Claire LLM

*OpenLLM France:
Developing open language
models in France* 



WHO AM I - OUR MISSION WITH LINAGORA SINCE 2000



Julie Hunter
NLP/Linguistics

✉ jhunter@linagora.com



*« Ethical, responsible, sustainable and Open Source technologies
to make the world a better place, with maximum positive impact
on people, society and the planet. »*



LINTO: PLATE-FORME VOCALE



Outils linguistiques

Mots clés

- Bâche
- Changement
- Conjoncture
- Coup de pouce
- Informatique
- Point de vue
- Propositions
- Système
- Système si
- Systèmes

X Fermer l'éditeur Gestion d'équipe Publier le document

spk3 Qu'est-ce que je vais manger ce soir ? Faudrait que je fasse les courses peut-être

spk4 Hum il était temps

spk3 Bonjour madame ! Bonjour ! Oui m'excusez, c'est en retard, mais on n'a pas que ça à faire, je suis très occupée. Comme d'habitude, c'est encore moi qui vais devoir tout décider. Alors à l'ordre du jour, la gestion des absences nouveau système, qu'avez-vous à me proposer

spk2 Déjà je ne sais pas ce qu'on fait ici, parce que de toute façon le **système** de gestion de l'absence fonctionne très bien depuis des années et je ne vois pas pourquoi on aurait changé ça au moins de 2 mois.

spk3 Le **changement** c'est maintenant, l'évolution aux équipements.

00:00:00 / 00:06:18 1 2 3

Capture d'écran

Transcription + correction and annotation

Contexte de la demande

Produit Catégorie

Linto.app

A traiter

Ajouter par tag

Ajouter un média

Compile les événements à venir mentionnés dans ces documents

Bien sur ! j'ai trouvé 3 dates.

- Le 29 novembre, il y a l'innovation coffee, avec la présentation de linto.app
- Le 4 décembre, Ismail présentera à la réunion du lundi les avancés sur l'extra
- Le 5 décembre, vous avez une réunion avec la commission européenne

J'ai créé pour vous un fichier [calendrier-linto-app.ics](#) que vous pouvez importer

calendrier-linto-app.ics

Query / response, summarization

AMBITION OF THE OPENLLM FRANCE FR INITIATIVE

1

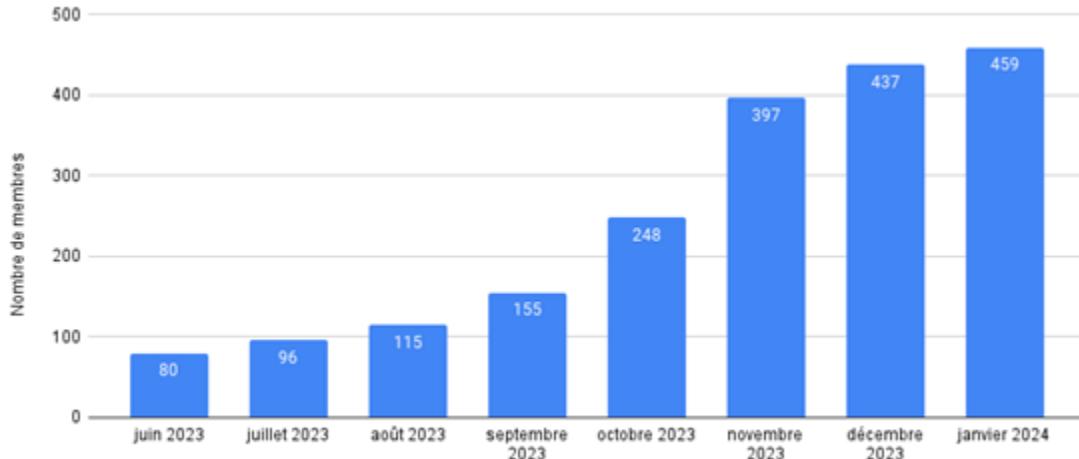
Build trusted, sovereign and
REAL Open Source AI models & technologies

2

Build an **open and transparent collaborative ecosystem** around LLMs and generative AI

<https://www.openllm-france.fr/>

WE'VE ALREADY COMPLETED OUR SECOND OBJECTIVE



Academics / Public research



Corporates

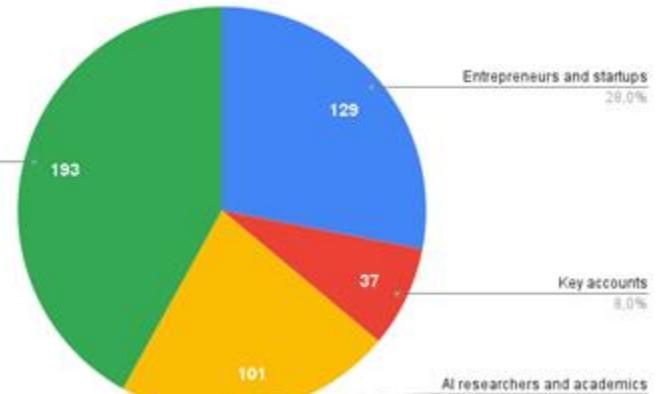


Curious and enthusiasts
42,0%

Entrepreneurs and startups
28,0%

Key accounts
8,0%

AI researchers and academics
22,0%



OPEN WEIGHTS ≠ OPEN SOURCE

July 20, 2023 Stefano Maffulli OSI opinion

Meta's LLaMa 2 license is not Open Source

(...neither is Mistral)



open source
initiative®

What is Open Source AI

An Open Source AI is an AI system made available to the public under terms that grant the freedoms to:



- Use the system for any purpose and without having to ask for permission.
- Study how the system works and inspect its components.
- Modify the system for any purpose, including to change its output.
- Share the system for others to use with or without modifications, for any purpose.

OUR CODE OF CONDUCT → CONTRIBUTIONS TO OSI AI DEFINITION

1

Open Source code

→ *Source code of the code model, pre training tool released under OSI compliant Open Source Licence*

2

Open Model

→ *Licence and user agreement without any restrictions on who may use it and for what*

3

Open Corpus

→ *100% of training data must be publicly available in a format that allows for investigation of the model's biases (preferences) and for retraining*

Model as a derivative work from data

<https://github.com/OpenLLM-France/OpenSourceAI-Definition>

THE PUSH FOR OPEN DATA

- **Common Crawl** (web)
- **C4** (web)
- **ArXiv** (academic papers)
- **Wikipedia**
- **StackExchange** (Q/A threads)
- **The Gutenberg project** (Books)
- **The Stack** (GitHub)
- ...



Hugging Face



1. Web crawled data
2. English

SOME CONCERNS

Web data

- personal information
- toxicity
- quality
- format
- duplication



RefinedWeb, OSCAR, CulturaX
(but can't solve everything)

English

- not just a choice
- not just about the language

Pour faire un boeuf
bourguignon il faut

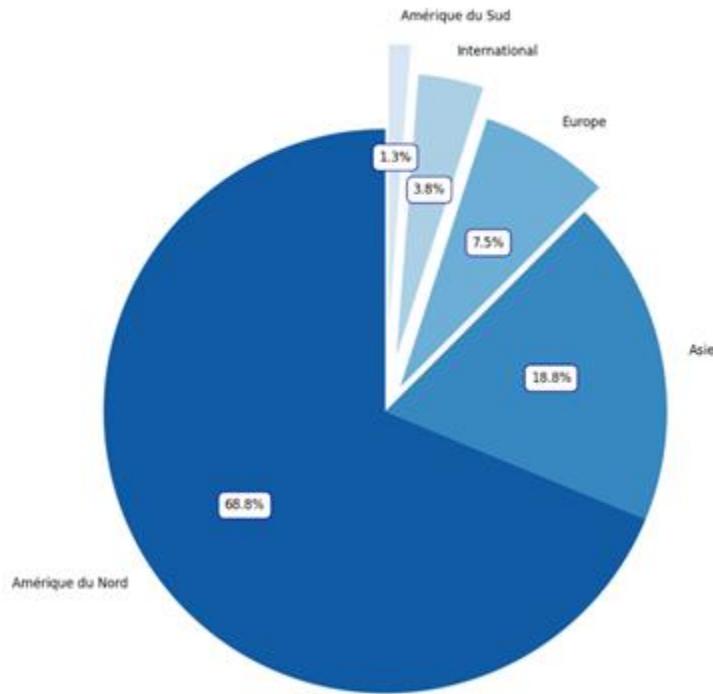
commencer par un bon vin.
To make a beef bourguignon
you must start with a good
wine.

- Julia Child
#####JULIA CHILD

-- Mistral

CREATING LLMS COMPLIANT WITH OUR CULTURE AND VALUES

Geographical distribution of LLMs with more than one billion parameters since 2018



LLAMA V2 : Language distribution in pretraining data with percentage

Language	Percent	Language	Percent
en	89.70%	uk	0.07%
unknown	8.38%	ko	0.06%
de	0.17%	ca	0.04%
fr	0.16%	sr	0.04%
sv	0.15%	id	0.03%
zh	0.13%	cs	0.03%
es	0.13%	fi	0.03%
ru	0.13%	hu	0.03%
nl	0.12%	no	0.03%
it	0.11%	ro	0.03%
ja	0.10%	bg	0.02%
pl	0.09%	da	0.02%
pt	0.09%	sl	0.01%
vi	0.08%	hr	0.01%

SMALL IS BEAUTIFUL

- **Compact & specialized models**
- **Better control → explicability / reliability**
- **Light training → continuous learning**
- **Low inference costs**
- **On edge deployment**

CLAIRE FOUNDATION MODEL (OCTOBER 2023)

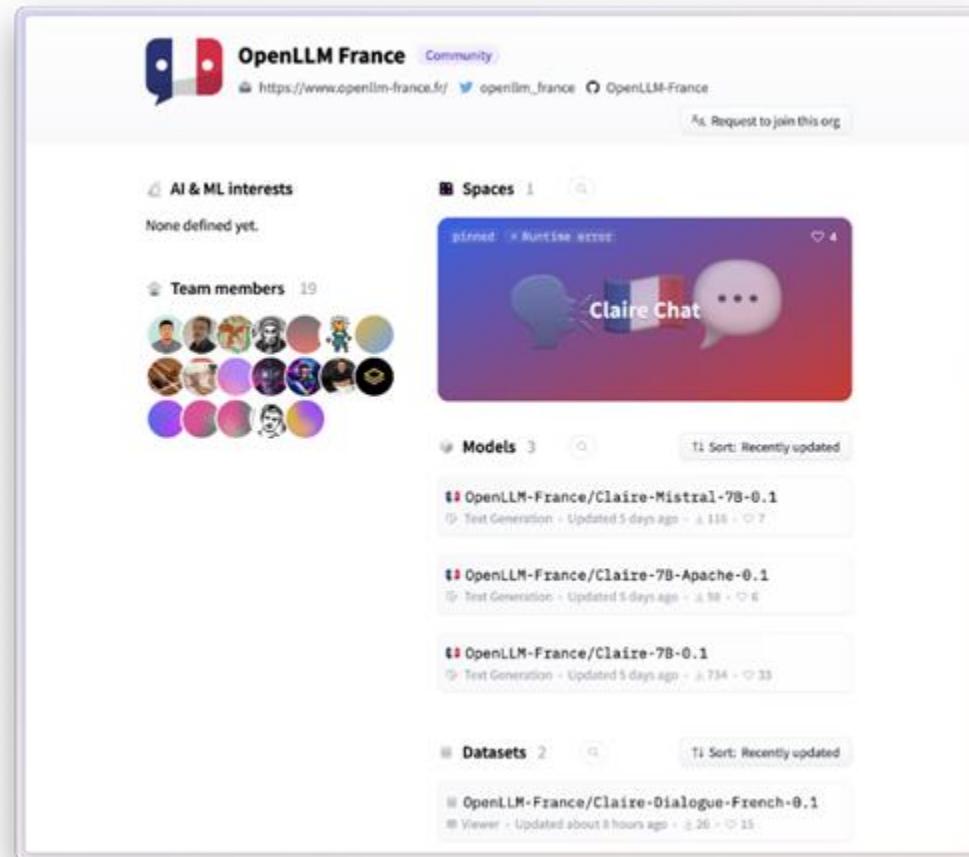
CLAIRE

Continual pre-training of Falcon 7B
1000H GPU (8xGPU) on
Jean ZAY supercomputer
25 kWh and 1.5kg of CO₂ emission

Data: 138M FR conversational data
(drama show, literature and real-life
meetings transcriptions). **No web-
crawled data**

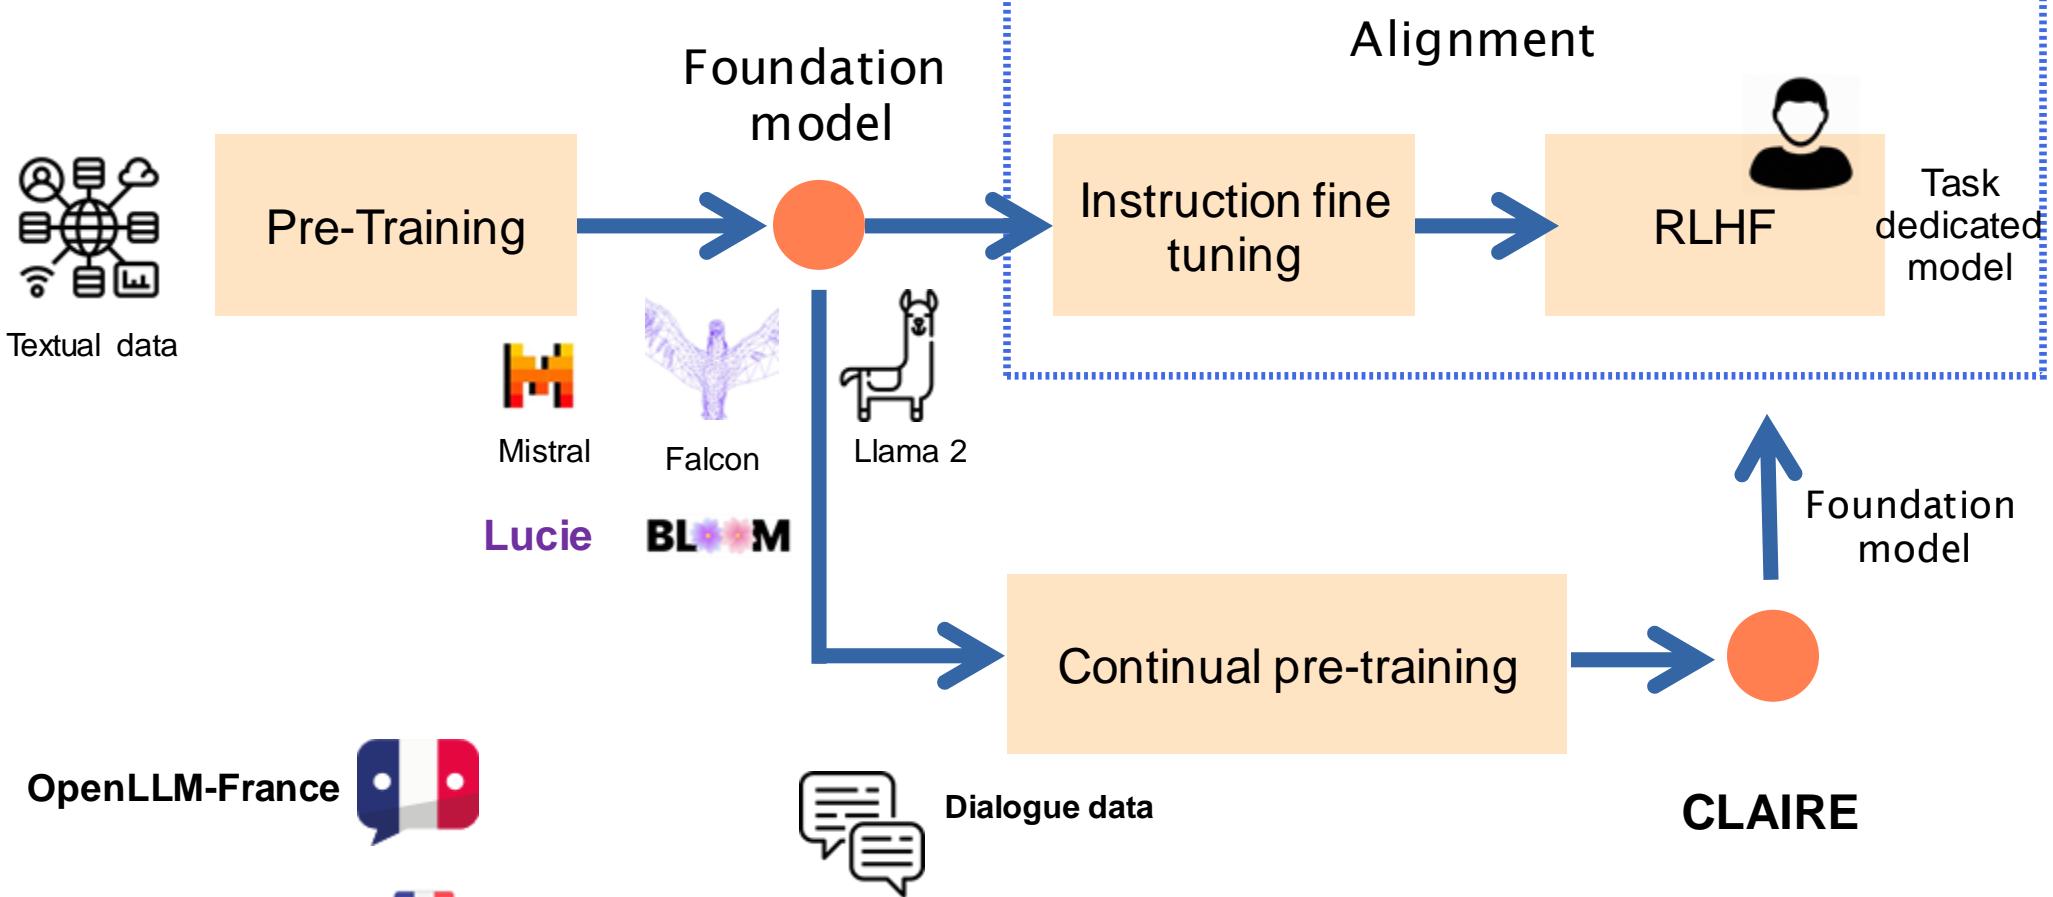
Features:

- Understand dialogues with diarization
- Generation of human-like
conversations (disfluencies,
hesitations...)



<https://huggingface.co/OpenLLM-France>

CONTINUAL PRETRAINING





**Appel à projets Thématisques
Spécifiques en Intelligence Artificielle
(TSIA) 2023**

Research and development of open, voice and text, generative models
for conversation

Applications to business meetings and SAMU emergency call analysis

<https://ia.loria.fr/llm4all>



LUCIE IS UNDERWAY

LUCIE

7B 100 % Open Source model

200 000H GPU (96xGPU) on
Jean ZAY supercomputer

Data: 120B of high quality FR data
(Gallica, Hal, Europarl, Wikipedia,
CLaIRE Datasets...), EN (60B,
peS2o), GE (3B), ES (3B), IT (2B),
Code (50B)

Features:

- 100% open source datasets
- Larger context windows
- Rotary & sliding windows
- Custom tokenizer



IF YOU SHARE OUR VALUES AND OUR AMBITION

Feel free to join the team



OpenLLM-Europe
on Discord

<https://discord.gg/3KvntCm6>



**THANKS FOR
YOUR
ATTENTION**



@linagora

Villa Good Tech | 37 Rue Pierre Poli, 92130
Issy-les-Moulineaux, FRANCE
Tél. : +33 (0)1 46 96 63 63 - Fax : +33 (0)1 46 96 63 64

OPENLLM FRANCE



OpenLLM France Community

<https://www.openlm-france.fr/> openlm_france [OpenLLM-France](#)

[Request to join this org](#)

AI & ML interests
None defined yet.

Spaces 1

Team members 19

Models 3

Sort: Recently updated

- [OpenLLM-France/Claire-Mistral-7B-0.1](#)
Text Generation · Updated 5 days ago · 119 · 0 · 7
- [OpenLLM-France/Claize-7B-Apache-0.1](#)
Text Generation · Updated 5 days ago · 59 · 0 · 6
- [OpenLLM-France/Claize-7B-0.1](#)
Text Generation · Updated 5 days ago · 33 · 0 · 33

Datasets 2

Sort: Recently updated

- [OpenLLM-France/Claire-Dialogue-French-0.1](#)
IR Viewer · Updated about 8 hours ago · 26 · 13

[Sign up](#)

OpenLLM-France

Communauté OpenLLM-France

49 followers [France](#) <https://www.openlm-france.fr/> <https://discord.gg/2f77BR4dY7> <https://huggingface.co/OpenLLM-F...> [contact@...](#)

[Overview](#) [Repositories](#) 6 [Discussions](#) [Projects](#) [Packages](#) [People](#) 9

README.md

Welcome to OpenLLM-France

[discord](#) [git](#)

The aim of the [OpenLLM France community](#) is to collaborate on the development of a French, sovereign, and truly Open Source LLM, that would be based on

- public and open training corpora,
- documented algorithms to ensure their explicability, and
- free, non-restrictive user licenses.

Follow us:

- [Discord](#)
- [Hugging Face](#)

People

Top languages

Python

<https://huggingface.co/OpenLLM-France>

<https://github.com/OpenLLM-France>