



Vers des LLMs ouverts et transparents pour l'Europe : conception, adaptation et explicabilité

Céline Hudelot,
Professeur en Informatique, CentraleSupélec
Laboratoire MICS



Avant propos

Une rapide bio



Profession

Professeur en Informatique – MICS - CentraleSupélec, Université Paris Saclay
Directrice du laboratoire MICS

Formation

HDR en Informatique, Université Paris-Sud Paris-Sud
Doctorat en Informatique, INRIA- Sophia Antipolis – France

Activités de recherche

Interprétation sémantique de données non-structurées

Paradigmes d'apprentissage (frugaux, continus, hybrides, actifs)

Modèles de fondation et grands modèles de langue

Explicabilité des systèmes d'IA


Laboratoire MICS

Mathématiques et Informatique pour la Complexité des Systèmes et des Données



Recherche méthodologique et fondamentale en **Mathématiques** et en **Informatique**


Orientée vers l'étude et la modélisation des systèmes **complexes** au sens large



Interaction multi-échelle
Ex : vivant



Systèmes stochastiques
Incertitude



Composants hétérogènes
en interaction





Données, non-
structurées, hétérogènes,
de grande taille

Intelligence Artificielle Générative

Defining Generative AI

To understand generative artificial intelligence (GenAI), we first need to understand how the technology builds from each of the AI subcategories listed below.



- Pré-entraînés à **grande échelle**, avec deux principaux objectifs: **mask language modeling (MLM)** et **causal language modeling (CLM)**.
- La phase de **pré-entraînement** permet au modèle d'acquérir des **connaissances** et des **capacités** étendues.
- Lors de l'**inférence**, à partir d'une invite d'entrée (**prompt**), le LLM génère une distribution de probabilité sur un vocabulaire pour les mots ou tokens suivants possibles.
- Un même modèle peut être utilisé **avec peu ou pas d'apprentissage** pour un ensemble de tâches (e.g. traduction, classification, résumé, réponses à des questions,...).
- Vers des **modèles de fondation**.

Travaux sur les LLMs au MICS

Pré-entraînement



The EuroLLM Suite

[Faysse et al, TMLR 25]
[Alves et al, COLM 24]
[Colombo et al, NeurIPS 24]
[Boizard et al, COLM 25]

Adaptation



Safe Retrieval [Gisserot et al, TMLR 24]

Colpali : Multimodal RAG [Faysse et al, ICLR 25]

Model Distillation [Boizard et al, TMLR 25]

Évaluation



Instruction Fine-tuned Model Evaluation


[Faysse et al, EMNLP 23]



New metric, benchmarking

[Colombo et al, AAAI 22]
[Colombo et al, NeurIPS 22]

Explicabilité




Concept-based approaches

[Claye et al, preprint 25]
[Aswal et al, preprint 25]

Et sur les modèles de fondation, e.g. santé

Modèles de fondation



Novae : graph-based FM for spatial transcriptomics data

[Blampey et al, preprint 24]

Sam-Path : Digital pathology segmentation

[Zhang et al, MICCAI Workshop 23]

rayDINO : X-ray analysis

[Moutakanni et al, preprint 24]

Robustesse, Adaptation



Full Conformal Adaptation of Medical VLMs [Silva-Rodriguez et al, MICCAI 25]

Out-of-distribution generalization [Scalbert et al, MICCAI 22]


Évaluation, Benchmarks



<https://mics-lab.github.io/thunder/>

Fair and comprehensive comparison of FMs in computational pathology

[Marza et al, preprint 25]



Explicabilité

Concept-based approaches

[Claye et al, GenBio ICML 25]

Explanation generation

[Charachon et al, FGCS 22]

Counterfactual analysis for digital histopathology


[Benkirane et al, MIDL 24]

Contexte : des modèles très performants

Des progrès majeurs à un rythme très rapide !

International AI Report [Bengio et al, 25]


« Between the end of the writing period for this report (5 December 2024) and the publication of this report in January 2025, an important development took place »



Contexte : des modèles loin d'être dignes de confiance

CNNs learn to predict pneumonia by detecting hospital which took the image

- Study on detecting pneumonia using 158,323 chest radiographs
- CNNs robustly identified hospital system and department within a hospital
- CNN has learned to detect a metal token that radiology technicians place on the patient in the corner of the image



Variable generalization performance of a deep learning model to detect pneumonia in chest radiographs: A cross-sectional study.
Zech J¹, Baddeley MA², Liu M², Costa AB³, Titano J^{2,4}, Germann EK³. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC30399157/>



Tesla on autopilot slam into truck



AI INCIDENT DATABASE

Type Here

Display Option Incidents 1211 results found Sort by Relevance Export More filters

Classifications Source Incident Date Published Date Language

Kronos Scheduling Algorithm Allegedly Caused Financial Issues for Starbucks Employees
cbsnews.com - 2015
Kronos's scheduling algorithm and its use by Starbucks managers allegedly negatively impacted financial and scheduling stability for Starbucks employees, which disadvantaged wage workers.

BlenderBot 3 Cited Dutch Politician as a Terrorist
twitter.com - 2022
Meta's conversational AI BlenderBot 3, when prompted "who is a terrorist," responded with an incumbent Dutch politician's name, who was confused about its association.

AI Tools Failed to Sufficiently Predict COVID Patients, Some Potentially Harmful
technologyreview.com - 2021
AI tools failed to sufficiently predict COVID patients, some potentially harmful.

LinkedIn Search Prefers Male Names
qz.com - 2016
An investigation by The Seattle Times in 2016 found a gender bias in LinkedIn's search engine.

incidentdatabase.ai

NEWS

Exploring the Dangers of AI in Mental Health Care

JUNE 11, 2025

DATE TOPICS

HEALTHCARE GENERATIVE AI

A new Stanford study reveals that AI therapy chatbots may not only lack effectiveness compared to human therapists but could also contribute to harmful stigma and dangerous responses.

Microsoft Created a Twitter Bot to Learn From Users. It Quickly Became a Racist Jerk.




Quelques challenges


- **Protection** des données : **confidentialité** et **intégrité** 
- Contraintes liées aux **ressources** disponibles, y compris les données 
- **Multimodalité** : plus que du texte et des images 
- **Confiance** : sécurité, robustesse, **explicabilité** 
- **Confiance** : vérification, validation 
- **Certification, conformité légale** 
- **Souveraineté** 

1. Il est possible de concevoir des modèles européens ouverts et transparents.

Une suite de modèles européens



Une suite de modèles européens



CROISSANT LLM : un petit modèle de langue

Un partenariat industriel et universitaire pour un SLM souverain



CroissantLLM: A Truly Bilingual French-English Language Model

Manuel Faysse^{1,5} Patrick Fernandes^{6,8,11} Nuno M. Guerreiro^{2,5,6,8}
António Loison¹ Duarte M. Alves^{6,8} Caio Corro⁹ Nicolas Boizard^{4,5}
João Alves² Ricardo Rei^{2,7,8} Pedro H. Martins² Antoni Bigata Casademunt¹⁰
François Yvon⁹ André F.T. Martins^{2,6,8} Gautier Viaud¹ Céline Hudelot⁵
Pierre Colombo^{3,5}



CentraleSupélec



université
PARIS-SACLAY



Manuel Faysse
CentraleSupélec, MICS
PhD student



Pierre Colombo
CentraleSupélec, MICS
Assistant Professor



Céline Hudelot
CentraleSupélec, MICS
Professor



Nicolas Boizard
CentraleSupélec, MICS
Diabolocom
PhD Student

Croissant LLM

Comment le construire ?

Option 1: Pré-entraînement from “scratch”

- ▶ Entrainer un nouveau modèle à partir de zéro;
 - ▶ Contrôle total ;
 - ▶ Nécessite beaucoup de puissance de calcul !

- ● ● ● ● ● ● ● ● ● ● ● ● ● ● ●

Option 2: Pre-entraînement continu

- ▶ On part d'un modèle existant et on continue son pré-entraînement;
 - ▶ On ne connaît pas tout du modèle d'origine;
 - ▶ Ne pas repartir de zéro.

Un projet de recherche avec des motivations industrielles



Recherche

CroissantLLM est un projet de recherche visant à étudier l'impact du **bilinguisme** sur le pré-entraînement et les performances des modèles de langue.



Industrie

Un modèle conçu pour être **suffisamment petit pour** fonctionner en local, mais suffisamment **performant** pour exécuter des tâches génératives souvent réservées à des modèles plus volumineux (**entraînement optimal pour l'inférence**). Il est entraîné uniquement sur des **données sous licence permissive**.



Open-Source

Basé sur l'open source, avec des modèles, des données, des bases de code et des critères d'évaluation **ouverts**, permettant ainsi aux **chercheurs et aux praticiens** d'en tirer profit.



Le modèle (lois d'échelle de Chinchilla)

Les modèles génératifs sont souvent des décodeurs (GPT, Mistral, LLaMa) dont les performances sont étroitement liées (1) au **nombre de paramètres du modèle** et (2) au **nombre de tokens d'entraînement**.

Entraîner le meilleur modèle étant donné un **budget de calcul fixé**

Pour un budget de calcul donné, il existe un rapport optimal entre le nombre de paramètres et la taille des données d'entraînement. (~20 selon les lois d'échelle de Chinchilla)

OU

Entraîner le meilleur modèle pour une **taille fixée**

En entraînant plus longtemps que le ratio Chinchilla, nous continuons à améliorer le modèle, mais les gains de performance sont de plus en plus coûteux.

Notre choix : surentraîner un petit modèle (1,3B) → rapport token:param de 2307 contre 20 optimal pour Chinchilla..



Plus léger



Plus rapide



Capable



Coût d'entraînement

Les données

L'entraînement des LLMs nécessite dénormes quantités de données... En français et sous licence permissive, il est encore plus difficile d'en rassembler suffisamment !

Corpus



Culture

Données sous licence permissive



Business

Données de l'industrie et des administrations



Connaissance

Données scientifiques et factuelles



Traduction

Données parallèles Anglais-Français



Internet

Données filtrées du web

Livres dans le domaine public

Podcasts

Poèmes

Paroles de chansons

Sous titres de films

Corpus de lois

Débats parlementaires

Décisions administratives

Documents commerciaux publics

Encyclopédies

Manuels scolaires

Résumés de thèses

Publications scientifiques

Une quantité considérable de paires de traduction provenant de différents domaines

Filtrées à l'aide de méthodes d'estimation de la qualité à l'état de l'art

Données à l'échelle du Web filtrées pour obtenir des textes français et anglais de haute qualité

Code Github sous licence libre

Les données

L'entraînement des LLMs nécessite dénormes quantités de données... En français et sous licence permissive, il est encore plus difficile d'en rassembler suffisamment !

Corpus



Culture

Données sous licence permissive



Business

Données de l'industrie et des administrations



Connaissance

Données scientifiques et factuelles



Traduction


Données parallèles Anglais-Français



Internet

Données filtrées du web

Pré-traitement des données



Transparence & Open-Source

Projet fondé sur la transparence, destiné à servir de ressource utile aux professionnels de l'industrie et aux chercheurs !



Processus d'entraînement documenté du début à la fin




- Ouvert à tous :
- **Corpus d'entraînement**
 - **Points de contrôle du modèle**
 - **Critères d'évaluation**
 - **Bases de code**




Pas de restrictions d'usage (MIT)

Foundation Model Transparency Index Total Scores




Application : Traduction dans le navigateur (DINUM)



<https://securitrad.centralesupelec.fr>

Une suite de modèles européens



Decodeurs vs. Encodeurs



À l'ère moderne du NLP, deux types principaux de modèles dominent : les modèles génératifs à encodeur et à décodeur uniquement.

Decodeur

How much do you like
encoders?



Decoder



I like encoders very much!

Encodeur


How much do you like
encoders?



Encoder



Stratégies de pré-entraînement : CLM vs. MLM



$$\mathcal{L}_{\text{CLM}} = - \sum_{t=1}^T \log P(x_t | x_{<t})$$

$$\mathcal{L}_{\text{MLM}} = - \sum_{i \in \mathcal{M}} \log P(x_i | x_{\setminus \mathcal{M}})$$

Focus sur deux travaux récents sur les encodeurs



EuroBERT: Scaling Multilingual Encoders for European Languages
COLM (2025)



Should We Still Pretrain Encoders with Masked Language Modeling?
Under review

Pourquoi des encodeurs ?



Avec l'explosion récente des modèles d'IA générative, les chercheurs ont tendance à oublier que les encodeurs restent de loin les modèles de texte d'apprentissage profond les plus utilisés dans l'industrie !



Polyvalence

Les représentations des encodeurs peuvent être utilisées pour des tâches telles que la classification, la recherche, la NER, les questions-réponses ...



Efficacité

Les modèles encodeurs sont intrinsèquement plus compacts que les modèles décodeurs, ce qui les rend nettement plus rapides tant pour le réglage fin que pour l'inférence.




Opportunités

Grâce aux récentes avancées sur les décodeurs (améliorations en termes de qualité des données, d'échelle et d'architecture), il existe un fort potentiel pour réaliser des progrès similaires dans le domaine des encodeurs.

Aperçu des modèles EuroBERT



- **3 tailles** adaptées à diverses contraintes
- **5T tokens** vus pendant l'entraînement
- **15 languages** supportés
- **8k taille du contexte**
- **Entièrement Open-Source**



Architecture



Les modèles EuroBERT comptent entre 210 millions et 2,1 milliards de paramètres, tous entraînés sur le même nombre de tokens et utilisant des configurations architecturales identiques.




Architecture inspirée de Llama 3



> Llama 3 tokenizer



> Grouped Query Attention



> Rotary Position Embeddings



> RMS Normalization



> SwiGLU layers



> Non-causal masking

Recettes pour l'apprentissage de bout en bout

Pre-training

**Data**

- > Large quantity of unsupervised data
- > Tokens masked randomly

**Learning objective**

- > MLM: model trained to retrieve the masked tokens

Annealing

**Data**

- > Smaller quantity of unsupervised data
- > Higher quality

**Learning objective**

- > MLM
- > Learning rate decreased to 0

Fine-tuning

**Data**

- > Depending on use case (classification, regression...)

**Learning objective**

- > Depending on use case (CE , MSE...)



Boizard et al, COLM 2025

EuroBERT: Scaling Multilingual Encoders for European Languages

<https://arxiv.org/abs/2503.05500>

<https://huggingface.co/collections/EuroBERT/eurobert-67ceb6c01804878b1f7999c6>

Recettes pour l'apprentissage de bout en bout

Pre-training

Data

- > Large quantity of unsupervised data
- > Tokens masked randomly

**Learning objective**

- > MLM: model trained to retrieve the masked tokens

Annealing

Data

- > Smaller quantity of unsupervised data
- > Higher quality

**Learning objective**

- > MLM
- > Learning rate decreased to 0

Fine-tuning

Data

- > Depending on use case (classification, regression...)

**Learning objective**

- > Depending on use case (CE , MSE...)



Evaluation

Boizard et al, COLM 2025

EuroBERT: Scaling Multilingual Encoders for European Languages

<https://arxiv.org/abs/2503.05500>

<https://huggingface.co/collections/EuroBERT/eurobert-67ceb6c01804878b1f7999c6>


Données pour le pré-entraînement



Un bon mix est la clé

- **Mix:** un modèle est performant sur les domaines qu'il a observés.
- **Math & code:** pour le raisonnement
- **Parallel data:** pour transférer des connaissances entre les langues

Data Mix of 5T Tokens




Stratégie de masquage



Stratégie de masquage

- > 50% de la phrase est masquée¹
- > **Seulement du masquage:** pas de remplacement par des jetons aléatoires (cf. entraînement de type BERT)




¹Alexander Wettig et al., "Should You Mask 15% in Masked Language Modeling?"

$f(x)$

: Cross-entropy on vocabulary space

Recettes pour l'apprentissage de bout en bout



Boizard et al, COLM 2025


EuroBERT: Scaling Multilingual Encoders for European Languages

<https://arxiv.org/abs/2503.05500>


<https://huggingface.co/collections/EuroBERT/eurobert-67ceb6c01804878b1f7999c6>

Procédure d'Annealing

Filtrage – Qualité des données



Learning Rate Decay



- **Performance améliorée**
- **Meilleure adéquation** avec les données du monde « réel »
- **Convergence plus efficace vers un minimum local**

Recettes pour l'apprentissage de bout en bout

Pre-training

**Data**

- > Large quantity of unsupervised data
- > Tokens masked randomly

$$f(\mathbf{x})$$

Learning objective

- > MLM: model trained to retrieve the masked tokens

Annealing

**Data**

- > Smaller quantity of unsupervised data
- > Higher quality

$$f(\mathbf{x})$$

Learning objective

- > MLM
- > Learning rate decreased to 0

Fine-tuning

**Data**

- > Depending on use case (classification, regression...)

$$f(\mathbf{x})$$

Learning objective

- > Depending on use case (CE , MSE...)



Boizard et al, COLM 2025

EuroBERT: Scaling Multilingual Encoders for European Languages

<https://arxiv.org/abs/2503.05500>

<https://huggingface.co/collections/EuroBERT/eurobert-67ceb6c01804878b1f7999c6>

Protocole d'évaluation





Protocole d'évaluation

- > Tâches: retrieval, sequence classification & regression, token classification
- > Baselines: XLM-RoBERTa, mDeBERTa, mGTE, ModernBERT
- > Fine-tuning: Tous les modèles sont soumis au même protocole afin de garantir une comparaison équitable.



Task	European Languages							Extra-European Languages					Code	Math	
	en	de	es	fr	it	nl	pl	pt	ar	hi	ja	ru	tr	vi	zh
<i>Information Retrieval</i>															
MIRACL	✓			✓	✓					✓	✓	✓	✓		✓
MLDR	✓	✓	✓	✓	✓	✓			✓	✓	✓	✓			✓
Wikipedia	✓	✓			✓	✓	✓		✓			✓			
CC-News	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
CodeSearchNet	✓														
DupStackMath	✓														✓
MathFormula	✓														✓
<i>Sequence Classification</i>															
XNLI	✓	✓	✓	✓	✓					✓	✓		✓	✓	✓
PAWS-X	✓	✓	✓	✓	✓										
AmazonReviews	✓	✓	✓	✓	✓					✓					
MassiveIntent	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
CodeDefect	✓														
CodeComplexity	✓														✓
MathShepherd	✓														✓
<i>Sequence Regression</i>															
WMT	✓	✓			✓				✓						
SeaHorse	✓	✓	✓	✓						✓	✓	✓	✓	✓	
<i>Token Classification</i>															
NER	✓	✓	✓				✓								

Résultats

Tâches multilingues



Tâches codes et maths




Performance d' EuroBERT


➤ **Multilingue:** EuroBERT égale ou surpassé les modèles de taille similaire sur les benchmarks multilingues.

➤ **Math & Code:** EuroBERT obtient des résultats SOTA dans les tâches mathématiques et liées au code

Token Classification



Impact de la fertilité du tokenizer sur la performance en NER

-  > **Observation:** Les modèles EuroBERT sont moins performants que leurs homologues de taille similaire en NER, malgré des performances globales raisonnables.
- > **Explication:** Une fertilité plus élevée implique la division des entités en plusieurs sous-tokens, ce qui dilue leur cohérence sémantique et complique ainsi la supervision.

Devons-nous continuer à pré-entraîner les encodeurs avec MLM ?



EuroBERT: Scaling Multilingual Encoders for European Languages
Accepted @ COLM (10/25)



Should We Still Pretrain Encoders with Masked Language Modeling?
Preprint (07/25)



- **Les gains minimes** obtenus entre 600 millions et 2 milliards d'EuroBERT ont soulevé des questions sur la mise à l'échelle traditionnelle des encodeurs.
- **EuroBERT est axé sur les données** ; Examen du rôle de l'objectif de pré-entraînement et de la bidirectionnalité.

Motivations



Entraînement bidirectionnel

> L'entraînement bidirectionnel est l'approche standard pour apprendre de bonnes représentations (e.g., BERT)



Pre-entraînement causal et apprentissage de représentations


> Plus récemment, les modèles génératifs (qui fonctionnent généralement à une échelle beaucoup plus grande) ont été adaptés à l'apprentissage de représentation, obtenant des résultats à l'état de l'art sur les benchmarks.



Question de recherche

Dans quelle mesure le pré-entraînement causal contribue-t-il réellement à renforcer les représentations, et dans quelle mesure cet effet est-il influencé par des facteurs confondants tels que l'échelle du modèle et le régime des données ?

CLM vs. MLM



$$\mathcal{L}_{\text{CLM}} = - \sum_{t=1}^T \log P(x_t | x_{<t})$$

$$\mathcal{L}_{\text{MLM}} = - \sum_{i \in \mathcal{M}} \log P(x_i | x_{\setminus \mathcal{M}})$$

Protocole expérimental



But : Évaluer l'impact spécifique de l'objectif de pré-entraînement sur la qualité de la représentation



- > **2 cadres réalistes:** PFS, CPT
- > **3 tailles de modèles:** 210M, 610M, 1B
- > **Cadre unifié:** Pipelines unifiés de pré-entraînement et d'ajustement / d'évaluation

PreTraining From Scratch (PFS)




Continued PreTraining (CPT)



Pré-entraînement





Question: Entre CLM et MLM, quel objectif est le plus efficace pour apprendre de bonnes représentations textuelles ?



- MLM **surpasse globalement CLM pour l'apprentissage des représentations textuelles.**
- Le passage à l'échelle diffère selon la tâche (e.g., QA vs. IR)
- CLM égale ou surpassé MLM en matière de TC.

Pré-entraînement avec MLM ou CLM




- > CLM est plus **data-efficient** que MLM (gauche)
- > CLM génère des modèles plus **faciles à adapter** que MLM (droite)

Recyclage de modèles via un pré-entraînement continu





Question: Si nous voulons poursuivre le pré-entraînement d'un modèle existant, devons-nous partir d'un point de contrôle MLM ou CLM ?



> Dans l'ensemble, adapter un CLM avec MLM donne de meilleurs résultats que la poursuite du MLM sur un modèle pré-entraîné avec MLM.

Pré-entraînement continu



- > Quelques étapes de CPT suffisent pour atteindre de bonnes performances
> Les modèles pré-entraînés avec CLM montrent une **trajectoire plus prometteuse**.



Conclusions

- Il est possible de construire des **modèles européens ouverts, transparents et compétitifs**
- Importance de l' **ouverture des modèles, codes et données** :
 - Plus que les modèles eux-mêmes, l'ouverture dans ce domaine permet de **partager le savoir-faire et des recettes importantes**.
 - Vers des modèles entièrement ouverts incluant les **points de contrôle d'entraînement** pour étudier de nouvelles pistes d'amélioration mais aussi comprendre la dynamique de l'entraînement



2. Importance des données pour l'adaptation

Adaptation



Adapter les LLMs et les rendre accessibles au plus grand nombre impliquent de les **adapter à des données spécifiques**, de remédier aux **contraintes liées aux coûts** et de résoudre les limites en **matière d'évaluation**.




Safe Retrieval

Trustworthy Reranking:
abstention mechanism



TMLR-2024



ULD - Distillation Loss

Loss using optimal transport theory to enable distillation across different architectures & tokenizers.



TMLR-
2025



université
PARIS-SACLAY

ColPali – Multimodal LM

Simple Document Retrieval in the Vision Space.



ICLR - 2025

Adaptation



Adapter les LLMs et les rendre accessibles au plus grand nombre impliquent de les **adapter à des données spécifiques**, de remédier aux **contraintes liées aux coûts** et de résoudre les limites en **matière d'évaluation**.



Safe Retrieval

Trustworthy Reranking:
abstention mechanism



TMLR-2024



ULD - Distillation Loss

Loss using optimal transport theory to enable distillation across different architectures & tokenizers.



TMLR-
2025



université
PARIS-SACLAY

ColPali – Multimodal LM


Simple Document Retrieval in the Vision Space.




ICLR - 2025

RAG: Retrieval Augmented Generation

Le cas d'usage n°1 en entreprise



Pipeline classique pour la recherche de documents



Une chaîne complexe et lente

Colpali : recherche dans le domaine visuel

Idée : supprimer complètement l'analyse des documents, en travaillant avec des « captures d'écran » des documents.

Les pipelines standard fonctionnent avec le contenu textuel extrait.

Des pipelines complexes sont nécessaires pour extraire du texte, détecter la mise en page du document, légendrer les éléments visuels, intégrer le contenu textuel à l'aide de modèles d'intégration de texte...

vs.

Peut-on former des retrievers à travailler à partir d'images de documents ?

Les modèles linguistiques visuels sont utilisés pour créer directement des représentations de l'image de chaque page du document !

La récupération de documents à partir d'images est un concept totalement nouveau... Est-ce que cela fonctionne bien ?



Capable




Plus rapide



Entrainable

Colpali : recherche dans le domaine visuel



Colpali : le benchmark ViDoRe

ViDoRe, Visual Document Retrieval Benchmark (référentiel de recherche documentaire visuelle), qui permet d'évaluer la capacité des moteurs de recherche à **extraire des informations riches sur le plan visuel** dans des documents, avec des tâches couvrant divers **sujets, modalités** (figures, tableaux, texte) et **langues** !

Dataset	# Queries	Domain
Academic Tasks		
DocVQA (eng)	500 (500)	Industrial
InfoVQA (eng)	500 (500)	Infographics
TAT-DQA (eng)	1600 (1600)	Varied Modalities
arXiVQA (eng)	500 (500)	Scientific Figures
TabFQuAD (fra)	210 (210)	Tables
Practical Tasks		
Energy (eng)	100 (1000)	Scientific
Government (eng)	100 (1000)	Administrative
Healthcare (eng)	100 (1000)	Medical
AI (eng)	100 (1000)	Scientific
Shift Project (fra)	100 (1000)	Environment

Table 1: *ViDoRe* comprehensively evaluates multimodal retrieval methods. The size of the document corpus is indicated in parentheses.

Colpali : le benchmark ViDoRe

Exemples de paires (document, requête)

What types of accounts or products allow investors to defer paying taxes?

What are some common outcome areas targeted by TAI for different age groups?

ViDoRe V2 et V3




- ViDoRe V2 a étendu le benchmark à des requêtes plus ouvertes.
- ViDoRe V3 conçu pour établir une nouvelle norme d'excellence dans le secteur de l'évaluation multimodale de la recherche de documents d'entreprise (avec NVIDIA)

Query

Where is the S-3's single point receptacle located?

Relevant Pages & Bounding Boxes

Answer



The S-3's single point receptacle (SPR) is located on the right side of the fuselage immediately aft of the main landing gear well.

Quelques résultats




Figure 3: Offline indexing with *ColPali* is much simpler and faster compared to standard retrieval methods. Indexing speeds reported are computed on Nvidia L4 GPUs and detailed in subsection B.5.

ColPali est simple & rapide


L'encodage s'effectue par simple transfert, ce qui permet d'intégrer les documents 18 fois plus rapidement qu'avec des pipelines PDF/OCR complexes.

	ArxivQ	DocQ	InfoQ	TabF	TATQ	Shift	AI	Energy	Gov.	Health.	Avg.
Unstructured Text only											
- BM25	-	34.1	-	-	44.0	59.6	90.4	78.3	78.8	82.6	-
- BGE-M3	-	28.4 _{±5.7}	-	-	36.1 _{±7.9}	68.5 _{±8.9}	88.4 _{±2.0}	76.8 _{±1.5}	77.7 _{±1.1}	84.6 _{±2.0}	-
Unstructured + OCR											
- BM25	31.6	36.8	62.9	46.5	62.7	64.3	92.8	85.9	83.9	87.2	65.5
- BGE-M3	31.4 _{±0.2}	25.7 _{±11.1}	60.1 _{±2.8}	70.8 _{±24.3}	50.5 _{±12.2}	73.2 _{±8.9}	90.2 _{±2.6}	83.6 _{±2.3}	84.9 _{±1.0}	91.1 _{±3.9}	66.1 _{±0.6}
Unstructured + Captioning											
- BM25	40.1	38.4	70.0	35.4	61.5	60.9	88.0	84.7	82.7	89.2	65.1
- BGE-M3	35.7 _{±4.4}	32.9 _{±5.4}	71.9 _{±1.9}	69.1 _{±33.7}	43.8 _{±17.7}	73.1 _{±12.2}	88.8 _{±0.8}	83.3 _{±1.4}	80.4 _{±2.3}	91.3 _{±2.1}	67.0 _{±1.9}
Contrastive VLMs											
Jina-CLIP	25.4	11.9	35.5	20.2	3.3	3.8	15.2	19.7	21.4	20.8	17.7
Nomic-vision	17.1	10.7	30.1	16.3	2.7	1.1	12.9	10.9	11.4	15.7	12.9
SigLIP (Vanilla)	43.2	30.3	64.1	58.1	26.2	18.7	62.5	65.7	66.1	79.1	51.4
Ours											
SigLIP (Vanilla)	43.2	30.3	64.1	58.1	26.2	18.7	62.5	65.7	66.1	79.1	51.4
BiSigLIP (+fine-tuning)	58.5 _{±15.3}	32.9 _{±2.6}	70.5 _{±6.4}	62.7 _{±4.6}	30.5 _{±4.3}	26.5 _{±7.8}	74.3 _{±11.8}	73.7 _{±8.0}	74.2 _{±8.1}	82.3 _{±3.2}	58.6 _{±7.2}
BiPali (+LLM)	56.5 _{±2.0}	30.0 _{±2.9}	67.4 _{±3.1}	76.9 _{±14.2}	33.4 _{±2.9}	43.7 _{±17.2}	71.2 _{±3.1}	61.9 _{±11.7}	73.8 _{±0.4}	73.6 _{±8.8}	58.8 _{±0.2}
ColPali (+Late Inter.)	79.1 _{±22.6}	54.4 _{±24.5}	81.8 _{±14.4}	83.9 _{±7.0}	65.8 _{±32.4}	73.2 _{±29.5}	96.2 _{±25.0}	91.0 _{±29.1}	92.7 _{±18.9}	94.4 _{±20.8}	81.3 _{±22.5}

Table 2: Comprehensive evaluation of baseline models and our proposed method on *ViDoRe*. Results are presented using NDCG@5 metrics, and illustrate the impact of different components. Text-only metrics are not computed for benchmarks with only visual elements.

3. Importance de l'explicabilité : vers des outils ouverts

Composantes clés de l'explicabilité



Tutoriels PFIA

PFIA 2024



PFIA 2025



Des outils en open-source



Interpreto

Interpretability Toolbox for LLMs

DEEL FOR ANITI



Optimized for Tensorflow / Keras ecosystem.

Xplique

A deep learning Explainability Toolbox

Thomas FEL*, Lucas HERVIER*, David VIGOUROUX, Antonin POCHE, Justin PLAKO, Rémi CADENE, Mathieu CHALVIDAL, Julien COLIN, Thibaut BOISSIN, Louis BETHUNE, Agustin PICARD, Claire NICODEME, Laurent GARDES, Grégory FLANDIN, Thomas SERRE

(1) Attribution Methods more than 14 black-box / white-box methods

```
from xplique.attributions import GradCAM
explainer = GradCAM(model)
explanations = explainer(x, y)
```

*Pytorch, Sklearn supported for black-box methods

(3) Feature Visualization

- Neurons • Channels • Directions

```
from xplique.visualization import Objective, optimize
obj = Objective.neuron(model, 'logits', 10)
images, obj_name = optimize(obj)
```

'Ladybug' 'Goldfish'

Visualize Neurons, Channels, Vectors in activation space (e.g. CAV) or a mix of them!

(2) Metrics more than 6 attributions metrics each supporting multiple baselines

Deletion (low AUC + better faithfulness) **Insertion*** (high AUC + better faithfulness)

```
from xplique.metrics import Deletion
from xplique.attributions import GradCAM
metric = Deletion(model, x, y)
explanations = GradCAM(model)(x, y)
score = metric(explanations)
```

(4) Concept based concept activation vector, CRAFT (new!)

```
from xplique.concepts import Cav
extractor = Cav(model, 'mixed')
concept_vector = extractor(striped_samples, random_samples)
```

Easily extract and test CAVs:

Used in:
CRAFT: Concept Activation FactORIZATION for Explainability
Look at the Variance! Efficient Black-box Explanations with Sobol-based Sensitivity Analysis
Don't Lie to Me: Robust & Efficient explainability with Verified Permutation Analysis
Making Sense of Dependence: Efficient Black-box Explanations Using Dependence Measure

github.com/deel-ai/xplique
See also: github.com/deel-ai/deel-ip

Evolution of learned concepts during training




Figure 8: Evolution of θ over discrete time steps, with vectors indicating orientations toward three fixed concepts. The vector lengths represent the coefficients associated with each concept. The main intuition behind this figure is that, during training, the model may learn similar concepts but represent them differently (here, concept directions do not evolve linearly over time). In such a case, our process may fail to properly track concepts for direct comparison. However, the relative importance of concepts should remain stable-hence, we should focus on comparing their significance rather than their raw orientation (illustrated here by the arrow lengths).



**Internship of Raphael Bernas
with Fanny Jourdan and A. Poché, IRT Saint Exupéry**




Conclusions

- Il est possible de construire des **modèles européens ouverts, transparents et compétitifs**
- Importance de **l'ouverture des données, modèles, code de bases, points de contrôle d'entraînement.**
- Problème du **contexte-shift** : les jeux d'évaluation sont souvent peu représentatifs de l'ensemble des cas réels, e.g. ViDOrE.
- Importance de supporter la mise à disposition d'outils pour la conception de systèmes de confiance.

The team



Many more



Q&A

6
5