

TAL, IA et corpus médicaux

Ioana BUHNILA

Post-doctorante à ATILF, CNRS - Université de Lorraine

ioana.buhnila@univ-lorraine.fr

1. Présentation du projet de postdoc



1. Explorer les comptes-rendus des patients qui ont des tumeurs cérébrales de type gliome
2. Trouver des réponses à des questions de recherche médicales dans des articles scientifiques

- ATILF (Mathieu Constant)
- IECL (Marianne Clausel)
- CRAN (Hélène Dumond)
- CHRU Nancy (Luc Taillandier)

2. Motivation

1. Explorer les comptes-rendus des patients qui ont des tumeurs cérébrales de type gliome
2. Trouver des réponses à des questions de recherche médicales dans des articles scientifiques

- Aider à améliorer les traitements des patients
- Adapter les traitements des patients par rapport à leurs profils

**médecine
personnalisée**


3. Contexte linguistique

1. **Le terme** - une unité lexicale de spécialité qui représente des connaissances spécifiques à un domaine du savoir (Costa, 2006)
2. **Entités nommées (NER)**
3. **Relations sémantiques (RE)**

4. Données

1. Articles scientifiques
2. Textes grand public
3. Dossiers des patients (CHRU Nancy)

4. Données



4. Données

Ressources textuelles

3. Dossiers patients

- Compte-rendu visite patient
- Compte-rendu IRM
- Bilan anatomopathologique
- Bilan orthophonique

5. Méthode(s) TAL


1. NER
2. RE
3. RAG
4. IA générative

5. Méthode(s) TAL

1. **NER**
2. RE
3. RAG
4. IA générative

5. Méthode(s) TAL


NER (*Named Entity Recognition*) = reconnaissance d'entités nommées d'un texte
(PERS, ORG, LIEU, etc.)



DrBERT (Labrak et al., 2023)



QUAERO (Névéol et al., 2014)



Droits d'auteurs de l'image : Névéol Aurélie, Grouin Cyril, Leixa Jeremy, Rosset Sophie, Zweigenbaum Pierre

DrBERT NER

➤ Exemple de résultat


```
462  
463 phrase = Tysabri est utilisé dans le traitement des adultes atteints de sclérose en plaques ( SEP ).  
464  
465 DrBERT NER  
466  
467 [{ 'entity_group': 'CHEM', 'score': 0.96629834, 'word': 'T', 'start': 0, 'end': 1},  
468   { 'entity_group': 'CHEM', 'score': 0.9808131, 'word': 'ys', 'start': 1, 'end': 3},  
469   { 'entity_group': 'CHEM', 'score': 0.96141714, 'word': 'abri', 'start': 3, 'end': 7},  
470   { 'entity_group': 'PROC', 'score': 0.99979216, 'word': 'traitement', 'start': 27, 'end': 38},  
471   { 'entity_group': 'LIVB', 'score': 0.9994868, 'word': 'adultes', 'start': 42, 'end': 50},  
472   { 'entity_group': 'DISO', 'score': 0.999736, 'word': 'sclérose en plaques', 'start': 62, 'end': 82},  
473   { 'entity_group': 'DISO', 'score': 0.97993124, 'word': 'SEP', 'start': 84, 'end': 88}]
```

5. Méthode(s) TAL

1. NER
2. RE
3. RAG
4. IA générative

5. Méthode(s) TAL

RE (*Relation Extraction*) =
extraction de relations sémantiques
entre les entités nommées
(Detroja et al., 2023)




5. Méthode(s) TAL

1. NER
2. RE
3. **RAG**
4. IA générative

RAG

RAG (*Retrieval Augmented Generation*) = modèle qui combine la mémoire interne des modèles de langues avec une mémoire externe (base de connaissances) (Lewis et al., 2021)

- RAG-end2end (Siriwardhana et al., 2023) ; SELF-RAG (Asai et al., 2023) ; SELF-BioRAG (Jeong et al., 2024)



RAG

➤ Exemple de résultat


```
1 from transformers import RagTokenizer, RagRetriever, RagTokenForGeneration
2
3 tokenizer = RagTokenizer.from_pretrained("facebook/rag-token-nq")
4 retriever = RagRetriever.from_pretrained("facebook/rag-token-nq", index_name="exact", use_dummy_dataset=
  True)
5 model = RagTokenForGeneration.from_pretrained("facebook/rag-token-nq", retriever=retriever)
6
7 input_dict = tokenizer.prepare_seq2seq_batch("What is a glioma?", return_tensors="pt")
8
9 generated = model.generate(input_ids=input_dict["input_ids"])
10 print(tokenizer.batch_decode(generated, skip_special_tokens=True)[0])
11
12 # Réponse : cancer
13
14
```

5. Méthode(s) TAL

1. NER
2. RE
3. RAG
4. **IA générative**

5. Méthode(s) TAL

IA générative = modèle de langue pré-entraîné qui génère du texte



(Zhao et al., 2023)

Fig. 1. A timeline of existing large language models (having a size larger than 10B) in recent years. We mark the open-source LLMs in yellow color.

IA générative

Arena (battle) Arena (side-by-side) Direct Chat Leaderboard About Us

🗡️ Chatbot Arena: Benchmarking LLMs in the Wild

[| Blog](#) | [| GitHub](#) | [| Paper](#) | [| Dataset](#) | [| Twitter](#) | [| Discord](#) |

📄 Rules

- Ask any question to two anonymous models (e.g., ChatGPT, Claude, Llama) and vote for the better one!
- You can continue chatting until you identify a winner.
- Vote won't be counted if model identity is revealed during conversation.

🏆 Arena Elo ([Leaderboard](#))

We collect 200K+ human votes to compute an Elo-based LLM leaderboard. Find out who is the 🏆 LLM Champion!

👉 Chat now!

🔍 Expand to see 20+ Arena players

Model A	Model B

UC Berkeley [SkyLab](#)

<https://chat.lmsys.org/?model=koala-13b>

6. Références bibliographiques

- Asai, A., Wu, Z., Wang, Y., Sil, A., & Hajishirzi, H. (2023). Self-RAG: Self-reflective Retrieval Augmented Generation. In *NeurIPS 2023 Workshop on Instruction Tuning and Instruction Following*.
- Costa, R. (2005). Texte, terme et contexte. In *Actes des septièmes Journées scientifiques du réseau de chercheurs Lexicologie Terminologie Traduction*, pp. 79-88. Bruxelles, Belgique.
- Detroja, K., Bhensdadia, C. K., & Bhatt, B. S. (2023). A Survey on Relation Extraction. *Intelligent Systems with Applications*, 200244.
- Jeong, M., Sohn, J., Sung, M., & Kang, J. (2024). Improving Medical Reasoning through Retrieval and Self-Reflection with Retrieval-Augmented Large Language Models. *arXiv preprint arXiv:2401.15269*.
- Labrak, Y., Adrien Bazoge, Richard Dufour, Mickael Rouvier, Emmanuel Morin, Béatrice Daille and Pierre-Antoine Gourraud. (2023). [DrBERT: A Robust Pre-trained Model in French for Biomedical and Clinical domains](#).
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., ... & Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive nlp tasks. *Advances in Neural Information Processing Systems*, 33, 9459-9474.
- Névéal A, Grouin C, Leixa J, Rosset S, Zweigenbaum P. (2014). The QUAERO French Medical Corpus: A Ressource for Medical Entity Recognition and Normalization. Fourth Workshop on Building and Evaluating Ressources for Health and Biomedical Text Processing. In Proceedings of the Fourth Workshop on Building and Evaluating Ressources for Health and Biomedical Text Processing BioTxtM2014. 2014:24-30.
- Siriwardhana, S., Weerasekera, R., Wen, E., Kaluarachchi, T., Rana, R., & Nanayakkara, S. (2023). Improving the domain adaptation of retrieval augmented generation (RAG) models for open domain question answering. *Transactions of the Association for Computational Linguistics*, 11, 1-17.
- Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., ... & Wen, J. R. (2023). A survey of large language models. *arXiv preprint arXiv:2303.18223*.

Merci pour votre attention !
