



HAL
open science

Pistes pour l'optimisation de modèles de parsing syntaxique

Rayan Ziane, Natasha Romanova

► **To cite this version:**

Rayan Ziane, Natasha Romanova. Pistes pour l'optimisation de modèles de parsing syntaxique. LIFT 2 - 2024 : Journées de lancement, Nov 2024, Orléans, France. . hal-04811291

HAL Id: hal-04811291

<https://hal.science/hal-04811291v1>

Submitted on 29 Nov 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

PISTES POUR L'OPTIMISATION DE MODÈLES DE PARSING SYNTAXIQUE

CRISCO
Langues | Signification | Contexte

Rayan ZIANE*°, Natasha ROMANOVA*

*CRISCO, Université Caen Normandie; °LLL, Université d'Orléans



ANR
Agence nationale de la recherche



DFG
Deutsche Forschungsgemeinschaft

INTRODUCTION

Avec l'avènement de technologies d'apprentissage profond, toute analyse syntaxique automatique d'un corpus textuel présuppose l'utilisation de "systèmes d'annotation" (Renwick & Kraif 2024) : 1) un analyseur syntaxique automatique, 2) un gros modèle de langue, ou LLM (issu d'un apprentissage non-supervisé), et 3) un corpus d'entraînement pour l'entraînement supervisé qui permet l'acquisition du schéma d'annotation (en l'occurrence, parsing et tagging dans le système Universal Dependencies (UD), de Marneffe et al., 2021) et des traits linguistiques spécifiques.

La distance en ce qui concerne la variété linguistique (dont les variétés diachronique et diatopique) ainsi que celle de genre ou de registre a un impact sur la performance. L'attention portée à la qualité du corpus d'entraînement pour l'apprentissage supervisé, néanmoins, peut être étendue aux autres étapes du processus d'annotation agile afin d'optimiser l'injection des caractéristiques du corpus cible dans le système de parsing. Nous avançons deux hypothèses : 1) que l'introduction d'une étape supplémentaire avant l'acquisition du schéma d'annotation peut apporter un gain de performance et 2) que la qualité et échantillonnage des "sous-corpus de finetuning" (post-apprentissage du schéma d'annotation) peut augmenter les performances du système d'annotation lors d'entraînements progressifs.

PRÉSENTATION DES CORPUS

Corpus "Guernesey" (GNS) : transcription du registre Crime I, conservé aux Archives du Tribunal de l'île anglo-normande de Guernesey. La source est un texte juridique (dépositions) du 16ème siècle, en français qui présente une forte variation dialectale (normande) au niveau des graphies et de la grammaire - Corpus cible/sous-corpus de finetuning.
Corpus "Profiterole" (PRFT) : corpus de textes en ancien et moyen français (majoritairement littéraires) du 9ème au 15ème siècle, annotés en Universal Dependencies (Profiterole Old 2@14 et Profiterole Middle 2@14, Prévost et al., 2024) - Corpus de finetuning.


	GNS	PRFT
Tokens	40996	239262
Phrases	1271	20277
Taille moyenne de la phrase	32.25	11.79

CONFIGURATION D'ENTRAÎNEMENT

- Python
 - LLM: google-bert/bert-base-multilingual-cased
 - Parser: kiriauguiller/BertForDeprel
- Interface Web
 - Arborator Grew



MÉTHODES





RÉSULTATS

Pré-finetuning avec les POS

	PRFT	MICLE_noPOS+PRFT	MICLE_gPOS+PRFT	GNS_gPOS+PRFT
LAS	69.72	68.81	73.61	72.84
UAS	76.02	75.37	78.65	78.17
DEPREL	83.75	83.48	86.88	86.07
UPOS	90.33	90.43	93.93	93.59

	PRFT	1578_Terrien_gPOS+PRFT	1487_cronique_gPOS+PRFT	GNS_noPOS+PRFT	GNS_gPOS+PRFT
LAS	69.72	69.06	69.59	69.00	72.84
UAS	76.02	75.16	75.87	75.44	78.17
DEPREL	83.75	83.79	84.13	83.41	86.07
UPOS	90.33	90.81	91.35	90.47	93.59




Résultats combinés

	Sans Pré-finetuning	Avec Pré-finetuning
PRFT	68,07	72,84
ft100_court	72,44	75,09
ft100_moyen	78	79,82
ft100_mix	81,86	83,96
ft100_long	84,06	85,77

BIBLIOGRAPHIE

- DE MARNEFFE, M.-C., MANNING, C. D., NIVRE, J., & ZEMAN, D. (2021). Universal Dependencies. *Computational Linguistics*, 47(2), 255-308. https://doi.org/10.1162/coli_a_00402
- DEVLIN, J., CHANG, M.-W., LEE, K., & TOUTANOVA, K. (2019). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding (No. arXiv:1810.04805). arXiv. <https://doi.org/10.48550/arXiv.1810.04805>
- GROBOL, L., PRÉVOST, S., & CRABBÉ, B. (2021). Is Old French tougher to parse? *Proceedings of the 20th International Workshop on Treebanks and Linguistic Theories (TLT, SyntaxFest 2021)*, 27-34. <https://aclanthology.org/2021.tlt-1.3>
- CRIME I, 1563-1567. Guernesey Greffe (manuscrit).
- GUIBON, G., TELLIER, I., PRÉVOST, S., CONSTANT, M., & GERDES, K. (2015). Analyse syntaxique de l'ancien français: quelles propriétés de la langue influent le plus sur la qualité de l'apprentissage? *TALN 22*. http://www.atala.org/taln_archives/TALN/TALN-2015-long-017.pdf. <https://hal.science/hal-01251006>
- GUILLER, K. (2020). Analyse syntaxique automatique du pidgin-créole du Nigeria à l'aide d'un transformateur (BERT): Méthodes et Résultats. *Mémoire de Master, Sorbonne Nouvelle*.
- MILETIC, A. (2018). Un treebank pour le serbe: *constitution et exploitations* [Phdthesis, Université Toulouse le Mirail - Toulouse II]. <https://theses.hal.science/tel-02639473>
- PENG, Z., GERDES, K., & GUILLER, K. (2022). Pull your treebank up by its own bootstraps. In L. Becerra, B. Favre, C. Gardent, & Y. Parmentier (Éds.), *Journées Jointes des Groupements de Recherche Linguistique Informatique, Formelle et de Terrain (LIFT) et Traitement Automatique des Langues (TAL)* (p. 139-153). CNRS. <https://hal.science/hal-03846834>
- PRÉVOST, S., GROBOL, L., DEHOUCQ, M., LAVRENTIEV, A., & HEIDEN, S. (2024). Profiterole: un corpus morpho-syntaxique et syntaxique de français médiéval. *Corpus*, 25. <https://doi.org/10.4000/corpus.8538>
- RENWICK, A., & KRAIF, O. (2024). Annotation de textes d'états de langue anciens: pour le redéploiement de l'existant. *Corpus*, 25. <https://doi.org/10.4000/corpus.8286>

VALIDATION D'UNE PARTIE DU CORPUS



Processus itératif

REMERCIEMENTS

Nous remercions les Archives du Tribunal de Guernesey (Guernesey Greffe) et l'ancien archiviste de l'île Daryl Ogier pour nous avoir accordé l'accès au manuscrit de Crime I. Nous remercions aussi la Direction du Système d'Information de l'Université de Caen pour avoir soutenu ce travail en fournissant l'accès aux ressources informatiques. Cette recherche a été menée dans le cadre des projets ANR Franco-allemand MICLE (2021-2024) et le projet AUTOMATED (2023-2024) financé par la région Normandie, sous la direction de Professeur Pierre Larrivière (CRISCO, Université de Caen).

CONCLUSION

Les résultats des expériences menées montrent l'impact de la réutilisation des PoS en pré-entraînement pour la performance de modèles de parsing syntaxique ainsi que celui du recours au critère de la longueur de la phrase pour la constitution de corpus d'entraînement dans le cadre d'un processus itératif. Les expériences nous amènent à formuler deux recommandations pour une approche à l'annotation agile de treebanks : 1) Prendre en considération la distance et la proximité du corpus d'entraînement et du corpus cible en ce qui concerne les critères linguistiques (langue et variation diachronique et diatopique, genre etc); 2) tenir compte du statut du corpus existant et du corpus cible en ce qui concerne les traitements et enrichissements effectués (segmentation, annotation etc). Combinant les différents paramètres à de différentes étapes de réentraînement progressif on peut réduire l'intervention humaine et augmenter la qualité et la cohérence des annotations.

Travaux à venir

À la suite de l'étude menée, deux pistes de recherche se dégagent: 1) L'application de la méthode pour un processus de bootstrapping avec des langues différentes; 2) Analyse qualitative des résultats afin d'optimiser l'annotation de certains types de phrases à différentes étapes du traitement.