



**HAL**  
open science

## Automatisation du codage des récits de rêve : une approche basée sur la génération de paraphrases

Gustave Cortal, Alain Finkel, Patrick Paroubek, Lina Ye

### ► To cite this version:

Gustave Cortal, Alain Finkel, Patrick Paroubek, Lina Ye. Automatisation du codage des récits de rêve : une approche basée sur la génération de paraphrases. *Affects, Compagnons Artificiels et Interactions*, Jul 2023, Strasbourg, France. hal-04269424

**HAL Id: hal-04269424**

**<https://hal.science/hal-04269424v1>**

Submitted on 3 Nov 2023

**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.

# Automatisation du codage des récits de rêve : une approche basée sur la génération de paraphrases

Gustave Cortal<sup>1,2</sup>, Alain Finkel<sup>1,4</sup>, Patrick Paroubek<sup>2</sup>, Lina Ye<sup>1,3</sup>

<sup>1</sup> Université Paris-Saclay, ENS Paris-Saclay, CNRS, LMF, 91190, Gif-sur-Yvette, France, gustave.cortal@ens-paris-saclay.fr, alain.finkel@lsv.fr

<sup>2</sup> Université Paris-Saclay, CNRS, Laboratoire Interdisciplinaire des Sciences du Numérique, 91400, Orsay, France, patrick.paroubek@lisn.upsaclay.fr

<sup>3</sup> Université Paris-Saclay, ENS Paris-Saclay, CNRS, CentraleSupélec, 91190, Gif-sur-Yvette, France, Lina.Ye@centralesupelec.fr

<sup>4</sup> Institut Universitaire de France, France



hf.co/gustavecortal/dream-report-best

## Introduction

- La recherche sur les rêves s'appuie sur l'**analyse manuelle et chronophage** de récits de rêve, utilisant généralement le schéma d'annotation de Hall et Van de Castle (HVdC) qui code les personnages (**identité** par rapport au rêveur, **status**, **genre** et **âge**) et leurs émotions.
- Les études précédentes n'utilisent pas les modèles de langues [4] ou n'identifient pas les personnages conjointement avec leurs émotions [1].
- Dans ce travail, nous automatisons le codage des récits en le considérant comme une **tâche de génération de paraphrases**. Grâce à cette approche, il est possible (1) de prédire simultanément les personnages et leurs émotions, (2) d'exploiter la sémantique des codes HVdC en apprenant à les générer en langage naturel.

## Méthodologie

- Nous utilisons **DreamBank** [3], une base de données de 1823 récits de rêve, divisés selon six séries de rêveurs, annotés selon le schéma d'annotation HVdC.
- Pour générer les codes convertis en langage naturel des récits de rêve, entraînement de LaMini-Flan-T5 [6], un **modèle séquence à séquence T5** [5] affiné sur 2.58 millions d'instructions.

**Récit de rêve** : J'ai appelé mon amie sur mon téléphone. Je lui ai demandé si elle aimait un garçon de l'école que je pensais qu'elle n'aimait pas, mais elle a dit "oui". J'étais vraiment *triste*.

**Codes des personnages** : 1FCA, 1MCA. L'amie du rêveur et le garçon de l'école.

**Codes des émotions** : R TS. Le rêveur (R) est triste (TS).

T5

conversion en langage naturel

[PERSONNAGE]status est **individu vivant**, genre est **féminin**, identité est **connue**, âge est **adulte**[PERSONNAGE]status est **individu vivant**, genre est **masculin**, identité est **connue**, âge est **adulte**[ÉMOTION]rêveur est **triste**

## Expérimentations

Étude de l'effet de la **taille des modèles**, des **manières de convertir les codes**, de l'**impact des noms propres** et de l'**augmentation des données cibles**. Le modèle de **RÉFÉRENCE** est LaMini-Flan-T5<sub>348M</sub> utilisant l'ordre de conversion : status, genre, identité et âge. Tous les modèles sont entraînés avec les mêmes hyperparamètres à partir de LaMini-Flan-T5<sub>348M</sub> (sauf pour PETIT et GRAND). Les comparaisons sont effectuées par rapport à **RÉFÉRENCE**. Entraînement sur toutes les séries de rêveurs excepté une considérée comme la série d'évaluation. Les résultats d'évaluation sont moyennés selon les résultats individuels des six séries.

| Modèle                    | status F1   | genre F1     | identité F1 | âge F1      | personnage F1 | émotion F1  |
|---------------------------|-------------|--------------|-------------|-------------|---------------|-------------|
| RÉFÉRENCE                 | 82.87       | 78.02        | 76.17       | 86.21       | 64.74         | 75.13       |
| PETIT                     | 78.35 -4.52 | 72.13 -5.89  | 70.25 -5.92 | 81.66 -4.55 | 56.79 -7.95   | 70.15 -4.98 |
| GRAND                     | 84.51 +1.64 | 80.3 +2.28   | 78.63 +2.46 | 87.29 +1.08 | 67.63 +2.89   | 74.71 -0.42 |
| SANS SÉMANTIQUE           | 71.37 -11.5 | 56.54 -21.48 | 61.0 -15.17 | 90.51 +4.3  | 41.79 -22.95  | 75.79 +0.66 |
| VIRGULE                   | 84.02 +1.15 | 79.84 +1.82  | 77.67 +1.5  | 87.08 +0.87 | 66.69 +1.95   | 73.68 -1.45 |
| MARQUEUR                  | 82.39 -0.48 | 78.45 +0.43  | 76.53 +0.36 | 86.09 -0.12 | 65.44 +0.7    | 74.36 -0.77 |
| GROUPE PREMIER            | 82.33 -0.54 | 77.71 -0.31  | 74.86 -1.31 | 85.61 -0.6  | 63.71 -1.03   | 71.94 -3.19 |
| INDIVIDU PREMIER          | 80.59 -2.28 | 76.14 -1.88  | 74.22 -1.95 | 83.87 -2.34 | 62.67 -2.07   | 67.32 -7.81 |
| ÉMOTION PREMIER           | 83.92 +1.05 | 78.74 +0.72  | 77.06 +0.89 | 87.63 +1.42 | 64.97 +0.23   | 72.03 -3.1  |
| PERSONNAGE SEULEMENT      | 83.09 +0.22 | 78.46 +0.44  | 77.18 +1.01 | 86.76 +0.55 | 65.17 +0.43   | -           |
| ÉMOTION SEULEMENT         | -           | -            | -           | -           | -             | 75.41 +0.28 |
| VALIDATION CROISÉE        | 86.28 +3.41 | 81.9 +3.88   | 79.51 +3.34 | 89.52 +3.31 | 68.64 +3.9    | 76.18 +1.05 |
| SANS NOMS                 | 80.66 -2.21 | 74.32 -3.7   | 74.2 -1.97  | 83.95 -2.26 | 60.93 -3.81   | 73.04 -2.09 |
| AUGMENTATION <sub>3</sub> | 83.28 +0.41 | 79.12 +1.1   | 77.8 +1.63  | 86.43 +0.22 | 66.45 +1.71   | 76.23 +1.1  |
| AUGMENTATION <sub>5</sub> | 85.72 +2.85 | 81.32 +3.3   | 79.64 +3.47 | 89.57 +3.36 | 66.07 +1.33   | 76.44 +1.31 |

## Observations

- Nous obtenons des performances supérieures aux études précédentes ([1] obtient 86 de F1-mesure pour une tâche simplifiée, qui est la classification de l'absence ou la présence de chaque émotion à l'échelle du récit, sans relier les émotions aux personnages qui les vivent).
- Le passage à l'échelle des modèles et l'augmentation des données cibles avec de nouveaux ordres augmentent les performances.
- La prise en compte de la sémantique des personnages améliore fortement la prédiction des personnages, mais n'améliore pas la prédiction des émotions.
- La conversion avec des virgules ne fait pas baisser les performances de prédiction des personnages.
- L'imposition d'un ordre spécifique à la prédiction des personnages baisse les performances.
- La prédiction des personnages, au préalable, améliore la prédiction des émotions.
- Les performances de la validation croisée révèlent que les modèles s'appuient sur des spécificités des séries.
- Les modèles s'appuient sur les noms propres pour prédire les personnages et leurs émotions.

Ces travaux ont bénéficié d'un accès aux moyens de calcul de l'IDRIS au travers de l'allocation de ressources 20XX-AD011014205 attribuée par GENCI.

## Bibliographie

- Bertolini, V. Elce, A. Michalak, G. Bernardi, and J. Weeds. Automatic scoring of dream reports' emotional content with large language models. *arXiv:2302.14828*, 2023.
- Cortal, A. Finkel, P. Paroubek, and L. Ye. Emotion recognition based on psychological components in guided narratives for emotion regulation. In *Proceedings of the 7th Joint SIGHUM Workshop on Computational Linguistics for Cultural Heritage, Social Sciences, Humanities and Literature*, pages 72–81, Dubrovnik, Croatia, May 2023. Association for Computational Linguistics.
- G. W. Domhoff and A. Schneider. Studying dream content using the archive and search engine on DreamBank.net. *Consciousness and Cognition*, 17(4):1238–1247, Dec. 2008.
- V. Elce, G. Handjaras, and G. Bernardi. The language of dreams: Application of linguistics-based approaches for the automated analysis of dream experiences. *Clocks & Sleep*, 3(3):495–514, 2021.
- C. Raffel, N. Shazeer, A. Roberts, K. Lee, S. Narang, M. Matena, Y. Zhou, W. Li, and P. J. Liu. Exploring the limits of transfer learning with a unified text-to-text transformer. *Journal of Machine Learning Research*, 21(140):1–67, 2020.
- M. Wu, A. Waheed, C. Zhang, M. Abdul-Mageed, and A. F. Aji. Lamini-lm: A diverse herd of distilled models from large-scale instructions. *CoRR*, abs/2304.14402, 2023.

## Description des modèles

- Différentes tailles de modèle : PETIT (77M) et GRAND (783M).
- Différentes conversions pour les personnages : SANS SÉMANTIQUE (1FCA), VIRGULE (**individu vivant**, **féminin**, **connue**, **adulte**) et MARQUEUR ([STATUS]**individu vivant**[GENRE]**féminin**[IDENTITE]**connue**[AGE]**adulte**).
- Différents ordres de prédiction des personnages : INDIVIDU PREMIER (prédiction des individus avant les groupes) et GROUPE PREMIER (prédiction des groupes avant les individus).
- Prédiction des émotions avant la prédiction des personnages : ÉMOTION PREMIER.
- Prédiction des émotions seulement : ÉMOTION SEULEMENT. Prédiction des personnages seulement : PERSONNAGE UNIQUEMENT.
- Validation croisée à 5 paquets (80%/20%) : VALIDATION CROISÉE.
- Suppression des noms propres dans les récits : SANS NOMS.
- Augmentation des données cibles avec trois (resp. cinq) ordres tirés aléatoirement pour chaque récit : AUGMENTATION<sub>3</sub> (resp. AUGMENTATION<sub>5</sub>).

## Conclusion et perspectives

- Nous considérons le codage des récits de rêve comme une tâche de génération de paraphrases. Nous avons entraîné des modèles de langue pour prédire, à partir de récits de rêve, les codes des personnages et des émotions convertis en langage naturel. Cette approche obtient des performances supérieures aux études précédentes.
- Via des études d'ablation, nous avons identifié diverses méthodes pouvant améliorer les performances, telles que l'augmentation des données cibles et le passage à l'échelle des modèles. Nous espérons accélérer l'annotation couteuse des récits de rêve, une tâche centrale dans la recherche sur les rêves, en rendant disponible nos modèles entraînés : [hf.co/gustavecortal/dream-report-best](https://hf.co/gustavecortal/dream-report-best).
- Il serait bénéfique d'inclure les rêves non annotés et l'intégralité des annotations du schéma HVdC (les interactions entre les personnages, les objets des récits, etc.), d'utiliser d'autres types de récits narratifs (récits émotionnels [2]), d'ancrer les annotations avec des méthodes d'explicabilité.