

- < iels, historiques et sensibles. S'inquiéter face à des machines capables de produire du langage n'est pas nouveau. Dès 1954, le public s'effrayait de Calliope, invention du cybernéticien A. Ducrocq, tandis que Boris Vian, lui, s'en amusait. Dans une correspondance restée célèbre sous le titre « Un robot-poète ne nous fait pas peur »¹, il écrivait : « Mirandolez, éclaboussez ce robot poète de vos connaissances en cybernétique, expliquez-lui comment il marche et vous l'aurez tout humble à votre merci. »
- < I. Vian, B. (1953/2023). *Un robot poète ne nous fait pas peur* (J.-N. Lafargue, ill., notes). Cormeilles-en-Parisis, France : Ateliers Geeks. ISBN 978-2-9589026-0-5
- < Aujourd'hui, notre rapport aux mots prend une forme nouvelle, incarnée par l'intégration de machines dans nos conversations et l'apparition de vocables qui circulent, se répètent et se diffusent dans nos imaginaires. Parmi eux, un mot en particulier cristallise ces tensions : le mot « arafed ».

UNE SOCIOLINGUISTIQUE ARAFED

- < C'est à l'occasion du Chaos Computer Congress, dans l'une des grandes salles de conférence du centre des congrès de Hambourg, que le terme « arafed » est décrit par deux chercheurs²
- < 2. Liu, T.-C., & Kühr, L.-E. "Arafed Futures - An Artist Dialogue on Chip Storage and AI Accelerationism." 38eme Chaos Computer Congress, Hamburg, Germany, December 28, 2024. qui exposent, à cette occasion, la genèse de ce terme nouveau qui relève davantage d'une hallucination algorithmique que d'un vocable. S'il ressemble à un véritable mot, le terme « arafed » ne renvoie en effet à rien de connu dans la langue anglaise, ni même dans aucune autre langue, bien qu'il apparaisse que le mot « arafed » ait une existence en gallois³. Au cours de leur présentation, les scientifiques démontrent pourtant l'existence de cet assemblage incongru de lettres dans de multiples contextes sur Internet. Son origine, expliquent-ils, réside dans les couches successives qui jalonnent l'évolution des recherches en apprentissage machine et, surtout, dans la succession des monopoles logiciels qui ont forgé ces évolutions.
- < 3. Zair, Nicholas. *The Reflexes of the Proto-Indo-European Laryngeals in Celtic*. Brill, 2012.
- < 4. Li, J., Li, D., Xiong, C., & Hoi, S. "BLIP: Bootstrapping Language-Image Pre-Training for Unified VisionLanguage Understanding and Generation." International Conference on Machine Learning, June 2022, pp. 12888-12900. PMLR. C'est BLIP⁴, un modèle d'intelligence artificielle spécialisé dans la génération de légendes d'images, qui aurait, le premier, fait apparaître le mot « arafed » en se basant sur l'ensemble de données (*dataset*) constitué d'images légendées qu'est COCO⁵. Utilisé massivement parce qu'accessible gratuitement et facilement dès 2014, COCO contient des textes en anglais qui décrivent des images. Ces légendes commencent, dans la très grande majorité des cas, par les articles indéfinis « A » et «
- < 5. Lin, T. Y., Maire, M., Belongie, S., Hays, J., Perona, P., Ramanan, D., & Zitnick, C. L. "Microsoft COCO: Common Objects in Context." In Computer Vision-ECCV 2014: 13th European Conference, Zurich, Switzerland, September 6-12, 2014,

An » : *An apple on a table, a brown teddy bear with a blue bib on that says baby*. La surreprésentation de ces articles indéfinis en début de phrase a mené BLIP à produire, au cours de son entraînement, trois jetons qui se trouvent à leurs tours surreprésentés dans ses productions : a, ##raf et ##ed. Ayant ainsi enregistré qu’une phrase commence généralement par le jeton « a » et que les deux autres jetons suivent généralement cette lettre, les légendes produites par BLIP débutent alors régulièrement par ce terme artificiel qu’est « arafed ».

Les résultats générés par BLIP ont ensuite nourri de nouveaux modèles d’IA qui sont par la suite utilisés dans la recherche et produisent à leur tour des données qui vont encore nourrir de nouveaux modèles. Par sa présence dans des contextes variés, le nouveau mot se trouve aspiré par des processus d’extraction de données en ligne et se propage encore davantage et continue d’être contextualisé sans qu’un sens ou une définition claire n’apparaissent. « *Arafed* » est ainsi un mot vide, un signe sans signification, un vocable stérile mais qui ne cesse d’être intégré dans des contextes linguistiques toujours nouveaux. Dans le réseau informatique mondialisé, il se diffuse à la façon d’un virus artificiel et culturel, un artefact linguistique ayant muté de lui-même, adapté aux organismes automatiques et auquel nous sommes aussi exposés.

CONTAMINATION DE LA LANGUE

La prolifération d’un artefact linguistique tel que « arafed » apparaît comme un cas d’école manifeste de l’intégration grandissante des machines dans nos conversations et de leur capacité d’action sociolinguistique. Les LLM animent aujourd’hui de très nombreux programmes informatiques, des *bots*, qui lisent et écrivent sur internet avec des objectifs allant de l’exploration de données (*data mining*) à la diffusion de propagande politique. De X à Instagram en passant par Reddit, les réseaux sociaux pullulent de ces *bots* qui produisent textes, images et sons pour nous encourager à interagir avec eux et entretenir ces interactions. Sur des plateformes comme Medium et Quora, la quantité de contenus générés par des algorithmes d’intelligence artificielle a augmenté de manière significative ces dernières années pour atteindre jusqu’à 40 %

de ce qui y est posté⁶. Un pourcentage qui serait équivalent à celui des productions générées par IA sur l’ensemble du réseau internet⁷.

L’usage des outils de génération de texte, en particulier, ne se limite pas à ces plateformes d’interactions entre humains. Le monde de la recherche académique, dont l’un des mottos réside dans la formule « *publish or*

6. Sun, Z., Zhang, Z., Shen, X., et al. (2025). *Are we in the AI-generated text world already? Quantifying and monitoring AIGT on social media* (preprint). arXiv. <https://arxiv.org/abs/2412.18148>

7. Spennemann, D. H. R. (2025). *Delving into: The quantification of AI-generated content on the internet (synthetic data)* (Preprint). arXiv. <https://doi.org/10.48550/arXiv.2504.08755>