

> deuxième méthode consistant à étudier les lemmes, intéressante en soi, s'est révélée un peu moins fiable (93%) lors de notre phase de calibration que l'étude des mots.

Étudier le vocabulaire dans son intégralité peut toutefois générer certains biais. Notre emploi de certains mots dépend bien sûr de qui nous sommes, mais aussi de ce dont nous parlons. Si l'on étudie des textes d'auteurs au style proche, les thèmes abordés peuvent engendrer plus de variations dans le vocabulaire que les différences de style des écrivains. Or la langue du théâtre classique est extrêmement codifiée, en particulier pour les pièces écrites en vers. Dans notre cas, la crainte de variations liées aux sujets n'est donc pas infondée.


Deux solutions contraires sont alors envisageables. On peut choisir de ne s'intéresser qu'aux mots choisis avec le plus grand soin : ceux qui sont placés à la rime. Ils demandent une réflexion particulière et sont souvent très révélateurs de l'auteur d'un texte. Cette méthode axée sur les rimes a donné sur notre corpus test des résultats corrects à 87%. À l'inverse, on peut se focaliser sur les mots choisis le plus inconsciemment. Les *mots outils* («et», «de», «or», «mais»...) sont peu susceptibles de varier en fonction du sujet traité et ils sont particulièrement fréquents, ce qui permet d'obtenir des statistiques fiables. Ils ont longtemps été considérés comme l'indice le plus pertinent pour déterminer l'auteur d'un texte et, pour notre corpus test, les résultats étaient corrects à 93%.

ORDRE DES ÉLÉMENTS DANS LES PHRASES, SYNTAXE

Une cinquième méthode s'intéresse à l'ordre des éléments d'une phrase. Les phrases «Belle marquise, vos beaux yeux me font mourir d'amour» et «D'amour mourir me font, belle Marquise, vos beaux yeux» comportent exactement les mêmes mots, les mêmes lemmes, les mêmes mots outils. Les méthodes précédentes les considèrent donc comme parfaitement identiques. Pourtant, il est indéniable que le style diffère notablement entre ces deux tournures.

Pour conserver de l'information sur l'enchaînement des mots, on peut considérer le texte non comme un «sac de mots», mais comme un sac de «*n*-grammes de caractères». Cette dernière expression désigne simplement un enchaînement d'un nombre *n* de caractères. Supposons que l'on décompose les phrases précédentes en 5-grammes de caractères. En notant _ chaque espace, nous obtiendrions pour la première: Belle_ elle_, lle_m, le_ma, e_mar, _marq, etc. Et pour la seconde, nous aurions: D'amo_, amou_, mour_, etc. On réplique alors nos calculs en travaillant non sur des mots, mais sur ce type de séquences.

Dernière option explorée: la syntaxe des auteurs. Écrire des phrases uniquement selon



une structure simple ou, à l'inverse, selon des tournures particulièrement alambiquées, constitue un trait distinctif du style d'une personne – l'un des plus fiables avec les mots outils. Pour mesurer ces variations, on annote la nature grammaticale de chaque mot du texte, grâce à une intelligence artificielle spécialement entraînée sur des pièces de l'époque. Puis on étudie à quelle fréquence des successions de trois natures grammaticales (du type «*pronom personnel / verbe conjugué / nom commun*») apparaissent.

SI QUATRE ET QUATRE SONT HUIT, CORNEILLE N'A PAS ÉCRIT MOLIÈRE

Nous avons appliqué ces six méthodes à un ensemble de comédies en vers écrites par Molière, Corneille et leurs contemporains. L'analyse principale a porté sur 37 pièces de Pierre Corneille, son frère Thomas Corneille, Molière, Jean de Rotrou et Paul Scarron. En suivant chacune d'entre elles, toutes les pièces de Molière ont été considérées par nos algorithmes comme celles d'un même auteur, et clairement distinguées des pièces de Corneille – alors que d'autres auteurs, comme Scarron, semblent même plus proches stylistiquement de Molière.

Il paraît donc plus qu'improbable que Molière ait servi de prête-nom à Corneille ou à d'autres dramaturges célèbres de son temps. Faute de génie pouvant le détrôner dans les cœurs et les esprits, le français devrait donc rester encore pour quelque temps «la langue de Molière». ■

Cet arbre de parenté correspond aux résultats de la classification des textes en fonction de l'usage de mots outils (en vert les pièces de Molière, en rouge celles de Pierre Corneille, en rose Thomas Corneille, en jaune Paul Scarron, en bleu Jean de Rotrou). On constate que l'algorithme a parfaitement regroupé les pièces selon leur auteur putatif.

BIBLIOGRAPHIE

F. Cafiero et J.-B. Camps, **Why Molière most likely did write his plays**, *Science Advances*, vol. 5, article eaax548, 2019.

C. Labbé et D. Labbé, **Inter-textual distance and authorship attribution. Corneille and Molière**, *Journal of Quantitative Linguistics*, vol. 8(3), pp. 213-231, 2010.

D. Labbé, **Si deux et deux sont quatre, Molière n'a pas écrit Dom Juan**, Max Milo, 2009.

H. Wouters et C. de Ville de Goyet, **Molière ou l'auteur imaginaire ?**, Complexe, 1990.