

Auto-similarité de formes pour la discrimination des styles d'écriture des manuscrits médiévaux

Ikram Moalla ⁽¹⁾⁽²⁾, Franck LeBourgeois ⁽¹⁾, Hubert Emptoz ⁽¹⁾, Adel M. Alimi ⁽²⁾

⁽¹⁾Laboratoire d'InfoRmatique en Image et Systèmes d'information

⁽²⁾REsearch Group on Intelligent Machines

Email: ikram.moalla@ieee.org

Résumé

Ce article présente notre contribution à la discrimination des écritures des manuscrits médiévaux pour la Paléographie. Nous cherchons à retrouver les classifications construites par les paléographes sur la généalogie des écritures et de leurs évolutions durant le moyen âge. Ce travail devrait contribuer à confirmer objectivement les travaux des paléographes et tester les possibilités de l'analyse des images dans la discrimination des écritures médiévales. Nous avons choisi de caractériser statistiquement les formes des écritures sans segmenter l'image ni sa structure physique. Nous utiliserons principalement la notion de cooccurrence comme mesure d'auto-similarité. Les premiers résultats obtenus semblent confirmer les classifications données par les experts.

Mots clefs

Documents anciens, paléographie, reconnaissance de styles, autosimilarité, matrice de cooccurrence.

1 Introduction

L'Analyse d'Images de Documents est un domaine de recherche particulier qui se situe entre l'analyse des images, la reconnaissance des formes et les sciences humaines, et en particulier la science de l'histoire des textes. Cette discipline connaît actuellement une expansion avec l'avènement de la numérisation des fonds anciens du patrimoine notamment dans les bibliothèques et les archives nationales, départementales, municipales etc. Dans le domaine de la recherche sur les textes anciens, la philologie (science qui s'intéresse au problème de datation, de localisation et d'édition de texte), étudie autant la manière dont les textes sont écrits ou imprimés que leurs contenus. L'analyse du style personnel de l'écriture permet de différencier les différents scribes d'un manuscrit ou d'authentifier un document alors que le style général de l'écriture et de la mise en page permet des applications innovantes en paléographie, une des sciences sur laquelle repose la philologie.

L'analyse des styles d'écritures apporte des informations complémentaires aux contenus des textes que l'on considère comme étant des méta-données. La manière dont le texte est représenté constitue une information introduite de façon consciente ou inconsciente par l'auteur ou le scribe qui peut permettre par exemple, de dater, d'authentifier ou d'indexer un document.

La présentation d'un document imprimé se manifeste par sa structure physique et la typographie des caractères

(polices, taille, déclinaison, fonte) alors que la présentation d'un manuscrit ancien recèle d'autres niveaux d'interprétation comme le style personnel d'écriture du scribe, la calligraphie utilisée et la mise en page du document. Ces derniers peuvent être représentatifs d'une époque et d'un lieu et servir à la datation et la transcription.

L'objet de ce travail consiste à apporter une première contribution méthodologique et applicative à l'analyse automatique des mises en forme des documents, au service de la recherche en histoire des textes. Nous nous intéresserons plus précisément aux manuscrits anciens latins du Moyen Age, période qui précède la Renaissance et l'avènement de l'imprimerie. La définition du style est multiple et complexe. Nous nous concentrerons sur une approche visuelle et perceptive du style des écritures, celle que l'on pourra qualifier et étudier avec des outils d'analyse d'images. La principale difficulté consiste à discerner le style d'une écriture manuscrite qui soit relié à la période historique et/ou une localisation géographique indépendamment du style personnel du scribe.

2 Définitions et généralités

- **La philologie classique** : elle a pour objectif d'étudier les textes et les langues anciennes, leurs grammaires, l'histoire et la phonétique des mots pour l'enseignement et la compréhension des textes anciens. La philologie se base principalement sur le contenu des textes et non sur leur forme. Cette science concerne aussi bien les manuscrits que les imprimés.

- **La paléographie** : c'est l'étude de l'écriture et de la forme des caractères, de l'évolution des manières d'écrire. La science paléographique est une discipline complémentaire de la philologie pour les documents manuscrits car elle étudie les écritures manuscrites anciennes et leurs évolutions alors que la philologie classique étudie le contenu des textes, des langues et de leurs évolutions.

Les objectifs de la science paléographique sont principalement l'enseignement du déchiffrement correct des écritures anciennes et l'étude de l'histoire de l'évolution de l'écriture.

- **Les écritures latines et leurs évolutions** : depuis la fin du I^{er} siècle avant J.-C, les écritures se sont transformées selon les usages mais le fonctionnement est resté le même. Du VIII^e au XII^e siècle, la caroline règne sur l'Occident. Elle évolue vers des formes anguleuses

pour donner naissance à l'écriture gothique. Le passage d'une écriture à l'autre ne s'est pas toujours effectué de façon radicale mais par évolution lente et progressive. Ce qui explique qu'il est difficile d'identifier catégoriquement une écriture donnée. Par exemple on observe des textes en écriture *caroline* qui contiennent déjà des attributs de l'écriture *gothique*. Le paléographe doit alors quantifier précisément la part de mélange des familles d'écritures. C'est le cas par exemple de la classe d'écriture *prégothique* qui est intermédiaire entre l'écriture caroline et l'écriture gothique (Figure1) ou encore l'écriture *Hybrida* entre la *cursiva* et la *textualis* (Figure2).

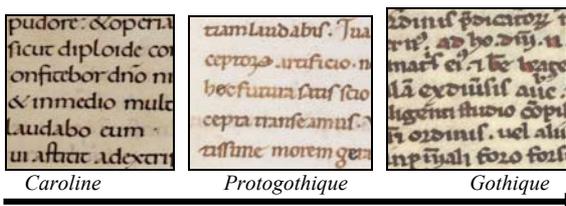


Figure1 - Evolution progressive de la caroline à la prégothique puis à la gothique.

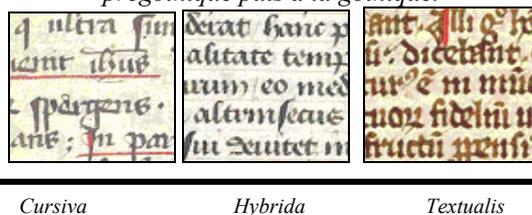


Figure2 - Evolution progressive de la Gothique cursiva à la gothique hybrida puis à la gothique textualis.

La diversification des familles d'écritures en Europe s'accélère jusqu'à la Renaissance et voit se développer des sous-familles d'écritures à l'intérieur de chaque grande famille de gothiques. Ainsi on peut distinguer plusieurs sous-familles de *gothique cursiva* représentées dans la Figure3 qui traduisent la précision de l'exécution de cette écriture. De même, la Figure4 montre plusieurs sous-familles de *gothique textualis*.

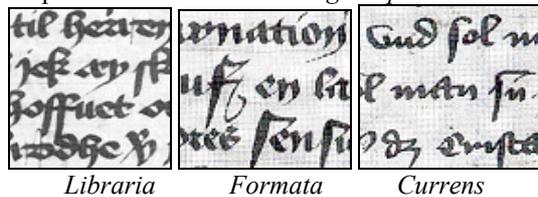


Figure3 - Exemples de sous-familles de styles cursiva entre le VIII^{ème} et le XVI^{ème} siècle [1]



Figure4 - Exemples de sous-familles de styles textualis entre le VIII^{ème} et le XVI^{ème} siècle

La Figure5 montre la variabilité des écritures à l'intérieur d'une même sous-famille comme la classe *gothique textualis*

rotunda. Elle illustre la difficulté en terme d'analyse d'images à définir des descripteurs de formes pour trouver une homogénéité entre les différents échantillons d'une même écriture. La paléographie est, de ce fait, une science complexe.




Figure5 - Exemples d'images de textes représentant la variation intra-classe du style gothique textualis rotunda [BGB]

De plus, il existe une diversité de classifications en familles et sous-familles d'écritures qui dépendent des paléographes. Un style d'écriture peut être étiqueté différemment par deux paléographes différents. La paléographie est une science subjective puisqu'elle n'a pas de règles précises pour trouver le style exacte d'une écriture. De plus, en examinant un style, le paléographe peut créer une confusion entre ses connaissances *a priori* ainsi que ses connaissances paléographiques sur les styles.

Trouver un système pour assister les paléographe est donc loin d'être un travail simple.

3 Etat de l'art

Les travaux sur la caractérisation des écritures ont été réalisés pour des applications différentes de celle de la paléographie comme la vérification et l'authentification de scripteurs, la pré-classification des écritures en terme de lisibilité pour une meilleure reconnaissance dans le tri automatique du courrier et des chèques. Toutes ces études sont connexes à notre problématique mais ces contributions ne sont pas toutes directement ré-exploitable pour l'étude paléographique. La rose des directions binaire a été utilisée par [2] pour identifier les formes différentes d'écritures en vue de leur reconnaissance. L'analyse fractale mesure les autosimilarités présentes dans une image, c'est une bonne mesure du style d'un scripteur qui peut servir à classer les écritures suivant leur lisibilité [3]. L'indice fractal est aussi susceptible de caractériser les différents alphabets dans les textes imprimés. [4] caractérise différents styles de texte par des mesures de complexité des formes, de lisibilité et de compacité indépendamment de l'alphabet utilisé. Enfin nous signalons d'autres travaux susceptibles d'être réutilisés pour la reconnaissance des écritures médiévales comme la reconnaissance des scripts (des mots dans un alphabet particulier) dans les documents multilingues. Ces travaux utilisent la similarité de

graphèmes [5], la texture [6], ou l'analyse de profil de projection [7] etc.

Du point de vue analytique, nous distinguons deux approches complémentaires pour le traitement des styles d'écritures:

- **Approche locale** : elle consiste à reproduire le travail des paléographes, en cherchant à établir des similarités visuelles entre des écritures à partir de lettres très particulières caractéristiques d'une écriture (exemples : 'r', 's', 'e', 'a'). En effet certaines lettres spécifiques sont utilisées par les paléographes comme des marqueurs porteurs d'information nécessaire à la reconnaissance d'une écriture. Ces lettres doivent être prises au milieu des mots car leurs graphies changent suivant le scripteur quand elles sont situées en début ou à la fin des mots [8] [9].

- **Approche globale** : on ne cherche pas à reproduire le travail des paléographes, mais à utiliser une méthode plus appropriée à l'analyse automatique d'images. Elle consiste à analyser statistiquement l'image entière d'un manuscrit, sans segmenter l'image ni segmenter les lignes de texte, les mots ou les caractères et à trouver des descripteurs de formes capables de distinguer les différentes écritures.

Le SPI pour *System for Paleographic Inspections* [8], constitue la seule tentative pour la réalisation d'un système d'assistance automatique en paléographie [9] en utilisant une approche locale. Elle consiste à isoler manuellement les caractères représentatifs d'une écriture et à les comparer à des caractères de référence contenus dans une base paléographique étiquetée manuellement. La comparaison utilise la distance tangente et la règle des *k-plus proches voisins*. Les conditions expérimentales ne permettent pas d'évaluer le système avec objectivité. De plus, aucun détail n'a été donné concernant les styles utilisés. Et le manque de résultats chiffrés nous empêche de juger la qualité de ce travail.

4 Méthode proposée

Notre objectif est le développement de méthodologies et d'outils d'analyse d'images pour assister les historiens dans la classification et la datation des manuscrits anciens latins à partir de la reconnaissance des écritures. En effet, chaque époque de l'histoire a été marquée par un ou plusieurs types d'écritures. Ainsi, la connaissance de l'écriture d'un document permet de connaître sa date et/ou son origine géographique. Notre domaine d'étude couvre les écritures anciennes latines du VIII^{ème} siècle jusqu'à la Renaissance au XVI^{ème} siècle. L'étude des écritures latines antérieures au VIII^{ème} siècle comme l'*onciale* ou l'écriture *cursiva* n'a pas un réel intérêt pour les paléographes. En revanche l'assistance à l'expertise des écritures médiévales est très utile à partir du XII^{ème} siècle. Il s'agit

de différencier les grandes familles d'écritures comme le montre la répartition de la Figure 6.

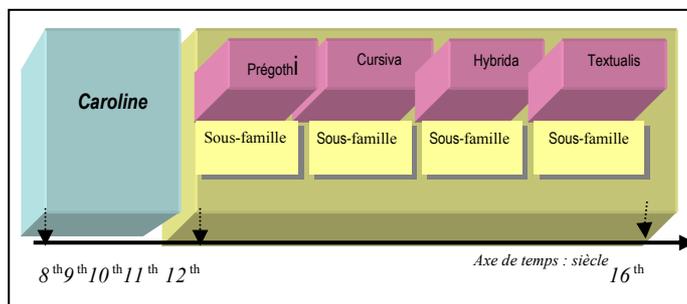


Figure 6 - Répartition des différentes familles et sous-familles de styles latin entre le 8^{ème} et le 16^{ème} siècle

Dans un premier temps, notre travail s'est focalisé sur l'extraction de caractéristiques suffisamment discriminantes pour pouvoir différencier le plus grand nombre d'écritures latines possibles. Cette étude a permis d'étudier la faisabilité d'un système d'analyse automatique des images à l'usage des paléographes.

Dans un deuxième temps nous avons affiné l'étude en tentant progressivement de discriminer les deux grandes familles de styles d'écritures latines : *caroline*, *gothique* puis les sous-familles de *gothiques* : *cursiva*, *hybrida* et *textualis* et enfin les sous-familles telles que la *rotunda*, la *quadrata*, la *semi-quadrata* et la *prescissa* pour la *textualis*; la *formata*, la *libraria* et la *currens* pour la *gothique cursiva*. Cette analyse a pour objectif à la fois d'augmenter la précision de la discrimination entre les écritures et d'étudier plus en détail les confusions possibles entre les écritures proches.

4.1 Des conditions difficiles

Le développement d'un système d'assistance à l'expertise des manuscrits anciens est une tâche rendue difficile par de nombreux facteurs la complexité des formes d'écritures (Figure 2, 3, 4), la grande variabilité des écritures d'une même classe (Figure 5), l'existence d'écritures hybrides issues de mélanges de plusieurs écritures (Figure 1, 2), la faible qualité de conservation des manuscrits, le vieillissement des supports et des encres (Figure 7), l'enchevêtrement des lignes et des mots (Figure 8), la présence de notes dans la marge et/ou entre les lignes (Figure 9) et la grande variabilité de la qualité des images de différentes origines : certaines images en couleurs proviennent d'une numérisation de qualité, d'autres images de mauvaise qualité sont issues de la numérisation de livres ou de microfilms, en niveaux de gris. La plupart des images présentent des dégradations dues à une trop forte compression (JPEG). Enfin nos échantillons ont été numérisés avec des résolutions toutes différentes (Figure 10).

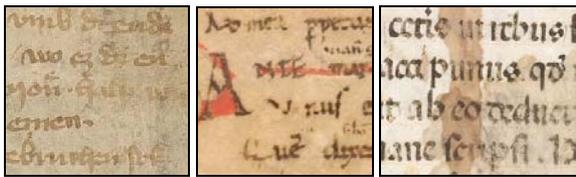


Figure7 - Vieillesse de l'encre [BGB]

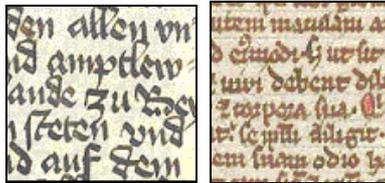


Figure8 - Enchevêtrement des lignes [BGB]



Figure9 - Ecriture à la marge et/ou entre les lignes [BGB]

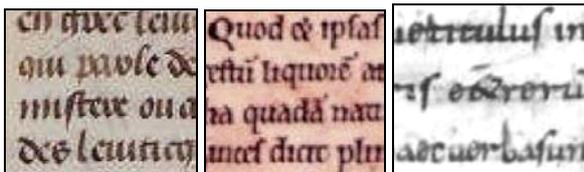


Figure10 - Dégradations dues à une mauvaise qualité de prise d'image

Dans ce contexte difficile, nous allons analyser directement l'image en niveaux de gris sans filtrage préalable, sans restauration et sans correction géométrique. Ce choix nous prive d'une grande partie des travaux réutilisables et en particulier tous ceux basés sur la segmentation.

4.2 Notre approche

Nous avons donc choisi l'approche globale du fait des conditions difficiles décrites précédemment. Nous avons cherché des descripteurs de formes capables de distinguer les différentes écritures. Ces mesures globales devraient être indépendantes du contenu du texte, du style personnel du scribe, de la langue utilisée, des lettres employées et de leurs fréquences. L'analyse globale s'affranchit des formes fantaisistes des caractères de début et de fin de mots, ainsi que de l'éventuelle présence d'ornements incrustés dans le texte. Ces avantages sont très précieux pour pouvoir analyser une grande quantité d'images de manuscrits de qualité très variable ainsi que les manuscrits dégradés.

Sans travaux antérieurs dans le domaine de l'analyse globale des écritures manuscrites médiévales, nous avons expertisé des descripteurs qui vérifient un certain nombre de conditions. Pour vérifier que l'on caractérise l'écriture et non le contenu du texte lui-même ni le style personnel

du scribe, l'inclinaison du texte, sa mise en page ou sa taille, les descripteurs de formes doivent être robustes, donc doivent pouvoir se calculer sans segmentation préalable des images et doivent résister au *changement de luminosité* et de contraste et au changement de résolution. Les descripteurs doivent être également *invariants au scribe*, aux *contenus des textes*, à la *taille de l'échantillon* de texte, au *changement d'échelle*, au *changement de ratio* et à la *rotation*.

4.3 Application de la cooccurrence sur les écritures médiévales

La cooccurrence a été largement utilisée comme moyen de caractériser une texture en analyse d'images. Les images de documents présentent aussi des textures par la répétition des motifs réguliers des caractères, des mots et des lignes de texte. Cependant nous ne voulons pas mesurer la mise en page ni décrire la gestion des espaces (densité des traits, interlignes...). Nous cherchons plutôt à caractériser les écritures. Nous allons utiliser la cooccurrence de façon à ne mesurer que les variations des formes elles-mêmes et non les variations des formes entre elles. Pour cela nous devons effectuer de très faibles déplacements et nous assurer que l'on ne compare pas verticalement une ligne de texte avec les lignes adjacentes ou recouvrir horizontalement une lettre avec les lettres voisines. Par conséquent nous avons calculé les cooccurrences sur des images qui ont été normalisées manuellement pour qu'elles présentent toutes un corps de texte de 30 pixels de hauteur et nous avons limité les déplacements à moins de la moitié de la taille du corps des lignes de texte. La normalisation de l'échelle des images par rapport au corps des textes est aussi nécessaire pour ne pas influencer la comparaison des observations sur des tailles de texte trop différentes (contrairement aux paléographes qui travaillent sur des images à l'échelle 1:1).

La cooccurrence se généralise aux images en niveaux de gris, et donne des matrices de taille $N_g \times N_g$ avec N_g le nombre de niveaux de gris de l'image pour chaque coordonnées trigonométrique (ρ, θ) .

$$Cooccurrence = \frac{1}{N} \sum_{x,y} I(x,y) \cap I(x+dx, y+dy) = \frac{1}{N} [M_{i,j}]_{i,j=0..N_g-1}$$

(Avec $I(x,y)$: image d'origine, $I(x+dx, y+dy)$: image tradlatée et $M_{i,j}$: matrice de cooccurrence)

Nous avons choisi d'utiliser initialement un maximum d'information et de prendre un pas très fin pour les valeurs de ρ et de θ . Nous avons utilisé 16 directions ($\theta \in [0..15]$) et 15 déplacements possibles ($\rho \in [1..15]$) soit 16x15 matrices au maximum. Les valeurs des pixels ont été ramenées de 256 à 16 valeurs différentes. Une subdivision plus fine des valeurs de gris n'apporte pas d'information complémentaire pour des images de manuscrits qui sont constituées essentiellement de traits. Chaque écriture décrit un signature différente suivant les valeurs de ρ et θ (Figure11).

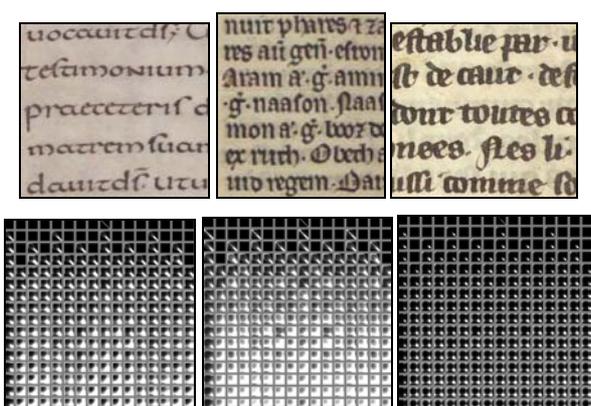


Figure 11 - Matrices de cooccurrences relatives à quelques exemples de planches de styles différents

4.4 Analyse des descripteurs

Nous analysons les données des n observations décrites par p variables avec p égal au nombre de matrices de cooccurrence non nulles suivant ρ et θ , multiplié par un nombre de descripteurs issus des travaux de Haralick [10] que nous présentons ci-dessous. Soit :

$$P(i, j) = \frac{M(i, j)}{\sum_{i=0}^{i < Ng} \sum_{j=0}^{j < Ng} M(i, j)}$$

f_1	Second Moment Angulaire ou énergie	$f_1 = \sum_{i=0}^{i < Ng} \sum_{j=0}^{j < Ng} P(i, j)^2$	Cette caractéristiques mesure l'homogénéité, et détecte le degré de dispersion d'une texture.
f_2	Moment de la Différence de l'élément	$f_2 = \sum_{k=0}^{k < Ng} k^2 \times P_{x-y}(k)$	Cet indice mesure le degré de contraste ou de variation locale présent dans une image.
f_3	Corrélation	$f_3 = \frac{\sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i-j) \times (j-i) \times P(i, j)}{\sigma_x \times \sigma_y}$	Cet indice décrit les corrélations entre les lignes et les colonnes de la matrice de cooccurrence et mesure de ce fait les dépendances linéaires entre les niveaux de gris dans une image.
f_4	Variance	$f_4 = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} (i-j)^2 P(i, j)$	Une forte valeur caractérise une texture fine.
f_5	Moment de la Différence Inverse	$f_5 = \sum_{i=1}^{Ng} \sum_{j=1}^{Ng} \frac{P(i, j)}{1 + i - j }$	Une forte valeur indique que les éléments texturaux sont de grande taille.
f_6	Moyenne des sommes	$f_6 = \sum_{k=0}^{k < 2Ng-1} k \times P_{x+y}(k)$	Moyenne des projections P_{x+y}
f_7	Variance des sommes	$f_7 = \sum_{k=0}^{k < 2Ng-1} (k - f_6)^2 \times P_{x+y}(k)$	Variance des projections P_{x+y}
f_8	Entropie des sommes	$f_8 = - \sum_{k=0}^{k < 2Ng-1} P_{x+y}(k) \times \log(P_{x+y}(k))$	Entropie de P_{x+y}
f_9	Entropie	$f_9 = - \sum_{i=0}^{i < Ng} \sum_{j=0}^{j < Ng} P(i, j) \times \log(P(i, j))$	C'est un indicateur de désordre.
f_{10}	Variance des Différences	$f_{10} = \sum_{k=0}^{k < Ng} (k - m_{x-y})^2 \times P_{x-y}(k)$	Variance de P_{x-y} avec $m_{x-y} = \sum_{k=0}^{k < Ng} k \times P_{x-y}(k)$
f_{11}	Entropie des Différences	$f_{11} = - \sum_{k=0}^{k < Ng} P_{x-y}(k) \times \log(P_{x-y}(k))$	Entropie de P_{x-y}
f_{12}	Entropy Measure	$f_{12} = \frac{HXY - HXY1}{\max\{HX, HY\}}$ $HXY = f_9$	$HX = - \sum_{i=0}^{i < Ng} P_x(i) \times \log(P_x(i))$ $HY = - \sum_{j=0}^{j < Ng} P_y(j) \times \log(P_y(j))$ $HXY1 = - \sum_{i=0}^{i < Ng} \sum_{j=0}^{j < Ng} P(i, j) \times \log(P(i) \times P_y(j))$

Avec $P_x(i) = \sum_{j=0}^{j < Ng} P(i, j)$, $P_y(j) = \sum_{i=0}^{i < Ng} P(i, j)$, $P_{x+y}(k) = \sum_{i < Ng} \sum_{j < Ng} P(i, j)$,

$P_{x-y}(k) = \sum_{i < Ng} \sum_{j < Ng} P(i, j)$ sont respectivement les projections selon

les axes horizontal, vertical et oblique de la matrice normalisée P .

Nous obtenons donc n points dans \mathbb{R}^p avec $p=216 \times 12$, n étant le nombre d'images d'écritures observées. L'espace des caractéristiques est bien trop grand par rapport au nombre d'observations n pour un classifieur. Nous pensons qu'il existe parmi les $p=2592$ variables, un nombre limité de facteurs qui peuvent faire apparaître les classes d'écritures. Un travail manuel de sélection des caractéristiques serait trop long et fastidieux. Il est donc nécessaire de réduire le nombre de descripteurs par une analyse statistique de la variance. Cette analyse nous a permis de trouver les descripteurs corrélés et donner un nombre réduit de facteurs qui sont des combinaisons linéaires des p variables d'origine. L'analyse des données est encore l'occasion de mener une analyse canonique de la proximité des classes puis comparer les résultats avec ceux des experts.

5 Analyse des résultats

L'analyse discriminante (AD) a permis de trouver les vecteurs permettant de projeter toutes les observations définies dans un espace à p dimensions, sur un plan qui discrimine une grande majorité de classes (Figure 12).

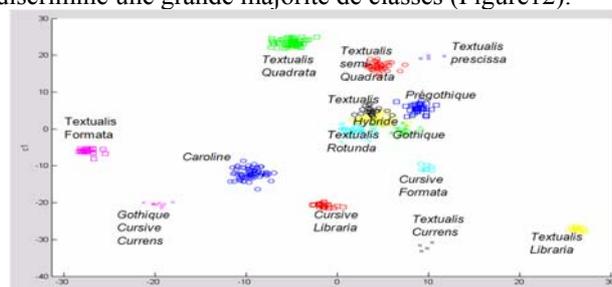


Figure 12 - Résultats de l'AD pour les 15 classes

Le fait d'obtenir une majorité de classes séparées signifie qu'il existe des combinaisons linéaires de descripteurs qui peuvent résoudre notre problème de discrimination des écritures médiévales. Nous avons obtenu une bonne dispersion des classes : 1. Caroline, 3. Cursiva Libraria, 4. Cursiva Formata, 5. Cursiva Currens, 8. Textualis prescissa, 9. Textualis Quadrata, 10. Textualis Semi-Quadrata, 12. Textualis Formata, 13. Textualis Libraria et 14. Textualis Currens. La matrice de confusion a donné des taux de discrimination assez satisfaisants (de 48% pour la classe 12. Textualis Formata à 100% pour la classe 5. Cursiva Formata) pour les types d'écritures relatifs à ces classes. Les exceptions concernent les classes 2. Gothique et 7. Textualis non considérées comme de vraies familles ainsi que la 8. Textualis Prescissa et la 14. Textualis Currens qui ne sont pas significatives vu leurs nombres très réduits de représentants.

Quant aux 2. Gothique, 6. Hybrida, 7. Textualis, 11. Textualis Rotunda et 15. Prègothique, elles sont les moins bien séparées par l'AD et cela a entraîné des taux de

confusions assez importants entre ces classes. Nos résultats montrent qu'il existe de véritables classes paléographiques au sens de la reconnaissance des formes. Certaines classes sont nettement séparées et forment de véritables familles bien identifiées. Ce sont les familles des écritures les plus détaillées (8. *Textualis Prescissa*, 9. *Textualis Quadrata*, 10. *Textualis Semi-Quadrata*, 12. *Textualis Formata*, 13. *Textualis Libraria*, 14. *Textualis Currens*) et les familles 1. *Caroline*, 3. *Gothique cursiva* ; elles sont nettement séparées des autres classes. Les quatre classes confuses qui sont la 2. *Gothique*, la 7. *Textualis*, la 15. *Prégothique* et la 6. *Hybrida* ne constituent pas de véritables classes d'écritures homogènes au sens de l'analyse d'images. Nous pensons (sous réserve que ces résultats soient validés par les experts) que les classes 2. *Gothique* et 7. *Textualis* contiennent des écritures non suffisamment renseignées par les paléographes et qu'il est donc normal que ces classes génériques soient confuses avec les sous-familles respectives. Enfin nous supposons que les écritures prégothiques sont des écritures transitoires entre les écritures *carolines* et *gothiques*. En omettant les classes confuses les plus problématiques qui sont la 2. *Gothique*, la 7. *Textualis*, la 15. *Prégothique* et la 6. *Hybrida*, nous obtenons 11 classes correctement séparées.

Tableau - Matrice de confusion obtenue par analyse discriminante sur 11 classes en utilisant les 12 caractéristiques de Haralick (f1 à f12)

	1	2	3	4	5	6	7	8	9	10	11	%correct
1. <i>Caroline</i>	55	1	0	1	0	0	0	5	0	0	0	91%
2. <i>Cursive Libraria</i>	0	18	1	0	0	0	0	0	3	0	0	82%
3. <i>Cursive Formata</i>	0	1	5	0	0	1	0	0	0	0	0	71%
4. <i>Cursive Currens</i>	0	1	0	8	0	0	0	0	0	0	0	89%
5. <i>Textualis Prescissa</i>	0	0	0	0	2	0	0	2	0	0	0	50%
6. <i>Textualis Quadrata</i>	0	0	0	0	0	49	1	4	2	0	0	88%
7. <i>Textualis Semi-Quadrata</i>	0	0	0	0	0	4	26	9	2	0	0	63%
8. <i>Textualis Rotunda</i>	1	1	0	0	0	5	3	64	1	0	0	85%
9. <i>Textualis Formata</i>	0	1	0	1	0	2	0	1	16	2	0	70%
10. <i>Textualis Libraria</i>	0	2	1	1	0	0	0	0	1	14	1	70%
11. <i>Textualis Currens</i>	0	0	0	0	0	0	0	0	2	2	0	50%
Total	69	25	7	11	2	61	30	85	22	21	3	81%

Le taux moyen de discrimination est passé de 59% à 81%. Il pourrait s'améliorer si nous disposions d'effectifs plus équilibrés et d'une meilleure représentation des classes 8. *Textualis Prescissa* et 14. *Textualis Currens*. Les 2 classes de faibles effectifs à savoir 8. *Textualis Prescissa* et 14. *Textualis Currens* ne peuvent pas être analysées du point de vue statistique, ce qui explique leurs faibles taux de discrimination. En conclusion, il existe bel et bien des classes d'écritures qui paraissent compatibles avec l'expertise paléographique (selon la Bibliothèque de Grande Bretagne [BGB]) et la cooccurrence constitue une bonne mesure pour différencier les différentes écritures.

6 Conclusion et perspectives

Après avoir établi le cadre de notre travail par rapport à la science de la paléographie, nous avons posé le problème de la classification des types d'écritures. Nous avons défini une approche globale comparant directement le type d'écriture à partir de zones de texte quelconques dans des documents. Nous avons choisi de travailler avec les indices statistiques de Haralick pour décrire nos matrices

de cooccurrence afin d'avoir un nombre plus réduit de descripteurs par image.

Après une décorrélation des données par une analyse factorielle, nous avons constaté que nos descripteurs d'images basés sur des mesures statistiques de cooccurrence permettent de retrouver approximativement les classes d'écritures définies par la Bibliothèque de Grande Bretagne [BGB]. Nous reprenons actuellement les tests avec une autre classification des types d'écritures présentée dans [1] pour la comparer avec la classification anglo-saxonne. Les résultats de l'analyse discriminante ont été concluants et nous ont permis d'avoir dans plusieurs cas des séparations correctes des classes d'écritures. Nous avons obtenu un taux de 81% de discrimination globale lorsque nous avons éliminé les quatre classes posant des problèmes de sous-représentation statistique ou bien d'absence de précision. Le passage d'une famille à une autre n'étant jamais brusque et certaines écritures peuvent présenter un mélange de caractéristiques des écritures qui ont contribué à leurs formations, nous devons remplacer pour ces écritures l'analyse discriminante par une analyse qui mesure le taux de mélange avec les autres classes bien définies.

Références

- [1] Derolez A., "The Palaeography of Gothic Manuscript Books", from the Twelfth to the Early Sixteenth Century", Cambridge Studies in Palaeography and Codicology, Cambridge University Press, 2003.
 - [2] Crettez J. P., "A set of handwriting families : style recognition", International conference on Document Analysis and Recognition, Vol 1, pp 489, 1995.
 - [3] Vincent N., Boulétreau V., Sabourin R., Emptoz H., "How to use fractal dimensions to qualify writings and writers, Fractals", World Scientific, Vol 8, n°1, pp.85-97, 2000.
 - [4] Eglin V., "Contributions à la structuration fonctionnelle des documents imprimés. Exploitation de la dynamique du regard dans le repérage de l'information", Thèse de Doctorat, INSA de Lyon, 1998.
 - [5] Moalla I., Alimi A.M. Ben Hamadou A., "Extraction of Arabic text from multilingual documents", IEEE International Conference on Systems, Man and Cybernetics, Tunisia, 2002.
 - [6] Tan T. N., "Rotation Invariant Texture Features and Their Use in Automatic Script Identification", IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 20, no. 7, pp. 751-756, 1998.
 - [7] Wood S. L., Yao X., Krishnamurthi K., Dang L., "Language Identification for Printed Text Independent of Segmentation", Proc. IEEE ICIP, pp. 428-431, 1995.
 - [8] Aiolli., Simi M., Sona D., Sperduti A., Starita A., Zaccagnini G. SPI: a System for Palaeographic Inspections. AIIA Notizie, vol. 4, pp 34-38, 1999.
 - [9] Ciula A., "Digital palaeography: using the digital representation of medieval script to support palaeographic analysis", Digital Medievalist 1.1, 2005.
 - [10] Haralick R. M., Shanmugam K. and Its'Hak Dinstein. "Textural Features for Image Classification", IEEE Transactions on Systems, Man, and Cybernetics, Vol. 3, pp. 610-621, 1973.
- [BV] <http://www.villevalenciennes.fr/bib/fondsvirtuels/microfilms/accueil.asp#item>
 [BGB] <http://prodigi.bl.uk/illcat/searchMSNo.asp>.