



**HAL**  
open science

# Décomposition des manuscrits anciens en graphèmes et construction des codes book basée sur la coloration de graphe

Hani Daher, Djamel Gaceb, Véronique Eglin, Stéphane Bres, Nicole Vincent

► **To cite this version:**

Hani Daher, Djamel Gaceb, Véronique Eglin, Stéphane Bres, Nicole Vincent. Décomposition des manuscrits anciens en graphèmes et construction des codes book basée sur la coloration de graphe. COMpression et REprésentation des Signaux Audiovisuels ( CORESA), Oct 2010, Lyon, France. pp.105. hal-00592009

**HAL Id: hal-00592009**

**<https://hal.science/hal-00592009v1>**

Submitted on 10 May 2013

**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.

# Décomposition des manuscrits anciens en graphèmes et construction des codes book basée sur la coloration de graphe

H. Daher<sup>1</sup> D. Gaceb<sup>1</sup> V. Eglin<sup>1</sup> S. Bres<sup>1</sup> N. Vincent<sup>2</sup>

<sup>1</sup> LIRIS (Laboratoire d'Informatique en Image et Systèmes d'information)  
UMR 5205 CNRS - INSA de Lyon – 69621 Villeurbanne Cedex

<sup>2</sup> CRIP5 (Centre de Recherche en Informatique Paris 5)  
Université René Descartes - Systèmes Intelligents de Perception - 75270 Paris Cedex

{hani.daher,djamel.gaceb1,veronique.eglin,stephane.bres}@insa-lyon.fr

Nicole.vincent@math-info.univ-paris5.fr

## Résumé

*Nous présentons dans cet article une nouvelle méthode d'analyse et de décomposition de l'écriture manuscrite en graphèmes pour la construction d'un code book. Les diverses techniques développées sont inspirées de méthodes empruntées à l'imagerie au sens large et de modèles mathématiques issus de la coloration de graphes. Nos approches apportent d'une part une caractérisation fine et rapide basée sur le suivi de mouvement de la plume (courbure, épaisseur, direction, etc.) et d'autre part une méthodologie d'analyse très performante pour la catégorisation des formes de base: les graphèmes. Les outils que nous avons produits permettent aux paléographes d'étudier rapidement et avec plus de précision un grand volume de manuscrits et d'extraire un nombre important de caractères spécifiques d'un individu, ou d'une époque.*

## Mots clefs

Clustering, Coloration de graphe, Moments de Zernike, Segmentation des manuscrits anciens.

## 1 Introduction

Cet article s'inscrit dans le cadre du projet ANR GRAPHEM. Il représente une contribution méthodologique applicable à l'analyse automatique des écritures manuscrites anciennes pour assister les experts en paléographie dans le délicat travail d'étude et de déchiffrement de ces écritures. Nous nous sommes intéressés en particulier aux anciens manuscrits latins du Moyen Âge qui précède la période de la Renaissance, avant l'émergence de l'imprimerie. Sur ce type de manuscrits, on se trouve confronté à plusieurs contraintes à cause du vieillissement des supports et des encres : imprégnation irrégulière des encres, plissement, déchirement, cassures et autres dégradations du papier. De plus, les règles d'exécution des écritures en paléographie sont très strictes

: certaines lettres et combinaison de lettres ne peuvent être produites que selon une unique dynamique d'exécution. Il est donc nécessaire de tenir compte dans notre étude de toutes ces contraintes et ces particularités d'exécution d'écritures. Notre objectif est :

- de produire une décomposition de l'écriture en graphèmes cohérents, en évitant notamment de produire des graphèmes qui correspondraient à certains gestes de rebroussement (retour en arrière du mouvement de la plume)

- de produire une classification robuste et modulable de l'ensemble de graphèmes obtenus sous la forme d'un code book (table de similarités de graphèmes).

Nous montrerons comment ces éléments peuvent servir à la reconnaissance des styles d'écriture des manuscrits. Nous présenterons, dans les sections suivantes, les insuffisances des méthodes conventionnelles ainsi que le principe de nos approches originales conçues pour être plus adaptées aux conditions citées ci-dessus. Nos approches se basent sur :

- une décomposition en graphèmes qui est basée sur la détection de l'axe médian directement réalisée sur l'image en niveau de gris.

- une classification de graphèmes par coloration de graphe.

## 2 Décomposition des manuscrits en graphèmes

Cette décomposition se réalise en deux étapes :

- Suivi de tracé et détection de l'axe médian
- Découpage du tracé en graphèmes

### 2.1 Suivi du tracé et détection de l'axe médian

Il existe actuellement une grande variété de méthodes de suivi et de détection de l'axe médian (ou squelette) de tracé. Dans la littérature, ces méthodes peuvent être

regroupées selon quatre catégories basées sur (pour plus de détails voir [1]) :

- **L'amincissement morphologique** : l'amincissement consiste à retirer au fur et à mesure les points du contour de la forme, tout en préservant ses caractéristiques topologiques. Ces méthodes nécessitant une étape préalable de binarisation des images en niveaux de gris. Celle-ci conduit à une grande perte d'informations lorsque les documents sont anciens (de mauvaise qualité) [2,3] et donne des traits binaires dégradés : caractères cassés, fusionnés ou biaisés (trous, bruit). Ces dégradations déforment souvent le squelette des traits et provoquent des erreurs significatives dans l'appariement de traits [4]. Ces limites ont donné naissance à d'autres méthodes de squelettisation qui s'appliquent directement sur les images en niveaux de gris comme la méthode basée sur les champs de potentiels 2D [5]. Ce type d'approche nécessite de coûteuses opérations de lissage, mais il est plus robuste aux dégradations des images. Comme exemples, nous pouvons citer :

- **La transformée de distance** : la carte de distances d'un objet consiste à associer à chacun de ses points sa distance au point de contour le plus proche. Les maxima locaux de la carte de distance correspondent exactement aux points du squelette de l'objet. Plusieurs distances ont été utilisées dans ce cadre (Euclidienne [6], Chamfer [7], etc.) appliquées le plus souvent sur des images binaires mais aussi sur des images en niveaux de gris.

- **Des heuristiques** : ces méthodes s'appliquent directement sur les images en niveaux de gris en utilisant des heuristiques pour régler un grand nombre de paramètres qui gèrent la détection de l'axe médian. Elles ont été développées à l'origine pour extraire le squelette des traits sur des empreintes digitales et leurs résultats sont nettement plus robustes et efficaces sur des images dégradées que ceux de deux familles de méthodes précédentes [3,8].

- **La détection des contours** : Ces méthodes utilisent les contours pour naviguer le long du trait et détecter l'axe médian par corrélation entre une ligne et ses deux bords. Dans ce cadre, une approche itérative intéressante est proposée dans [9] pour détecter l'axe médian dans des images de neurones. D'autres méthodes, fondées sur le même principe, sont utilisées dans le suivi des routes sur des images satellitaires [10,11]. Ce type de méthodes ne peut pas être facilement appliqué sur des manuscrits dégradés où les contours de traits sont souvent déformés et discontinus et le suivi de contours risque de se perdre dans des petites chaînes parasites.

## 2.2 Notre méthode de détection de l'axe médian

Notre approche s'applique directement sur les images en niveaux de gris de manuscrits anciens. Elle s'adapte mieux aux dégradations des manuscrits comme la discontinuité des traits tout en préservant et reconstituant,

dans la mesure du possible, la forme initiale des traits. Grâce à la grande diversité technique utilisée combinant les 3 premières catégories citées ci-dessus, notre méthode offre un suivi et une détection de l'axe médian plus précise. La combinaison des méthodes se déroule de la façon suivante :

- la méthode de Frangi [14] (utilisée à l'origine pour détecter des vaisseaux sanguins de propriétés comparables à celles des traits noirs de l'écriture) est appliquée directement sur l'image initiale pour mettre en évidence le tracé par rapport au fond. Le résultat subit un lissage gaussien pour enlever les discontinuités, les trous, les bruits ou les déformations qui peuvent être présents sur le tracé.

- la transformée de distance de Chamfer est appliquée sur la carte de Frangi pour déterminer d'une manière automatique le rayon (distance par rapport au point contour le plus proche) de chaque point du tracé. Ceci nous libère de tous les inconvénients liés à l'utilisation d'un rayon avec une taille fixe dans la méthode de Xu et offre à notre méthode une meilleure adaptation au changement d'épaisseur de traits.

- le suivi de l'axe médian repose, d'une part, sur une squelettisation par diffusion [21] de la carte de Frangi et d'autre part sur le principe de la méthode de Xu adapté à notre application. Nous avons amélioré la méthode de Xu, en utilisant à chaque point la combinaison de deux directions complémentaires. a) la direction géométrique pour assurer une certaine robustesse aux situations indésirables de bifurcations et de croisement. b) la direction dynamique basée sur l'intensité lumineuse pour garantir un suivi robuste au changement soudain d'orientation ou d'épaisseur le long des traits. Cette dernière utilise une fenêtre de taille dynamique pour chercher le point suivant qui va appartenir à l'axe médian. La taille de la fenêtre varie automatiquement selon que l'on se situe dans le cas d'une bifurcation, d'un croisement ou d'une ligne droite.




Figure 1 - Suivi du tracé et extraction de l'axe médian

Les étapes de notre méthode de suivi et de détection de l'axe médian sont résumées dans l'algorithme suivant :

### a) Initialisation

- Détecter les points de départ la carte issue de la diffusion (un point est considéré comme point de départ si son intensité lumineuse est maximale par rapport à ses voisins),
- Extraire le rayon de chaque point de départ,
- Commencer à partir de premier point de départ rencontré,
- Déterminer le point suivant  $P_{k+1}^0$  en utilisant  $d_k$  « Look ahead Distance »,
- Calculer sa direction  $\Psi_{k+1}^0$  ( direction de gradient de diffusion),

b) Déterminer le point suivant et ajuster sa position

- Tracer perpendiculairement à la direction  $\Psi_{k+1}^0$  un profil de la densité  $g_{k+1}$  du point  $p_{k+1}^0$ .
  - Mise à jour de la direction dans  $\Psi_{k+1}^1$  afin de déterminer le point suivant  $p_{k+1}^1$  qui aura la valeur du rayon calculée avant,
  - Procéder de la même façon par calcul du profil de densité pour avoir le point  $P_{k+1}$ , point de convergence au centre du trait. Calculer sa direction  $\Psi_{k+1}$ ,
  - Marquer ce point comme un point visité, de cette façon il ne sera pas visité une autre fois par notre suivi de tracé.
- C) Critères d'arrêt
- Dans le cas où on rencontre un point de bifurcation et que ce point a déjà été visité, on arrête le suivi du tracé si on arrive à un point marqué comme point de départ, il sera enlevé de la liste des points de départ.
  - -Réitération du processus le long du trait jusqu'à ce qu'un critère d'arrêt soit atteint.

La figure suivante montre le résultat de l'extraction de l'axe médian par notre méthode qui est nettement meilleur que celui obtenu par la méthode classique de Zhang. On remarque que notre méthode a bien détecté l'axe médian, même dans les situations où l'encre était dégradée ou très claire.




Figure 2 - Extraction de l'axe médian par : (a) notre méthode, (b) la méthode de Zhang. (c) binarisation par la méthode de Sauvola

### 2.3 Découpage de tracé en graphèmes

D'un point de vue méthodologique, la segmentation des traits en graphèmes cohérents est réalisée de la façon suivante : entre chaque point de départ et d'arrêt, tous les points impliqués dans la formation d'un trait sont sauvegardés dans une liste avec leurs directions et épaisseurs. Les points d'épaisseur minimale (minimum local) sont ensuite marqués et proposés comme point de découpage, comme cela est effectivement le cas dans la formation d'un trait. Chaque segment du tracé a une couleur différente. On identifie par cette approche les zones de croisements, les points de levers et de posers de plume (voir le zoom de la figure 3). La décomposition présentée dans la figure suivante montre que les lettres sont constituées de fragments adjacents rattachés aux points d'épaisseur minimale supposée correspondre à des points de poser et de lever de plume. Afin de construire avec robustesse un code book pour chaque page manuscrite à partir de ces graphèmes découpés, nous nous sommes intéressés à une approche innovante de regroupement des graphèmes similaires utilisant le concept de coloration de graphes, jamais exploitée dans un tel contexte. Cette méthode n'exige pas la connaissance a priori du nombre de classes, ni un apprentissage préalable

et permet d'offrir une bonne homogénéité intra-classes et une bonne disparité inter-classes. Elle s'adapte mieux à la nature des graphèmes réellement présents, à l'inverse des méthodes conventionnelles qui nécessitent l'introduction préalable du nombre de classes et l'étiquetage manuel des graphèmes durant l'apprentissage en introduisant des erreurs à plusieurs niveaux d'intervention de l'utilisateur. On peut citer, à titre d'exemple, la méthode de Zhu [15] et la méthode de Kumar [16] qui sont basées sur les SVM et la méthode de Schomaker [17] basée sur la carte de Kohonen.




Figure 3 - Exemple de décomposition des traits en graphèmes par notre méthode.

## 3 Principe théorique de la coloration de graphes

La coloration de graphe constitue une branche très importante de la théorie de graphes. Ses applications sont nombreuses dans différents domaines scientifiques (optimisation des réseaux de transports ou de communication, des formules chimiques, ...). Les définitions de la coloration sont simples et de véritables problèmes de recherche peuvent être posés sous une forme bien structurée dont la formulation peut recouvrir de grandes difficultés pratiques. Ce modèle a été introduit la première fois dans le domaine de documents par Gaceb et Eglin [18] qui l'ont adapté à toutes les étapes d'analyse des documents (de l'extraction de la structure physique et la localisation à la reconnaissance) pour consolider la coopération et assouplir les échanges d'information entre les différents modules. Grâce à sa simplicité et son potentiel en matière de classification, nous avons pu imaginer une méthode originale de construction de code book représentatif de la distribution des graphèmes de l'écriture et de leurs fréquences d'apparition.

### 3.1 Types de coloration existantes

Il existe ainsi plusieurs types de colorations de graphe : la coloration de sommets à laquelle nous nous sommes intéressés, la coloration d'arêtes, la coloration par liste, etc. [18,20]. Une coloration de graphe  $G(V,E)$  est une fonction qui affecte une couleur à chaque sommet, et qui est telle que deux sommets reliés par une arête (adjacents ou voisins) n'ont pas la même couleur (contrainte de propriété). Les couleurs (ou entiers) attribuées aux sommets du graphe servent uniquement à regrouper les sommets en classes.

### 3.2 Modalisation du problème de classification de graphèmes en termes de coloration

Le regroupement d'un ensemble  $X=\{x_1, \dots, x_n\}$  de  $n$  graphèmes en plusieurs groupes homogènes se base sur le principe que chaque groupe doit réunir le plus de graphèmes similaires. Les regroupements portent sur un critère de similarité  $S$ . Ce critère spécifie que certaines paires de graphèmes  $\{x_i, x_j\}$  ne peuvent être fusionnées au sein d'un même groupe. Pour résoudre ce problème de partitionnement (ou de classification), on peut partir du point de vue inverse et formuler la question suivante, à savoir : quel est le plus petit nombre de groupes homogènes que l'on peut former en respectant la contrainte  $S$ . L'intérêt de formuler le problème de cette manière, est qu'il devient alors possible de le modéliser en termes de coloration de graphe. Le positionnement du problème est alors le suivant : nous représentons chaque graphème  $x_i$  par un sommet  $v_i \in V$  d'un graphe simple  $G$  et nous ajoutons une arête  $E(v_i, v_j)$  entre chaque paire de graphèmes dissemblables ( qui ne respectent pas la contrainte  $S$ ).

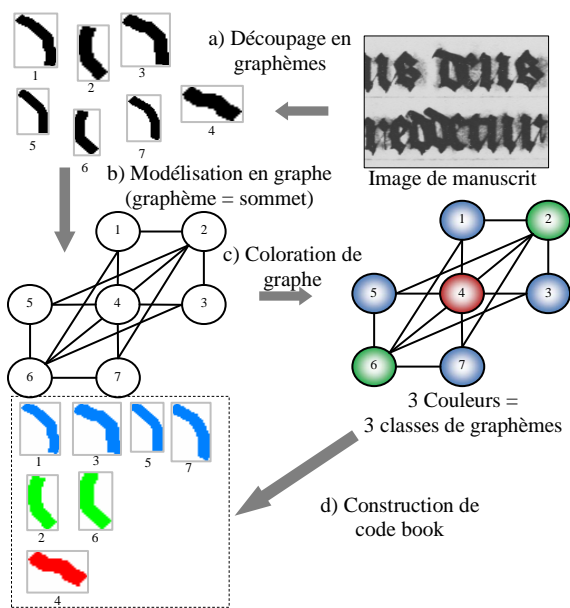


Figure 4 - Etapes de construction de code book par coloration de graphe.

La coloration des sommets du graphe  $G(V,E)$  consiste alors à affecter à tous ses sommets une couleur de telle sorte que deux sommets adjacents (dissemblables) ne puissent pas porter la même couleur. Ces couleurs vont correspondre aux différents groupes homogènes qui constituent les différents classes de graphèmes. Dans ce problème de regroupement, la question de la détermination du plus petit nombre de groupes homogènes, revient à rechercher le plus petit  $k$  pour lequel le graphe  $G$  correspondant admet une  $k$ -coloration : c'est

donc précisément le nombre chromatique  $\chi(G)$  du graphe  $G$  qu'il faut déterminer. En plus, cette modélisation présente l'avantage de gérer facilement plusieurs sortes d'ambiguïtés inhérentes à la forme de graphèmes par rapport aux mécanismes de regroupements classiques.

## 4 Construction du codes book

A partir de l'ensemble des graphèmes extraits dans l'étape précédente, nous procédons à la construction du code book de l'écriture (appelé aussi table de similarités).

### 4.1 Extraction des caractéristiques

Au départ, on produit une description vectorielle de chacun des graphèmes, qui sera ensuite traitée pour définir les critères de similarité nécessaire à la classification. Nous avons utilisé selon le besoin deux types de descripteurs : un descripteur de 15 caractéristiques topologiques et un descripteur de 25 moments de Zernike.

#### 4.1.1 Caractéristiques topologiques

Dix caractéristiques de forme ont été extraites à partir des graphèmes binaires. La longueur et la largeur du graphème sont utilisées pour différencier les styles d'écriture ainsi que la plume utilisée. L'orientation permet de connaître l'inclinaison du graphème et de différencier les différents mouvements d'exécution d'écriture. L'excentricité permet de savoir la forme globale du graphème. L'épaisseur permet connaître l'épaisseur de la plume et le style d'écriture. Par exemple dans les écritures gothiques l'épaisseur de la plume est grande ce qui n'est pas le cas des écritures modernes utilisant des stylos fins. Les trois dernières caractéristiques sont reliées à la surface qu'un graphème occupe dans un manuscrit par rapport aux autres.

Cinq caractéristiques de courbure (directions de la plus grande et de la plus petite courbure, les courbures Gaussienne et moyenne et le Laplacien de la courbure) sont extraites à partir des graphèmes en niveau de gris et sont calculées à partir de la matrice Hessienne [8]. Elles représentent la forme des courbes de graphèmes et reflète les propriétés structurelles telles que la convexité et concavité. Leur rôle est important, car elles sont des indicateurs essentiels permettant de différencier le style et l'époque de l'écriture.

#### 4.1.2 Moments de Zernike

Les 25 moments de Zernike utilisés pour décrire les graphèmes sont classés parmi les moments orthogonaux (géométrique, de Legendre, etc.) car ils possèdent la propriété d'invariance à la rotation.

Le moment de Zernike d'ordre  $n$  avec la répétition  $m$  ( $n - |m|$  est paire et  $|m| < n$ ) est définie par :

$$A_{nm} = \frac{n+1}{\pi} \sum_x \sum_y f(x,y) \cdot V_{nm}^*(\rho, \theta)$$



$V_{nm}(\rho, \theta)$  est un ensemble de polynômes complexes dans l'espace à deux dimensions qui forme un ensemble orthogonal sur l'intérieur du cercle unité ( $x^2+y^2=1$ ), avec :

$$V_{nm}(\rho, \theta) = R_{nm} e^{im\theta}$$

Où  $\rho$  est la longueur du vecteur d'origine au point de coordonnées  $(x, y)$ .  $\theta$  est l'angle entre le vecteur  $\rho$  et l'axe des abscisses.  $R_{n,m} = R_{n,-m}$  est un polynôme radial défini comme suit :

$$R_{nm}(\rho) = \sum_{s=0}^{(n-|m|)/2} (-1)^s \frac{(n-s)!}{s! \left(\frac{n+|m|}{2}-s\right)! \left(\frac{n-|m|}{2}-s\right)!} \rho^{n-2s}$$

Pour calculer les moments de Zernike, le centre de chaque graphème binaire est pris comme origine du repère et les coordonnées des pixels de l'image sont transformés de manière à être dans le domaine du cercle unité. Comme nous l'avons signalé précédemment les moments de Zernike sont invariants seulement à la Rotation. Pour les rendre invariants au changement d'échelle [19], on doit normaliser l'image binaire du graphème par le moment du premier ordre  $m_{00}$  défini comme étant la surface du graphème.

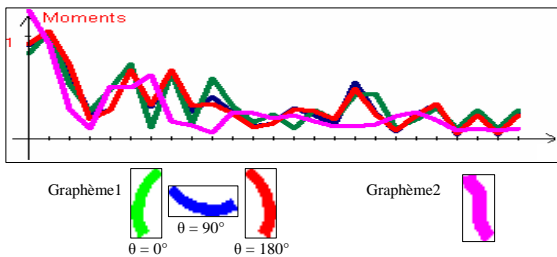


Figure 5 - Invariance à la rotation des 25 moments de Zernike ( $n=8$ ).

## 4.2 Mesure de similarité

La dissimilarité entre  $v_i$  et  $v_j$  est donnée par la distance généralisée de Minkowski d'ordre  $\alpha$  ( $\alpha = 2$  : distance euclidienne).  $D_s = \left( \sum_{k=1}^{N_c} g_k(v_i^k, v_j^k)^\alpha \right)^{\frac{1}{\alpha}}$

$N_c$  est la longueur des vecteurs des caractéristiques.  $g_k$  est la fonction de dissemblance qui compare les caractéristiques deux à deux.

## 4.3 Construction du graphe

La construction d'un graphe  $G$  à colorer à partir d'un ensemble  $X=\{x_1, \dots, x_n\}$  de  $n$  graphèmes (où chaque sommet  $v_i$  correspond au vecteur descripteur de graphème  $x_i$ ) est principalement basée sur le calcul de la matrice de distances  $MD_s$ . Cette matrice traduit les dissimilarités  $D_s(x_i, x_j)$  existantes entre les paires de graphèmes  $(x_i, x_j)$  données par la relation suivante :  $MD_s[v_i, v_j] = D_s(x_i, x_j)$  avec  $i \in [1, n]$  et  $j \in [1, n] \mid (i \neq j)$ . Une fois  $v$  calculée, nous

associons à  $X$  un graphe seuil supérieur  $G_{\geq S} = (V=X, E_{\geq S})$  en utilisant la relation suivante :

$$E_{\geq S}[v_i, v_j] = \begin{cases} 1 & \text{si } D_s(x_i, x_j) = D_s(v_i, v_j) \geq S \\ 0 & \text{sinon} \end{cases}$$

Pour ne pas confondre le terme adjacence (ou voisinage) avec le terme similarité, il faut noter que deux sommets sont adjacents s'ils ont une dissimilarité supérieur au seuil  $S$ . Le seuil  $S$  est également nommé seuil d'adjacence. Ce seuil peut être ajusté manuellement à l'aide des paléographes ou automatiquement en maximisant la qualité de classification  $\psi$  donné par [18]:

$$S^{Optimal} = \arg \max (\psi(S_i))$$

## 4.4 Classification des graphèmes

Une fois le graphe  $G$  construit à partir de l'ensemble des graphèmes, on applique l'algorithme de coloration de Gaceb et Eglin [18]. Les différentes couleurs résultantes représentent les classes de graphèmes.

## 5 Résultats et application

Nous avons testé notre méthode de décomposition en graphèmes sur 12 pages de textes manuscrites du Moyen-âge de différents types.



Figure 6 - Extraits des 12 manuscrits.

Un ensemble des 4863 graphèmes répartis de la façon suivante a été extrait des douze pages manuscrites. :

$\{p1=343, p2=583, p3=643, p4=248, p5=398, p6=528, p7=564, p8=316, p9=499, p10=193, p11=269, p12=279\}$ .

Cette décomposition a été soumise à la validation des experts paléographes et a obtenu leur approbation. La figure suivante montre un extrait de code book construit à partir des graphèmes de la page 12 par coloration de graphe (section 4). Il est important de noter ici que les descripteurs topologiques ont permis de mettre en évidence la dynamique dans la formation du tracé : les graphèmes qui représentent ainsi les mêmes particularités de mouvement (arrondis droits ou gauches) de la plume

sont regroupés dans une même classe. Une vérification complète produite par les experts paléographes permet de l'attester.




Figure 7 - Extrait de code book de page p12.

Pour reconnaître le style des manuscrits : chacune des 12 pages manuscrites  $p_i$  est représentée par son code book  $cb(p_i)$  de  $k_i$  classes de graphèmes ( $k_i$  nombre chromatique de la coloration de graphe) avec  $cb(p_i) = \{c_1^i, \dots, c_{k_i}^i\}$ . Chaque classe  $c_i$  contient  $n_i$  graphèmes avec  $c_i = \{x_1^i, \dots, x_{n_i}^i\}$ . On peut donc estimer la similarité entre chaque paire de pages ( $p_i, p_j$ ) par la distance  $dp$  suivante :

$$dp[cb(p_i), cb(p_j)] = \sup[dc(c_n, c_m)] | n=1..k_i \text{ et } m=1..k_j$$

Avec  $dc$ , la distance entre deux classes de graphèmes donnée par :  $dc(c_n, c_m) = \min\{Ds(x_i \in c_n, x_j \in c_m)\}$

Les distances  $dp$  entre les pages 12 sont illustrées dans le tableau suivant :

	1	2	3	4	5	6	7	8	9	10	11	12
1	0											
2	0.7145	0										
3	0.391	0.459	0									
4	0.3063	0.679	0.3464	0								
5	0.1559	0.596	0.3353	0.2483	0							
6	0.5464	0.391	0.7943	0.5372	0.4591	0						
7	0.127	0.422	0.3173	0.3419	0.1755	0.3867	0					
8	0.4871	0.448	0.8065	0.5029	0.5351	0.5487	0.2362	0				
9	0.7056	0.231	0.8526	0.7685	0.6276	0.4637	0.4141	0.7529	0			
10	0.8062	0.206	0.728	0.6466	0.6261	0.4637	0.1435	0.7122	0.153	0		
11	0.3437	0.597	0.2586	0.1511	0.2446	0.1863	0.208	0.3852	0.555	0.5772	0	
12	0.3413	0.603	0.3659	0.1331	0.2381	0.3868	0.1741	0.3883	0.589	0.6152	0.2295	0

Tableau 1 - Distances entre les codes book de pages.

On peut estimer à partir cette table que le style de la page 7 et le plus proche de celui de la page 1, que celui de la page 2 est plus proche de celui de la page 10, et ainsi de suite. Compte tenu de l'évidence visuelle facile à obtenir en observant les images de la base, cette distance est un indicateur efficace de similarités entre écriture. Ces premiers tests sont actuellement complétés par des tests en vraie grandeur sur la base paléographiques de 10000 images au sein de laquelle des différences plus difficiles à relever devront être relevées.

## 6 Conclusion

Nous avons présenté dans cet article une nouvelle méthode de découpage de l'écriture manuscrite en graphèmes et une construction d'un code book robuste bien adaptés aux exigences de notre domaine et basée sur la coloration de graphes. En perspective de ce travail, nous envisageons de reconnaître automatiquement les styles et l'époque des manuscrits de la base complète paléographique. Ce travail sera intégré prochainement dans un prototype expérimental à l'usage des experts paléographes du projet GRAPHEM.

## Références

- [1] H. Daher et al. A New approach for centerline extraction in handwritten strokes..., International Workshop on Document Analysis Systems, Boston, June, 2010.
- [2] D. Lee, S.W. Lee. A new methodology for gray-scale character segmentation and recognition, ICDAR, vol. 1, pp.524, 1995.
- [3] Maio, D. Maltoni, Direct Gray-Scale Minutiae Detection in Fingerprints, IEEE Transactions on PAMI, vol. 19, n°. 1, pp. 27-40, 1997.
- [4] Suh et al. Stroke extraction from gray-scale character image, Progress in Handwriting Recognition 593-598, 1997.
- [5] Grigorishin et al. Skeletonisation: An Electrostatic Field Based Approach, Pattern Analysis & Applications 98, v.1, pp. 163-177.
- [6] P.E. Danielsson. Euclidean Distance Mapping, Computer Graphics and Image Processing, vol. 14, pp. 227-248, 1980.
- [7] A. Rosenfeld and J.L. Pfalz. Distance Functions on Digital Pictures, Pattern Recognition, vol. 1, pp. 33-61, 1968.
- [8] Yaxuan Qi. Fingerprint Ridge Line Reconstruction. Intelligent Information Processing, pp. 211-220, 2004.
- [9] Y. Zhang et al. A novel tracing algorithm for high throughput imaging Screening of neuron-based assays, J Neurosci Methods 160, pp. 149-162, 2007.
- [10] D.Poz et al. Automated extraction of road network from medium and high-resolution images, Pattern Recognition and Image Analysis, vol. 16, n°. 2, pp 239-248, 2006.
- [11] R. Peteri et al. Detection and extraction of road networks from high resolution satellite images, International Conference on Image Processing, vol.1, pp I-301-4, 2003.
- [12] Y. Xu et al. An improved algorithm for vessel centerline tracking in coronary angiograms, Computer Methods and Programs in Biomedicine, Vol. 88, n° 2, Pages 131-143.
- [13] T.Y. ZHANG ET C.Y. SUEN: A fast parallel algorithm for thinning digital patterns. Communications of the ACM, 27(3):236-240, mars 1984.
- [14] A.F. Frangi et al. Multiscale Vessel Enhancement Filtering, MICCAI '98, pp. 130-137, 1998.
- [15] G. Zhu et al. Language Identification for Handwritten Document Images Using A Shape Codebook.
- [16] J. Kumar et al. Handwritten Arabic Text Zone Detection using A Shape Codebook. ICPR, 2010.
- [17] L. Schomaker et al. using codebooks of fragmented connected-component contours in forensic and historic writer identification. Pattern Recognition Letters 28(6), pp 719-727, 2007.
- [18] D. Gaceb et V. Eglin : Improvement of postal mail sorting system. IJDAR, 11(2):67-80, 2008.
- [19] M.R.Teague, Image analysis via the general theory of moments, J.opt.soc.Am, vol.70, n°8, pp 920-930, 1980.
- [20] V. PASCHOS, book, Optimisation combinatoire5: problèmes paradigmatiques et nouvelles problématiques, Lavoisier, France, pp. 270, 2007.
- [21] Z. Yu and C.L. Bajaj, A Segmentation-Free Approach for Skeletonization of Gray-Scale Images via Anisotropic Vector Diffusion, CVPR'04, vol.1, pp. 415-420, June 2004.