



EnVA
École nationale vétérinaire d'Alfort



GREYC



MASTER 2 RECHERCHE EN INFORMATIQUE, SPÉCIALITÉ LANGAGE, IMAGE ET DOCUMENT.

UNIVERSITÉ DE CAEN BASSE-NORMANDIE.
2010-2011.

MÉMOIRE DE STAGE DE FIN D'ÉTUDES

ANALYSE DE TRÈS GRANDES IMAGES MICROSCOPIQUES DE
TENDINOPATHIES ÉQUINES

Auteur :

Matthieu TOUTAIN

Encadrants du stage :

O. LÉZORAY, A. ELMOATAZ, F. AUDIGIÉ

Durée du stage :

6 mois (du 7 mars au 7 septembre)

Laboratoires GREYC et CIRALE

Caen

1 Remerciements

Je tiens à remercier respectivement tous ceux qui m'ont aidé, soutenu, et encouragé pendant ma période de stage au laboratoire GREYC, ainsi que lors de la rédaction de ce mémoire. Olivier Lézoray, Abderrahim Elmoataz ainsi que Fabrice Audigié, pour votre direction, vos orientations, et votre compréhension, ainsi que François Lozes, qui a été un collaborateur et ami de choix tout au long de ce stage. Je remercie bien sûr tous les enseignants et encadrants du Master, pour leurs enseignements, leur accompagnement et leur soutien. Enfin, je voudrais remercier celle qui me supporte depuis bientôt six ans, Alexandra, qui m'a soutenu et poussé, plus particulièrement pendant ce stage de fin d'études, et la rédaction de ce mémoire. Je remercie bien sûr toutes les personnes que j'aurais oubliées de citer et qui doivent être remerciées comme il se doit.

Table des matières

1	Remerciements	1
2	Introduction	4
3	Description du stage	5
3.1	Collaboration GREYC - CIRALE	5
3.2	Données	5
3.2.1	Tendons équins	5
3.2.2	Très grandes images microscopiques	7
3.3	Objectif du stage	8
4	Travail effectué	10
4.1	Approche	10
4.2	Segmentation	10
4.2.1	Préliminaires sur les graphes	10
4.2.2	Opérateurs discret sur graphes	11
4.2.3	Régularisation discrète	11
4.2.4	Régularisation de labels discrète	12
4.2.5	Segmentation de l'image	14
4.3	Traitement à plus haute résolution	16
4.3.1	Caractéristiques de texture	17
4.3.1.1	Invariance aux changements d'échelles de niveaux de gris	18
4.3.1.2	Invariance aux rotations	20
4.3.1.3	Extraction de ces caractéristiques	21
4.3.2	Caractéristiques de graphes	22
4.3.2.1	Extraction des fibroblastes	22
4.3.2.2	Caractéristiques de graphes et de fibroblastes	24
4.3.3	Alignements des cellules	27

4.4	Classification des tuiles	28
4.4.1	Clustering spectral	29
4.4.2	Clustering spectral simple vue	31
4.4.3	Clustering spectral multi-vues	33
4.4.4	Clustering spectral multi-vues par des méthodes basées sur les tenseurs	33
5	Résultats	37
5.1	Implémentation	37
5.2	Résultats du clustering multispectral	37
6	Conclusion	41
	Bibliographie	42

2 Introduction

Le stage, effectué au sein du GREYC, s'est déroulé dans le cadre d'une collaboration avec le CIRALE (Centre d'Imagerie et de Recherche sur les Affections Locomotrices Équines, École Nationale Vétérinaire d'Alfort). Le CIRALE détient des lames entières microscopiques de prélèvements histologiques de tendons de chevaux et souhaite disposer d'une analyse automatique d'images de ces lames microscopiques, afin de disposer d'une classification des tendinopathies équines. En effet, les tendinopathies équines touchent environ 15% de la population des chevaux de sports et de courses, ce qui représente pour la filière un grand impact économique. Ces affections représentent chez les chevaux une des principales causes de baisse de performances et d'arrêt temporaire ou définitif de la carrière sportive. L'enjeu du stage est donc de réussir à analyser les lames microscopiques de coupes de tendons de chevaux, par rapport à des critères préétablis. Dans un premier temps, je décrirais le stage dont nous verrons plus en détail les enjeux, problématiques et contraintes techniques. Dans un second temps, je décrirais l'approche que nous avons choisie afin de répondre à l'objectif du stage. Enfin, je finirai par l'évaluation des résultats obtenus par rapport aux critères de classification définis plus tôt.

3 Description du stage

Dans ce chapitre, je présenterai tout d'abord le contexte du stage, puis les données que nous avons à traiter. Je finirai en décrivant mes travaux effectués pendant le stage.

3.1 Collaboration GREYC - CIRALE

Le stage, effectué au sein du GREYC, s'est déroulé dans le contexte d'une collaboration avec le CIRALE (Centre d'Imagerie et de Recherche sur les Affections Locomotrices Equines, École Nationale Vétérinaire d'Alfort, USC INRA Biomécanique et Pathologie Locomotrice du Cheval). Le CIRALE dispose de lames entières microscopiques de prélèvements histologiques de tendons de chevaux obtenues dans divers projets de recherche en diagnostic et thérapeutique et souhaite disposer d'une analyse automatique d'images de ces lames microscopiques. Les développements ont été effectués dans le cadre du Pôle de compétitivité "Filière Équine".

3.2 Données

3.2.1 Tendons équins

Le tendon (figure 3.1) assure la transmission de la force développée par la masse musculaire sur la structure osseuse. C'est la structure la moins élastique du système musculaire, bien que très résistant. Le tendon subit en totalité l'augmentation de la tension imposée par le muscle.

Les efforts violents et répétés peuvent faire apparaître des lésions tendineuses, de la simple tendinite à la rupture. Les tendons peuvent également présenter des rétractions douloureuses.

Les muscles des membres antérieurs supportent la plus grande partie du poids du cheval, ils fatiguent plus rapidement. Contrairement aux membres postérieurs, les membres antérieurs sont plus sujets aux claquages. De plus, ce sont les tendons fléchisseurs (figure 3.2) qui sont le plus touchés car ils doivent fournir un effort plus important que les extenseurs. En effet, pour soulever un membre du sol, un fléchisseur produit un effort supérieur en comparaison à un extenseur qui ne fait que reposer

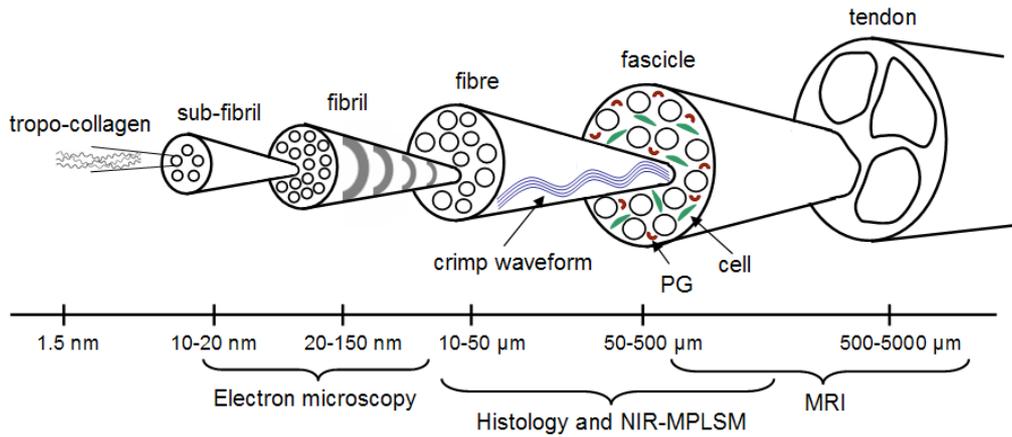


FIGURE 3.1 – Structure du tendon à différentes échelles.

le pied sur le sol.

Les tendinopathies représentent chez les chevaux de sport et de courses une des principales causes de baisse de performances et d'arrêt temporaire ou définitif de la carrière sportive. Des analyses rétrospectives conduites chez les chevaux trotteurs examinés au CIRALE montrent que les tendinopathies affectent 10 à 15% de la population. Chaque année, 11 000 trotteurs étant exploités en course en France, 1100 à 1600 chevaux vont présenter des lésions de tendinopathies. Le coût moyen associé (frais d'entretien et de soins, absence de gain) représente environ 4000€ par cheval. L'impact économique de cette entité pathologique, chez le trotteur uniquement, dépasse ainsi pour la filière 4 M€/an. Le diagnostic par imagerie (échographie tendineuse haute résolution et Imagerie par Résonance Magnétique (figure 3.3)) de ces affections [DAH⁺04] a connu ces 15 dernières années des progrès majeurs. Parallèlement, des études expérimentales sont menées afin de valider l'efficacité de nouvelles approches thérapeutiques sur la cicatrisation de tendons lésés, le cheval constituant un excellent modèle animal de pathologie spontanée du sportif humain. Cependant, l'ensemble de ces études requiert des analyses histologiques détaillées de prélèvements tendineux qui sont difficiles à systématiser car l'analyse est visuelle et subjective. Valider l'efficacité d'un traitement des tendinopathies équinés, thérapie qui sera ensuite commercialisée et appliquée à de nombreux chevaux de sport et de courses, principalement sur ces interprétations histologiques pose de nouveau la question de la représentativité des données histologiques. Différents critères histologiques sont utilisés pour étudier les tendinopathies équinés, mais ceux-ci ont l'inconvénient d'être généralement qualitatifs et basés sur une évaluation subjective de la lame. Quelques critères sont semi-quantitatifs mais ils sont alors mesurés que sur une partie très limitée de la lame. Il serait ainsi extrêmement utile pour obtenir des données plus fiables de pouvoir analyser :

- l'ensemble de la lame histologique ;
- de manière quantitative et non qualitative ou semi-quantitative ;
- en étant répétable et opérateur-indépendant.

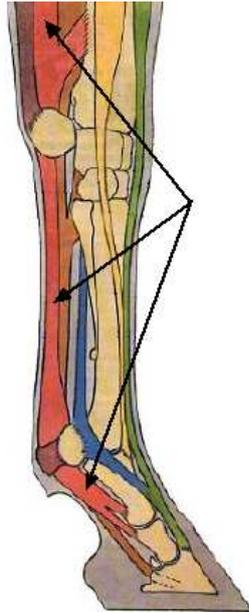


FIGURE 3.2 – Tendons fléchisseurs du cheval.

Les progrès de l'imagerie et de l'informatique ouvrent aujourd'hui la voie vers une nouvelle ère de l'analyse histologique : celle de l'Imagerie Lamelle Entière (ILE). En effet, la toute dernière génération de stations d'imagerie pathologique permet de disposer d'interfaces pour la microscopie virtuelle par l'Imagerie d'une Lamelle Entière (ILE), c'est-à-dire qu'il devient possible de scanner une lame histologique complète à une très forte résolution spatiale (de type microscopique). Comme mentionné précédemment, le laboratoire CIRALE nous a fourni des lames microscopiques de prélèvements histologiques de tendons de chevaux. Ceci afin d'étudier les tendinopathies équinées. Ces lames ont été numérisées par un scanner de lames entières dont dispose le GREYC (Sites distants de la Manche) sur le site universitaire de Saint-Lô.

L'ILE produit cependant des images énormes pour une unique lame (environ 30 Go) et la gestion de telles masses de données représente un réel défi de cette nouvelle ère de la microscopie numérique. C'est ce que je présenterai dans la prochaine sous section.

3.2.2 Très grandes images microscopiques

Les images de lames entières sont au format tiff tuilé pyramidal. Elles sont ainsi représentées par un seul fichier contenant l'image à pleine résolution et par une séquence d'images codant différentes résolutions de l'image de base. Celles-ci sont tuilées, et pyramidales (figure 3.4), offrant ainsi plusieurs niveaux de résolution. L'une des contraintes des images obtenues est leur très grande résolution (environ $40\,000 \times 30\,000$), ce qui est un inconvénient majeur si on veut les charger complètement en mémoire, afin de les traiter, ou simplement les visualiser.

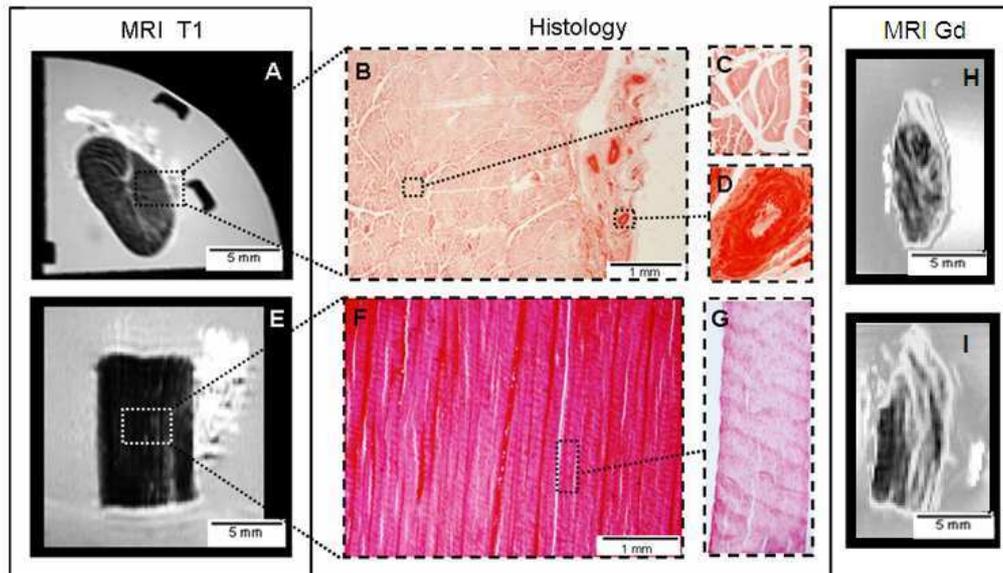


FIGURE 3.3 – IRM de tendons (A, E, H et I) avec les prélèvements histologiques correspondant.

3.3 Objectif du stage

L'objectif général du stage est de développer une méthodologie d'analyse d'ILE pour l'étude des tendinopathies du cheval visant à évaluer l'efficacité de nouveaux traitements des tendinopathies du cheval [BvSdG⁺10]. Il s'agira de quantifier les critères visuels histologiques employés pour évaluer les lésions tendineuses (alignement, organisation, ondulation des fibres de collagène, morphologie et densité des cellules fibroblastes, etc.).

Nous avons vu dans ce chapitre le contexte, l'objectif général du stage et les données à traiter. Dans le chapitre suivant, nous verrons quelle a été notre approche, ainsi que les techniques utilisées afin de répondre à l'objectif du stage.

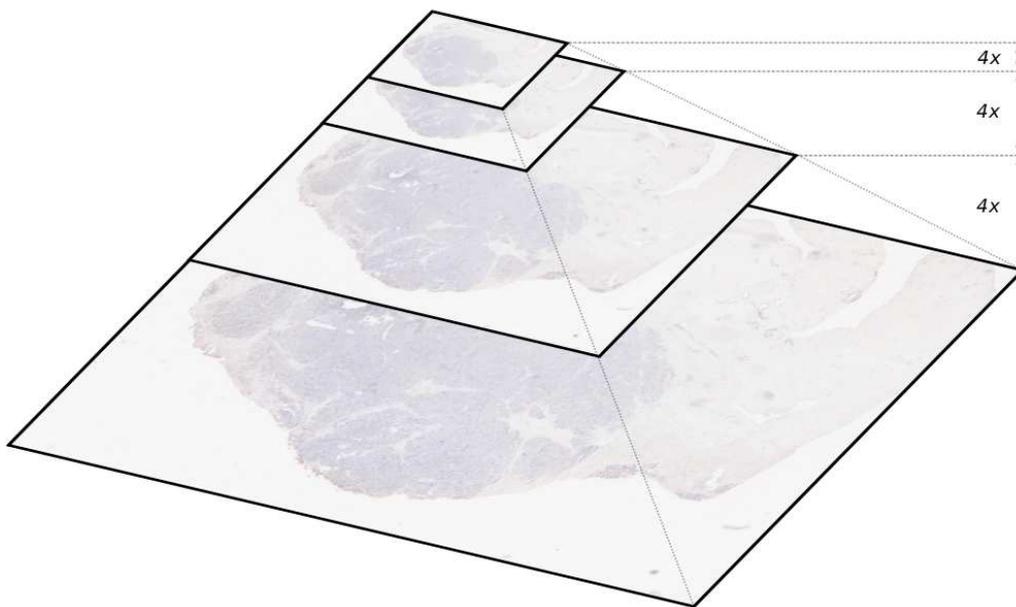


FIGURE 3.4 – Tiff tuilé pyramidal.

4 Travail effectué

Dans ce chapitre, nous verrons d'abord la stratégie que nous avons décidée d'adopter, nous verrons ensuite plus en détail l'application de cette approche.

4.1 Approche

Afin de pouvoir traiter les images, il a fallu adopter une approche qui prenne en compte la taille des images, mais aussi la variabilité biologique des éléments d'intérêts.

Notre approche est basée sur un processus top-down (inspection globale de la lame, puis analyse descendante à plus forte résolution sur les zones précédemment retenues), comme le ferait le vétérinaire ou le pathologiste, à la différence que nous n'avons pas traité chaque niveau de résolution, mais seulement le niveau à plus faible résolution et celui à plus haute résolution. L'image à plus faible résolution nous sert uniquement à séparer la zone de fond de celle de tissu. Une fois la zone de tissu déterminée, nous procédons à son analyse à la plus forte résolution, par tuile.

4.2 Segmentation

4.2.1 Préliminaires sur les graphes

Un graphe est une structure utilisée pour décrire un ensemble d'objets et la relation deux à deux entre ces objets. Dans notre cas, nous prenons en compte le fait que les graphes sont non-orientés, sans boucle et sans arêtes multiples (voir [Die05] pour de plus amples détails). Les objets sont appelés sommets et un lien entre deux objets est une arête. Un graphe pondéré $G = (V, E, w)$ est un ensemble fini $V = v_1, \dots, v_n$ de N arêtes, un ensemble d'arêtes $E \subset V \times V$ et une fonction de poids symétrique $w : E \rightarrow \mathbb{R}^+$ qui satisfait $w(u, v) = 0$ si (u, v) n'est pas une arête de E . La notation $u \sim v$ est utilisé pour dénoter que deux sommets sont adjacents.

Soit $\mathcal{H}(V)$ l'espace de Hilbert des fonctions définies sur les sommets d'un graphe. Une fonction $f : V \rightarrow \mathbb{R}$ de \mathcal{H} assigne une valeur réelle $f(v)$ à chaque sommets $v \in V$. Similairement,

soit $\mathcal{H}(E)$ l'espace des fonctions définies sur les arêtes d'un graphe. Les structures de graphe sont extrêmement utiles et se prêtent naturellement au traitement d'image : les sommets représentent les pixels, et les arêtes représentent généralement la relation de 8-connexité.

4.2.2 Opérateurs discret sur graphes

Soit $G = (V, E, w)$ un graphe pondéré et $f : V \rightarrow \mathbb{R}$ une fonction de $\mathcal{H}(V)$. L'opérateur de différence de f , noté $d : \mathcal{H}(V) \rightarrow \mathcal{H}(E)$, est défini sur l'arête $(u, v) \in E$ par $(df)(u, v) = \sqrt{w(u, v)}(f(v) - f(u))$. L'opérateur gradient pondéré d'une fonction $f \in \mathcal{H}(V)$, à un sommet $u \in V$ est l'opérateur vecteur défini par $\nabla_w f(u) = [(df)(u, v_1), \dots, (df)(u, v_k)]^T, \forall (u, v_i) \in E$. La norme \mathcal{L}_2 de ce vecteur représente la variation locale de la fonction f à un sommet du graphe. Elle est définie par $\|\nabla_w f(u)\| = \sqrt{\sum_{v \sim u} w(u, v)(f(v) - f(u))^2}$. Soit $p \in (0, +\infty)$ un réel. L'opérateur p-laplacien isotrope pondéré d'une fonction $f \in \mathcal{H}(V)$, noté $\Delta_w^p : \mathcal{H}(V) \rightarrow \mathcal{H}(V)$, est défini par [ELB08] :

$$\Delta_w^p f(u) = \frac{1}{2} \sum_{v \sim u} \gamma_w^f(u, v)(f(u) - f(v)) \quad (4.1)$$

avec

$$\gamma_w^f(u, v) = w(u, v)(\|\nabla_w f(v)\|^{p-2} + \|\nabla_w f(u)\|^{p-2}) \quad (4.2)$$

4.2.3 Régularisation discrète

Afin de régulariser une fonction $f^0 \in \mathcal{H}(V)$ en utilisant le p-Laplacien (4.1), on considère le problème variationnel général sur graphe suivant :

$$\min_{f \in \mathcal{H}(V)} \{E_{w,p}(f, f^0, \lambda) = R_{w,p}(f) + \frac{\lambda}{2} \|f - f^0\|^2\} \quad (4.3)$$

L'intuition derrière la régularisation est de d'avoir une version plus lisse d'une fonction initiale (avec le terme de régularisation) tout en la gardant très proche de la fonction initiale (avec le terme d'attache). Le premier terme, $R_{w,p}(f)$, est le régulariseur et est défini comme la forme de Dirichlet discrète de la fonction $f \in \mathcal{H}(V) : R_{w,p}(f) = \frac{1}{2} \sum_{u \in V} \|\nabla_w f(u)\|^p$. Le deuxième terme est le terme d'attache. $\lambda \geq 0$ est un paramètre de fidélité appelé multiplicateur de Lagrange qui spécifie le compromis entre les deux termes opposés. Les deux termes de $E_{w,p}(f, f^0, \lambda)$ dans (4.3) sont des fonctions strictement convexes de f ([COS01]). Ce problème d'optimisation a une solution unique qui satisfait, pour tout $u \in V$ [ELB08] :

$$\frac{\partial}{\partial f(u)} E_w(f, f^0, \lambda) = \Delta_w^p f(u) + \lambda(f(u) - f^0(u)) = 0. \quad (4.4)$$

L'équation 4.4 peut être interprétée comme l'analogie discret de l'équation d'Euler-Lagrange. En utilisant la formulation du p-Laplacien (4.1) dans (4.4), la solution du problème d'optimisation

peut être réécrite comme la solution d'un système d'équation. Pour approximer la solution de la minimisation (4.3), on peut linéariser ce système d'équations et utiliser la méthode de Gauss-Jacobi pour obtenir l'algorithme itératif suivant [BEM07] :

$$\begin{cases} f^{(0)} & = f^0 \\ f^{(t+1)}(u) & = \varphi^{(t)}(u, u)f^0(u) + \sum_{v \sim u} \varphi^{(t)}(u, v)f^{(t)}(v), \forall u \in V \end{cases} \quad (4.5)$$

avec $\varphi^{(t)}(u, v) = \frac{\gamma_{w,p}^{f^{(t)}}(v, u)}{2\lambda + \sum_{v \sim u} \gamma_{w,p}^{f^{(t)}}(v, u)}$ si $u \neq v$, et $\varphi^{(t)}(u, u) = \frac{2\lambda}{2\lambda + \sum_{v \sim u} \gamma_{w,p}^{f^{(t)}}(v, u)}$.

Pour $p = 1$:

$$f^{(t+1)}(u) = \frac{2\lambda f^0(u) + \sum_{v \sim u} w(u, v)(\|\nabla_w f^{(t)}(u)\|^{-1} + \|\nabla_w f^{(t)}(v)\|^{-1})f^{(t)}(v)}{2\lambda + \sum_{v \sim u} w(u, v)(\|\nabla_w f^{(t)}(u)\|^{-1} + \|\nabla_w f^{(t)}(v)\|^{-1})} \quad (4.6)$$

Pour $p = 2$:

$$f^{(t+1)}(u) = \frac{\lambda f^0(u) + \sum_{v \sim u} w(u, v)f^{(t)}(v)}{\lambda + \sum_{v \sim u} w(u, v)} \quad (4.7)$$

4.2.4 Régularisation de labels discrète

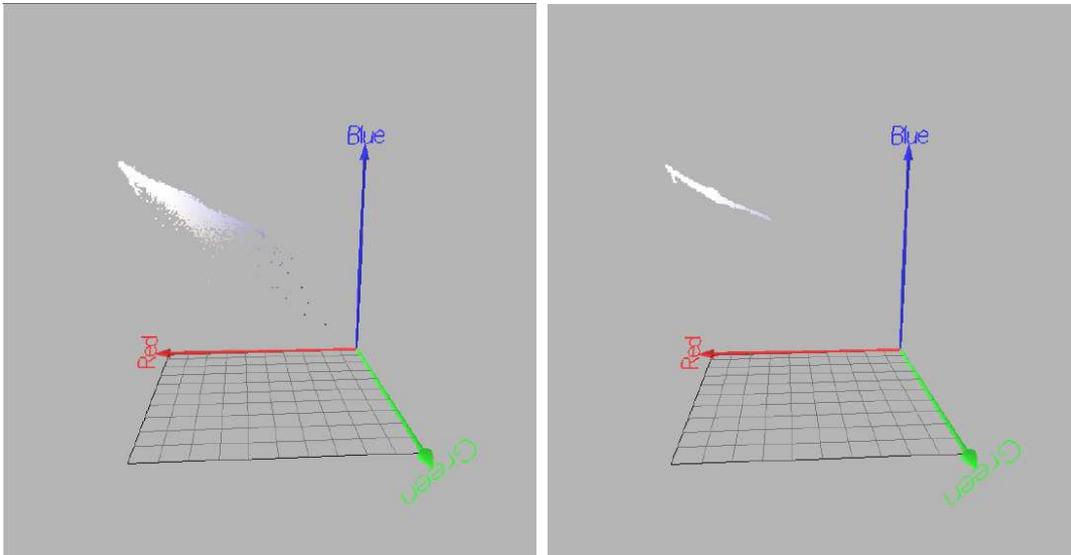


FIGURE 4.1 – Distribution des couleurs dans l'espace couleur RGB avant et après régularisation.

La régularisation discrète présentée précédemment peut aussi être adaptée pour segmenter des images par régularisation de labels discrète [TLES09]. De nombreuses méthodes de segmentations automatiques ayant montré leur efficacité ont été proposées dans la littérature. Cependant, des

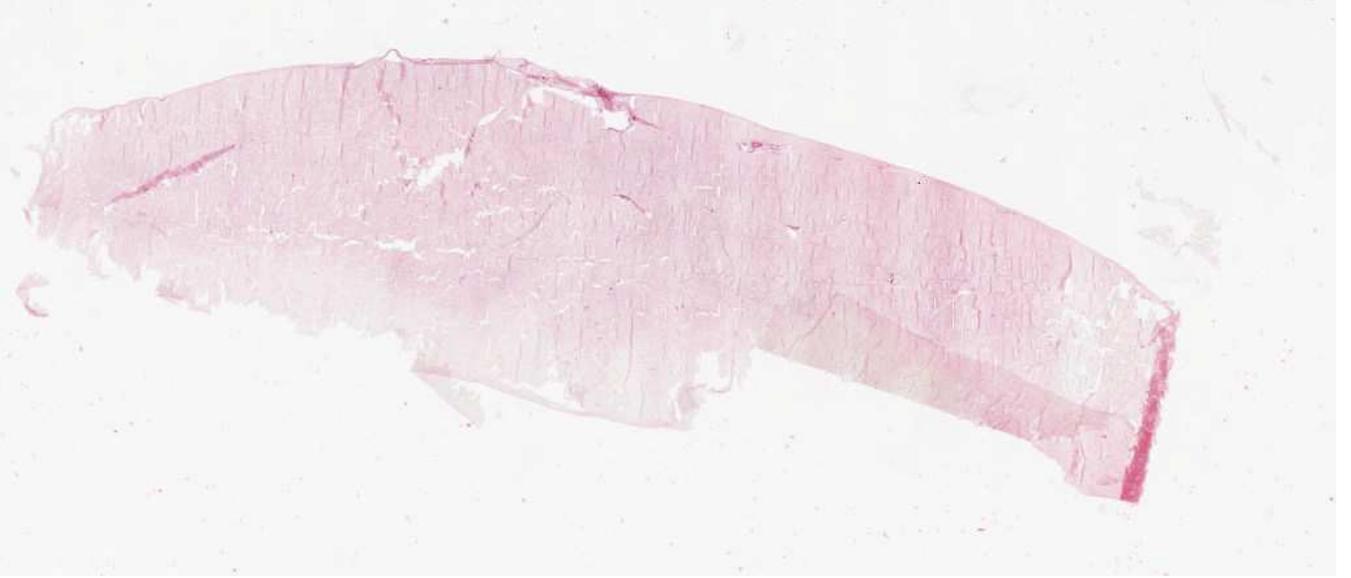


FIGURE 4.2 – Exemple d’image de tendons à plus faible résolution.

approches interactives de segmentation d’image ont été proposées récemment. Celles-ci reformulent la segmentation d’image en une stratégie de propagation de labels ([WZSW06], [Gra06], [SG07], [ZS05], [BNS06]). La régularisation discrète présentée précédemment peut être adaptée naturellement à ce problème d’apprentissage pour la segmentation par régularisation de label.

Afin d’adapter la précédente régularisation discrète à la régularisation de labels, il faut reformuler le problème. La régularisation d’un ensemble de sommets V composé de données labélisées et non labélisées consiste à grouper l’ensemble complet V en k classes, avec k le nombre de classes connu à l’avance. Le but est par conséquent d’estimer les données non labélisées à partir des données labélisées.

Soit $C = \{c_i\}_{i=1,\dots,k}$ l’ensemble des sommets initialement labélisés et $V \setminus C$ les sommets initialement non labélisés. Cette situation peut être modélisée en considérant k fonctions de labels initiales (une par classe) $f_i^0 : V \rightarrow \mathbb{Z}$; avec $i = 1, \dots, k$. Pour un sommet donné $u \in V$, si u est initialement labélisé alors

$$f_i^0(u) = \begin{cases} +1, & \text{si } u \in c_i \\ -1, & \text{sinon.} \end{cases} \quad (4.8)$$

Si u est initialement non labélisé, alors $f_i^0(u) = 0$. Ensuite, la labellisation des sommets est effectuée par k procédés de régularisation estimant les fonctions membres $f_i : V \rightarrow \mathbb{R}$ pour chaque



FIGURE 4.3 – Image simplifiée par régularisation p-Laplacienne avec $p = 1$, $\sigma = 15$.

classe i . En utilisant la régularisation discrète précédemment proposée, ceci est formalisé tel que :

$$\min_{f_i \in \mathcal{H}(V)} \left\{ R_{w,p}(f_i) + \frac{\lambda}{2} \|f_i - f_i^0\|^2 \right\}, \quad (4.9)$$

Nous utilisons le processus de diffusion discrète (4.7) pour calculer chaque minimisation. A la fin du procédé de propagation de labels, la probabilité que chaque sommet appartienne à une classe donnée peut être estimée. On procède d'abord à la normalisation de $f_i(u)$ afin que les valeurs soient comprises entre 0 et 1 : $f_i(u) = \frac{f_i(u)+1}{2}$. La classification finale peut ensuite être obtenue pour un sommet donné $u \in V$ par la formulation suivante. Pour tout $i \in 1, \dots, k$, le label assigné à un sommet u est :

$$\arg \max_i \left\{ f_i(u) / \sum_i f_i(u) \right\} \quad (4.10)$$

4.2.5 Segmentation de l'image

Comme nous l'avons vu dans la section précédente, le but est d'abord d'identifier la zone de tissu dans l'image à plus faible résolution. Il s'agit ici de proposer une segmentation automatique de l'image (figure 4.2).

Nous avons choisi de simplifier l'image par régularisation laplacienne sur graphe avec $p = 1$, $w(u, v)$ un noyau gaussien avec $\sigma = 15$; celle-ci conservant bien les contours (figure 4.3), pour faciliter une segmentation non supervisée par l'algorithme des k-moyennes sur l'histogramme RGB de l'image



FIGURE 4.4 – Image filtrée segmentée avec l’algorithme des k-moyennes.

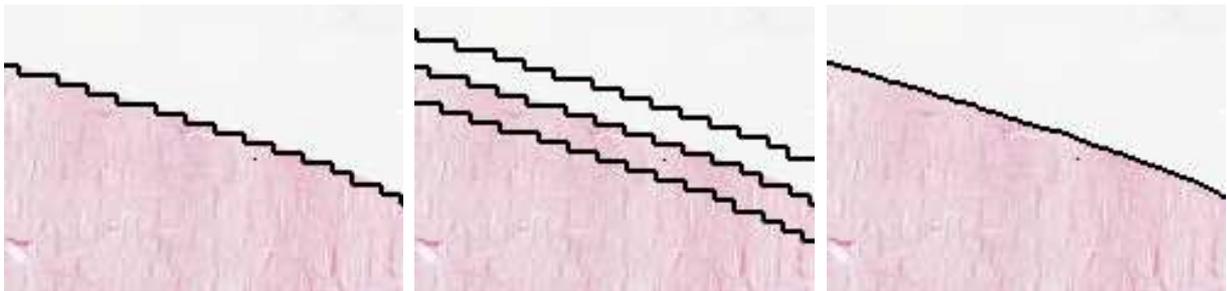


FIGURE 4.5 – Raffinement des bords par régularisation discrète des labels autour des frontières précédemment obtenues par k-moyennes.

afin d’extraire la zone de tissu de celle du fond.

La figure 4.1 montre l’effet de la régularisation d’une image sur son histogramme RGB. On peut voir le résultat de la segmentation de l’image filtrée par un k-moyennes sur la figure 4.4. Optionnellement, si on juge que la segmentation n’est pas assez bonne, on peut utiliser une segmentation par régularisation discrète sur une bande d’une certaine largeur autour des frontières définies par le k-moyennes, afin de raffiner les bords de la segmentation (figure 4.5). On s’aperçoit qu’il reste cependant des petites zones de tissu autour du tissu principal, ainsi que des trous au milieu de cette même zone. Afin d’éliminer ces zones parasites, nous avons d’abord procédé à un bouchage des trous, par reconstruction par érosion (figure 4.6), puis à une ouverture de l’image résultante (figure 4.7) suivi d’une reconstruction par dilatation de l’image ayant subi une ouverture dans l’image avec trous bouchés (figure 4.8). On peut voir les bords de la segmentation résultante projetés sur l’image sur la figure 4.9.

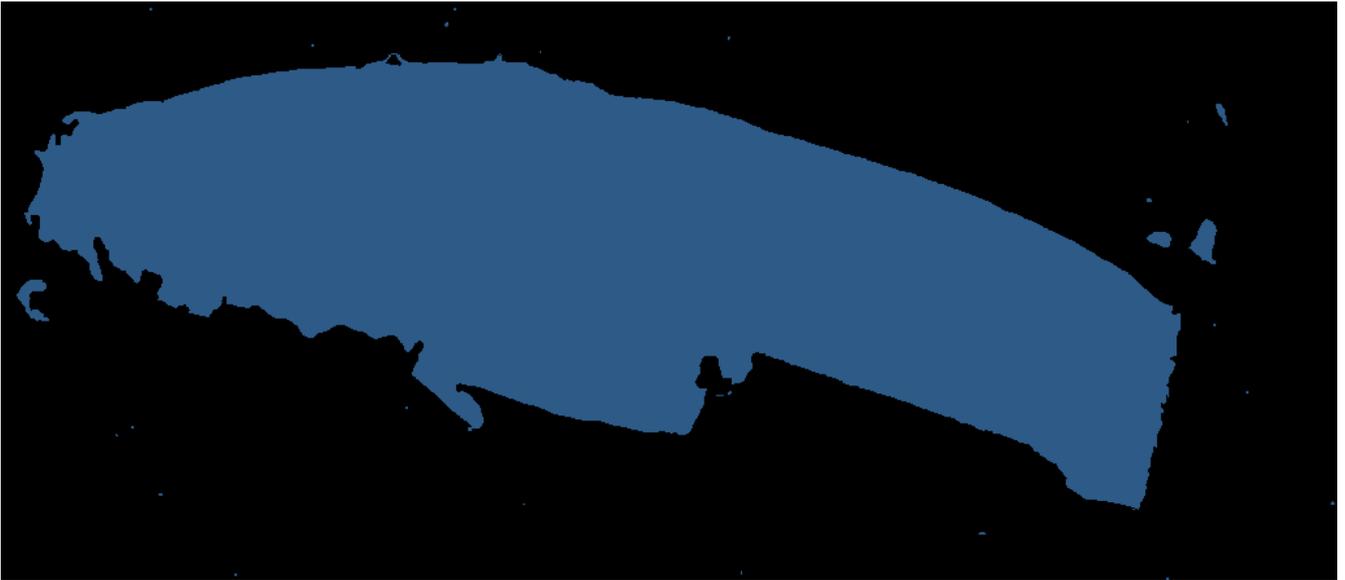


FIGURE 4.6 – Bouchage des trous dans la zone de tissu principale.

On peut résumer l'algorithme de segmentation à ces étapes :

- Simplification de l'image par régularisation p-laplacienne sur graphe,
- Classification par k-means de l'histogramme de l'image,
- Bouchage des trous par reconstruction par érosion,
- Suppression des zones de tissus non significatives par une ouverture suivi d'une reconstruction par dilatation.

4.3 Traitement à plus haute résolution

Maintenant que nous avons extrait la zone à analyser, le but est de pouvoir classifier les tuiles de l'image à plus haute résolution, afin de déterminer les tuiles contenant du tendon sain et les tuiles contenant du tendon lésé. Pour ce faire, nous nous sommes basés sur les critères visuels qu'utilise le vétérinaire (alignement, organisation, ondulation des fibres de collagène, morphologie et densité des cellules fibroblastes, etc.) comme l'illustre la figure 4.10. Dans les sous sections suivantes, nous parlerons de l'extraction de certaines de ces caractéristiques. Nous avons choisi de les extraire pour chaque tuile de l'image, puis de créer une matrice de similarité à partir des vecteurs de caractéristiques extraits, dans le but de pouvoir classifier chaque tuile par la suite.

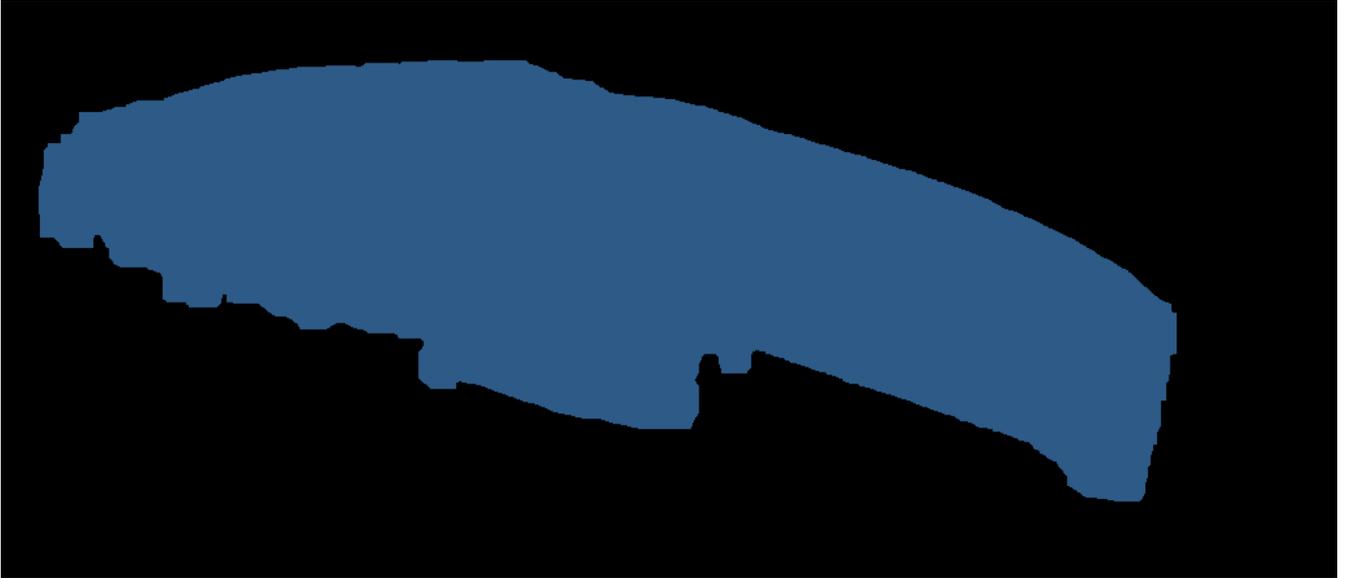


FIGURE 4.7 – Image avec trous bouchés ayant subi une ouverture.

4.3.1 Caractéristiques de texture

Comme on peut le voir sur la figure 4.10, la texture d’un tendon est bien plus homogène lorsque l’image représente du tissu sain que lorsque l’on a affaire à du tissu lésé. C’est pourquoi nous avons choisi d’extraire les caractéristiques de texture de chaque tuile de l’image.

Nous avons utilisé pour ce faire le ”Multiresolution Gray-Scale and Rotation Invariant Texture Classification with Local Binary Patterns” ([OPM02]). Dans cet article, les auteurs proposent une approche basé sur les LBP, théoriquement simple et qui ne requiert pas beaucoup de puissance de calcul, qui est robuste en terme de variation aux échelles de gris, et qui discrimine efficacement un grand nombre de textures ayant subi des rotations. L’invariance aux échelles de gris est souvent importante, à cause des illuminations inégales.

Les auteurs commencent la présentation de leur opérateur invariant aux changements d’échelles de gris et aux rotations en définissant une texture T dans un voisinage local d’une image monochrome comme la distribution jointe des niveaux de gris de P ($P > 1$) pixels de l’image :

$$T = t(g_c, g_0, \dots, g_{P-1}) \quad (4.11)$$

ou la valeur de gris g_c correspond à la valeur du pixel central du voisinage local et g_p ($p = 0, \dots, P - 1$) correspond aux valeurs de gris de P pixels également espacés sur un cercle de rayon R ($R > 0$) qui forme un ensemble de voisins circulairement symétrique. Si les coordonnées de g_c sont $(0, 0)$, alors les coordonnées de g_p sont données par $(-R \sin(2\pi p/P), R \cos(2\pi p/P))$. La figure 4.11 montre des ensembles de voisins symétriques circulairement pour différent (P, R) . Les valeurs de

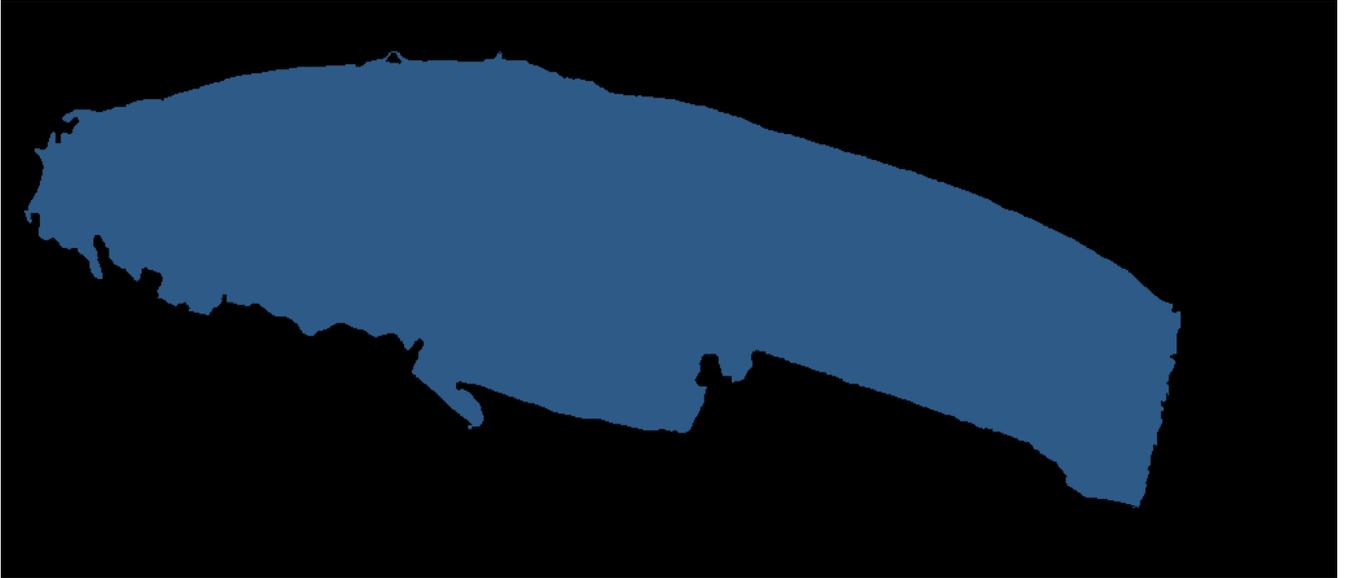


FIGURE 4.8 – Reconstruction de l’image ayant subi une ouverture dans l’image avec trous bouchés.

niveaux de gris qui ne tombent pas exactement sur un centre de pixel sont estimées par interpolation.

4.3.1.1 Invariance aux changements d’échelles de niveaux de gris

Avant de montrer l’invariance aux changements d’échelles de niveaux de gris, les auteurs de l’article transforment leur définition d’une texture en soustrayant, sans perte d’informations, la valeur de gris du pixel central (g_c) aux valeurs de gris du voisinage symétrique circulaire g_p ($p = 0, \dots, P-1$), ce qui donne :

$$T = t(g_c, g_0 - g_c, \dots, g_{P-1} - g_c) \quad (4.12)$$

Ensuite, les auteurs supposent que les différences $g_p - g_c$ sont indépendantes de g_c , ce qui leur permet de factoriser 4.12 en :

$$T \approx t(g_c)t(g_0 - g_c, \dots, g_{P-1} - g_c) \quad (4.13)$$

En pratique, une indépendance exacte n’est pas garantie, la distribution factorisé est seulement une approximation de la distribution jointe. Néanmoins, la perte d’information est acceptable, celle-ci permettant d’arriver à l’invariance par rapport aux changements d’échelles de niveaux de gris. La distribution $t(g_c)$ dans 4.13 décrit l’ensemble de la luminance de l’image, ce qui n’est pas lié à la texture locale de l’image et ne fournit pas d’information utiles dans le cadre de l’analyse de texture. De là, la majeure partie de l’information dans la distribution jointe des niveaux de gris

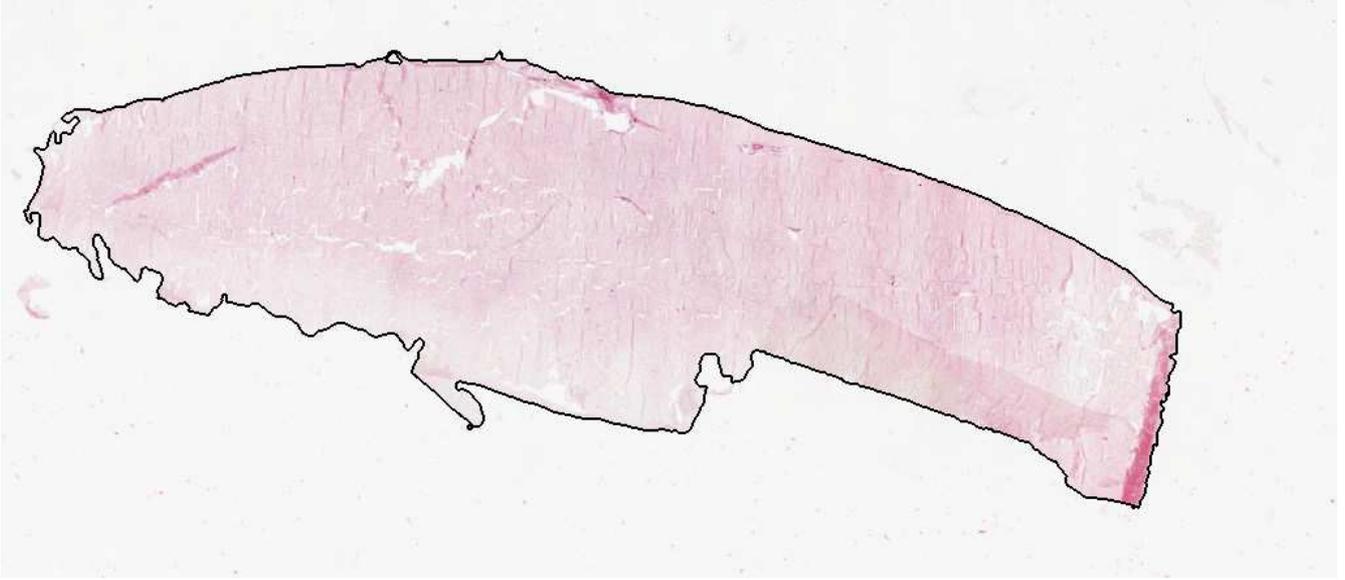


FIGURE 4.9 – Bords de la segmentation projetée sur l'image.

initiale (4.11) concernant les caractéristiques de textures est véhiculée par la distribution jointe des différences ([OVOP01]) :

$$T \approx t(g_0 - g_c, \dots, g_{P-1} - g_c) \quad (4.14)$$

Les différences signées $g_p - g_c$ ne sont pas affectées par les changements de luminances moyennes : la distribution jointe des différences est invariante par rapport aux changements d'échelles des niveaux de gris. L'invariance par rapport à l'échelle des niveaux de gris est obtenue en ne gardant que le signe des différences au lieu de prendre leurs valeurs exactes :

$$T \approx t(s(g_0 - g_c), \dots, s(g_{P-1} - g_c)). \quad (4.15)$$

avec :

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0. \end{cases} \quad (4.16)$$

En assignant un facteur binomial 2^p pour chaque signe $s(g_p - g_c)$, on peut transformer (4.15) en un nombre unique $LBP_{P,R}$ qui caractérise la structure spatiale de la texture locale de l'image :

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p. \quad (4.17)$$

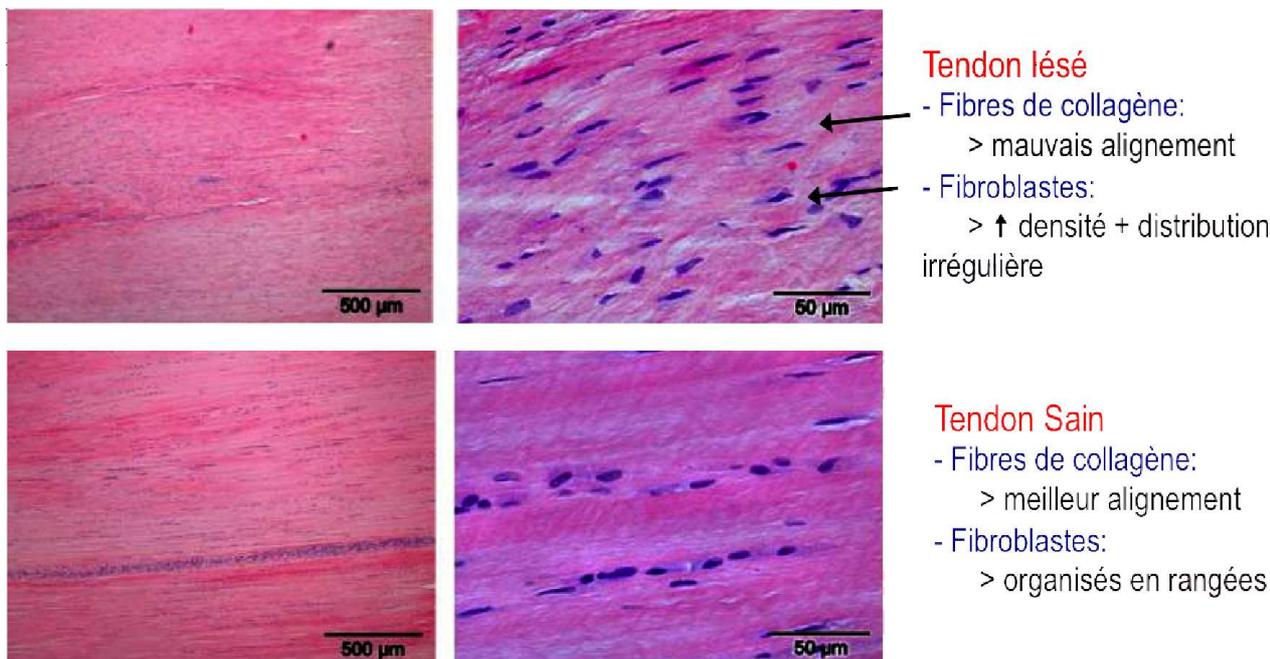


FIGURE 4.10 – Illustration des critères histologiques pour évaluer les lésions tendineuses.

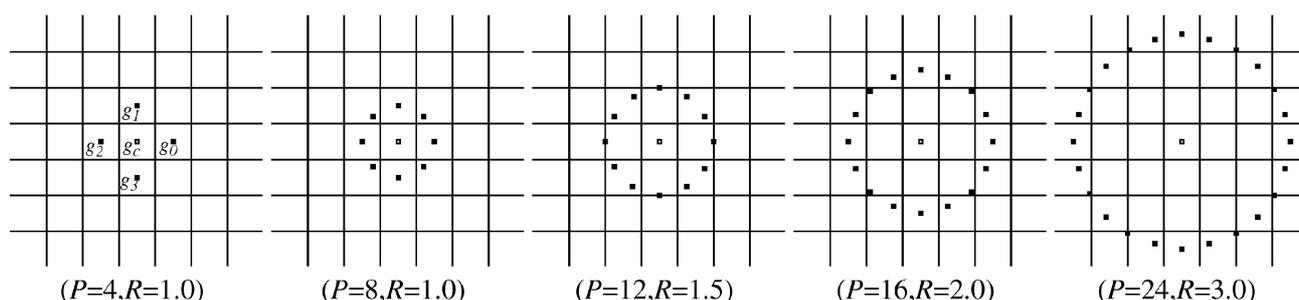


FIGURE 4.11 – Ensemble de voisins circulairement symétriques pour différents (P, R) .

Nous avons ici un opérateur qui agit sur le voisinage local d'un pixel central, pour en ressortir une structure binaire, d'où son nom "Local Binary Pattern". Cet opérateur est par définition invariant à toutes transformations monotones d'échelle de gris.

4.3.1.2 Invariance aux rotations

L'opérateur $LBP_{P,R}$ produit 2^P résultats différents, correspondant aux 2^P différents patterns qui peuvent être formés par les P pixels dans l'ensemble des voisins. Quand l'image subit une rotation, les valeurs de gris g_p vont se déplacer en conséquence le long du périmètre du cercle autour de g_0 . Puisque g_0 est toujours la valeur de gris de l'élément $(0, R)$ à droite de g_c , la rotation d'un pattern binaire particulier aura comme résultat une autre valeur de $LBP_{P,R}$. Ceci ne s'applique pas

aux patterns ne contenant que des 0 ou des 1, qui restent constant à tous les angles de rotations. L'opérateur suivant permet de supprimer les effets de la rotation [OPM02] :

$$LBP_{P,R}^{ri} = \min\{ROR(LBP_{P,R}, i) | i = 0, 1, \dots, P - 1\}, \quad (4.18)$$

ou $ROR(x, i)$ effectue une rotation à droite des P -bits de x , i fois. En terme de pixels, cela correspond à effectuer des rotation de l'ensemble des voisins dans le sens horaire autant de fois que nécessaire afin d'obtenir le nombre maximal de 0 à partir du msb (Most Significant Bit) du nombre obtenu par $LBP_{P,R}$. L'opérateur $LBP_{P,R}^{ri}$ quantifie les statistiques d'apparition de schémas de rotation individuels invariant, correspondant à certaines micro-caractéristiques dans l'image ; on peut considérer les patterns comme des détecteurs de caractéristiques. La figure 4.12 montre les 36 schémas binaires uniques invariant à la rotation qui peuvent apparaître pour $P = 8$. Par exemple le schéma #0 détecte les points brillants, #8 les points sombres et les zones plates et #4 les arêtes.

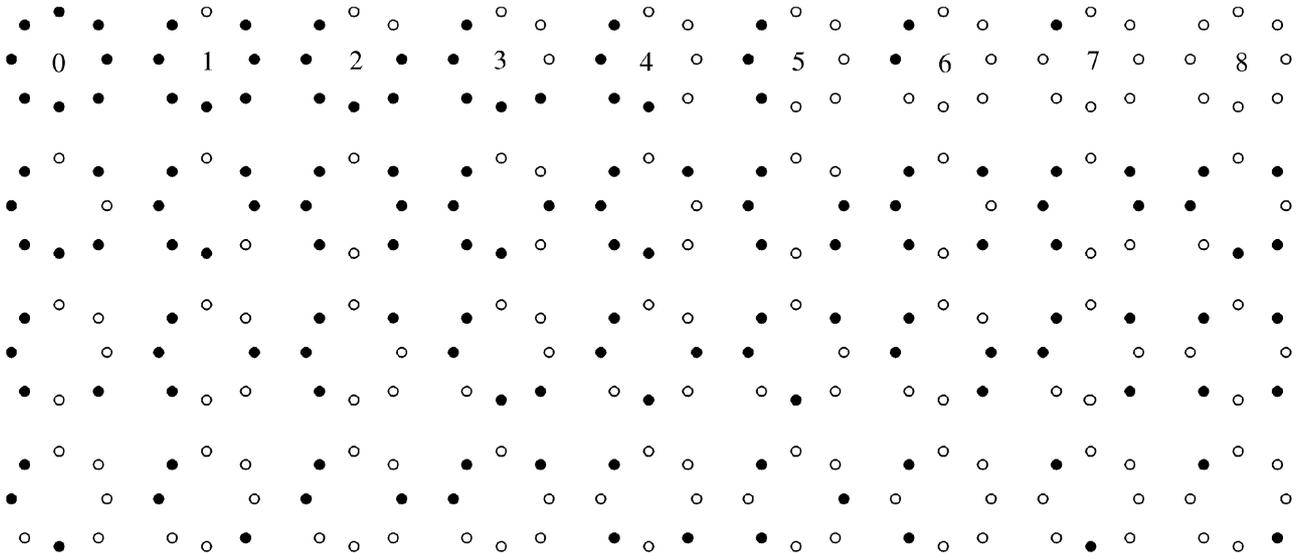


FIGURE 4.12 – Les 36 schémas binaires uniques invariant à la rotation qui peuvent apparaître dans l'ensemble des voisins circulairement symétrique de $LBP_{8,R}^{ri}$. Les cercles noirs et blancs correspondent à la valeur 0 et 1 des bits du résultat de l'opérateur.

4.3.1.3 Extraction de ces caractéristiques

Nous avons extrait, pour chaque tuile de l'image, l'histogramme normalisé de $LBP_{8,1}^{ri}$, chaque entrée de l'histogramme correspondant à l'un des 36 schémas décrit dans la figure 4.12. Une fois ces histogrammes créés pour chacune des tuiles, nous avons créé une matrice de distance de taille $N \times N$

avec N le nombre de tuiles, avec comme mesure de distance le χ^2 :

$$d(h_1, h_2) = \sum_{i=1}^N \frac{[h_1(i) - h_2(i)]^2}{h_1(i) + h_2(i)}. \quad (4.19)$$

Cette mesure de distance étant appliquée à chaque paire d'histogramme correspondant à une entrée de la matrice de distance. Nous verrons par la suite à quoi nous sert cette matrice de distance.

4.3.2 Caractéristiques de graphes

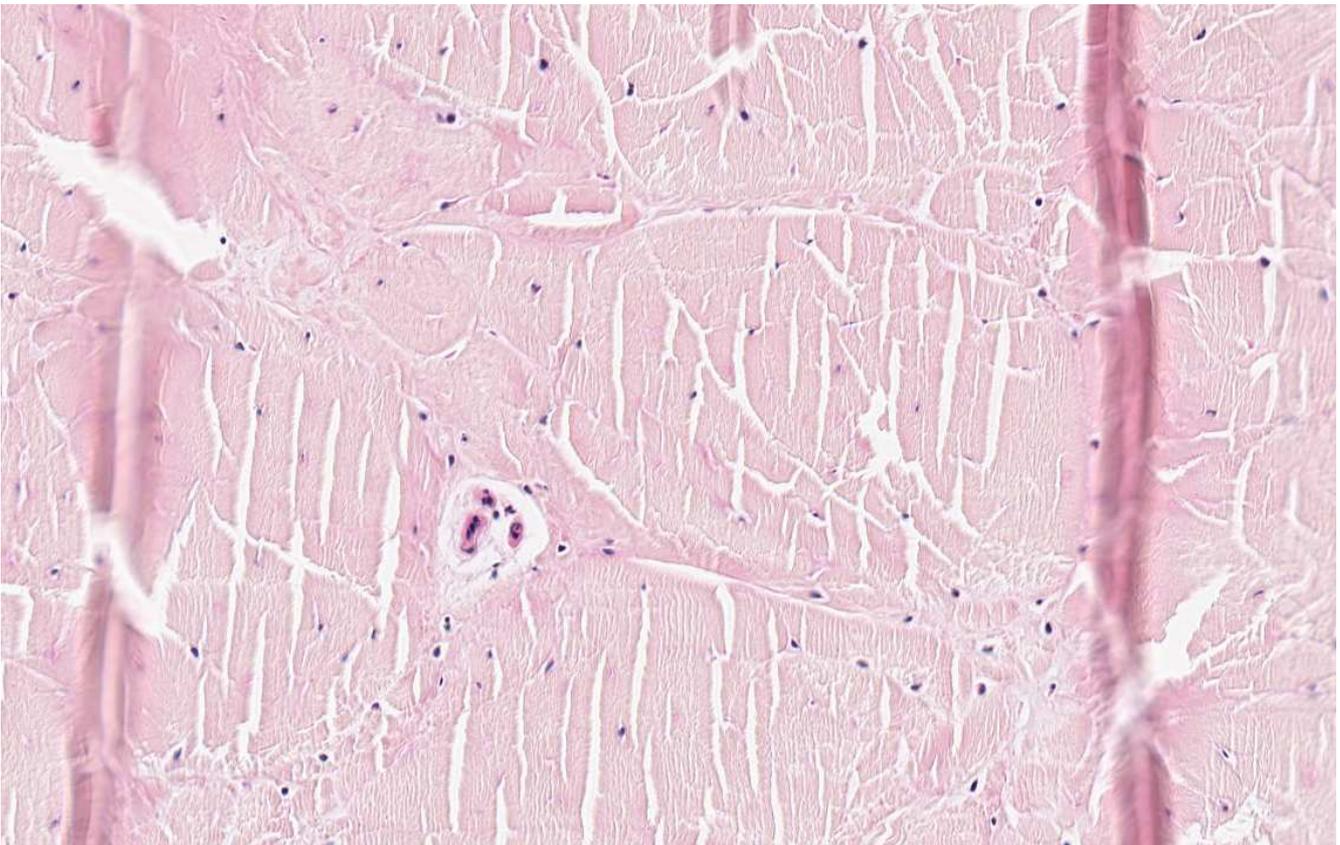


FIGURE 4.13 – Exemple d'image d'entrée pour la segmentation des fibroblastes.

4.3.2.1 Extraction des fibroblastes

Certaines caractéristiques histologiques visuelles sont liées aux fibroblastes. Afin de pouvoir "mimer" l'étude du vétérinaire, nous avons décidé de segmenter les tuiles à haute résolution afin d'en extraire les pixels concernant les fibroblastes. Nous avons ici utilisé une caractéristique de la lame : les teintes utilisées pour faire ressortir les fibroblastes et les autres zones de tissus. Les lames

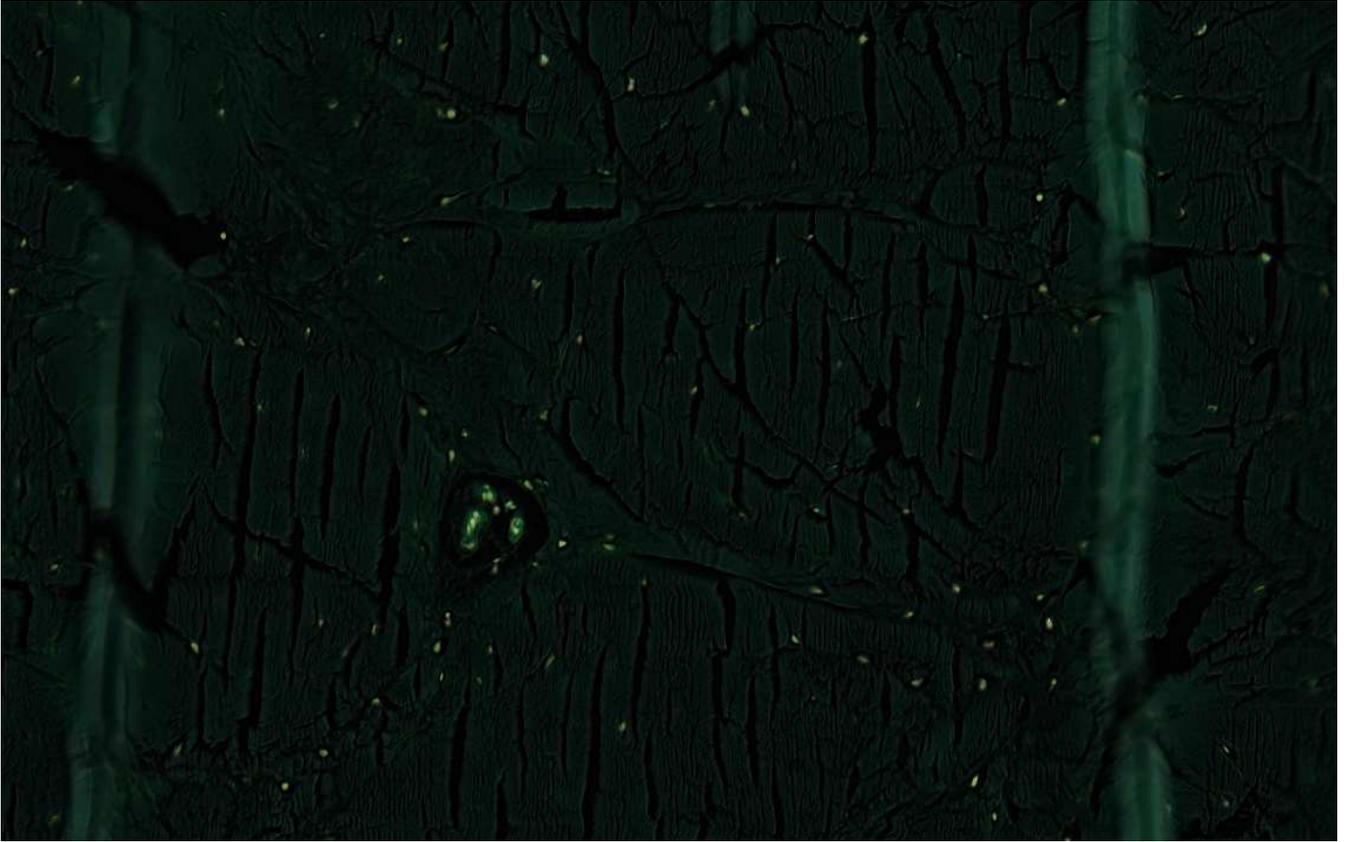


FIGURE 4.14 – Image de densité optique.

histologiques de coupes de tendons de chevaux sont teintées avec les colorants réactifs hématoxyline et éosine. Nous avons utilisé la déconvolution couleur [RJ01]. Il faut pour ceci, convertir les valeurs RGB de l'image en leur valeurs de densité optique (OD) correspondante :

$$OD = -\log_{10}(I) \quad (4.20)$$

avec I le vecteur couleur RGB dont les composantes sont normalisés entre $[0, 1]$. Cette transformation nous fournit un espace où une combinaison linéaire de teintes se traduira par une combinaison linéaire des valeurs de OD . Ensuite, on peut appliquer une déconvolution couleur [RJ01] :

$$OD = VS \Rightarrow S = V^{-1}OD \quad (4.21)$$

avec OD la densité optique observée, V et S sont respectivement les matrices de vecteurs de teintes et de saturation de chaque teintes. La matrice V est connu à priori (de part les colorants utilisés qui sont connus). La figures 4.13 illustre une image d'entrée possible. La figure 4.14 montre la densité optique obtenue, et la figure 4.15 montre la saturation optique de la teinte hématoxyline. Nous avons ensuite procédé à un seuillage automatique (figure 4.16) de l'image de saturation optique.

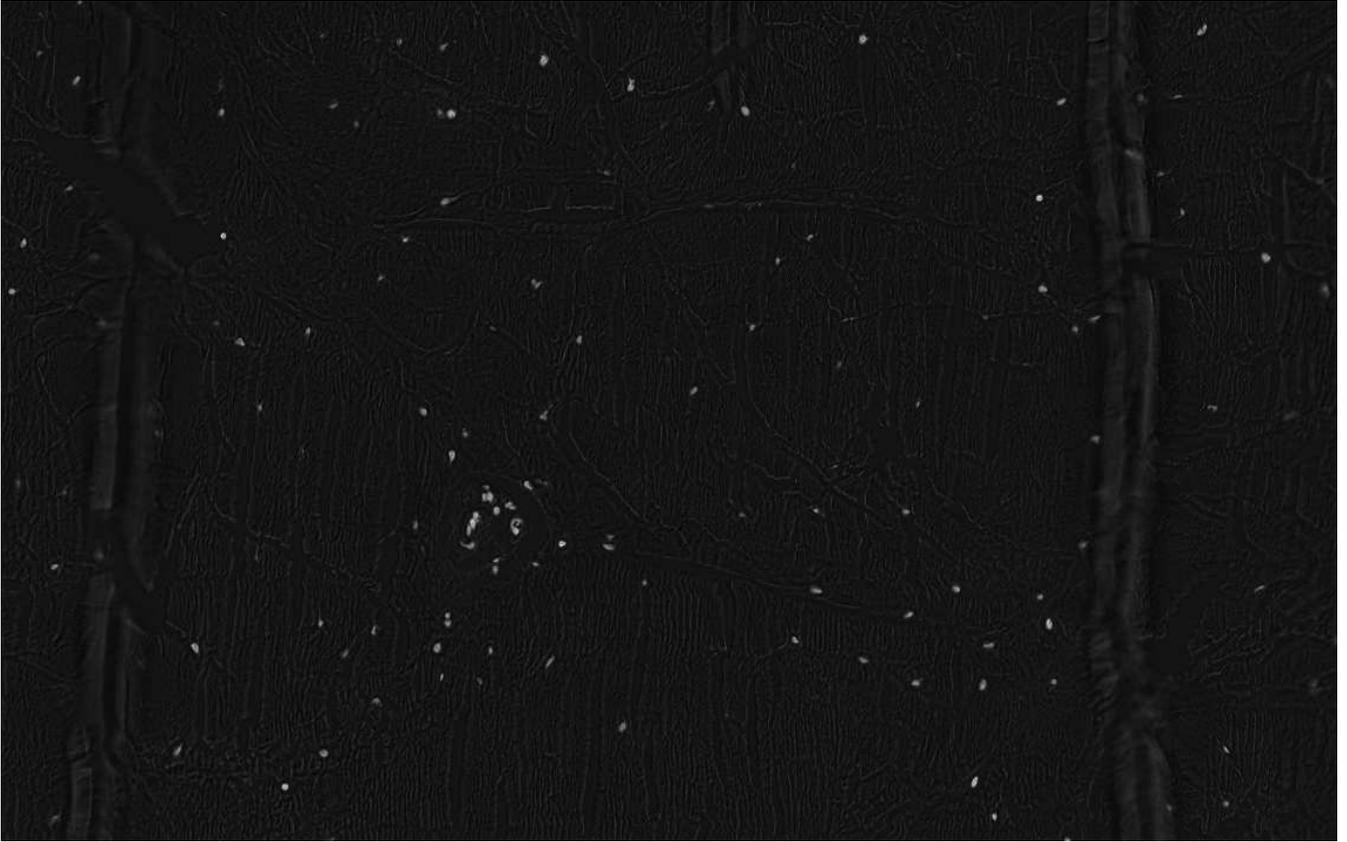


FIGURE 4.15 – Saturation optique.

4.3.2.2 Caractéristiques de graphes et de fibroblastes

Une fois les fibroblastes extraits, nous allons nous intéresser à leurs formes et arrangements, cette architecture pouvant être quantifié en utilisant des techniques basées sur les graphes [DAM⁺08]. Pour utiliser les graphes, nous prenons simplement les centroïdes des fibroblastes extraits, que nous noterons c^1, c^2, \dots, c^m , avec m le nombre de fibroblastes extraits.

Diagramme de Voronoi - Le diagramme de Voronoi \mathbf{V} comprend un ensemble de polygones $\mathbf{P} == \{P_1, P_2, \dots, P_m\}$. Chaque centroïde c est inclus dans un polygone P_a si $\mathbf{d}(c, c^a) = \min_j \{\|c - c^j\|\}$ avec $a, j \in \{1, 2, \dots, m\}$ et $\mathbf{d}(c, d)$ la distance Euclidienne entre deux centroïdes c, d . Nous avons ici extrait la moyenne et la mesure de désordre définie par : $1 - \frac{1}{1 + \frac{\text{écart type}}{\text{moyenne}}}$ [SMR00] de l'aire de chaque polygone de $\mathbf{P} \in \mathbf{V}$, pour chaque tuile de l'image.

Triangulation de Delaunay - Le graphe de Delaunay \mathbf{D} est construit tel que deux centroïdes uniques c^a et c^b , ou $a, b \in \{1, 2, \dots, m\}$, sont connectés par une arête $E^{a,b}$ si P_a et P_b partagent un coté dans \mathbf{V} . Nous avons ici extrait la moyenne, la mesure de désordre et le maximum de la longueur de chaque arête pour chaque triangle dans \mathbf{D} , pour chaque tuile de l'image.

Arbre de recouvrement de poids minimal - Soit un graphe connexe, non orienté ; un



FIGURE 4.16 – Segmentation par seuillage automatique.

arbre de recouvrement \mathbf{S} de ce graphe est un sous graphe qui connecte tous ses m sommets avec $m - 1$ arêtes. Un graphe peut avoir de multiples \mathbf{S} . Des poids $w_{\mathbf{S}}^E$ sont assignés à chaque arête E dans chaque \mathbf{S} basé sur la longueur de E dans \mathbf{S} . La somme de tous les poids $w_{\mathbf{S}}^E$ dans chaque \mathbf{S} est calculée pour donner le poids $\hat{w}_{\mathbf{S}}$ assigné à chaque \mathbf{S} . L'arbre de recouvrement de poids minimal (Minimum Spanning Tree, MST), noté \mathbf{S}' , a un poids $\hat{w}'_{\mathbf{S}}$ inférieur ou égal à $\hat{w}_{\mathbf{S}}$ pour tous les autres arbres de recouvrement \mathbf{S} . Nous avons extrait la moyenne et la mesure de désordre de la longueur de chaque arête du MST, pour chaque tuile de l'image.

Élongation des fibroblastes - La forme des fibroblastes est aussi très importante pour la classification. Nous avons utilisé comme descripteur de forme l'élongation des fibroblastes. Les notations suivantes sont utilisées : I_S l'image des régions segmentée, o le label de la région à caractériser, $p(x, y)$ un point de l'image, $I_S(p)$ la valeur du pixel p dans l'image I_S . L'élongation d'un objet o est donnée par la formule suivante :

$$Elongation(o) = \frac{\sqrt{|M_x - M_y|} + 4M_{xy}}{Surface(o)} \quad (4.22)$$



FIGURE 4.17 – Résultat de la segmentation projeté sur l'image d'entrée.

avec

$$Surface(o) = Card\{p \in I_S / I_S(p) = o\} \quad (4.23)$$

et

$$\begin{aligned} M_x &= \frac{1}{Surface(o)} \sum_{i=1}^{Surface(o)} (x_i^2 - x_g^2) \\ M_y &= \frac{1}{Surface(o)} \sum_{i=1}^{Surface(o)} (y_i^2 - y_g^2) \\ M_{xy} &= \frac{1}{Surface(o)} \sum_{i=1}^{Surface(o)} (x_i y_i - x_g y_g) \end{aligned} \quad (4.24)$$

La moyenne et la mesure de désordre sont calculées sur cette mesure d'élongation pour chaque tuile de l'image.

En prenant en compte les caractéristiques extraites du diagramme de Voronoi, de la triangulation de Delaunay, du minimum spanning tree et de l'élongation des fibroblastes, nous avons donc extrait ici neuf caractéristiques par tuile de l'image. Comme précédemment pour les caractéristiques de textures, nous créons une matrice de distance de taille $N \times N$ avec N le nombre de tuiles, avec comme mesure de distance la distance euclidienne entre les vecteurs de caractéristiques normalisés extraits.

Nous avons vu dans cette section comment extraire des caractéristiques d'arrangement spa-

tiales ainsi que de forme des fibroblastes, ceci dans le but de mimer la démarche d'analyse du vétérinaire. Dans la section suivante, nous verrons comment extraire l'alignement des fibroblastes, qui est aussi une caractéristique visuelle utile à l'évaluation des lésions tendineuses.

4.3.3 Alignements des cellules

L'alignement des cellules est aussi une caractéristique histologique visuelle à prendre en compte afin de classifier les coupes de tendons (figure 4.10). Nous avons pour ceci adapté l'algorithme de [VBI10] pour des nuages de points dans le plan. Le nuage de points que nous prenons en compte ici est constitué des centroïdes des fibroblastes extraits précédemment.

Définition d'un alignement - Soit $\mathcal{A} = \{a_1, \dots, a_n\}$ un groupe de points dans \mathbb{R}^2 . \mathcal{A} est aligné si et seulement si :

- Il existe une ligne L qui intersecte tous les points, ou
- Il existe un angle $\theta \in [0, \pi)$ tel que pour toutes paire de points a_i et $a_j (i \neq j)$, a_j se trouve dans la direction θ ou $\theta + \pi$ de a_i , par rapport à l'axe horizontal.

L'algorithme de [VBI10] se base sur une mesure de distance d'histogramme d'angle entre deux objets, nous avons ici utilisé la mesure de l'angle entre deux objets par rapport à l'axe horizontal. L'algorithme est basé sur un graphe de voisinage, nous avons choisi ici d'utiliser un k plus proches voisin, basé sur la distance spatiale entre deux points, que nous appellerons G dans l'algorithme (figure 4.18). Afin de pouvoir quantifier l'alignement entre paires de points, nous avons créé le dual de ce graphe, que nous appellerons \tilde{G} . Ainsi, les sommets de G deviennent les arêtes de \tilde{G} , et les arêtes G deviennent les sommets de \tilde{G} . Le pseudo code de l'algorithme adapté est présenté ci dessous 1 :

La figure 4.18 illustre l'étape 1 de l'algorithme 1, ou on peut y voir, à gauche, le graphe de voisinage construit à partir des points dans le plan, au milieu ce même graphe pondéré par les angles entre chaque arête et l'axe horizontal (valeurs en radians), on peut y voir deux valeurs par arête, celles-ci représentent les angles quand on parcourt les arêtes dans un sens et dans le sens opposé. Ce graphe est appelé G dans l'algorithme 1. À droite, le graphe dual \tilde{G} est pondéré par la différence entre deux arêtes de G . Cette différence représente la distance entre chaque arêtes de G . La figure 4.19 représente, à gauche, le graphe \tilde{G} où seul les arêtes inférieures à β ont été retenues (étape 2 de l'algorithme), appelé \tilde{G}_{TH} dans l'algorithme 1 et, à droite, l'ensemble des composantes connexes \mathfrak{C} de \tilde{G}_{TH} (étape 3 de l'algorithme). Une fois que l'on a \tilde{G}_{TH} , on a déjà les alignements dont l'angle est inférieur à β . On va ensuite chercher à élaguer chaque composantes connexes (boucle à l'étape 4 de l'algorithme). Sur la figure 4.20 on peut voir à gauche une composante connexe et à droite cette composante connexe avec toutes les arêtes du graphe d'origine \tilde{G} . Dans le but d'obtenir une composante connexe totalement alignée, on va retirer les sommets dont le degré est le maximum de la composante connexe (étapes 7 à 10), tant que le poids maximal des arêtes (étape 5) de cette

Algorithm 1 En entrée : seuil d'alignement β

```
1: Construire  $G$  et  $\tilde{G}$  (figure 4.18)
2: Construire  $\tilde{G}_{TH} = (\tilde{V}, \tilde{E}_{TH})$  ou  $\tilde{E}_{TH} = \{(i, j) \in E | \tilde{e}_{ij} < \beta\}$  (figure 4.19)
3: Trouver l'ensemble des composantes connexes  $\mathfrak{C}$  de  $\tilde{G}_{TH}$  (figure 4.19)
4: for all  $\mathcal{C}_k \in \mathfrak{C}$  (figure 4.20) do
5:    $cons(\mathcal{C}_k) = \max \{\tilde{w}_{ij} | \tilde{v}_i, \tilde{v}_j \in \mathcal{C}_k\}$  (figure 4.20)
6:   while  $cons \geq \beta$  et  $|\mathcal{C}_k| \geq 2$  do
7:     for all  $\tilde{v}_i \in \mathcal{C}_k$  do
8:        $deg_i = \frac{\sum_{\tilde{v}_j \in \mathcal{C}_k} \tilde{s}_{ij}}{|\{(i, j) | \tilde{v}_j \in \mathcal{C}_k\}|}$ 
9:     end for
10:    Supprimer  $\tilde{v}_j$  de  $\mathcal{C}_k$  pour  $\tilde{v}_j = \max_{\tilde{v}_i \in \mathcal{C}_k} deg_i$  (figure 4.21)
11:    Mettre à jour  $cons$ 
12:    if  $cons < \beta$  then
13:      Ajouter  $\mathcal{C}_k$  à  $\mathfrak{L}$ 
14:    end if
15:  end while
16: end for
```

composante connexe est supérieur ou égal au seuil d'alignement β (boucle étape 6). La figure 4.21 montre ce processus, à gauche on a d'abord retiré le sommet $(2 - 4)$, puisqu'on peut voir sur la figure 4.20, à droite, que c'est ce sommet qui a le degré le plus élevé. Toujours sur la figure 4.21, à droite, on a retiré le sommet $(3 - 4)$ lors de la deuxième itération de l'étape 6 de l'algorithme 1 de la même façon.

La figure 4.22 illustre le résultat de l'algorithme 1 de détection d'alignements. La figure 4.23 illustre le résultat de cet algorithme sur un exemple d'image extrait d'une des images de coupe de tendon dont nous disposons. Une fois les alignements extraits, nous créons l'histogramme des angles par rapport à l'axe horizontal des alignements par tuiles de l'image à plus haute résolution, puis nous créons une matrice de distance entre chaque tuile comme précédemment en utilisant la distance du χ^2 .

4.4 Classification des tuiles

Dans cette section nous verrons comment, après avoir extrait des caractéristiques servant à évaluer visuellement les tendons et avoir créé des matrices de distances sur ces caractéristiques, combiner ces différentes mesures afin de pouvoir les utiliser pour classifier les tuiles à plus haute résolution des images de coupes de tendons. Nous avons pour ceci utilisé une technique multi-vues basée sur les tenseurs d'ordre 3 [LDLJ⁺]. Nous introduirons d'abord les notions de clustering spectral, puis nous verrons comment les auteurs de [LDLJ⁺] présentent le clustering simple vue puis multi-vues afin d'en arriver au clustering spectral multi-vues basé sur les tenseurs. Pour faciliter la

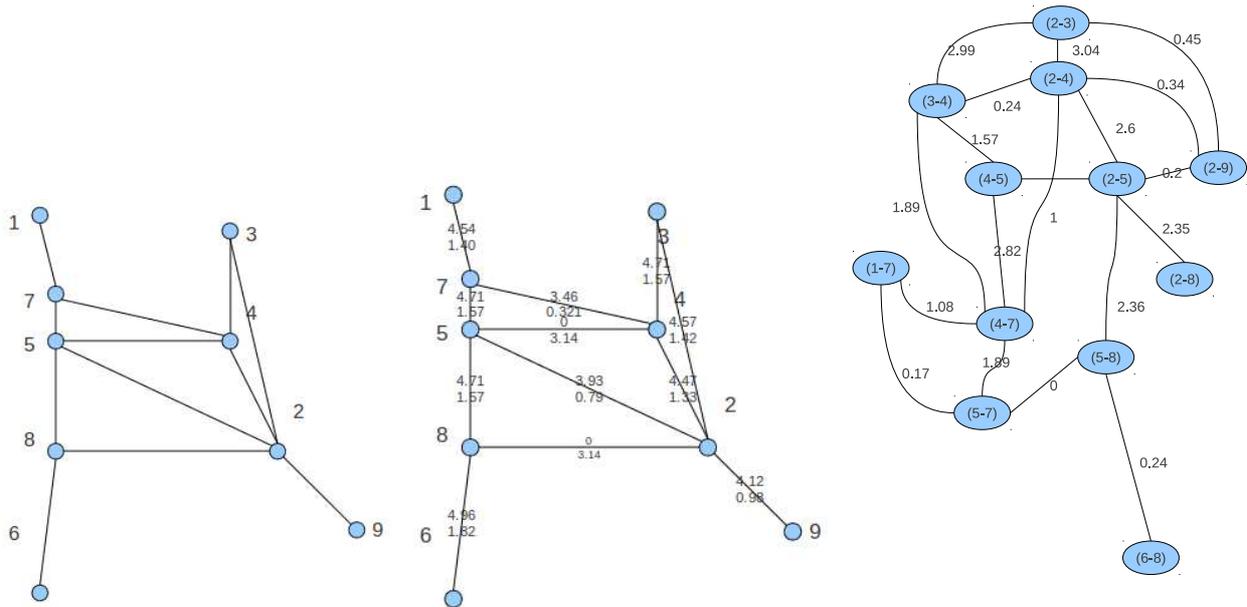


FIGURE 4.18 – De gauche à droite : exemple de graphe de voisinage, du graphe de voisinage pondéré par l’angle entre les arêtes et l’axe horizontal et de son dual pondéré par la différence d’angle entre deux arêtes du graphe initial pondéré pour l’algorithme de détection des alignements.

distinction entre les scalaires, vecteurs, matrices et tenseurs de plus haut ordre, nous utiliserons la même convention d’écriture que les auteurs de [LDLJ⁺], à savoir : les scalaires seront noté en lettres minuscules ($a, b, \dots; \alpha, \beta, \dots$), les vecteurs seront notés en lettres capitales italiques (A, B, \dots), les matrices seront notées en gras capital ($\mathbf{A}, \mathbf{B}, \dots$) et les tenseurs seront notés en lettres calligraphiques ($\mathcal{A}, \mathcal{B}, \dots$).

4.4.1 Clustering spectral

Étant donnée un ensemble de N points $\{x_i\}_{i=1}^N$, avec $x_i \in \mathbb{R}^d$ le i ème point, une similarité $s_{ij} \geq 0$ peut être définie pour chaque paire de points x_i et x_j , basée sur une mesure de similarité. Une façon intuitive de représenter cet ensemble de points est d’utiliser un graphe $G = (V, E)$ dans lequel les sommets V représentent les points et les arêtes $e_{ij} \in E$ caractérisent la similarité quantifiée par s_{ij} entre les points. Généralement, la mesure de similarité est symétrique, et le graphe est non orienté. La matrice d’affinité du graphe G est la matrice \mathbf{S} avec l’entrée ij $\mathbf{S}_{ij} = s_{ij}$. Le degré du sommet v_i , défini comme :

$$d_i = \sum_{j=1}^N s_{ij}, \tag{4.25}$$

est la somme des poids des arêtes connectées à v_i . La matrice des degrés \mathbf{D} est une matrice diagonale contenant les degrés des sommets d_1, \dots, d_N sur la diagonale. La matrice Laplacienne est définie

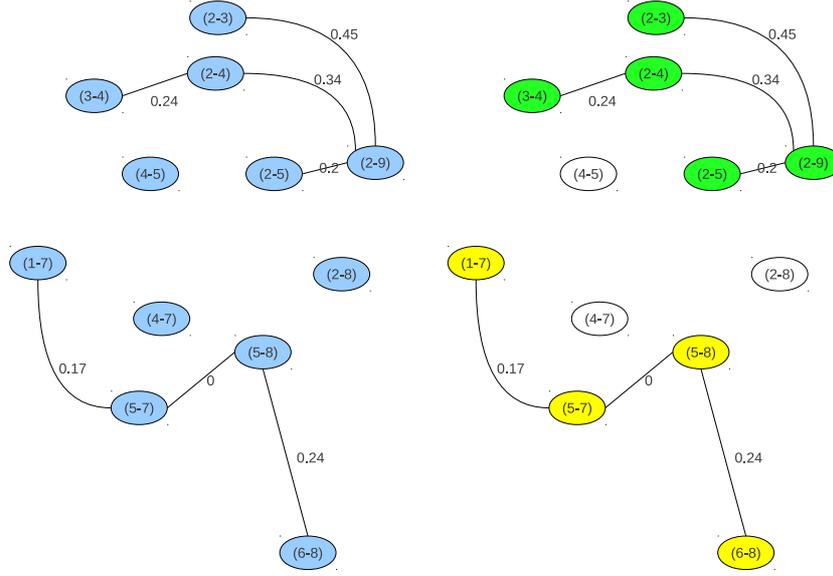


FIGURE 4.19 – De gauche à droite : exemple du graphe dual seuillé par β et des composantes connexes retenues.

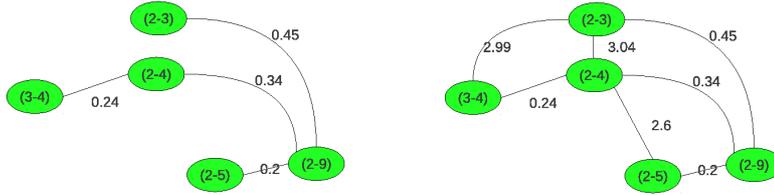


FIGURE 4.20 – De gauche à droite : première composante connexe C_1 de \mathfrak{C} et composante connexe avec toutes les arêtes afin de calculer $cons(\mathcal{C}_k)$.

comme $\mathbf{L} = \mathbf{D} - \mathbf{S}$, et la matrice Laplacienne normalisée, dont les vecteurs propres correspondent au critère de coupes normalisées (Ncut), est définie comme

$$\mathbf{L}_{Ncut} = \mathbf{D}^{-1/2} \mathbf{L} \mathbf{D}^{-1/2} = \mathbf{I} - \mathbf{S}_N, \quad (4.26)$$

avec \mathbf{S}_N la matrice de similarité normalisée et défini comme

$$\mathbf{S}_N = \mathbf{D}^{-1/2} \mathbf{S} \mathbf{D}^{-1/2}. \quad (4.27)$$

Les matrices \mathbf{S}_N et \mathbf{L}_{Ncut} ont les mêmes vecteurs propres et leurs valeurs propres ont la relation $\lambda(\mathbf{S}_N) = 1 - \lambda(\mathbf{L}_{Ncut})$, avec $\lambda(\mathbf{S}_N)$ et $\lambda(\mathbf{L}_{Ncut})$ les valeurs propres de \mathbf{S}_N et \mathbf{L}_{Ncut} respectivement.

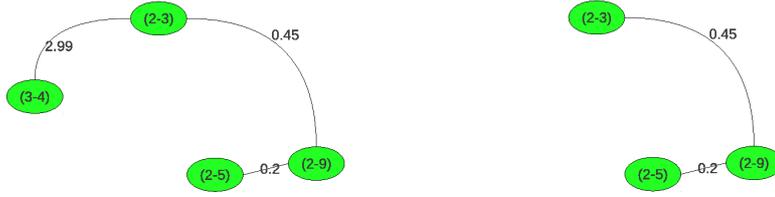


FIGURE 4.21 – De gauche à droite : suppression des sommets à la première et deuxième itération de l’algorithme pour la première composante connexe.

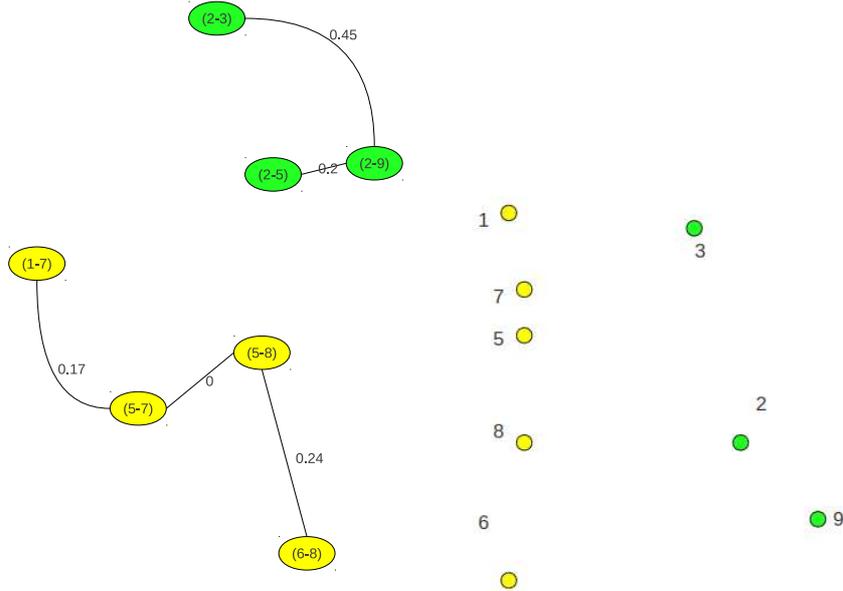


FIGURE 4.22 – De gauche à droite : composantes connexes restantes à la fin de l’algorithme et illustration des alignements correspondant pour les points du plan initial.

4.4.2 Clustering spectral simple vue

Nous allons d’abord considérer le clustering spectral en simple vue. Supposons que $\mathbf{U} \in \mathbb{R}^{N \times M}$ soit la matrice d’assignement relaxée, avec N le nombre de points et M le nombre de clusters. Le problème du clustering spectral peut s’écrire

$$\begin{aligned} \min_{\mathbf{U}} \operatorname{tr}(\mathbf{U}^T \mathbf{L}_{\text{Ncut}} \mathbf{U}), \\ \text{avec } \mathbf{U}^T \mathbf{U} = \mathbf{I}. \end{aligned} \tag{4.28}$$

D’après le théorème de Ki Fan [OW93], la solution optimale de (4.28) est donnée par les M premiers vecteurs propres de \mathbf{L}_{Ncut} . Si on considère la relation entre \mathbf{S}_N et \mathbf{L}_{Ncut} , la formulation du

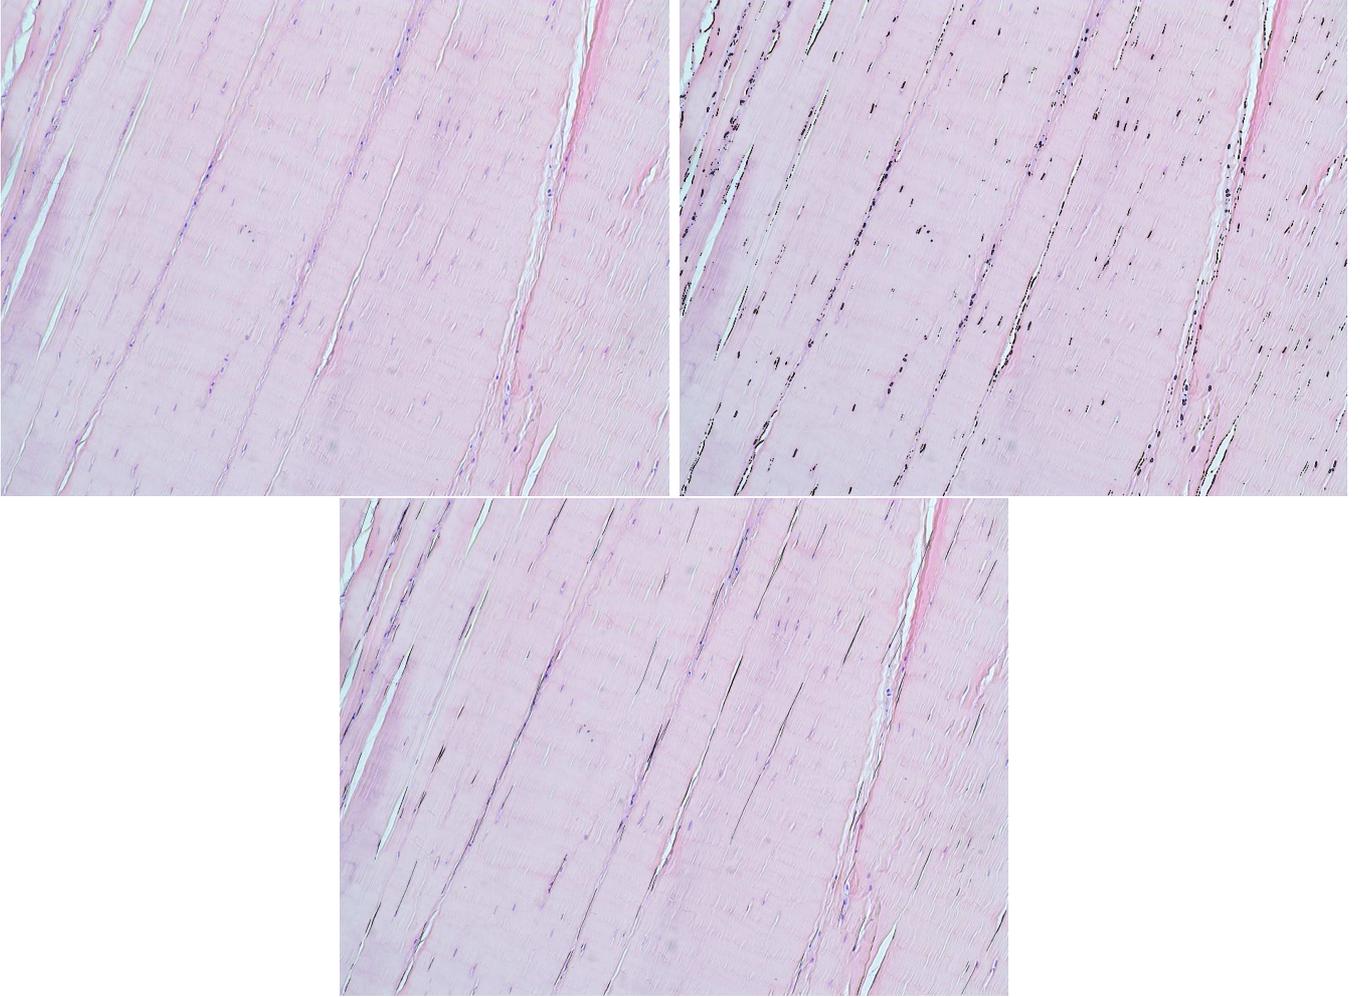


FIGURE 4.23 – Exemple d’image en entrée de l’algorithme de segmentation des fibroblastes (haut gauche), la segmentation des fibroblastes (haut droit) et les alignements les plus représentatifs en sortie de l’algorithme de détection des alignements (bas).

clustering spectral peut être exprimée comme :

$$\begin{aligned} \max_U \operatorname{tr}(\mathbf{U}^T \mathbf{S}_N \mathbf{U}), \\ \text{avec } \mathbf{U}^T \mathbf{U} = \mathbf{I}. \end{aligned} \quad (4.29)$$

Comme \mathbf{S}_N est semi définie positive, le clustering spectral peut être reformulé comme un problème d’optimisation de norme de Frobenius :

$$\begin{aligned} \max_U \|\mathbf{U}^T \mathbf{S}_N \mathbf{U}\|_F^2, \\ \text{avec } \mathbf{U}^T \mathbf{U} = \mathbf{I}. \end{aligned} \quad (4.30)$$

Les fonctions objectives de (4.29) et (4.30) sont différentes, mais elles ont la même solution

optimale, à savoir, les colonnes d'une matrice \mathbf{U} recouvre l'espace propre dominant de \mathbf{S}_N .

4.4.3 Clustering spectral multi-vues

Étant donnée des données multi-vues, le résultat du clustering pourrait être amélioré si les multiples vues étaient intégrées d'une façon adaptée. Les auteurs de [LDLJ⁺] proposent deux approches afin d'intégrer les données multi-vues dans un contexte de clustering spectral. Leurs stratégies de partition multi-vues vont capturer les informations complémentaires véhiculées dans les différentes vues afin de produire un meilleur résultat de clustering. Nous nous intéresserons ici à la première stratégie :

Multi-view clustering by optimisation integration (MC-OI) : Cette méthode est basée sur la partition spectrale de chaque vue des données. La stratégie est d'intégrer la fonction objective des partitions individuelles de chaque vue des données. Les auteurs proposent comme optimisation du clustering multi-vues, le simple ajout des fonctions objectives individuelles :

$$\begin{aligned} \max_{\mathbf{U}} \sum_{i=1}^K \|\mathbf{U}^T \mathbf{S}_N^{(i)} \mathbf{U}\|_F^2, \\ \text{avec } \mathbf{U}^T \mathbf{U} = \mathbf{I}. \end{aligned} \quad (4.31)$$

avec $\mathbf{S}_N^{(i)}$ la matrice de similarité normalisée pour la i ème vue et \mathbf{U} le facteur commun partagé pas les multiples vues.

4.4.4 Clustering spectral multi-vues par des méthodes basées sur les tenseurs

Dans cette sous-section, nous présenterons l'une des solutions proposé dans [LDLJ⁺] basée sur les tenseurs. Un tenseur est un tableau multidimensionnel. L'ordre ou le rang d'un tenseur est son nombre de dimensions (ou d'indices). Un tenseur d'ordre 1 est un vecteur, un tenseur d'ordre 2 est une matrice, plus généralement, on peut envisager des tenseurs définis avec trois, quatre, m indices, qu'on appellera tenseur d'ordre m . Nous nous intéresserons ici aux tenseurs d'ordre 3 seulement.

Le "dépliage" en matrice est un procédé de réagencement des éléments d'un tableau de 3 dimensions en une matrice. Les dépliages mode- n ($n = 1, 2, 3$) en matrice d'un tenseur $\mathcal{A} \in \mathbb{R}^{I \times J \times K}$ sont notés $\mathbf{A}_{(1)}$, $\mathbf{A}_{(2)}$ et $\mathbf{A}_{(3)}$. Par exemple, le dépliage en matrice $\mathbf{A}_{(1)}$ est la matrice avec I lignes et $J \times K$ colonnes. La figure 4.24 montre le dépliage en matrice d'un tenseur d'ordre 3.

Un tenseur peut être multiplié par une matrice. Soit un tenseur $\mathcal{A} \in \mathbb{R}^{I \times J \times K}$ et les matrices $\mathbf{B} \in \mathbb{R}^{I_1 \times I}$, $\mathbf{C} \in \mathbb{R}^{J_1 \times J}$ et $\mathbf{D} \in \mathbb{R}^{K_1 \times K}$. Le produit mode-1 ($\mathcal{A} \times_1 \mathbf{B}$), le produit mode-2 ($\mathcal{A} \times_2 \mathbf{C}$) et

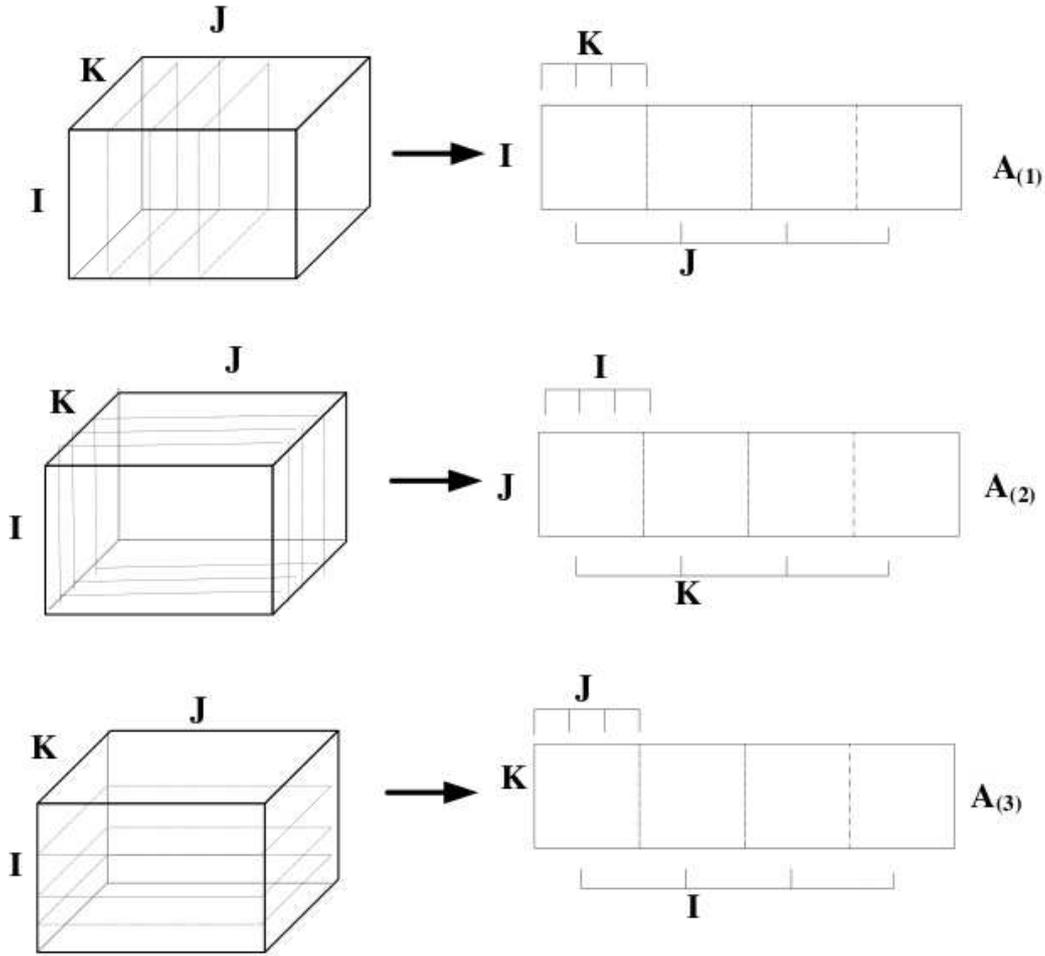


FIGURE 4.24 – Dépliage en matrice d'un tenseur d'ordre 3.

le produit mode-3 ($\mathcal{A} \times_3 \mathbf{D}$) sont respectivement définis par :

$$\begin{aligned}
 (\mathcal{A} \times_1 \mathbf{B})_{i_1 j k} &= \sum_{i=1}^I a_{ijk} b_{i_1 i}, \forall i_1, j, k, \\
 (\mathcal{A} \times_2 \mathbf{C})_{i j_1 k} &= \sum_{j=1}^J a_{ijk} c_{j_1 j}, \forall i, j_1, k, \\
 (\mathcal{A} \times_3 \mathbf{D})_{i j k_1} &= \sum_{k=1}^K a_{ijk} d_{k_1 k}, \forall i, j, k_1,
 \end{aligned} \tag{4.32}$$

La décomposition en valeurs singulières multilinéaire (Multi-Linear Singular Value Decomposition, MLSVD) [DLDMV00] [Tuc64] est une extension à la décomposition en valeurs singulières d'une matrice. Elle décompose un tenseur en tenseur noyau multiplié par une matrice selon chaque mode. Dans le cas en 3 dimensions ou $\mathcal{A} \in \mathbb{R}^{I \times J \times K}$, nous avons :

$$\mathcal{A} = \mathcal{B} \times_1 \mathbf{U} \times_2 \mathbf{V} \times_3 \mathbf{W}, \tag{4.33}$$

ou $\mathbf{U} \in \mathbb{R}^{I \times I}$, $\mathbf{V} \in \mathbb{R}^{J \times J}$ et $\mathbf{W} \in \mathbb{R}^{K \times K}$ sont appelées matrices facteur ou facteurs et peuvent être vu

comme les composantes principales du tenseur original selon chaque mode. Les matrices facteur \mathbf{U} , \mathbf{V} et \mathbf{W} sont supposées orthonormales. Le tenseur $\mathcal{B} \in \mathbb{R}^{I \times J \times K}$ est appelé tenseur noyau. D'après [Tuc64], étant donné un tenseur \mathcal{A} , ses matrices facteurs \mathbf{U} , \mathbf{V} et \mathbf{W} définies à l'équation (4.33), peuvent être calculées comme les vecteurs singuliers gauches des matrices dépliées $\mathbf{A}_{(1)}$, $\mathbf{A}_{(2)}$ et $\mathbf{A}_{(3)}$ respectivement. L'approximation du tenseur en tronquant la décomposition est appelé MLSVD tronqué.

Construction du tenseur - Comme nous l'avons vu dans les sections précédentes, pour chaque vecteur de caractéristiques extrait de l'image, nous avons créé une matrice de distance. Ces matrices de distances vont nous servir à créer des matrices de similarités, que nous appellerons $\mathbf{S}^{(i)}$, avec i l'indice de la caractéristique, sachant qu'il y a K caractéristiques. Nous avons choisi ici un noyau gaussien comme mesure de similarité. Nous avons ensuite créé à partir de ces matrices de similarités les matrices de similarités normalisées (équation (4.27)) $\mathbf{S}_N^{(i)}$. Nous avons ensuite construit un tenseur \mathcal{A} à partir de ces matrices de similarité $\{\mathbf{S}_N^{(1)}, \mathbf{S}_N^{(2)}, \dots, \mathbf{S}_N^{(K)}\}$ comme les coupes frontales du tenseur, comme le proposent [LDLJ⁺].

Clustering multi-vues - Nous avons ici utilisée l'approche optimisation - intégration pour le clustering multi-vues (Multi-view Clustering by Optimization Integration, MC-OI, [LDLJ⁺]). Supposons qu'un tenseur de similarité \mathcal{A} soit construit à partir des matrices de similarités $\mathbf{S}_N^{(i)} \in \mathbb{R}^{N \times N}$ ($i = 1, \dots, K$), l'intégration de l'optimisation spectrale peut être écrite

$$\sum_{i=1}^K \|\mathbf{U}^T \mathbf{S}_N^{(i)} \mathbf{U}\|_F^2 = \|\mathcal{A} \times_1 \mathbf{U}^T \times_2 \mathbf{U}^T \times_3 \mathbf{I}\|_F^2, \quad (4.34)$$

ou l'espace colonne de $\mathbf{U} \in \mathbb{R}^{N \times M}$ est le sous espace optimal joint et $\mathbf{I} \in \mathbb{R}^{K \times K}$ est une matrice identité.

L'optimisation du clustering multi-vues dans l'équation (4.31) peut être reformulée en se basant sur la décomposition de tenseur comme

$$\begin{aligned} \max_{\mathbf{U}} \|\mathcal{A} \times_1 \mathbf{U}^T \times_2 \mathbf{U}^T \times_3 \mathbf{I}\|_F^2, \\ \text{avec } \mathbf{U}^T \mathbf{U} = \mathbf{I}. \end{aligned} \quad (4.35)$$

Cette optimisation peut être approximée par MLSVD et les auteurs appellent cette méthode multi-view clustering based on MLSVD (MC-OI-MLSVD). Comme expliqué dans [DLDLMV00], la projection par MLSVD sur le vecteur singulier dominant donne une bonne approximation du tenseur donné. Les auteurs proposent donc ici de prendre les colonnes de \mathbf{U} comme vecteurs singuliers mode-1 dominants. Leurs résultats expérimentaux montrent que cette solution mène à des performances satisfaisantes. Les vecteurs singuliers mode-1 dominants de \mathbf{U} équivalent aux vecteurs singuliers gauches dominants de \mathbf{A}_1 . La MLSVD tronquée ainsi obtenue ne maximise pas l'équation (4.31) en général. Néanmoins, le résultat est habituellement satisfaisant et l'algorithme est efficace et facile à

implémenter. De plus, il existe une limite supérieure sur l'approximation de l'erreur ([DLDMV00]). L'algorithme de la MC-OI-MLSVD est présenté ci-dessous (2)

Algorithm 2 MC-OI-MLSVD($\mathbf{S}^{(1)}, \mathbf{S}^{(2)}, \dots, \mathbf{S}^{(K)}, M$)

- 1: Construire un tenseur de similarité \mathcal{A}
 - 2: Obtenir la matrice dépliée $\mathbf{A}_{(1)}$
 - 3: Calculer \mathbf{U} à partir du sous espace engendré par les M vecteurs singuliers gauche dominant de $\mathbf{A}_{(1)}$
 - 4: Normaliser les lignes de \mathbf{U} à la longueur unitaire
 - 5: Calculer les clusters avec un k-means sur \mathbf{U}
-

5 Résultats

5.1 Implémentation

Nous avons choisi pour implémenter les différents algorithmes le langage C++, ainsi que les bibliothèques :

- Asgard : Structure de donnée de graphe ainsi que traitement de données sur graphe.
- CGAL et Boost : Structure de donnée de graphe et algorithmes sur graphe (MST, Delaunay, Voronoi).
- CImg (+lapack) : Tout ce qui est image mais aussi pour tout ce qui est matriciel (structure de données et opérateurs sur les matrices, ainsi que la recherche de vecteurs propres).
- ImTiff : Accès aux images : pages et tuiles des images.
- TBB : Parallélisation portable des algorithmes.

Étant donnée que les images sont tuilées, nous en avons parallélisés certains algorithmes, notamment l'extraction des fibroblastes, ainsi que l'extraction des caractéristiques de textures (LBP). Nous avons aussi parallélisé la régularisation discrète sur graphe.

Le temps d'exécution le plus long que nous avons pu observer est d'un peu de moins 11 minutes pour une image d'environ 35000×25000 (Core i7 740 @ 1.73GHz, 4GB DDR3). On peut encore facilement améliorer ce temps en utilisant des versions parallélisés des opérations sur matrices.

5.2 Résultats du clustering multispectral

Dans cette section nous verrons différents résultats du clustering multispectral des différentes caractéristiques extraites. Pour la première image, nous avons choisi $k = 3$ pour le k-means de l'algorithme MC-OI-MLSVD.

La figure 5.1 représente, au niveau de l'image centrale, la classification des tuiles, sur le côté droit figure le détail de certaines tuiles classifiées comme lésées (en bleu), le reste des tuiles étant saines. Sur cet exemple on peut voir que les tuiles classifiées comme lésées correspondent aux critères de classification visuelle du tendon, il y a une forte densité de fibroblastes, ce qui témoigne d'une

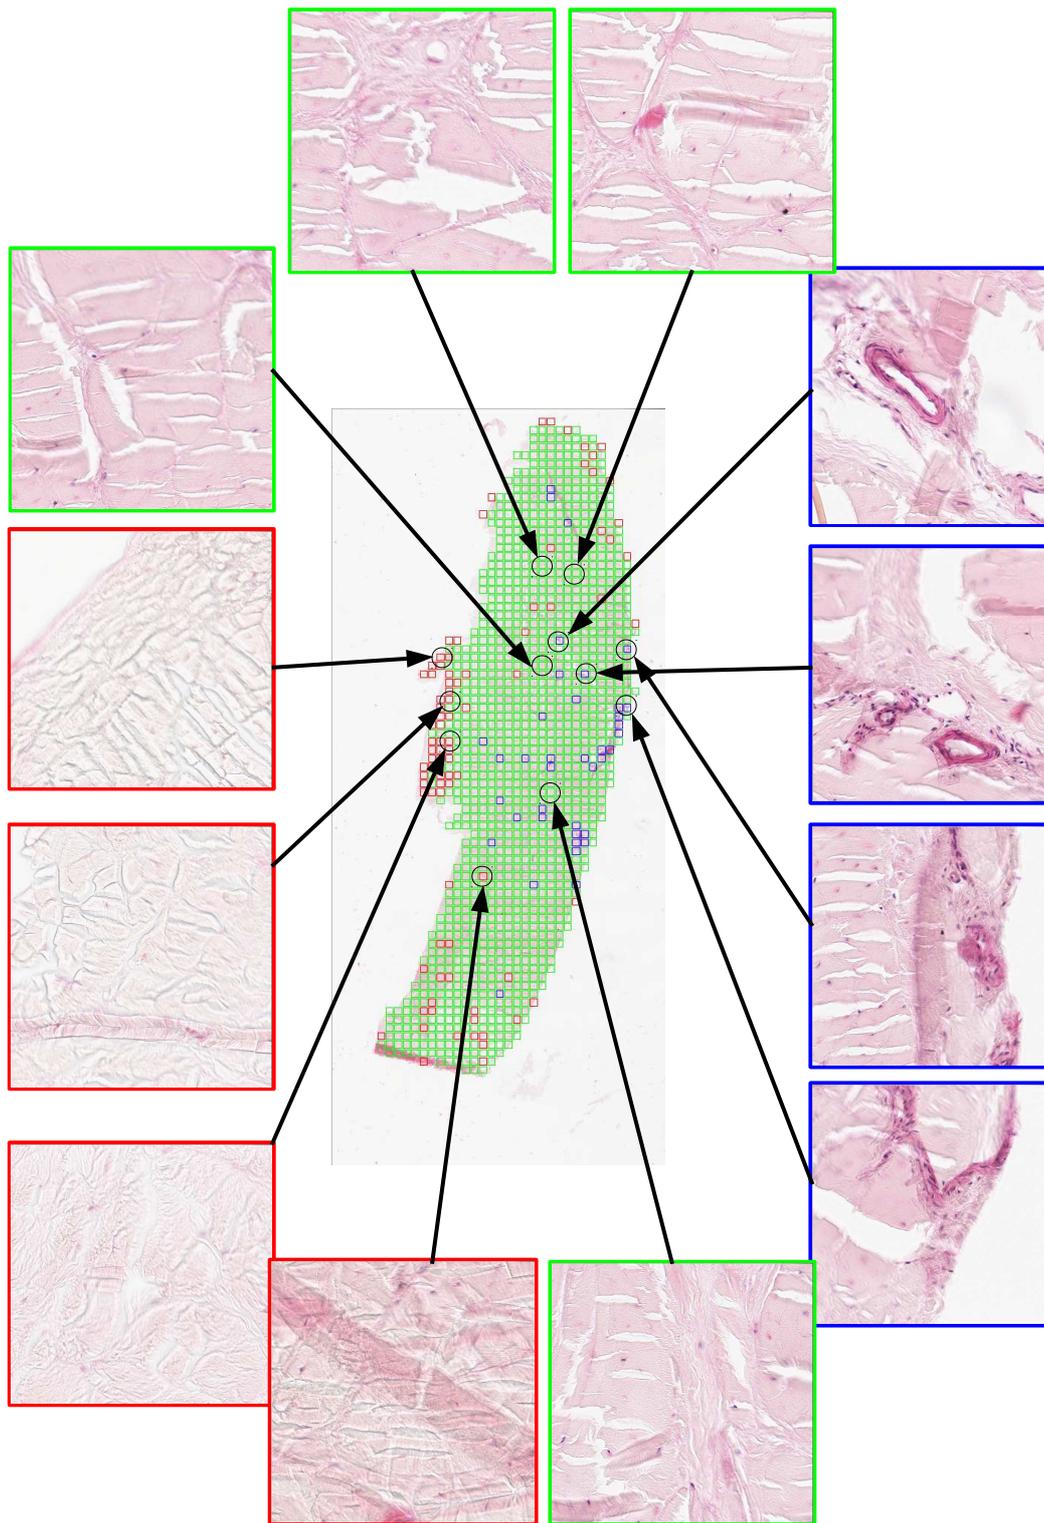


FIGURE 5.1 – Classification des tuiles de la première image.

reconstruction en cours du tendon, ceux-ci sont également disposés assez anarchiquement et certains sont assez allongés. Dans la deuxième classe (en vert), on peut voir qu'il y a une faible densité de fibroblastes, que les textures des images sont assez proches. Dans la troisième classe, on se rend compte que les images ne comportent pas ou très peu de fibroblastes.

Pour la seconde image (figure 5.2), nous obtenons de meilleurs résultats de classification avec $k = 4$ et on peut faire les mêmes constatations que pour la première image, avec une classe en plus (en noir).

Nous n'avons pas encore de vérité terrain pour l'évaluation de ces résultats, cependant ceux-ci paraissent corrects par rapport aux caractéristiques extraites.

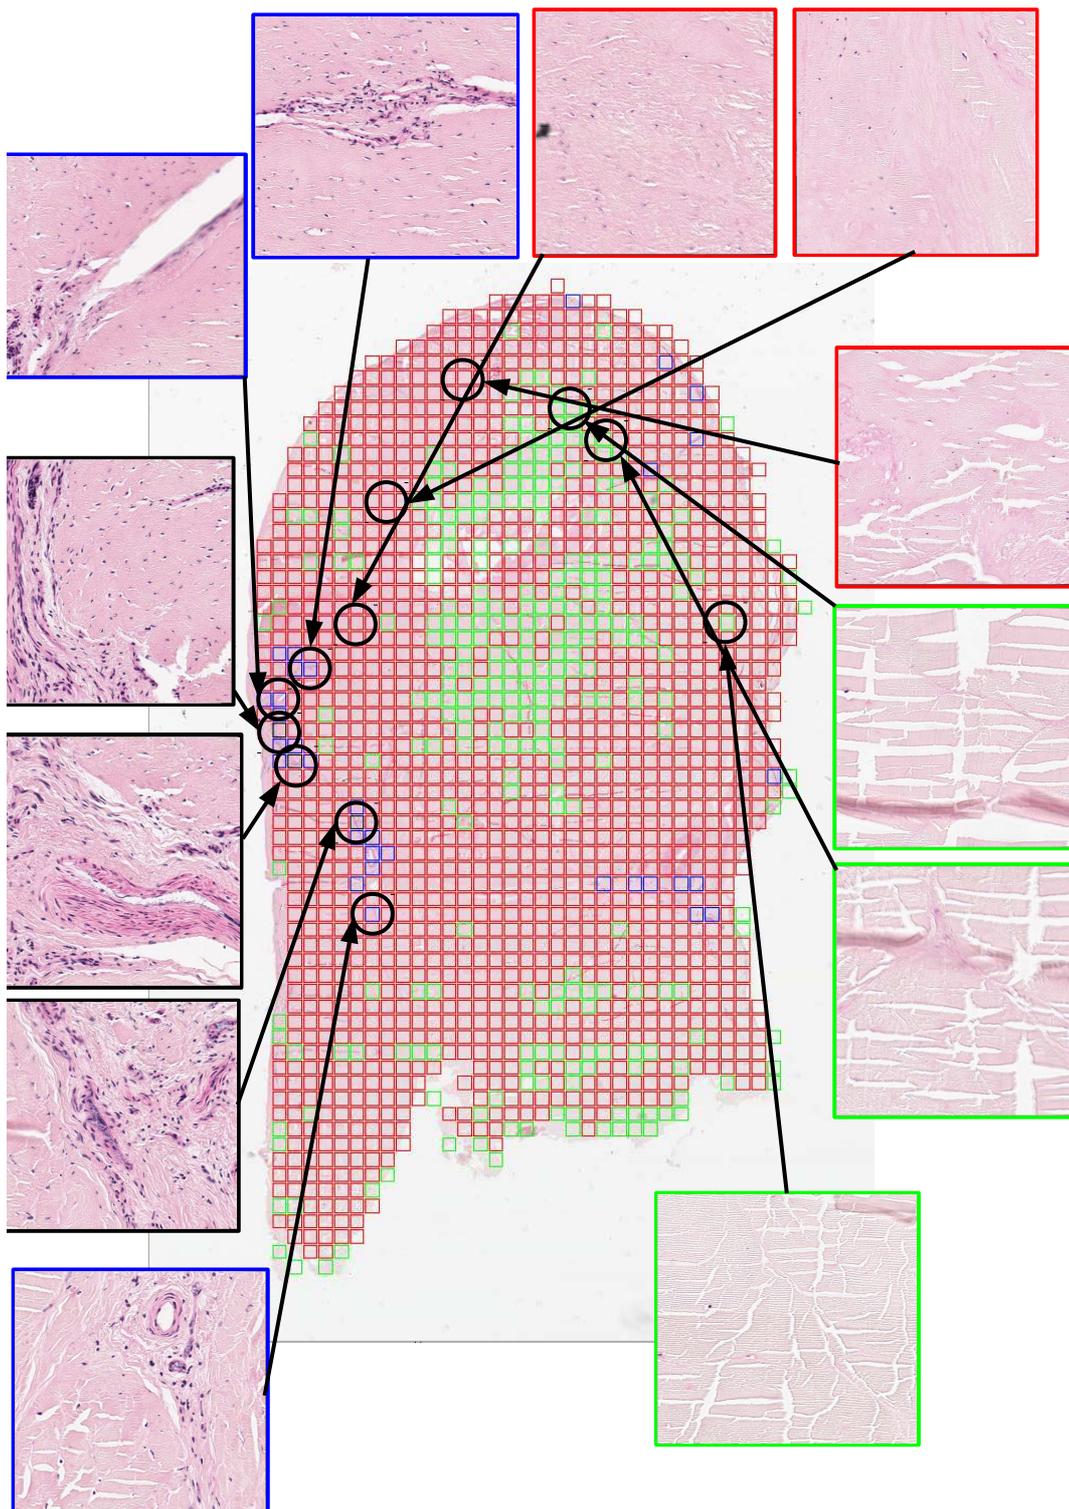


FIGURE 5.2 – Classification des tuiles de la deuxième image.

6 Conclusion

Le stage, effectué au sein du GREYC, s'est déroulé dans le cadre d'une collaboration avec le CIRALE (Centre d'Imagerie et de Recherche sur les Affections Locomotrices Equines, École Nationale Vétérinaire d'Alfort). Le CIRALE dispose de lames entières microscopiques de prélèvements histologiques de tendons de chevaux et souhaite disposer d'une analyse automatique d'images de ces lames microscopiques, afin de disposer d'une classification des tendinopathies équinnes. En effet, les tendinopathies équinnes touchent environ 15% de la population des chevaux de sports et de courses, ce qui représente pour la filière un grand impact économique. Ces affections représentent chez les chevaux une des principales causes de baisse de performances et d'arrêt temporaire ou définitif de la carrière sportive. J'ai dans un premier temps présentés les tendons équinns ainsi que les enjeux des affections de ces tendons, l'acquisition des images, les images elles-mêmes puis l'objectif du stage. J'ai ensuite expliquée l'approche que nous avons adoptée, qui mime la façon de faire du vétérinaire, en utilisant un processus top-down. La stratégie est d'abord d'extraire la zone de tendon de celle du fond à plus basse résolution, de reporter la zone de tendon extraite sur l'image à plus haute résolution, puis d'extraire les caractéristiques servant à la classification des différentes tuiles. Afin d'exploiter les multiples matrices de similarités construites à partir des différentes caractéristiques extraites, nous avons utilisé un algorithme de clustering multi-vues, basé sur la décomposition de tenseur du 3ème ordre, construit à partir des matrices de similarités. Les résultats montrent une cohérence entre les caractéristiques extraites et la classification des tuiles obtenu par k -moyennes sur la décomposition spectrale du tenseur.

Bibliographie

- [BEM07] Sébastien Bougleux, Abderrahim Elmoataz, and Mahmoud Melkemi. Discrete regularization on weighted graphs for image and mesh filtering. In Fiorella Sgallari, Almerico Murli, and Nikos Paragios, editors, *SSVM*, volume 4485 of *Lecture Notes in Computer Science*, pages 128–139. Springer, 2007.
- [BNS06] M. Belkin, P. Niyogi, and V. Sindhwani. Manifold regularization : A geometric framework for learning from labeled and unlabeled examples. *The Journal of Machine Learning Research*, 7 :2399–2434, 2006.
- [BvSdG⁺10] G. Bosch, H. van Schie, M.W. de Groot, J.A. Cadby, C.H.A. van de Lest, A. Barneveld, and P.R. van Weeren. Effects of platelet-rich plasma on the quality of repair of mechanically induced core lesions in equine superficial digital flexor tendons : A placebo-controlled experimental study. *Journal of Orthopaedic Research*, 28(2) :211–217, 2010.
- [COS01] Tony F. Chan, Stanley Osher, and Jianhong Shen. The digital tv filter and nonlinear denoising. *IEEE Transactions on Image Processing*, 10(2) :231–241, 2001.
- [DAH⁺04] JM Denoix, F. Audigie, KW Hinchcliff, AJ Kaneps, and RJ Geor. Imaging of the musculoskeletal system in horses. *Equine sports medicine and surgery : basic and clinical sciences of the equine athlete*, pages 161–187, 2004.
- [DAM⁺08] S. Doyle, S. Agner, A. Madabhushi, M. Feldman, and J. Tomaszewski. Automated grading of breast cancer histopathology using spectral clustering with textural and architectural image features. In *Biomedical Imaging : From Nano to Macro, 2008. 5th IEEE International Symposium on*, pages 496–499. IEEE, 2008.
- [Die05] R. Diestel. *Graph Theory*. Springer, 2005.
- [DLDMV00] L. De Lathauwer, B. De Moor, and J. Vandewalle. A multilinear singular value decomposition. *SIAM Journal on Matrix Analysis and Applications*, 21(4) :1253–1278, 2000.
- [ELB08] Abderrahim Elmoataz, Olivier Lezoray, and Sébastien Bougleux. Nonlocal discrete regularization on weighted graphs : A framework for image and manifold processing. *IEEE Transactions on Image Processing*, 17(7) :1047–1060, 2008.

- [Gra06] L. Grady. Random walks for image segmentation. *IEEE transactions on pattern analysis and machine intelligence*, pages 1768–1783, 2006.
- [LDLJ⁺] X. Liu, L. De Lathauwer, S. Ji, W. Glanzel, and B. De Moor. Multi-view partitioning via tensor methods. *IEEE Transactions on Knowledge and Data Engineering*, 2011.
- [OPM02] Timo Ojala, Matti Pietikäinen, and Topi Mäenpää. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Trans. Pattern Anal. Mach. Intell.*, 24(7) :971–987, 2002.
- [OVOP01] T. Ojala, K. Valkealahti, E. Oja, and M. Pietikäinen. Texture discrimination with multidimensional distributions of signed gray level differences. 2001. *Pattern Recognition* 34 :727 - 739.
- [OW93] M.L. Overton and R.S. Womersley. Optimality conditions and duality theory for minimizing sums of the largest eigenvalues of symmetric matrices. *Mathematical Programming*, 62(1) :321–357, 1993.
- [RJ01] A.C. Ruifrok and D.A. Johnston. Quantification of histochemical staining by color deconvolution. 2001. *Anal Quant Cytol Histol* 23 : 291-299.
- [SG07] A.K. Sinop and L. Grady. A seeded image segmentation framework unifying graph cuts and random walker which yields a new algorithm. *International Conference on Computer Vision*, pages 1-8, 2007.
- [SMR00] J. Sudbo, R. Marcelpoil, and A. Reith. New algorithms based on the voronoi diagram applied in a pilot study on normal mucosa and carcinomas. *Anal Cell Pathol*, 21(2) :71–86, 2000.
- [TLES09] V.T. Ta, O. Lézoray, A. Elmoataz, and S. Schüpp. Graph-based tools for microscopic cellular image segmentation. *Pattern Recognition*, 42(6) :1113–1125, 2009.
- [Tuc64] L.R. Tucker. The extension of factor analysis to three-dimensional matrices. *Contributions to mathematical psychology*, pages 109–127, 1964.
- [VBI10] M. Vanegas, I. Bloch, and J. Inglada. Searching aligned groups of objects with fuzzy criteria. *Computational Intelligence for Knowledge-Based Systems Design*, pages 605–613, 2010.
- [WZSW06] F. Wang, C. Zhang, H.C. Shen, and J. Wang. Semi-supervised classification using linear neighborhood propagation. *International Conference on Computer Vision and Pattern Recognition*, Vol. 1, pages 160 - 167, 2006.
- [ZS05] D. Zhou and B. Schölkopf. Regularization on discrete spaces. *Pattern Recognition*, pages 361–368, 2005.