Mesures de la dissimilarité entre images

D. COQUIN

Laboratoire d'Informatique, Systèmes, Traitement de l'Informarion et de la Connaissance
LISTIC - Université de Savoie, BP 806, F. 74016 Annecy cedex.
(CNRS - GdR - ISIS)
Email: Didier.Coquin@univ-savoie.fr

Partie 1: Dissimilarité entre images à niveaux de gris

1. Introduction:

Un problème d'intérêt théorique et pratique en traitement d'images est la comparaison de deux images en niveaux de gris, de même taille et de même échelle de niveaux de gris. Cette comparaison doit également prendre en compte les éventuelles différences dues à la translation, la rotation ou le changement d'échelle.

Une mesure quantitative de dissimilarité D(A,B) entre deux images A et B est utile pour de nombreuses applications pratiques comme, par exemple, le filtrage, la restauration, la compression, la segmentation .... Les résultats de cette études ont un caractère préliminaire et ne doivent pas être considérés comme une réponse approfondie à la question sur la mesure de la dissimilarité dans son ensemble.

Le but de ce travail est de présenter les mesures de dissimilarité existantes, de développer une mesure de dissimilarité entre deux images en niveaux de gris et enfin, de la tester sur des applications pratiques. La mesure de dissimilarité décrite ici, peut être calculée sur n'importe quelle paire d'images. Cette mesure de dissimilarité donne également quelques conseils utiles sur la localisation des classes de distorsions.

De nombreux travaux ont été réalisés sur des images binaires [1, 5, 6] mais peu sur des images en niveaux de gris [4, 10, 11]. Dans ce rapport nous introduisons une nouvelle mesure de dissimilarité qui est une extension de la distance de Baddeley aux images en niveaux de gris. Cette mesure est basée sur l'accumulation d'informations locales de distance. Le principal avantage de cette mesure de dissimilarité réside dans le contrôle de l'importance de chaque classe de distorsions en ajustant un paramètre de l'opérateur local de distance. Pour chaque classe, une carte de distances peut être calculée [4, 12].

La section 2 introduit les grandes classes de mesures de dissimilarité selon le modèle image choisi et indique les conditions auxquelles doit satisfaire une mesure de dissimilarité. La section 3 donne une brève description de plusieurs mesures de dissimilarité appliquées aux images en niveau de gris et décrit le principe de l'extension de la mesure de dissimilarité de Baddeley aux cas des images en niveaux de gris. La section 4 décrit le critère local. Dans la section 5, nous comparons cette nouvelle dissimilarité aux autres mesures de dissimilarité, en nous basant sur une étude expérimentale.

2. Le modèle image

Les deux approches classiques de comparaison quantitative d'images sont basées sur ces deux modèles classiques d'image: considérer une image en tant que fonction ou en tant qu'ensemble de points.

2.1 Image en tant que fonction.

Considérons deux images, nommées A et B. Ces images ont un support commun S et prennent leurs valeurs dans l'ensemble des niveaux de gris G. Soit $s \in S$ un pixel. Les images A et B peuvent être représentées par les fonctions f_A et f_B de S vers G.
Avec ce modèle, l'opérateur de comparaison peut être défini par:

$$D(A, B) = \Psi\left(\sum_{s \in S} \varphi(f_A(s) - f_B(s)) \right) \quad (1)$$

avec: φ: une fonction positive de préférence paire
Ψ: une fonction positive et croissante avec Ψ(0) = 0

Alors, la dissimilarité entre deux images est obtenue par accumulation d'informations locales.

exemples:
Avec φ la valeur absolue et Ψ la moyenne, on obtient le critère de la moyenne des différences absolues.
Avec φ la fonction élévation au carré et Ψ la racine carrée de la moyenne, on obtient le critère RMS. Ceci peut être généralisé aux distances de Minkowski en utilisant des fonctions puissances.

2.2 Image en tant qu'ensemble de points

Soit A une image ayant toujours comme support S=NxN (dimension de l'image: N) et comme échelle de niveaux de gris $G = \{0, 1, ...,255\}$. L'image A peut être représentée par l'ensemble de voxels $X_A \subset S \times G$, où x est le produit cartésien.

$$X_A = \{v(s, g) \in S \times G, g = f_A(s)\} \quad (2)$$

A partir de cette définition, les mesures de dissimilarité peuvent être définies comme étant la distance entre deux ensembles de points.

$$D(A, B) = d(X_A, X_B) \quad (3)$$

Dans cette catégorie, on trouve la distance de Hausdorff [6] et la distance de Baddeley [1].

❑ **la distance de Hausdorff** entre deux ensembles de points X et Y est définie par:

$$H(X, Y) = max\left\{ \sup_{x \in X}\{d(x, Y)\}, \sup_{y \in Y}\{d(y, X)\} \right\} \quad (4)$$

on rappelle que la distance entre un point x et un ensemble de points Y est:

$$d(x, Y) = min_{y \in Y} d(x, y) \quad (5)$$

Si on adapte cette définition aux images en niveaux de gris, le critère devient:

$$D_H(X_A, X_B) = max\left\{ \sup_{a \in X_A}\{d(a, X_B)\}, \sup_{b \in X_B}\{d(b, X_A)\} \right\} \quad (6)$$

❑ **la distance de Baddeley** entre deux ensembles X et Y inclus dans le référentiel Z est définie par:

$$B(X, Y) = \left[\frac{1}{card(Z)} \sum_{z \in Z} |d(z, X) - d(z, Y)|^E \right]^{\frac{1}{E}} \quad (7)$$

avec l'exposant E tel que $1 \leq E \leq \infty$

Cette distance a été proposée en 1992, pour calculer l'erreur entre deux images binaires [1]. Nous proposerons une extension de cette distance aux images en niveaux de gris.

Certains auteurs ont suggéré de combiner les deux informations globale et locale. Parmi eux on trouve comme opérateurs hybrides, celui proposé par Dubuisson et Jain [5] (distance de Hausdorff modifiée) et celui de Zamperoni et Starovoitov [11]. Ces opérateurs seront décrits dans la section 3.

2.3 Conditions auxquelles doit satisfaire une mesure de dissimilarité entre images

Pour que la mesure de dissimilarité satisfasse aux critères d'une distance, elle doit vérifier les conditions suivantes:

1. *D(A,B)* doit être égale à 0 si A=B (identité) et égale à une grande valeur pour la dissimilarité extrêmale. Si on considère une échelle de niveaux de gris entre 0 et 255, la plus grande valeur de la dissimilarité doit avoir lieu entre une image uniformément blanche et une image uniformément noire. La mesure de dissimilarité doit avoir un grand pouvoir discriminant, sa valeur doit croître avec la dissemblance entre deux objets.

2. *D* doit satisfaire aux propriétés d'une distance à savoir:
(i) $D(A, B) \geq 0$, et D(A, B) = 0 si et seulement si A=B
(ii) D(A, B) = D(B, A)
(iii) $D(A, C) \leq D(A, B) + D(B, C)$, (inégalité triangulaire)

Il arrive parfois que nous soyons obligés de travailler avec une mesure qui ne soit pas forcément une distance, nous considérerons alors la propriété 2-(iii) comme une condition souhaitée mais non obligatoire.

3. *D* doit être sensible à la déformation des objets, au déplacement des contours, à une variation du niveau de gris moyen .....

4. Au moins pour de petites translations entre 2 images, *D* devrait augmenter.

5. Si l'image B était obtenue par addition d'un bruit blanc à l'image A, et si C est la version restaurée de l'image B, alors on devrait avoir $D(A, B) \geq D(A, C)$

2.4 Modèle image que nous avons utilisé

Dans la suite de ce rapport puisque nous serons amenés à travailler en 3D, nous considérerons des voxels parallélépipédiques (LxHxP) représentés par la Figure 1, et pour simplifier nous considérerons des pixels carrés de taille L=H=1. Ceci n'est pas une contrainte car dans la plupart des cas, l'image est numérisée avec le même pas d'échantillonnage en ligne et en colonne mais pas forcément en intensité.

Soit S = une grille 2D, le support de l'image, avec des coordonnées discrètes $s = (x, y) \in S$. L'image A peut donc être vue comme une fonction $f_A: S \rightarrow G$, ou une fonction binaire $F_A: S \times G \rightarrow \{0, 1\}$, avec

$$F_A(x,y,g) = 1 \quad \text{si} \quad f_A(x,y) = g$$
$$= 0 \quad \text{sinon} \qquad (8)$$

Avec cette représentation une image peut être considérée comme un ensemble binaire de points (voxels) dans un volume 3D. Cet ensemble binaire représente alors une surface dans le volume 3D.

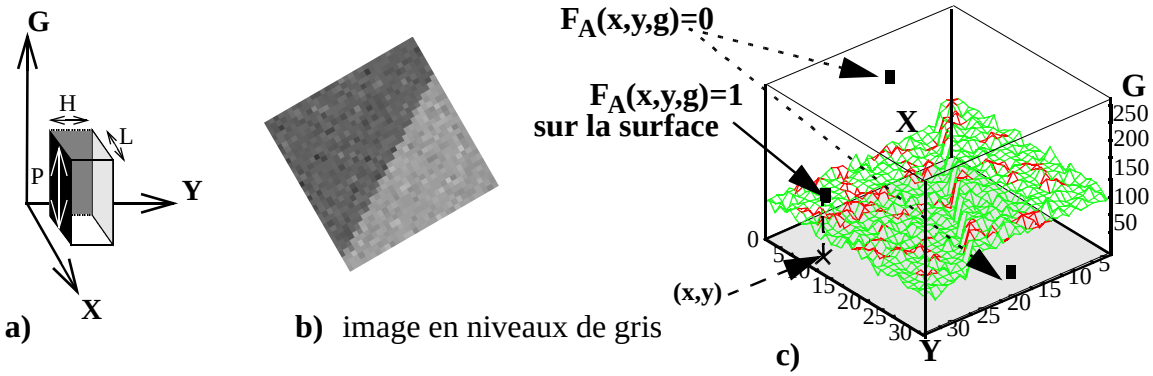


Figure 1: Représentation d'une image: a) représentation d'un voxel b) représentation en niveaux de gris de f, c) fonction F

Cette représentation est avantageuse pour les mesures de distance basées sur les opérations ensemblistes.

3. Mesures de dissimilarité

La comparaison entre images binaires est souvent réalisée numériquement en utilisant l'une des deux techniques provenant de l'étude des algorithmes de détection de contours, et de la mesure de localisation des erreurs. La situation est de loin plus compliquée avec des images en niveaux de gris. Pour comparer deux images en niveaux de gris, les mesures très utilisées sont l'erreur quadratique moyenne (RMS) et le rapport signal/bruit (SNR). Mais rappelons que se sont des prédicteurs imprécis de la déformation perceptible. En effet, une même différence d'intensité lumineuse est perçue différemment selon les niveaux de gris pour lesquels cette opération est effectuée, alors que la valeur du RMS reste inchangée. Un autre facteur est que ces critères dépendent uniquement des différences de niveaux de gris, mais ne tiennent pas compte directement de l'information géométrique (Fig. 2) présente dans les images, et donc d'éventuels déplacements géométriques.

La figure 2 illustre ce deuxième point. On considère comme image originale A, un contour de type marche, et comme image B_1, l'image A décalée d'un pixel vers la droite, et comme image B_2, l'image A filtrée.

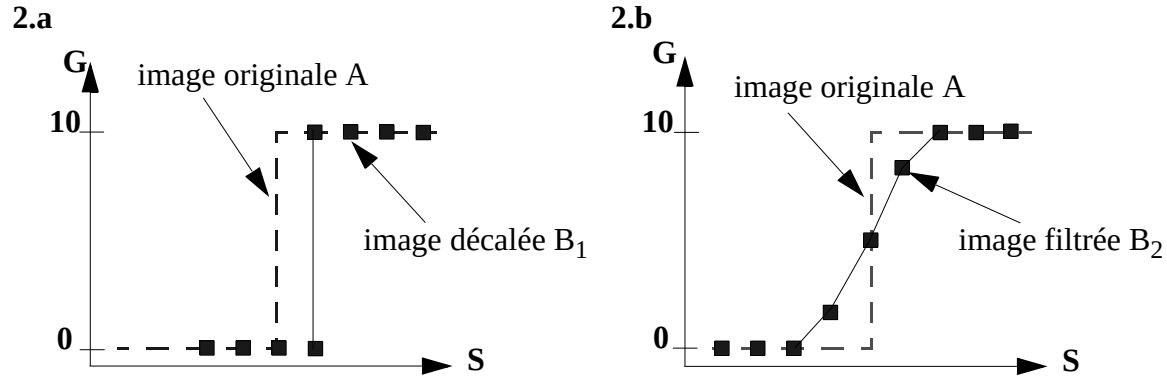


Figure 2: Deux images filtrées

Sur l'image B_1, nous voyons que le contour est mieux préservé par rapport à celui de l'image B_2. Cependant, l'erreur quadratique moyenne (RMS) est plus petite dans le cas 2.b

$RMS(A,B_1) = 1.78$ $RMS(A,B_2) = 1.63$

La mesure du RMS ne tient donc pas compte du déplacement des objets dans l'image.

Une mesure de dissimilarité performante devrait tenir compte des informations géométriques contenues dans l'image. Parmi les mesures de dissimilarité existantes, trois méthodes prennent en compte ces informations géométriques. Nous donnons dans ce qui suit une brève description de ces trois mesures de dissimilarité.

3.1 Méthode développée par Zamperoni et Starovoitov

Ils ont proposé une mesure de dissimilarité multi-étapes, dans laquelle chaque étape (pixel à pixel, pixel à fenêtre, fenêtre à fenêtre, et image à image) peut être basée sur différentes mesures de distance, d'où plusieurs variantes des mesures de dissimilarité. Ils ont examiné quelques unes de ces variantes liées aux conditions posées à la dissimilarité et à la structure des images à comparer. Ils ont fait des vérifications expérimentales basées sur la préservation des contours et sur la restauration d'images bruitées.
La meilleure mesure de dissimilarité qu'ils préconisent est celle qui consiste à faire cette comparaison fenêtre par fenêtre. Dans ce qui suit, nous décrivons brièvement cette méthode.

Soient $W_A = A \cap W$ et $W_B = B \cap W$ les intersections de l'image A et de l'image B avec la fenêtre W, centrée sur la position (x,y) et donc sur le pixel courant $a \in A$ ou $b \in B$. La Figure 3. montre une coupe undimensionnelle de A et de B au voisinage de la position (x,y). Zamperoni et Starovoitov ont introduit la mesure de dissimilarité suivante [11], pour une valeur de l'exposant E tel que $1 \le E < \infty$:

$$D_Z(A,B) = \frac{1}{2GN}\left\{ \sum_{(x,y) \in S} [min_{b' \in W_B}\{d_{city}(a,b')\} + min_{a' \in W_A}\{d_{city}(a',b)\}]^E \right\}^{\frac{1}{E}} \qquad (9)$$

avec $G = \{0, 1, ...,255\}$ et N = taille de l'image, et où $d_{city}(a, b')$ est la distance city-block entre le pixel noté "a" et tous les pixels $b' \in W_B$. Les auteurs recommandent d'utiliser une fenêtre de taille 21x21 et un exposant E=2 [11]. La figure 3 illustre cette mesure.

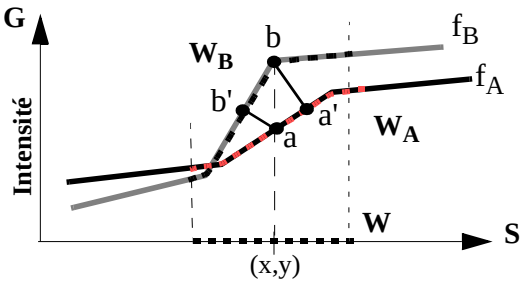


Figure 3: Dissimilarité calculée à l'intérieur d'une fenêtre W

Ils ont évalué leur mesure de dissimilarité sur des images bruitées puis filtrées, et ont montré l'intérêt de choisir une mesure basée sur la combinaison d'informations spatiales et en niveaux de gris. Toutes les mesures tendent à pénaliser des variations de contours ou des déformations d'objets dans les régions plates, et donnent moins de poids aux contours flous qui ne sont pas décalés.
L'ensemble des mesures de dissimilarité proposé dans cet article [11] n'est pas applicable à n'importe quels types d'images en niveaux de gris, parce que l'un des buts pratiques de ces mesures de dissimilarité est d'être exécuté seulement entre des images très semblables.

3.2 Méthode développée par Wilson et al.

Wilson et al. ont introduit une nouvelle mesure de dissimilarité qui est une extension possible de la distance de Baddeley aux images en niveaux de gris [10].

Soit f : $S \rightarrow G$ la fonction image. Le sous-graphe de f, en accord avec Matheron [7] est défini par: $\Gamma_f = \{(x, y, g), (x, y) \in S, g \in G, g \leq f(x, y)\}$. C'est l'ensemble de tous les points entre la surface représentative de f (donc de l'image = surface dans un volume 3D) et le plan f(x, y) = 0.

Soit f1 et f2, deux fonctions images définies sur un support commun S, et prenant leur valeur dans le même domaine de niveaux de gris G. Soient Γ_{f1} et Γ_{f2} les sous-graphes de f1 et f2 respectivement. Alors Δ_g la mesure de dissimilarité entre deux images en niveaux de gris est définie pour $1 \leq E < \infty$ par:

$$\Delta_g(\Gamma_{f1}, \Gamma_{f2}) = \left[\frac{1}{N^2 G} \sum_{(x,y) \in S} \sum_{g \in S} \left| d^*((x, y, g), \Gamma_{f1}) - d^*((x, y, g), \Gamma_{f2}) \right|^E \right]^{\frac{1}{E}} \quad (10)$$

où $d^*((x, y, g), \Gamma_{f1}) = inf_{g';(|g-g'| \leq c)}(\{max[d((x, y), X_{g'}(f1)), |g - g'|]\}, c)$ est la plus courte distance entre le voxel $(x, y, g) \in SxG$ et le sous-graphe de f1, $\Gamma_{f1} \subseteq SxG$. Et $X_{g'}(f1) = \{(x, y) \in S; (f1(x, y) \geq g')\}$ est le sous-ensemble de voxels, où chaque voxel est supérieur ou égal au niveau de gris g'.

A partir de la définition de $d^*((x, y, g), y, \Gamma_{f1})$, on peut remarquer que d* est bornée par la valeur c.

Le principe de calcul de d* est le suivant: pour chaque niveau de gris g', on recherche la plus grande distance entre:

- premièrement le voxel courant (x,y,g) et le sous-graphe Γ_{f1} et
- deuxièmement la valeur absolue de la différence entre les niveaux de gris g et g' donc $|g - g'|$.

d* est alors la plus petite des distances sur l'ensemble des niveaux que peut décrire g' (Fig. 4).

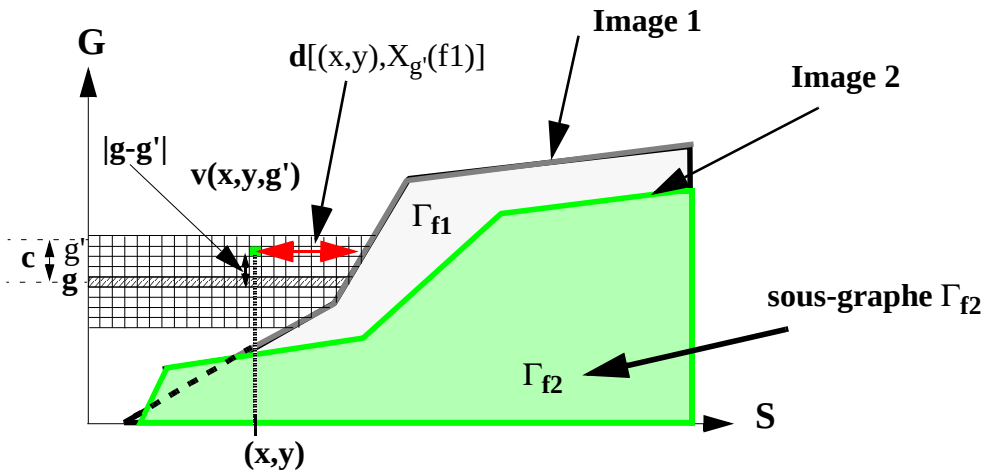


Figure 4: Distance entre un pixel (x,y) et le sous-ensemble $X_{g'}(f1)$, et le sous-graphe des fonctions images f1 et f2.

Il est montré en [10] que Δ_g tend vers la distance de Hausdorff si E tend vers l'infini.

Dans leur implémentation, S est une grille bidimensionnelle et la distance $d(x, y, X_{g'}(f))$ entre un point (x, y) et le sous-ensemble $X_{g'}(f)$ défini pour le niveau de gris g' dans le domaine S est calculée au moyen d'une transformée de distance 2D proposée par Borgefors [2]. Pour calculer cette transformée de distance ils ont utilisé le masque de chanfrein $d_{5\text{-}7\text{-}11}$.
Ils ont montré que pour un certain type de distorsions résultant d'une compression ou d'un filtrage, il y avait une petite différence entre les erreurs détectées par Δ_g et celles trouvées par le RMS. Mais pour des distorsions portant sur la forme des objets, comme reconnaître le point sur la barre de la lettre "i", parmi plusieurs images bruitées, la mesure de dissimilarité Δ_g est bien meilleure que le RMS.

3.3 Méthode développée par Dubuisson et Jain

Dubuisson et Jain ont analysé les propriétés de la distance de Hausdorff (HD), et ils ont déterminé que, parmi la classe des mesures de distance basées sur la distance de Hausdorff, la distance de Hausdorff modifiée (MHD) était la meilleure pour retrouver des objets dans une images à partir de leurs points de contours [5]. La définition de la mesure MHD est:

$$MDH(A, B) = max[d(A, B), d(B, A)] \qquad (11)$$

où d(A,B) est la distance entre deux ensembles de points $A = \{a_1, a_2, \ldots, a_{N_A}\}$ et $B = \{b_1, b_2, \ldots, b_{N_B}\}$, définie par:

$$d(A,B) = \frac{1}{N_A}\sum_{\in} d(a,B) \qquad \text{et} \qquad d(a,B) = min_{b \in B} d(a,b) \tag{12}$$

N_A est le nombre de pixels de l'image A et d(a,B) est la distance entre un point "a" et un ensemble B.

Ils ont montré que MHD a les propriétés suivantes:

(i) sa valeur croît de façon monotone au fur et à mesure que les différences entre les deux ensembles de points de contours augmentent,

(ii) est robuste vis à vis du bruit

Ils n'ont testé leur méthode que pour retrouver des objets à partir d'images binaires. Ils ont montré l'efficacité de la mesure MHD vis à vis de tous types de bruits.

Pour l'implémentation de cette dissimilarité, la distance entre deux ensembles de points A et B est approximée au moyen d'un opérateur local de distance 3D [3, 4]. Nous avons utilisé le masque de chanfrein 3x3x3, et la distance $d_{16\text{-}23\text{-}28}$ avec comme facteur de normalisation N=17.

4. Extension de la distance de Baddeley aux images en niveaux de gris

Afin d'améliorer la mesure de dissimilarité entre deux images, ayant les mêmes dimensions et la même échelle de niveaux de gris, nous proposons une extension de la distance de Baddeley [1] aux images en niveaux de gris.

4.1 Principe

En conservant les mêmes notations qu'au paragraphe 2.1, soient A et B les images à comparer. La distance de Baddeley entre A et B est définie, pour un exposant E, par:

$$D(A,B) = \left[\frac{1}{N_S G}\sum_{v \in V} \left|d_A(v) - d_B(v)\right|^E\right]^{\frac{1}{E}} \tag{13}$$

où le voxel v=(x,y,g); N_S=CardA, et V = S x G: le volume sur lequel la dissimilarité est calculée.

$d_A(v)$ (resp. $d_B(v)$) est une distance entre le voxel v et l'ensemble binaire caractérisant l'image A (resp. B) (Fig. 5). Alors, nous avons $d_A(v) = d((x,y,g),A)$, et nous pouvons définir la distance locale par:

$$d^*_{AB}(v) = \frac{1}{2}[d((x,y,g),A) + d((x,y,g),B)] \tag{14}$$

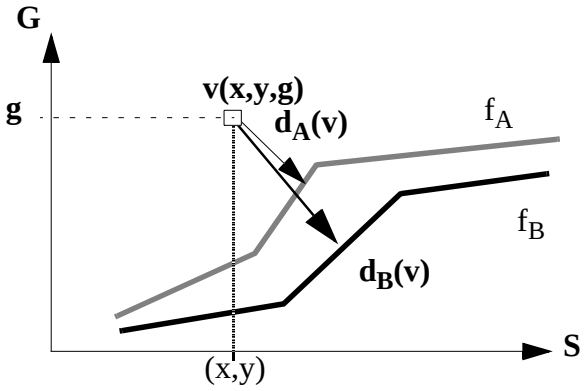


Figure 5: Dissimilarité entre deux images

4.2 Implémentation

Afin de réduire la complexité du calcul informatique, les distances Euclidiennes $d_A(v)$ et $d_B(v)$ sont approximées par un opérateur local de distances 3D [3, 4, 12].

En considérant un maillage parallélépipédique, les voxels sont caractérisés par leur largeur L, leur longueur H et leur hauteur P, qui sont en général différentes (Fig. 6a). Soit d_{ijk} les coefficients du masque d'un opérateur M×M×M avec (M=2m+1). Les indices i, j et k vérifiant: $i,j,k \in \{0,1, ..., m\}$ et PGCD(i,j,k) = 1 (Plus Grand Diviseur Commun). La figure 6b montre les coefficients d'un opérateur 3x3x3 représentés par les directions d_{ijk} des déplacements élémentaires entre deux voxels.

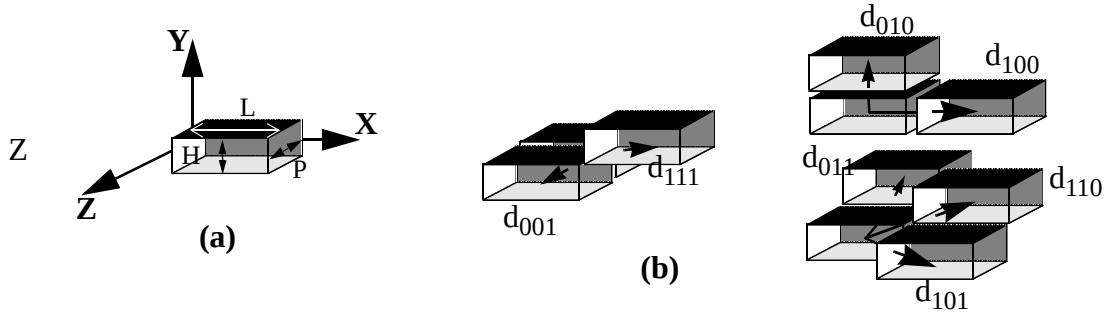


Figure 6: Opérateur 3x3x3 en maillage parallélépipédique:
(a) Caractéristiques d'un voxel. (b) Déplacements élémentaires.

Une transformée de distance avec l'opérateur 3x3x3 est calculée à partir (eq. 8) des ensembles binaires définissant les images A et B. Les distances globales sont donc calculées par propagation d'informations locales (à partir des déplacements élémentaires). Un algorithme séquentiel ou parallèle peut être utilisé pour calculer cette transformée.

4.3 Paramétrisation

Les dimensions du voxel sont fonction des paramètres H, L et P (Fig. 6a). Les valeurs de H et L dépendent de la période d'échantillonnage spatial des données. Le paramètre P dépend du poids des niveaux de gris par rapport aux distorsions spatiales (Fig. 7).

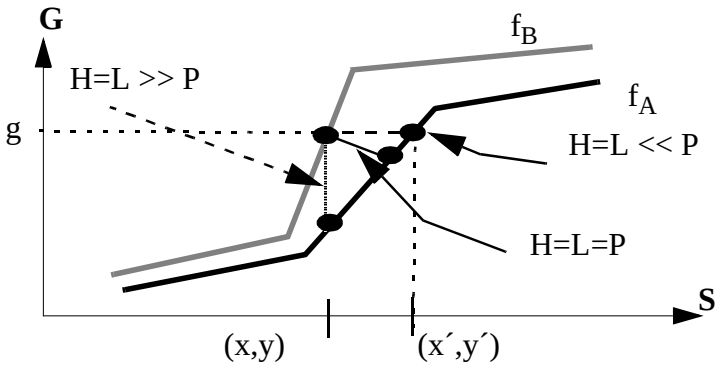


Figure 7: Distance entre 2 images

Premier cas: H, L >> P

Le poids des déplacements spatiaux est très supérieur aux déplacements selon l'axe des niveaux de gris. Le chemin minimal sera alors vertical.
Alors, nous avons:

$$d^*_{AB}(x, y) = \left| f_B(x, y) - f_A(x, y) \right| \tag{15}$$

Seule la différence entre les niveaux de gris sera prise en compte dans le calcul de la dissimilarité locale.

Deuxième cas: H, L << P

A l'opposé, si le poids des déplacements selon l'axe des niveaux de gris est très grand devant les déplacements spatiaux, alors le chemin minimal sera horizontal, et sera égal au déplacement entre le point (x,y) et le point (x´,y´) dans le plan de niveau de gris g.
Alors, nous avons:

$$d^*_{AB}(x, y) = \frac{1}{2}[d_A(x, y, f_B(x, y)) + d_B(x', y', f_A(x', y'))] \tag{16}$$

Seules les distorsions géométriques seront prises en compte dans le calcul de la dissimilarité locale. Ces distorsions seront visibles dans l'image des distances [4, 12].

4.4 Conclusion

Nous avons proposé une extension de la mesure de dissimilarité développée par Baddeley. Cette mesure donne un critère global. Nous avons également montré comment définir un critère local, basé sur une mesure de dissimilarité entre deux voxels localisés dans S. Le résultat peut être visualisé à partir des images de distances.

5. Résultats expérimentaux

Dans cette section, nous présentons des résultats expérimentaux appliqués à des images en niveaux de gris, qui permettent de comparer l'erreur quadratique moyenne RMS, l'extension aux images à niveau de gris de la dissimilarité de Baddeley: D, la mesure de dissimilarité développée par Zamperoni et Starovoitov: D_Z, la mesure de dissimilarité Δ_g développée par Wilson et al., et la mesure MHD développée par Dubuisson et Jain, étendue aux images en niveaux de gris. Nous comparons les réponses de ces 5 dissimilarités.

Dans tous les tests qui suivent, nous avons utilisé le rapport P/H=1 pour le calcul de la dissimilarité D avec un masque de chanfrein 3x3x3, avec la distance $d_{16\text{-}23\text{-}28}$ pour un facteur de normalisation N=17. Dz est calculé avec une taille de fenêtre W=21x21, et la distance d_{city}. Pour toutes les dissimilarités nous avons pris l'exposant E = 2.

5.1 Augmentation uniforme du niveau de gris

Le premier exemple considéré ici est une augmentation de 10 niveaux de gris par pas de 10, d'une image. Les résultats sont obtenus en comparant chaque image modifiée par rapport à l'image originale (Fig. 8). L'image originale provient du site http://www.inrialpes.fr/movi/people/Gros/Gros_fr.html.

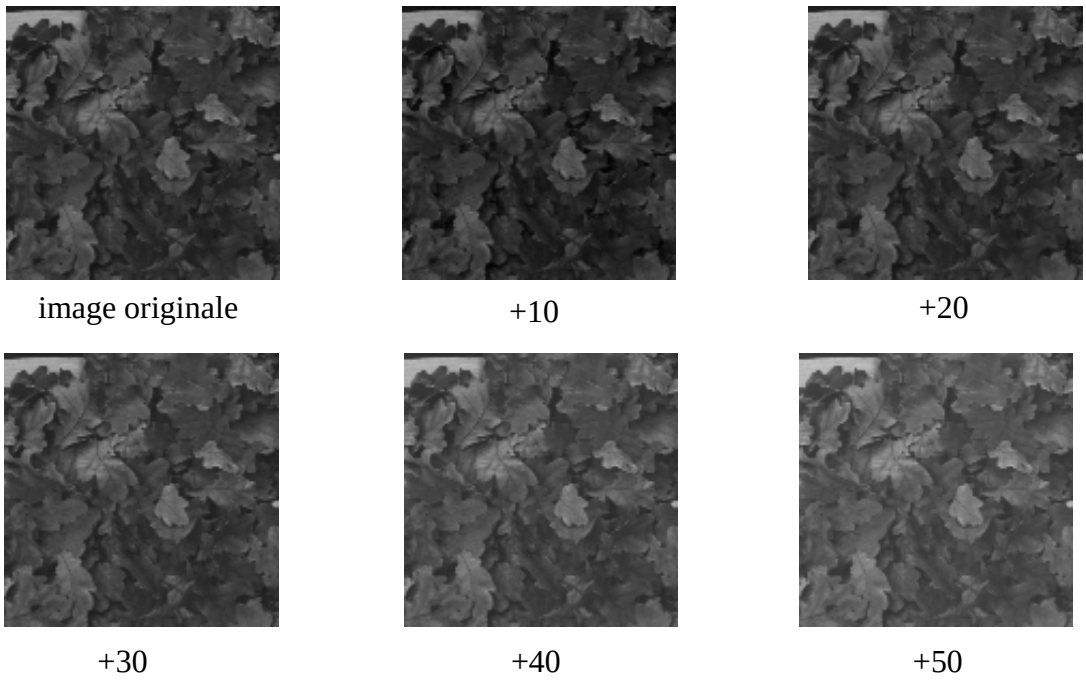


Figure 8: image originale et images translatées de 10 niveaux de gris en 10 niveaux de gris.

On peut remarquer dans la figure 9 que la réponse RMS est linéaire, tout comme la réponse de notre extension de la distance de Baddeley D. Par contre la réponse de Wilson-Baddeley Δ_g ainsi que les réponses de Zamperoni-Starovoitov Dz et la méthode de Hausdorff modifiée MHD ne sont pas linéaires.

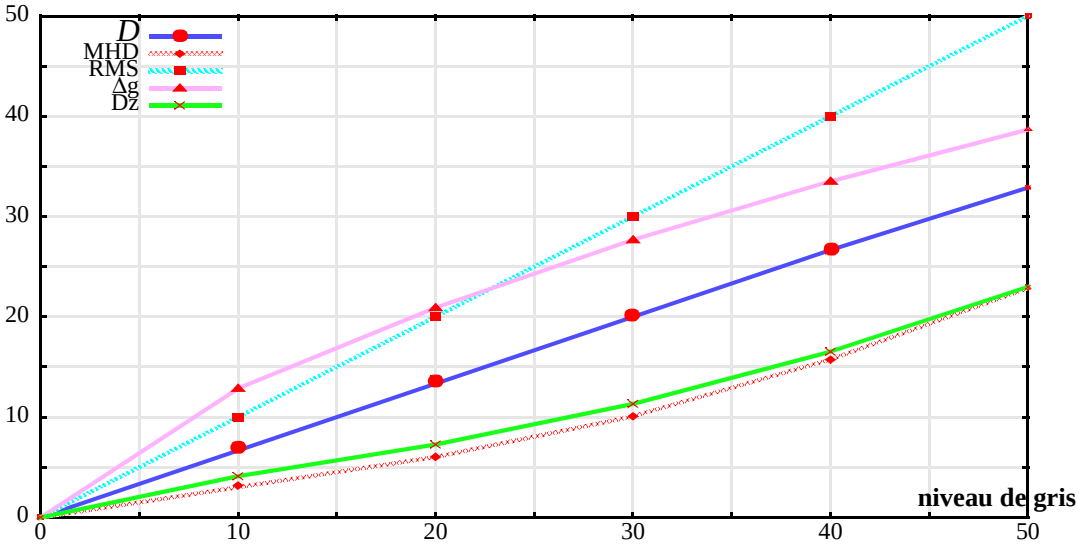


Figure 9: Mesures de dissimilarité par rapport à une augmentation uniforme du niveau de gris.

On notera que pour une augmentation uniforme du niveau de gris, il est préférable que la réponse de l'opérateur de dissimilarité soit linéaire. En effet, les conditions de luminosité lors de l'acquisition d'une image peuvent changer entre deux prises de vues. Avec un opérateur qui possède une réponse linéaire, la comparaison entre les images sera plus facile à étudier.

5.2 Influence du niveau de gris moyen

Les courbes de la figure 10 montrent l'influence de la valeur absolue du niveau de gris sur les mesures de dissimilarité. Les dissimilarités sont tracées pour différents couples d'images successives, la deuxième image est décalée de 10 niveaux de gris par rapport à la première image. On peut remarquer que toutes les dissimilarités sont constantes par rapport au niveau de gris moyen.

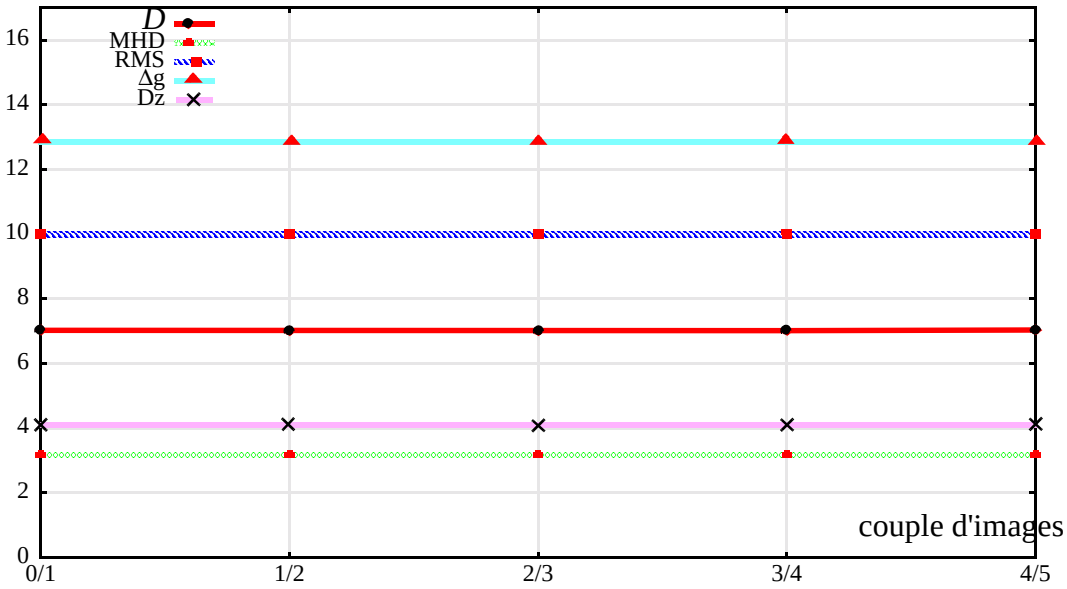


Figure 10: Résultats de la comparaison entre 2 images successives.

5.3 Compression / Décompression

Dans ce paragraphe nous allons étudier l'influence du taux de compression sur les mesures de dissimilarité. L'algorithme de compression utilisé pour faire ces expériences est celui du programme *XV* [13], qui permet de passer d'une image originale, à l'image compressée au format JPEG.

L'image originale est compressée avec des taux de compression croissants. Plus le taux de compression augmente, et plus les distorsions sont visibles à l'oeil, sous forme de pavé. L'image originale est comparée avec chaque version de l'image ayant subi un cycle de compression/décompression et ceci lorsque le taux de compression augmente (Fig. 11).

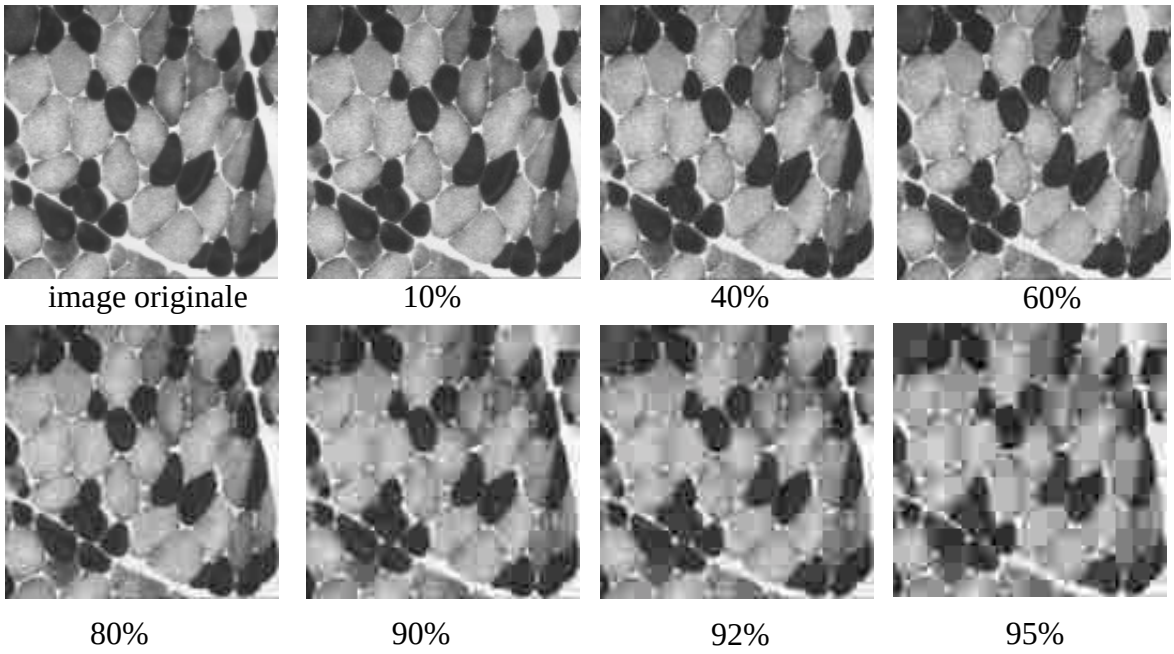


Figure 11: Image originale et images ayant subies un cycle de compression/décompression, avec un taux de compression croissant.
Source: muscle GDR ISIS

Toutes les dissimilarités ont des réponses semblables, exceptée peut être la dissimilarité D, qui a des valeurs plus élevées. Il semble que pour un taux de 60%, l'allure des courbes change, une compression plus importante entraîne davantage de distorsions, que l'on peut distinguer sur les images de la figure 11.

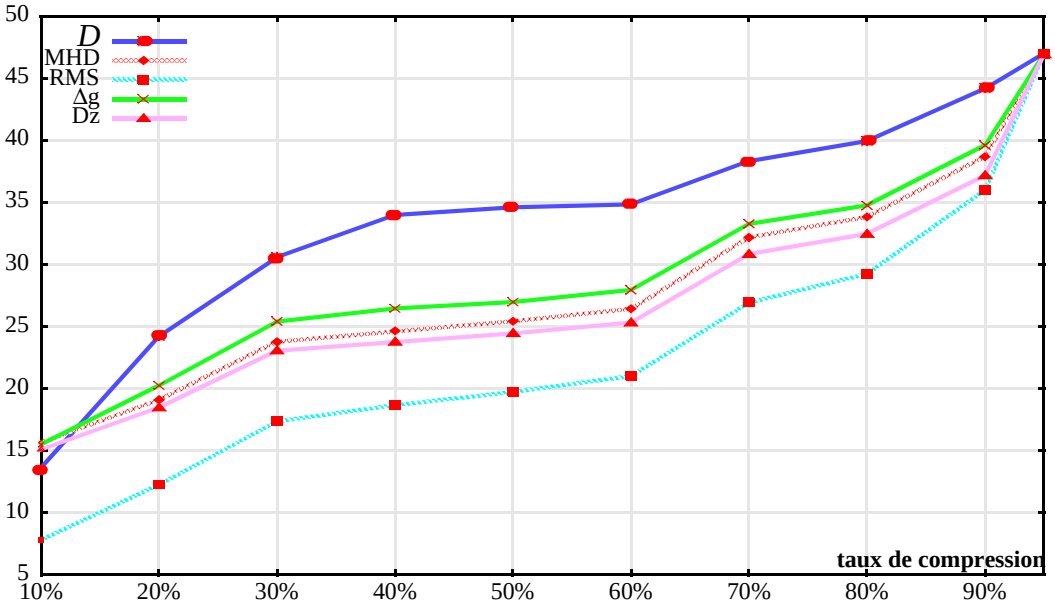


Figure 12: Compression d'images. Dissimilarités en fonction du taux de compression

Toutes les courbes ont été normalisées par un facteur K, afin de ramener leur valeur maximale au même point du graphe. La figure 13 montre l'influence du rapport P/H sur la mesure de dissimilarité D. On peut alors voir, comme nous l'avons établi dans le paragraphe 4.3, que la mesure de dissimilarité tend vers la mesure RMS lorsque le rapport P/H tend vers 0.

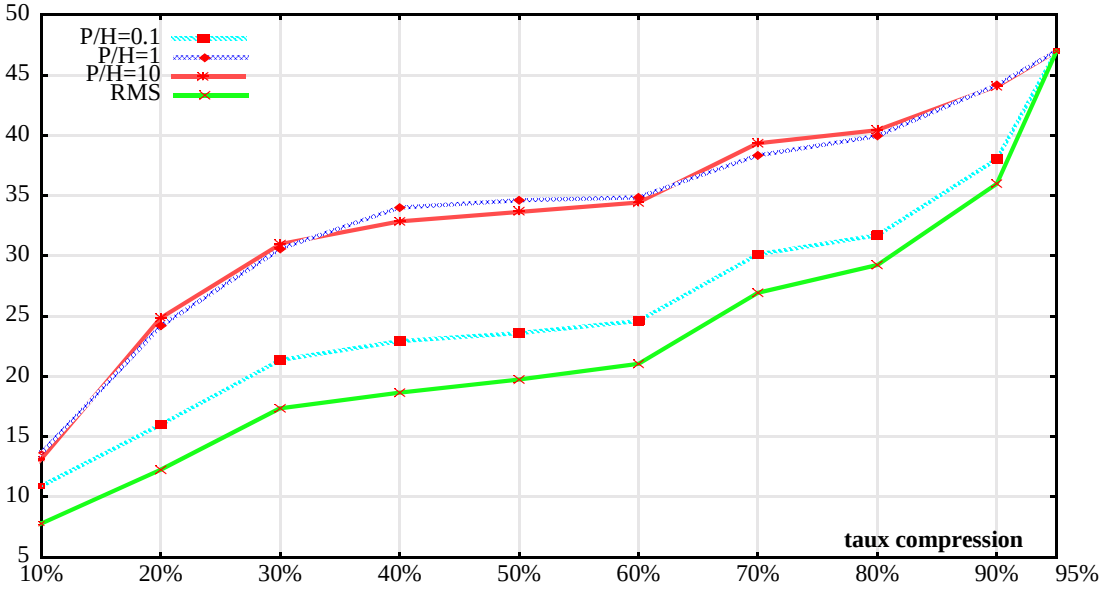


Figure 13: Influence du rapport P/H sur la mesure de dissimilarité D

On peut également conclure que les distorsions dues à la compression sont plus liées à des distorsions spatiales qu'à des distorsions dues à des changements de niveaux de gris.

5.4 Sensibilité à la variation de la forme

Dans ce paragraphe, nous étudions l'effet sur les mesures de dissimilarité, de la rotation d'une caméra. La séquence d'images est composée de 78 vues d'un même objet. La caméra tourne autour de l'objet. La rotation globale est légèrement supérieure à 360 degrés. Cette séquence a été réalisée par Patrick Gros et les images sont accessibles sur le site: http://www.inrialpes.fr/movi/people/Gros/Gros.fr.html. La figure 14 présente quelques images de cette séquence.

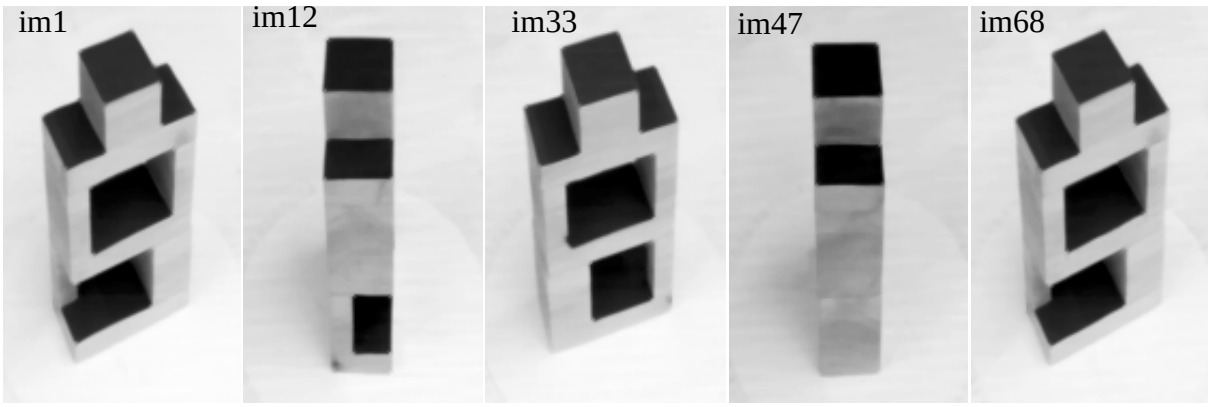


Figure 14: Image originale im1 et quelques images issues de la séquence.

Comme le montre la figure 14, l'image im1 est semblable à l'image im68, mais légèrement différente de l'image im33. En effet, l'image im33 est présentée du coté opposé à l'image im1 et très légèrement décalée. Les images im12 et im47 sont également similaires, mais elles correspondent également aux deux cotés opposés.

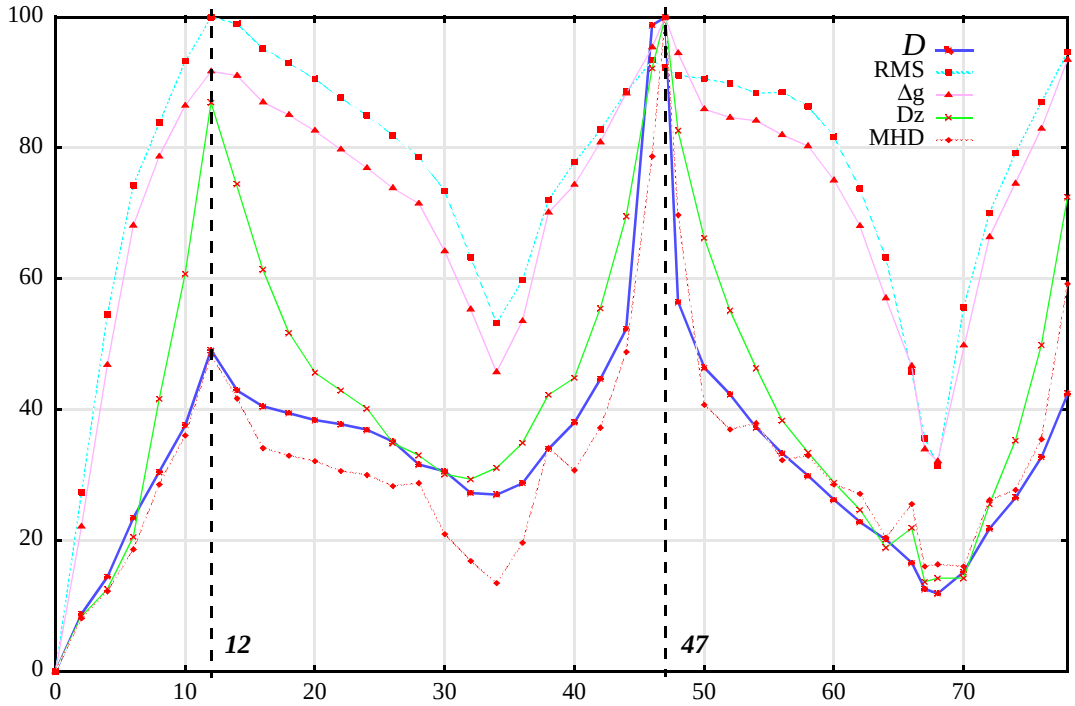


Figure 15: Rotation de la caméra. Mesures de dissimilarité en fonction du numéro de l'image dans la séquence.

La figure 15 montre les différentes mesures de dissimilarité produites par les différents opérateurs en fonction du numéro de l'image dans la séquence. Les courbes sont normalisées ce qui permet de rendre la comparaison plus simple.

On peut remarquer que le maximum global de la courbe du RMS se situe pour l'image im12, alors que pour toutes les autres dissimilarités ce maximum global se situe pour l'image im47. La différence entre l'image im12 et l'image im47 se trouve dans l'encoche sombre au bas de l'objet. Globalement, l'image im47 présente moins de zones sombres que l'image im33, d'où une dissimilarité plus élevée par rapport à l'image d'origine im1.

L'allure de la courbe Δg est très proche de celle du RMS, pour laquelle seules les différences entre les niveaux de gris sont pris en compte dans le calcul. La courbe de la mesure de dissimilarité D est plus régulière que celle de la mesure MHD ou Dz.

Durant toute cette expérience, l'exposant E est pris égal à 2. Pour E variant de 1 à 8, nous obtenons des résultats similaires. Nous pouvons donc conclure que la dissimilarité n'est pas sensible au paramètre E, lorsque celui-ci reste inférieur à 10.

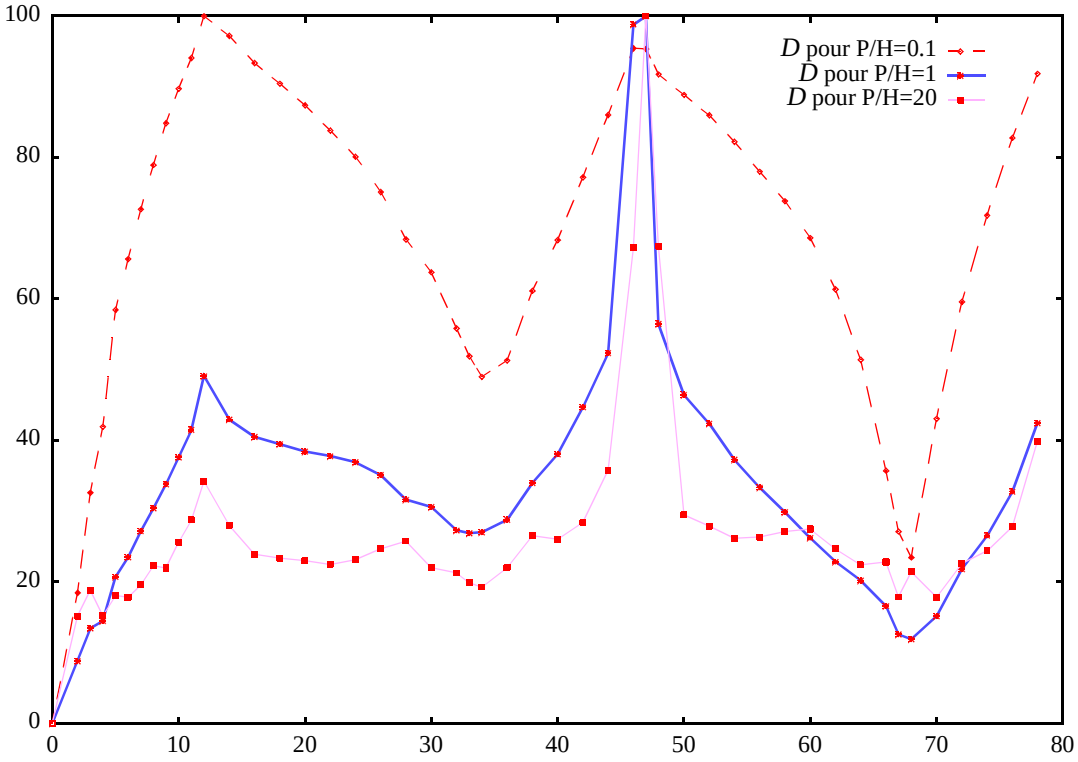


Figure 16: Influence du rapport P/H. P/H valant 0.1; 1; 20.

La figure 16 montre l'influence du rapport P/H sur la mesure de la dissimilarité D. Pour de faible valeur de P/H (P/H=0.1) on obtient une courbe similaire au RMS, ce qui est logique. L'opérateur D est moins sensible aux variations de niveaux de gris qu'aux variations de formes.

6. Conclusion

Dans ce rapport, nous avons introduit une autre façon de calculer la dissimilarité entre deux images en niveaux de gris. Cette mesure est une extension aux images en niveaux de gris de la méthode développée par Baddeley. Le but recherché est d'être sensible aux variations tant en niveaux de gris qu'aux distorsions spatiales. Ces deux types de distorsions peuvent être pondérées par le rapport P/H de la forme du voxel utilisée, pour le calcul des images de distances. Cette dissimilarité a été comparée aux autres dissimilarités connues dans ce domaines, ainsi qu'à la mesure du RMS. Du fait de sa sensibilité aux distorsions spatiales et aux variations de niveaux de gris, cet opérateur pourrait être utilisé en contrôle de qualité, et comme critère pour comparer deux images en niveaux de gris.

Partie 2: Dissimilarité entre images couleurs

1. Introduction:

Nous nous intéressons actuellement à l'extension de ces méthodes aux cas des images couleurs. Vu la représentation des images couleurs, il y a deux approches:

- une approche marginale où l'on exploite séparément l'information sur chaque composante et après on fusionne les résultats; cette méthode a l'inconvénient qu'elle n'exploite pas la corrélation entre les composantes
- une approche vectorielle où l'on prend en compte la nature vectorielle des images couleurs.

Nous nous sommes intéressés à la méthode vectorielle qui permet d'exploiter l'information contenue dans l'image et la corrélation qui existe entre les composantes couleurs de celle-ci. Deux méthodes peuvent être envisagées.

- La première méthode est une extension en 5 dimensions de la méthode développée pour les images en niveaux de gris. L'opérateur 5D est l'extension naturelle de l'opérateur 3D pour les images couleurs. C'est la meilleure façon de tenir compte de la nature vectorielle des pixels des images couleurs. Le grand désavantage de cette méthode est la taille des données. Pour une image 256×256 avec 256 niveaux sur chaque composante on obtient une matrice 5D (l'image de distances) avec 256^5 éléments. Supposant que chaque élément occupe 2 octets (comme le type de données `short int` utilisé par le langage C) la taille de la matrice sera de 2048 GB (avec 1 kB = 1024 B, 1 MB = 1024 kB et 1 GB = 1024 MB).

- La deuxième méthode consiste à indexer les couleurs, donc construire une palette de 256 couleurs et utiliser la méthode des images en niveaux de gris sur les images indexées. C'est cette méthode que nous avons retenue. Des résultats expérimentaux et une comparaison entre plusieurs façons d'exploiter les images de distances pour le calcul de la dissemblance, seront présentés.

2. Méthode basée sur l'indexation des couleurs [14, 15]

Vu la grande taille des données utilisées pour la méthode de l'opérateur 5D, nous avons développé une autre approche afin de réduire la place mémoire et le temps de calcul. La méthode consiste en deux étapes:

- l'indexation des couleurs de l'image 24 bits en conservant le voisinage relatif dans l'espace des couleurs. C'est-à-dire que deux couleurs voisines dans l'espace RVB sont voisines dans la palette de couleurs.
- la construction d'une carte de distances à partir de l'image des indexes obtenue par la première étape.

Le réseau de Kohonen

Pour la première étape nous avons besoin d'une transformée pour indexer les couleurs tout en conservant la propriété de voisinage des couleurs. Nous avons utilisé un réseau de neurones de Kohonen qui a cette propriété.

Le réseau de Kohonen, connu aussi comme SOM (Self Organising Map, [Kohonen-95]), définit une fonction entre l'espace des données Rn et une structure régulière de noeuds à deux dimensions. A chaque noeud i on associe un vecteur référence paramétrique $w_i \in \boldsymbol{R}^n$. On peut considérer ces vecteurs comme les poids du réseau. La structure régulière peut être définie comme une structure rectangulaire ou hexagonale. Le réseau repose sur le principe de la compétition. C'est-à-dire qu'un vecteur d'entrée x est comparé avec wi et la meilleure concordance est définie comme une réponse.

Soit $x \in \boldsymbol{R}^n$ un vecteur d'entrée de l'ensemble de données d'entraînement. Ce vecteur peut être comparé avec les wi en utilisant n'importe quelle sorte de distance (Euclidienne, Mahalanobis etc). Dans la plupart des applications pratiques la distance Euclidienne est utilisée. La meilleure concordance est définie comme la plus petite distance $\|x - w_i\|$ entre le vecteur x et les poids wi. Soit c le noeud pour lequel on a:

$$\|x - w_c\| = \min_i \{\|x - w_i\|\}, \text{ ou}$$
$$c = \arg\min_i \{\|x - w_i\|\} \quad . \tag{17}$$

Pendant l'entraînement, les noeuds qui sont proches du point de vue de la topologie du réseau s'activent les uns les autres pour apprendre la même entrée. Sans démonstration mathématique il est montré dans [Kohonen-95] que les valeurs utiles de wi peuvent être trouvées comme la limite convergente du processus d'apprentissage donné par la relation:

$$w_i(t+1) = w_i(t) + h_{ci}(t)[x(t) - w_i(t)] \quad , \tag{18}$$

avec t entier, la coordonnée discrète du temps, hci(t) une fonction appelée le noyau de voisinage, définie sur les points de la structure rectangulaire. D'habitude $h_{ci}(t) = h(\|r_c - r_i\|, t)$, où $r_c, r_i \in \boldsymbol{R}^2$ sont les vecteurs de la position des noeuds c et i dans le tableau. Quand $\|r_i - r_c\|$ croit, $h_{ci} \to 0$.

Il y a deux façons de choisir la forme de hci(t). La première consiste à choisir une boule Bc autour du noeud c et définir $h_{ci}(t)$ comme suit:

$$h_{ci}(t) = \begin{cases} \alpha(t) & \text{si} \quad w_i \in B_c \\ 0 & \text{sinon} \end{cases} \tag{19}$$

La dimension de la boule sera choisie comme fonction décroissante du temps. $\alpha(t)$ est une fonction monotone et décroissante par rapport au temps. Elle est appelée le taux d'apprentissage.

La deuxième façon de choisir la forme de hci consiste à la choisir comme une fonction Gaussienne:

$$h_{ci}(t) = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right) \tag{20}$$

où $\alpha(t)$ est la même fonction d'apprentissage. Le paramètre $\sigma(t)$ définit la largeur du noyau et correspond au rayon de la boule Bc précédemment citée. Les deux fonctions sont des fonctions monotones et décroissantes. En ce qui concerne le choix de ces deux fonctions, on peut utiliser la définition suivante:

$$\alpha(t) = \frac{A}{B + t} \quad , \tag{21}$$

où A et B sont des constantes.

Nous avons utilisé un cas particulier du réseau de Kohonen. Le tableau de noeuds est un tableau avec une structure topologique circulaire. C'est-a-dire que le dernier noeud du réseau est voisin avec le pre-

mier noeud du réseau.

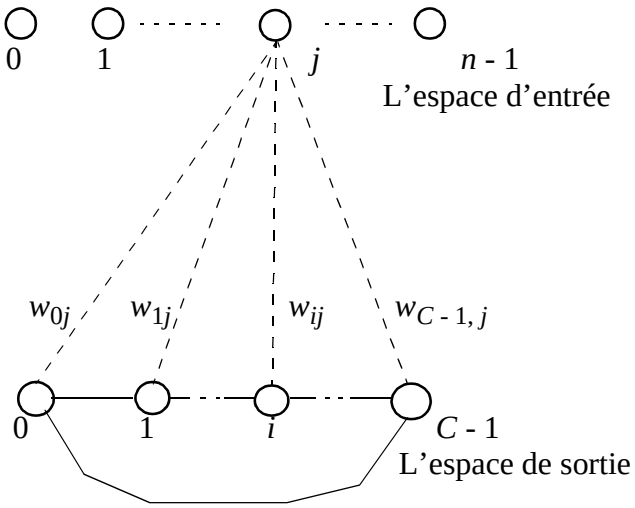


Figure 1: L'illustration de la circularité d'un réseau de Kohonen avec une sortie unidimensionnelle et circulaire (w_i est le vecteur poids, w_{ij} est la composante j du vecteur w_i)

Après l'indexation des couleurs, on obtient une image des indexes dans une palette de couleurs commune aux images que l'on veut comparer. La palette de couleurs est construite à partir des vecteurs wi qui contiennent les vecteurs les plus significatifs des classes. Dans notre cas nous avons choisi de prendre 256 couleurs les plus significatives.

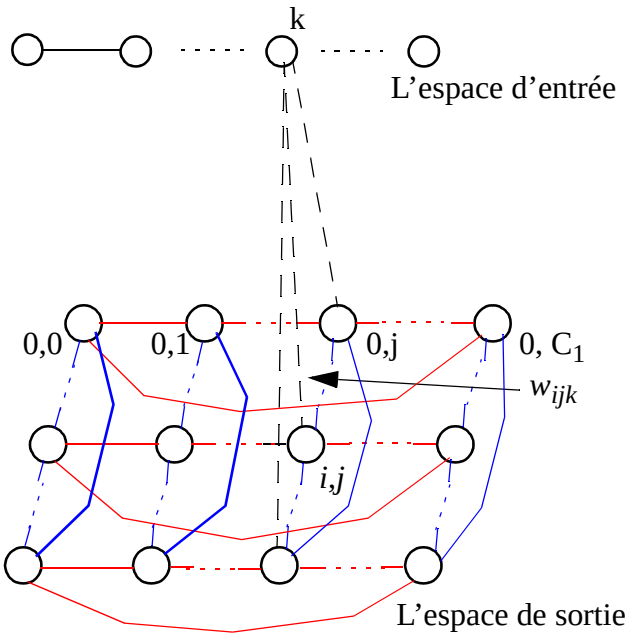
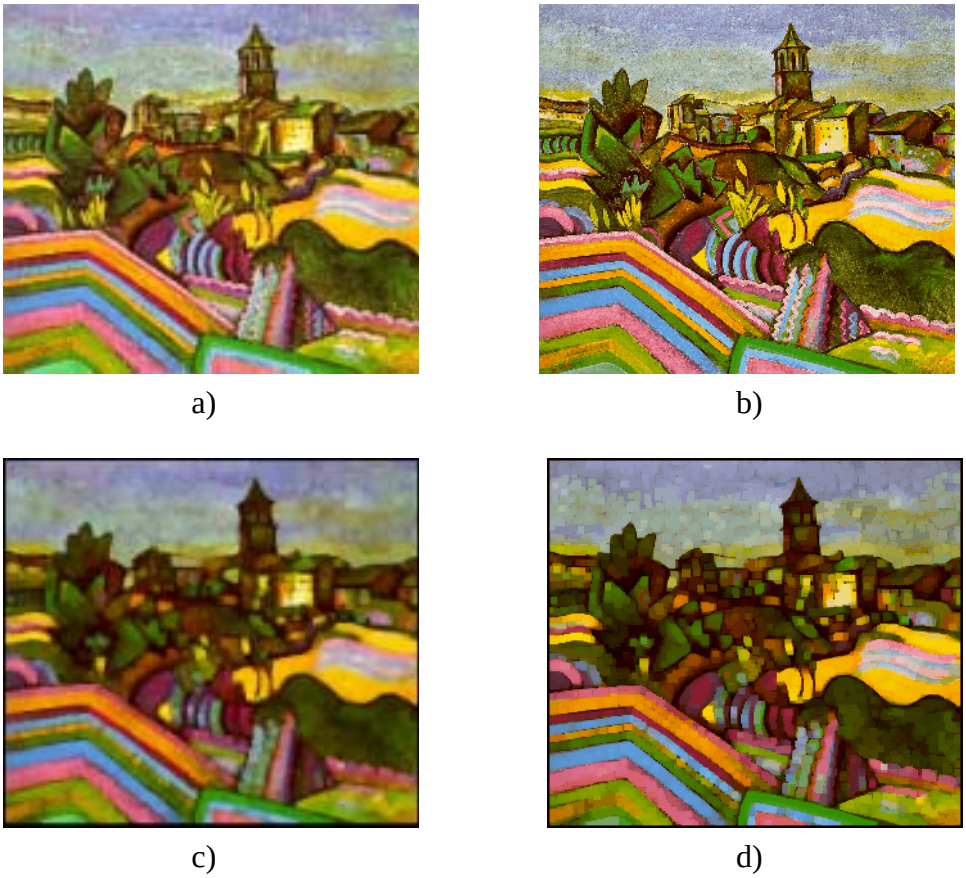


Figure 2: L'illustration de la circularité d'un réseau de Kohonen avec une sortie 2-dimensionnelle et circulaire (w_{ij} est le vecteur poids, w_{ijk} est la composante k du vecteur w_{ij})

Dans ce qui suit on présente quelques résultats expérimentaux sur l'indexation des couleurs en utili-

sant le réseau de Kohonen. On a utilisé plusieurs images pour construire l'ensemble d'entraînement et le nombre de noeuds dans le tableau est 256. Le réseau avec une sortie unidimensionnelle et circulaire donne les meilleurs résultats.
Dans la figure 3, on reprend la topologie du réseau unidimensionnelle et circulaire et on présente le résultat de deux images ainsi indexées, les deux images ayant la même palette de couleurs. Les images



a) b)

c) d)

Figure 3: Résultats expérimentaux de l'indexation des images: a) l'image miro originale, avec la représentation du pixel sur 24 bits; b) l'image miro indexée; c) l'image miro_o5 obtenue par une ouverture morphologique; d) l'image miro_o5 indexée

indexées sont très proches des images originales. Nous avons testé cette méthode d'indexation des images de couleurs sur de nombreuses images et les résultats sont similaires à ceux présentés.
Cette méthode d'indexation des couleurs nous permet donc de passer d'un espace 5D (x, y, r, g et b comme coordonnées) à un espace 3D (seulement x, y, c comme coordonnées). Cependant, contrairement aux cas des images à niveaux de gris où les niveaux sont équirépartis entre 0 et 255 (deux niveaux successifs sont distants de 1), l'indexation des couleurs nous donne des couches successives de tailles différentes. Nous n'allons pas pouvoir utiliser le principe de calcul des images de distances décrit précédemment puisque les niveaux ne sont pas équidistants. Nous allons utiliser l'opérateur de distance en maillage parallélépipédique dont nous rappellerons le principe de calcul.

3. Image de distances en maillage parallélépipédique (3D)

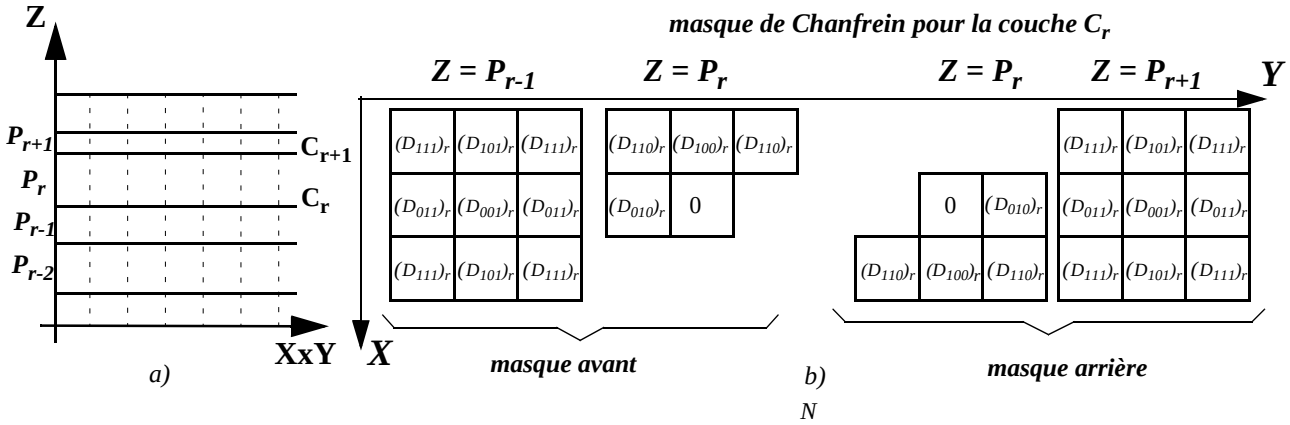
Pour les images 3D telles que les images sismiques ou les images médicales formées de coupes scanner successives, le pas d'échantillonnage varie selon la direction considérée. Le maillage du volume est donc parallélépipédique et un cas particulier est le maillage cubique. Le maillage parallélépipédique est défini par une grille 3D dont l'élément est un parallélépipède donné par ses 3 dimensions no-

tées L (Largeur), H (Hauteur) et P (Profondeur). L, H, P sont des réels positifs non nuls et en général on a $L \neq H \neq P$. On considère dans la suite que $H \leq L \leq P$. Les autres cas en découlent à une permutation d'indices près.

Comme dans le cas des maillages rectangulaires, en maillages parallélépipédiques il y a seulement une symétrie par rapport aux axes Ox, Oy et Oz. On peut diviser la sphère (qui est l'extension en 3D du cercle utilisé dans le cas 2D) en 8 parties égales. L'étude de l'optimisation des opérateurs locaux de distance 3D peut être effectué dans l'une de ces 8 parties. Nous choisissons de faire les calculs dans la partie pour laquelle x, y et z sont positifs.

Le principe de la distance locale en 3D est le même qu'en 2D. La distance $d_L(O, Q)$ entre deux voxels O(0, 0, 0) pris comme l'origine et un voxel Q(x, y, z) est la longueur du plus court chemin entre O et Q. En 3D, le plus court chemin est constitué de 3 segments de droite au plus, suivant les trois directions délimitant la proportion à l'intérieur de laquelle le voxel Q appartient.

Cette distance $d_L(O, Q)$ est calculée par propagation d'opérateurs locaux de distance dont les coefficients sont calculés selon certains critères. Le critère d'optimisation des coefficients est le même que celui utilisé en 2D, c'est-à-dire la minimisation de l'écart maximum entre la distance locale et la distance Euclidienne $d_E(O, Q) = \sqrt{x^2L^2 + y^2H^2 + z^2P^2} = R$, lorsque Q décrit une trajectoire sphérique.



$\boldsymbol{P_r}$ est défini par: $P_r = \|c_r - c_{r+1}\| / \overline{c_r}$ avec $\overline{c_r} = \frac{1}{N}\sum_{i=1} c_i$ (22)

Pour chaque couche $\boldsymbol{C_r}$ nous calculons les coefficient du masque. Les coefficients réels $(d_{ijk})_r$ sont donnés par:

$$(d_{ijk})_r = (T_{ijk})_r \cdot \frac{(d_{010})_r}{W} \quad \text{avec} \quad (T_{ijk})_r = \sqrt{(iW)^2 + (jH)^2 + (kP_r)^2} \tag{23}$$

$$\text{avec} \quad (d_{ijk})_r = \frac{-2W + 2W \cdot \sqrt{1 + \lambda_r}}{\lambda_r} \tag{24}$$

$$\text{et} \quad \lambda_r = \frac{1}{W^2} \cdot [(T_{1m0})_r - m \cdot H]^2 + \frac{1}{P_r^2} \cdot [(T_{1m1})_r - (T_{1m0})_r]^2 \tag{25}$$

Nous avons autant de masques que de couches, les coefficients de chaque masque étant adapté à l'épaisseur $\mathbf{P_r}$ de la couche **r**. Les coefficients entiers $(D_{ijk})_r$ utilisé dans le masque de chanfrein sont obtenus en multilipant les coefficients réels $(d_{ijk})_r$ par un entier N et en arrondissant à l'entier le plus proche:

$$(D_{ijk})_r = round[N \cdot (d_{ijk})_r] \tag{26}$$

4. Le calcul des images de distances des images de couleurs indexées

Les images ainsi indexées seront traitées comme des images en 256 niveaux de gris. La méthode de calcul a ***2 particularités***.

La ***première particularité*** c'est dans la configuration circulaire du réseau Etant donnée la circularité

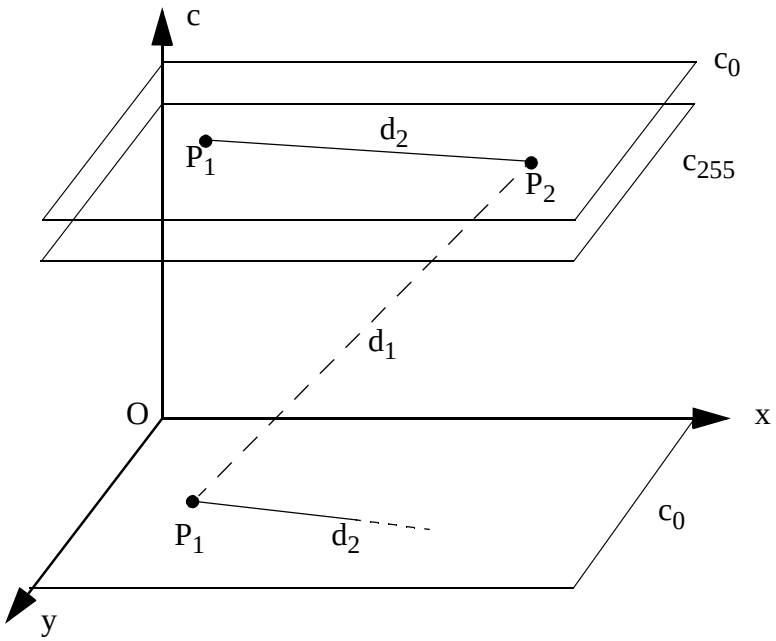


Figure 4: La circularité du réseau modifie le voisinage aux bordes ($P_1 \in \text{plan}(c_0)$, $P_2 \in \text{plan}(c_{256})$)

du réseau, les couches c_0 et c_{256} seront aussi voisines. La conséquence est que le plus court chemin entre $P_1 \in \text{plan}(c_0)$ et $P_2 \in \text{plan}(c_{256})$ ne sera plus d_1 comme dans le cas des images en niveaux de gris mais le chemin d_2. Il faudra donc en tenir compte dans l'algorithme de calcul de l'image des distances. Le passage d'un masque sera fait deux fois aller et deux fois retour à cause de la circularité du réseau.

La ***deuxième particularité*** concerne les couches. L'axe Oz qui correspond aux indexes dans la palette de couleurs dans ce cas n'est pas uniformément échantillonnée. C'est-à-dire que la distance entre les couches c_{i-1} et c_i n'est pas la même que la distance entre les couches c_i et c_{i+1}. On a deux façons pour résoudre ce problème. Soit on fait un **sous-échantillonnage** soit on utilise un **masque déformable**. Nous allons exposer ces deux méthodes dans ce qui suit.

4.1 Méthode basée sur le sous-échantillonnage

Pour le sous-échantillonnage on cherche la plus petite distance entre deux couleurs successives. Soit p l'indice définit comme

$$p = \arg\min_i \{d(c_i, c_{i+1})\} \quad . \tag{27}$$

où $d(c_i, c_{i+1}) = \|c_i - c_{i+1}\|$ est la distance entre deux couleurs successives. Pour chaque intervalle [ci, ci + 1] on génère artificiellement ni sous-couches, où ni est définit par la relation

$$n_i = \left[\frac{d(c_i, c_{i+1})}{d(c_p, c_{p+1})}\right] \tag{28}$$

avec [.] l'opérateur qui arrondit à l'entier le plus proche.

Le désavantage de cette méthode est qu'on peut se trouver dans le cas où la distance la plus petite est tellement petite par rapport aux autres que le nombre total de sous-couches est très grand. Par exemple, l'image cub (voir figure ??) génère une palette de couleurs pour laquelle on rencontre la plus petite distance entre les couleurs 28 et 29 (0.6648; une seule couche) et la plus grande distance entre les couleurs 133 et 134 (9.4967; 14 couches). En faisant la somme de toutes les couches, on arrive à 1279 couches. L'image a une taille 256×256 et la matrice 3D obtenue aura $256 \times 256 \times 1279 = 83820544$ éléments. En supposant toujours que la taille d'un élément de 2 octets, la mémoire occupée sera de 159.88 MB. Une telle matrice demandera un temps de traitement important. Nous allons donc proposer une autre approche pour calculer les images de distance des images de couleurs indexées.

4.2 Méthode basée sur le masque déformable

Pour le masque déformable on calcule les coefficients du masque sachant que la distance entre 2 couches successives n'est pas constante. Alors comment allons-nous calculer les coefficients P, c'est-à-dire la profondeur d'un voxel? Ce coefficient n'est pas constant et il dépend de la distance entre 2 couleurs successives. Nous allons utiliser pour le calcul de Pi l'écart entre deux couleurs successives:

$$P_i = d(c_i, c_{(i+1) \bmod 256}) = \left\| c_i - c_{(i+1) \bmod 256} \right\| \quad . \tag{29}$$

En utilisant cette relation, nous soulevons le problème de l'optimisation des coefficients du masque. Pour l'optimisation des coefficients d'un masque de taille quelconque nous devons tenir compte de tous les coefficients Pi, avec $i = 0, \ldots, 255$. Vu la complexité des calculs nous nous contenterons d'utiliser un masque $3 \times 3 \times 3$ et les relations III.18 et III.19 seront remplacées par les relations suivantes:

$$(d_{010})_k = \frac{-2H + 2H\sqrt{1+\lambda_k}}{\lambda_k} \quad \text{avec} \quad \lambda_k = \frac{1}{L^2}(T_{110} - H)^2 + \frac{1}{P_k^2}(T_{111} - T_{110})^2 \quad \text{et} \tag{30}$$

(31)

(32)

$$(d_{ijk})_k = T_{ijk}\frac{(d_{010})_k}{H} \quad \text{avec} \quad T_{ijk} = \sqrt{(iL)^2 + (jH)^2 + (kP_k)^2} \quad . \tag{33}$$

5. Les résultats expérimentaux

5.1 Méthodes d'évaluation des dissimilaritées

Nous avons utilisé deux méthodes d'évaluation des dissimilaritées.

La première est une extension de la distance de Baddeley [Wilson-97, Coquin-97, Coquin-98] notée D_{AB}, définie par la relation:

$$D_{AB} = D(A, B) = \left[\frac{\sum_{v \in V} |d_A(v) - d_B(v)|^p}{N} \right]^{\frac{1}{p}} \quad , \tag{34}$$

avec v le voxel (x, y, c), V le volume $S \times C$ ($S \subset \mathbf{Z}^2$ est le domaine sur lequel les images sont définies, $C = \{0, 1, \ldots, 255\}$ l'ensemble des indexes ou bien de niveaux de gris), p une puissance (on prend généralement p = 2) $d_A(v)$ (resp. $d_B(v)$) la distance Euclidienne entre le voxel v et la surface de référence $F_A(x, y, c)$, l'ensemble binaire caractérisant l'image A (resp. $F_B(x, y, c)$), N = card(V).

Pour la deuxième méthode on suppose les voxels de l'image binaire F_A de niveau 1 comme des points de référence à partir desquels on applique une transformation de distance. Soient D_A et D_B les cartes de distances pour l'image A et l'image B. A tout pixel de l'image B on associe la distance $d_B(x, y) = D_A(x, y, f_B(x, y))$, où f_B est la fonction $f_B : S \to C$ définie par l'image B.

La dissemblance entre les deux images avec A comme image de référence est donnée par la relation [Coquin-95]:

$$\overline{D_{B \to A}} = \frac{\sum_{(x,y) \in S} d_B(x,y)}{\mathrm{card}(S)} \quad . \tag{35}$$

Nous avons calculé également les dissemblances $\overline{D_{A \to B}}$ avec l'image B comme image de référence. Dans le cas de la méthode du sous-échantillonnage, les formules IV.1 et IV.2 sont modifiées comme suit:

- dans la formule 34, $d_A(v) = d_A(x, y, c)$ sera calculée comme une moyenne de toutes les sous-couches qui correspondent à la couleur c. C'est-à-dire $d_A(x,y,c) = \frac{\sum_{i \in V_c} D_A(x,y,i)}{n_c}$, où V_c est l'ensemble des indexes des sous-couches qui correspondent à la couleur c et $n_c = \mathrm{card}(V_c)$. De même pour $d_B(v)$;
- dans la formule 35, $d_B(x, y)$ sera calculée aussi comme une moyenne de toutes les sous-couches de D_A qui correspondent à la couleur $f_B(x, y)$. C'est-à-dire $d_B(x,y) = \frac{\sum_{i \in V_{f(x,y)}} D_A(x,y,i)}{n_{f(x,y)}}$, où $V_{f(x,y)}$ est l'ensemble des indexes des sous-couches correspondants à la couleur $f(x,y)$ et $n_{f(x,y)} = \mathrm{card}(V_{f(x,y)})$.

Nous avons testé notre méthode en considérant les 5 situations suivantes:

- la variation de la luminance;
- la variation de la teinte;
- la variation de la saturation;
- le déplacement géométrique;
- l'effet d'une opération morphologique.

5.2 Influence de la Luminance, de la Teinte et de la Saturation

Nous avons pris l'image ombrel.ras et nous avons fait varier la luminance de $\pm 5\%$, $\pm 10\%$, $\pm 15\%$. Nous avons construit une palette commune à toutes les images par la méthode mentionnée précédemment et nous avons calculé les mesures de dissimilaritées entre l'image originale et les images avec la luminance modifiée.

Nous avons calculé les dissimilaritées D_{AB} et RMS



a) -20 **b) original** **c) +20**

Figure 5: variation de l'intensité

La figure 6 montre l'allure de la dissimilarité en fonction de l'intensité. L'image de référence est l'image de la figure 5b. D_{AB} est quasi linéaire pour une variation de l'intensité supérieure à 2.

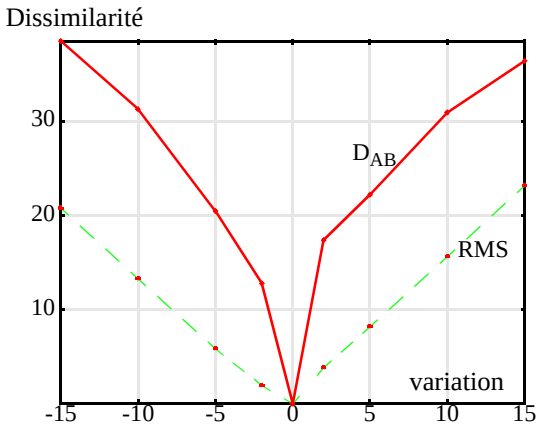


Fig 6: *Dissimilarité en fonction de l'intensité*

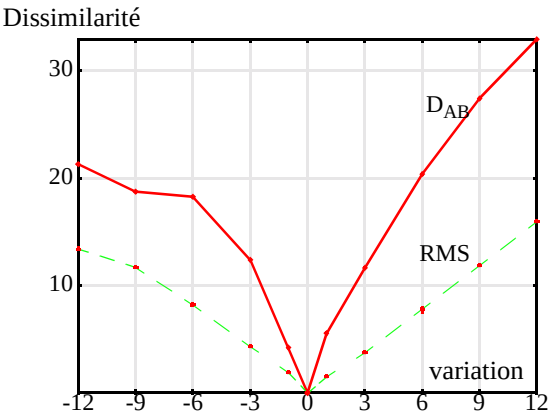


Fig 7: *Dissimilarité en fonction de la Teinte*

On observe les mêmes phénomènes pour une variation de la Teinte ou de la Saturation.

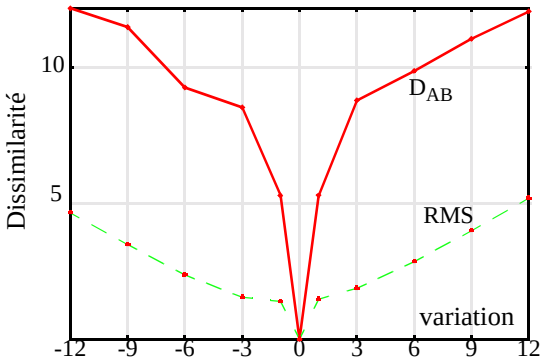


Fig. 8: Dissimilarité en fonction de la Saturation

5.3 Influence du déplacement géométrique

Nous avons pris l'image cub.ras et nous avons déplacé le contenu de 5, 10, 15, 20 et 25 pixels. La figure 9 montre la linéarité de notre mesure de dissimilaritée en fonction du déplacement.

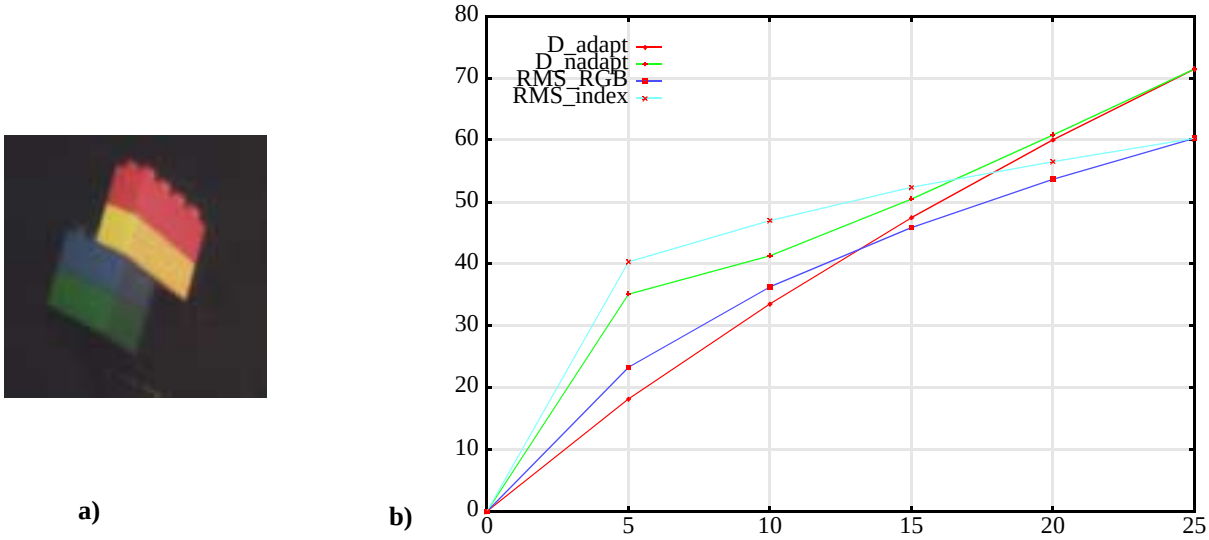


Figure 9: *a) image original indexée*
b) Dissimilarité Globale

- Influence du nombre de couches

Afin de réduire la taille de l'espace mémoire et le temps de traitement, il est possible de réduire le nombre de couleurs lors de l'indexation des images. On peut voir l'effet de la réduction du nombre de couleurs dans la figure ci -dessous. La réduction du nombre de couleurs ne change pas le comportement de l'allure de la dissimilarité, qui reste quasi linéaire, lors d'un déplacement spatial de l'objet cube.

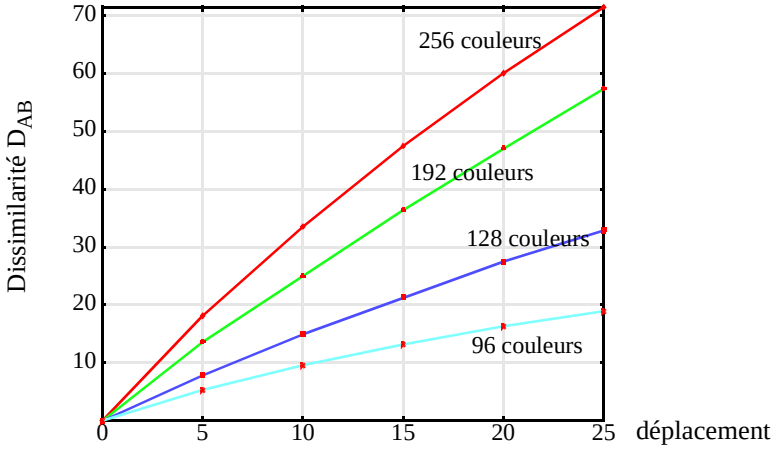
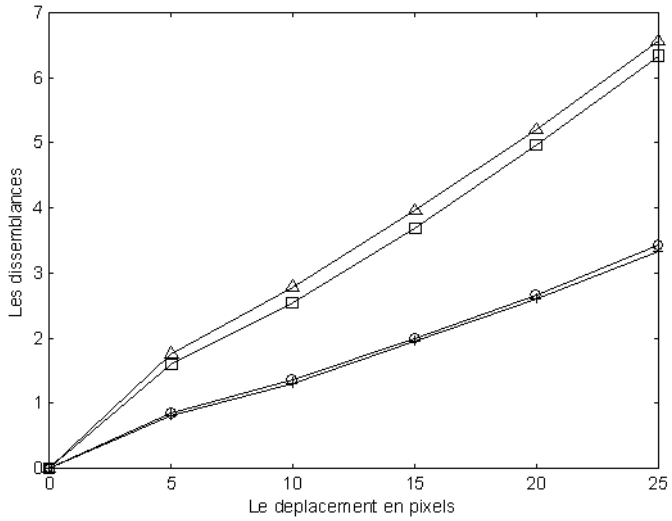


Figure 10: réduction du nombre de couleurs



a)



b)

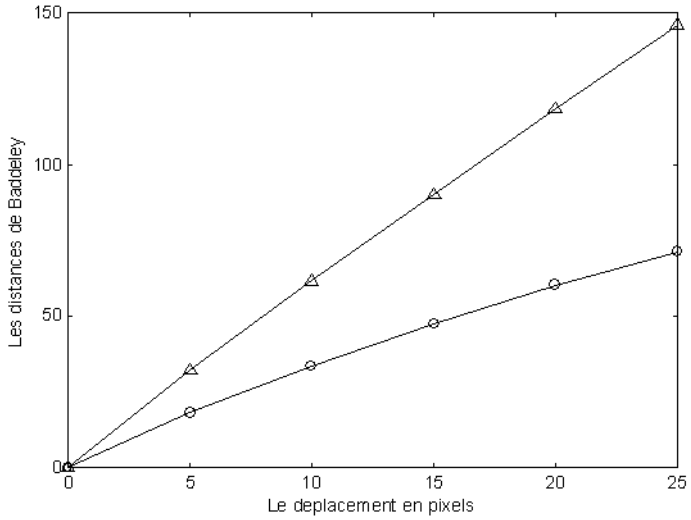
LEGENDE:

○ pour $\overline{D_{def,\,B\to A}}$

\+ pour $\overline{D_{def,\,A\to B}}$

△ pour $\overline{D_{ech,\,B\to A}}$

□ pour $\overline{D_{ech,\,A\to B}}$



c)

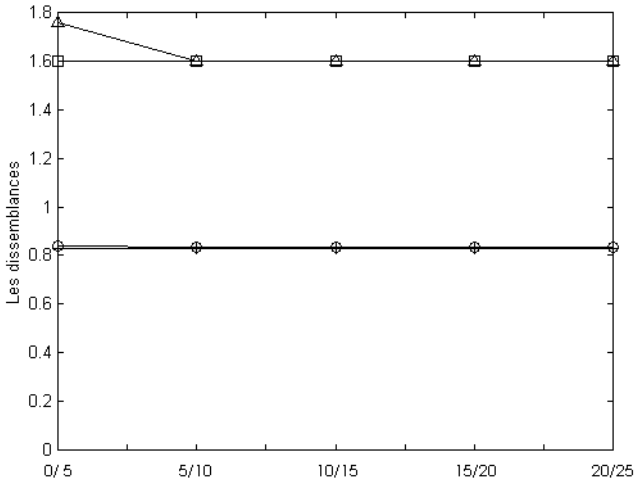
LEGENDE:

○ pour $\overline{D_{AB,\,def}}$

△ pour $\overline{D_{AB,\,ech}}$

Figure 11: Comportement des dissimilaritées en fonction du déplacement: a) l'image cub.ras utilisée; b) les dissemblances; c) l'extension de la distance de Baddeley D_{AB}

Les figures 11 et 12 montrent les courbes des dissemblances et de l'extension de la distance de Baddeley pour les images successives.



LEGENDE:

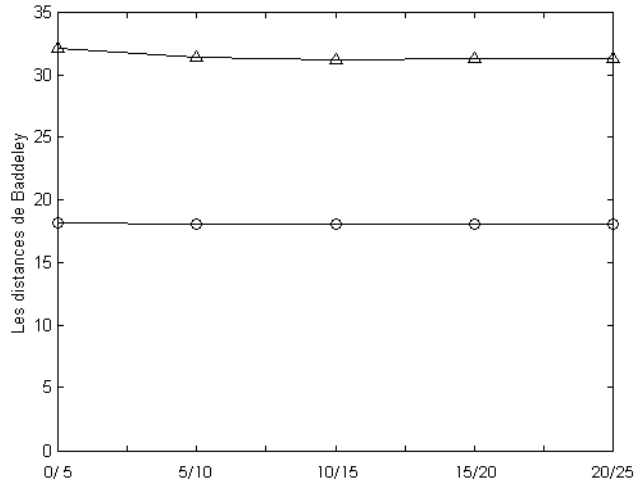
○ pour $\overline{D_{def,\,B\to A}}$

\+ pour $\overline{D_{def,\,A\to B}}$

△ pour $\overline{D_{ech,\,B\to A}}$

□ pour $\overline{D_{ech,\,A\to B}}$

a)



LEGENDE:

○ pour $\overline{D_{AB,\,def}}$

△ pour $\overline{D_{AB,\,ech}}$

b)

Figure 12: Comportement de la différence entre les images successives pour le déplacement: a) les dissemblances; b) l'extension de la distance de Baddeley D_{AB}

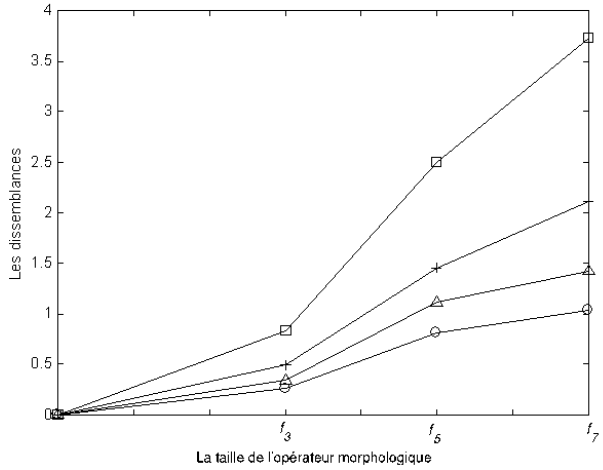
Conclusion: Comme on l'attendait, la variation des dissemblances est linéaire par rapport au déplacement géométrique. Le rapport $\overline{D_{def,\,B\to A}}(\Delta x)/\Delta x$ est toujours constant. De même pour les autres rapports $\overline{D_{def,\,A\to B}}(\Delta x)/\Delta x$, $\overline{D_{ech,\,B\to A}}(\Delta x)/\Delta x$, etc. Les courbes de la figure 12 nous confirment cette conclusion puisque on peut observer que la différence entre 2 images successives est toujours constante.

5.4 L'effet d'un filtre morphologique

Nous avons analysé le comportement de notre méthode à l'effet d'un filtre morphologique. Nous avons pris les images munch1 ([Chanussot-98], figure 13a) et les images filtrées par une fermeture morphologique dont l'opérateur de filtrage a une taille variable (3, 5 et 7). Les résultats sont montrés dans la figure 13.

a)





b)

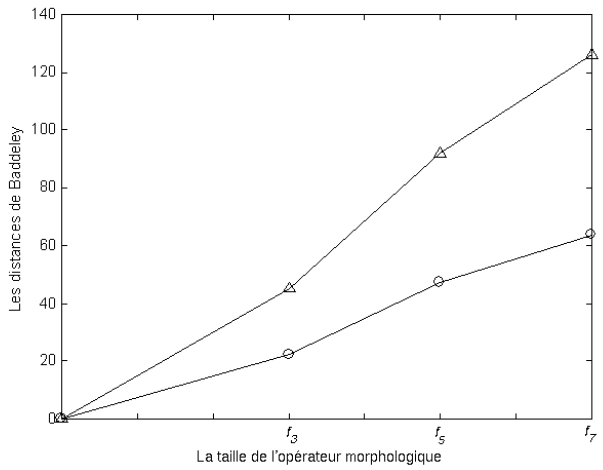
LEGENDE:

○ pour $\overline{D_{def,\,B\to A}}$

\+ pour $\overline{D_{def,\,A\to B}}$

△ pour $\overline{D_{ech,\,B\to A}}$

□ pour $\overline{D_{ech,\,A\to B}}$



c)

LEGENDE:

○ pour $\overline{D_{AB,\,def}}$

△ pour $\overline{D_{AB,\,ech}}$

Figure 13: Comportement des dissimilaritées en fonction de l'opérateur morphologique: a) l'image munch1.ras utilisée; b) les dissemblances; c) l'extension de la distance de Baddeley D_{AB}

Les dissimilaritées croissent avec la taille de l'opérateur morphologique ce qui nous permet de dire que plus la taille de la fenêtre de filtrage augmente, plus les images obtenues sont différentes. Ce test permet de mettre également en évidence le fait que les dissimilaritées tiennent compte des déplacements spatiaux des structures composant l'image.

6. Conclusion de la partie 2

Du point de vue mathématique, la méthode de l'opérateur en 5 dimensions est la méthode la mieux adaptée à la structure des données. Elle exploite de la meilleure façon l'intercorrélation entre les composantes, les déplacements géométriques et les variations de couleur. Mais le principal inconvénient est la taille gigantesque de la structure des données et le temps de calcul nécessaire pour les traiter.

Les méthodes de l'indexation des couleurs réalise un compromis entre l'exploitation de la nature vectorielle des images couleurs d'une part et la taille des données de l'autre. Un désavantage de cette méthode est la troncation du nombre des couleurs qui a comme résultat une perte d'information concernant la variation de la couleur et qui constitue une source d'imprécision dans l'évaluation des dissimilaritées. Le problème géométrique complexe du calcul des coefficients optimaux du masque posé par la distance différente entre les couleurs constitue une autre source d'imprécision. En revanche, on gagne beaucoup en temps de calcul et en taille de données.

Nous avons montré que les mesures de dissimilaritées étaient sensibles à la variation de la teinte, de la saturation, de la luminance ainsi qu'aux déplacements des objets dans l'image. Cette technique de mesure peut donc être utilisée pour évaluer des opérations de prétraitement sur des images couleurs.

Nous remarquons que la variation des dissemblances est plus régulière que la variation des mesures obtenues par l'extension de la distance de Baddeley D_{AB} . De plus, la méthode basée sur le sous-échantillonnage donne toujours des réponses de plus fortes amplitudes que la méthode basée sur le masque déformable, donc cette méthode est plus sensible aux variations des paramètres.

7. Références

[1] A. J. Baddeley. "An error metric for binary images". Robust Computer Vision, Wichmann, Karlsruhe, pp 59-78, 1992.

[2] G. Borgefors. "Distance transformations in arbitrary dimensions", CVGIP, vol 27, pp 321-345, 1984.

[3] D. Coquin, Ph. Bolon. "Discrete distance operator on rectangular grids" Pattern Recognition Letters 16, pp 911-923, 1995

[4] D. Coquin, Ph. Bolon, Y. Chehadeh. "Opérateurs de distance 3D - Application à la comparaison d'images", Actes du 15ème colloque GRETSI, pp 761-764, September 1995.

[5] M.P. Dubuisson, A. K. Jain. "A modified Hausdorff Distance for object matching", Proceeding 12th International Conference on Pattern Recognition. pp 566 - 568, Jerusalem, Israel, October 1994.

[6] D. P. Huttenlocher, G. A. Klanderman, W. J. Rucklidge. "Comparing Images using the Hausdorff Distance", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol 15, No 9, pp 850 - 863, September 1993.

[7] G. Matheron. "Random sets and integral geometry", ppix-x, 12-21, 128, John Wiley & Sons, NY, 1975.

[8] A. Rosenfeld, J. Pfaltz. "Sequential operations in digital picture processing" Journal of the ACM 13, pp 471-494. 1966

[9] B. Verwer. "Local distances for distance transformations in two and three dimensions". Pattern Recognition Letters 12, pp 671-682, 1991.

[10] D. L. Wilson, A. J. Baddeley, R. A. Owen, "A new metric for grey-scale image comparison", International Journal of Computer Vision, vol 24, No 1, pp 5-18, August 1997.

[11] P. Zamperoni, V. Starovoitov. "On measures of dissimilarity between arbitrary gray-scale images?". International Journal of shape Modeling, Vol. 2, No. 2&3, pp189-213, 1996.

[12] D. Coquin, Ph. Bolon, Y. Chehadeh. " Evaluation quantitative d'images filtrées", Actes du 16ème colloque GRETSI, pp 1351-1354, September 1997.

[13] *XV*, logiciel de visualisation d'images développé par J. Bradley, version 3.10, 1994.

[14] D. Coquin, Ph. Bolon, A. Onéa, "3D Nonstationnary local distance operator", *IEEE 15th International Conference on Pattern Recognition* (ICPR 2000), pp. 963-966, Barcelona, Spain, 2000.

[15] D. Coquin, Ph. Bolon, A. Onéa, "Objective metric for colour image comparison", *10th European Signal Processing Conf.* (EUSIPCO'2000), pp. 119-122, Tampere, Finland, September 2000.

[16] D. Coquin, Ph. Bolon, B. Ionescu, "Dissimilarity measure in color spaces", *IEEE 16th Int. Conf. on Pattern Recognition* (ICPR 2002), pp. 612-615, Quebec City, Canada, August 2002.