
Mesure de la netteté sur une image seule dans des documents anciens

Emile Vinsonneau* — Jean-Philippe Domenger** — Anne Cherif*

* i2S

30 Rue Jean Perrin, 33608 Pessac
e.vinsonneau@i2s.fr, a.cherif@i2s.fr

** Laboratoire LaBRI, Equipe Image et Son

351, cours de la Libération, 33405 Talence Cedex
jean-philippe.domenger@labri.fr

RÉSUMÉ. Cet article présente différentes méthodes permettant d'analyser le flou de focus dans le contexte de numérisation. Nous allons définir des méthodes pour mesurer cette information. Ensuite, nous estimerons la pertinence de ces mesures en faisant varier le flou. Puis enfin, nous associerons ces informations en utilisant un modèle d'apprentissage supervisé afin d'évaluer le gain possible de cette mesure.

ABSTRACT. This article presents some way to do quality control after digitization, specially out of focus problem. We will enumerate different point of view to analyse and to estimate this information. To validate descriptors, we suggest to blur any picture and to compute blur estimation in order to evaluate precision. After that, we propose to combine descriptors by machine learning.

MOTS-CLÉS : documents anciens, apprentissage automatique, flou de focus, contrôle qualité, workflow de numérisation.

KEYWORDS: old document, machine learning, out of focus, quality control, digitization workflow.

1. Introduction

Le travail présenté, ici, se situe dans un contexte industriel en collaboration avec l'entreprise i2S qui développe une chaîne de numérisation complète dont l'objectif est la valorisation du contenu. L'un des maillons de cette chaîne est le contrôle qualité. Son objectif est de mesurer les défauts de numérisation afin de rejeter ou de retraiter le document si besoin. Les défauts recensés portent notamment sur le flou (focus, bougé), ou encore la saturation, les ombres, etc.

Lors des campagnes de numérisation, le contrôle qualité est systématique afin de produire les résultats spécifiés dans le cahier des charges techniques. Il existe un contrôle sur le matériel de numérisation qui est soumis aux normes industriels de la FADGI (FADGI, 2010), ces normes permettent de valider/quantifier les performances des scanners mais aussi de les calibrer au mieux. Certaines étapes se basent sur la reproduction de mires de référence. Connaissant les caractéristiques physiques de la mire (géométrie, colorimétrie), il est possible de déterminer la résolution, le contraste, et aussi d'améliorer la mise au point. Certains des éléments présents sur la mire sont utilisables par l'autofocus et fournissent des informations pour la mesure du flou. Dans le cadre de ce travail, nous nous intéresserons à quantifier le flou du à un défaut de mise au point, en utilisant uniquement le document (sans mire).

Le flou de focus est un défaut optique qui crée une divergence du rayon lumineux, cela se traduit par un étalement et une dégradation des hautes fréquences de l'image. Ce défaut assimilable à un « filtrage passe-bas » est généralement modélisé par un modèle gaussien. Notre mesure du flou dans une image se basera sur l'estimation des paramètres du modèle gaussien (moyenne, écart type).

La mesure du flou se fait sur l'analyse des contours et de leur étalement. Dans le cadre du document, la forte proportion de texte nous permet de disposer d'une information de contours très importante. Notre méthode de catégorisation du flou se base sur un ensemble de descripteurs qui participent à la caractérisation des contours et de leur étalement. Cet ensemble de descripteurs sera utilisé par une approche « apprentissage supervisé » dont le résultat sera une catégorisation de la puissance du flou.

Nous présenterons l'état de l'art sur l'étalement des contours dans la section 2. Nous développerons les descripteurs utilisés dans la section 3. Nous analyserons les descripteurs en simulant un flou par un filtre gaussien dans la section 4, afin de valider la pertinence de ces descripteurs. Puis, nous analyserons les résultats obtenus par notre méthode d'évaluation dans la section 5. Et nous finirons dans la section 6 par une conclusion et des perspectives.

2. État de l'art :

L'approche que nous proposons s'appuie sur la mesure de la qualité des contours sans connaître l'image d'origine. Dans le domaine de la compression d'une image, certaines des caractéristiques prises en compte pour évaluer la qualité de la compres-

sion sont basées sur la qualité de reproduction des contours et donc sur la connaissance de l'image d'origine. Même si les conditions sont différentes, certains des descripteurs utilisés pour qualifier la qualité des contours peuvent être retenus dans notre contexte. L'article de Marziliano (Marziliano *et al.*, 2004) utilise une métrique qui est basée sur l'étude des épaisseurs de contours verticaux, dont l'épaisseur est calculée en fonction de la distance en nombre de pixels séparant le minimum local du maximum local. La mesure finale est une moyenne calculée sur tous les contours détectés. Chung et al (Chung *et al.*, 2004) ont établi une métrique sur le calcul du contraste, le module du gradient et l'épaisseur de contour. La méthode calculant l'épaisseur de contour est une version améliorée de Marziliano. La méthode propose alors une fusion des informations afin d'affiner la mesure locale. Une autre amélioration a été proposée dans l'article de Narvekar et Karam (Narvekar et Karam, 2009) où la mesure du contour peut ne pas être prise en compte. Les auteurs se basent sur l'étalement des contours défini par Marziliano, mais la solution qu'ils proposent est d'utiliser les informations locales de l'image (contraste et le nombre de pixels de contour dans la région) pour interpréter directement le résultat. Ainsi, pour chaque contour, les auteurs le valident et l'évaluent en fonction de ces critères.

Dans le domaine de l'amélioration d'image, Bae et Durand (Bae et Durand, 2007) définissent une carte du flou afin d'accentuer ou d'atténuer le flou présent dans certaines zones de l'image. Cette carte est construite en évaluant l'erreur de profondeur de champ en chaque point. Pour calculer cette information au niveau des pixels, la méthode évalue la netteté en se basant sur la localisation et la mesure des zones de contours. L'article de Elder et Zucker (Elder et Zucker, 1998) utilise le gradient et le laplacien de l'image pour localiser et quantifier le flou des contours. L'article (Tai et Brown, 2009) suggère l'utilisation du contraste local de l'image pour obtenir les informations de netteté. La détection des contours proposée par Zhuo et Sim (Zhuo et Sim, 2011) est originale : pour chaque pixel de contour, le flou est calculé comme le rapport entre le gradient de l'image initiale et le gradient de l'image refloutée.

D'autres démarches se basent sur une classification des contours pour en mesurer leur qualité. Par exemple, l'article de Tong et al (Tong *et al.*, 2004) propose une méthode basée sur la structure des contours. A l'aide de la transformée en ondelettes de Haar de l'image, ils classifient les différents contours selon leurs caractéristiques à différentes échelles. Ainsi, ils déterminent une mesure du flou en se basant sur le nombre de « contours nets » et de « contours flous ». Le même auteur, dans (Tong *et al.*, 2005), propose un modèle d'apprentissage supervisé basé sur la dégradation des contours selon le type de compression. Le descripteur utilisé est la répartition locale des pixels de contour. D'autres auteurs utilisent la classification pour divers objectifs, l'un suggère de quantifier la qualité de l'image comme dans l'article de Ke et al (Ke *et al.*, 2006).

Liu et al (Liu *et al.*, 2008) proposent d'utiliser la classification pour segmenter les zones de flous de l'image. Cet article vise à caractériser le flou partiel de l'image, une première étape consiste à le localiser et une deuxième étape à le quantifier. Cette approche se base sur un ensemble de descripteurs chacun ayant des caractéristiques différentes. Un des descripteurs utilisés par Liu est construit à partir d'une analyse

fréquentielle, ce type de descripteur permet de mettre en évidence certains défauts optiques (flou de bougé, flou de focus) grâce aux informations des contours dans une région de l'image. Les travaux de D. J. Field (Field *et al.*, 1987) et (Field et Brady, 1997) ont mis en avant l'importance du coefficient directeur de la pente de la densité spectrale de puissance pour caractériser une image, Liu montre que lorsque l'image devient floue, le coefficient de la pente devient de plus en plus faible. Parmi les approches basées sur la transformée de Fourier, on notera la méthode spécifique au flou de mouvement d'une scène supposée statique et artificielle, proposée par Lelegard (Lelegard *et al.*, 2010). Leur méthode consiste à binariser la transformée de Fourier et à récupérer les informations pertinentes. Par contre, il n'est pas spécifié dans l'article l'impact du flou sur la méthode. Nous proposons de l'étudier par la suite.

Dans la suite de l'article, nous utiliserons les descripteurs sélectionnés pour caractériser les informations de contours. Nous nous placerons dans un contexte d'images non-naturelles (documents anciens) contenant un flou uniforme gaussien (défaut de mise au point lors de la numérisation). Nous proposerons d'estimer les caractéristiques du flou à l'aide d'un modèle d'apprentissage supervisé qui se base sur un ensemble de descripteurs participant à la caractérisation du flou.

3. Descripteurs

L'étude de la section précédente montre qu'il existe de nombreux descripteurs pour déterminer la netteté (étalement) d'un contour. Chaque descripteur cherche à évaluer une des spécificités d'un contour tels que son amplitude, son épaisseur, sa dégradation en fonction d'un flou, sa structure, ses caractéristiques fréquentielles, etc. La mesure de ces spécificités nous permet d'évaluer la netteté selon certaines hypothèses. Nous présentons ci-dessous les cinq descripteurs qui nous semblent les plus pertinents :

– **D_1 le maximum du gradient :**

Le descripteur le plus simple est le maximum du gradient. Le gradient de l'image mesure la transition des pixels. Plus la transition des pixels est grande, plus le capteur est susceptible de faire la différence entre les détails.

Afin de normaliser cette mesure selon les différentes sources, on divisera par la valeur maximum de l'espace de définition de l'image. Soit L l'image en niveaux de gris, on écrit alors :

$$D_1 = \frac{\max(|\nabla L|)}{255} \quad [1]$$

, avec ∇ l'opérateur gradient.

– **D_2 l'histogramme des épaisseurs des contours :**

Notre méthode consiste tout d'abord à détecter les contours de l'image en niveaux de gris. La détection est obtenue par un seuillage global du gradient normalisé. La




Figure 1. Profil d'un contour 1D

normalisation est faite à partir du maximum du gradient de l'image (soit 255 en 8 bit). Pour tous les pixels de contours P_c , nous calculons l'épaisseur de contour.

La figure 1 montre une coupe 1D d'un contour. Pour définir l'épaisseur d'un contour, nous le parcourons dans les deux sens selon la direction du gradient. Nous arrêtons ce parcours lorsque la dérivée est inférieure à une valeur seuil proche de zéro. Soit $Ep(P_c)$ le nombre total de pixels d'un contour dont le pixel de départ est P_c .

La mesure de l'épaisseur d'un contour est une mesure locale, on propose d'utiliser un histogramme H_{ep} pour analyser l'ensemble des contours sur toute l'image. Cet histogramme possède N classes, chaque classe est liée au nombre de pixels qui constituent l'épaisseur du contour. Par exemple, pour une résolution de 300 dpi, la répartition des épaisseurs varie de 2 à 10 pixels. Les contours supérieurs à 10 étant regroupés dans la dernière classe. Cette référence nous permet d'être indépendant de la résolution en convertissant notre mesure et de normaliser notre résultat en divisant par N.

La contribution des $Ep(P_c)$ sera pondérée par l'amplitude du gradient du point P_c courant. Nous considérons qu'un contour plus fort permet d'obtenir de manière plus précise la tangente du contour. De ce fait, nous utiliserons le module du gradient de P_c comme valeur de pondération. Le résultat obtenu sera la moyenne de cet histogramme.

$$D_2 = \frac{\sum_{i=1}^{i=N} |H_{ep}(i)|i}{\sum |H_{ep}(i)|} \quad [2]$$

– D_3 la catégorisation de Haar :

La méthode des catégorisations de contours est basée sur l'article de Tong et al (Tong *et al.*, 2004).

Leur approche se base sur une classification de contours en utilisant les ondelettes de Haar. Après avoir calculé la transformée en ondelette de Haar sur trois niveaux de l'image en niveaux de gris, ils proposent de détecter les contours en calculant une carte des contours basée sur les niveaux des hautes fréquences. On rappelle que la transformée en ondelette décompose l'image en quatre parties. Les blocs LH, HL et HH contiennent les informations des détails et LL contient les basses résolutions. Le calcul proposé est le suivant :

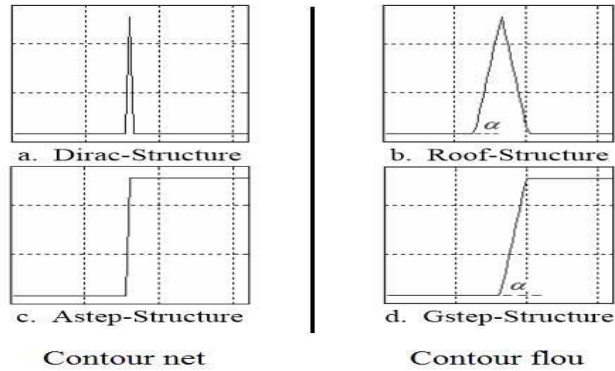


Figure 2. Les différents types de structure de contour

$$Emap_i(k, l) = \sqrt{LH_i^2 + HL_i^2 + HH_i^2} \quad (i = 1, 2, 3) \quad [3]$$

soit i le niveau de décomposition de l'ondelette et (k, l) les coordonnées du pixel sur le niveau i . On appliquera une fenêtre centrée sur le pixel (k, l) , la fenêtre est de plus en plus petite au fur et à mesure que l'échelle augmente afin de connaître le maximum local. Ce pixel sera labélisé comme point de contour lorsque le maximum local dépassera une valeur seuil. L'auteur propose quatre modèles de contours, que l'on appellera structures (cf figure 2). Ils définissent les structures en 'Dirac' et en 'Astep' pour les contours nets, et les structure en 'Roof' et en 'Gstep' pour les contours flous. Ils définissent un ensemble de règle permettant de classifier chacun des contours en un type de structure en comparant les valeurs des coefficients à différentes échelles d'ondelettes.

La mesure est le ratio du nombre de structure de contours nets sur le nombre de contours, soit :

$$D_3 = \frac{\#\text{Astep-struct} + \#\text{Dirac-struct}}{\#\text{contour}} \quad [4]$$

– D_4 **l'estimation de netteté de l'autofocus (Defocus Blur Estimation) :**

Ce descripteur est basé sur la première partie de l'article (Zhuo et Sim, 2011).

Soit I l'image initiale en niveau de gris, que nous lissos par un filtre gaussien d'écart-type σ pour obtenir l'image lissée L . Ensuite, nous détectons tous les pixels de contour P_c à partir de l'image initiale. La détection est faite à partir d'un seuillage global du gradient normalisé, comme nous l'avons fait pour le descripteur D_2 . Pour tous les pixels de contours P_c , nous calculons la différence entre les deux contours par la formule suivante :

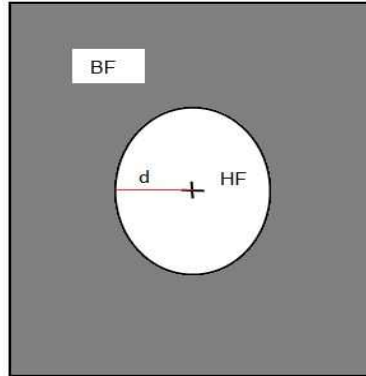


Figure 3. Binarisation dans l'espace de Fourier après filtrage

$$R(P_c) = \frac{\|\nabla I(P_c)\|}{\|\nabla L(P_c)\|} \quad [5]$$

Pour obtenir la mesure du flou, nous moyennons ces valeurs puisque l'erreur de mise au point est quasi uniforme sur l'ensemble de la numérisation. Ce descripteur s'écrit alors :

$$D_4 = \frac{\sum_{c=1}^{c=n} R(p_c)}{n} \quad [6]$$

avec n le nombre de pixel de contours. Dans la mesure où $\|\nabla I\| > \|\nabla L\|$ lorsque $\|\nabla I\| > \delta$ avec δ proche de 1, le ratio R sera systématiquement compris dans l'intervalle $]0, 1]$.

– **D_5 la binarisation de Fourier :**

Ce dernier descripteur est obtenu par une approche similaire à celle proposée par Lelégard et al (Lelegard *et al.*, 2010).

Nous calculons le module de la transformée de Fourier de l'image. Nous binarisons par la moyenne. Nous supprimons les éléments isolés par des outils de filtrage afin d'avoir deux éléments distincts. Nous obtenons alors les basses et hautes fréquence comme on peut le voir dans la figure 3.

Nous calculons la distance d entre le point le plus proche des basses fréquences et le centre des hautes fréquences. Cette distance est normalisée par la taille de la diagonale de l'image. L'utilisation de la binarisation dans l'espace fréquentiel n'est possible que lorsque l'image est composée de basses et hautes fréquences. Par conséquent, nous prenons en compte la valeur de l'écart-type du module de la transformée

de Fourier. Cette valeur nous permet d'évaluer cette contrainte. Nous obtenons la formule suivante :

$$D_5 = \frac{d}{stddev(||FFT(I)||)} \quad [7]$$

avec `stddev` le calcul de l'écart-type, et la `FFT` le calcul de la transformée de Fourier.

4. Analyse des descripteurs

Pour analyser ces descripteurs, nous validons leur pertinence selon leur évolution en fonction de la force d'un flou gaussien. La force du flou est l'écart-type σ de la gaussienne. Nous mesurons ensuite les erreurs d'estimations sur un échantillon d'images. Cette étude permet de mesurer les avantages et inconvénients de chacun des descripteurs.

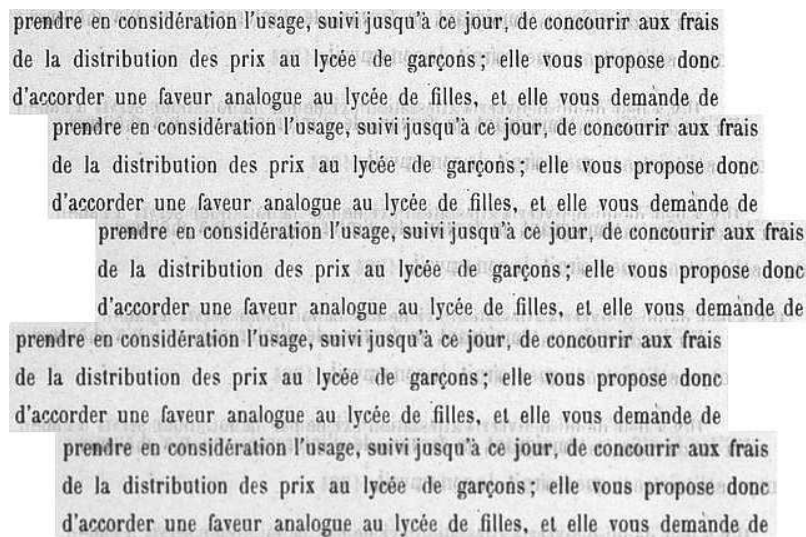


Figure 4. Représentation de 5 mêmes régions d'une image lissée par un filtre gaussienne de noyau 7×7 et de σ variant d'un pas de 0.4. Le morceau d'image du haut est supposée nette, la troisième image correspondant à un filtrage de σ de 0.8 et elle est considérée comme floue par une organisation telle que la Bibliothèque Nationale de France, tandis qu'une personne non spécialisée dans le domaine va davantage considérer qu'une image est floue pour un σ allant de 0.8 et 1.2 soit entre la troisième et quatrième image.




Figure 5. Représentation des valeurs normalisées des descripteurs en fonction de σ_{th}

A partir d'un ensemble composé de 100 images de même résolution nous construisons une base de donnée d'images floues. Cette base de donnée est obtenue en appliquant un filtre gaussien dont nous faisons varier σ_{th} de 0 (pour l'image nette), à 1.8 par pas de 0.2.

Afin de construire un modèle de comportement par descripteur, nous moyennons chacune des valeurs obtenues selon chaque valeur σ . La figure 5 représente ces comportements.

Le descripteur idéal est une droite de coefficient directeur d'environ 0.5 (ou -0.5) qui minimise au mieux les erreurs d'estimation. Toutefois, on souhaite avoir une distinction notable entre 0.6 et 1.2 puisque la séparation image nette, image floue se situe dans cet intervalle (cf figure 4).

D'un point de vue général, on remarque que tous les descripteurs ont des difficultés à différencier les σ inférieures à 0.4. Ensuite, les valeurs normées sont toutes différentes, les courbes ne sont pas linéaires et qu'aucunes n'ont un coefficient directeur proche de 0.5 ou -0.5 .

Les courbes de D1, D2, et D4 semblent avoir un comportement linéaire sur l'intervalle $[0.4, 1.8]$, tandis que D5 n'est linéaire que sur l'intervalle $[0.4, 1]$, puis la courbe devient constante.

La courbe D3 représentant la méthode de la catégorisation de Haar, a une forte décroissance sur l'intervalle $[0.4, 0.8]$ et devient invariante sur le reste de l'intervalle. Si l'on se focalise sur la zone $[0.6, 1.2]$, on s'aperçoit que la courbe du gradient max a

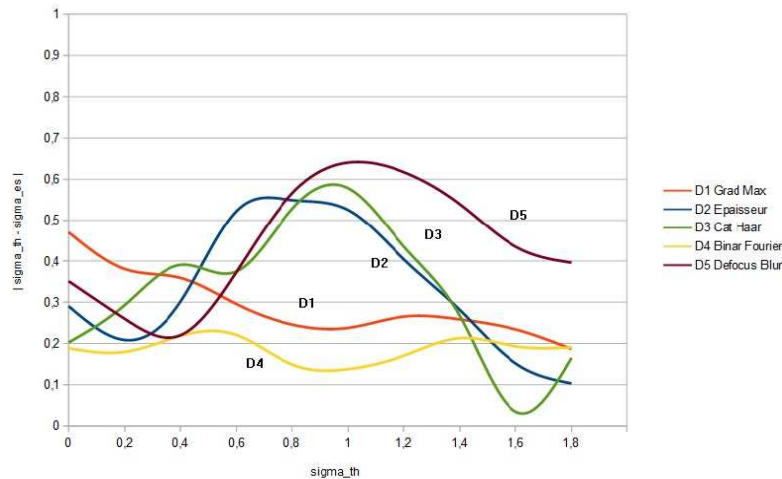


Figure 6. Représentation des erreurs d'estimation de σ en fonction du σ théorique

le coefficient directeur le plus discriminant (coefficient directeur de 0.3), tandis que le Defocus Blur a le plus faible (coefficient directeur de 0.1).

Les comportements de chaque descripteur sont ensuite modélisés par des polynômes de degré 3. On peut alors estimer un σ en fonction de la donnée de chaque descripteur. Les erreurs d'estimation sont présentées dans la figure 6.

Les courbes oscillent entre 0.2 et 0.6 sur notre intervalle d'intérêt.

On notera que les images prises sont de sources différentes étant donné la position du problème (qualité du livre et de la machine) ce qui explique le manque de précision des descripteurs pour les valeurs σ_{th} inférieure à 0.4. En soit, une erreur de 0.4 pour un σ_{th} nul est acceptable.

On remarque que deux descripteurs semblent cohérent : D1 le gradient max dont la moyenne est aux alentours de 0.3 et D4 le descripteur basé sur la transformée de Fourier avec une erreur moyenne de 0.2.

Les trois autres courbes ont des erreurs qui augmentent pour atteindre un maximum d'environ 0.55 pour un σ_{th} de 1. Aucun de ces estimateurs ne peuvent être considérés comme bon. Les descripteurs D2 et D5 ont un comportement similaire à la courbe de la figure 5 lorsqu'on analyse différents flous d'une même image, mais l'évolution de la valeur du descripteur normé est trop variable d'une image à une autre. La courbe D3 est beaucoup trop binaire pour être capable d'estimer σ , sa courbe d'erreur nous le confirme.

On notera que les erreurs convergent toutes lorsque l'on tend vers $\sigma_{th} = 1.8$ à cause du modèle régressif mise en place, ce qui se traduit par une bonne estimation de cette valeur.

Procédons maintenant à une analyse de tous les descripteurs, en se basant sur les différentes méthodes, hypothèses et résultats.

La courbe D4, qui est la représentation de la binarisation de Fourier est la plus précise. L'erreur qui apparaît est obtenu lorsque la numérisation contient des images. La courbe D1, qui est le maximum du gradient obtient des résultats pertinents mais reste subordonné de la qualité du document numérisé.

L'épaisseur de contour a un intervalle de définition trop petit, on peut voir sur la courbe qu'un contour net est d'environ 5 pixels, tandis qu'un contour flou de $\sigma_{th} = 1$ est d'environ 6 pixels. L'erreur d'estimation de l'épaisseur des contours engendre une erreur trop importante. Le modèle basé sur la catégorisation de Haar est trop discriminante, on obtient un bon estimateur net/flou, mais la quantification du flou est quasi impossible. L'approche du Defocus Blur induit des difficultés pour estimer un contour flou. Il permet de détecter une image nette, mais sa valeur varie trop d'une image à une autre pour produire un estimateur fiable.

Notre objectif est de fusionner les informations de tous les descripteurs par un modèle d'apprentissage supervisé. Nous allons donc évaluer cette méthode et estimer la pertinence de chacun des descripteurs dans ce modèle.

5. Méthode d'analyse basée sur l'apprentissage supervisé

Notre base d'entraînement est composée de la base de donnée de la section précédente. Toutes les images sont défini par les cinq descripteurs. Et l'image est étiquetée par sa valeur σ . Notre base de test est créée à partir de nouvelles images nettes, dont les images sont différentes de la base de donnée. Toutes les images sont floutées de la même manière.

La figure 7 montre les erreurs de prédiction de cette base de test faite par la méthode des k-plus proche voisins (ici, $k = 20$), et par machine à vecteurs de support (SVM) avec un polynôme d'ordre 2.

Les résultats d'apprentissages sont définis entre 0.1 et 0.2 sur l'ensemble de la courbe, l'erreur est plus faible pour la méthode des k-nn comparée au SVM. Le modèle est basé sur un pas de sigma de 0.2. Notre estimation est inférieure à ce pas, elle est donc satisfaisante.

Nous proposons une méthode pour évaluer la contribution de chaque descripteur au résultat final. Pour cela, on utilise le modèle des moindres carrés pour résoudre le système $Ax = b$, avec A la matrice $N \times 5$, des N σ estimés, et b le vecteur de taille N, des σ_{th} des échantillons. Ce modèle nous donne les résultats obtenus dans le tableau suivant :

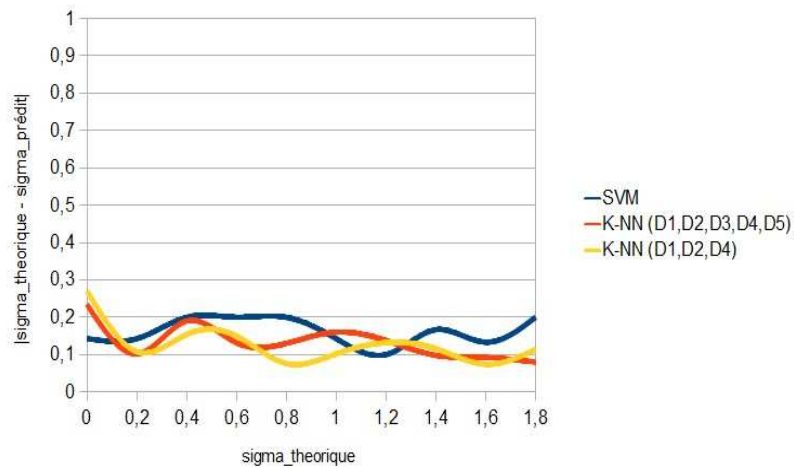


Figure 7. Représentation des erreurs d'estimation de σ obtenu par apprentissage des k plus proche voisins en fonction du σ théorique

D1 Max Grad	D2 Épaisseur	D3 Haar	D4 Fourier	D5 Defocus blur
0.27	0.19	-0.04	0.60	-0.01

A partir de ce résultat, on observe que deux descripteurs (D3 et D5) sont négligés. Il est vrai que la catégorisation de Haar et le Defocus Blur estimation ne sont pas les plus pertinents, comme nous l'avons montré et expliqué dans la section précédente. À l'inverse, le descripteur basé sur la binarisation de Fourier a une contribution importante pour aboutir à l'estimateur final.

Ce modèle régressif met en évidence que l'apprentissage est plus optimal en utilisant uniquement le gradient max, l'épaisseur des contours et la binarisation de Fourier. La courbe K-NN(D1,D2,D4) montre de meilleur résultat que K-NN(D1,D2,D3,D4,D5) (cf. figure 7). La moyenne d'erreur est de 0.1 dans l'intervalle $[0.6, 1.2]$.

Les résultats sont meilleurs en proposant un modèle d'apprentissage supervisé et valide l'approche proposée.

6. Conclusion

Au cours des travaux détaillés dans cet article, nous avons mis en avant un certain nombre de descripteurs évaluant les spécificités des contours. Toutes ces caractéristiques permettent d'estimer la netteté de l'image. Nous avons pu observer que la qualité des contours se mesure sur différents points : l'épaisseur, l'accentuation, la dé-

gradation, la structure, l'information fréquentielle. Tous ces référentiels nous donnent une information de netteté, mais malheureusement la précision n'est pas toujours pertinente. Les descripteurs du maximum du gradient et la binarisation dans l'espace de Fourier sont de bons descripteurs dans le cadre des documents anciens. Pour améliorer cette estimation, nous proposons d'utiliser un apprentissage supervisé. Ce modèle nous permet d'interpréter et de fusionner les différents descripteurs. Les résultats montrent une erreur de l'estimation de σ inférieure à 0.1 dans notre intervalle d'intérêt. Ce résultat est très bon.

Dans un contexte industriel, il est nécessaire de catégoriser les images. Notre approche permet, en définissant des seuils ou en adaptant notre base de donnée, de classer les images en trois ensembles : les images nettes, les images floues mais qui peuvent être traitées par des méthodes de traitement d'image et les images floues dont les informations sont trop dégradées pour être utilisables. De plus, notre méthode propose une estimation du flou utiles aux méthodes de déconvolution. Dans la suite de nos travaux, nous souhaitons créer une base de donnée à partir du flou de l'optique afin de se dissocier du modèle passe-bas utilisé.

7. Bibliographie

- Bae S., Durand F., « Defocus magnification », *Computer Graphics Forum*, vol. 26, Wiley Online Library, p. 571-579, 2007.
- Chung Y.-C., Wang J.-M., Bailey R. R., Chen S.-W., Chang S.-L., « A non-parametric blur measure based on edge analysis for image processing applications », *Cybernetics and Intelligent Systems, 2004 IEEE Conference on*, vol. 1, IEEE, p. 356-360, 2004.
- Elder J. H., Zucker S. W., « Local scale control for edge detection and blur estimation », *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 20, n° 7, p. 699-716, 1998.
- FADGI, *Digital Imaging Framework*, <http://www.digitizationguidelines.gov>. 2010.
- Field D. J., Brady N., « Visual sensitivity, blur and the sources of variability in the amplitude spectra of natural scenes », *Vision research*, vol. 37, n° 23, p. 3367-3383, 1997.
- Field D. J. *et al.*, « Relations between the statistics of natural images and the response properties of cortical cells », *J. Opt. Soc. Am. A*, vol. 4, n° 12, p. 2379-2394, 1987.
- Ke Y., Tang X., Jing F., « The design of high-level features for photo quality assessment », *Computer Vision and Pattern Recognition, 2006 IEEE Computer Society Conference on*, vol. 1, IEEE, p. 419-426, 2006.
- Lelegard L., Bredif M., Vallet B., Boldo D., « Motion blur detection in aerial images shot with channel-dependent exposure time », 2010.
- Liu R., Li Z., Jia J., « Image partial blur detection and classification », *Computer Vision and Pattern Recognition, 2008. CVPR 2008. IEEE Conference on*, IEEE, p. 1-8, 2008.
- Marziliano P., Dufaux F., Winkler S., Ebrahimi T., « Perceptual blur and ringing metrics : application to JPEG2000 », *Signal Processing : Image Communication*, vol. 19, n° 2, p. 163-172, 2004.

- Narvekar N. D., Karam L. J., « A no-reference perceptual image sharpness metric based on a cumulative probability of blur detection », *Quality of Multimedia Experience, 2009. QoMEX 2009. International Workshop on*, IEEE, p. 87-91, 2009.
- Tai Y.-W., Brown M. S., « Single image defocus map estimation using local contrast prior », *Image Processing (ICIP), 2009 16th IEEE International Conference on*, IEEE, p. 1797-1800, 2009.
- Tong H., Li M., Zhang H.-J., Zhang C., He J., Ma W.-Y., « Learning no-reference quality metric by examples », *Multimedia Modelling Conference, 2005. MMM 2005. Proceedings of the 11th International*, IEEE, p. 247-254, 2005.
- Tong H., Li M., Zhang H., Zhang C., « Blur detection for digital images using wavelet transform », *Multimedia and Expo, 2004. ICME'04. 2004 IEEE International Conference on*, vol. 1, IEEE, p. 17-20, 2004.
- Zhuo S., Sim T., « Defocus map estimation from a single image », *Pattern Recognition*, vol. 44, n° 9, p. 1852-1858, 2011.