

# Méthode d'évaluation univariante de la qualité des images. Application à des images comprimées selon la norme JPEG

---

## Univariant assessment of the visual quality of images. Application to JPEG compressed images

par Mathieu JUNG, Dominique LEGER, Marc GAZALET

Adresse de l'auteur

### *résumé et mots clés*

Cet article présente une méthode originale de détermination de la qualité d'une image en niveaux de gris. Un exemple d'application de la méthode sur des images comprimées selon la norme JPEG est présenté. Contrairement à la plupart des méthodes existantes, cette évaluation de qualité est univariante, c'est-à-dire ne nécessite aucune image de référence. La qualité est donnée sous la forme d'une note dont la progression est étalonnée selon l'utilisation qui doit être faite de l'image : visuelle, mathématique, informatique. Pour ce faire, un apprentissage est effectué à l'aide d'un réseau de neurones sur une base d'exemples connus faite d'images dont on a préalablement noté la qualité avec le modèle souhaité. Pour s'assurer de sa fiabilité, la méthode est comparée à des méthodes bivariantes classiques. Elle permet de retrouver avec une erreur inférieure à 7 % les résultats prévus par celles-ci.

Qualité image, jpeg, compression, artefacts de bloc.

### *abstract and key words*

This paper presents an original method to assess the quality of a grey level image. An example of application is presented on images compressed according to the JPEG standard. Contrary to most of the existing methods, this quality assessment is univariant, i.e. it doesn't require any reference image. The quality is represented by a mark whose variation depends on what use the image is for : visual, mathematical, data processing. A neural network is used to learn the marking way with a pool of known examples. The method is then compared to classical bivariant methods to make sure that it is reliable. The anticipated results arrived at have a less than 7 % precision.

Image quality, jpeg, compression, block artefacts.

## 1. introduction

Disposer d'un outil universel d'évaluation automatique de la qualité des images est très utile lorsque le nombre d'images à traiter est important. C'est par exemple le cas quand il s'agit d'optimiser les paramètres caractéristiques d'un système imageur [OLI98], de mesurer la qualité des images de télévision [DC90], de déterminer la qualité d'un instrument satellitaire en vol... La plupart des méthodes existantes d'évaluation de la qualité des images sont des méthodes bivariantes, c'est-à-dire reposant sur une comparaison quelle qu'elle soit, entre une image dégradée et la même image parfaite. Elles sont réparties en deux familles : les méthodes non pondérées, ou purement mathématiques, et les méthodes pondérées, prenant en compte les caractéristiques du système visuel. Les critères non pondérés peuvent être un simple calcul de distance entre les deux images (MSE : Mean Squared Error, NMSE : Normalized Mean Squared Error, distance euclidienne), ou fondés sur une modélisation des propriétés statistiques de l'image, comme les critères de Linfoot [LIN56], [LIN58]. Les critères pondérés utilisent quant à eux une modélisation de la vision, sous forme d'une ou plusieurs fonctions de transfert [SHA56], [MS74], [DAL92], [DAL93], [KK95], [CL93], [WAT93]. Ces méthodes ont des domaines de stabilité ou de validité très différents, selon le type de dégradation ou la nature des images [MEC98].

Cependant, très souvent, on ne dispose d'aucune référence pour évaluer la qualité d'une image. C'est le cas, par exemple, des images acquises par le satellite SPOT et destinées à être commercialisées. Actuellement, les membres du service qualité de SPOTIMAGE scrutent méticuleusement chaque image à la recherche d'éventuels défauts. Cette phase est longue et pénible pour les observateurs. C'est plus généralement le cas de toutes les images satellitaires destinées à des applications physiques, études radiométriques, reconnaissance d'objets, etc..., qui sont très souvent sélectionnées visuellement.

Quelques méthodes univariantes, c'est-à-dire ne nécessitant aucune image de référence, ont été développées. [ABP96] utilise, dans le cadre de l'évaluation de la qualité d'une image comprimée selon la norme JPEG, des coefficients de continuité entre les blocs (cf. §3.1) à partir desquels un réseau de neurones estime la qualité de l'image. Cependant les résultats sont de l'ordre de 25 % de précision par rapport à la qualité théorique attendue, alors que ceux obtenus avec un modèle bivariant peuvent atteindre 5-10 % de précision [OLI98]. A nouveau dans le contexte des images SPOT, une méthode bivariante a été développée pour estimer un éventuel défaut de mise au point [ML96]. Elle utilise les deux caméras, identiques, dont l'une sert de référence à la seconde. Cette méthode nécessite néanmoins une connaissance théorique précise du système de focalisation. Elle demeure inapplicable pour estimer le défaut de mise au point d'un satellite dont on ne connaît pas la conception, ou ne disposant que d'une seule caméra.

Dans cet article, nous proposons une méthode permettant d'évaluer de façon univariante la qualité d'une image. La démarche proposée peut être appliquée à tout type de dégradation et à tout type de notation de qualité : visuelle, mathématique... Nous montrerons qu'il est possible de reproduire, de façon univariante, l'estimation de qualité qui aurait été faite par un modèle bivariant. Cette méthode peut aussi être adaptée pour retrouver certaines caractéristiques du système d'acquisition de l'image : quantifier un défaut de mise au point, un rapport signal sur bruit... Pour illustrer notre démarche, nous présentons un exemple d'application de la méthode aux images comprimées selon la norme JPEG. La méthode est appliquée d'une part pour retrouver l'indice de qualité de la compression JPEG et d'autre part pour reproduire une estimation bivariante de qualité donnée par un modèle représentatif d'une notation subjective. Nous utiliserons comme exemple la notation de qualité du modèle de Karunasekera et Kingsbury [KK95a], référence en matière de notation de la qualité des images JPEG.

Par ailleurs, cette approche a aussi été appliquée à la recherche de dégradations visuellement gênantes sur les images SPOT : défauts ponctuels, défaut de mise au point de SPOT 1, bruit... Pour atteindre cet objectif, notre démarche comporte trois étapes fondamentales. Il faut tout d'abord trouver sur l'image dégradée les caractéristiques qui permettent d'évaluer sa qualité. Il faut ensuite étalonner un modèle pour donner la note de qualité désirée à partir de ces caractéristiques. Enfin, il faut vérifier la stabilité du modèle sur un grand nombre d'images.

Les informations caractérisant la dégradation sont extraites de l'image par des traitements et calculs systématiques pour être regroupées sous la forme d'un *vecteur caractéristique*. Ce vecteur sert d'entrée au modèle univariant. Nous avons choisi d'utiliser comme modèle un réseau de neurones (RN). Ce type de modèle, non linéaire, permet l'apprentissage d'une fonction très complexe en raison des nombreux paramètres dont il est constitué, pour une mise en œuvre très simple. L'étalonnage des paramètres du RN se fait sur un grand nombre d'exemples connus, c'est-à-dire d'images dégradées dont on connaît ou dont on a préalablement évalué la qualité. Ces exemples constituent la *base d'apprentissage* du RN. Ils sont choisis de manière à obtenir un échantillon représentatif de tous les types d'images que l'on peut rencontrer : structurées ou uniformes, paysages ou personnages... Finalement, le RN est utilisé de manière autonome pour interpoler la qualité d'une image inconnue sur la base d'apprentissage.

## 2. méthode générale

Seules les images dégradées par des défauts simples ont été considérées, l'objectif étant, dans un premier temps, de prouver la faisabilité d'une étude de qualité univariante. Un défaut simple peut être par exemple du flou, des artefacts de compres-

sion, un phénomène de rebond des contours, etc., mais aucune combinaison de ces derniers sur l'ensemble de l'image.

La démarche générale suivie pour évaluer de manière univariante la qualité d'une image est la même quelle que soit la dégradation considérée. La dégradation doit être identifiée et caractérisée dans l'image, indépendamment du type de scène représentée. Ensuite, un réseau de neurones apprend à faire la correspondance entre cette caractérisation et une note, par exemple celle qui aurait été donnée pour la même image par un modèle bivariant ou un calcul mathématique. Finalement, l'apprentissage est validé sur un lot d'images quelconques et inconnues, en comparant la note donnée de manière univariante par le RN et celle théoriquement attendue.

## 2.1. caractérisation de la dégradation

Pour caractériser la dégradation, tous les outils statistiques, mathématiques, issus du traitement de l'image, peuvent être utilisés. Par exemple un calcul de corrélation moyenne entre les pixels de l'image, certaines valeurs de la transformée de Fourier, un prétraitement de l'image à l'aide de filtres spécifiques pour accentuer les défauts... Selon la dégradation, il s'agira d'identifier les meilleurs outils, c'est-à-dire ceux qui vont fournir les informations les plus pertinentes. En pratique, ce ne sont pas toujours ceux qui ont la signification physique la plus évidente. D'autre part, la gêne occasionnée par la dégradation dépend de la zone considérée sur l'image. Par exemple, pour donner une note de qualité représentative de la gêne visuelle provoquée par du bruit, il faudra tenir compte de l'uniformité ou non de la zone considérée : pour un même rapport signal sur bruit, la zone semble moins dégradée si elle est structurée. Ceci est aussi vrai pour des critères autres que des critères visuels. En conséquence, la caractérisation de la dégradation devra être complétée par des renseignements sur le type d'image, de manière à permettre une décision univariante fiable. Dans la mesure du possible, ces derniers devront dépendre le moins possible de l'intensité de la dégradation pour fournir une information *a priori* sur l'image parfaite. Cela devient difficile pour des intensités de dégradation importantes...

Tous ces renseignements, tant sur la dégradation que sur l'image elle-même, sont regroupés pour former le *vecteur caractéristique* de la dégradation pour l'image considérée. Les éléments de ce vecteur seront les entrées du RN. En raison des propriétés que doit avoir un RN pour être en mesure d'apprendre la base, le nombre d'entrées qu'il comporte ne doit pas être trop grand. Il est en particulier hors de question d'utiliser comme vecteur d'entrée l'ensemble de tous les niveaux de gris des pixels de l'image !

## 2.2. l'apprentissage

La phase d'apprentissage du RN, comme tout autre modèle, va conditionner son comportement après coup. Un soin très impor-

tant doit être en particulier accordé au choix des exemples qui vont constituer la base d'apprentissage. Le RN est un très bon interpolateur, mais son comportement en extrapolation n'est pas aussi bien maîtrisé que celui d'un modèle fabriqué d'après des considérations physiques. En conséquence, les images de la base devront être représentatives de tous les types d'images sur lesquels on désire un comportement stable et fiable du modèle. Pour un apprentissage général, il faut des images, uniformes, structurées... de tous types. Pour chacune de ces images, il faut différentes intensités de dégradation. Les images parfaites sont dégradées avec le défaut qui doit être appris et sont notées de manière bivariante par le modèle qui sert de référence pour l'apprentissage. C'est cette notation bivariante que le RN va apprendre à retrouver à partir du vecteur caractéristique.

Cette base d'apprentissage constituera en quelque sorte le domaine de validité du modèle univariant. Pour tous les défauts considérés, la base utilisée est constituée de 800 images diverses de  $256 \times 256$  pixels, codées sur 256 niveaux de gris. Chacune de ces 800 images est dégradée avec une dizaine d'intensités du défaut, ce qui porte à 8000 le nombre d'exemples présents dans la base d'apprentissage. Pour des raisons de place, elle n'est pas représentée dans ce papier.

En cours d'apprentissage, la qualité de la convergence est évaluée sur une base de test indépendante, elle aussi représentative du domaine de stabilité recherché. Elle est constituée de 16 images différentes dégradées avec une dizaine d'intensités du défaut, soit 160 images. Les images non dégradées de la base de test sont présentées sur la figure 1. Les bases d'apprentissage et de test que nous avons utilisées ne sont pas exhaustives en termes de types d'images, mais elles sont suffisamment variées pour valider le protocole d'évaluation de qualité décrit par la suite. De plus, l'étude montrera que pour une application très spécifique (texte, images médicales...) la précision est améliorée en utilisant une base spécifique adaptée au type d'images.




Figure 1. – Base de test.

### 2.3. validation : comparaison avec une notation bivariante

La validation du modèle de notation se fait dans un premier temps sur la base de test, dans un deuxième temps sur un lot d'images quelconques et inconnues, c'est-à-dire n'appartenant ni à la base d'apprentissage, ni à la base de test. La notation univariante est comparée à la notation bivariante de référence. Le modèle bivariant de référence n'ayant pas une stabilité absolue vis-à-vis des différentes images, l'apprentissage est considéré comme bon non seulement si la notation univariante est proche de la notation bivariante, mais aussi si l'écart statistique entre les deux comportements est faible sur un grand nombre d'exemples. En effet, l'écart entre les deux notations peut être important sur un exemple sans pour autant remettre en cause la fiabilité du modèle univariant.

## 3. application : qualité des images JPEG

### 3.1. dégradations introduites par le codage

En raison de la nature même du codage [WAL91][EC96], la perte de qualité de l'image s'effectue de manière cohérente sur les blocs de  $8 \times 8$  pixels, indépendamment d'un bloc à l'autre. Le seul lien susceptible d'exister entre deux blocs dépend de la statistique de répartition des niveaux de gris dans l'image, et non du codage. Cet effet, très visible pour de fortes compressions, est connu sous le nom d'*artefacts de blocs*. Au sein d'un même bloc, les pertes dépendent du contenu fréquentiel. Les hautes fréquences apparaissent assez vite dégradées quand le taux de compression augmente alors que les artefacts de blocs apparaissent plus tard, essentiellement sur les zones uniformes, comme le montrent les figures 2 et 3.

Plusieurs outils existent déjà pour quantifier de manière bivariante la qualité d'une image JPEG [OLI98]. A partir d'une mesure de distance entre l'image non comprimée et l'image dégradée, ces outils permettent d'évaluer la qualité de l'image comprimée. Notre objectif est d'arriver à évaluer cette qualité, qui peut être soit l'indice de qualité JPEG, soit tout autre indice visuel ou purement mathématique, directement à partir de l'image dégradée.

L'apprentissage sera effectué d'une part sur l'indice de qualité JPEG choisi lors de la phase de compression, indice purement mathématique, d'autre part sur un modèle représentatif d'une notation visuelle, donc subjective.

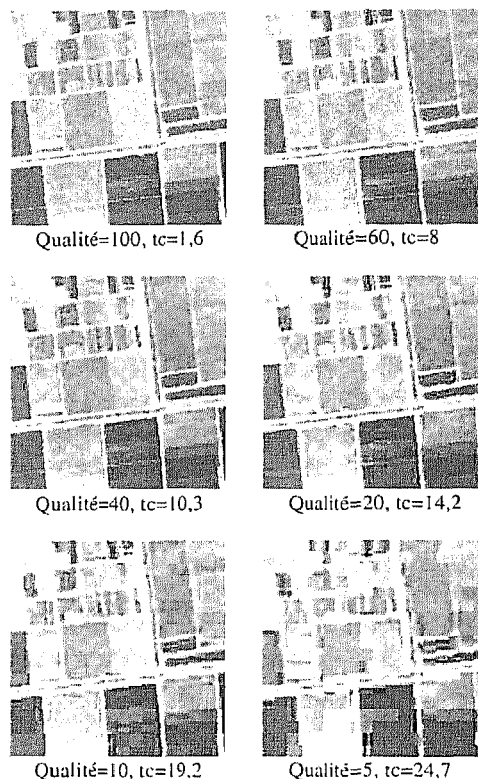


Figure 2. – Relation entre la qualité JPEG et le taux de compression pour une image uniforme de type champs.

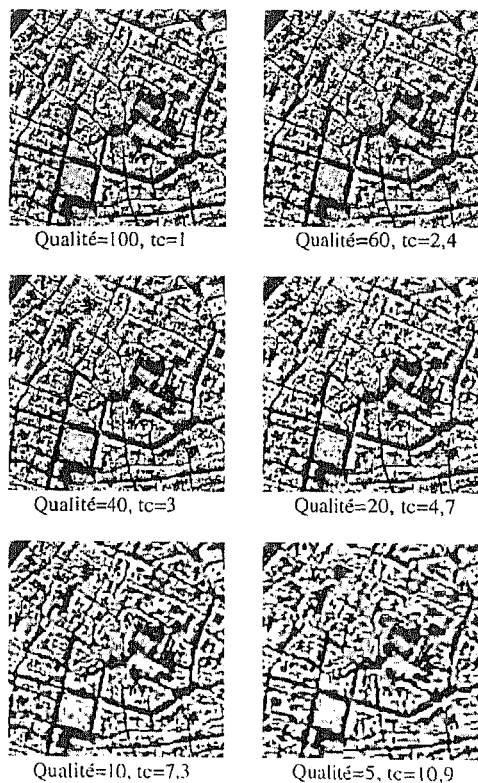


Figure 3. – Relation entre la qualité JPEG et le taux de compression pour une image structurée de type ville.

### 3.2. extraction du vecteur caractéristique

Il s'agit de rechercher les grandeurs physiques susceptibles de caractériser la qualité de l'image comprimée. Nous recherchons donc toute grandeur caractérisant la dégradation ou le type d'image. Ces deux aspects sont cependant très souvent liés et la confrontation de plusieurs de ces grandeurs permettra au RN d'estimer soit une qualité visuelle, soit une qualité purement mathématique.

Rappelons que le choix des composantes du vecteur caractéristique n'est pas exclusivement fondé sur des considérations physiques. Des grandeurs ayant une signification évidente sont bien sûr introduites dans le vecteur caractéristique, mais l'avantage de la méthode d'apprentissage avec un RN est qu'elle permet de sélectionner elle-même les données importantes. Pour cette raison, au cours de toutes les étapes du prétraitement de l'image, certaines grandeurs statistiques seront ajoutées au vecteur caractéristique sans raison apparente.

#### 3.2.1. prétraitement : caractérisation des blocs

L'objectif de cette phase est d'arriver à quantifier l'importance du phénomène de bloc, indépendamment du type d'image. Cette information, capitale lors de la phase d'apprentissage, est pourtant difficilement observable sur l'image comprimée non traitée. Les différentes étapes du prétraitement de l'image sont représentées sur la figure 4. Pour une image  $Im$  de  $N$  lignes et  $N$  colonnes constituée des pixels  $Im(i, j)$ , on calcule tout d'abord le Laplacien de l'image. Le noyau choisi permet de ne retenir que les composantes horizontale et verticale de l'image comprimée et donc de mettre en évidence les artefacts de blocs :

$$\Delta Im = Im * \begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix} \quad (1)$$

Nous ne considérerons par la suite que la valeur absolue du Laplacien de l'image, car seuls les contrastes aux frontières des blocs ont une importance dans l'évaluation de la qualité.

Les artefacts de blocs ont une structure dont la taille est un multiple de 8 pixels et peut varier d'un bloc à l'autre. Pour cette raison, il est difficile de les observer sur la transformée de Fourier du Laplacien de l'image. Pour amplifier encore le phénomène, nous avons cumulé d'une part les lignes et d'autre part les colonnes de l'image pour former 2 vecteurs  $V_{horiz}$  et  $V_{vertic}$  :

$$V_{horiz}(k) = \sum_{i=0}^N |\Delta Im(i, k)| \quad (2)$$

$$V_{vertic}(k) = \sum_{j=0}^N |\Delta Im(k, j)| \quad (3)$$

Ces vecteurs caractérisent l'amplitude du phénomène dans les directions horizontale et verticale. Nous avons formé le vecteur




Figure 4. – Prétraitement et détection des artefacts de blocs.

caractéristique de l'importance des artefacts de blocs sur l'image, indépendamment de son orientation :

$$V(k) = V_{horiz}(k) + V_{vertic}(k) \quad (4)$$

Ce vecteur est statistiquement un peigne de Dirac bruité, de période 8 pixels et on retiendra comme valeur caractéristique de l'importance du phénomène de bloc, la valeur  $FF_8$  de la FFT de  $V(k)$  qui correspond à une périodicité de 8 pixels.

La figure 5 montre l'évolution de ce coefficient en fonction de l'indice de qualité JPEG pour des images de types différents. On constate que, pour un même indice de qualité, ce coefficient est toujours plus grand pour une image très structurée (Test014) que pour une image uniforme (Test000), alors que visuellement l'image structurée paraît moins dégradée, comme le montrent les figures 2 et 3.

Ce coefficient, seul, n'est donc pas suffisant pour arriver à déterminer la qualité de l'image. En effet, selon le type d'image, il décrit l'une ou l'autre des courbes du faisceau de la figure 5 représentant sa variation en fonction de la qualité de l'image. Pour pouvoir déterminer la qualité, quelle qu'elle soit, il devra être associé à des informations concernant le type de l'image, telles que son variogramme (cf. § 3.2.2) ou ses moments. Ces informations permettront de déterminer la courbe sur laquelle on se situe (cf. figure 5), pour accéder ensuite à l'indice de qualité de manière bijective.

Parmi les grandeurs susceptibles de fournir une information complémentaire, nous avons choisi de retenir la valeur  $FF_{7,9}$  de la FFT de  $V(k)$ , moyenne de  $FF_7$  et  $FF_9$ , ainsi que  $FF_4$ , afin d'apporter au réseau de neurones une information sur l'image originale qui puisse être comparée à  $FF_8$ . En effet, il se peut qu'une image contienne une structure périodique de période proche de 8 pixels. Ce sera le cas si  $FF_{7,9}$  a sensiblement le même ordre de grandeur que  $FF_8$ . Dans le cas contraire, la probabilité que la valeur de  $FF_8$  soit uniquement due au phénomène de bloc est grande.




Figure 5. – Variation du coefficient  $FF_8$  en fonction de la qualité JPEG selon le type d'image.

D'autre part et pour la même raison, lors de chaque étape du pré-traitement, certaines grandeurs statistiques seront conservées sans raison physique évidente. La phase d'apprentissage du RN permettra de sélectionner les informations pertinentes.

Le calcul des paramètres précédents est décrit dans le cas d'images carrées. Dans le cas d'images rectangulaires, on peut, dans la plupart des cas, réaliser l'évaluation de qualité sur une partie carrée de l'image : l'indice de qualité JPEG, par exemple, est le même quel que soit la zone de l'image. Pour une évaluation de qualité dépendant de la zone considérée, visuelle par exemple, il faudrait calculer tous les  $FF_k$  à la fois sur  $V_{horiz}$  et  $V_{vertic}$ , sans calculer  $V(k)$ , et les inclure dans le vecteur caractéristique.

En revanche, tous les paramètres calculés par la suite le sont de la même manière pour des images carrées ou rectangulaires.

### 3.2.2. informations sur le type d'image

#### le variogramme

Le variogramme  $\gamma(h)$  d'une image est une mesure moyenne de la variation (au carré) des niveaux de gris pour des pixels séparés d'un nombre de pixels  $h$  donné [MAT71], [HUI75] :

$$\gamma(h) = \frac{1}{2} E[|Im(p+h) - Im(p)|^2] \quad (5)$$

où  $Im(p)$  est le niveau de gris du pixel  $p$ .

$\gamma(h)$  varie de 0 à une asymptote qui est la variance de l'image. La pente à l'origine est caractéristique du type d'image en étant l'inverse de la distance de corrélation statistique habituelle. Certaines fluctuations locales peuvent être observées selon la structure de l'image. La figure 6 montre les variogrammes des images de type « ville » (Test014) et « champs » (Test000) pour différentes qualités de compression JPEG. Deux images différentes ont des variogrammes différents et la qualité de la compression n'influe que peu sur l'allure générale du variogramme. C'est donc un bon descripteur du type d'image. La compression a tendance à diminuer les valeurs du variogramme car, en coupant les hautes fréquences, elle augmente la corrélation entre des points voisins d'un même bloc. Pour cette même raison, la compression affecte plus le variogramme d'une image structurée (Test014) que celui d'une image très uniforme. Pour des images dont la texture est homogène, le variogramme est habituellement modélisé par une fonction du type [RR89] :

$$\gamma(h) = A(1 - e^{-Bh}) \quad (6)$$

où  $A$  représente la variance de l'image et  $B$  est caractéristique de la texture. Un tel modèle n'est pas suffisant pour décrire les variogrammes d'images quelconques, en particulier très structurées, dont la pente à l'origine et la variance sont élevées.

Nous avons choisi une modélisation à quatre paramètres, du type :

$$\gamma(h) = A(1 - e^{-Bh}) + C(1 - e^{-Dh}) = E_1 + E_2 \quad (7)$$

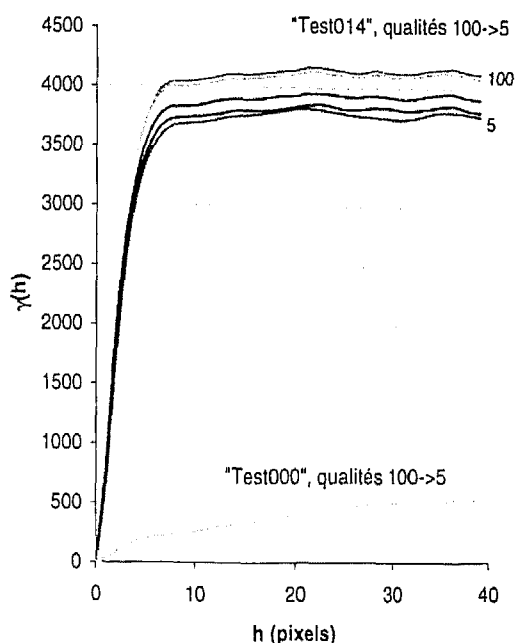


Figure 6. – Variogrammes d'une image de type « ville » (Test014) et « champs » (Test000) pour les qualités JPEG 100, 60, 40, 20, 10, 5.

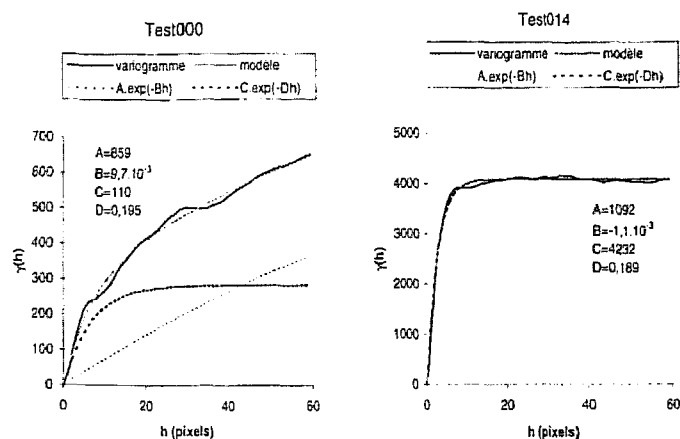


Figure 7. – Propriétés du modèle de variogramme.

En effet, elle permet de représenter aussi bien les variogrammes du type « ville » que ceux du type « champ », tout en conservant les informations pente à l'origine, asymptote, distance de corrélation (abscisse pour laquelle la tangente à l'origine coupe l'asymptote). Les paramètres  $A$ ,  $B$ ,  $C$ ,  $D$  ont été calculés de manière à minimiser l'erreur quadratique moyenne entre le modèle et le variogramme. Les fonctions  $E_1$  et  $E_2$  étant permutables, nous avons choisi pour  $E_1$  le couple  $(A, B)$  de paramètres correspondant à la variation des niveaux de gris à longue distance sur l'image, et pour  $E_2$  le couple  $(C, D)$  correspondant à la variation à courte distance. Notons cependant que  $A + C$  (asymptote du modèle) représente la variance de l'image et que  $AB + CD$  (dérivée à l'origine du modèle) est inversement proportionnel à la distance de corrélation habituelle. La figure 7 montre pour 2 images de types différents extraites de la base de test (cf. figure 1) que les fonctions  $E_1$  et  $E_2$  du modèle traduisent le comportement à l'origine et à l'asymptote du variogramme, c'est-à-dire justement la variation des niveaux de gris des pixels de l'image pour des courtes et grandes distances.

#### autres statistiques

Toute grandeur statistique pouvant fournir une information sur le contenu de l'image est intéressante, à condition qu'elle ne soit pas modifiée par la compression. C'est le cas en ce qui concerne la moyenne et la variance qui ne sont quasiment pas modifiées lors de la transformée discrète en cosinus de la compression JPEG. On retiendra aussi les moments d'ordre 3 et 4 de l'image comme paramètres susceptibles de fournir une information complémentaire pour déterminer la qualité. L'étude de sensibilité (cf. § 3.4.) donnera des informations sur la pertinence de ce choix.

Toutes ces grandeurs statistiques ne sont affectées par la compression que pour des indices de qualité JPEG faibles. C'est-à-dire de très forts taux de compression, elles donnent une information sur l'image parfaite.

#### 3.2.3. le vecteur caractéristique

C'est l'ensemble des paramètres qui vont caractériser la dégradation et le type d'image pour servir d'entrée au RN. Il est défini de manière à tenir compte des propriétés essentielles des artefacts de blocs ainsi que de celles de l'image. L'utilisation d'un RN permet lors de l'apprentissage (cf. § 3.4.) de mesurer l'importance de l'une ou l'autre de ces composantes. Certaines d'entre elles, à la signification physique moins évidente, ont été retenues parce que l'apprentissage a montré qu'elles étaient significatives dans l'appréciation de la qualité. L'étude de sensibilité présentée au § 3.4. permettra de déterminer quelles sont les composantes réellement importantes dans l'évaluation de la qualité et donc d'éliminer d'éventuelles redondances. Le vecteur caractéristique est constitué des composantes suivantes :

0. Moyenne de l'image

1. Variance de l'image

2. Moment d'ordre 3 de l'image

3. Moment d'ordre 4 de l'image

4. Coefficient  $A$  du variogramme

5. Coefficient  $B$  du variogramme

6. Coefficient  $C$  du variogramme

7. Coefficient  $D$  du variogramme

8. Moyenne de la valeur absolue du Laplacien de l'image

9. Variance de la valeur absolue du Laplacien de l'image
10. Moment d'ordre 3 de la valeur absolue du Laplacien de l'image
11. Moment d'ordre 4 de la valeur absolue du Laplacien de l'image
12. Moyenne de  $V_{vertic}$
13. Variance de  $V_{vertic}$
14. Moment d'ordre 3 de  $V_{vertic}$
15. Moment d'ordre 4 de  $V_{vertic}$
16. Variance de  $V_{horiz}$
17. Moment d'ordre 3 de  $V_{horiz}$
18. Moment d'ordre 4 de  $V_{horiz}$
19. Valeur de  $FF_8$  sur  $V(k)$
20. Valeur de  $FF_4$  sur  $V(k)$
21. Valeur de  $FF_{7,9}$  sur  $V(k)$  (pour comparaison avec  $FF_8$ )
22. Valeur de  $FF_8$  sur l'image
23. Valeur de  $FF_{7,9}$  sur l'image (pour comparaison avec  $FF_8$ )
24. Moyenne de  $V(k)$
25. Variance de  $V(k)$
26. Moment d'ordre 3 de  $V(k)$
27. Moment d'ordre 4 de  $V(k)$

Les paramètres 22 et 23 sont calculés exactement comme les paramètres 19 et 21 mais directement sur l'image et non pas sur le Laplacien de l'image : l'image est sommée sur les lignes et les colonnes pour former un vecteur  $V'(k)$  dont on calcule la FFT. Nous pensons, à ce niveau, que ces paramètres étaient susceptibles d'apporter une information complémentaire au RN, mais l'étude de sensibilité (3.4.) montrera que leur importance est en fait négligeable.

D'autre part, la moyenne de  $V_{horiz}$  est rigoureusement la même que celle de  $V_{vertic}$  et pour cette raison elle n'a pas été incluse dans le vecteur caractéristique.

### 3.3. résultats

Le logiciel utilisé pour la mise en place du RN est SNNS (Stuttgart Neural Network Simulator v4.1), logiciel en distribution gratuite. Le réseau est constitué d'une couche d'entrée de 28 neurones (qui reçoivent les composantes du vecteur caractéristique), de deux couches cachées de 30 et 10 neurones et d'un neurone de sortie. Ces paramètres sont fixés de manière empirique. Le nombre de coefficients  $p_i$  est donc  $28 * 30 + 30 * 10 + 10 = 1150$ . La taille de la base d'apprentissage permettant d'étalonner les coefficients  $p_i$  doit être plusieurs fois supérieure au nombre de coefficients [CAR93], [AMA95], [MAA95].

L'apprentissage a été effectué sur une base de 800 images différentes et variées (structurées, uniformes, images satellitaires, photographies, etc.) avec des indices de qualité JPEG 10, 20, ...

100, soit au total 8000 exemples. Ces données sont représentatives de n'importe quel type d'image, avec des taux de compression faible, moyen et fort. Un indice de qualité égal à 100 correspond à une compression entropique et l'image restituée est parfaite.

En cours d'apprentissage, le réseau est testé régulièrement sur une base de test (figure 1). L'apprentissage est arrêté quand l'erreur moyenne sur la base de test remonte, signe que le RN apprend trop sa base d'apprentissage et perd sa capacité de généralisation.

Pour prouver l'adaptabilité de la méthode, l'apprentissage a été réalisé d'après deux notations de qualité très différentes. Dans un premier temps nous avons vérifié qu'il était possible de retrouver l'indice de qualité JPEG d'une image comprimée. Dans un deuxième temps, l'apprentissage a été réalisé de manière à reproduire une notation plus subjective correspondant à la qualité visuelle de l'image, grâce au modèle bivariant de Karunasekera et Kingsbury ([KK95b]).

#### 3.3.1. apprentissage de l'indice de qualité JPEG

L'indice de qualité JPEG est normalisé sur l'intervalle [0,1], toutes les entrées sont normalisées sur [-1, 1]. La figure 8 présente les résultats obtenus après apprentissage de l'indice de qualité pour chacune des images de la base de test et les résultats moyens, de manière à identifier d'éventuelles singularités.

L'erreur quadratique moyenne (EQM) entre la qualité théorique de l'image et celle prédite par le RN est de 5,5 %. L'erreur maximale de 14 % est obtenue pour l'image Test000, qui est une image de champs, très uniforme. On constate aussi pour cette même image que l'erreur est plus importante pour des qualités moyennes que pour les extrêmes. Aucune explication n'est pro-

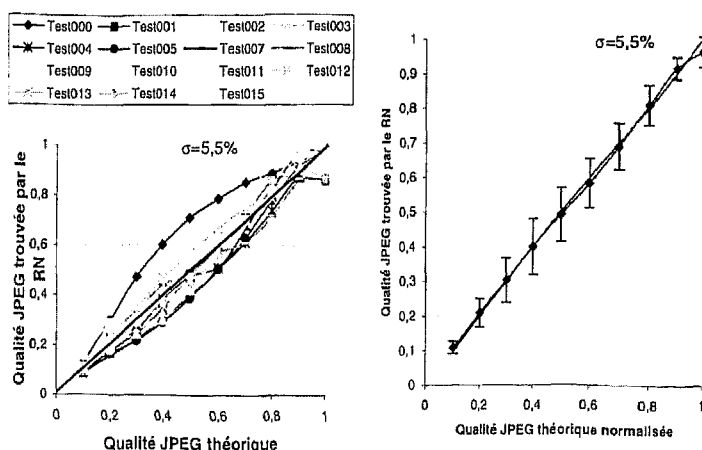


Figure 8. – Résultats obtenus sur la base de test, après apprentissage de l'indice de qualité JPEG.



posée pour expliquer ce phénomène. Le RN est un très bon interpolateur, son comportement en extrapolation n'est pas toujours bien connu. Cette image est vraisemblablement mal située par rapport à la base d'apprentissage.

Pour mesurer la similitude entre la notation du RN et la note théorique, le coefficient de corrélation de Pearson a été calculé. Si  $(x_i)$  et  $(y_i)$  sont les notes de qualité théorique et donnée par le modèle, ce coefficient vaut :

$$R = \frac{\sum_i x_i y_i - \frac{1}{N} \sum_i x_i \sum_i y_i}{\sqrt{[\sum_i x_i^2 - \frac{1}{N} (\sum_i x_i)^2][\sum_i y_i^2 - \frac{1}{N} (\sum_i y_i)^2]}} \quad (8)$$

Comme le montre le tableau 1, il existe toujours une très forte corrélation entre les indices de qualité JPEG théoriques et les indices calculés par le RN, preuve que la notation du RN est très semblable à la notation théorique : pour une même image, le RN arrive toujours à classer les images en fonction de leur qualité.

Tableau 1. – Statistiques concernant l'apprentissage de l'indice de qualité JPEG : coefficient de corrélation entre la notation théorique et celle du modèle univariant, erreur quadratique moyenne.

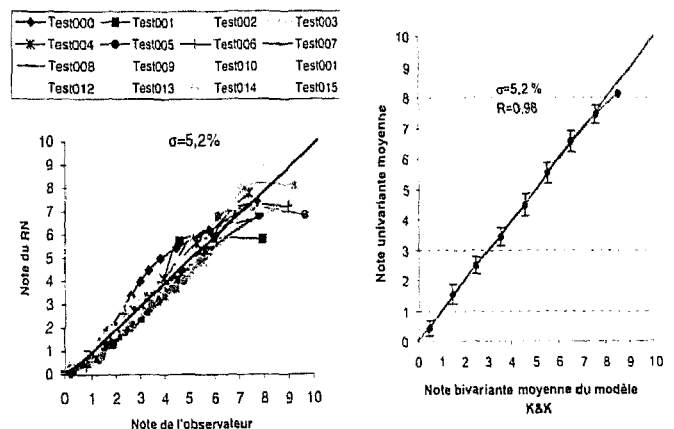
Image	Coefficient de corrélation R de Pearson	EQM (%)
Test000	0,963	13,9
Test001	0,986	5,5
Test002	0,985	7,6
Test003	0,996	4,4
Test004	0,995	4,9
Test005	0,990	6,8
Test006	0,980	4,1
Test007	0,989	6,6
Test008	0,991	4,8
Test009	0,997	2,3
Test010	0,995	6,0
Test011	0,980	6,5
Test012	0,997	3,4
Test013	0,996	2,8
Test014	0,987	5,1
Test015	0,995	3,8
Moyenne	0,989	5,5

### 3.3.2. apprentissage d'une notation de qualité visuelle (Karunasekera et Kingsbury [KK93], [KK94], [KK95])

La notation de l'image envisagée maintenant est beaucoup plus représentative d'une notation subjective que l'indice de qualité JPEG. Nous nous proposons de retrouver la note de qualité visuelle d'une image JPEG prédite par le modèle bivariant de S. Karunasekera et N. Kingsbury (K & K). Dans ce modèle, étalonné d'après les résultats d'une campagne de tests visuels, la note de qualité attribuée à l'image comprimée est fonction du temps que l'observateur met pour la différencier de l'image parfaite : plus l'image est dégradée, plus la décision est rapide, alors que lorsque l'image est très peu comprimée, le temps mis pour prendre la décision peut atteindre plusieurs secondes. Cette note n'a plus rien à voir avec l'indice de qualité utilisé précédemment. Notre objectif est de montrer que le modèle peut aussi reproduire de façon univariante un tel type de notation.

Les images de la base d'apprentissage restent les mêmes : 800 images différentes, chacune comprimée avec les 10 indices de qualité 10, 20, ..., 100. Un indice de qualité de 100 correspond à une compression entropique et l'image n'est absolument pas dégradée. Chacune des 8000 images ainsi obtenues est notée par le modèle bivariant K & K. C'est sur cette notation, rapportée à l'intervalle [0, 10], que l'apprentissage est réalisé.

Comme le montrent la figure 9 et le tableau 2, les résultats ont dans ce cas aussi une erreur moyenne inférieure à 6 %, avec un pic de 10 % pour l'image Test014 qui est une ville.



(a) Résultats obtenus image par image. (b) Résultats moyens obtenus sur des intervalles de un point de notation. Les barres d'erreurs sont les écarts types sur ces mêmes intervalles.

Figure 9. – Résultats obtenus sur la base de test après apprentissage de la notation de qualité visuelle donnée par le modèle K&K.

Tableau 2. – Statistiques concernant les résultats obtenus sur la base de test dans le cadre de l'apprentissage de l'indice de qualité visuelle : coefficient de corrélation entre la notation théorique et celle du modèle univariant, erreur quadratique moyenne.

Image	Coefficient de corrélation R de Pearson	EQM (%)
Test000	0,971	7,9
Test001	0,934	8,0
Test002	0,996	2,6
Test003	0,994	2,8
Test004	0,997	2,7
Test005	0,997	5,0
Test006	0,975	5,9
Test007	0,978	4,9
Test008	0,995	2,0
Test009	0,989	3,5
Test010	0,991	2,9
Test011	0,958	7,7
Test012	0,998	5,1
Test013	0,977	6,6
Test014	0,935	10,1
Test015	0,968	5,9
Moyenne	0,978	5,2

### 3.4. étude de sensibilité – réduction du vecteur caractéristique

L'importance de chacune des composantes du vecteur d'entrée du RN, difficilement accessible directement, est estimée par une étude de sensibilité. Cette étude doit permettre de supprimer les composantes du vecteur caractéristique inutiles ou redondantes. La sensibilité est évaluée de la manière suivante : pour chaque type d'image, le vecteur d'entrée correspondant à l'image parfaite est calculé. La sensibilité vis-à-vis de la  $j^{\text{ème}}$  composante est calculée en la faisant varier sur  $[-1, 1]$  (qui est l'intervalle de définition des entrées), toutes les autres étant constantes, et en évaluant la déviation maximale introduite sur la sortie du RN par rapport à la valeur correspondant à l'image parfaite.

Si  $(x_0, \dots, x_j, \dots, x_p)$  sont les composantes du vecteur caractéristique d'une image non comprimée et  $f(x_0, \dots, x_j, \dots, x_p)$  est la sortie du RN associée à cette image, la sensibilité  $S(j)$  à la  $j^{\text{ème}}$  composante est définie de la manière suivante :

$$S(j) = \max_{x'_j \in [-1, 1]} \left[ \frac{f(x_0, \dots, x'_j, \dots, x_p) - f(x_0, \dots, x_j, \dots, x_p)}{f(x_0, \dots, x_j, \dots, x_p)} \right] \quad (9)$$

Pour chaque image, les  $S(j)$  ont été normalisées à 100 pour la plus importante. La sensibilité moyenne à la composante  $x_j$  sur l'ensemble des images est la moyenne sur les images des  $S(j)$  non normalisées. La sensibilité moyenne est ensuite elle aussi normalisée à 100.

#### 3.4.1. sensibilité de l'apprentissage de l'indice de qualité JPEG

La figure 10 montre les sensibilités vis-à-vis des différentes composantes pour 3 images de types différents et en moyenne sur la base de test.

On constate que les différentes entrées prennent des importances différentes selon le type d'image. Pour évaluer la qualité de la plupart des images, seuls 3 ou 4 paramètres semblent importants. Le coefficient  $FF_8$  est utilisé en priorité pour estimer la qualité de l'image, pondérée par des informations plus spécifiques concernant le type d'image. Pour apprendre la qualité d'une image uniforme (Test000), une grande importance est accordée aux coefficients  $B$  et  $C$  du variogramme qui permettent d'identifier la texture de l'image. En revanche, pour une image très structurée (Test014), beaucoup de paramètres semblent influencer la décision. Quelques entrées semblent ne jamais avoir d'influence, c'est le cas des moments d'ordre 3 et 4 de  $V(k)$  dont la signification physique n'est pas triviale.

#### réduction du vecteur caractéristique :

Des apprentissages ont été réalisés en supprimant les entrées d'importance moindre pour en vérifier la non importance. Si dans un premier temps, on ne retient que les composantes d'importances supérieures à 20 sur une base 100, l'apprentissage est très mauvais, l'erreur quadratique moyenne sur l'ensemble des images est d'environ 40-45 % selon les configurations de RN choisies. Si l'on ne considère maintenant que les entrées d'importances relatives supérieures à 10/100, cette erreur reste très élevée, autour de 30-35 %.

Dans un deuxième temps, nous avons émis l'hypothèse que l'orientation des images n'avait pas d'influence sur la note de qualité pour supprimer du vecteur caractéristique les composantes correspondant à  $V_{horiz}$  et  $V_{vertic}$ , devenues redondantes avec  $V(k)$ . L'erreur quadratique moyenne sur l'ensemble des images se dégrade pour atteindre 9,2 % dans cette configuration et l'étude de sensibilité ne montre pas de hausse de sensibilité vis-à-vis de  $V(k)$ . Le fait que  $V_{horiz}$  et  $V_{vertic}$  aient une importance, même faible, peut être expliqué au regard de la base d'apprentissage qui

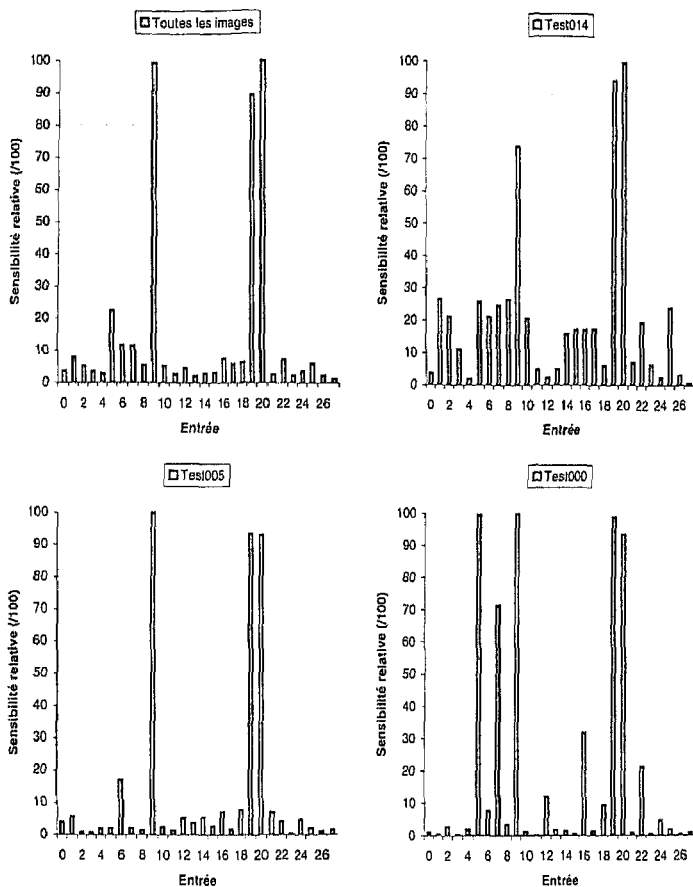


Figure 10. – Sensibilité vis-à-vis des composantes dans le cadre de l'apprentissage de l'indice de qualité JPEG.

contient un grand nombre d'images de scènes extérieures, de façades ou de visages, dans lesquelles l'une des directions horizontale ou verticale est privilégiée. En effet, les artefacts de blocs ont statistiquement la même composante sur  $V_{horiz}$  et  $V_{vertic}$ . Les différences entre ces deux vecteurs sont dues aux composantes verticales et horizontales de l'image autres que les blocs, et cette information est susceptible de fournir une indication sur la qualité.

Finalement, nous avons tenté de conserver  $V_{horiz}$  et  $V_{vertic}$  pour supprimer les moments de  $V(k)$ , qui peuvent sembler redondants. L'erreur quadratique moyenne sur l'ensemble des images est de 6,5 % dans cette configuration et la sensibilité vis-à-vis des composantes relatives à  $V_{horiz}$  et  $V_{vertic}$  n'augmente pas de manière notable. Il semble que  $V(k)$ , représentatif de l'importance globale des artefacts de blocs sur l'image, apporte une information complémentaire, mais d'importance moindre, pour déterminer la qualité de l'image.

### 3.4.2. sensibilité de l'apprentissage de la qualité visuelle

Une étude de sensibilité identique à la précédente a été réalisée. La figure 11 en présente les résultats. Dans ce cas, chaque entrée intervient à un moment ou à un autre. Comme précédemment, la donnée la plus importante est le coefficient  $FF_8$  pour tous les types d'image.

Des apprentissages ont été réalisés en ne conservant que les composantes qui semblent avoir une grande importance physique. Le tableau 3 montre que seul un faible nombre d'entrées a une réelle importance sur l'apprentissage, mais chacune apporte sa contribution pour améliorer la précision. Contrairement à l'apprentissage de l'indice de qualité JPEG, la donnée du coefficient  $FF_8$  associée à quelques informations sur le type d'image suffisent pour prédire la qualité visuelle avec la précision très acceptable de 7 %. L'ajout des autres composantes permet d'améliorer la précision petit à petit.

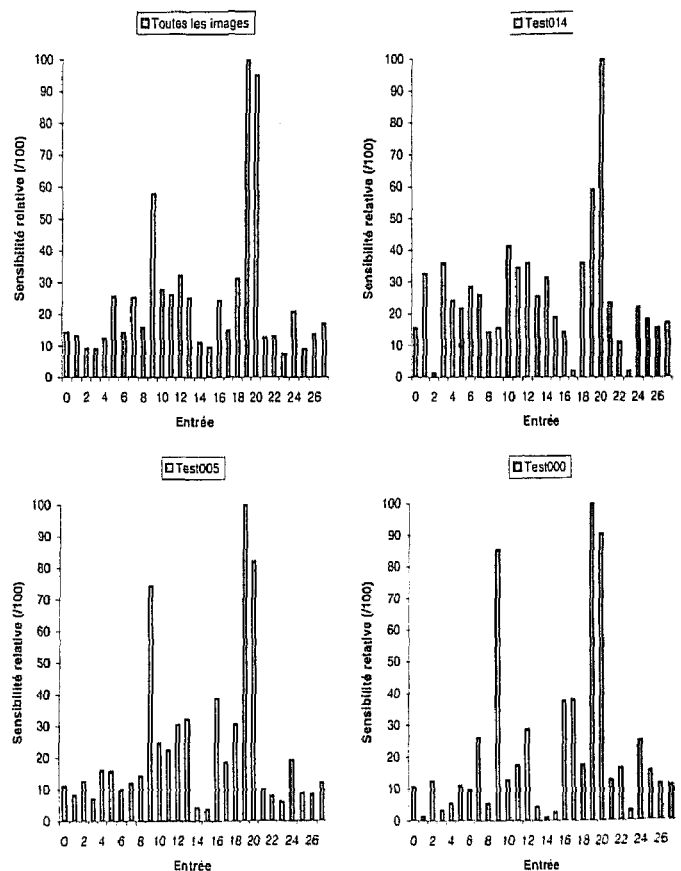


Figure 11. – Sensibilité vis-à-vis des composantes dans le cadre de l'apprentissage de la notation de qualité visuelle.

Tableau 3. – Influence de la suppression de certaines composantes du vecteur caractéristique sur la qualité de l'apprentissage.

Entrées conservées pour l'apprentissage	Coefficient de corrélation R de Pearson : sur la base de test moyenne sur la base de test	EQM moyenne %
Sensibilité $\geq 30/100$	0,974	7,2
Sensibilité $\geq 20/100$	0,975	6,8
Sensibilité $\geq 10/100$	0,976	5,7

La différence de comportement entre les deux modèles semble être liée à leur nature. L'œil ne peut pas différencier tous les indices de qualité JPEG parce que sa sensibilité n'est pas assez importante. Pour cette raison, la note donnée par le modèle visuel pour plusieurs indices de qualité différents mais proches peut être sensiblement identique. De ce fait elle est plus simple à approximer et nécessite moins de paramètres.

### 3.5. stabilité de la méthode

Pour nous assurer de la fiabilité du RN, nous l'avons utilisé pour évaluer la qualité d'images satellitaires comprimées JPEG. Nous avons choisi des images représentant des scènes diverses, champs, villes, montagnes, nuages, avec des résolutions différentes (10 m et 20 m).

La figure 12 montre les résultats obtenus pour les deux apprentissages que nous avons réalisés. Ces résultats montrent que la




Figure 12. – Validation des apprentissages sur un lot inconnu de 20 images satellitaires.

méthode fait preuve d'une fiabilité importante : l'erreur quadratique moyenne sur l'ensemble de ces images ne dépassent pas 4 % pour la notation visuelle, il en est de même pour l'estimation de l'indice de qualité JPEG.

### 3.6. apprentissage spécifique

Pour prouver l'efficacité de la méthode et pour montrer que la précision de l'évaluation peut être améliorée si le contexte applicatif est parfaitement défini, nous avons réalisé un apprentissage uniquement sur des images de texte. Nous avons généré ces images de façon totalement aléatoire : longueur des mots, taille de la police (cf. figure 13)...




Figure 13. – Quelques images de texte comprimées. La longueur des mots ainsi que la taille de la police est aléatoire.

Etant donné qu'aucune image de ce type n'est présente dans la base d'apprentissage utilisée jusqu'ici, les résultats ne sont pas très bons si l'on essaye d'évaluer la qualité de ces images avec le RN calibré précédemment : l'erreur avoisine les 20 % et le RN a parfois du mal à classer les images par intensité de dégradation. C'est en partie dû au fait que, pour ces images très spécifiques, en deux niveaux de gris et dont le fond est uniforme, la dégradation ne devient perceptible que pour de fortes compressions.

Si on réalise maintenant un apprentissage sur des images de ce type la précision des résultats est considérablement améliorée. L'erreur est maintenant inférieure à 2 % (cf. figure 14) et le RN arrive à classer des niveaux de dégradations qui sont absolument indifférenciables à l'œil. Des résultats comparables ont été obtenus pour l'apprentissage de la qualité visuelle d'images de texte comprimées.




Figure 14. – Evaluation de l'indice de qualité d'images de texte comprimées, après un apprentissage spécifique.

## 4. conclusion

Une nouvelle méthode d'évaluation de la qualité des images a été présentée dans cet article. A titre d'exemple, nous avons montré, pour des images comprimées JPEG, qu'il était possible de prédire, sans image de référence parfaite, une qualité mathématique ou subjective de l'image dégradée. Cette méthode repose sur un apprentissage de la qualité à base de réseaux de neurones.

Dans le cas d'une dégradation unique uniformément répartie sur l'image (compression, flou, rebond, bruit), elle permet de pré-

voir, avec une précision de 5 à 6 %, la qualité d'une image qui aurait été donnée par un modèle bivariant quel qu'il soit, après apprentissage sur ce modèle. De plus, elle permet aussi de sélectionner très simplement, par le biais d'une étude de sensibilité du réseau de neurone vis-à-vis des composantes du vecteur caractéristique, les paramètres physiquement importants dans l'évaluation de la qualité.

L'étude a aussi permis de montrer que l'on gagne d'une manière non négligeable en précision en utilisant une base d'apprentissage spécifique au domaine et que l'utilisation d'une telle base est recommandée dès lors que le contexte applicatif est très spécifique.

Pour généraliser la méthode à une combinaison de défauts uniformément répartis sur l'image, il est nécessaire d'effectuer un apprentissage sur des images contenant ces défauts dans des proportions différentes. L'ordre dans lequel les défauts sont appliqués sur l'image prend alors une grande importance. Pour certaines combinaisons de défauts, il reste possible de caractériser chacun d'eux individuellement (flou+JPEG dans cet ordre, par exemple). Pour d'autres combinaisons, seule une évaluation globale de qualité demeure possible (bruit+flou, dans cet ordre), les défauts intervenant les derniers pouvant masquer ou modifier les premiers.

L'avantage d'une telle approche, hormis l'absence de référence, est sa performance en termes de temps de traitement. Le seul coût est imposé par le calcul des composantes du vecteur d'entrée. Sur l'Enterprise E450 biprocesseurs UltraSPARC 300 MHz que nous avons utilisé, ce temps de calcul est de 9 secondes pour les images JPEG. Le RN n'effectue qu'un petit nombre de calculs élémentaires. Son inconvénient majeur est sans doute de n'offrir qu'une estimation statistique de fiabilité, alors que ce paramètre est mieux maîtrisé pour un modèle bivariant.

## Remerciements

Nous remercions MM. Paul Bourret et Jean-Loup Bussenot de l'ONERA/DTIM pour leur aide précieuse en ce qui concerne l'utilisation des réseaux neuronaux. Leurs conseils avisés ont permis d'améliorer considérablement la qualité des résultats.

## BIBLIOGRAPHIE

- [ABP96] D. Anguita, I. Barbiéri, and F. Passagio. « Block distortion assessment for image compression through ANNS ». In *Proceeding of the SPIE - The international society for optical engineering*, volume 2664, pages 25–36, 1996.
- [AMA95] S. Amari. « *The Handbook of Brain Theory and Neural Networks* ». MIT Press, Cambridge, Massachusetts, m. a. arbib edition, 1995.
- [CAR93] R. Caruna. « Generalization vs net size ». *Neural Information Processing Systems*, 1993.

- [CL93] H. Chou and Y.C. Li. « A perceptually tuned subband image coder based on the measure of just-noticeable distortion profile ». *IEEE transactions on circuits and systems for video technology*, 5(6) : 467–476, 1993.
- [DAL92] S. Dali. « The visible differences predictor : an algorithm for the assessment of image fidelity ». In *Proceedings of the SPIE, Human Vision, Visual Processing and Digital Display III*, volume 1666, pages 2–15, 1992.
- [DAL93] S. Dali. « The Visible Differences Predictor : an Algorithm for the Assessment of Image Fidelity, in *Digital Images and Human Vision* ». MIT press, a. b. watson edition, 1993.
- [DC90] Recommandation 500-4 du CCIR. Méthode d'évaluation subjective de la qualité des images de télévision ». 1990.
- [EC96] T. Eude and H. Chérifi. « Optimisation perceptuelle d'un codeur jpeg ». In *Proc. of CORESA 96*, pages 220–227, 1996.
- [HUI75] C. Huijbregts. « Regionalized variables and quantitative analysis of spatial data ». In *Display and analysis of spatial data*. Wiley, j. davis and m. mac cullagh edition, 1975.
- [KK93] S.A. Karunasekera and N.G. Kingsbury. « A distortion measure for blocking artifacts in images based on human visual sensitivity ». In *Proceedings of the SPIE, Visual Communications and Image Processing*, volume 2094, pages 474–486, 1993.
- [KK94] S.A. Karunasekera and N.G. Kingsbury. « A distortion measure for image artifacts based on human visual sensitivity ». In *Proceedings of ICASSP - IEE*, volume 5, pages 117–120, 1994.
- [KK95a] S.A. Karunasekera and N.G. Kingsbury. « A distortion measure for blocking artifacts in images based on human visual sensitivity ». *IEEE Transaction on Image Processing*, 4 : 713–724, 1995.
- [KK95b] S.A. Karunasekera and N.G. Kingsbury. « A distortion measure for coding artifacts in images : Implementation aspects ». Technical report, Department of Engineering, University of Cambridge, Signal Processing Group, 1995.
- [LIN56] E.H. Linfoot. « Transaction factors and optical design ». *Journal of the Optical Society of America*, 46(9) : 740–752, 1956.
- [LIN58] E.H. Linfoot. « Quality evaluation of optical systems ». *Optica Acta*, 5(1-2) : 1–13, 1958.
- [MAA95] W. Maas. « Vapnik-chervonenkis dimension of neural networks ». In *The Handbook of Brain Theory and Neural Networks*, pages 522–52. MIT Press, Cambridge, Massachusetts, m. a. arbib edition, 1995.
- [MAT71] G. Mathéron. « The theory of regionalized variables and its application ». *Les cahiers du centre de morphologie mathématique de Fontainebleau*, 1971.
- [MEC98] A. Mayache, T. Eude, and H. Chérifi. « A comparison of image quality models and metrics based on human visual sensitivity ». In *Proceedings of the International conference on image processing*, volume 3, pages 409–413, 1998.
- [ML96] A. Meygret and D. Léger. « In-flight refocusing of the spot1 hrv cameras ». In *Proceedings of the SPIE, Algorithms for Multispectral and Hyperspectral Imagery II*, volume 2758, 1996.
- [MS74] J.L. Mannos and D.J. Sakrison. « The effects of visual fidelity criterion on the encoding of images ». *IEEE Transactions on Information Theory*, IT - 20(4) : 525–536, 1974.
- [OLI98] J.L. Olives. « Optimisation globale d'un système imageur à l'aide de critères de qualité visuelle ». PhD thesis, ENSAE, 1998.
- [RR89] M. Raffy and G. Ramstein. « Analysis of the structure of radiometric remotely sensed images ». *Remote Sensing*, 10(6) : 1049–73, 1989.
- [SHA56] O.H. Shade. « Optical and photoelectric analog of the eye ». *Journal of the Optical Society of America*, 46(9) : 721–739, 1956.
- [WAL91] G.K. Wallace. « The jpeg still image compression standard ». *Communication of the ACM*, 34 : 30–44, 1991.
- [WAT93] A.B. Watson. « Visual optimization of dct quantification matrices for individual images ». In *Proceedings of AIAA Computing in Aerospace 9*, pages 286–291, 1993.

Manuscrit reçu le 30 septembre 1999.

#### LES AUTEURS

##### Mathieu JUNG

Mathieu Jung est ingénieur de l'Ecole Nationale Supérieure d'Electronique d'Electrotechnique d'Informatique et d'Hydrolique de Toulouse (ENSEEIH96). Il est diplômé d'Etudes Approfondies en Signaux Images et Communications numériques (96) et en Astrophysique (97). Il termine actuellement sa thèse de doctorat dans le Département d'Optique Théorique et Appliquée de l'ONERA. Ses recherches portent sur l'évaluation de la qualité d'une image dégradée, dans un contexte où l'on ne dispose pas de l'image de référence.

##### Dominique LÉGER

Dominique Léger est ingénieur de l'Ecole Supérieure d'Optique (ESO73) et Docteur-Ingénieur (76). Il est ingénieur de recherche à l'ONERA depuis 1977. Il travaille dans le domaine de l'expertise qualité image des satellites d'observation de la terre, plus particulièrement sur le thème de la mesure en vol du défaut de mise au point et de la fonction de transfert de modulation des caméras satellitaires.

##### Marc GAZALET

Marc Georges Gazelet a reçu le « Bachelor of Science in Electrical Engineering and Telecommunications » en 1973 et le « Master of Science in Electrical Engineering » en 1976. Il a obtenu son PhD en 1979 et le Doctorat d'Etat ès-Sciences de l'université de Valenciennes en 1983. Il est, depuis, professeur dans le département d'Opto-Acousto-Electronique de l'Institut d'Electronique et de Microélectronique du Nord (IEMN UMR 8520 CNRS). Ses recherches portent sur l'acousto-optique, les communications numériques, le traitement du signal et de l'image.