

Recherche d'image par le contenu visuel utilisant la décomposition BEMD et le modèle Gamma généralisé des IMFS

Aziza Benkuider, Abdelouahed Sabri, Abed Allah Aarab

► To cite this version:

Aziza Benkuider, Abdelouahed Sabri, Abed Allah Aarab. Recherche d'image par le contenu visuel utilisant la décomposition BEMD et le modèle Gamma généralisé des IMFS. 42èmes Journées de Statistique, 2010, Marseille, France, France. 2010. <inria-00494809>

HAL Id: inria-00494809

<https://hal.inria.fr/inria-00494809>

Submitted on 24 Jun 2010

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

RECHERCHE D'IMAGE PAR LE CONTENU VISUEL UTILISANT LA DÉCOMPOSITION BEMD ET LE MODÈLE GAMMA GÉNÉRALISÉE DES IMFs

A.Benkuider¹ & A. Sabri² & A.Aarab²

¹ISII, Département de maths et informatique

²LESSI, Département de physique.

Faculté des sciences Dhar el mahraz BP 1796 FES MAROC.

azbenkuidier@yahoo.fr

Résumé

Dans ce travail, nous proposons, une approche de recherche d'images par le contenu visuel (CBIR), qui se base sur l'idée de calculer la distance de Kullback-leibler entre les densités marginales des modules des coefficients issus des sous bandes de la Décomposition Empirique Multimodale Bidimensionnelle (BEMD). Cette dernière conduit à une décomposition de l'image en un nombre adaptative des composantes hiérarchiques multiples IMFs (Intrinsic Mode Function).

Nous avons utilisé la décomposition FABEMD (the Fast and Adaptive BEMD) pour décomposer l'image, et nous avons proposé de modéliser les densités des modules des coefficients de détails des IMFs avec la distribution Gamma Généralisée.

Les résultats montrent que cette approche donne des taux de reconnaissance meilleurs que ceux de l'approche classique, qui *utilise la décomposition en ondelettes discrètes (DWT)*, les ondelettes de Gabor, et la DTCWT de Kingsbury.

Abstract

In this paper, we propose to characterize images without extracting local features, by using global information extracted from the image Bidimensional Empirical Mode Decomposition (BEMD). This method decompose image into a set of functions named Intrinsic Mode Function (IMF) and residue. The Generalized Gamma Density function (GG) is used to represent the coefficients derived from each IMF, and the Kullback-Leibler Distance (KLD) compute the similarity between GGs. Results are promising: retrieval efficiency is higher than 86 % for same cases.

Mots clefs

Recherche d'image par le contenu visuel (CBIR), Décomposition Empirique Multimodale Bidimensionnelle (BEMD), Intrinsic Mode Functions (IMF), FABEMD (the Fast and Adaptive BEMD), la distribution Gamma Généralisée, la distance de Kullback-leibler.

1) Introduction

Avec le grand essor de l'informatique et du multimédia, les bases de données des images numériques sont de plus en plus larges. L'image est aujourd'hui utilisée par les professionnels

comme par le public énorme qui dispose de capteurs très puissants et à des prix à la portée de tout le monde.

Afin d'améliorer l'interaction des utilisateurs avec ces bases de données, il est primordiale de développer des méthodes de recherche efficaces et pertinentes. Pour cela, la recherche d'image par le contenu visuel (CBIR), à connue une montée en puissance ces dernières années.

Afin de développer un système CBIR, on distingue deux tâches principales. La première est l'extraction des caractéristiques des images (FE : Feature Extraction). Elle consiste à générer un ensemble de caractéristiques sous forme de signatures capables de bien décrire les images de la base de données. La taille de la signature doit être beaucoup plus petite que celle de l'image en gardant toute l'information sur son contenu.

La deuxième tâche, est la mesure de similarité (SM : Similarity Measurement), qui consiste à calculer une distance entre une image requête et toutes les images de la base de données, qui seront ordonnées selon leurs similarité par rapport à cette image.

En supposant que les bases de données sont très grandes, nous devons opter pour des choix peu coûteux en termes de temps de calcul. De là, plusieurs méthodes de recherche d'image par le contenu visuel, quittent le domaine spatial de l'image vers d'autres domaines plus parcimonieux comme celui des ondelettes. Un grand nombre de ces méthodes s'est basé sur les ondelettes de Gabor, sur les transformations en ondelettes discrètes (DWT).les transformation en ondelettes complexes DTCWT de N.Kingsbury [1][2] , la Décomposition Empirique Multimodale Bidimensionnelle (BEMD). [3] et le FABEMD [4].

Dans notre travail, nous utilisons la décomposition Empirique Multimodale Bidimensionnelle (FABEMD),et une mesure de similarité en se basant sur la distance de Kullback-Leibler.

Notre contribution est de proposer un nouveau modèle pour la densité marginale des modules des coefficients de détails des IMFs issues de la décomposition FABEMD, ce modèle est la distribution Gamma Généralisée.

2) La Décomposition Bidimensionnelle Empirique Modale (BEMD)

La BEMD est définie par un processus appelé tamisage «sifting» permettant de décomposer l'image en contributions de base appelées modes empiriques ou IMF «Intrinsic Mode Functions» qui sont de type AM-FM, chacun de moyenne nulle [3].

➤ BEMD classique

Le sifting de la BEMD est décrit comme suit :

1. $I_r = I$ (I est l'image originale et I_r est l'image résiduelle)
2. construire l'enveloppe moyenne de I_r .
 - Calculons l'enveloppe supérieure et inférieure en interpolant les maxima et les minima de I_r
 - Déterminer l'enveloppe moyenne des deux enveloppes.
3. soustraire l'enveloppe moyenne de l'image résiduelle
4. répéter de 1 à 4 jusqu'à ce que l'imagerésiduelle soit une IMF.

➤ FABEMD (the Fast and Adaptive BEMD)

La decomposition FABEMD (the Fast and Adaptive BEMD) a les même étapes que la BEMD sauf

que la construction de l'enveloppe moyenne est différente de celle de la BEMD .

Construction de l'enveloppe moyenne par le FABEMD :

- calculer un filtre max-min.
- calculer l'enveloppe supérieure et inférieure par un filtrage moyenne.
- Déterminer l'enveloppe moyenne.

Pour déterminer la fenêtre de filtrage, la décomposition FABEMD utilise une méthode adaptative à chaque IMF (voir [4])

La figure 1 présente un exemple de décomposition d'une image par FABEMD.




Figure 1. Décomposition d'une image de la base Vistex par FABEMD et le résidu

3) Modélisation des densités marginales des modules des coefficients des IMFs par la distribution Gamma Généralisé

➤ *La Recherche d'Image par le Contenu Visuel dans un contexte statistique*

Supposons que nous avons N images dans notre base de données. Chaque image $I_i, 1 \leq i \leq N$, est représentée par un vecteur de caractéristiques $x_i = \{x_{i1}, \dots, x_{in}\}$, obtenu après l'étape d'extraction des caractéristiques (FE).

Le but du système CBIR est de trouver les K plus similaires images à l'image requête I_q , selon une mesure de similarité bien définie, et en supposant que toutes les images ont la même probabilité.

Dans l'approche paramétrique, chaque vecteur de caractéristique x_i de l'image I_i , contient n variables aléatoires indépendantes et identiquement distribuées $\{x_{i1}, \dots, x_{in}\}$ suivant une distribution dont la fonction de densité de probabilité est $p(x/\theta)$. θ est le vecteur des paramètres de la PDF.

Nous pouvons utiliser l'estimateur $\hat{\theta}$ de θ sans limites, en étant sûr de sa consistance. De là, on peut trouver l'image I_r la plus similaire à l'image I_q comme étant celle dont le paramètre θ_r conduit à une maximisation de la fonction log-vraisemblance.

Soit $x_q = \{x_{q1}, \dots, x_{qn}\}$, le vecteur de caractéristiques de l'image requête I_q , en ayant n suffisamment grand on peut appliquer la loi faible des grands nombres.

$$r = \arg \max_j \frac{1}{n} \sum_{i=1}^n \log(p(x_{ji}/\theta_j)) \quad (1)$$

$$(n \rightarrow \infty) r = \arg \max_i E_{p(x/\theta_q)}(\log(p(x/\theta_i))) \quad (2)$$

$$= \arg \max_i \int_D p(x/\theta_q) \log(p(x/\theta_i)) dx \quad (3)$$

$$= \arg \min_i \left\{ - \int_D p(x/\theta_q) \log(p(x/\theta_i)) dx \right\} \quad (4)$$

$$= \arg \min_i \int_D p(x/\theta_q) \log\left(\frac{p(x/\theta_q)}{p(x/\theta_i)}\right) dx \quad (5)$$

Nous constatons que le terme $\int_D p(x/\theta_q) \log\left(\frac{p(x/\theta_q)}{p(x/\theta_i)}\right) dx$ de l'équation (5) n'est autre que la mesure de Kullback-Leibler $KL(p_q/p_i)$ entre $p(x/\theta_q)$ et $p(x/\theta_i)$, avec $p_i = p(x/\theta_i)$. Donc, le problème de maximisation de la fonction log-vraisemblance peut être vu comme une minimisation de la mesure de Kullback-Leibler

➤ **Modélisation avec la distribution Gamma Généralisée**

Pour modéliser la densité marginale des modules des coefficients des IMFs issus de la decomposition FABEMD des images, nous utilisons la distribution Gamma Généralisée dont la PDF est :

$$f(y // \alpha, \tau, \lambda) = \frac{\tau}{\lambda^{\alpha\tau} \Gamma(\alpha)} y^{\alpha\tau-1} e^{-\left(\frac{y}{\lambda}\right)^\tau}, y \geq 0, \alpha, \tau, \lambda > 0$$

tel que $\Gamma(\cdot)$ est la fonction Gamma, α et τ sont les paramètres de formes, et λ le paramètre d'échelle.

La distribution Gamma Généralisée est très flexible, car elle inclue plusieurs autres distributions qui servent comme modèles pour les données positives, comme l'exemple de Weibull ($\alpha = 1$), et Gamma ($\tau = 1$). Elle donne l'Exponentiel pour ($\alpha = \tau = 1$).

Pour l'estimation des paramètres nous nous basons sur le travail de Stacy et Mirham [5].

La mesure de Kullback-Leibler entre deux Gamma Généralisées est la suivante :

$$KL_{\text{Gamma}}(p // p_0) = \log \frac{\phi_\tau}{\phi_\lambda^{\alpha\phi_\tau}} - \log \frac{\Gamma(\alpha)}{\Gamma(\alpha_0)} - \alpha + \mu(\alpha, \phi_\tau, \phi_\lambda) + (\alpha\phi_\tau - \alpha_0) \nu(\alpha, \phi_\tau, \phi_\lambda) \quad (8)$$

avec $p = GG(\alpha, \tau, \lambda)$ et $p_0 = GG(\alpha_0, \tau_0, \lambda_0)$.

$$\phi_\tau = \frac{\tau}{\tau_0}, \quad \phi_\lambda = \left(\frac{\lambda}{\lambda_0}\right)^{\tau_0}.$$

$$\mu(\alpha, \tau, \lambda) = \frac{\lambda \Gamma\left(\alpha + \frac{1}{\tau}\right)}{\Gamma(\alpha)}, \text{ le moment d'ordre 1 de la Gamma Généralisée } GG(\alpha, \tau, \lambda).$$

$$\nu(\alpha, \tau, \lambda) = \log \lambda + \frac{1}{\tau} \psi(\alpha), \text{ la moyenne géométrique de } GG(\alpha, \tau, \lambda).$$




Figure 2 – Histogramme des coefficients des IMFs .Modélisation avec Gamma Généralisée.

4) Résultats de simulation

Nous visons à comparer notre approche avec celles proposées dans [2], [3] et [6]. Pour cela, nous avons gardé les mêmes conditions d’expériences, en utilisant la base de données Vistex [7], qui contient 40 classes de textures de taille 512 x 512, chacune divisée en 16 textures de taille 128 x 128 pixels, et en effectuant une normalisation des textures par soustraction de la moyenne et division par l’écart-type.

Pour calculer le taux de reconnaissance de notre système, on prend les K-plus proches images à notre image requête, et on calcule combien parmi elles font vraiment partie de la même classe

Méthode	Ondelettes de Gabor,	DWT	DTCWT	FABEMD
Taux de reconnaissance	72.3438	77.7734	79.5996	89.6773

Tableau 1: Taux de reconnaissance des K=16 plus proches images.

Nous constatons d’après le Tableau 1 que l’approche se basant sur le FABEMD en utilisant les modèles Gamma Généralisée donne des résultats plus élevés que celle utilisant les Ondelettes de Gabor, les ondelettes DWT [2] et DTCWT [6]..

5) Conclusion

Dans ce travail, nous avons proposé une approche de recherche d’image par le contenu visuel, qui se base sur la modélisation des modules des coefficients des IMFs issus de la décomposition FABEMD, avec le modèle Gamma Généralisée pour la tâche d’extraction des caractéristiques (FE), et se basant sur la mesure de Kullback-Leibler pour la tâche de mesure de similarité (SM).. Les résultats de simulation sont très satisfaisants et montrent l’intérêt de tels descripteurs.

Bibliographie

- [1] N. Kingsbury, (1998) “The Dual-Tree Complex Wavelet Transform:A new Technique for Shift-Invariance and Directional Filters,” in Proceedings of the 8th IEEE DSP Workshop, Bryce Canyon,Utah, USA, Aug, pp. 9–12.
- [2] R.Kwitt and A.Uhl, (Oct. 2008) « Image similarity measurement by Kullback-Leibler divergences between complex wavelet subband statiscs for texture retrieval », in Proceedings of the IEEE international Conference on Image Processing , (ICIP’ 2008), pp.933-936.
- [3] J.C. Nunes, Y. Bouaoune, E. Deléchelle, S. Guyot, and Ph. Bunel.(2003) "Texture analysis

based on the bidimensional empirical mode decomposition". Journal of Machine Vision and Applications (MVA).

[4] Sharif M. A. Bhuiyan¹, Reza R. Adhami, Jesmin F. (mars 2008)" Fast and adaptive bidimensional empirical mode decomposition using a novel approach of envelope estimation "IEEE Internationl conference.

[5] E. W. Stacy and G. A. Mihram, 3 (Aug.,1965), " Parameter Estimation for a Generalized Gamma Distribution" American Statistical Association and American Society for Quality Technometrics, Vol. 7, No. pp. 349-358.

[6] A.Drissi El Maliana, M.El Hassounia, Y.Berthoumieu, (2009)"Recherche d'image par le contenu visuel utilisant le modèle Gamma Généralisée"JDTIC conférence.

[7] "MIT vision and modeling group," [Online], Available from: <http://vismod.www.media.mit.edu>.