

Analyse de la vidéo

Chapitre 4.3 - Introduction aux images Super-résolution

10 mars 2015

Plan de la présentation

- 1 Idée générale de la Super-résolution
 - Introduction
 - Comment augmenter la résolution ?
- 2 Super-resolution à plusieurs images
 - Définition du problème
 - Approche par interpolation non uniforme
 - Approche par transformée de Fourier
 - Reconstruction SR régularisée
- 3 Super-resolution à une seule image
 - Approche générale
 - Ensemble d'entraînement
 - SR par réseaux de Markov

Terminologie

Low-resolution (LR)

La densité de pixel pour une image est basse, ce qui offre moins de détail.

High-resolution (HR)

La densité de pixel pour une image est haute, ce qui offre plus de détail.

Super-resolution (SR)

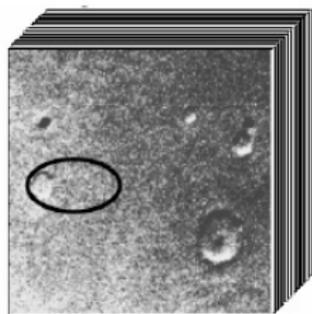
L'action d'obtenir une image HR à partir d'une ou plusieurs images LR.

Applications

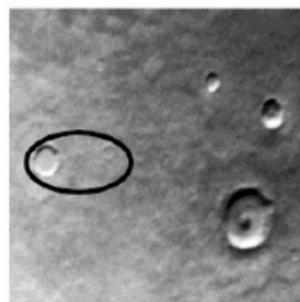
- Imagerie médicale
- Image satellite
- Vidéo surveillance (zoom sur plaque d'immatriculation).
- Télévision HD (conversion de contenu de vidéo NTSC en haute résolution).
- ...

Applications

Imagerie Médicale



Acquisition temporelle



Super-résolution



Applications



Applications

Original image



Low-resolution image (1 of 16)



4x Super-resolved image (Bayesian)



4x Super-resolved image (MAP)



Approches

Pour un besoin de précision, on voudrait augmenter la **densité de pixel** pour une scène. Il y a trois principales approches pour cela :

- 1 Diminuer la taille des pixels → Acquisition
 - + Augmente la résolution spatiale.
 - Introduction de bruit → Quantité de lumière réduite.
- 2 Augmenter la taille des capteurs CCD → Acquisition
 - + Augmente la résolution spatiale.
 - Capteurs coûtent très cher.
- 3 Super-résolution (SR) → Traitement
 - + Ne coûte rien.
 - + On obtient à la fois des images LR et HR.

Super-résolution (SR)

Il y a principalement deux approches de la SR :

- ➊ Approche à plusieurs images (MFSR) :
 - Permet, selon certaines hypothèses, d'obtenir des images haute-résolution avec de multiples faibles acquisitions.
 - Extrapolation de l'information HR des différentes images LR.
- ➋ Approche à une image (SFMR) :
 - Crée par interpolation une image HR à partir d'une image basse résolution (LR)
 - Interpole l'information HR, donc PAS d'ajout d'information HR réelle à l'image résultante.

Plan de la présentation

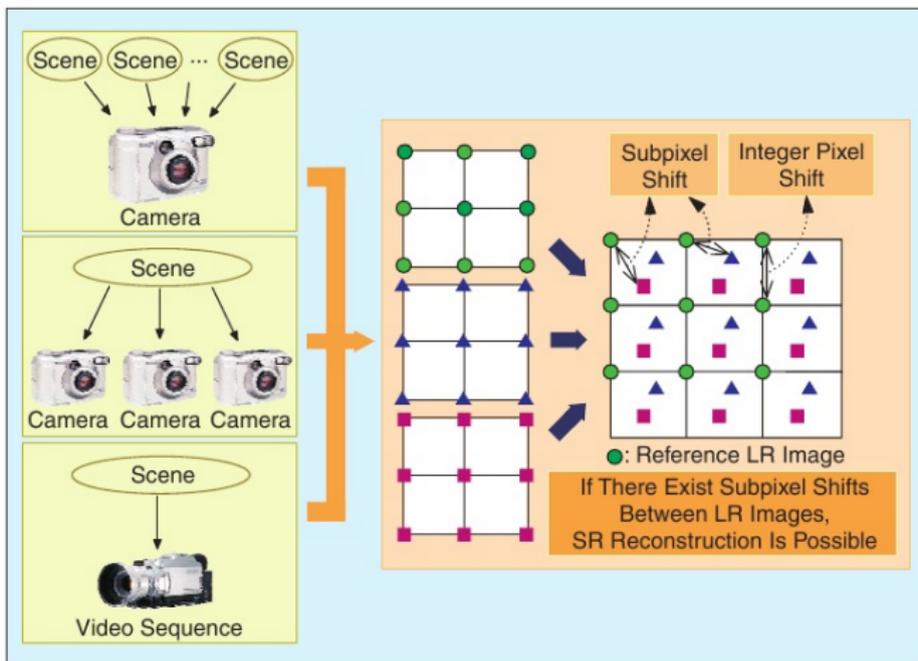
- 1 **Idee générale de la Super-résolution**
 - Introduction
 - Comment augmenter la résolution ?
- 2 **Super-resolution à plusieurs images**
 - Définition du problème
 - Approche par interpolation non uniforme
 - Approche par transformée de Fourier
 - Reconstruction SR régularisée
- 3 **Super-resolution à une seule image**
 - Approche générale
 - Ensemble d'entraînement
 - SR par réseaux de Markov

Multi-frame Super-résolution (MFSR)

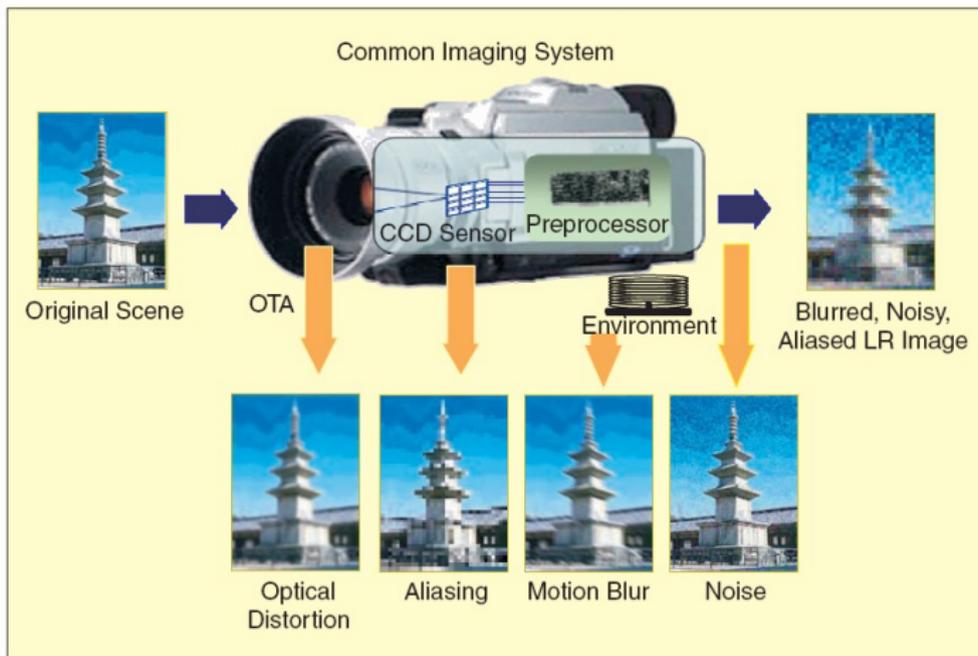
Comment peut-on obtenir une image HR à l'aide d'une séquence de LR ?

- On doit d'abord avoir fait l'acquisition de plusieurs LR représentant la même scène ;
 - Ces LR doivent donner un différent point de vue de la scène, et ce **avec un décalage sous-pixel**.
- Si les images ont un décalage unitaire (décalage de un, deux... pixels), alors **les images contiennent la même information**. SR ne sera pas possible.
- Si les images ont un décalage sous-pixel différent, alors SR est possible.

Décalage sous-pixel

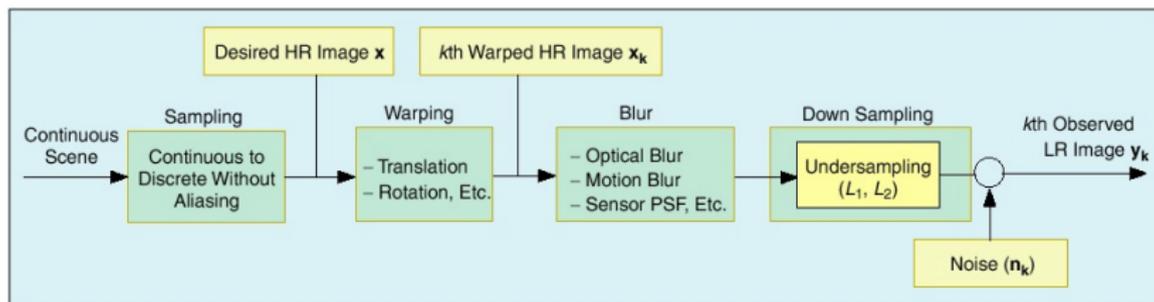


Système d'acquisition

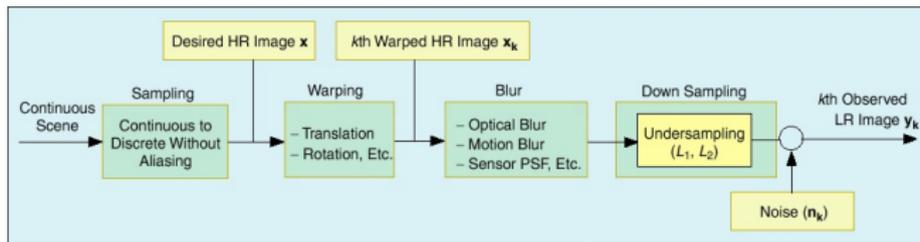


Modèle d'observation

Pour bien comprendre la SR, il faut bien modéliser le système d'observation afin de trouver un lien entre les images LR et l'image désirée HR.



Modèle d'observation



On peut alors représenter le modèle d'observation selon l'équation suivante, où on tiens compte des transformations du modèle d'observation précédent :

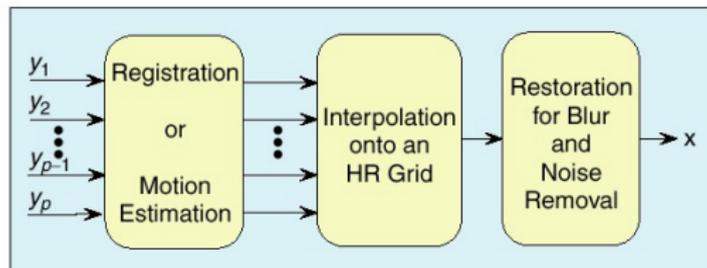
$$\begin{aligned}
 y_k &= D \cdot B_k \cdot M_k \quad x + n_k \quad \forall 1 \leq k \leq p \\
 &= W_k \quad x + n_k \quad \forall 1 \leq k \leq p
 \end{aligned} \tag{1}$$

- M_k est une matrice de warping (translation-rotation) ;
- B_k représente une matrice de flou ;
- D est une matrice de sous-échantillonnage ;
- n_k représente une matrice de bruit.

Approche par interpolation non uniforme

L'**approche par interpolation non uniforme** est l'approche la plus intuitive pour la reconstruction SR. Elle est composée de trois étapes :

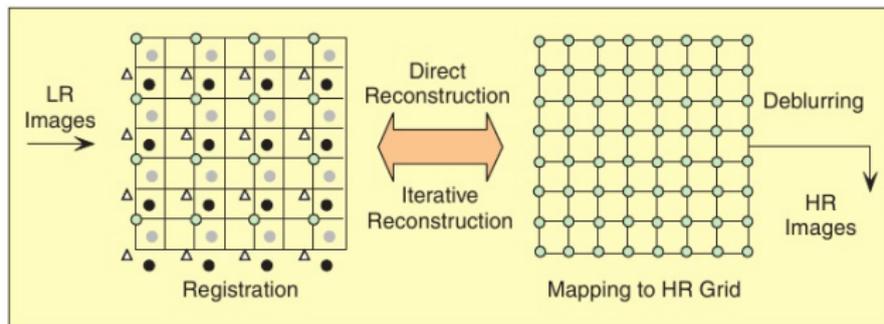
- 1 Recalage (ou alignement) ;
- 2 Interpolation sur une grille HR ;
- 3 Réduction de bruit et de flou.



Compensation du mouvement

Si on ne connaît pas le mouvement global entre les différents LR, on doit, par un algorithme de recalage ou d'estimation de mouvement, **trouver la transformation** qui permet de **réaligner les images LR de façon uniforme sur une grille HR**.

Si un faible mouvement non uniforme perturbe la scène, on doit faire une **interpolation non uniforme** sur les différentes images pour obtenir l'espacement uniforme requis :



Réduction de flou et de bruit

L'étape de réduction de flou et de bruit utilise les mêmes filtres utilisés dans le traitement d'image conventionnel.

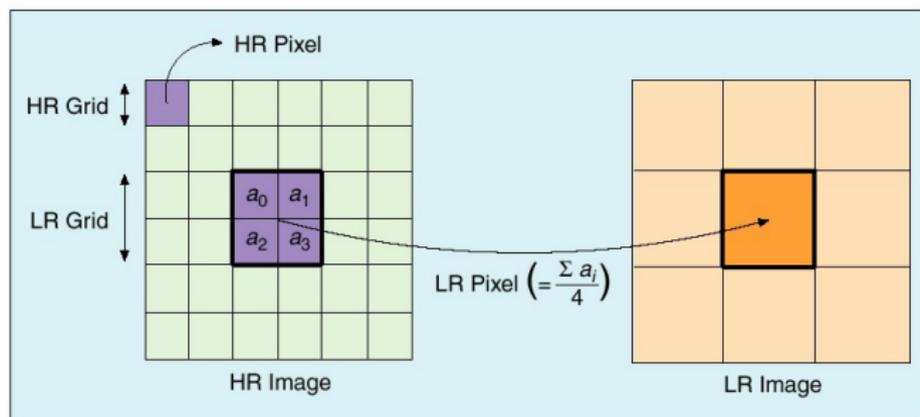
Dépendamment de notre connaissance *a priori* du **bruit** et de la **dispersion du flou**, on utilisera les algorithmes/filtres suivants :

- Cas sans bruit, flou connu
Filtre inverse
- Cas bruit connu, flou connu
Filtre Weiner
- Cas bruit et flou inconnu
Filtre par Expection-Maximisation

Réduction de flou et de bruit

On ne connaît ni le bruit, ni le flou... On peut l'approximer en observant comment le flou est créé dans le système.

Le flou créé par le système est modélisé comme étant l'effet d'un **filtre moyeneur**, qui cause une **perte de haute fréquence seulement** :



Réduction de flou et de bruit

La modélisation du flou sera donc de faible intensité dans la cas d'une scène statique. Dans le cas d'une scène en mouvement, nous parlerons alors de **flou de mouvement** qui exige un traitement plus avancé.

Nous utiliserons donc un **filtre Wiener**, qui suppose une connaissance *a priori* du flou et du bruit. Le filtre Wiener est basé sur le filtre inverse.

Réduction : Filtre inverse

Supposons que h est un filtre passe-bas d'écart-type faible ($\sigma = 0.06$ à 0.50), \hat{x} est l'image corrompue, x l'image sans corruption, on modélise le système de corruption de l'image ainsi :

$$\begin{aligned}\hat{x}(i, j) &= x(i, j) * h(i, j) && \text{Domaine spatial} \\ \hat{X}(u, v) &= X(u, v) \cdot H(u, v) && \text{Domaine fréquentiel}\end{aligned}$$

On peut aisément modéliser le **filtre inverse** dans le domaine de

Fourier $G(u, v) = \frac{1}{H(u, v)}$.

Réduction : Filtre inverse

Le problème est que toute source de bruit ne sera pas traitée, puisque nous n'avons pas modélisé notre système pour en tenir compte. Supposons que l'on souhaite intégrer un bruit additif n à notre système :

$$\hat{x}(i, j) = x(i, j) * h(i, j) + n(i, j)$$

Le résultat du filtre inverse $G(u, v) = \frac{1}{H(u, v)}$ sera :



Réduction : Filtre Wiener

Le filtre de Wiener résoud l'équation d'énergie donné par la minimisation de la différence au carré entre l'image corrompue et l'image non-corrompue :

$$E(i, j) = (x(i, j) - \hat{x}(i, j))^2$$

Dans le domaine de fourrier, le filtre $G(u, v)$ minimisant l'équation de l'erreur ci-dessus est donnée par :

$$\begin{aligned} G(u, v) &= \frac{H^*(u, v) \cdot (X(u, v)X^*(u, v))}{(X(u, v)X^*(u, v)) \cdot (H(u, v)H^*(u, v)) + N(u, v)N^*(u, v)} \\ &= \frac{H^*(u, v)}{|H(u, v)|^2 + \frac{|N(u, v)|^2}{|X(u, v)|^2}} \\ &= \frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + \frac{|N(u, v)|^2}{|X(u, v)|^2}} \end{aligned}$$

Réduction : Filtre Wiener

En pratique, on ne connaît ni l'image sans corruption, ni le bruit. Donc, on approxime le rapport avec un facteur K (par exemple, $K = 0.04$) :

$$G(u, v) = \frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + K} \quad (2)$$

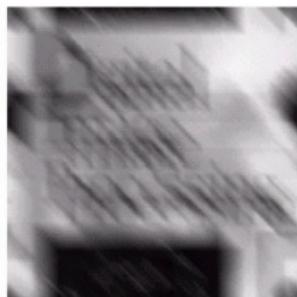
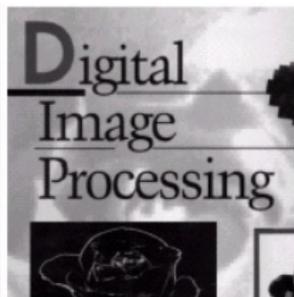


Image corrompue



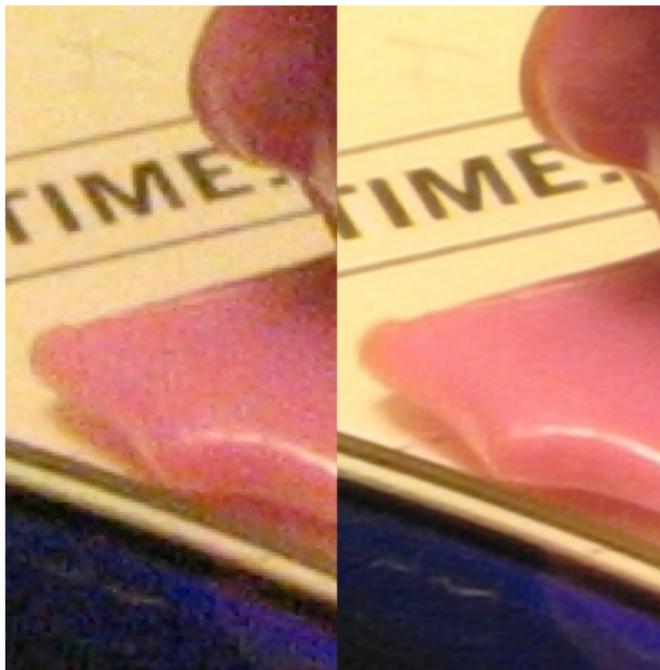
Inverse



Weiner

Résultat SR par approche uniforme

Suite aux opérations de recalage, d'interpolation et de réduction sur les LR :



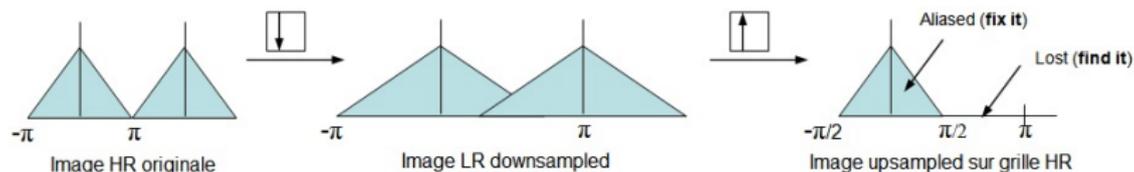
Plan de la présentation

- 1 **Idee générale de la Super-résolution**
 - Introduction
 - Comment augmenter la résolution ?
- 2 **Super-resolution à plusieurs images**
 - Définition du problème
 - Approche par interpolation non uniforme
 - **Approche par transformée de Fourier**
 - Reconstruction SR régularisée
- 3 **Super-resolution à une seule image**
 - Approche générale
 - Ensemble d'entraînement
 - SR par réseaux de Markov

Approche par transformée de Fourier

Tout comme l'approche non-uniforme, l'**approche par TF** utilise les même trois étapes : recalage, projection sur la grille HR et réduction. Cependant, la projection sur la grille utilise le domaine fréquentiel.

Étant donné que les LR sont des images sous-échantillonnées, on voudrait retrouver les valeurs de haute fréquence perdues. On a donc de l'aliasing dans nos images sous-échantillonnées LR.



Approche par transformée de Fourier

Projection sur grille HR - Algorithme de Papoulis-Gerchberg

La méthode de projection par Papoulis-Gerchberg assume deux choses :

- Quelques valeurs de la grille haute résolution sont connus ;
- Aucune image LR upsampled dans la grille HR n'a de contenu haute fréquence.

Approche par transformée de Fourier

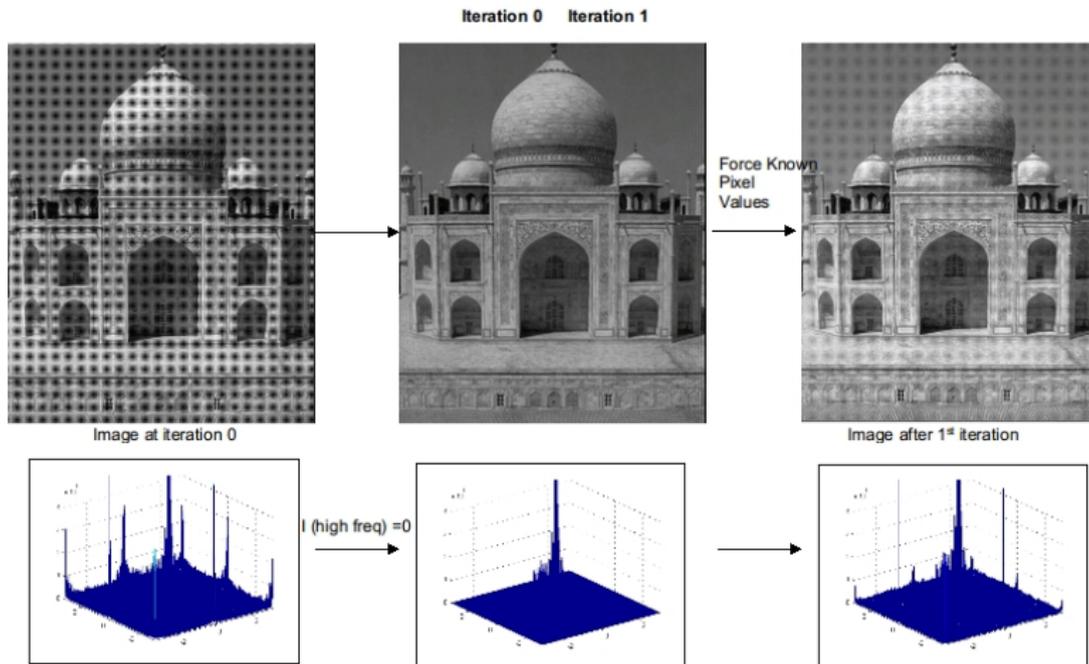
Projection sur grille HR - Algorithme de Papoulis-Gerchberg

On assume 1) que quelques pixels de la grille de haute résolution (HR) sont connus et 2) le contenu de haute résolution des LR est à zéro.

- 1 On situe chacune des LR par rapport aux autres (recalage)
- 2 On forme une grille HR où on ajoute les valeurs connues venant des LR (on arrondit au plus près)
- 3 On calcule la TF de la HR et on coupe les hautes fréquences (les trous de la grille auront une valeur, et les valeurs connues seront "affaiblies")
- 4 On "force" les pixels connus à reprendre leur valeur initiale
- 5 On recommence itérativement

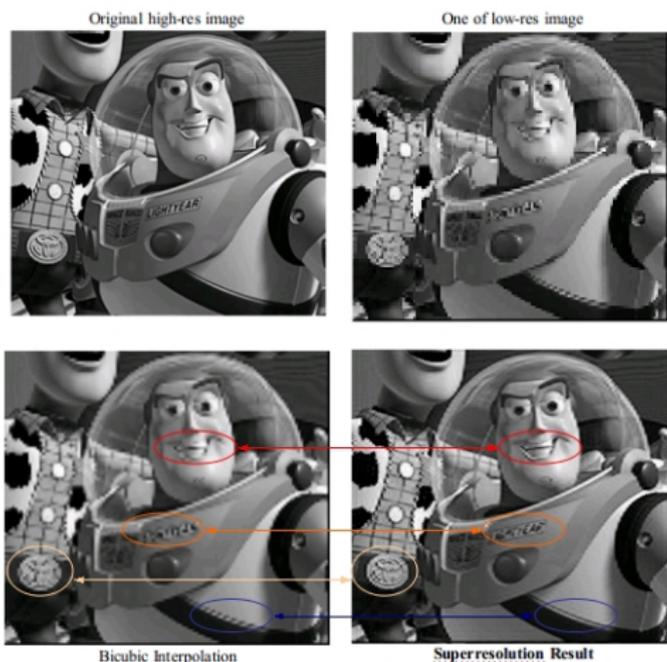
Approche par transformée de Fourier

Projection sur grille HR - Algorithme de Papoulis-Gerchberg



Approche par transformée de Fourier

Projection sur grille HR - Algorithme de Papoulis-Gerchberg



Approche par transformée de Fourier

Projection sur grille HR - Algorithme de Papoulis-Gerchberg

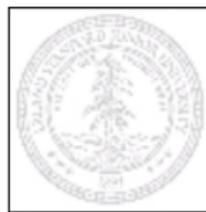
Cas où les LR ont un décalage d'un pixel :



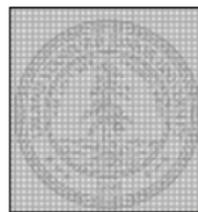
Original high-res image



One of low-res image



Bicubic Interpolation

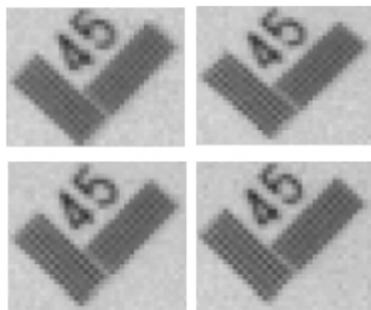


Superresolution result

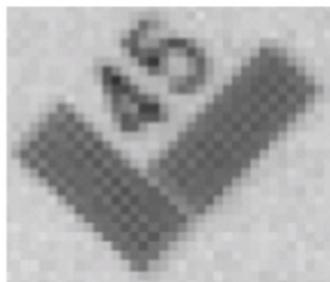
Approche par transformée de Fourier

Projection sur grille HR - Algorithme de Papoulis-Gerchberg

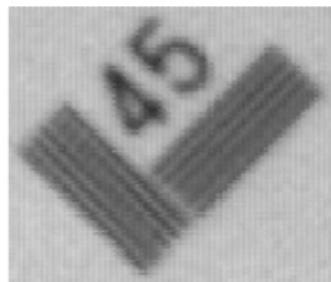
Cas où les images un décalage sous-pixel “répandu uniformément”



Original Low-res images



Bicubic Interpolation (1st image)

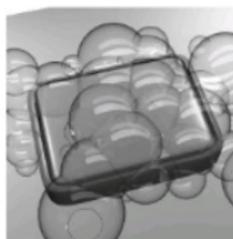


Superresolution Result

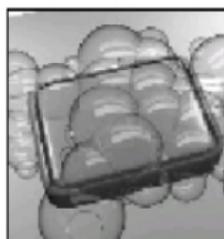
Approche par transformée de Fourier

Projection sur grille HR - Algorithme de Papoulis-Gerchberg

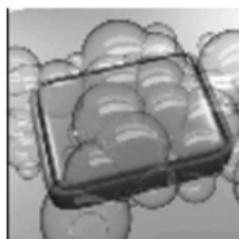
Cas où les images un décalage sous-pixel “répandu uniformément”



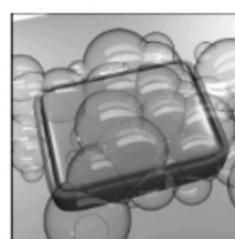
Original high-res image



One of low-res image



Bicubic Interpolation



Superresolution result

Plan de la présentation

- 1 **Idee générale de la Super-résolution**
 - Introduction
 - Comment augmenter la résolution ?
- 2 **Super-resolution à plusieurs images**
 - Définition du problème
 - Approche par interpolation non uniforme
 - Approche par transformée de Fourier
 - **Reconstruction SR régularisée**
- 3 **Super-resolution à une seule image**
 - Approche générale
 - Ensemble d'entraînement
 - SR par réseaux de Markov

Reconstruction SR régularisée

Avec une bonne quantité d'images LR, on peut résoudre l'équation du système d'observation :

$$\begin{aligned} y_k &= D \cdot B_k \cdot M_k \quad x + n_k \quad \forall 1 \leq k \leq p \\ &= W_k \quad x + n_k \quad \forall 1 \leq k \leq p \end{aligned}$$

En réalité, il est difficile d'avoir un nombre suffisant de LR, car le système est mal posé. On utilise alors une **regression linéaire** pour stabiliser l'inversion de problème. On tentera alors d'approcher la solution de façon itération par des techniques **statistiques**.

Reconstruction SR régularisée

Maximisation a posteriori (MAP)

On cherche à savoir quelle est la meilleure image HR X connaissant les p images Y_k . D'un point de vue statistique, on cherche donc X qui maximisera la probabilité conditionnelle $P(x|y_1 \dots y_n)$:

$$E(X) = \arg \max P(X|Y_1 \dots Y_n)$$

Reconstruction SR régularisée

Maximisation a posteriori (MAP)

Par la loi de Bayes :

$$\begin{aligned}
 E(X) &= \arg \max && P(X|Y_1 \dots Y_n) \\
 &\simeq \arg \max && \log P(X|Y_1 \dots Y_n) \\
 &= \arg \max && \log(P(Y_1 \dots Y_n|X)) + \log(P(X)) \\
 &= \arg \max && \log\left(e^{-\frac{1}{2\sigma^2}(\sum_{k=1}^p \|Y_k - W_k \cdot X\|^2)}\right) + \log\left(\frac{1}{Z} e^{-\lambda A(X)}\right) \\
 &= \arg \min && \sum_{k=1}^p \|Y_k - W_k \cdot X\|^2 + \lambda A(X)
 \end{aligned} \tag{3}$$

Où $P(y_1 \dots y_n|x)$ la distribution (influence) de chacune des image y_k sur X et $P(X)$ est un *a priori* de l'image résultante. $A(X)$ est une fonction dépendant du contenu de l'image résultante (*a posteriori*)

→ L'avantage d'un modèle Bayésien réside dans représentation d'un *a priori* de préservation de contour.

Reconstruction SR régularisée

Maximum de vraisemblance

Supposons $A(X)$ uniforme (ou nul). Le **maximum de vraisemblance** (le terme de gauche) sera alors le seul auteur de la réponse optimale pour X

$$E(X) = \arg \min \sum_{k=1}^p \|Y_k - W_k \cdot X\|^2 \quad (4)$$

En dérivant le terme, on obtient :

$$\frac{\delta E(X)}{X} = \sum_{k=1}^p (W_k^T W_k)^{-1} W_k X \quad (5)$$

Où $(W_k^T W_k)^{-1}$ doit être inversible, ce qui est rarement le cas.

Reconstruction SR régularisée

Maximum de vraisemblance - IBP

Pour pallier au problème, on peut utiliser une méthode appelée *Iterative Back projection*, qui consiste à produire une image basse résolution simulée \hat{Y}_k à partir de X^t courant :

$$X^{t+1} = X^t + \alpha \left(\sum_{k=1}^p \hat{Y}_k - Y_k \right) \quad (6)$$

Cette méthode est très semblable à Papoulis (domaine fréquentiel).

Reconstruction SR régularisée

Approche variationnelle

Supposons maintenant que $A(X)$ soit une méthode dépendante du gradient de l'image.

Soit W_k la matrice qui combine le sous-échantillonnage, le mouvement et le bruit de la k image Y_k . On intègre alors un terme de régularisation basé sur les hautes fréquences, soit le gradient de l'image X .

$$E(x) = \sum_{k=1}^p \|Y_k - W_k \cdot X\|^2 + \lambda \|\nabla x\|^2 \quad (7)$$

λ est un terme de régularisation. Plus λ est élevé, plus le résultat sera lissé (utile pour peu de LR ou beaucoup de bruit).

Reconstruction SR régularisée

Approche variationnelle (TV)

Par Euler-Lagrange, on peut trouver X qui minimise la fonction de coût (Eq.7) de façon itérative :

$$\frac{\delta E(X)}{X} = \sum_{k=1}^p W_k^T \cdot (W_k \cdot X - Y_k) - \Delta X \quad (8)$$

Par la descente de gradient, on trouve alors la forme itérative suivante :

$$X^{t+1} = X^t + \alpha \left(\sum_{k=1}^p W_k^T \cdot (W_k \cdot X^t - Y_k) - \lambda \Delta X^t \right) \quad (9)$$

Reconstruction SR régularisée

Approche variationnelle (TV)

L'algorithme procède ainsi :

- 1 On choisit une image Y_k de départ, Y_0 ;
- 2 On estime le déplacement (flux optique) de toutes les Y_i par rapport à Y_0 ;
- 3 On interpole les mouvements à la résolution de X . On ajoute du bruit (flou) pour donner W_k ;
- 4 On initialise X^0 en mettant tous les pixels à 0 ;
- 5 Itérativement pour T itérations :
 - a) Pour toutes les k images Y_k :
 - 1) On bruite, enlève le mouvement et sous-échantillonne X^k à l'aide de W_k ;
 - 2) On calcule le terme de la somme de Eq.9
 - b) On projette sur l'itération suivante (Eq.9)

Reconstruction SR régularisée

Approche variationnelle - Norme L1 (TV-L1)

Parfois, en utilisant une norme L1, on peut préserver les détails de façon plus précise qu'avec une norme L2. C'est le cas pour la Super-Résolution. Les équations deviennent :

$$E(x) = \sum_{k=1}^p |Y_k - W_k \cdot X|^2 + \lambda |\nabla x| \quad (10)$$

Et par Euler-Lagrange :

$$\frac{\delta E(X)}{X} = \sum_{k=1}^p W_k^T \cdot \frac{W_k \cdot X - Y_k}{|W_k \cdot X - Y_k|} - \lambda \operatorname{div} \left(\frac{\nabla X}{|\nabla X|} \right) \quad (11)$$

Reconstruction SR régularisée

Approche variationnelle



L² superresolution



L¹ superresolution



input



L² superresolution



L¹ superresolution

Reconstruction SR régularisée

Approche stochastique (MAP)



Image HR - proche voisin



Image HR - SR (CLS petit alpha)



Image HR - SR (CLS gros alpha)



Image HR - SR (MAP)

Autres approches

POCS (Projection onto Convex Sets)

Semblable à Papoulis

Motionless SR reconstruction

Qui utilise les différences de focus plutôt que les mouvements subpixels.

Adaptative filtering

Qui intègre l'information temporelle dans le système d'observation.

Démo : <https://www.youtube.com/watch?v=9G69WcHqRfo>

Plan de la présentation

- 1 Idée générale de la Super-résolution
 - Introduction
 - Comment augmenter la résolution ?
- 2 Super-resolution à plusieurs images
 - Définition du problème
 - Approche par interpolation non uniforme
 - Approche par transformée de Fourier
 - Reconstruction SR régularisée
- 3 Super-resolution à une seule image
 - Approche générale
 - Ensemble d'entraînement
 - SR par réseaux de Markov

Plan de la présentation

- 1 **Idee générale de la Super-résolution**
 - Introduction
 - Comment augmenter la résolution ?
- 2 **Super-resolution à plusieurs images**
 - Définition du problème
 - Approche par interpolation non uniforme
 - Approche par transformée de Fourier
 - Reconstruction SR régularisée
- 3 **Super-resolution à une seule image**
 - Approche générale
 - Ensemble d'entraînement
 - SR par réseaux de Markov

Introduction

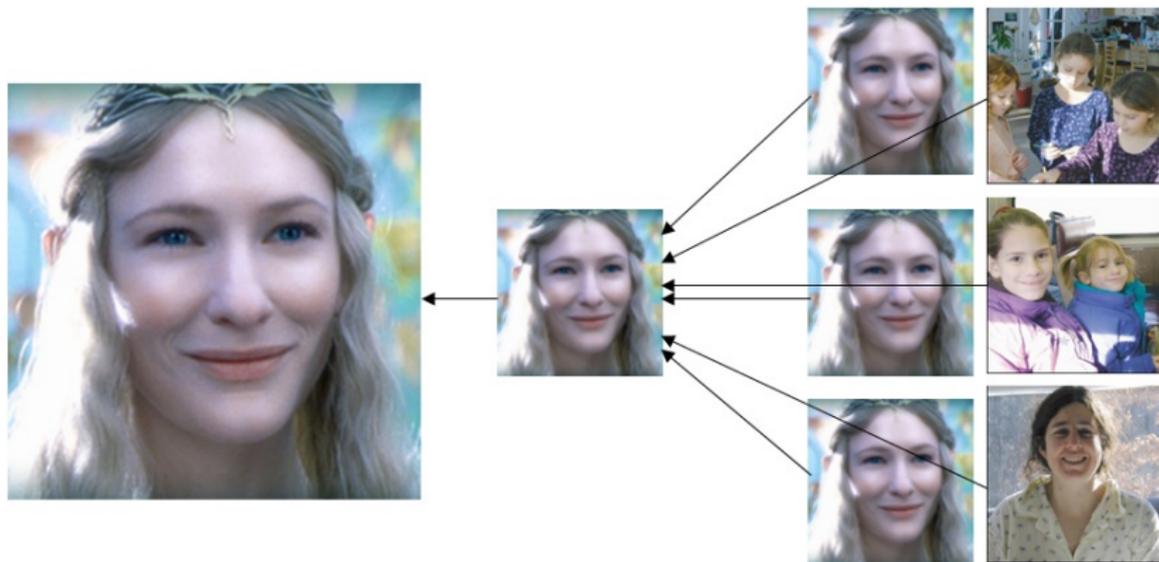
Traditionnellement, on utilise, pour un frame, les techniques de rehaussement de résolution suivantes :

- Basé sur le flou : Filtre de Weiner, filtre median, . . .
- Basé sur l'interpolation : Plus proche voisin, bilinéaire, bicubique, . . .
- Basé sur l'affutage : Sharpening filter (amplification de détail sans amplifier le bruit), . . .

La **SR à un seul frame** estime les détails HR manquants **qui ne sont pas présents dans l'image**, ce qui n'est pas possible avec un filtre basé sur l'affutage.

Ensemble d'entraînement

Bien que cela puisse paraître contre-intuitif, la SR à un frame n'utilise pas seulement le frame LR. Il utilise un ensemble d'entraînement pour apprendre les détails HR à basse résolution.



Ensemble d'entraînement

Il utilise ensuite ces relations acquises en phase d'apprentissage pour prédire les détails HR dans d'autres images (une seule image à la fois).

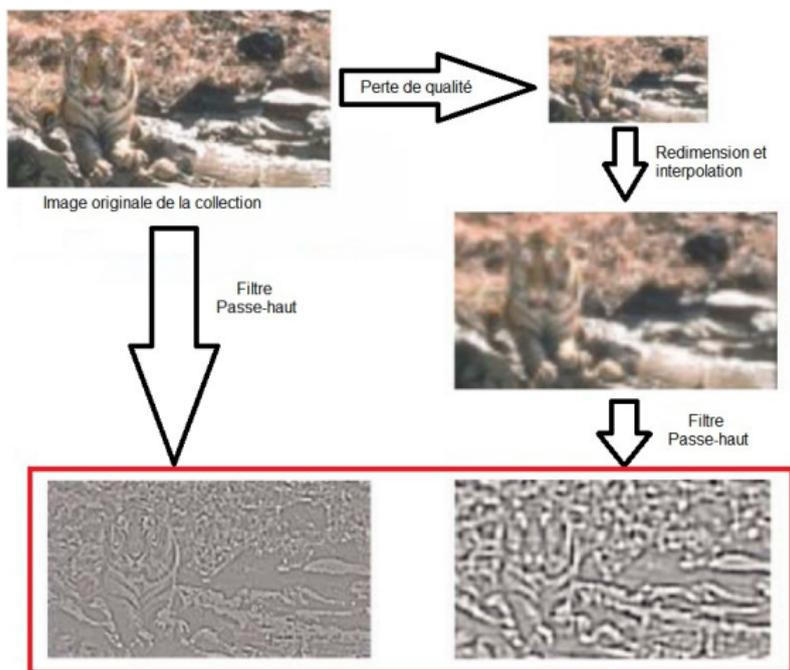
Nous verrons l'algorithme utilisant les **réseaux de Markov**.

Ensemble d'entraînement

Pour bâtir notre ensemble d'entraînement, nous utiliserons le concept de **patch en overlap**. D'abord, on effectue les étapes suivantes :

- 1 On prend une collection d'images HR ayant un petit lien sémantique avec notre image LR (par exemples, des tigres et des chat pour notre image LR de tigre)
- 2 Pour toutes les images HR de la collection, on dégrade la qualité de l'image (sous-échantillonnage de facteur 4 et flou global).
- 3 Redimensionner en HR en interpolant (cubic spline), ce qui causera la perte des données HR.
- 4 Filtre passe-haut et normalisation de l'intensité pour l'image interpolée et l'image HR originale.

Ensemble d'entraînement



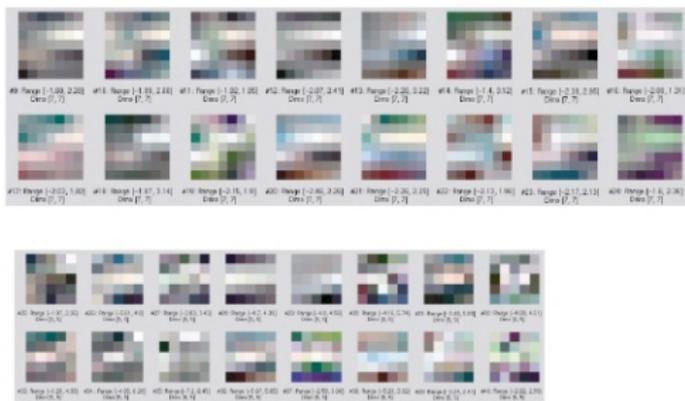
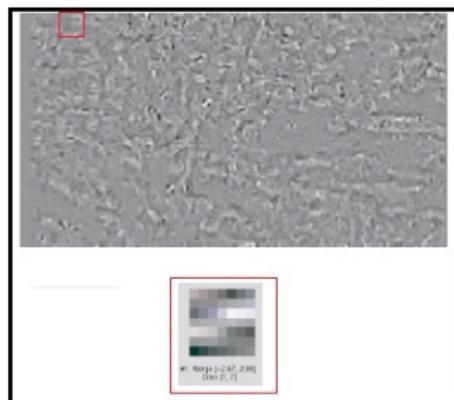
Ensemble d'entraînement

On décrit alors à la fois l'image LR (x) et HR (y) obtenue précédemment selon le système de patch. Soit P la distance entre chaque acquisition de patch, $N \times N$ la dimension de la patch LR et $M \times M$ la dimension de la patch HR :



Ensemble d'entraînement

Pour une image LR en entrée que l'on veut améliorer, on voudrait *intuitivement* séparé la LR en patches et, pour chaque patches, **rechercher dans la base de donnée de patches LR le meilleur candidat pour prendre sa patche HR appairée**. Mais cette approche ne fonctionne pas, car le contenu LR local ne suffit pas :

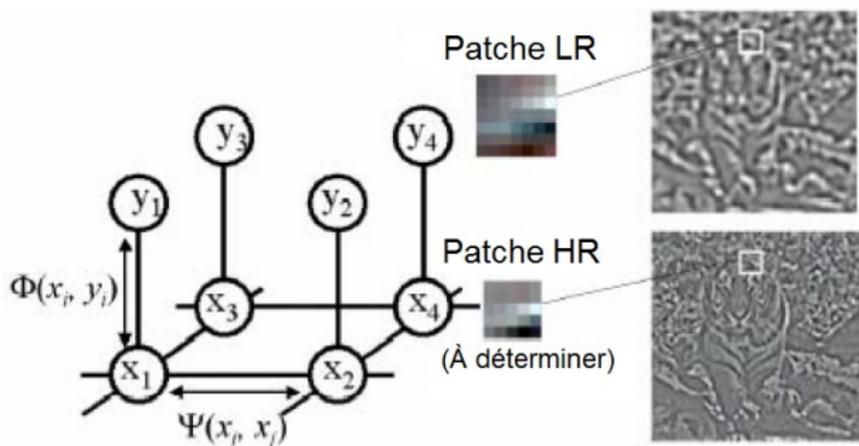


Plan de la présentation

- 1 **Idee générale de la Super-résolution**
 - Introduction
 - Comment augmenter la résolution ?
- 2 **Super-resolution à plusieurs images**
 - Définition du problème
 - Approche par interpolation non uniforme
 - Approche par transformée de Fourier
 - Reconstruction SR régularisée
- 3 **Super-resolution à une seule image**
 - Approche générale
 - Ensemble d'entraînement
 - SR par réseaux de Markov

Réseaux de Markov

Dans un **réseau de Markov**, les cercles représentent les noeuds du réseau, et les lignes sont les **dépendances statistiques** entre les noeuds. Les noeuds y représentent les patches LR de l'image d'entrée, et x représente les patches HR recherchées.



ψ représente le lien entre les patches désirées avoisinantes de l'image et ϕ représente la relation entre la patches d'entrée et la patche HR désirée.

Réseaux de Markov

Pour chaque noeud y_i (patche LR de l'image d'entrée), on cherche parmi la banque de patches d'entraînement LR les 16 meilleurs candidats. Les patches HR associées à ces candidats forment les possibles valeurs que peuvent prendre x_i .

Mais choisir la bonne patche, puisque les 16 patches candidates LR sont identiques ?
Le réseau de Markov permet justement de définir, par ψ , un lien entre patches voisins.

Pour le réseau, **la probabilité d'un choix de patches HR pour tous les noeuds sachant les patches d'entrée LR** est le produit de *tous* les liens inter-voisins ψ et des liens entre l'entrée et la sortie ϕ :

$$P(x|y) = \frac{1}{Z} \cdot \prod_{(i,j)} \psi_{ij}(x_i, x_j) \cdot \prod_i \phi_i(x_i, y_j) \quad (12)$$

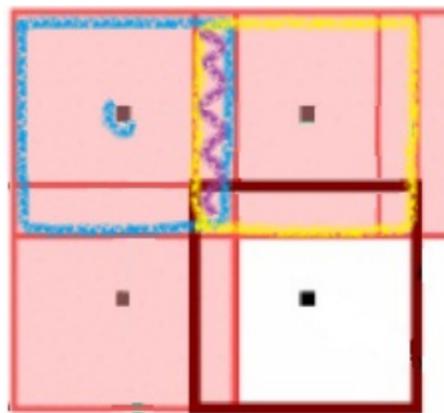
Réseaux de Markov

Comment définir ψ ?

On établit une relation de distance entre les patches voisins. Comme **on s'arrange pour avoir un overlay de 1 ou 2 pixels entre les patches HR**, on définira la distance $d_{ij}(x_i, x_j)$ comme étant une relation de différence d'intensité de chaque pixel **dans la zone commune** :

$$\psi_{ij}(x_i, x_j) = \exp\left(-\frac{d_{ij}(x_i, x_j)}{2\sigma^2}\right) \quad (13)$$

Où σ est un facteur de bruit.

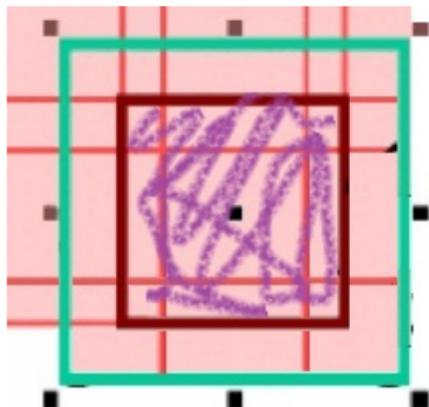


Réseaux de Markov

Comment définir ϕ ?

ϕ utilise le même principe que ψ , c'est-à-dire une relation de distance euclidienne entre les pixels de la zone commune :

$$\phi_{ij}(x_i, y_i) = \exp\left(-\frac{d_i(x_i, y_i)}{2\sigma^2}\right) \quad (14)$$

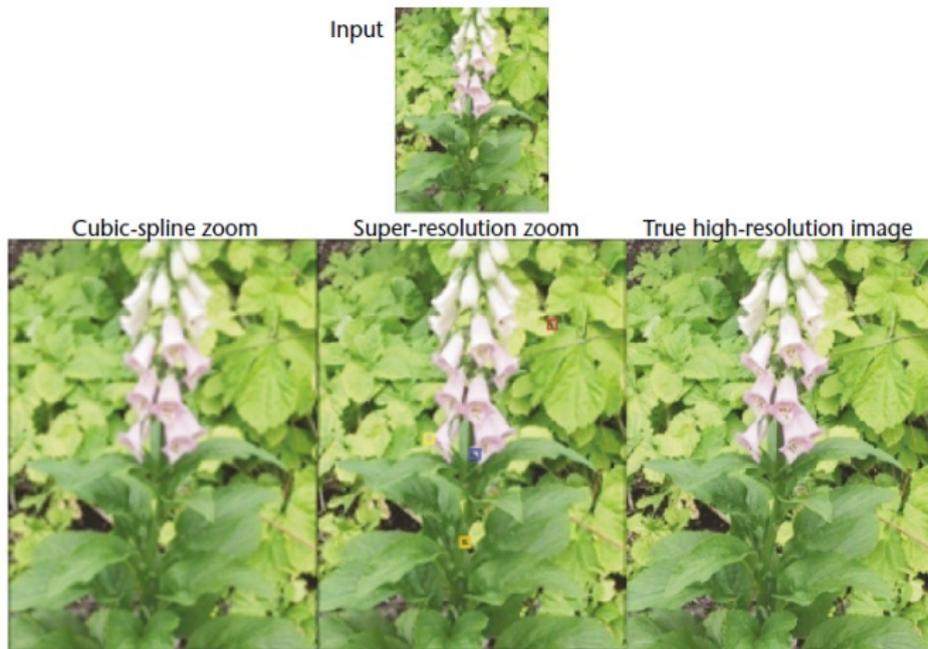


Algorithme à une passe

Une variante des réseaux de Markov, l'**algorithme à une passe**, permet d'obtenir plus rapidement la SR sans avoir trop de perte de la qualité.

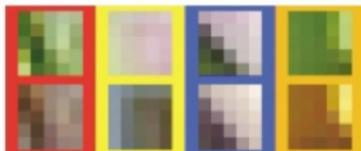
Cette variante n'utilise, dans le calcul de la probabilité (Eq.12), que les patches x_i précédemment calculés. C'est donc une sorte de *balayage* de l'Image d'entrée patche LR par patche LR.

Résultats



Résultats

Source image patches



Best-match patches
from training data



Résultats



angitiregairgberriedu,or'cu
anelvacatedarulingbythefe
ystem,andsentitdowntoanew
finedastandardforweighing
eraproduct-bundlingdecisi
softsayssthatthenewfeature:
andpersonalidentification:
osoft'sview,butusersandthi
adedwithconsumerinnovatio
hePCindustryislookingforw



Conclusion des SR multi-frame et single-frame

Améliorations ?

- Améliorer la robustesse des algorithmes de recalage :
 - Algorithme minimisant les erreurs ;
 - Des images LR avec beaucoup d'erreurs de recalages devraient moins contribuer à l'estimé de la grille HR.
- Méthode pour détecter automatique le flou dans l'image ;
- Améliorer la vitesse d'exécution des algorithmes (*Graphcut*)