



*UE Vision, Réalité Augmentée et Applications*

# **Matière : Vision**

Partie III

(Classe inversée)

Sylvie CHAMBON

[schambon@toulouse-inp.fr](mailto:schambon@toulouse-inp.fr)

15 octobre 2025



# Plan - Partie mise en correspondance

## Introduction

- Éléments à déterminer

- Approches globales

- Approches locales

- Approches locales/globales

- Mise en correspondance et segmentation

## Mesures de similarité locale

- Définition et difficultés

- Famille de mesures



## Avant de commencer : Question cours précédent

### Quelles différences entre Harris et SUSAN ?

- **Ce qui les rassemble :**
  1. Étude du voisinage / région
  2. Aucune invariance
- **Ce qui les distingue :**
  1. Harris = point le plus différent de ses voisins  
 $\neq$  SUSAN = centre d'une région qui se distingue de ses voisins
  2. Harris = coins, intersection des contours, dérivées  
 $\neq$  SUSAN = information photométrique uniquement
- **Qui choisir ?**



## Points importants

- Savoir identifier les difficultés de la mise en correspondance
- Savoir distinguer approche locale/globale d'appariement
- Savoir qu'il existe différentes mesures de similarité et leurs avantages/inconvénients
- Savoir que l'on peut appliquer des contraintes et qu'elles sont souvent liées aux disparités/correspondances trouvées
- Comprendre le descripteur SIFT et sa force
- Connaître la méthode KLT et ses principes



# Plan

## Introduction

- Éléments à déterminer

- Approches globales

- Approches locales

- Approches locales/globales

- Mise en correspondance et segmentation

## Mesures de similarité locale

- Définition et difficultés

- Famille de mesures



# Définitions

1. Trouver les entités homologues, c'est-à-dire, les éléments qui se correspondent entre deux images
2. **Propriétés attendues des points d'intérêt pour la mise en correspondance**
  - 2.1 Permettre une mise en correspondance fiable
  - 2.2 Respecter un critère de répétabilité

**Pour toute cette partie, on suppose des images rectifiées !**  
**Les approches peuvent s'appliquer à du suivi temporel**



# Éléments à déterminer : Primitives et attributs

- *Pixels de l'image*
  - Tous les pixels de l'image (**mise en correspondance dense**)
  - Ou seulement une partie / points d'intérêt (**mise en correspondance épars**)
  - Attributs : niveaux de gris ou composantes couleur



# Éléments à déterminer : Primitives et attributs

- *Pixels de l'image*
  - Tous les pixels de l'image (**mise en correspondance dense**)
  - Ou seulement une partie / points d'intérêt (**mise en correspondance épars**)
  - Attributs : niveaux de gris ou composantes couleur
- *Primitives structurées ou feature-based matching*
  - Segments : position, orientation, longueur, niveaux de gris, contraste, relations avec les segments adjacents
  - Contours : niveaux de gris, composantes couleur ou gradients
  - Régions : niveaux de gris ou couleurs de la région, la variance des niveaux de gris ou des moments etc

## Éléments à déterminer :

### Coût global de mise en correspondance

$$E(I_1, I_2) = \sum_{\mathbf{p}_1 \in \mathcal{S}} \left( \underbrace{E_{sim}(\mathbf{p}_1, \mathbf{p}_2)}_{\text{Ressemblance photométrique}(I_1(\mathbf{p}_1))} + \underbrace{E_{cont}(\mathbf{p}_1)}_{\text{Respect de contraintes (ordre, symétrie)}} \right)$$

avec  $\mathbf{p}_2 = \mathbf{p}_1 + d(\mathbf{p}_1)$

$d(\mathbf{p}_1)$  = vecteur de disparité = déplacement entre les deux images  
 $\mathcal{S}$ , le support = l'ensemble des pixels pour lesquels on recherche un correspondant

Si  $\mathcal{S}$  = l'image entière alors **Mise en correspondance dense**

Si  $\mathcal{S}$  = sous ensemble de points alors **Mise en correspondance éparse ou partielle**



## Éléments à déterminer :

# Coût global de mise en correspondance

$\mathcal{A}$  = ensemble d'appariements possibles

$$\mathcal{A} = \operatorname{argmin} E(I_1, I_2)$$

- Zones d'agrégation = voisinages considérés
- Méthode d'optimisation
- Affinement des résultats



## Coût de correspondance

$$E_{\text{sim}}(\mathbf{p}_1, \mathbf{p}_2) = \sum_{\mathbf{p}_1 \in \mathcal{S}} E_{\text{local}}(\mathbf{p}_1, \mathbf{p}_2) \quad (1)$$

avec  $\mathbf{p}_2 = \mathbf{p}_1 + d(\mathbf{p}_1)$ .

$$E_{\text{local}}(\mathbf{p}_1, \mathbf{p}_2) = \sum_{\substack{\mathbf{p}'_1 \in \text{ZA}(\mathbf{p}_1) \\ \mathbf{p}'_2 \in \text{ZA}(\mathbf{p}_2)}} E_{\text{dissimilarité}}(\mathbf{p}'_1, \mathbf{p}'_2), \quad (2)$$

- $\text{ZA}(\mathbf{p})$  : zone d'agrégation considérée
- $E_{\text{dissimilarité}}$  : évalue à quel point deux pixels ne se ressemblent pas



## Coût de contrainte

$$E_{cont}(\mathbf{p}_1) = \sum_{c=0}^{N_c-1} E_{voisinage}^c(\mathbf{p}_1). \quad (3)$$

$$E_{voisinage}^c(\mathbf{p}_1) = \sum_{\mathbf{p}'_1 \in ZAC^c(\mathbf{p}_1)} E_{lissage}^c(\mathbf{p}_1, \mathbf{p}'_1). \quad (4)$$

- $ZAC^c$  : zone d'agrégation considérée
- $E_{lissage}^c$  : comparaison des disparités associées aux deux pixels considérés
- Comparaison ZA/ZAC souvent différentes



## Coût global

$$E(I_1, I_2) = \sum_{\mathbf{p}_1 \in \mathcal{S}} \left( (1 - \lambda) \underbrace{\sum_{\substack{\mathbf{p}'_1 \in \text{ZA}(\mathbf{p}_1) \\ \mathbf{p}_2 \in \text{ZA}(\mathbf{p}_2)}} E_{\text{dissimilarité}}(\mathbf{p}'_1, \mathbf{p}'_2)}_{\text{coût local}} + \lambda \underbrace{\sum_{c=0}^{N_c-1} \sum_{\mathbf{p}'_1 \in \text{ZAC}^c(\mathbf{p}_1)} E_{\text{lissage}}^c(\mathbf{p}_1, \mathbf{p}'_1)}_{\text{coût du voisinage}} \right) \quad (5)$$

avec  $\mathbf{p}_2 = \mathbf{p}_1 + d(\mathbf{p}_1)$  et  $\mathbf{p}'_2 = \mathbf{p}'_1 + d(\mathbf{p}'_1)$



## Coût global

- $\lambda$  : Souvent  $\lambda = 0.5$  (peu d'études dans la littérature sur ce choix)
- $E_{\text{dissimilarité}}$
- $E_{\text{lissage}}^c$
- ZA : un seul pixel (le pixel étudié/globale) ou un voisinage (local)
- ZAC<sup>c</sup> : un seul pixel du voisinage ou un ensemble
- S : le pixel considéré ou l'ensemble des pixels dans l'image



# Description des approches globales

- **Algorithme**

1. Estimer un coût de correspondance initiale liée à une première approximation des disparités ;
2. Mettre à jour  $C$  grâce à la méthode d'optimisation choisie


- **Optimisation**

- Recherche exhaustive trop coûteuse
- Méthodes utilisées : programmation dynamique, coupure de graphes, propagation de croyance, algorithmes génétiques ...
- Pour (1), deux solutions
  - Appariement dense : optimisation = mise à jour des affectations  
Coûteux si solution initiale bruitée
  - Appariement épars mais fiable : optimisation = propagation des correspondances  
Plus rapide mais impact plus important des erreurs sur les correspondances initiales




## Principe des approches locales

1. Fenêtre de corrélation  $\mathbf{f}_l$
2. Zone de recherche  $Z_d$
3. Mesure de corrélation Mes



$j$

$i$




$j$




## Principe des approches locales

1. Fenêtre de corrélation  $\mathbf{f}_l$
2. Zone de recherche  $Z_d$
3. Mesure de corrélation Mes



$j$

$i$



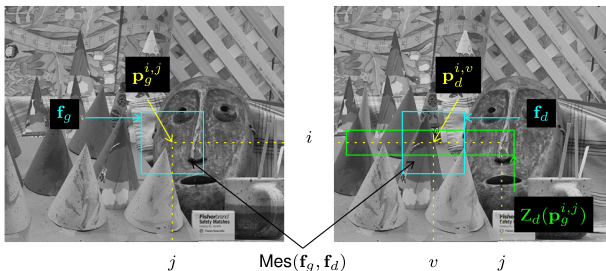
$v$

$j$



## Principe des approches locales

1. Fenêtre de corrélation  $\mathbf{f}_l$
2. Zone de recherche  $Z_d$
3. Mesure de corrélation Mes





# Algorithme

## Données

Images à traiter :  $I_1$  et  $I_2$

Point d'intérêt :  $\mathbf{p}_1 = (x_1, y_1)$

Zone de recherche du point d'intérêt correspondant de

$\mathbf{p}_1$  :  $ROI(\mathbf{p}_1)$

Mesure de similarité :  $m(p_1, p_2)$

## Algorithme de mise en correspondance

1. Pour chaque  $\mathbf{p}_1 \in I_1$  faire

Estimer  $\mathbf{p}_2 \in I_2$  tel que

$$\mathbf{p}_2 = \operatorname{argmin}_{\mathbf{p} \in ROI(\mathbf{p}_1)} m(\mathbf{p}_1, \mathbf{p})$$

2. Ajout de contrainte (seuil, bidirectionnelle)



## 2 Applications possibles

1. Points d'intérêt vers image
2. Points d'intérêt vers points d'intérêt



# Approches locales versus globales

- Méthode d'optimisation
  - Globale : prise en compte de toutes les correspondances à optimiser ensemble
  - Locale : de type **winner takes all** pour chaque point individuellement



## Avantages des approches locales

- Mise en œuvre simple et rapide
- Peu coûteuse en temps de calcul (moins coûteuse que les méthodes globales)
- Dans de nombreux travaux, efficacité démontrée !



## Avantages des approches globales

- Moins de propagation d'erreur, liée au lissage
- Obtiennent de meilleures performances à grande échelle
- Introduction de contraintes plus complexes (régions, graphes, labels)



## Inconvénients (liées aux deux approches)

- Certaines situations rendent difficile la mise en correspondance :
  - Bruits
  - Zones non texturées
  - Textures répétitives
  - Changements de luminosité
  - Occultations
  - Déformation des objets
  - Changement d'échelle
  - Points de vue trop éloignés
  - Résultats erronés car certaines caractéristiques globales de l'image ne sont pas prises en compte (comme une sursegmentation)



## Conclusion local versus global: quels choix

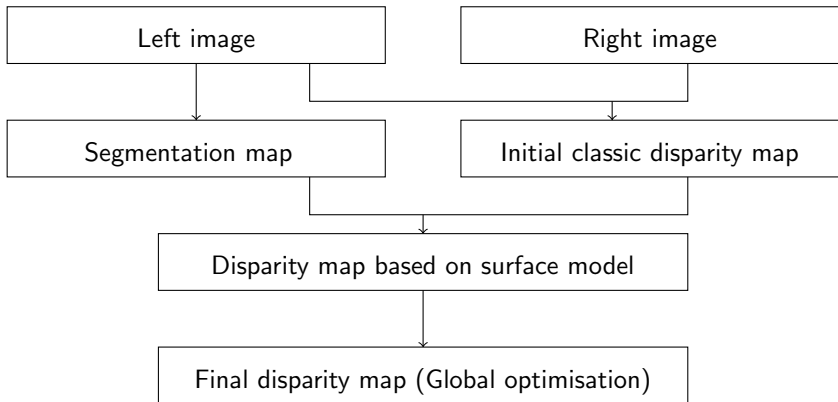
- Locale ou globale ?
- Quelle mesure de similarité ?



# Mise en correspondance et segmentation

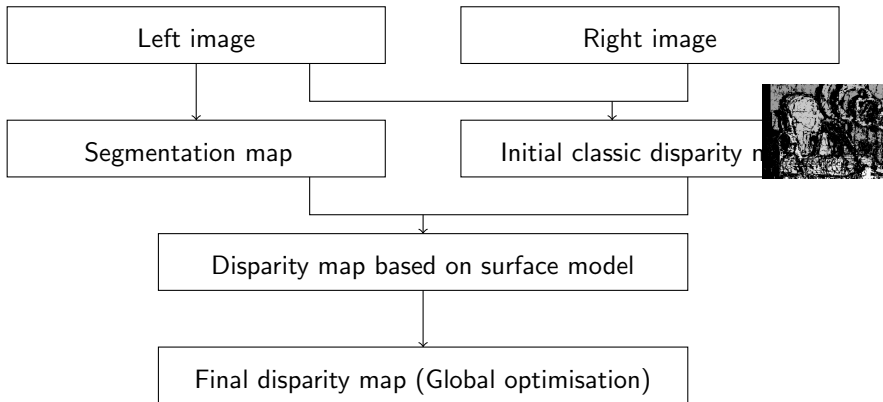


## Mise en correspondance et segmentation



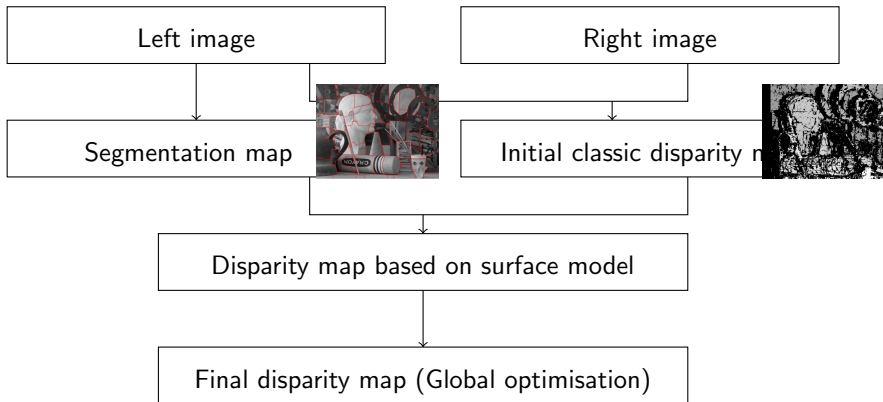


## Mise en correspondance et segmentation



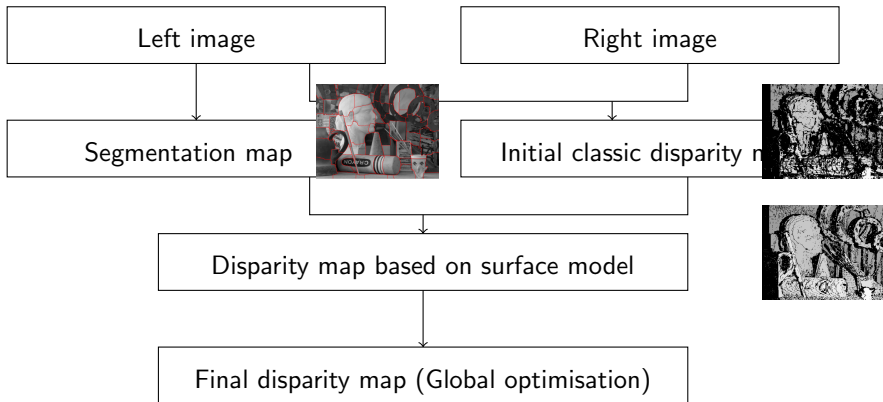


## Mise en correspondance et segmentation



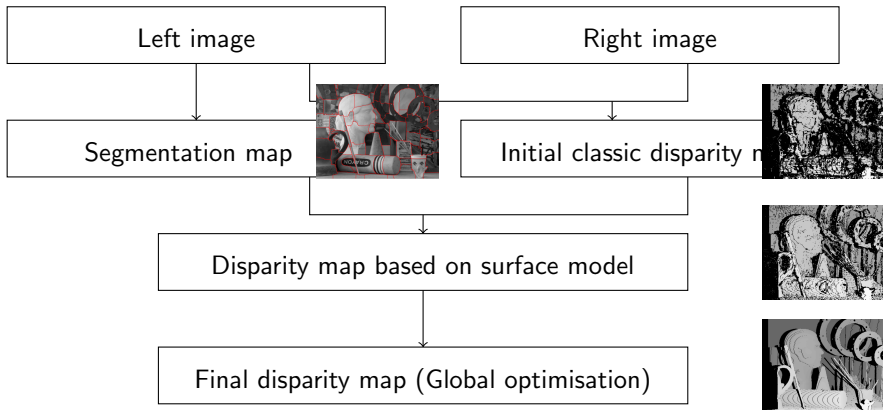


## Mise en correspondance et segmentation





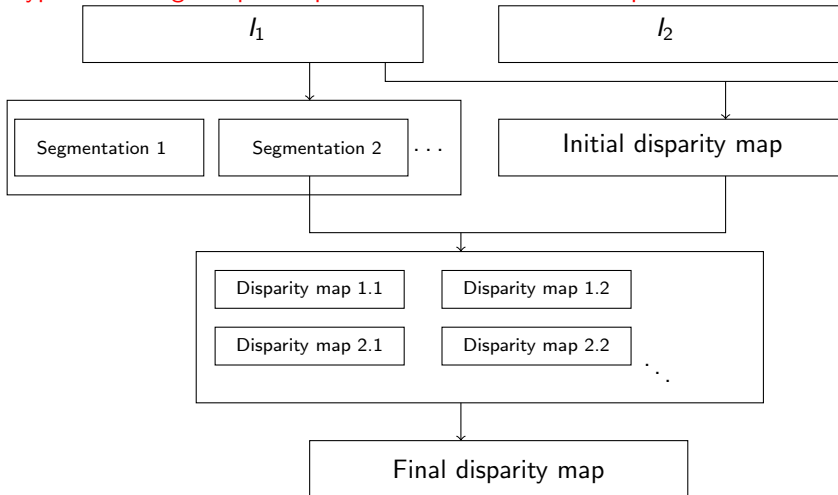
## Mise en correspondance et segmentation





# Mise en correspondance et segmentation

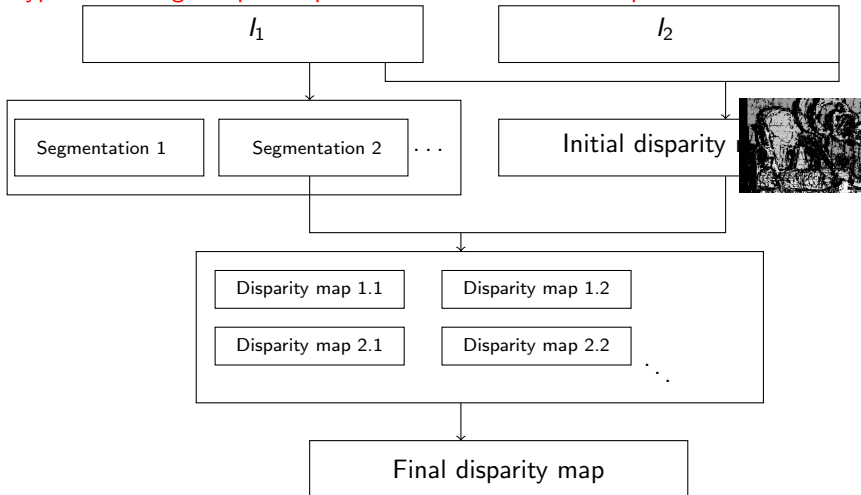
Hypothèse : régions planes par morceaux ou surface B-spline





# Mise en correspondance et segmentation

Hypothèse : régions planes par morceaux ou surface B-spline

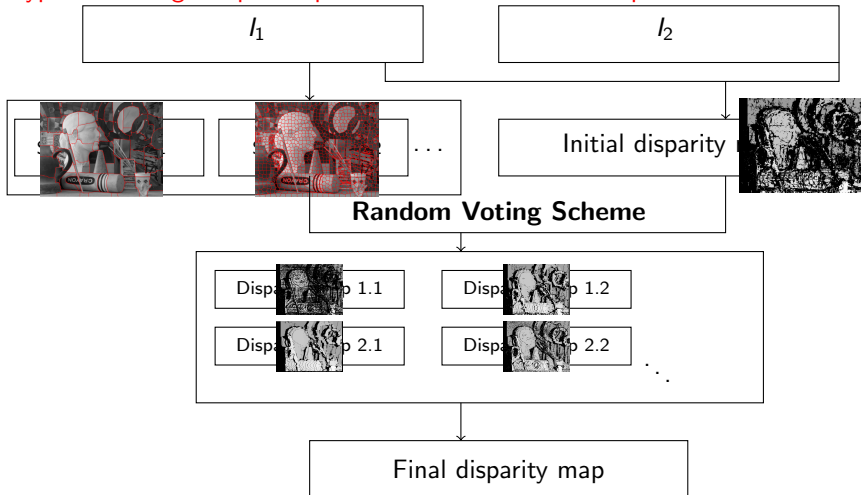






# Mise en correspondance et segmentation

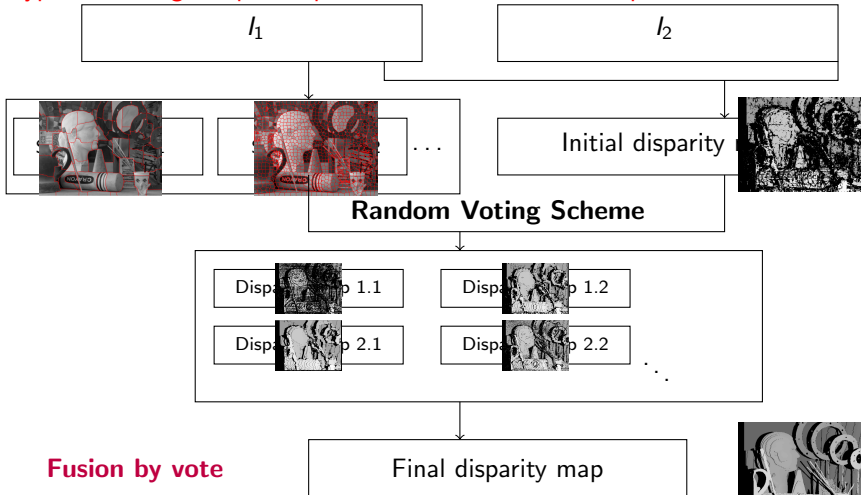
Hypothèse : régions planes par morceaux ou surface B-spline





# Mise en correspondance et segmentation

Hypothèse : régions planes par morceaux ou surface B-spline





# Analyse des approches basées segmentation

- **Quand les utiliser ?**
  - Sur-segmentation avantageuse :  
Plus la surface est petite, plus l'hypothèse est vérifiée
  - Hypothèse de modèles de surface localement vérifiée
  - Pas de contrainte de temps de calculs
- **Autres exemples de mises en correspondance multiples ?**
  - Approches combinant plusieurs techniques de mise en correspondance locale
  - Approches avec approches locales et globales



# Plan

## Introduction

Éléments à déterminer

Approches globales

Approches locales

Approches locales/globales

Mise en correspondance et segmentation

## Mesures de similarité locale

Définition et difficultés

Famille de mesures



## Définition d'une mesure de similarité

*Il s'agit d'une mesure qui évalue à quel point deux ensembles de données se ressemblent*



## Définition d'une mesure de similarité

*Il s'agit d'une mesure qui évalue à quel point deux ensembles de données se ressemblent*

- **But** : trouver pour chaque pixel  $p_1$  de la première image, le pixel  $p_2$  qui lui correspond dans l'image droite



## Définition d'une mesure de similarité

*Il s'agit d'une mesure qui évalue à quel point deux ensembles de données se ressemblent*

- **But** : trouver pour chaque pixel  $p_1$  de la première image, le pixel  $p_2$  qui lui correspond dans l'image droite
- **Hypothèse** : niveaux de gris des pixels correspondants et des pixels de leurs voisinages se ressemblent



## Définition d'une mesure de similarité

*Il s'agit d'une mesure qui évalue à quel point deux ensembles de données se ressemblent*

- **But** : trouver pour chaque pixel  $p_1$  de la première image, le pixel  $p_2$  qui lui correspond dans l'image droite
- **Hypothèse** : niveaux de gris des pixels correspondants et des pixels de leurs voisinages se ressemblent
- **Ensembles comparés** : le pixel dans l'image 1 et son voisinage,  $f_1$ , et le pixel de l'image 2 et son voisinage,  $f_2$



# Difficultés

- **Hypothèse de similarité dans le voisinage** = tout le voisinage possède la même disparité
- **Hypothèse fautive en présence de**
  - Bruits
  - Changements de luminosité
  - Déformations (dus à la projection perspective) des objets de la scène
  - Occultations



## Prise en compte de ces difficultés

- **Bruit** : préfiltrage



## Prise en compte de ces difficultés

- **Bruit** : préfiltrage
- **Changements de luminosité** : normalisation et centrage



## Prise en compte de ces difficultés

- **Bruit** : préfiltrage
- **Changements de luminosité** : normalisation et centrage
- **Projection perspective** : corrélation fine (estimation des paramètres d'une transformation locale)



## Prise en compte de ces difficultés

- **Bruit** : préfiltrage
- **Changements de luminosité** : normalisation et centrage
- **Projection perspective** : corrélation fine (estimation des paramètres d'une transformation locale)
- **Occultations** : deux solutions
  - *Fenêtres adaptatives* : Forme de la fenêtre non fixe
  - *Mesures robustes aux occultations* : Intégration direct du problème des occultations dans le calcul du score de corrélation



## 5 familles des mesures

- CROISÉE : corrélation croisée
- CLASSIQUE : outils des statistiques classiques de la distribution des différences des niveaux de gris
- DÉRIVÉE : mesures utilisant les dérivées des niveaux de gris
- NON PARAMÉTRIQUE : outils des statistiques non paramétriques
- ROBUSTE : outils des statistiques robustes



# Invariance

- BIAIS : ajout d'un scalaire
- GAIN: multiplication par un scalaire



## Corrélation croisée

### Corrélation centrée normalisée, Zero-mean Normalised Cross Correlation

$$\text{ZNCC}(\mathbf{f}_1, \mathbf{f}_2) = \frac{(\mathbf{f}_1 - \bar{\mathbf{f}}_1) \cdot (\mathbf{f}_2 - \bar{\mathbf{f}}_2)}{\|\mathbf{f}_1 - \bar{\mathbf{f}}_1\| \|\mathbf{f}_2 - \bar{\mathbf{f}}_2\|}$$

$\mathbf{f}_w, w = g, d$  = vecteurs des niveaux de gris dans les voisinages respectifs des points appariés



## Corrélation classique

- *Somme des valeurs absolues des différences –  $L_1$ , Sum of Absolute Differences*

$$\text{SAD}(\mathbf{f}_1, \mathbf{f}_2) = D_1(\mathbf{f}_1, \mathbf{f}_2) = \|\mathbf{f}_1 - \mathbf{f}_2\|_1 \quad (6)$$



## Corrélation classique

- *Somme des valeurs absolues des différences –  $L_1$ , Sum of Absolute Differences*

$$\text{SAD}(\mathbf{f}_1, \mathbf{f}_2) = D_1(\mathbf{f}_1, \mathbf{f}_2) = \|\mathbf{f}_1 - \mathbf{f}_2\|_1 \quad (6)$$

- *Somme des carrés des différences –  $L_2$ , SSD, Sum of Squared Differences*

$$\text{SSD}(\mathbf{f}_1, \mathbf{f}_2) = D_2(\mathbf{f}_1, \mathbf{f}_2) = \|\mathbf{f}_1 - \mathbf{f}_2\|^2 \quad (7)$$



## Corrélation classique

- *Somme des valeurs absolues des différences –  $L_1$ , Sum of Absolute Differences*

$$\text{SAD}(\mathbf{f}_1, \mathbf{f}_2) = D_1(\mathbf{f}_1, \mathbf{f}_2) = \|\mathbf{f}_1 - \mathbf{f}_2\|_1 \quad (6)$$

- *Somme des carrés des différences –  $L_2$ , SSD, Sum of Squared Differences*

$$\text{SSD}(\mathbf{f}_1, \mathbf{f}_2) = D_2(\mathbf{f}_1, \mathbf{f}_2) = \|\mathbf{f}_1 - \mathbf{f}_2\|^2 \quad (7)$$

- Normalisation et centrage possible



## Corrélation des dérivées

- **On ne prend plus en compte les niveaux de gris directement mais les gradients**



## Corrélation des dérivées

- **On ne prend plus en compte les niveaux de gris directement mais les gradients**
- Plupart des mesures : uniquement la direction du gradient, de manière ponctuelle
- Information seule ambiguë (surtout en cas de faible norme du gradient)

## Corrélation des dérivées

- On ne prend plus en compte les niveaux de gris directement mais les gradients
- Plupart des mesures : uniquement la direction du gradient, de manière ponctuelle
- Information seule ambiguë (surtout en cas de faible norme du gradient)
- Mesure la plus utilisée : GC (*Gradient field Correlation*) ou corrélation des champs de gradients

$$GC(\mathbf{f}_1, \mathbf{f}_2) = \frac{\sum_{p=-N_v}^{N_v} \sum_{q=-N_h}^{N_h} \|\nabla I_1^{i+p, j+q} - \nabla I_2^{i+p, v+q}\|}{\sum_{p=-N_v}^{N_v} \sum_{q=-N_h}^{N_h} (\|\nabla I_1^{i+p, j+q}\| + \|\nabla I_2^{i+p, v+q}\|)} \quad (8)$$



# Mesures non paramétriques

- **Aucune hypothèse sur les distributions sous-jacentes des niveaux de gris de la fenêtre de corrélation**



## Mesures non paramétriques

- **Aucune hypothèse sur les distributions sous-jacentes des niveaux de gris de la fenêtre de corrélation**
- Deux grands types de mesures
  1. Mesures sur les différences de niveaux de gris entre le point étudié et ses voisins
  2. Mesures exploitant le rang



## Mesures non paramétriques

**Utilisation des rangs : Modèle de mesure  $\alpha$**

$$\alpha(\mathbf{f}_1, \mathbf{f}_2) = 1 - \frac{2D_\alpha(R_\pi(\mathbf{f}_1), R_\pi(\mathbf{f}_2))}{D_{\max}}. \quad (9)$$



## Mesures non paramétriques

**Utilisation des rangs : Modèle de mesure  $\alpha$**

$$\alpha(\mathbf{f}_1, \mathbf{f}_2) = 1 - \frac{2D_\alpha(R_\pi(\mathbf{f}_1), R_\pi(\mathbf{f}_2))}{D_{\max}}. \quad (9)$$

- $R_\pi(\mathbf{f}_l)$  : Vecteurs contenant les rangs des pixels de  $\mathbf{f}_l$



## Mesures non paramétriques

### Utilisation des rangs : Modèle de mesure $\alpha$

$$\alpha(\mathbf{f}_1, \mathbf{f}_2) = 1 - \frac{2D_\alpha(R_\pi(\mathbf{f}_1), R_\pi(\mathbf{f}_2))}{D_{\max}}. \quad (9)$$

- $R_\pi(\mathbf{f}_l)$  : Vecteurs contenant les rangs des pixels de  $\mathbf{f}_l$
- $D_\alpha(R_\pi(\mathbf{f}_1), R_\pi(\mathbf{f}_1))$  distance à définir

Distances utilisés : la distance de Hamming, le nombre de permutations de ces rangs ...



## Mesures non paramétriques

### Utilisation des rangs : Modèle de mesure $\alpha$

$$\alpha(\mathbf{f}_1, \mathbf{f}_2) = 1 - \frac{2D_\alpha(R_\pi(\mathbf{f}_1), R_\pi(\mathbf{f}_2))}{D_{\max}}. \quad (9)$$

- $R_\pi(\mathbf{f}_l)$  : Vecteurs contenant les rangs des pixels de  $\mathbf{f}_l$
- $D_\alpha(R_\pi(\mathbf{f}_1), R_\pi(\mathbf{f}_1))$  distance à définir  
Distances utilisés : la distance de Hamming, le nombre de permutations de ces rangs ...
- $D_{\max}$  : maximum atteint par  $D_\alpha(R_\pi(\mathbf{f}_1), R_\pi(\mathbf{f}_1))$



## Mesures non paramétriques

**Utilisation des comparaisons des niveaux de gris :** *Increment Sign*  
*Correlation*

**On détermine si les niveaux de gris varient dans le même sens**

## Mesures non paramétriques

**Utilisation des comparaisons des niveaux de gris :** *Increment Sign Correlation*

**On détermine si les niveaux de gris varient dans le même sens**

- Utilisation des vecteurs  $\mathbf{b}_I$  :

$$\mathbf{b}_I = (\dots b_I^k \dots)^T \text{ pour } k = 0 \dots N_f - 2 \text{ avec } b_I^k = \begin{cases} 1 & \text{si } f_I^{k+1} \geq f_I^k \\ 0 & \text{sinon.} \end{cases} \quad (10)$$

## Mesures non paramétriques

**Utilisation des comparaisons des niveaux de gris :** *Increment Sign Correlation*

**On détermine si les niveaux de gris varient dans le même sens**

- Utilisation des vecteurs  $\mathbf{b}_I$  :

$$\mathbf{b}_I = (\dots b_I^k \dots)^T \text{ pour } k = 0 \cdot \dots \cdot N_f - 2 \text{ avec } b_I^k = \begin{cases} 1 & \text{si } f_I^{k+1} \geq f_I^k \\ 0 & \text{sinon.} \end{cases} \quad (10)$$

- Si le niveau de gris augmente entre  $f_I^k$  et  $f_I^{k+1}$ , alors  $b_I^k$  vaut 1 ou 0 dans le cas contraire
- ISC = comparaison entre  $\mathbf{b}_1$  et  $\mathbf{b}_2$

$$\text{ISC}(\mathbf{f}_1, \mathbf{f}_2) = \frac{1}{N_f - 1} (\mathbf{b}_1 \cdot \mathbf{b}_2 + (\mathbf{1} - \mathbf{b}_1) \cdot (\mathbf{1} - \mathbf{b}_2)) \quad (11)$$



## Mesures non paramétriques

**Mesure de recensement = utilisation de la transformation de recensement qui permet d'obtenir une chaîne de bits représentative des pixels contenus dans la fenêtre de corrélation**



## Mesures non paramétriques

**Mesure de recensement = utilisation de la transformation de recensement qui permet d'obtenir une chaîne de bits représentative des pixels contenus dans la fenêtre de corrélation**

- **Principe de la chaîne :** rend compte des pixels dont l'intensité est inférieure à celle du pixel central

## Mesures non paramétriques

**Mesure de recensement = utilisation de la transformation de recensement qui permet d'obtenir une chaîne de bits représentative des pixels contenus dans la fenêtre de corrélation**

- **Principe de la chaîne :** rend compte des pixels dont l'intensité est inférieure à celle du pixel central
- Transformation en chaîne

$$R_T(\mathbf{f}_I) = \bigotimes_{k \in [0; N_f - 1]} \xi(f_I^{N_f/2}, f_I^k). \quad (12)$$


Le terme  $\xi(f_I^{N_f/2}, f_I^k)$  vaut 1 si

$f_I^{N_f/2} < f_I^k$  ou 0 dans le cas contraire.



## Mesures non paramétriques

### Transformation de recensement



## Mesures non paramétriques

**Mesure de recensement** = CENSUS

$$\text{CENSUS}(\mathbf{f}_1, \mathbf{f}_2) = \sum_k^{N_f-1} D_{Ham}(R_\tau(\mathbf{p}_1^k), R_\tau(\mathbf{p}_2^k)). \quad (13)$$

où la distance de Hamming est donnée par :

$$D_{Ham}(\mathbf{f}_1, \mathbf{f}_2) = \sum_{k=0}^{N_f-1} \text{sgn}|f_1^k - f_2^k| \quad (14)$$

avec la fonction  $\text{sgn}$  définie par :

$$\text{sgn}(x) = \begin{cases} -1 & \text{si } x < 0 \\ 0 & \text{si } x = 0 \\ 1 & \text{sinon.} \end{cases} \quad (15)$$



# Mesures robustes

- **Gestion des occultations**

Dans le voisinage d'un pixel situé à la frontière d'un changement de profondeur, certains pixels appartiennent au premier niveau de profondeur et d'autres au deuxième niveau de profondeur

**Cette situation peut perturber la mise en correspondance et provoquer des résultats erronés**



# Mesures robustes

- **Gestion des occultations**

Dans le voisinage d'un pixel situé à la frontière d'un changement de profondeur, certains pixels appartiennent au premier niveau de profondeur et d'autres au deuxième niveau de profondeur


**Cette situation peut perturber la mise en correspondance et provoquer des résultats erronés**

- **Principe des mesures robustes :**

Les pixels qui ont une profondeur différente du pixel étudié sont considérés comme des données aberrantes



## Mesures robustes



**Traitement des données aberrantes pour la reconstruction 3D**



## Mesures robustes

- Outils de statistiques robustes qui sont beaucoup moins sensibles aux données aberrantes que les outils des statistiques classiques

## Mesures robustes

- Outils de statistiques robustes qui sont beaucoup moins sensibles aux données aberrantes que les outils des statistiques classiques
- En utilisant une norme/distance  $L_P$ , nous avons cette mesure,  $SMPD_P$  (*Smooth Median Powered Deviation*) = somme des  $h$  premières puissances des écarts à la médiane :

$$SMPD_P(\mathbf{f}_1, \mathbf{f}_2) = \sum_{k=0}^{h-1} \left( |\mathbf{f}_1 - \mathbf{f}_2 - \text{med}(\mathbf{f}_1 - \mathbf{f}_2)|^P \right)_{k:N_f-1}. \quad (16)$$



## Mesures robustes

- Outils de statistiques robustes qui sont beaucoup moins sensibles aux données aberrantes que les outils des statistiques classiques
- En utilisant une norme/distance  $L_P$ , nous avons cette mesure,  $SMPD_P$  (*Smooth Median Powered Deviation*) = somme des  $h$  premières puissances des écarts à la médiane :

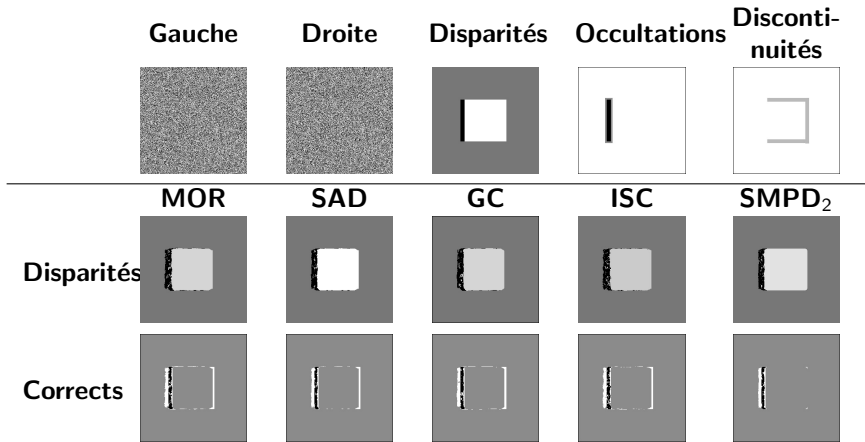
$$SMPD_P(\mathbf{f}_1, \mathbf{f}_2) = \sum_{k=0}^{h-1} \left( |\mathbf{f}_1 - \mathbf{f}_2 - \text{med}(\mathbf{f}_1 - \mathbf{f}_2)|^P \right)_{k:N_f-1}. \quad (16)$$

- Si nous choisissons  $P = 2$ , nous obtenons la mesure **Smooth Median Powered Deviation**

$$SMAD(\mathbf{f}_1, \mathbf{f}_2) = \sum_{k=0}^{h-1} \left( |\mathbf{f}_1 - \mathbf{f}_2 - \text{med}(\mathbf{f}_1 - \mathbf{f}_2)|^2 \right)_{k:N_f-1} \quad (17)$$



## Résultats sur images de synthèse et réelles





## Résultats sur images de synthèse et réelles

Gauche




Droite



Disparités



Occultations

Disconti-  
nuités


MOR




SAD



GC



ISC

SMPD<sub>2</sub>

Disparités

Corrects

