

Intérpretation automatique de nuages de points LiDAR

Journée Recherche 2017

Loic Landrieu

MATIS - IGN

Mars 2017



- 1 **Sémantisation de nuage de point LiDAR**
- 2 **Régularisation par optimisation structurée**
- 3 **Présegmentation pour la classification**



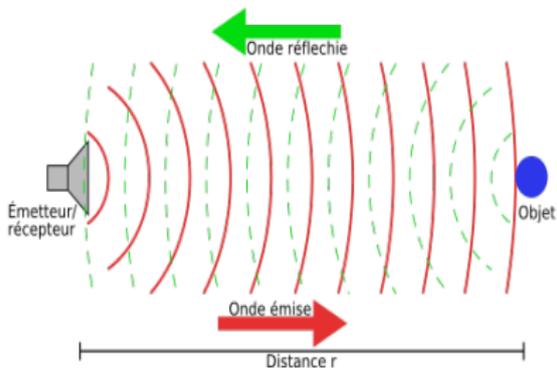
Presentation Layout

- 1 **Sémantisation de nuage de point LiDAR**
- 2 Régularisation par optimisation structurée
- 3 Présegmentation pour la classification



Acquisition LIDAR

- Un outil de télédétection actif par **LASER**





Acquisition LIDAR

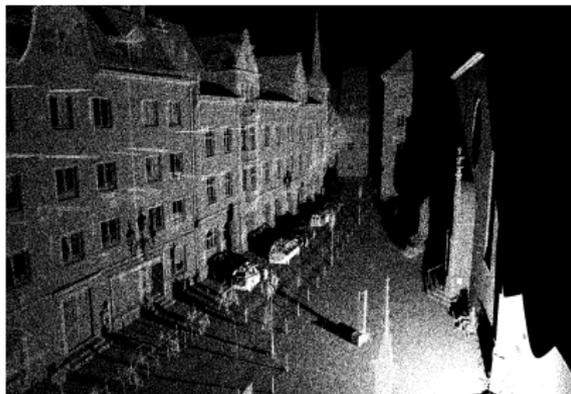
- Un outil de télédétection actif par **LASER**
- Fixe, embarqué, mobile





Acquisition LIDAR

- Un outil de télédétection **actif par LASER**
- Fixe, embarqué, mobile
- Produit un *nuage de point 3D* très précis





Acquisition LIDAR

- Un outil de télédétection **actif par LASER**
- Fixe, embarqué, mobile
- Produit un *nuage de point 3D* très précis
- Un très large champs d'application (topographie, archéologie, défense...)





Acquisition LIDAR

- Un outil de télédétection **actif par LASER**
- Fixe, embarqué, mobile
- Produit un *nuage de point 3D* très précis
- Un très large champs d'application (topographie, archéologie, défense...)
- Reconstruction de surface





Acquisition LIDAR

- Un outil de télédétection **actif par LASER**
- Fixe, embarqué, mobile
- Produit un *nuage de point 3D* très précis
- Un très large champs d'application (topographie, archéologie, défense...)
- Reconstruction de surface
- **guidage automatique de véhicules**



Caractéristiques des données

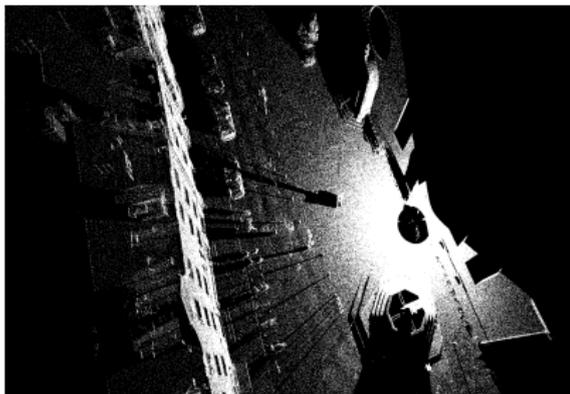
- Une volumétrie importante





Caractéristiques des données

- Une volumétrie importante
- Une densité très variable



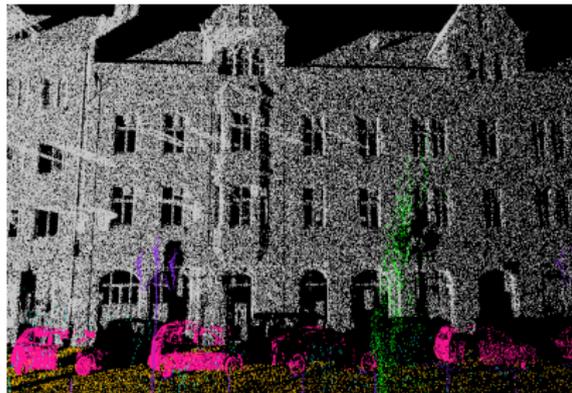
Caractéristiques des données

- Une volumétrie importante
- Une densité très variable
- Artefacts d'acquisition



Caractéristiques des données

- Une volumétrie importante
- Une densité très variable
- Artefacts d'acquisition
- **Structuré:** plus de points que d'objets, structure urbaine



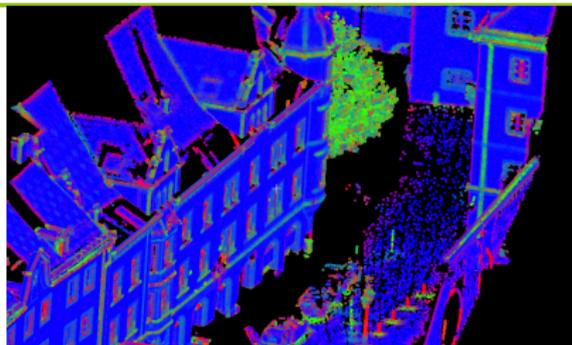
Caractéristiques des données

- Une volumétrie importante
- Une densité très variable
- Artefacts d'acquisition
- **Structuré:** plus de points que d'objets, structure urbaine
- Structure plus complexe qu'une image

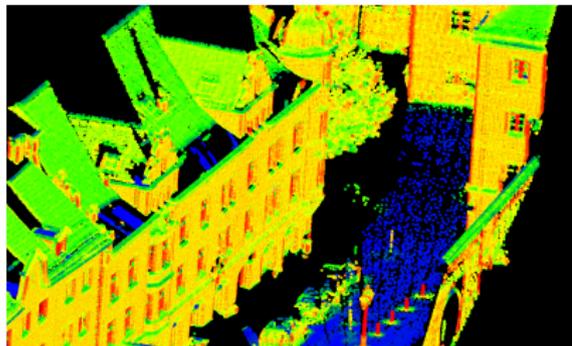


Méthodes de classification

- Descripteurs de la géométrie locale



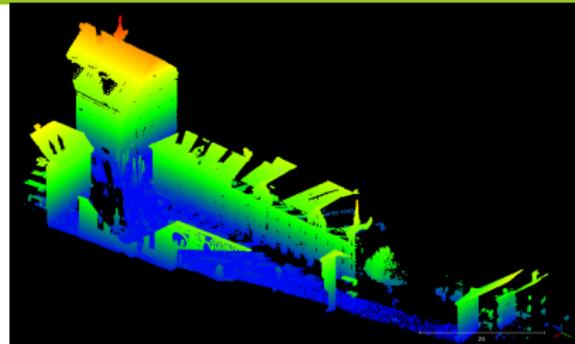
dimensionnalité



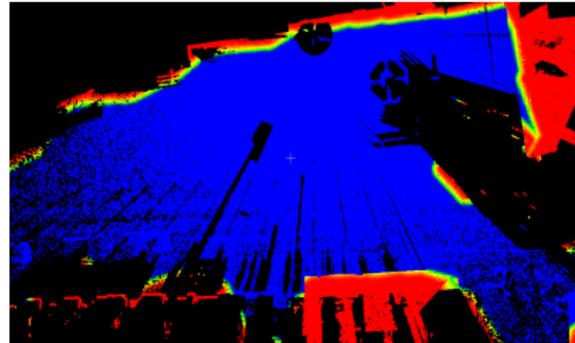
verticalité

Méthodes de classification

- Descripteurs de la géométrie locale
- Descripteurs globaux



élévation

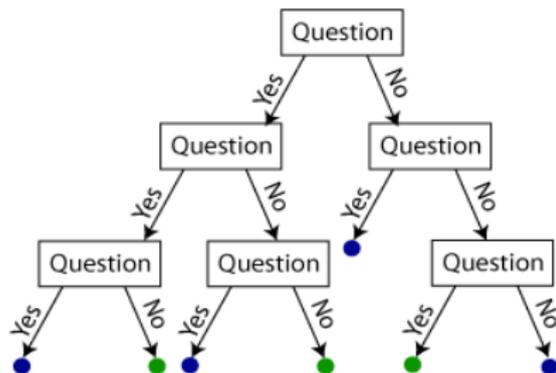


distance à la route



Méthodes de classification

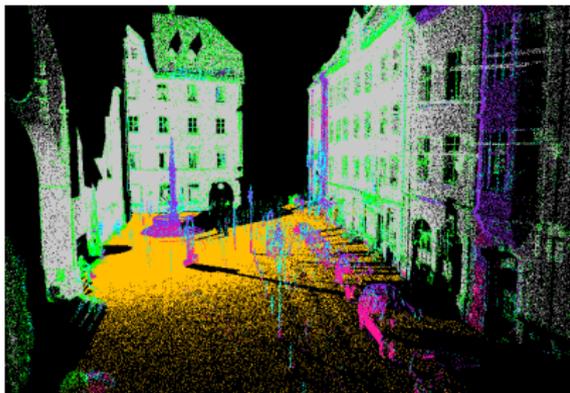
- Descripteurs de la géométrie locale
- Descripteurs globaux
- Apprentissage supervisé (Random Forest, etc...)



Méthodes de classification

- Descripteurs de la géométrie locale
- Descripteurs globaux
- Apprentissage supervisé (Random Forest, etc...)
- \Rightarrow un label + une distribution

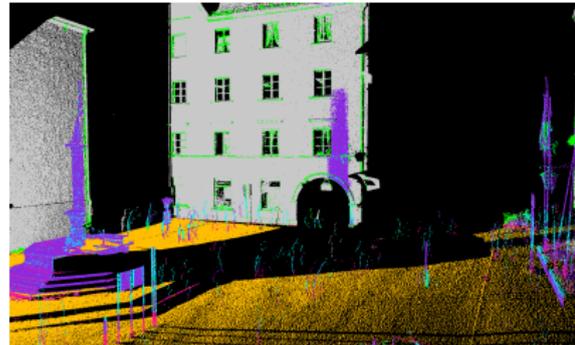
$$p_v = [p_{v,1}, \dots, p_{v,n}]$$





Affectation probabiliste

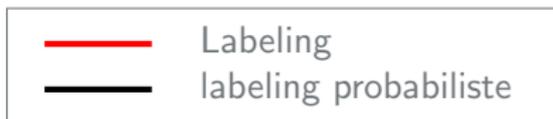
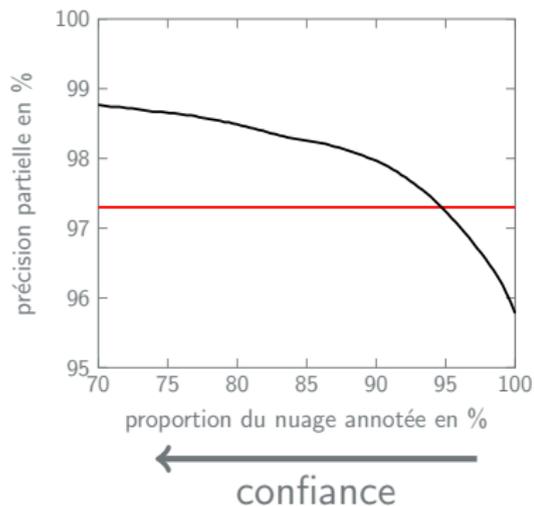
- Permet d'associer une mesure de la certitude





Affectation probabiliste

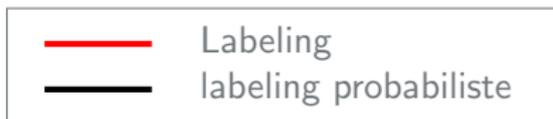
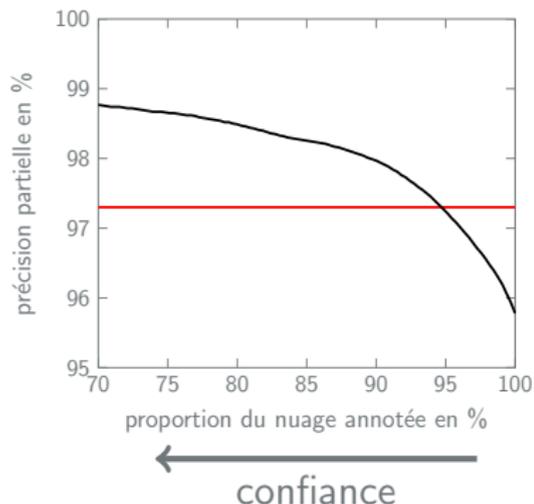
- Permet d'associer une **mesure de la certitude**
- Classement des labels par ordre de certitude





Affectation probabiliste

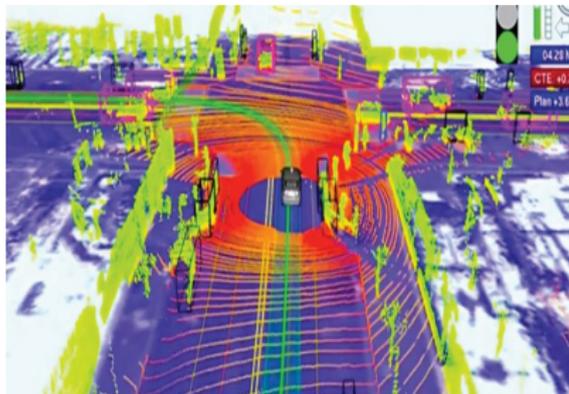
- Permet d'associer une **mesure de la certitude**
- Classement des labels par ordre de certitude
- Courbes de précision partielle





Affectation probabiliste

- Permet d'associer une **mesure de la certitude**
- Classement des labels par ordre de certitude
- Courbes de précision partielle
- \Rightarrow quand la précision est plus importante que le rappel (guidage automatique)





Affectation probabiliste

- Permet d'associer une **mesure de la certitude**
- Classement des labels par ordre de certitude
- Courbes de précision partielle
- \Rightarrow quand la précision est plus importante que le rappel (guidage automatique)
- \Rightarrow quand le rappel est important que la précision (anonymisation)





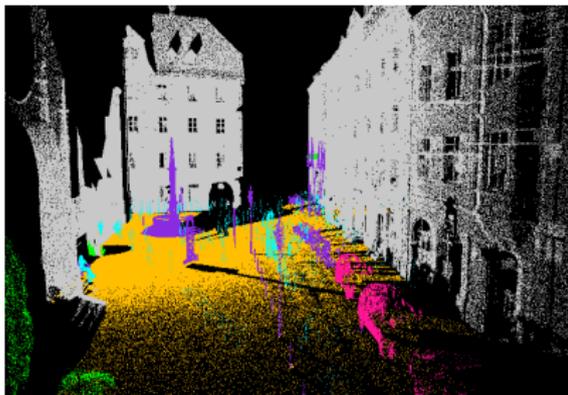
Presentation Layout

- 1 Sémantisation de nuage de point LiDAR
- 2 Régularisation par optimisation structurée**
- 3 Présegmentation pour la classification



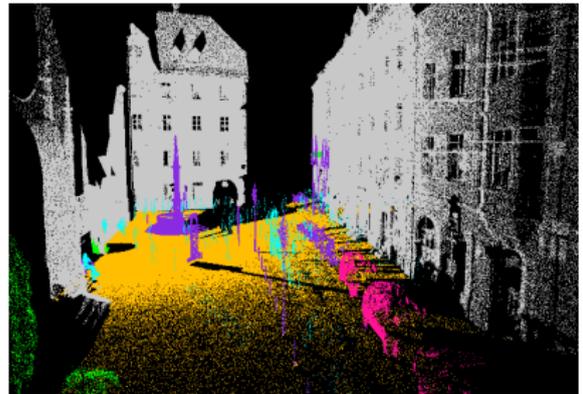
Pourquoi régulariser?

- Beaucoup plus de points que d'objets



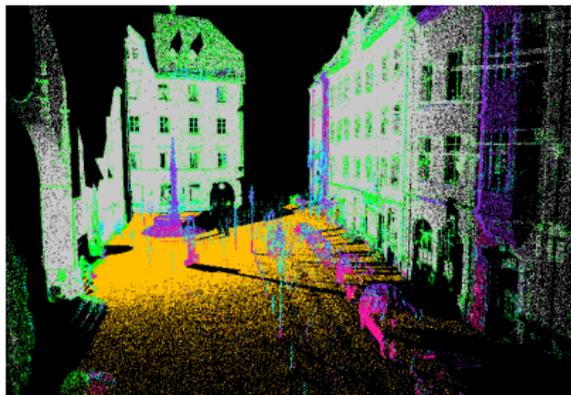
Pourquoi régulariser?

- Beaucoup plus de points que d'objets
- \Rightarrow un point est (en moyenne) entouré de points avec la meme classe



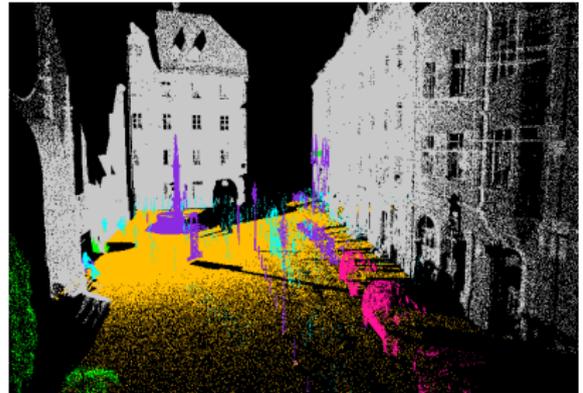
Pourquoi régulariser?

- Beaucoup plus de points que d'objets
- \Rightarrow un point est (en moyenne) entouré de points avec la même classe
- Classification point par point **aucune régularité**



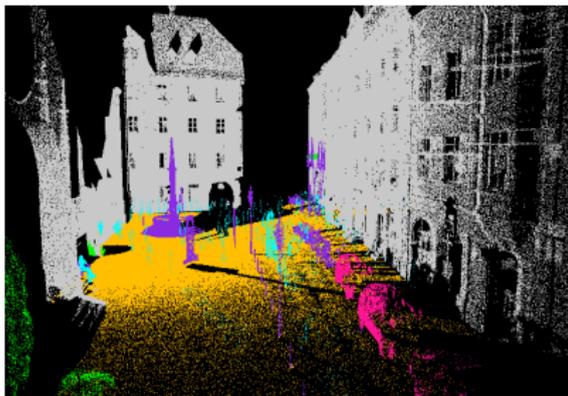
Pourquoi régulariser?

- Beaucoup plus de points que d'objets
- \Rightarrow un point est (en moyenne) entouré de points avec la même classe
- Classification point par point **aucune régularité**
- Classification régulière = meilleure précision



Présentation du problème

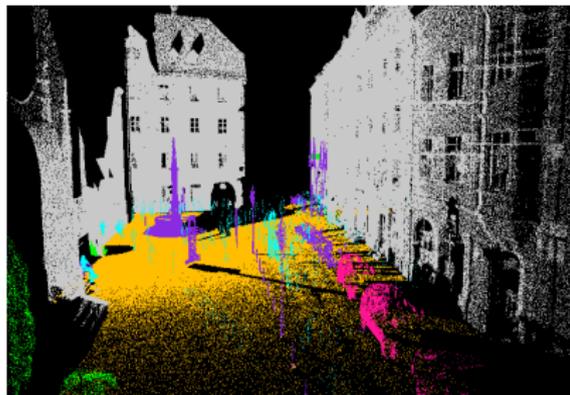
- $V =$ nuage de point.





Présentation du problème

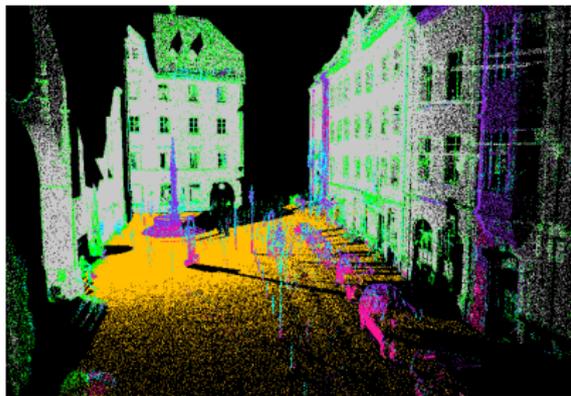
- V = nuage de point.
- K = ensemble de classes



végétation, routes. façades,
voitures, aménagements, arte-
facts,

Présentation du problème

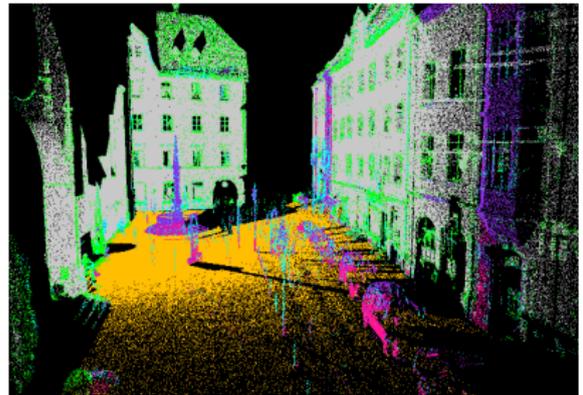
- V = nuage de point.
- K = ensemble de classes
- $p \in [0, 1]^{K \times V}$ probabilité points par points



végétation, routes. façades,
voitures, aménagements, artefacts,

Présentation du problème

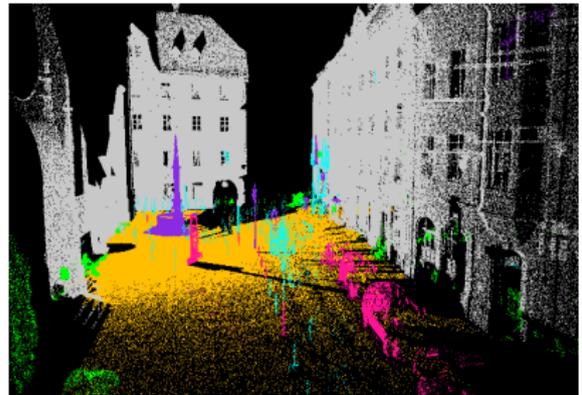
- V = nuage de point.
- K = ensemble de classes
- $p \in [0, 1]^{K \times V}$ probabilité points par points
- $G = (V, E)$ graphe d'adjacence (plus proche voisins)



végétation, routes. façades,
voitures, aménagements, arte-
facts,

Présentation du problème

- V = nuage de point.
- K = ensemble de classes
- $p \in [0, 1]^{K \times V}$ probabilité points par points
- $G = (V, E)$ graphe d'adjacence (plus proche voisins)
- $I \in K^V$ labeling recherché



végétation, routes. façades,
voitures, aménagements, artefacts,



Modèle graphique pour la régularisation

- Modèle probabiliste: Conditional random field (CRF):

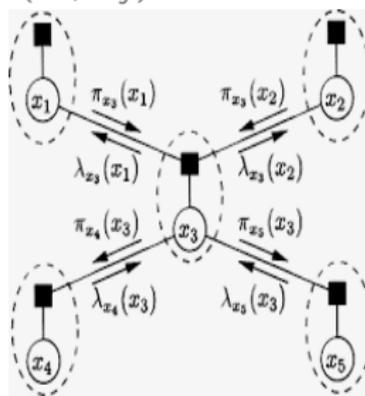
$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

Modèle graphique pour la régularisation

- Modèle probabiliste: Conditional random field (CRF):

$$\mathcal{L}(I) = - \sum_{v \in V} \langle I_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(I_i \neq I_j)$$

- Résolution par message-passing algorithms (LBP): lent et peu précis

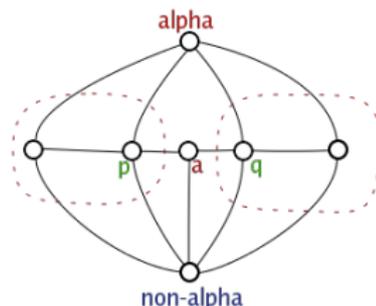


Modèle graphique pour la régularisation

- Modèle probabiliste: Conditional random field (CRF):

$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

- Résolution par message-passing algorithms (LBP): lent et peu précis
- Résolution par Graph-cut: rapide mais perd l'aspect probabiliste

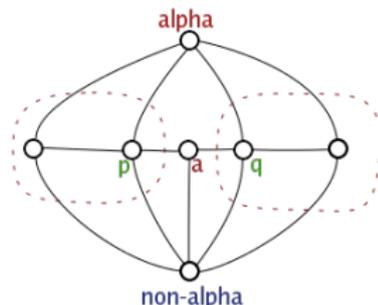


Modèle graphique pour la régularisation

- Modèle probabiliste: Conditional random field (CRF):

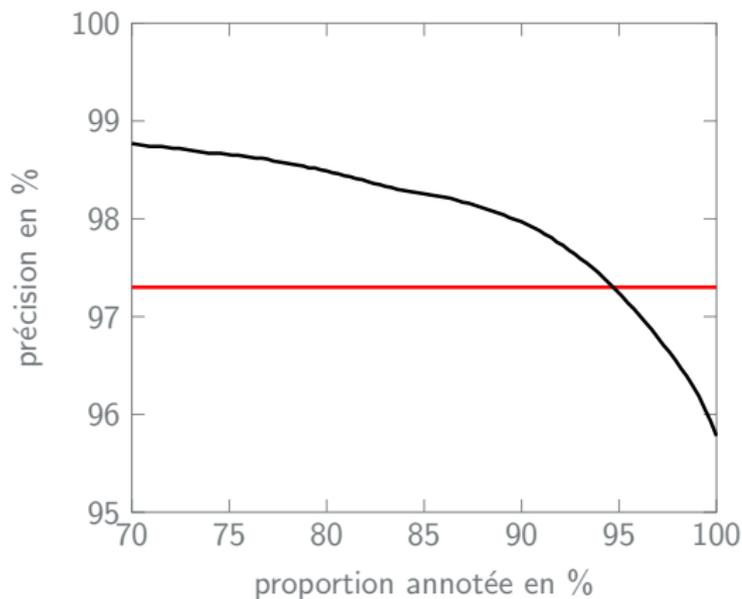
$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

- Résolution par message-passing algorithms (LBP): lent et peu précis
- Résolution par Graph-cut: rapide mais perd l'aspect probabiliste



COMPARISON OF BELIEF PROPAGATION AND GRAPH-CUT APPROACHES FOR CONTEXTUAL CLASSIFICATION OF 3D LIDAR DATA, Landrieu Loic, Weinmann Martin, Mallet Clément, IGARSS2017

Modèle graphique pour la régularisation





Régularisation par optimisation structurée

- CRF:

$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

- Optimization structurée:

$$F(q) = \sum_{v \in V} \phi(q_v, p_v) + \sum_{(i,j) \in E} w_{u,v} \psi(q_i - q_j)$$



Régularisation par optimisation structurée

- CRF:

$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

- Optimization structurée:

$$F(q) = \sum_{v \in V} \phi(q_v, p_v) + \sum_{(i,j) \in E} w_{u,v} \psi(q_i - q_j)$$



Régularisation par optimisation structurée

- CRF:

$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

- Optimization structurée:

$$F(q) = \sum_{v \in V} \phi(q_v, p_v) + \sum_{(i,j) \in E} w_{u,v} \psi(q_i - q_j)$$

- q un label *ou une distribution*



Régularisation par optimisation structurée

- CRF:

$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

- Optimization structurée:

$$F(q) = \sum_{v \in V} \phi(q_v, p_v) + \sum_{(i,j) \in E} w_{u,v} \psi(q_i - q_j)$$

- q un label *ou une distribution*
- ϕ : fonction de fidélité



Régularisation par optimisation structurée

- CRF:

$$\mathcal{L}(l) = - \sum_{v \in V} \langle l_v, \log(p_v) \rangle + \sum_{(i,j) \in E} w_{u,v} \delta(l_i \neq l_j)$$

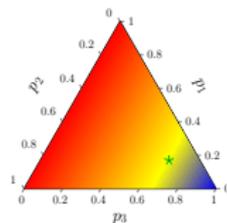
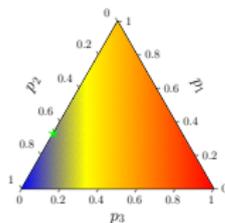
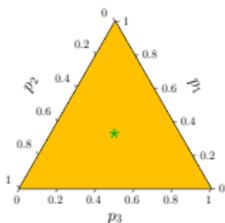
- Optimization structurée:

$$F(q) = \sum_{v \in V} \phi(q_v, p_v) + \sum_{(i,j) \in E} w_{u,v} \psi(q_i - q_j)$$

- q un label *ou une distribution*
- ϕ : fonction de fidélité
- ψ : fonction de regularization

Fonction de fidélité

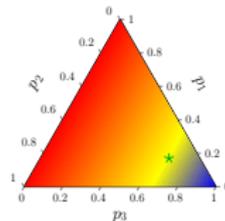
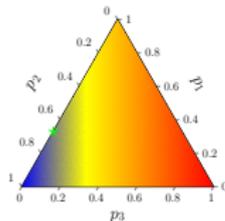
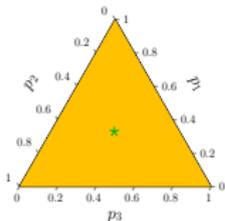
linéaire



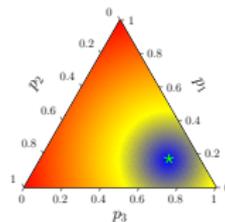
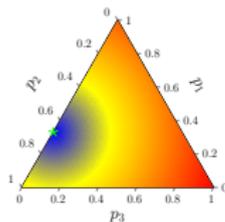
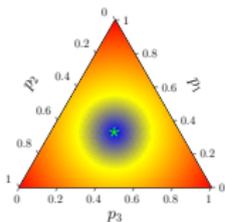
★ probabilité observée **fidélité haute**  **fidélité basse**

Fonction de fidélité

linéaire



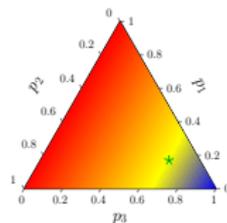
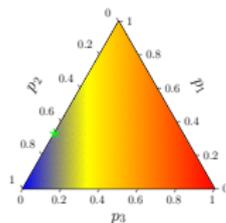
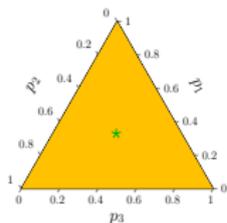
quadratique



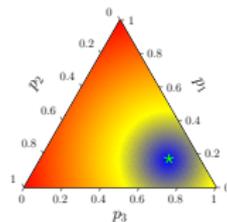
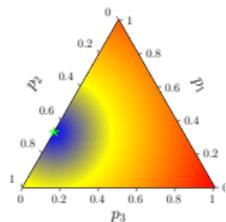
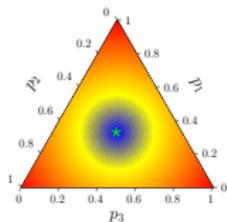
★ probabilité observée **fidélité haute**  **fidélité basse**

Fonction de fidélité

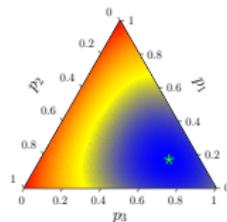
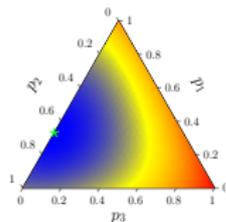
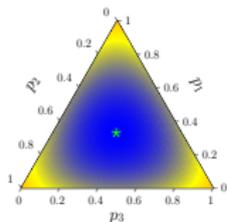
linéaire



quadratique



Kullback-Leibler

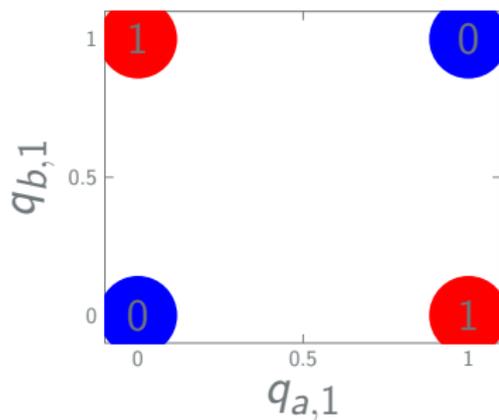


★ probabilité observée fidélité haute  fidélité basse



Fonction de pénalité

- Pénalité de Potts
 $\psi(l_i - l_j) = \delta(l_i \neq l_j)$

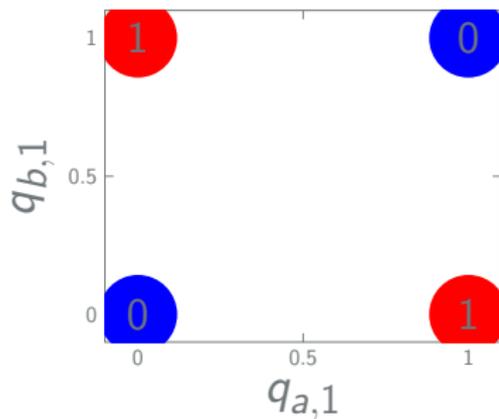


$\Psi(q_a - q_b)$ pour $K = \{1, 2\}$



Fonction de pénalité

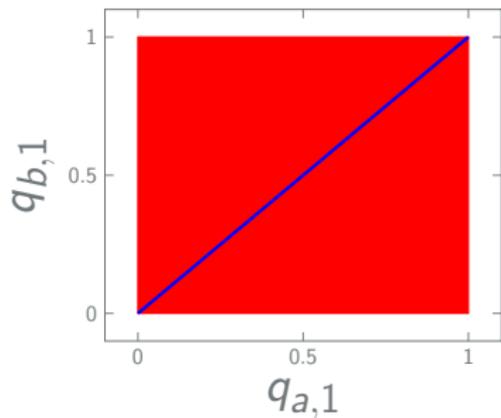
- Pénalité de Potts
 $\psi(l_i - l_j) = \delta(l_i \neq l_j)$
- optimisation combinatoire
(α -expansion)



$\Psi(q_a - q_b)$ pour $K = \{1, 2\}$

Fonction de pénalité

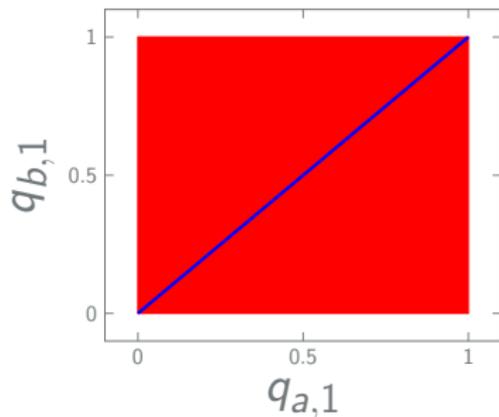
- Pénalité de Potts
 $\psi(l_i - l_j) = \delta(l_i \neq l_j)$
- optimisation combinatoire
 (α -expansion)
- Extension aux distributions
 $\psi(q_i - q_j) = \delta(q_i \neq q_j)$



$\Psi(q_a - q_b)$ pour $K = \{1, 2\}$

Fonction de pénalité

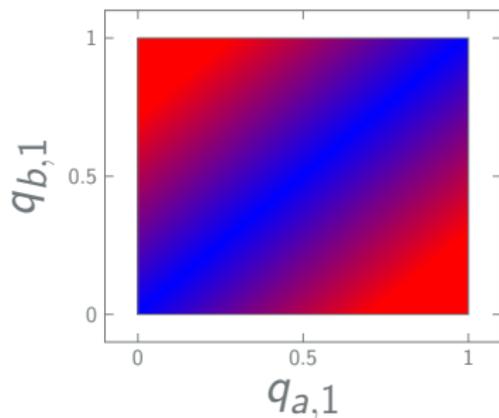
- Pénalité de Potts
 $\psi(l_i - l_j) = \delta(l_i \neq l_j)$
- optimisation combinatoire
 (α -expansion)
- Extension aux distributions
 $\psi(q_i - q_j) = \delta(q_i \neq q_j)$
- approche gloutonne (ℓ_0 -cut
 pursuit)



$\Psi(q_a - q_b)$ pour $K = \{1, 2\}$

Fonction de pénalité

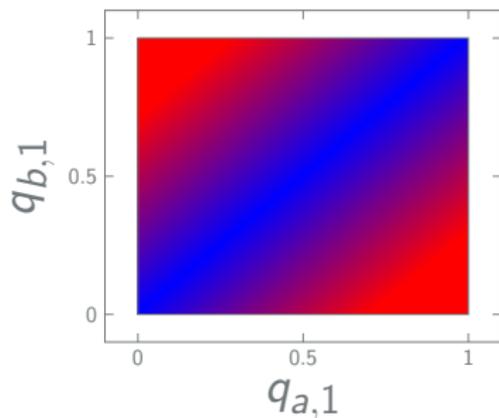
- Pénalité de Potts
 $\psi(l_i - l_j) = \delta(l_i \neq l_j)$
- optimisation combinatoire
 (α -expansion)
- Extension aux distributions
 $\psi(q_i - q_j) = \delta(q_i \neq q_j)$
- approche gloutonne (ℓ_0 -cut
 pursuit)
- relaxation convexe
 $\psi(q_i - q_j) = \|q_i - q_j\|$



$\Psi(q_a - q_b)$ pour $K = \{1, 2\}$

Fonction de pénalité

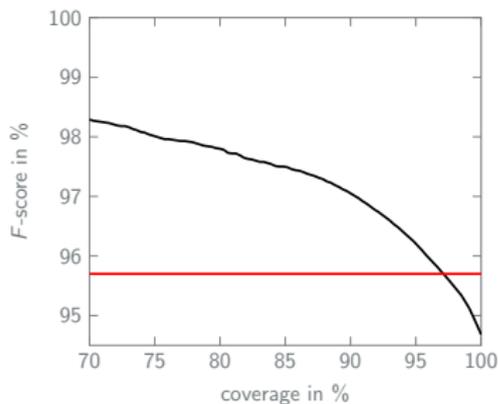
- Pénalité de Potts
 $\psi(l_i - l_j) = \delta(l_i \neq l_j)$
- optimisation combinatoire
 (α -expansion)
- Extension aux distributions
 $\psi(q_i - q_j) = \delta(q_i \neq q_j)$
- approche gloutonne (ℓ_0 -cut
 pursuit)
- relaxation convexe
 $\psi(q_i - q_j) = \|q_i - q_j\|$
- optimization convexe (PFDR)



$\Psi(q_a - q_b)$ pour $K = \{1, 2\}$



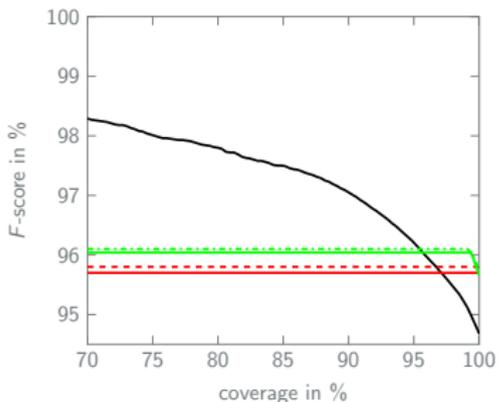
Résultats



— LBP
— log_potts (CRF)

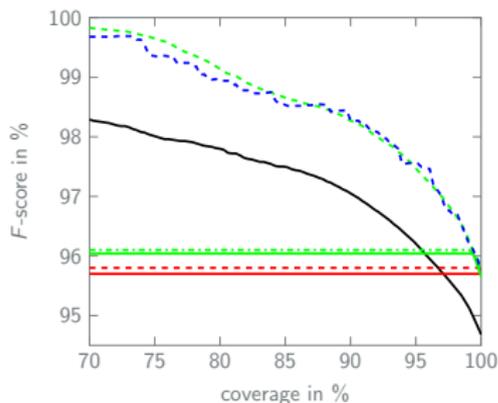


Résultats



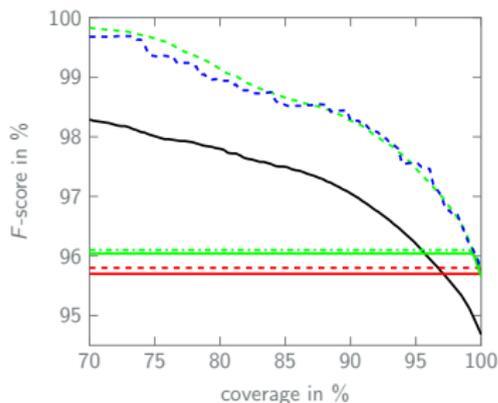


Résultats

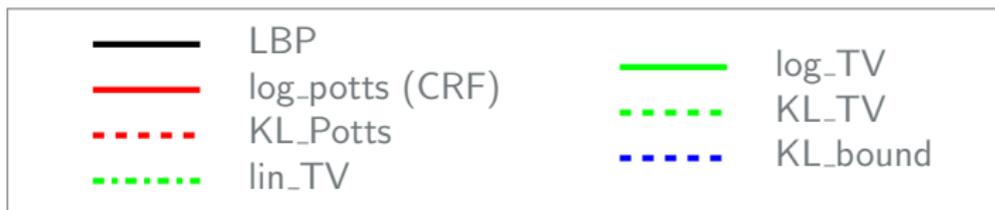
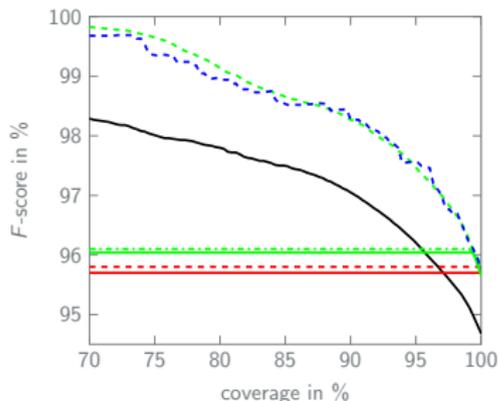




Résultats



Résultats

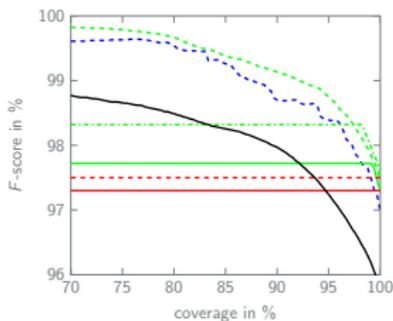


A structured regularization framework for spatially smoothing semantic labelings of 3D point clouds, Landrieu Loïc, Raguét Hugo, Vallet Bruno, Mallet Clément, Weinmann Martin

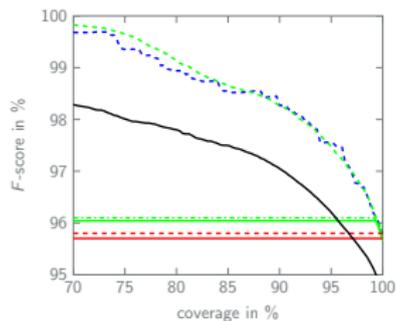




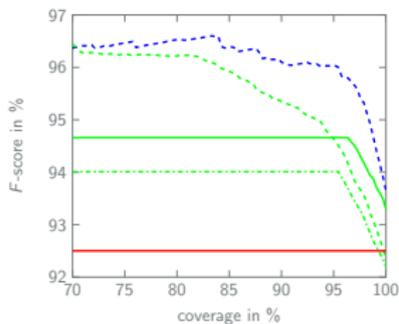
Résultats



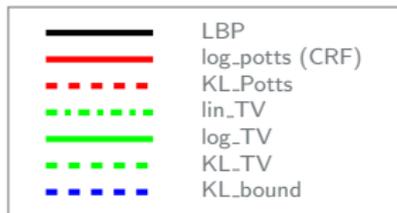
(a) Oakland 3C



(b) Oakland 5C



(c) Rue Cassette





Presentation Layout

- 1 Sémantisation de nuage de point LiDAR
- 2 Régularisation par optimisation structurée
- 3 Présegmentation pour la classification**

Motivation

- Scène urbaine: structurée par objets anthropiques



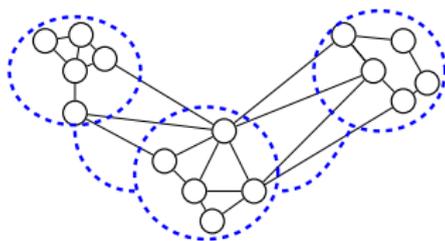
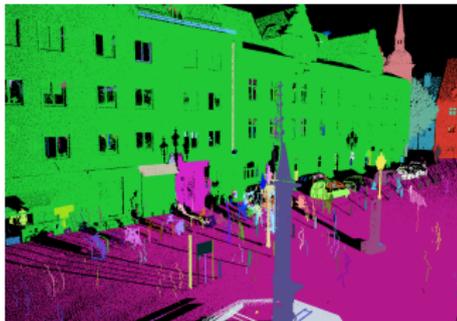
Motivation

- Scène urbaine: structurée par objets anthropiques
- géométriquement homogène ⇒ sémantiquement homogène



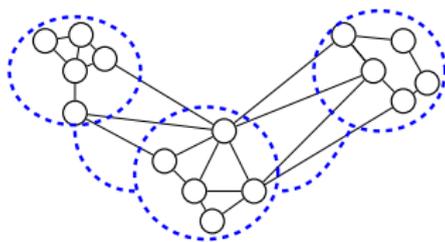
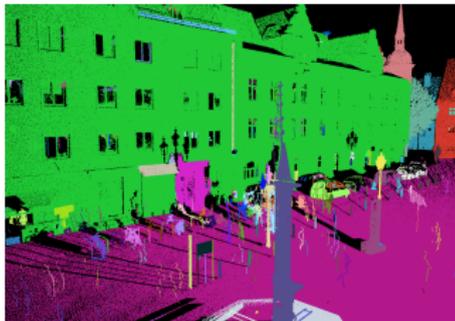
Motivation

- Scène urbaine: structurée par objets anthropiques
- géométriquement homogène ⇒ sémantiquement homogène
- + Diminution de la complexité



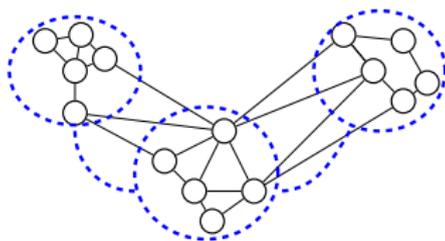
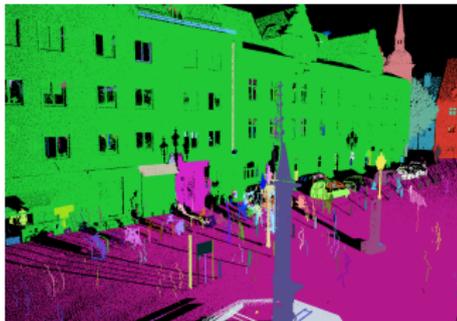
Motivation

- Scène urbaine: structurée par objets anthropiques
- géométriquement homogène
⇒ sémantiquement homogène
- + Diminution de la complexité
- + Interactions longue portée



Motivation

- Scène urbaine: structurée par objets anthropiques
- géométriquement homogène ⇒ sémantiquement homogène
- + Diminution de la complexité
- + Interactions longue portée
- + Aggregation d'observations





Segmentation géométriquement homogène

- Approche traditionnelle : super voxel de taille fixée



Segmentation géométriquement homogène

- Approche traditionnelle : super voxel de taille fixée
- problème d'optimisation structurée

$$E(S) = \sum_{s \in S} \sum_{i \in s} |x_i - x_s|^2 + \lambda \sum_{s \in S} \text{contour}(s).$$



Segmentation géométriquement homogène

- Approche traditionnelle : super voxel de taille fixée
- problème d'optimisation structurée

$$E(S) = \sum_{s \in S} \sum_{i \in s} |x_i - x_s|^2 + \lambda \sum_{s \in S} \text{contour}(s).$$

- Peut être minimisé efficacement avec ℓ_0 -cut poursuit



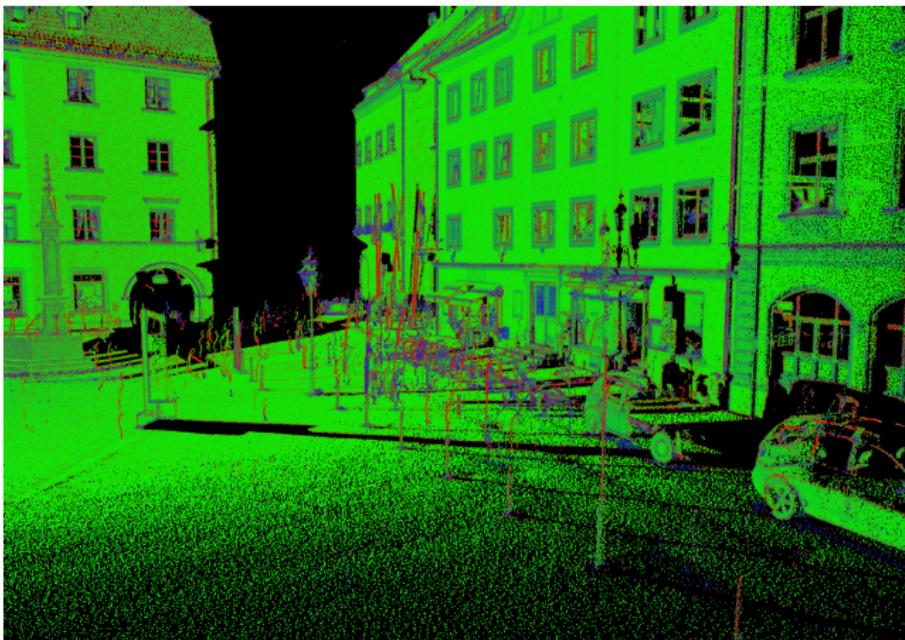
Segmentation géométriquement homogène

- Approche traditionnelle : super voxel de taille fixée
- problème d'optimisation structurée

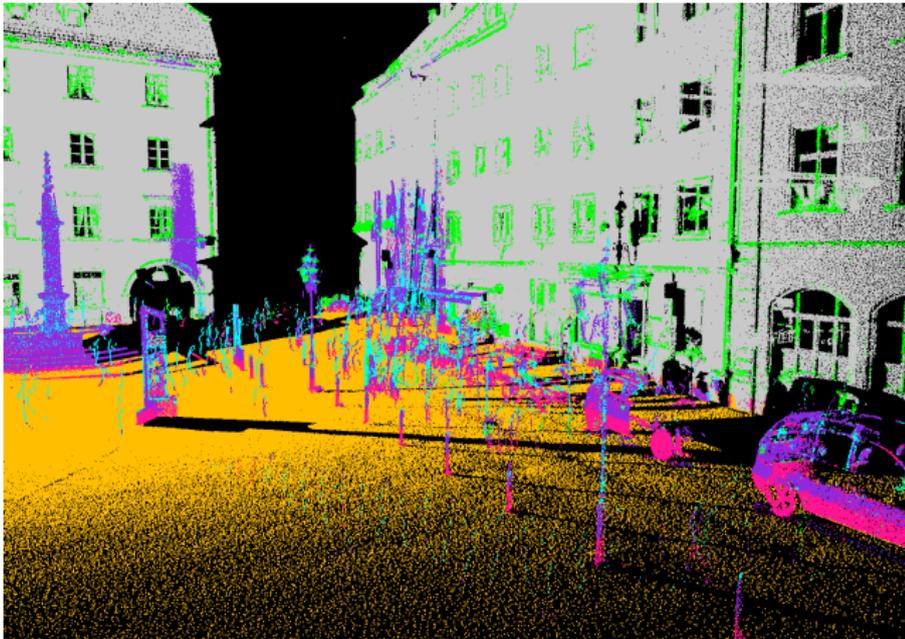
$$E(S) = \sum_{s \in S} \sum_{i \in s} |x_i - x_s|^2 + \lambda \sum_{s \in S} \text{contour}(s).$$

- Peut être minimisé efficacement avec ℓ_0 -cut poursuit
- Segments de tailles adaptative

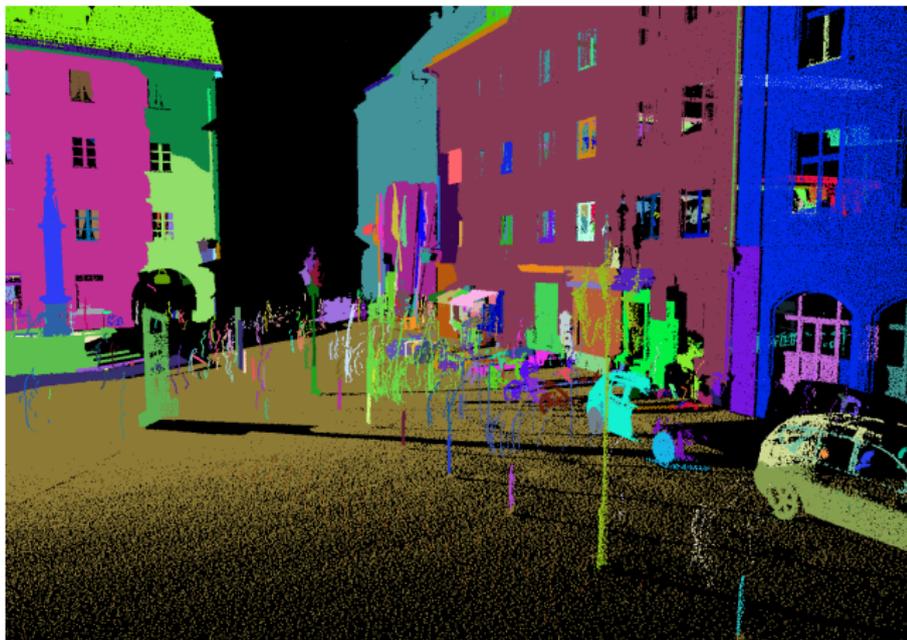
Segmentation géométriquement homogène



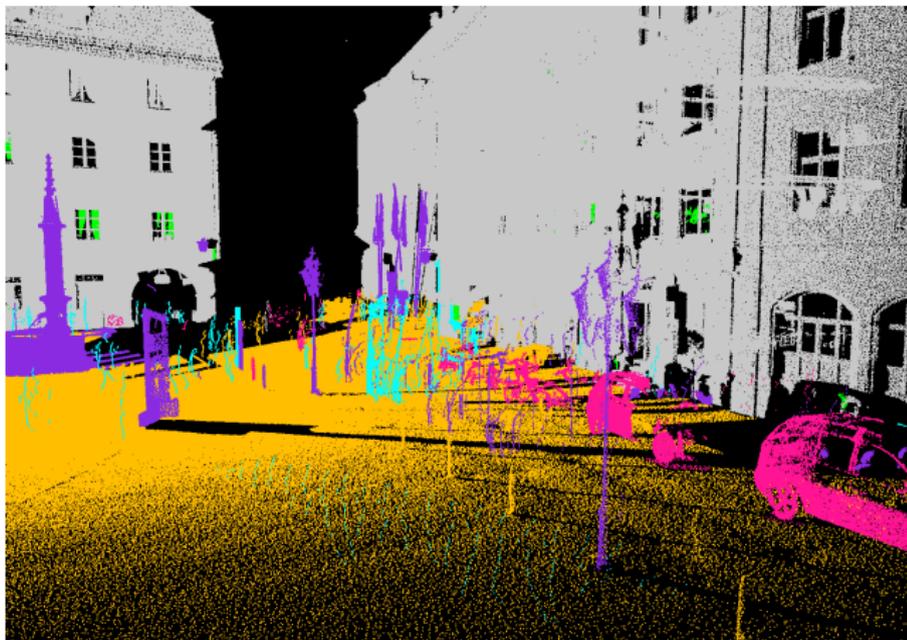
Segmentation géométriquement homogène



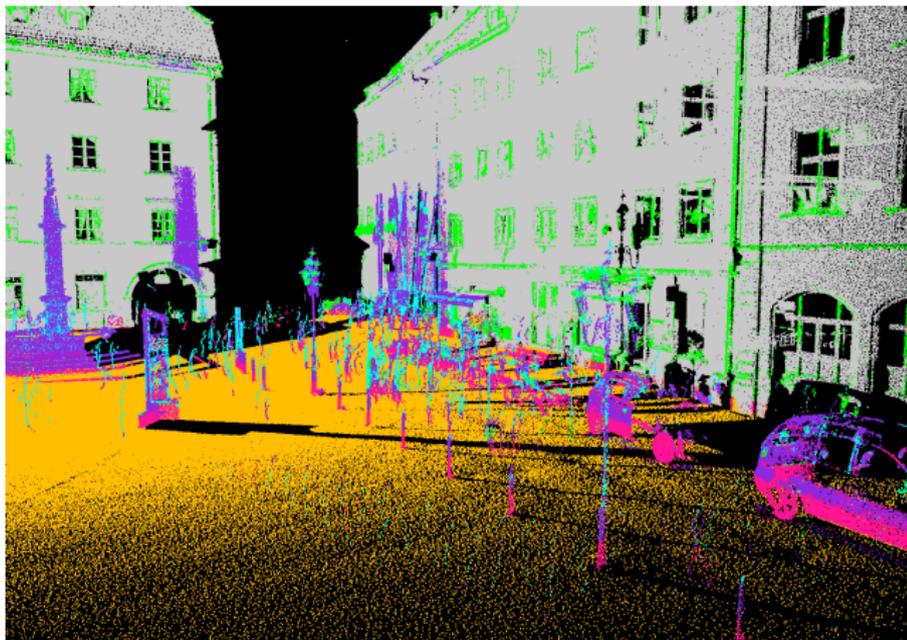
Segmentation géométriquement homogène



Segmentation géométriquement homogène



Segmentation géométriquement homogène





Segmentation géométriquement homogène

	class	pointwise	CRF	notre méthode
Fscore pour Oakland 1.3 M points	<i>Wires</i>	7.5	47.0	41.9
	<i>Poles</i>	15.9	51.0	55.8
	<i>Façades</i>	65.1	87.6	93.6
	<i>Road</i>	92.8	97.4	99.4
	<i>Vegetation</i>	84.1	93.3	95
	<i>total</i>	53.1	75.2	77.1
Fscore pour Semantic3D 3 M points	<i>Road</i>	97.7	98.3	98.1
	<i>Vegetation</i>	24.2	62.6	67.0
	<i>Façade</i>	93.5	98.7	98.8
	<i>Hardscape</i>	73.1	91.2	91.5
	<i>Artifacts</i>	24.6	54.7	51.3
	<i>Cars</i>	37.6	75.1	82.3
	<i>Total</i>	58.4	80.1	82.3



Perspective

- Le deep learning a révolutionné la vision par ordinateur



Perspective

- Le deep learning a révolutionné la vision par ordinateur
- La structure des nuages de point résiste aux réseaux de neurones



Perspective

- Le deep learning a révolutionné la vision par ordinateur
- La structure des nuages de point résiste aux réseaux de neurones
- Plus pour très longtemps (HarrisNet, PointNet, etc...)



Perspective

- Le deep learning a révolutionné la vision par ordinateur
- La structure des nuages de point résiste aux réseaux de neurones
- Plus pour très longtemps (HarrisNet, PointNet, etc...)
- Une révolution est à venir dans le domaine



Perspective

- Le deep learning a révolutionné la vision par ordinateur
- La structure des nuages de point résiste aux réseaux de neurones
- Plus pour très longtemps (HarrisNet, PointNet, etc...)
- Une révolution est à venir dans le domaine
- Présegmentation et régularisation reste indispensable pour exploiter la structure des nuages de points