


Détection de regards de visite sur des images à THRS par une méthode d'apprentissage

COMMANDRE Benjamin, EN-NEJJARY Driss, PIBRE Lionel, CHAUMONT
Marc, SUBSOL Gérard, DERUELLE Laurent, DERRAS Mustapha,
DELENNE Carole, CHAHINIAN Nanée

Univ. Montpellier - HydroSciences Montpellier
Equipe INRIA Lemon



Projet Cart'Eaux: chercheur d'avenir 2015 2

Récolte et fusion de données hétérogènes pour la cartographie et la modélisation des écoulements dans un réseau d'assainissement urbain.

Nanée Chahinian^{1,2} ; Marc Chaumont^{3,4}

Carole Delenne^{1,5} ; Mustapha Derras⁶

Laurent Deruelle⁶ ; Gérard Subsol^{3,7}

+

Jean-Stephane Bailly (LISAH);

Sandra Bringay (LIRMM);

Maguelonne Tैसेire et Mathieu Roche (TETIS)

+

Benjamin Commandré



PROJET COFINANCE PAR LE FONDS EUROPEEN DE DEVELOPPEMENT REGIONAL

Projet Cart'Eaux

Objectifs:

- ▶ Détection des plaques d'égout sur les images aériennes
- ▶ Fusion avec d'autres données géographiques (plan, réseau routier...)
- ▶ Fouille de données pour créer une table attributaire
- ▶ Cartographies probables du réseau
- ▶ Simulations hydrauliques (avec analyse de sensibilité aux paramètres)



Téledétection
Données géographiques

Schéma directeur d'Assainissement

Le Schéma Directeur d'Assainissement définit, à l'échelle de règlement, les types d'équipement à mettre en œuvre dans la commune. L'article 55 de la loi sur l'eau du 3 janvier 1992 oblige chaque commune à se doter d'un Schéma Directeur d'Assainissement au plus tard le 31 décembre 2015.




NO	NO MAT	ENTREE	QUOTID	SEAU LIBE D
1	1	Pluie	NO	ALLIANCE
2	2	Pluie	NO	ALLIANCE
3	3	Pluie	NO	ALLIANCE
4	4	Pluie	NO	ALLIANCE
5	5	Pluie	NO	ALLIANCE
6	6	Pluie	NO	ALLIANCE
7	7	Pluie	NO	ALLIANCE
8	8	Pluie	NO	ALLIANCE
9	9	Pluie	NO	ALLIANCE
10	10	Pluie	NO	ALLIANCE
11	11	Pluie	NO	ALLIANCE
12	12	Pluie	NO	ALLIANCE
13	13	Pluie	NO	ALLIANCE
14	14	Pluie	NO	ALLIANCE
15	15	Pluie	NO	ALLIANCE
16	16	Pluie	NO	ALLIANCE
17	17	Pluie	NO	ALLIANCE
18	18	Pluie	NO	ALLIANCE
19	19	Pluie	NO	ALLIANCE
20	20	Pluie	NO	ALLIANCE
21	21	Pluie	NO	ALLIANCE
22	22	Pluie	NO	ALLIANCE
23	23	Pluie	NO	ALLIANCE
24	24	Pluie	NO	ALLIANCE
25	25	Pluie	NO	ALLIANCE
26	26	Pluie	NO	ALLIANCE
27	27	Pluie	NO	ALLIANCE
28	28	Pluie	NO	ALLIANCE
29	29	Pluie	NO	ALLIANCE
30	30	Pluie	NO	ALLIANCE
31	31	Pluie	NO	ALLIANCE
32	32	Pluie	NO	ALLIANCE
33	33	Pluie	NO	ALLIANCE
34	34	Pluie	NO	ALLIANCE
35	35	Pluie	NO	ALLIANCE
36	36	Pluie	NO	ALLIANCE
37	37	Pluie	NO	ALLIANCE
38	38	Pluie	NO	ALLIANCE
39	39	Pluie	NO	ALLIANCE
40	40	Pluie	NO	ALLIANCE
41	41	Pluie	NO	ALLIANCE
42	42	Pluie	NO	ALLIANCE
43	43	Pluie	NO	ALLIANCE
44	44	Pluie	NO	ALLIANCE
45	45	Pluie	NO	ALLIANCE
46	46	Pluie	NO	ALLIANCE
47	47	Pluie	NO	ALLIANCE
48	48	Pluie	NO	ALLIANCE
49	49	Pluie	NO	ALLIANCE
50	50	Pluie	NO	ALLIANCE

Fouille de données

Attributs:
Positions, Cotes, Matériaux,
Diamètres, Ouvrages, dates...




Cartographie d'un
réseau probable

Modélisation
hydraulique



2 images à 5cm de résolution spatiale

- ▶ Gigean
- ▶ Prades-Le-Lez



Détection des plaques d'égout

5

Difficultés:

- ▶ 80cm seulement => 16 pixels maximum à une résolution de 5cm.



Détection des plaques d'égout

Difficultés:

- ▶ 80cm seulement => 16 pixels maximum à une résolution de 5cm.



- ▶ Généralement très peu de contraste



Détection des plaques d'égout

Difficultés:


- ▶ 80cm seulement => 16 pixels maximum à une résolution de 5cm.



- ▶ Généralement très peu de contraste



- ▶ De nombreux autres objets circulaires sur l'image.



Ombre de lampadaire



Cheminée



???






Table de jardin





Bouée ??



Parabole?

Filtre circulaire



Indices basés sur les distributions radiométriques (nécessite une image en niveaux de gris):

- ▶ S similitude entre les régions R1 et R2
- ▶ S8: maximum des similitudes entre R1 et les sous-régions de R2 (évite la détection de linéaires)
- ▶ U1 et U2: uniformité au sein de chaque région = min de la similitude entre une sous région et les autres.

$$\text{Résultat} = (1 - \max(S, S8)) * U1 * U2$$

Calcul sur fenêtre glissante puis seuillage:

- ▶ Méthode simple et directe (pas d'apprentissage).
- ▶ Très long (40h pour une image 20000x20000 soit 1km²)
- ▶ Résultats mitigés: Gigean, jusqu'à 42 plaques sur 100 détectées mais autant faux positifs !



Deep Learning (apprentissage)

7



0 250 500 m



Nécessite une base d'apprentissage

- ▶ Prades-Le-Lez: image RVB, 5cm de résolution spatiale
- ▶ 605 plaques disponibles pour l'entraînement => augmentation de la base de données (bibliothèque KERAS)
 - Rotation
 - Translation
 - Miroir



- ▶ Mode de remplissage: réflexion
- ▶ => 20450 images « plaques » + 509506 images « autres »




Nécessite une base d'apprentissage

- ▶ Prades-Le-Lez: image RVB, 5cm de résolution spatiale
- ▶ 605 plaques disponibles pour l'entraînement => augmentation de la base de données (bibliothèque KERAS)
 - Rotation
 - Translation
 - Miroir

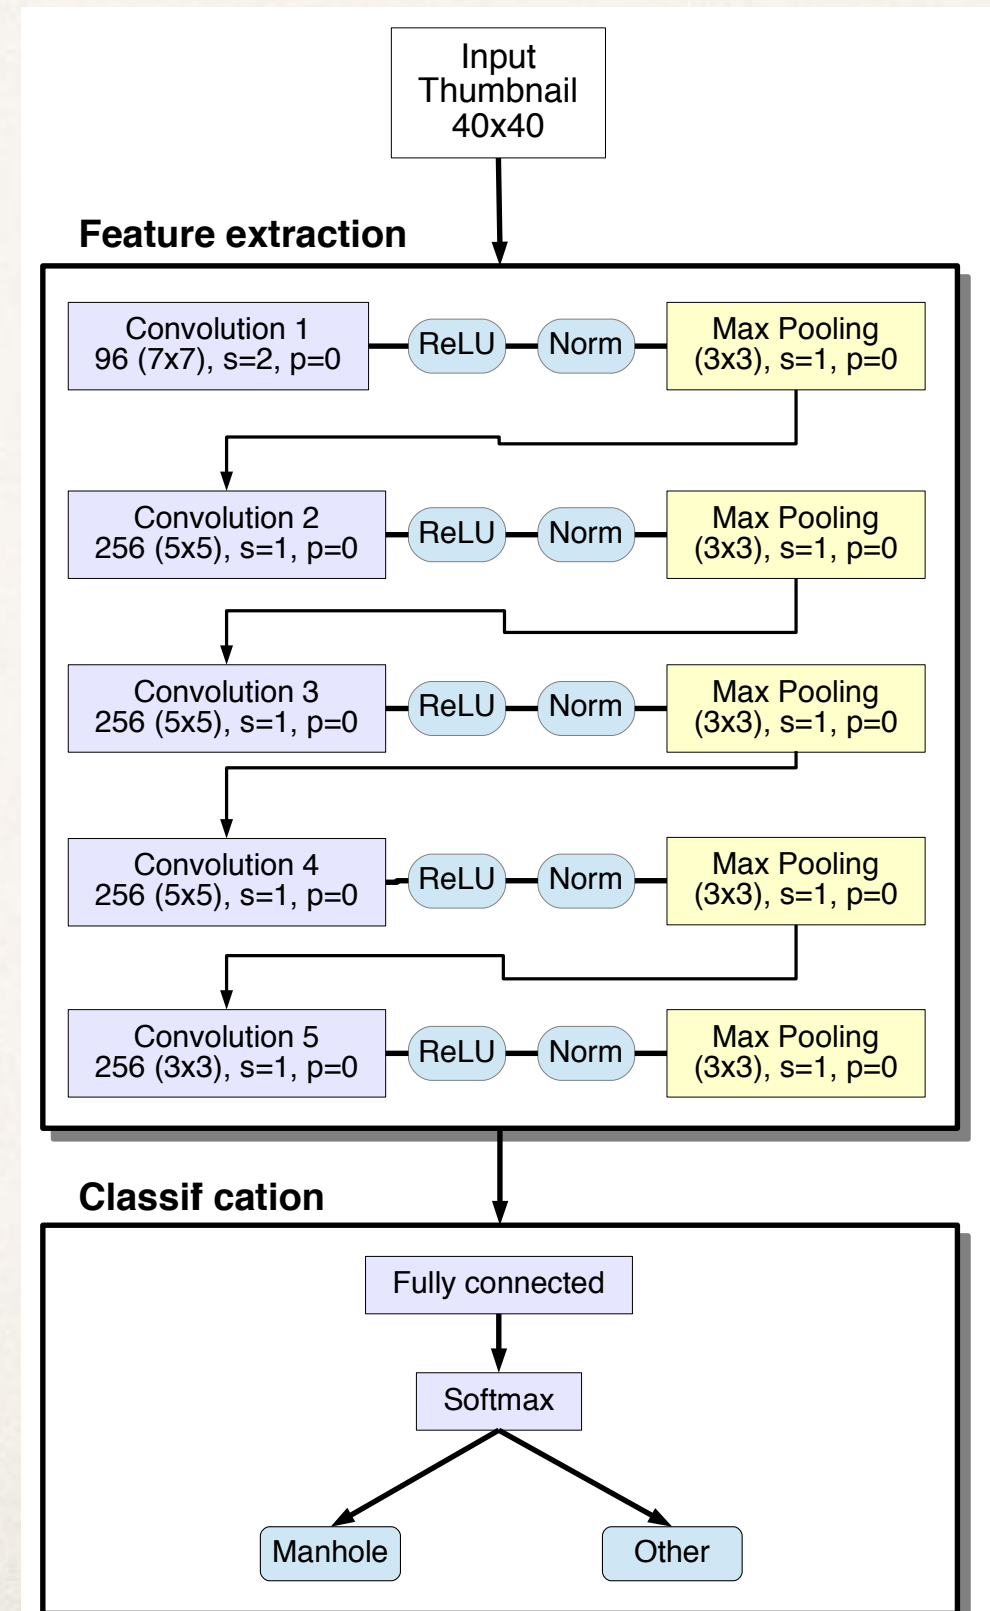


- ▶ Mode de remplissage: réflexion
- ▶ => 20450 images « plaques » + 509506 images « autres »



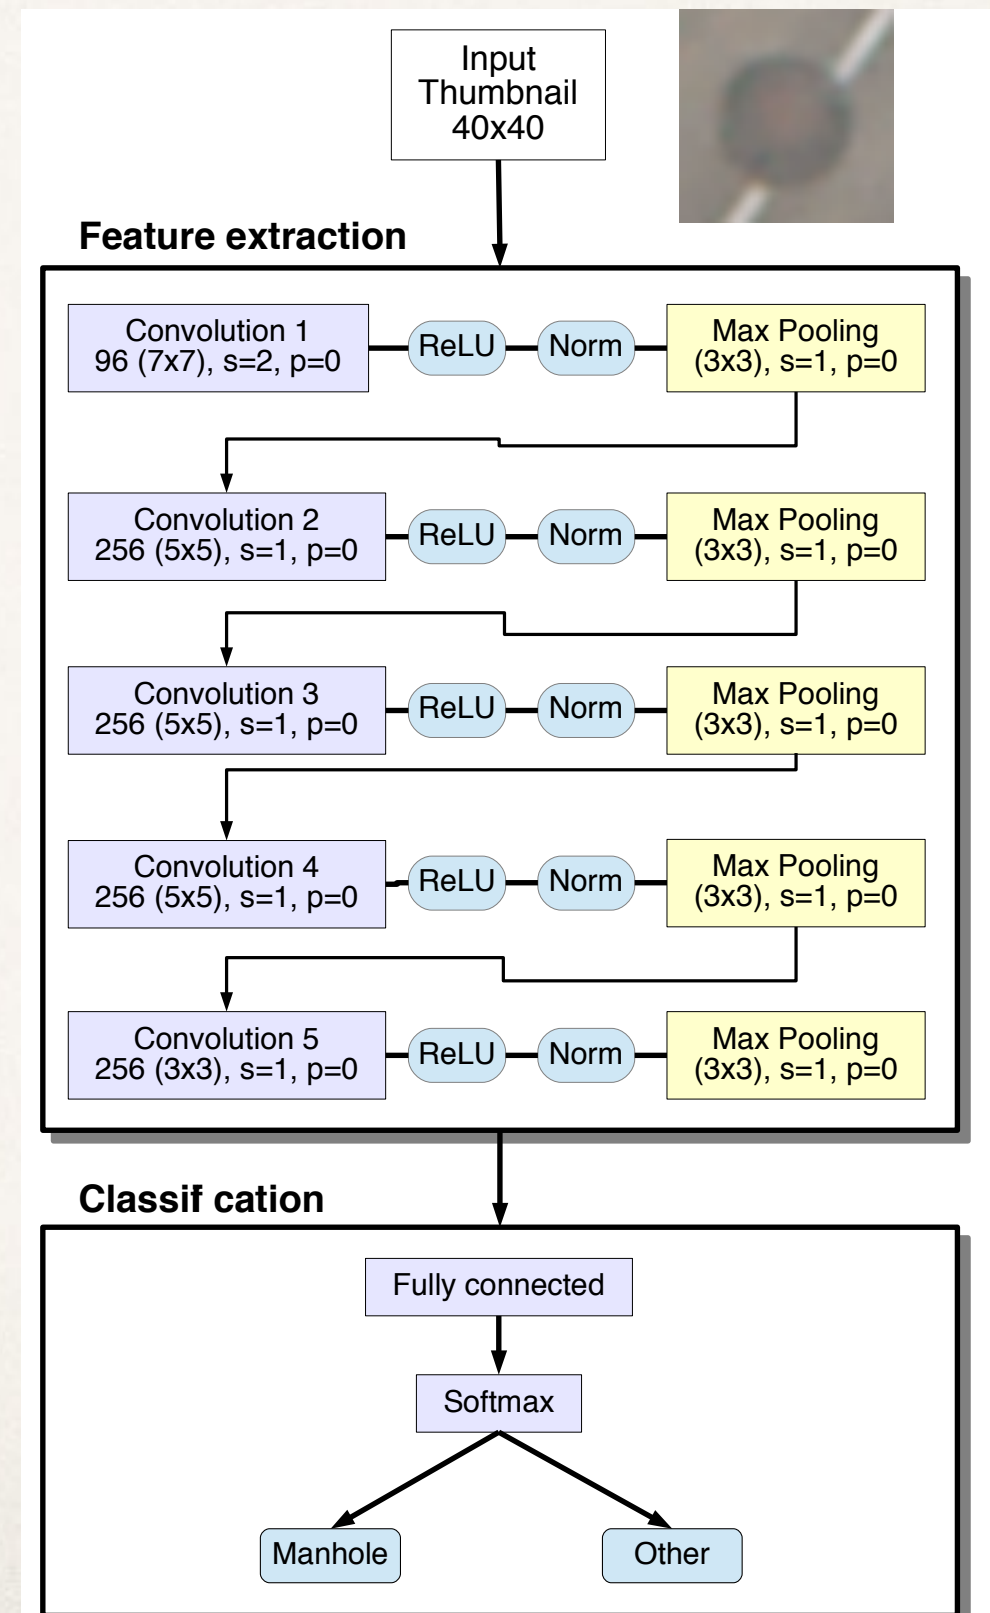
Convolutional Neural Network

AlexNet + adaptation des paramètres aux petits objets



Convolutional Neural Network

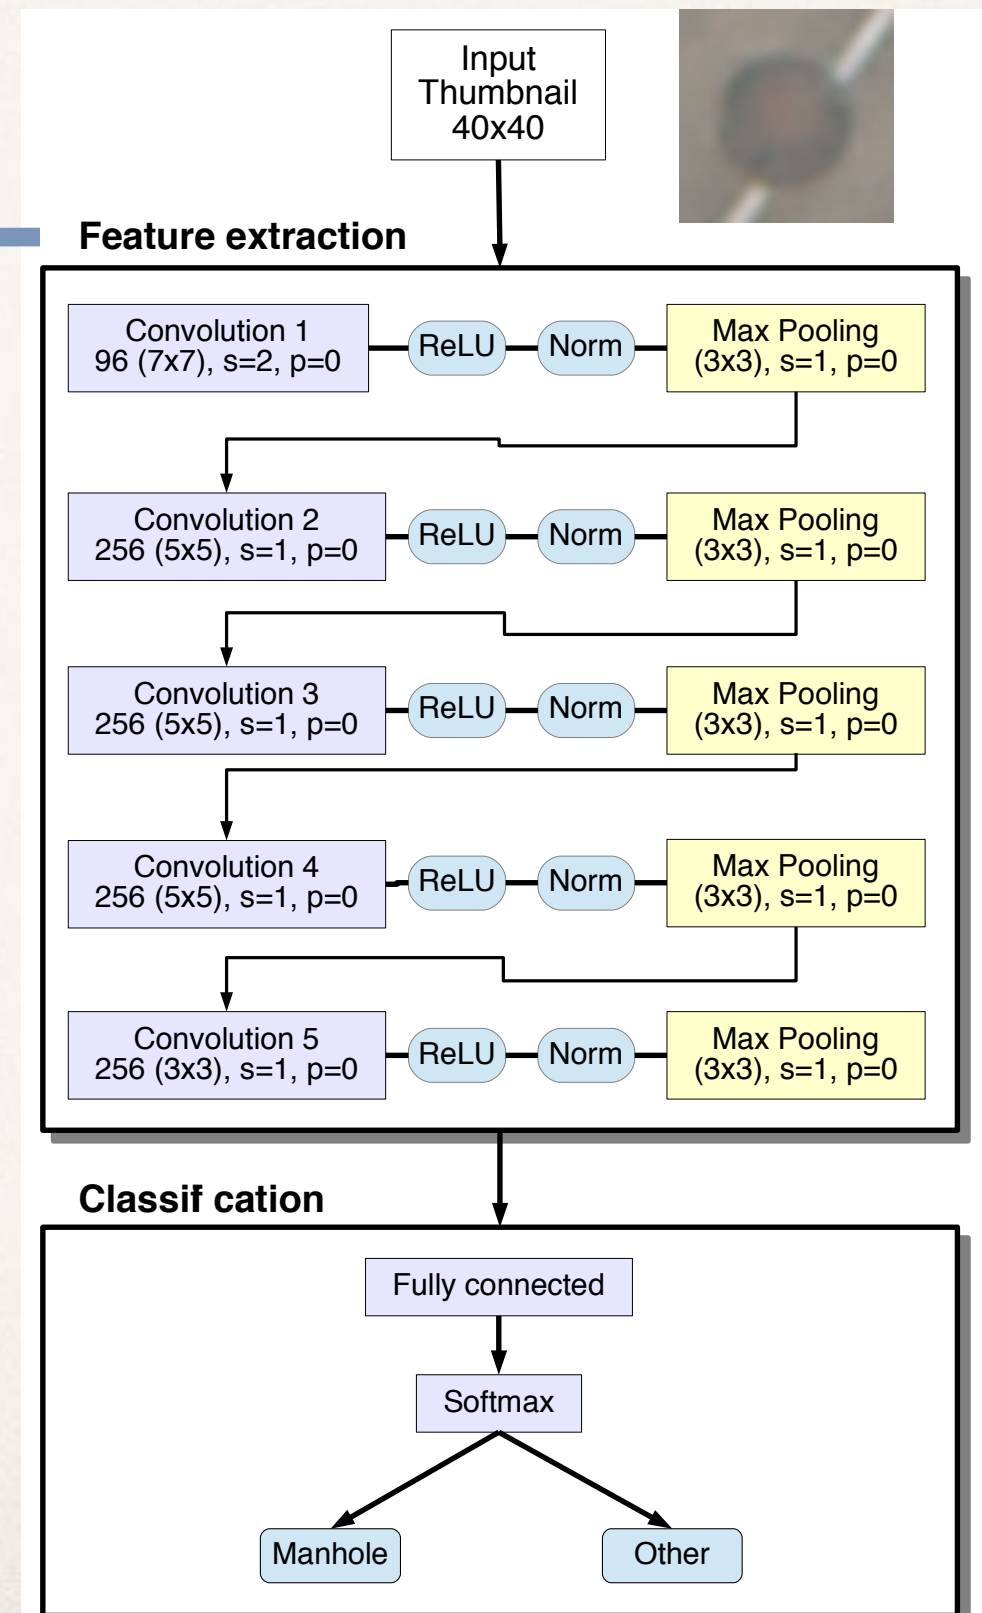
AlexNet + adaptation des paramètres aux petits objets



Convolutional Neural Network

AlexNet + adaptation des paramètres aux petits objets

5 couches avec différents paramètres ←

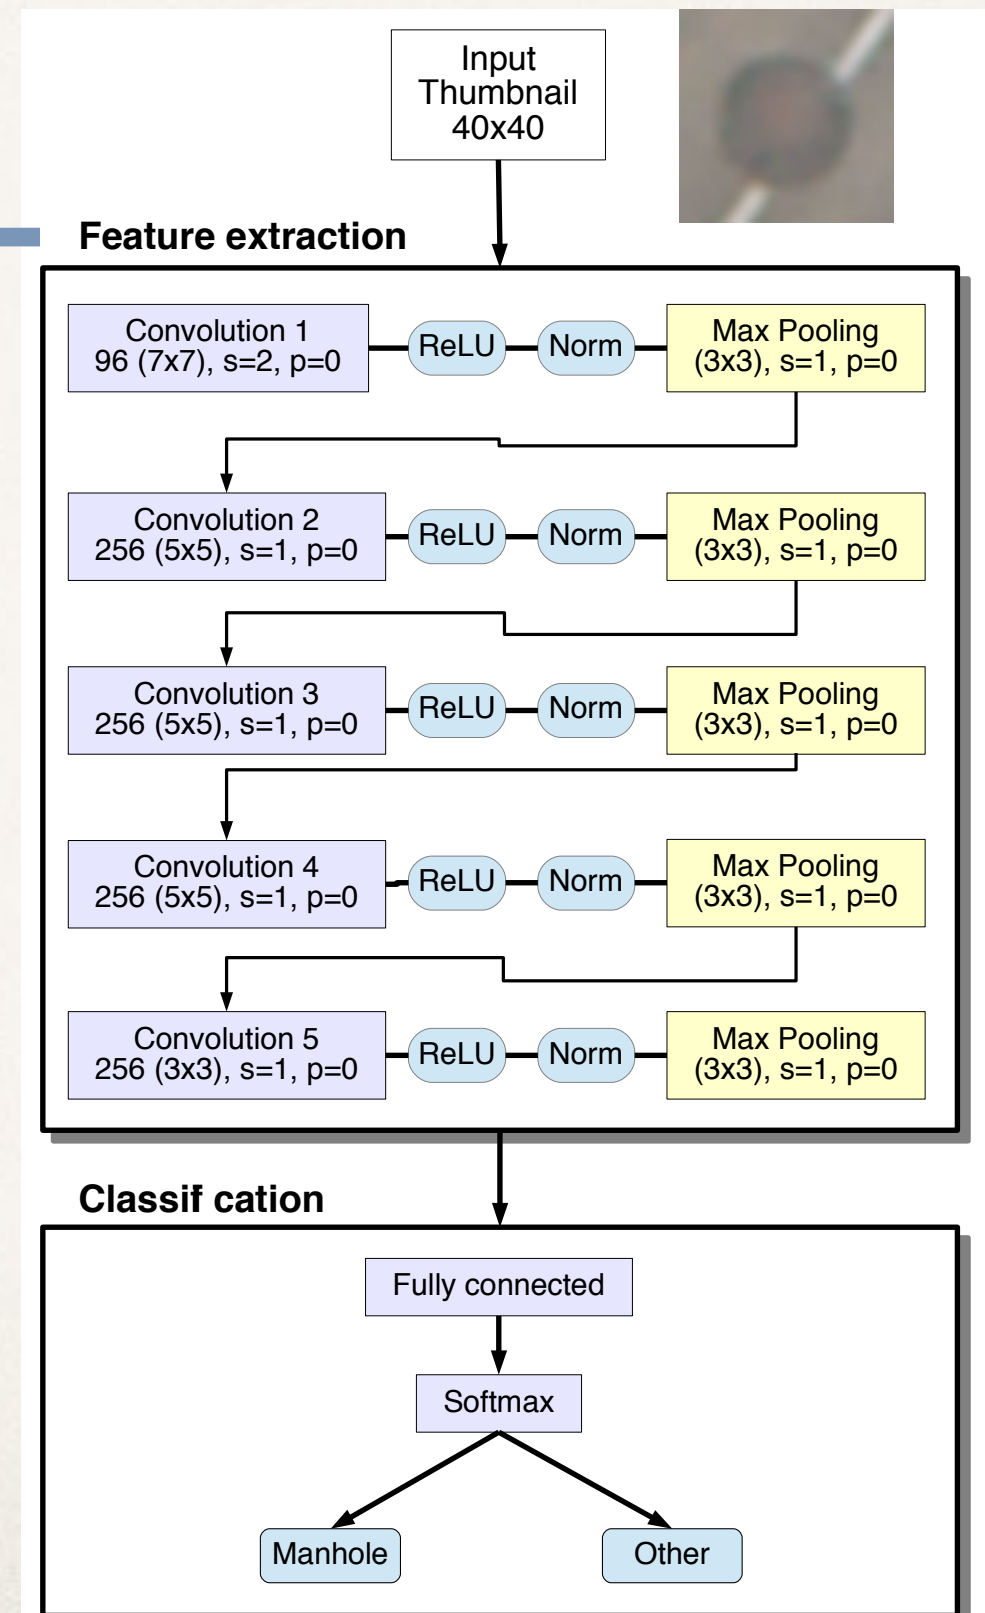


Convolutional Neural Network

AlexNet + adaptation des paramètres aux petits objets

5 couches avec différents paramètres ←

Initialisation aléatoire
des valeurs des noyaux
de convolution

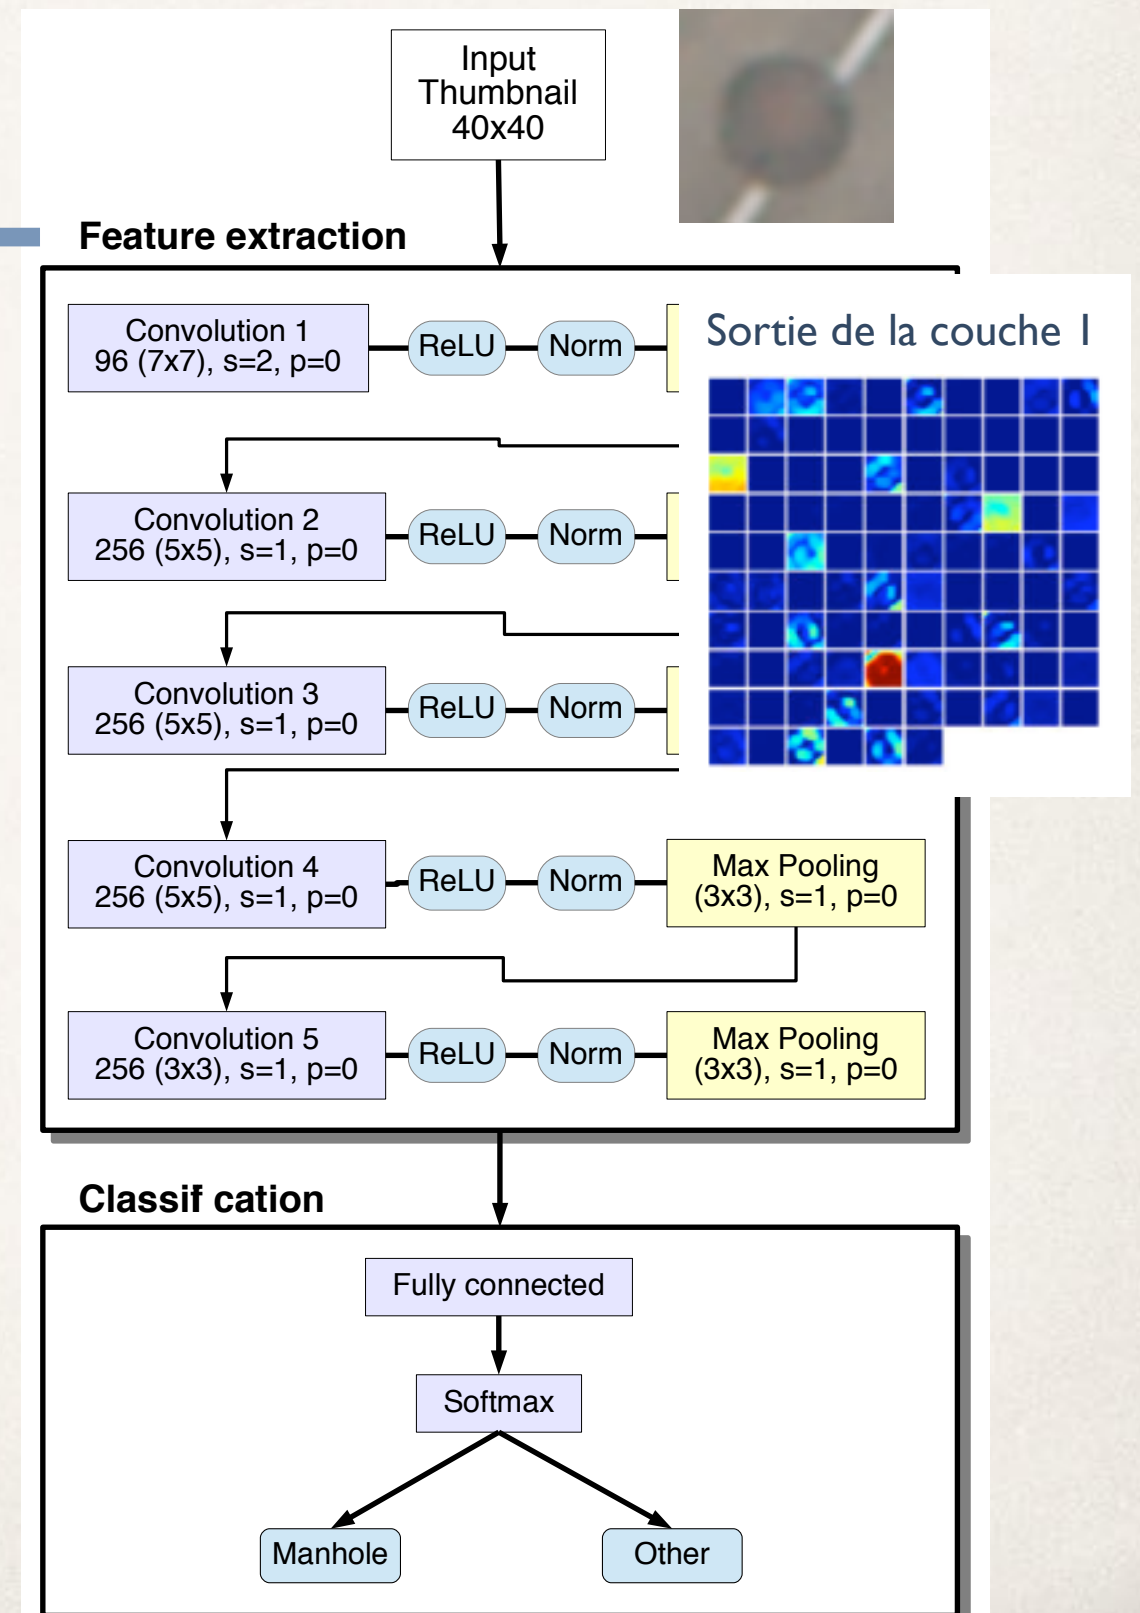


Convolutional Neural Network

AlexNet + adaptation des paramètres aux petits objets

5 couches avec différents paramètres ←

Initialisation aléatoire
des valeurs des noyaux
de convolution

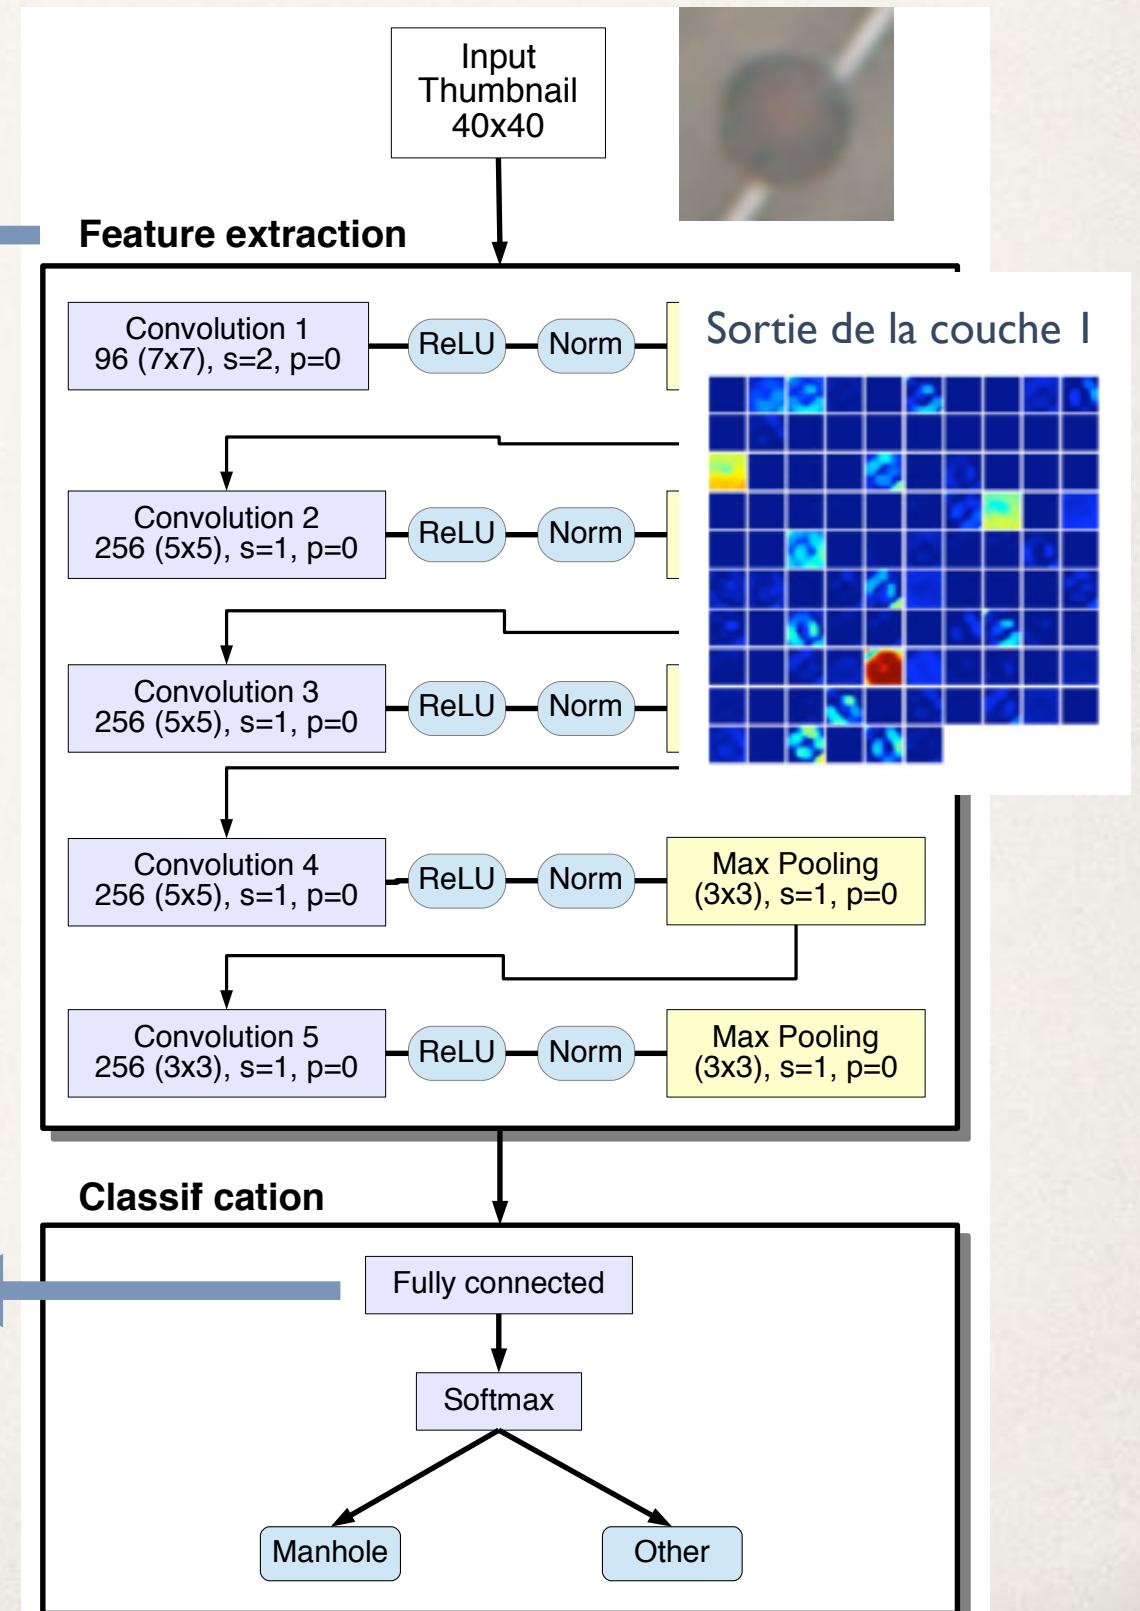


Convolutional Neural Network

AlexNet + adaptation des paramètres aux petits objets

5 couches avec différents paramètres ←

Initialisation aléatoire
des valeurs des noyaux
de convolution



← Fusion des résultats de chaque couche
Comparaison avec la vérité

Convolutional Neural Network

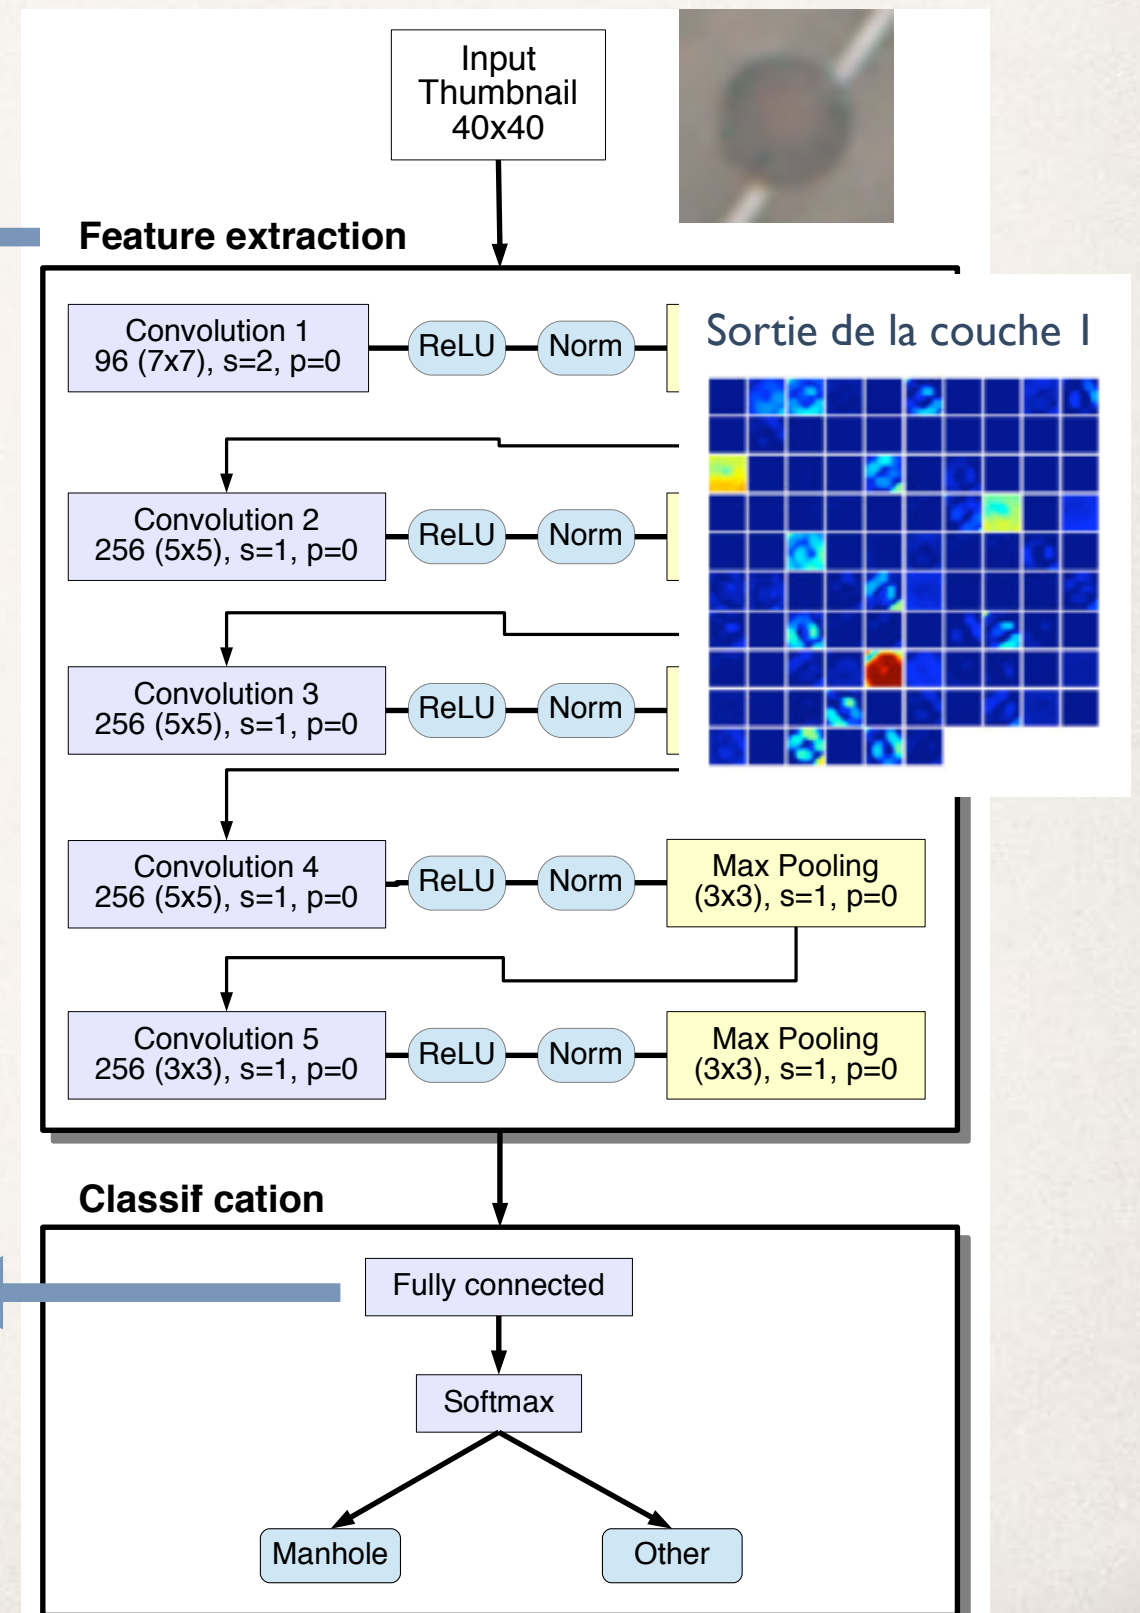
AlexNet + adaptation des paramètres aux petits objets

5 couches avec différents paramètres

~~Initialisation aléatoire
des valeurs des noyaux
de convolution~~

Modification
des valeurs des noyaux
de convolution

Fusion des résultats de chaque couche
Comparaison avec la vérité



Convolutional Neural Network

AlexNet + adaptation des paramètres aux petits objets

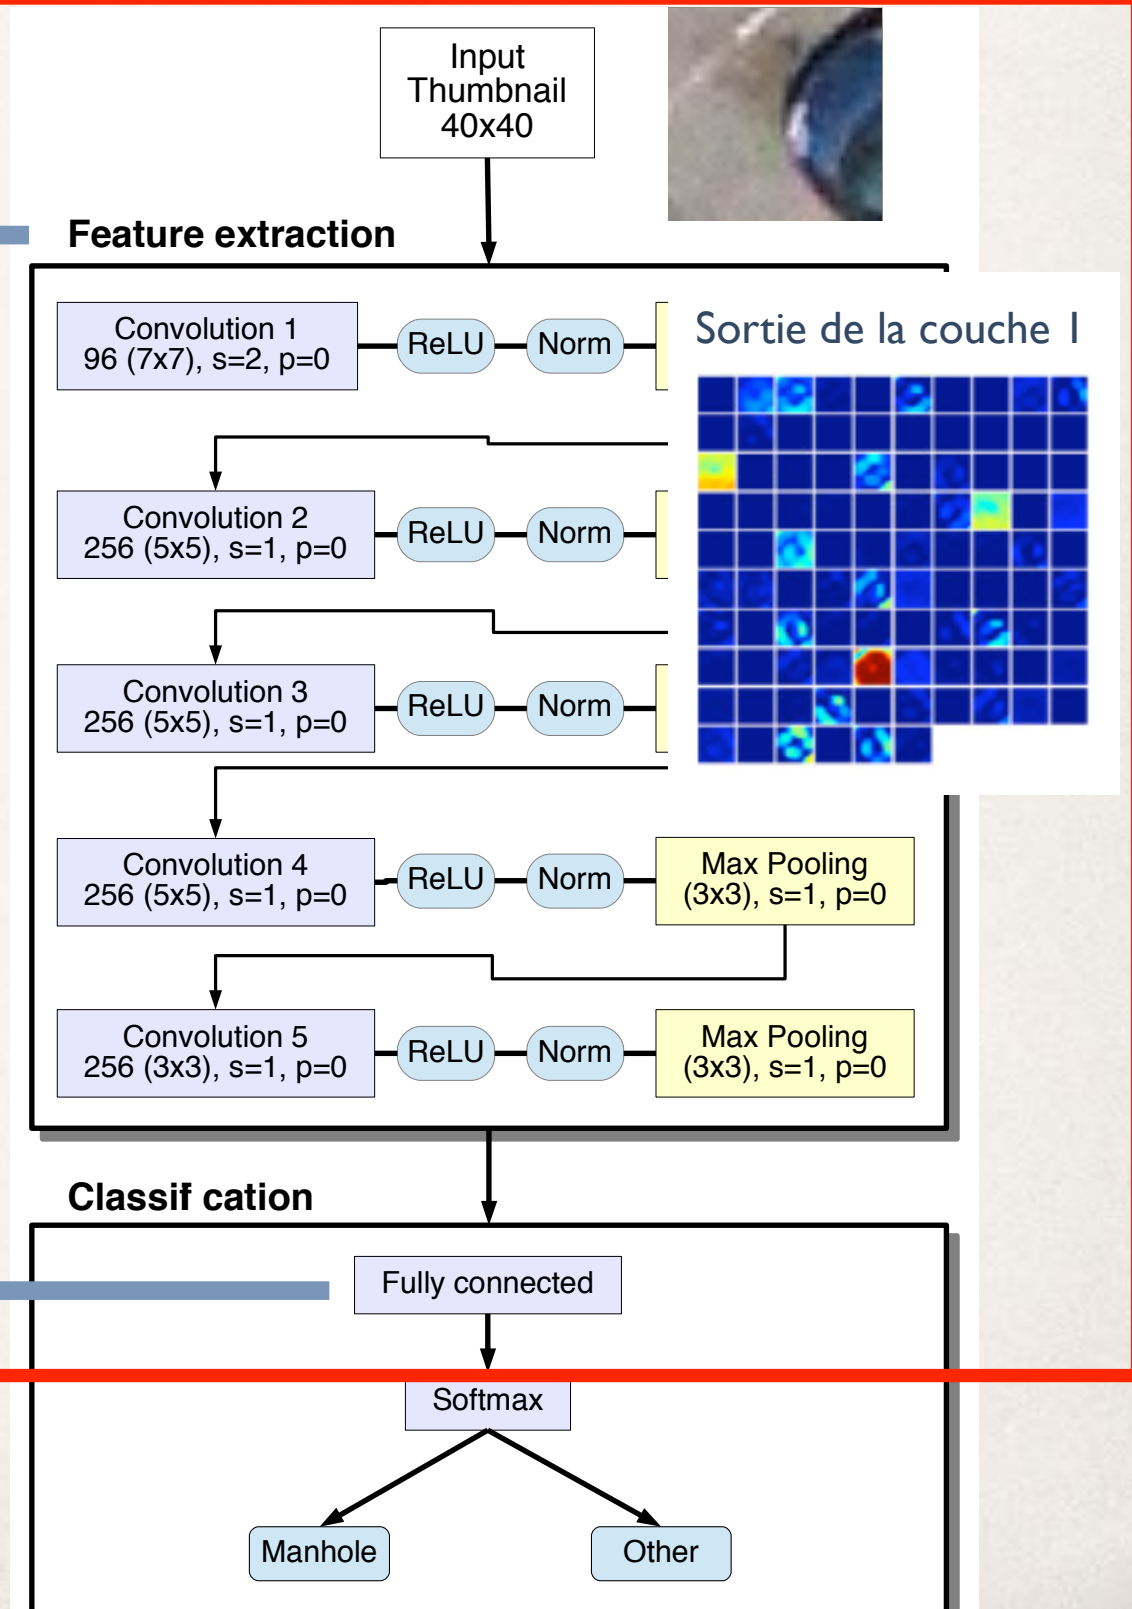
Apprentissage

5 couches avec différents paramètres

~~Initialisation aléatoire
des valeurs des noyaux
de convolution~~

Modification
des valeurs des noyaux
de convolution

Fusion des résultats de chaque couche
Comparaison avec la vérité



Convolutional Neural Network

AlexNet + adaptation des paramètres aux petits objets

Apprentissage

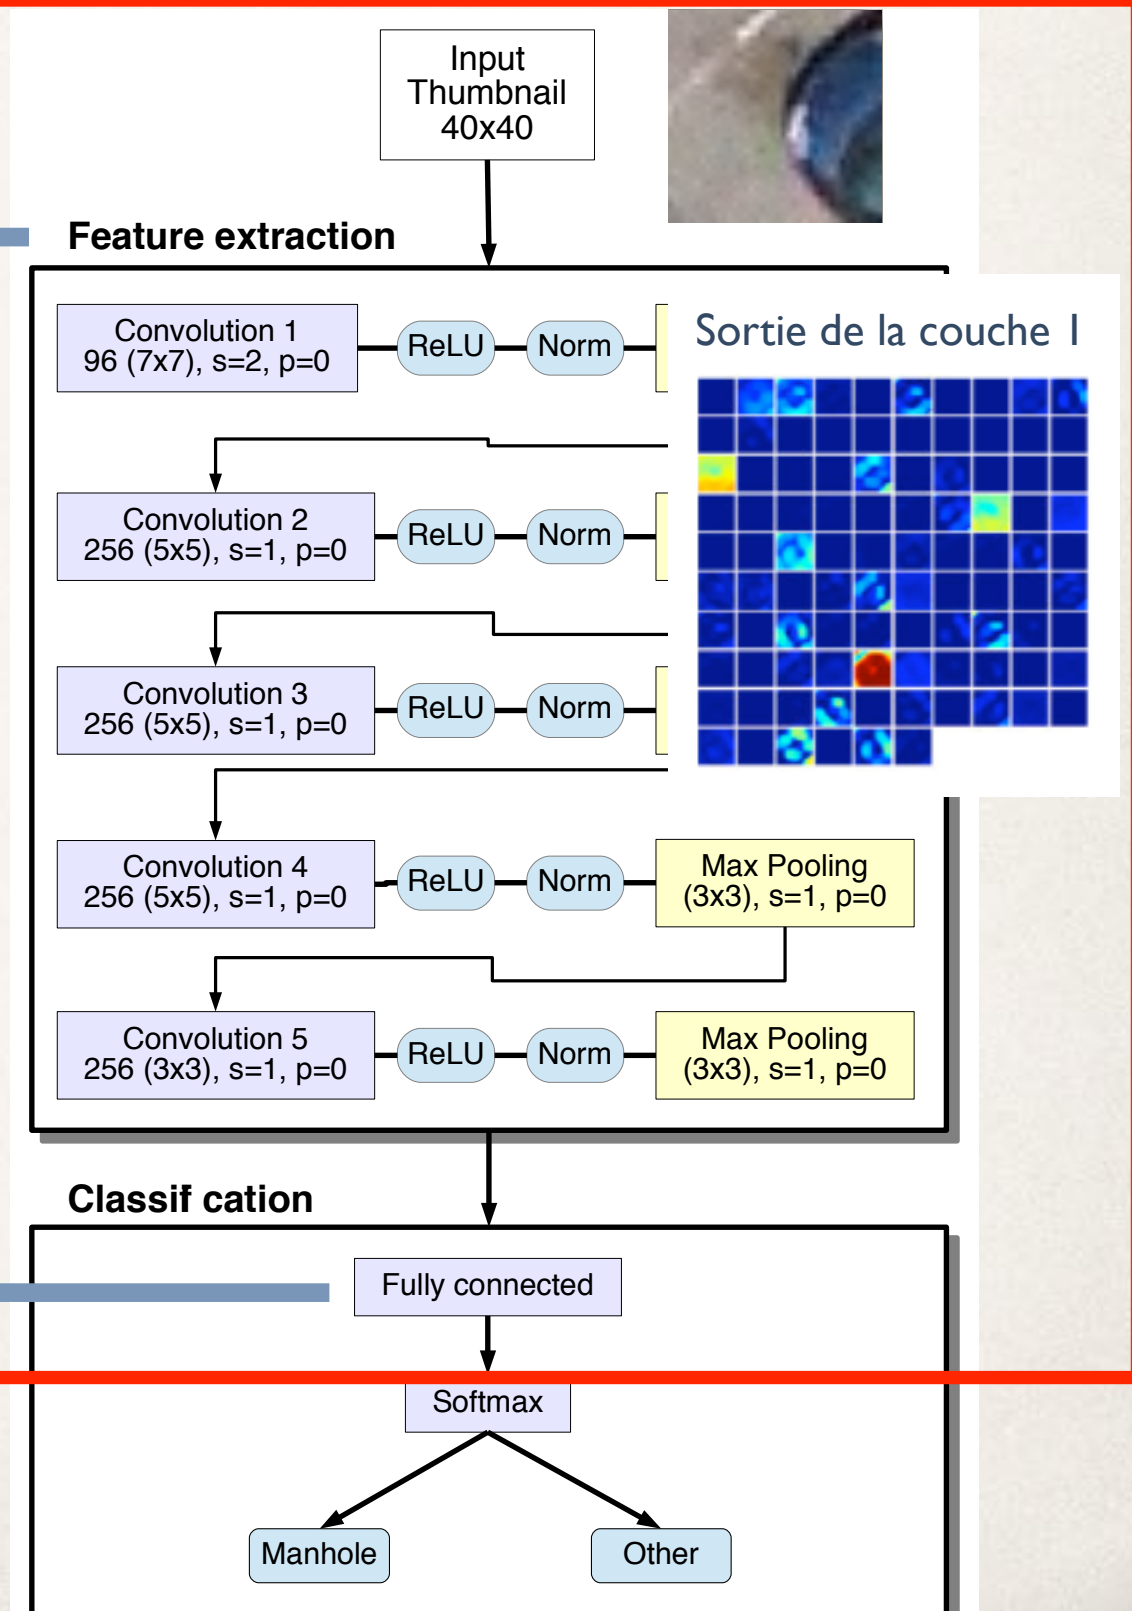
5 couches avec différents paramètres

~~Initialisation aléatoire des valeurs des noyaux de convolution~~

Modification des valeurs des noyaux de convolution

Fusion des résultats de chaque couche
Comparaison avec la vérité

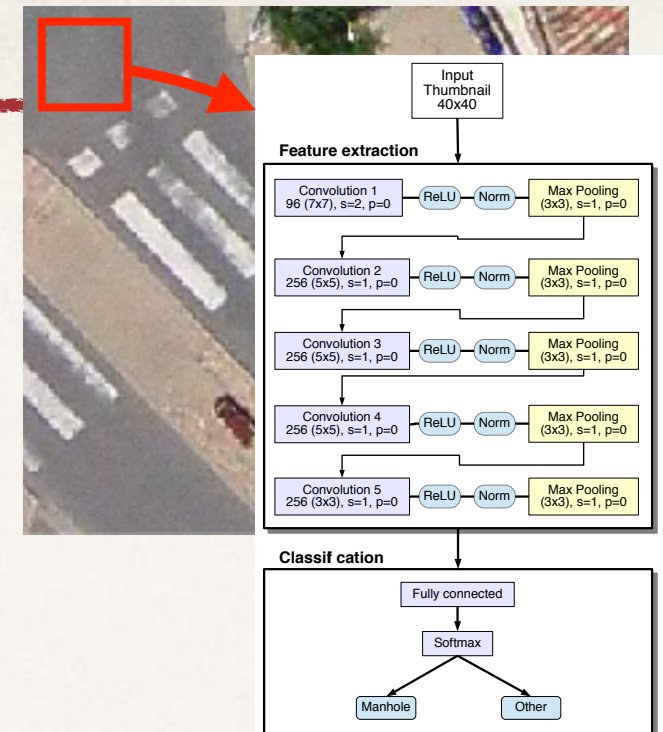
Proba d'appartenance à la classe plaque
Classification (seuillage)



Deep Learning: validation

Méthode:

- ▶ Fenêtre glissante (pas de 4 pixels) sur toute l'image
- ▶ CNN => probabilité d'appartenance à la classe « plaque »
- ▶ Seuil sur la probabilité => classification



Deep Learning: validation

Méthode:

- ▶ Fenêtre glissante (pas de 4 pixels) sur toute l'image
- ▶ CNN => probabilité d'appartenance à la classe « plaque »
- ▶ Seuil sur la probabilité => classification



Comparaison avec la vérité:

$$a_0 = \frac{\text{area}(B \cap B_t)}{\text{area}(B \cup B_t)}$$

Détection



Vérité




Deep Learning: validation

Méthode:

- ▶ Fenêtre glissante (pas de 4 pixels) sur toute l'image
- ▶ CNN => probabilité d'appartenance à la classe « plaque »
- ▶ Seuil sur la probabilité => classification

Comparaison avec la vérité:

$$a_0 = \frac{\text{area}(B \cap B_t)}{\text{area}(B \cup B_t)}$$


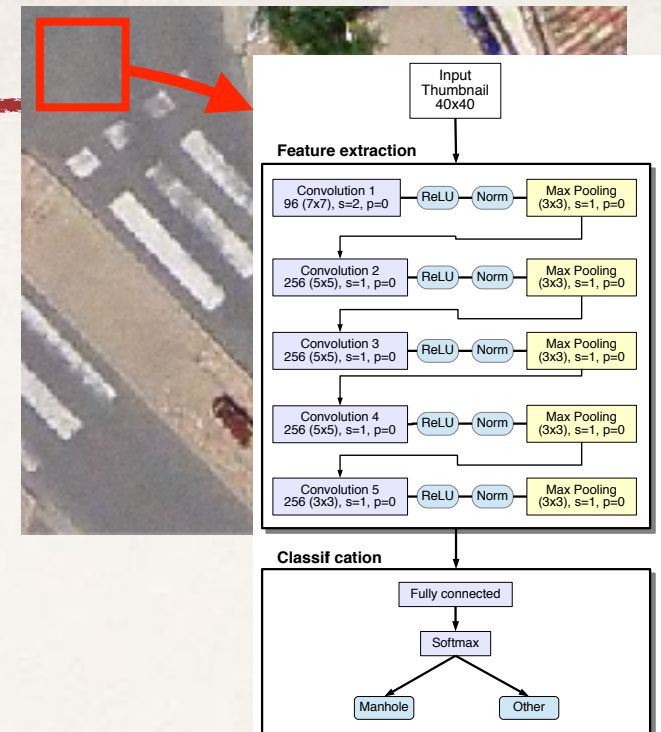


Définition précision / rappel:

- ▶ TP = True Positive = plaque correctement détectée: $a_0 > 50\%$
- ▶ FP = False Positive = image incorrectement classée comme « plaque »
- ▶ FN = False Negative = plaque non détectée

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$


$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$



Deep Learning: validation


Méthode:

- ▶ Fenêtre glissante (pas de 4 pixels) sur toute l'image
- ▶ CNN => probabilité d'appartenance à la classe « plaque »
- ▶ Seuil sur la probabilité => classification



Comparaison avec la vérité:

$$a_0 = \frac{\text{area}(B \cap B_t)}{\text{area}(B \cup B_t)}$$



Définition précision / rappel:

- ▶ TP = True Positive = plaque correctement détectée: $a_0 > 50\%$
- ▶ FP = False Positive = image incorrectement classée comme « plaque »
- ▶ FN = False Negative = plaque non détectée

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

Total détecté

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

Total vrai



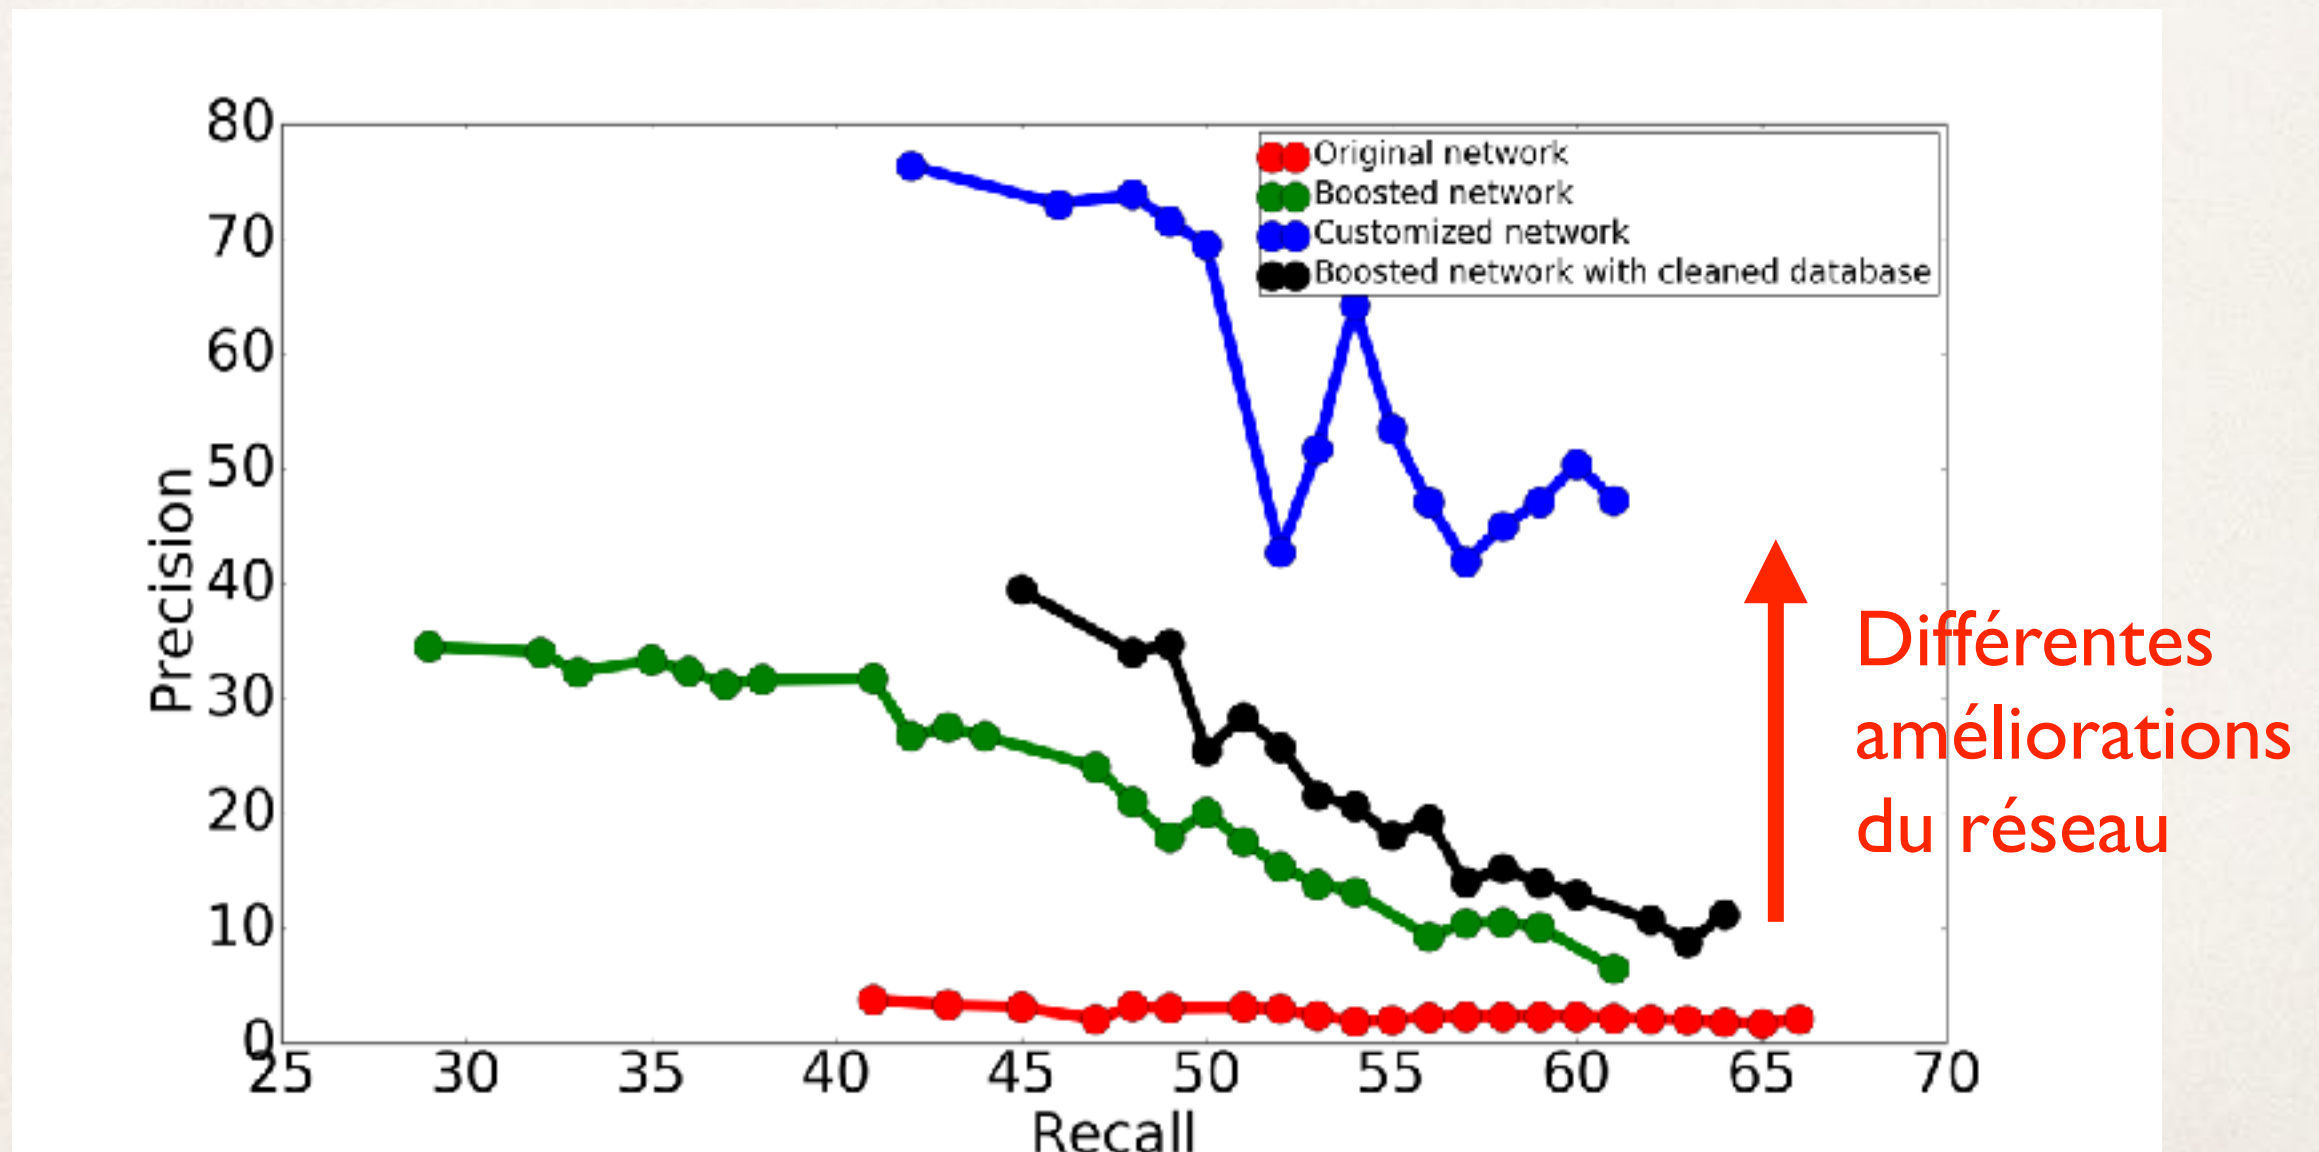
Deep Learning: validation

Validation:

- ▶ Gigan: 100 plaques - image RVB acquise avec le même capteur, même résolution

Courbes ROC:

- ▶ Précision en fonction du rappel pour différents seuils d'acceptation



Meilleurs taux de détection possible pour un seuil de 0.26

- ▶ Rappel = 60% — Précision = 47%

Beaucoup de faux positifs:

- ▶ Certaines plaques ne sont pas dans la base de données (=> autre réseau? Anciennes ou nouvelles plaques?)
- ▶ Tâches sur le sol
=> améliorer le contraste?
=> regrouper les détections trop proches?
- ▶ Beaucoup de Faux en dehors des routes
 - Filtre sur les routes => Rappel = 54% — Précision = 70%

Analyse des Résultats

11

Meilleurs taux de détection possible pour un seuil de 0.26

- ▶ Rappel = 60% — Précision = 47%

Beaucoup de faux positifs:

- ▶ Certaines plaques ne sont pas dans la base de données (=> autre réseau? Anciennes ou nouvelles plaques?)
- ▶ Tâches sur le sol
=> améliorer le contraste?
=> regrouper les détections trop proches?
- ▶ Beaucoup de Faux en dehors des routes
 - Filtre sur les routes => Rappel = 54% — Précision = 70%



Analyse des Résultats


11

Meilleurs taux de détection possible pour un seuil de 0.26

- ▶ Rappel = 60% — Précision = 47%

Beaucoup de faux positifs:

- ▶ Certaines plaques ne sont pas dans la base de données (=> autre réseau? Anciennes ou nouvelles plaques?)
- ▶ Tâches sur le sol
=> améliorer le contraste?
=> regrouper les détections trop proches?
- ▶ Beaucoup de Faux en dehors des routes
 - Filtre sur les routes => Rappel = 54% — Précision = 70%





Anal

Meille un seu

- ▶ Rap

Beauc

- ▶ Cer
(=>
- ▶ Tâc
=>
- ▶ Bea



Analyse des Résultats


11

Meilleurs taux de détection possible pour un seuil de 0.26

- ▶ Rappel = 60% — Précision = 47%

Beaucoup de faux positifs:

- ▶ Certaines plaques ne sont pas dans la base de données (=> autre réseau? Anciennes ou nouvelles plaques?)
- ▶ Tâches sur le sol
=> améliorer le contraste?
=> regrouper les détections trop proches?
- ▶ Beaucoup de Faux en dehors des routes
 - Filtre sur les routes => Rappel = 54% — Précision = 70%



60% de plaques détectées sur une image à 5cm

- ▶ Mieux que les relevés terrain effectués par les entreprises (1 plaque sur 3)

Mais au moins 25% de faux positifs:

- ▶ Utiliser l'information des routes (ou prétraitement d'image) pour accélérer les calculs et améliorer les résultats
- ▶ Associer un indice de confiance à la localisation des plaques (utile lors de la cartographie)

Fin de Cart'Eaux (fin 2018)

- ▶ Validation sur des images de Poitier (7,5cm de résolution)
- ▶ Mise en ligne d'un démonstrateur de la chaîne complète (détection, cartographie, fouille de texte)
- ▶ Ajout d'une couche d'information issue du filtre géométrique dans l'apprentissage
- ▶ Projet MéDo de fouille de données et analyse de texte



60% de plaques détectées sur une image à 5cm

- ▶ Mieux que les relevés terrain effectués par les entreprises (1 plaque sur 3)


Mais au moins 25% de faux positifs:

- ▶ Utiliser l'information des routes (ou prétraitement d'image) pour accélérer les calculs et améliorer les résultats
- ▶ Associer un indice de confiance à la localisation des plaques (utile lors de la cartographie)


Fin de Cart'Eaux (fin 2018)

- ▶ Validation sur des images de Poitiers (7,5cm de résolution)
- ▶ Mise en ligne d'un démonstrateur de la chaîne complète (détection, cartographie, fouille de texte)
- ▶ Ajout d'une couche d'information issue du filtre géométrique dans l'apprentissage
- ▶ Projet MéDo de fouille de données et analyse de texte

Plaques



Autres



Conclusion et perspectives


60% de plaques détectées sur une image à 5cm

- ▶ Mieux que les relevés terrain effectués par les entreprises (1 plaque sur 3)


Mais au moins 25% de faux positifs:

- ▶ Utiliser l'information des routes (ou prétraitement d'image) pour accélérer les calculs et améliorer les résultats

Plaques




Autres



Pour aller plus loin...

Distinction plaques / avaloirs

Détection des fossés ...



Pour aller plus loin...

Distinction plaques / avaloirs

Détection des fossés ...



Détection de regards de visite sur des images à THRS par une méthode d'apprentissage

COMMANDRE Benjamin, EN-NEJJARY Driss, PIBRE Lionel, CHAUMONT
Marc, SUBSOL Gérard, DERUELLE Laurent, DERRAS Mustapha,
DELENNE Carole, CHAHINIAN Nanée

Univ. Montpellier - HydroSciences Montpellier
Equipe INRIA Lemon

