IFT 615 – Intelligence artificielle

Vision par ordinateur

Hugo Larochelle
Département d'informatique
Université de Sherbrooke
http://www.dmi.usherb.ca/~larocheh/cours/ift615.html

Sujets couverts

- Opérations bas niveau sur les images
  - détection de contour
  - calcul de gradients d'image
- Reconnaissance d'objets
  - à base de caractéristiques (histogramme de gradients)
  - à l'aide d'un réseau de neurones à convolution

Mise en situation

- La vue est un sens très utile à la survie d'un organisme
  - apporte beaucoup d'information sur son environnement (nourriture, prédateur, etc.)
- Presque toutes les créatures intelligentes sont dotées de vision
- Chez l'humain ≈25% du cerveau sert à la vision
  - pour l'ouïe, c'est ≈8%
  - pour le touché, c'est ≈3%
- Ça donne une idée de la complexité de la tâche à résoudre...

Mise en situation

- Applications liées à la vision par ordinateur

Reconnaissance de caractères

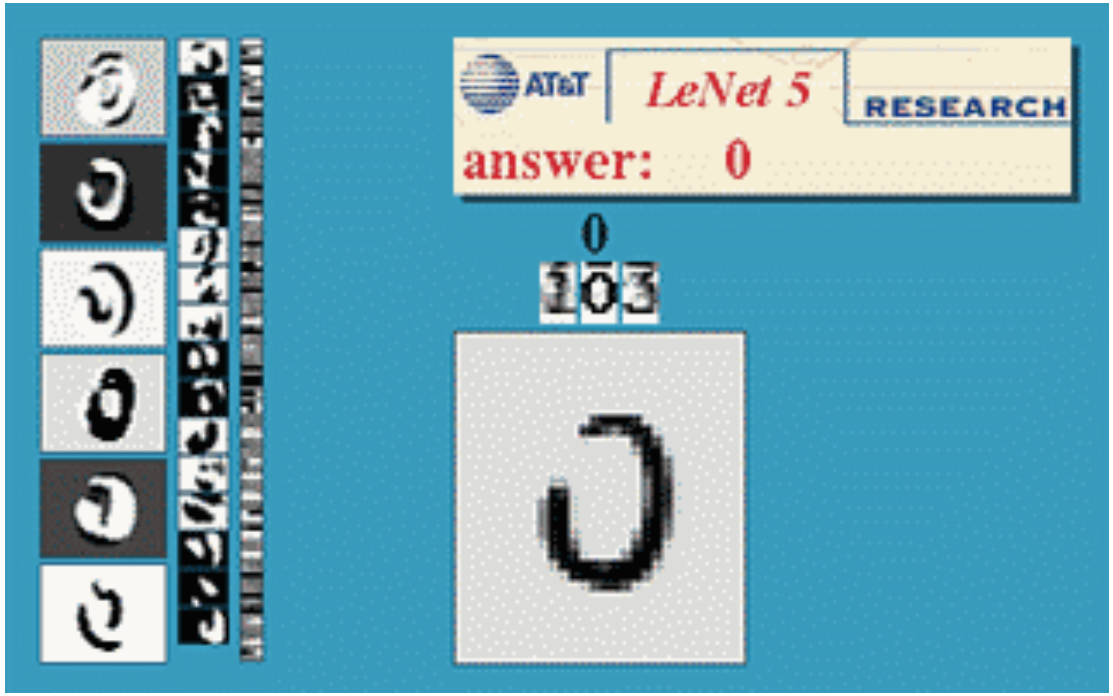

Mise en situation

- Applications liées à la vision par ordinateur

Détection de visages

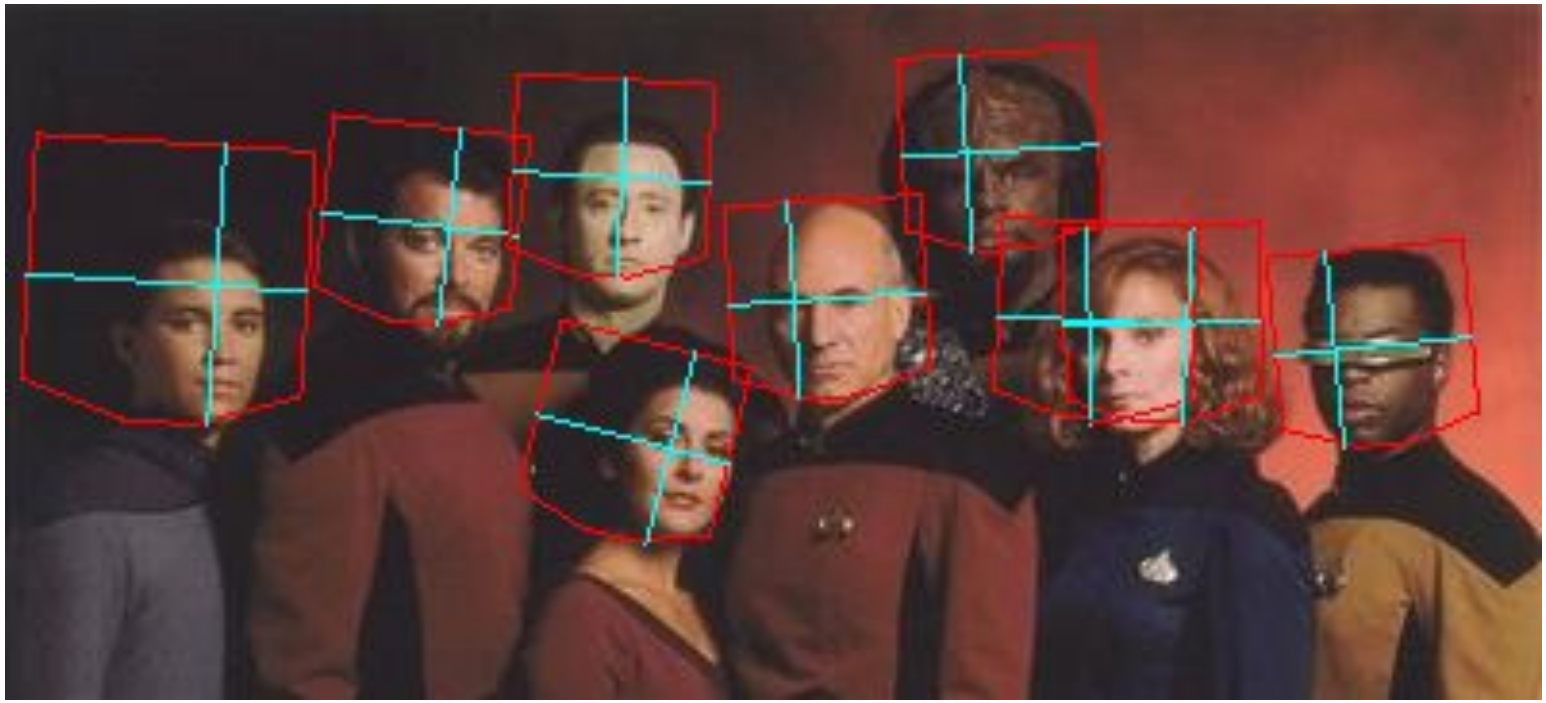

Mise en situation

- Applications liées à la vision par ordinateur

Recherche d'images par contenu

http://images.google.com/

Mise en situation

- Applications liées à la vision par ordinateur

Suivi d'objets

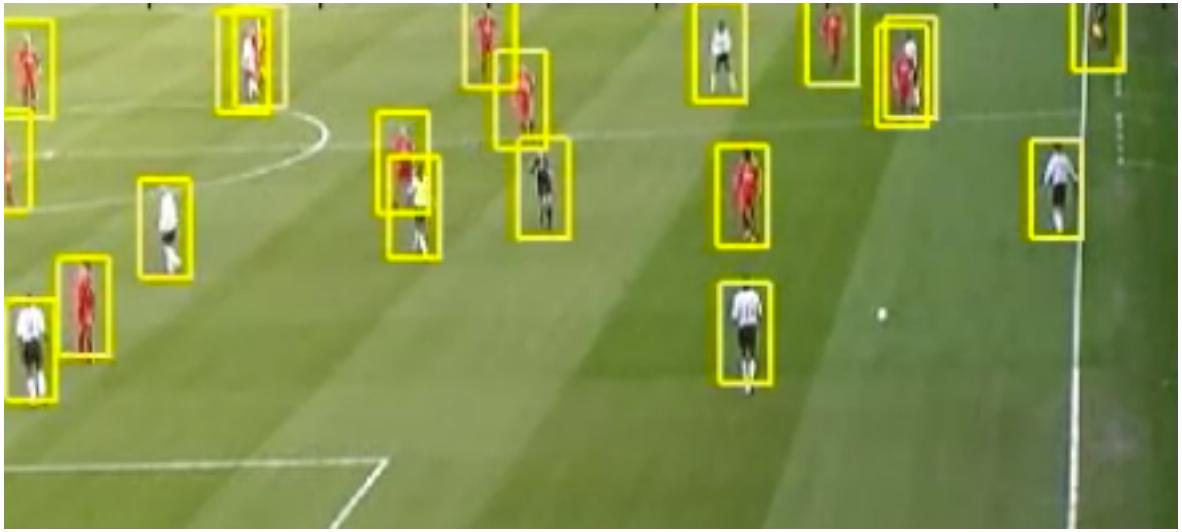

http://www.youtube.com/watch?v=fRowYlxKt7s

Dans ce cours...

- On va voir comment on manipule des images
  - quelle représentation de base utiliser
  - quel genre de prétraitements sont utiles
- L'objectif est d'avoir une vue d'ensemble des approches suivies en vision par ordinateur
- On va discuter des concepts fréquemment utilisés en vision
  - convolution
  - gradients d'image
  - histogramme
  - « *pooling* »

Représentation brute d'une image

- Image en niveau de gris: tableau 2D de pixels, entiers positifs de 8 bits

X =

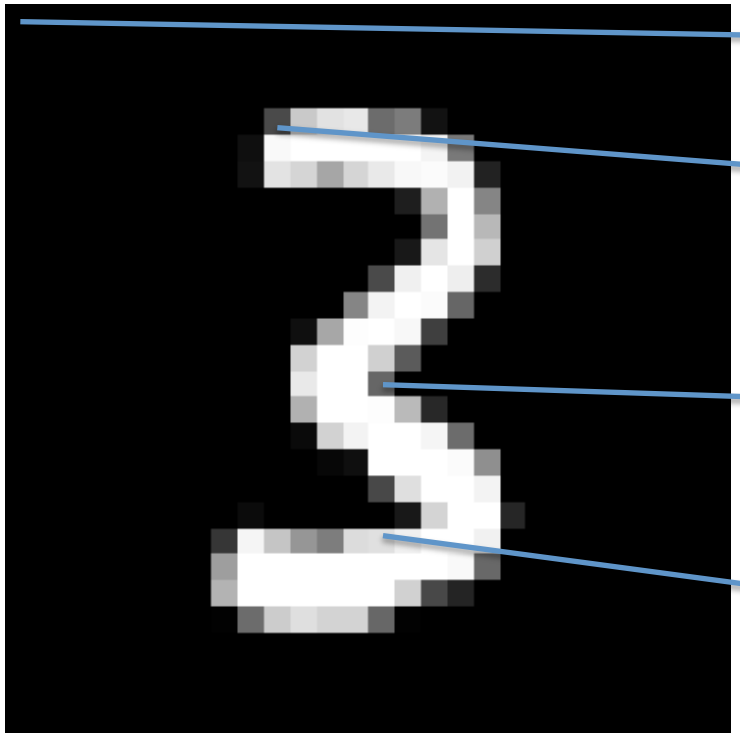

X[0,0] = 0

X[4,10] = 47

X[14,14] = 65

X[20,14] = 191

Représentation brute d'une image

- Image en couleur: tableau 3D de pixels RGB, entiers positifs de 8 bits

X =

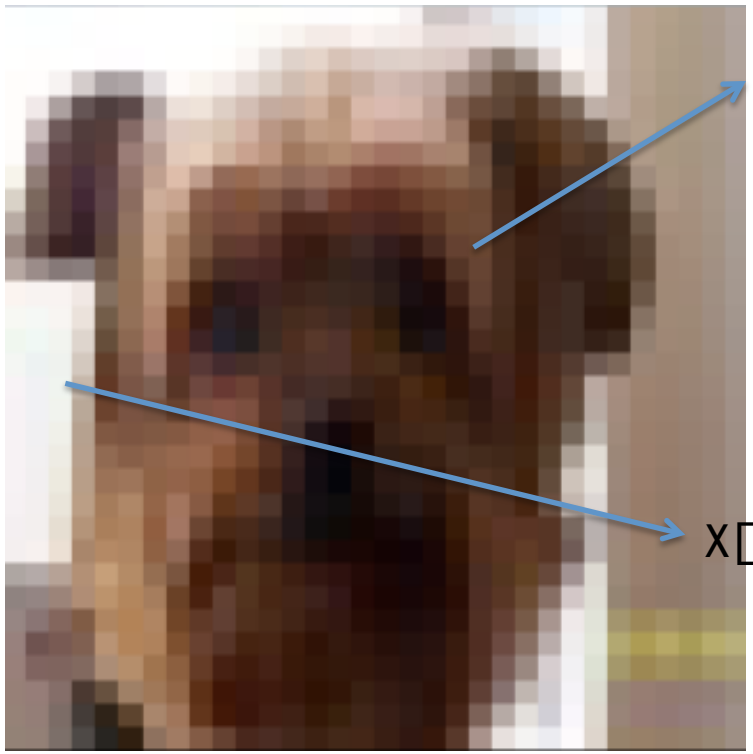

X[10,20,:] = array([85, 54, 37])

R G B

X[16,2,:] = array([237, 241, 234])

Opérations bas niveau sur les images

- La représentation sous forme de pixels a des désavantages
  - elle est lourde, c.-à-d. coûteuse en mémoire
    - » 1024x1024 pixels de 8 bits (en niveau de gris) = 1 MB / image
    - » 1024x1024 pixels de 24bits (canaux RGB) = 3 MB / image
  - elle contient plus d'information qu'on en a besoin
    - » pour détecter une voiture dans une image, la couleur n'est pas utile
    - » la scène (arrière plan) dans laquelle se trouve un objet à détecter peut être ignorée
- On aimerait appliquer des **opérations bas niveau simples** (**prétraitement**) sur les images, afin d'y **extraire l'information pertinente** pour la tâche à résoudre

Détection de contour

- Un contour est une changement soudain dans l'intensité/couleur de pixels adjacents

image originale

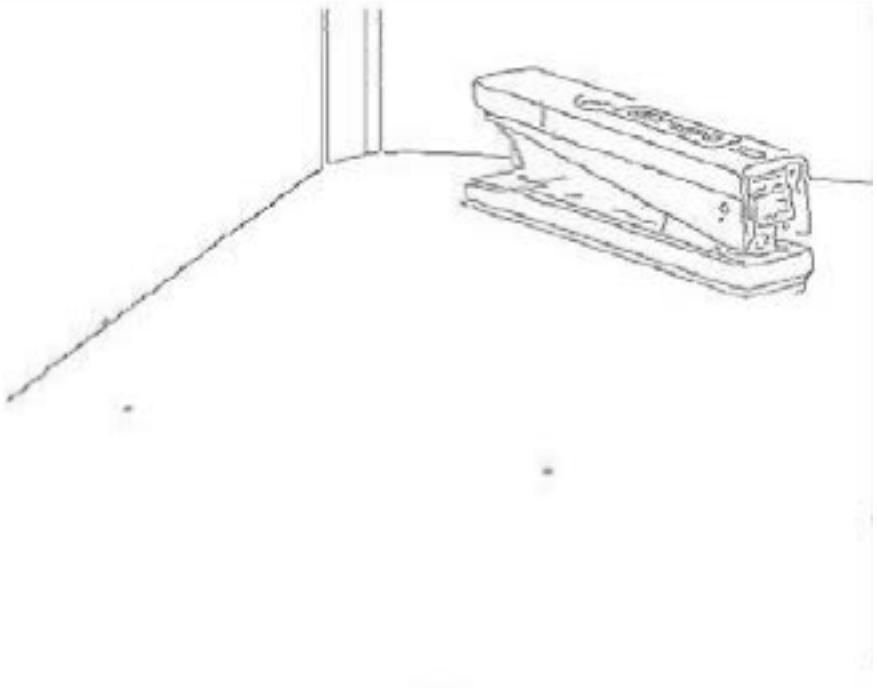

extraction des contours

Détection de contour

- Qu'est-ce qui cause des contours?

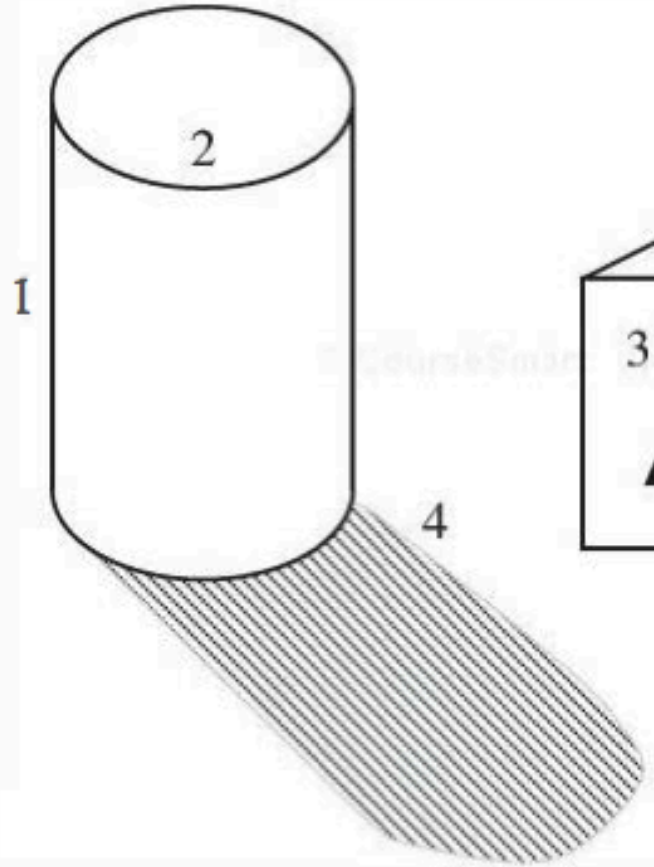

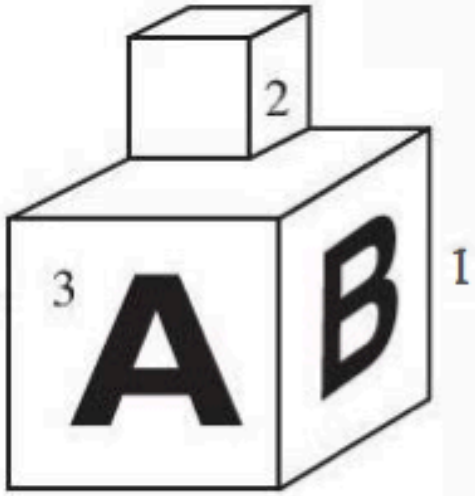

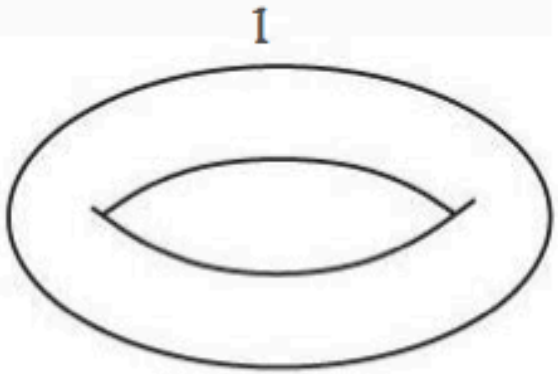

1- changement de profondeur
2- changement d'orientation de surface
3- changement de couleur (réflexion)
4- changement d'illumination

Gradient d'image

- Pour détecter si un pixel est sur la frontière d'un contour, on peut regarder la valeur relative des pixels autour de ce pixel

- Exemple: variation **horizontale** $H[i,j] = X[i,j+1] - X[i,j]$

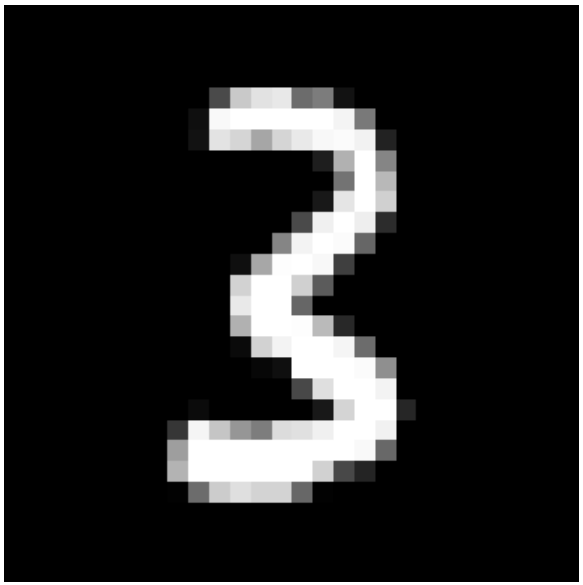

X

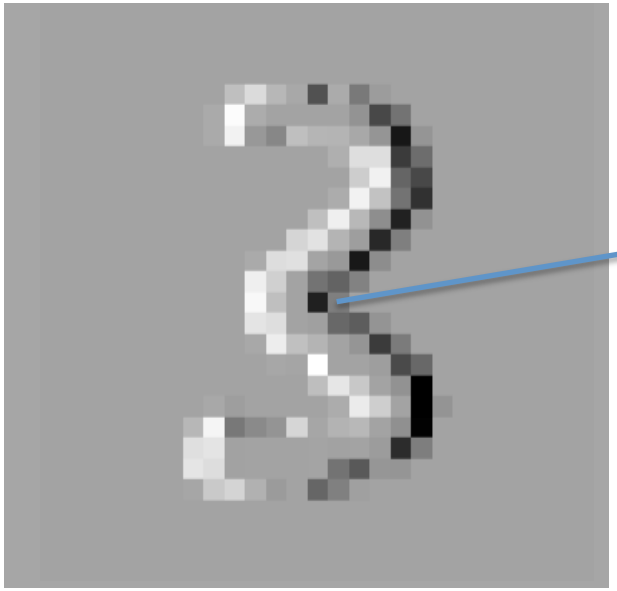

H

Gradient d'image

- Pour détecter si un pixel est sur la frontière d'un contour, on peut regarder la valeur relative des pixels autour de ce pixel

- Exemple: variation **verticale** `V[i,j] = X[i+1,j] – X[i,j]`

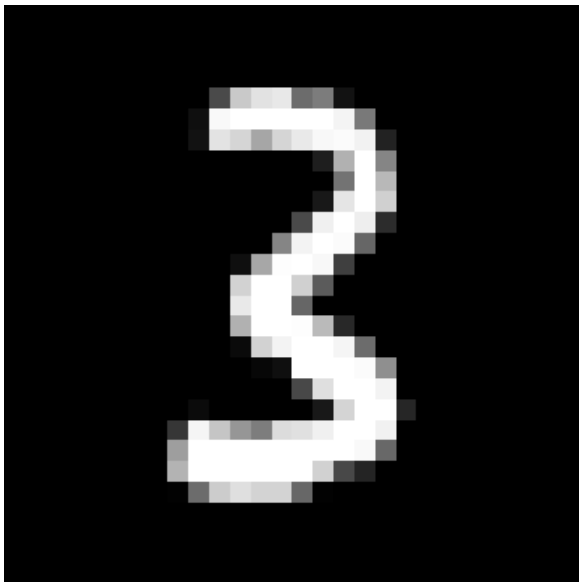

X

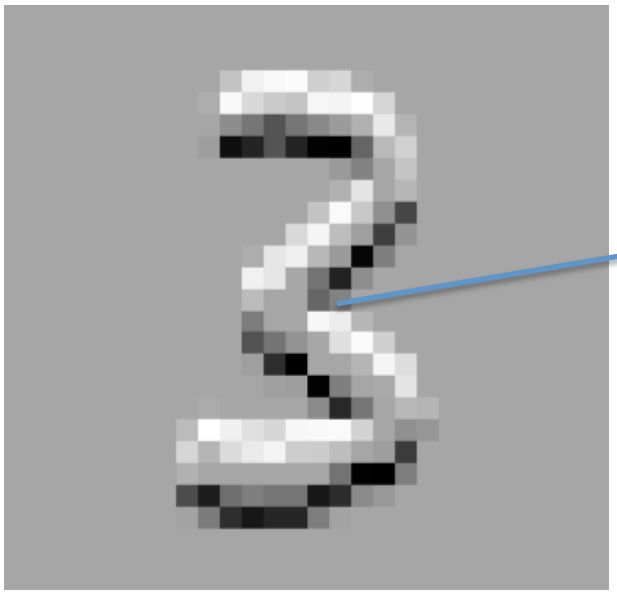

V

Gradient d'image

- Un pixel ferait partie d'un contour si la somme des variations (positive ou négative) horizontale et verticale est élevée

```
E[i,j] = sqrt(V[i,j]**2 + H[i,j]**2)
```

- On applique un seuil pour déterminer si contour ou pas

X

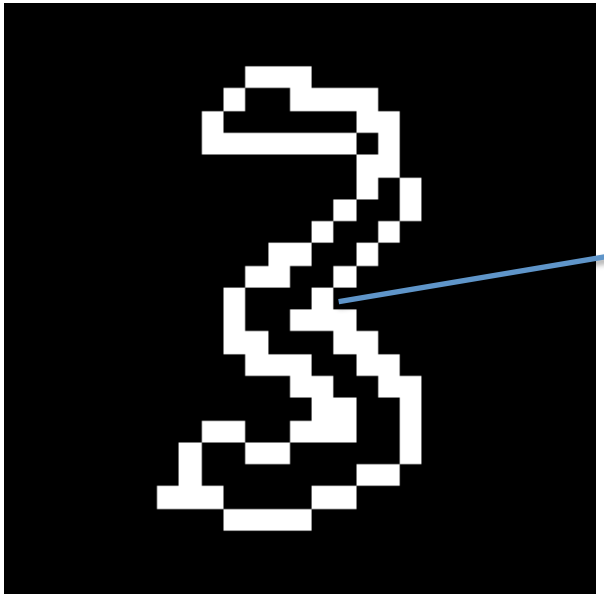

E > 128

Gradient d'image

- On peut voir le calcul des variations comme des dérivées partielles
- La « fonction » $f(a,b)$ serait la valeur de l'image à la position (a,b)

$$\frac{\partial f(a,b)}{\partial b} = \lim_{\Delta \to 0} \frac{f(a,b+\Delta) - f(a,b)}{\Delta} \approx \underbrace{\texttt{X[i,j+1] - X[i,j]}}_{\Delta = 1} = \texttt{H[i,j]}$$

$$\frac{\partial f(a,b)}{\partial a} = \lim_{\Delta \to 0} \frac{f(a+\Delta,b) - f(a,b)}{\Delta} \approx \overbrace{\texttt{X[i+1,j] - X[i,j]}}^{\Delta = 1} = \texttt{V[i,j]}$$

Gradient d'image

- Si `H[i,j]` et `V[i,j]` sont les dérivées partielles de l'image, alors

```
G[i,j,:] = [ H[i,j], V[i,j] ]
```

  est le **gradient de l'image**, à la position `(i,j)`

- La détection des contours vue précédemment calculait donc la norme euclidienne de ces gradients

```
E[i,j] = sqrt(V[i,j]**2 + H[i,j]**2) = sqrt(sum(G[i,j,:]**2))
```

  norme du vecteur `G[i,j,:]`

- On peut visualiser ce gradient (vecteur) à chaque pixel

Champ de vecteurs gradient

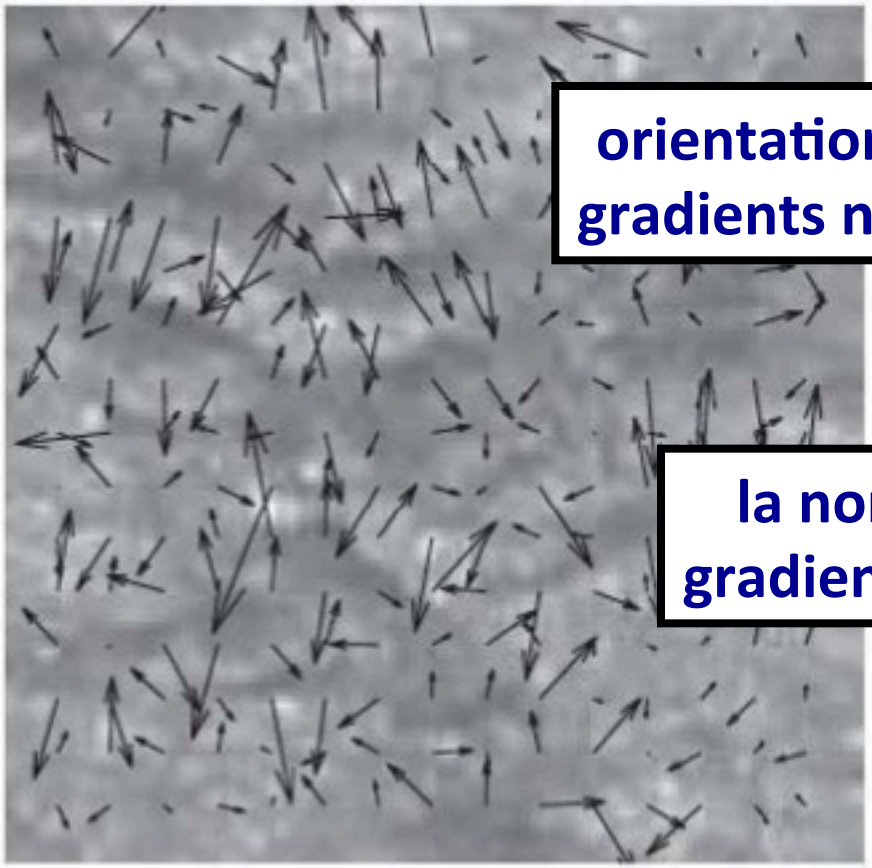

orientation (angle) des gradients ne change pas

la norme des gradients change

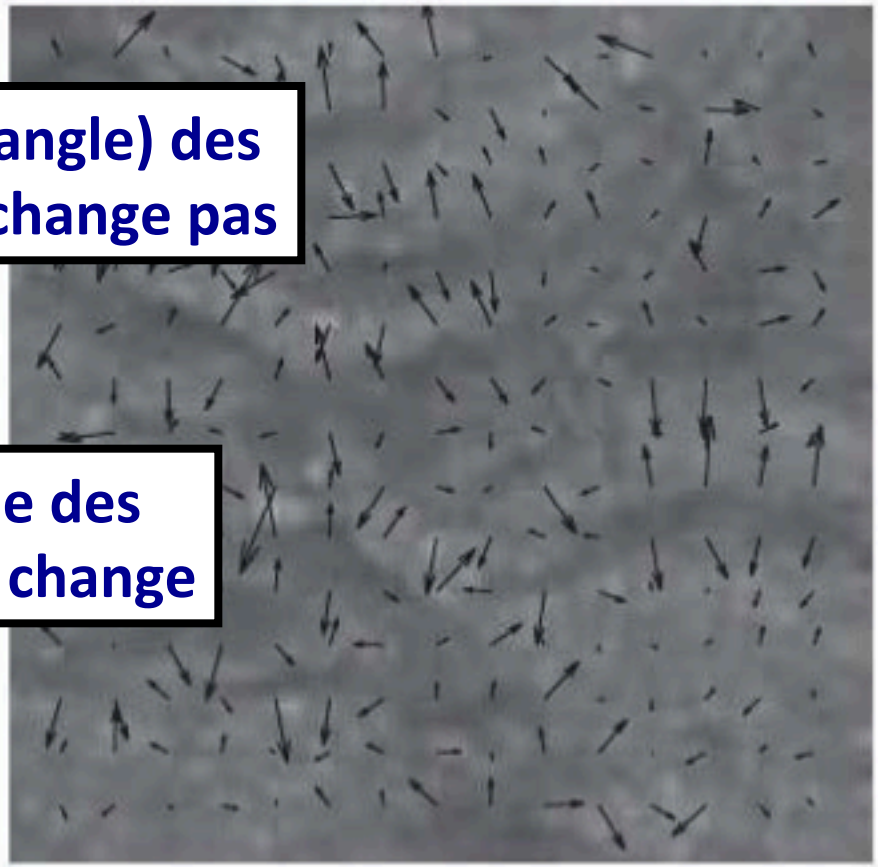

image X

image X avec moins d'illumination

Convolution

- Le calcul des tableaux H et V peut être vu comme l'application d'une **convolution**

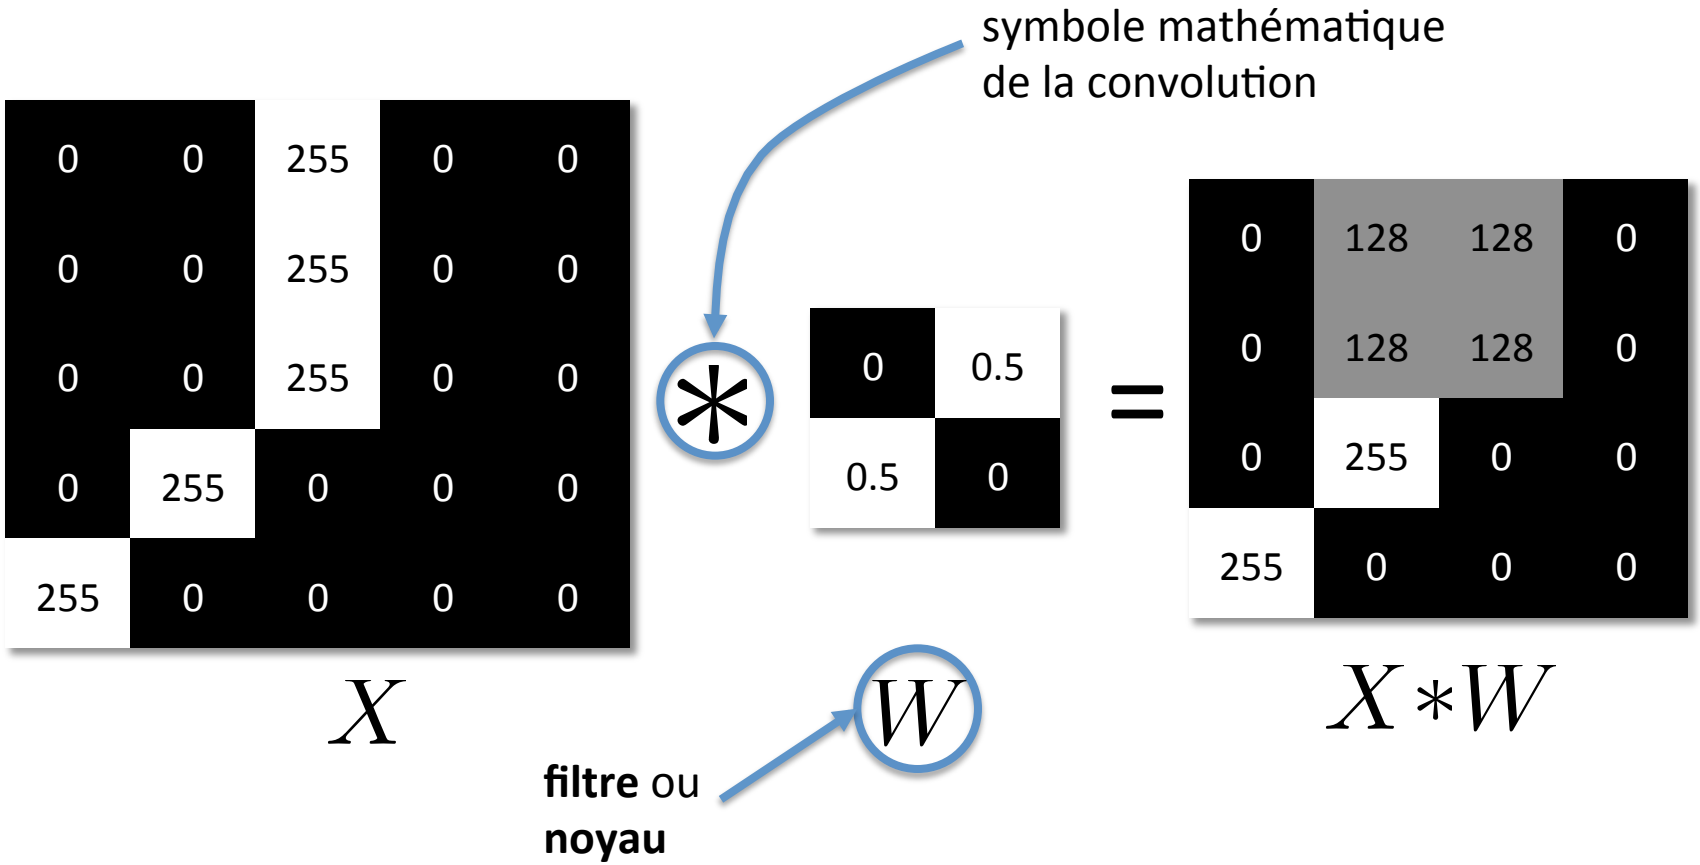

Convolution

- Le calcul des tableaux H et V peut être vu comme l'application d'une **convolution**

- On calcule le résultat C d'une convolution d'un **filtre** ou **noyau** W de taille h par w sur une image X comme suit

```
def convolution(X,W):
  h,w = W.shape
  C = zeros((X.shape[0]-h+1,X.shape[1]-w+1))
  for i in range(X.shape[0]-h+1):
    for j in range(X.shape[1]-w+1):
      C[i,j] = sum(X[i:i+h,j:j+w] * W)
  return C
```

Convolution

- Calculer H est l'équivalent de faire une convolution avec le filtre
  `W = array([[-1,1]])`

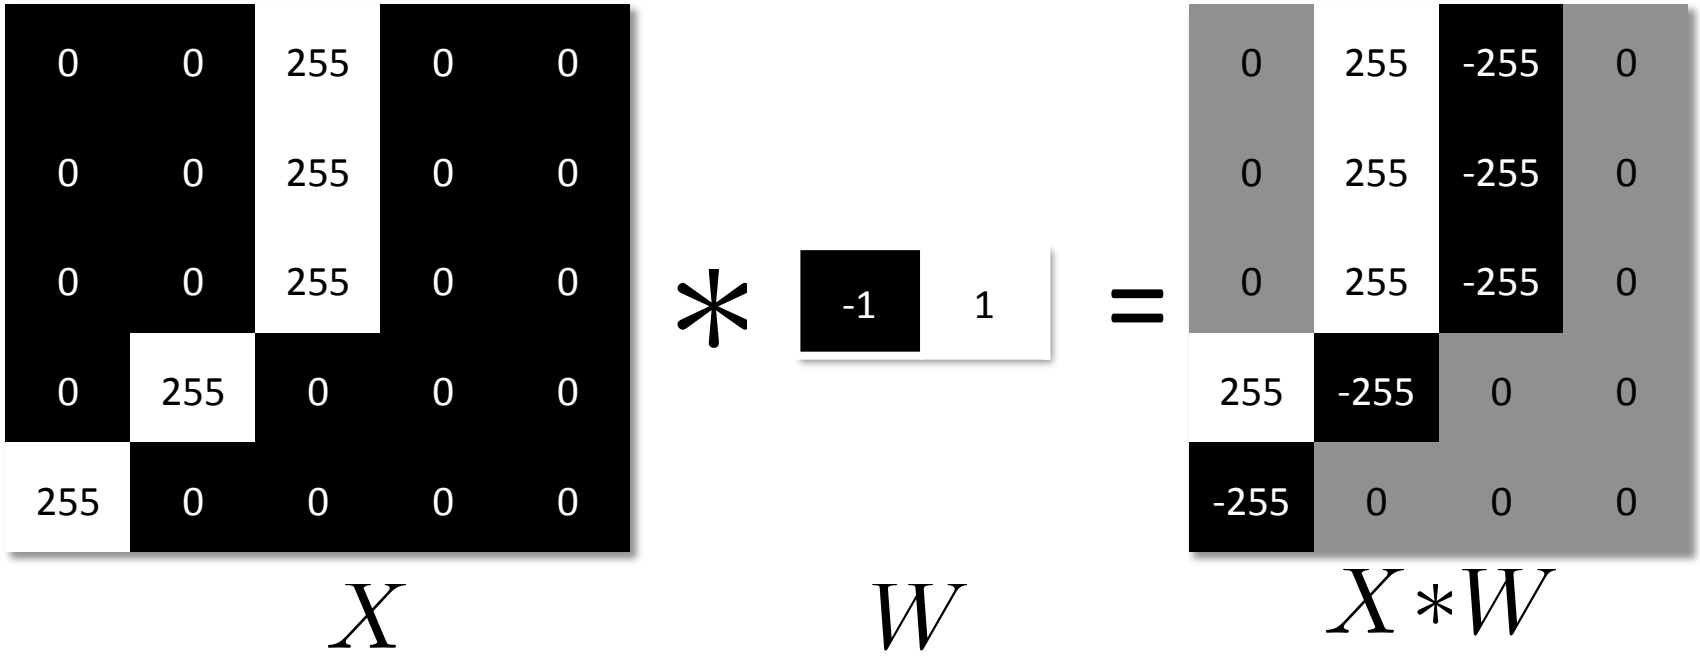

Convolution

- Calculer V est l'équivalent de faire une convolution avec le filtre
  `W = array([[-1],[1]])`

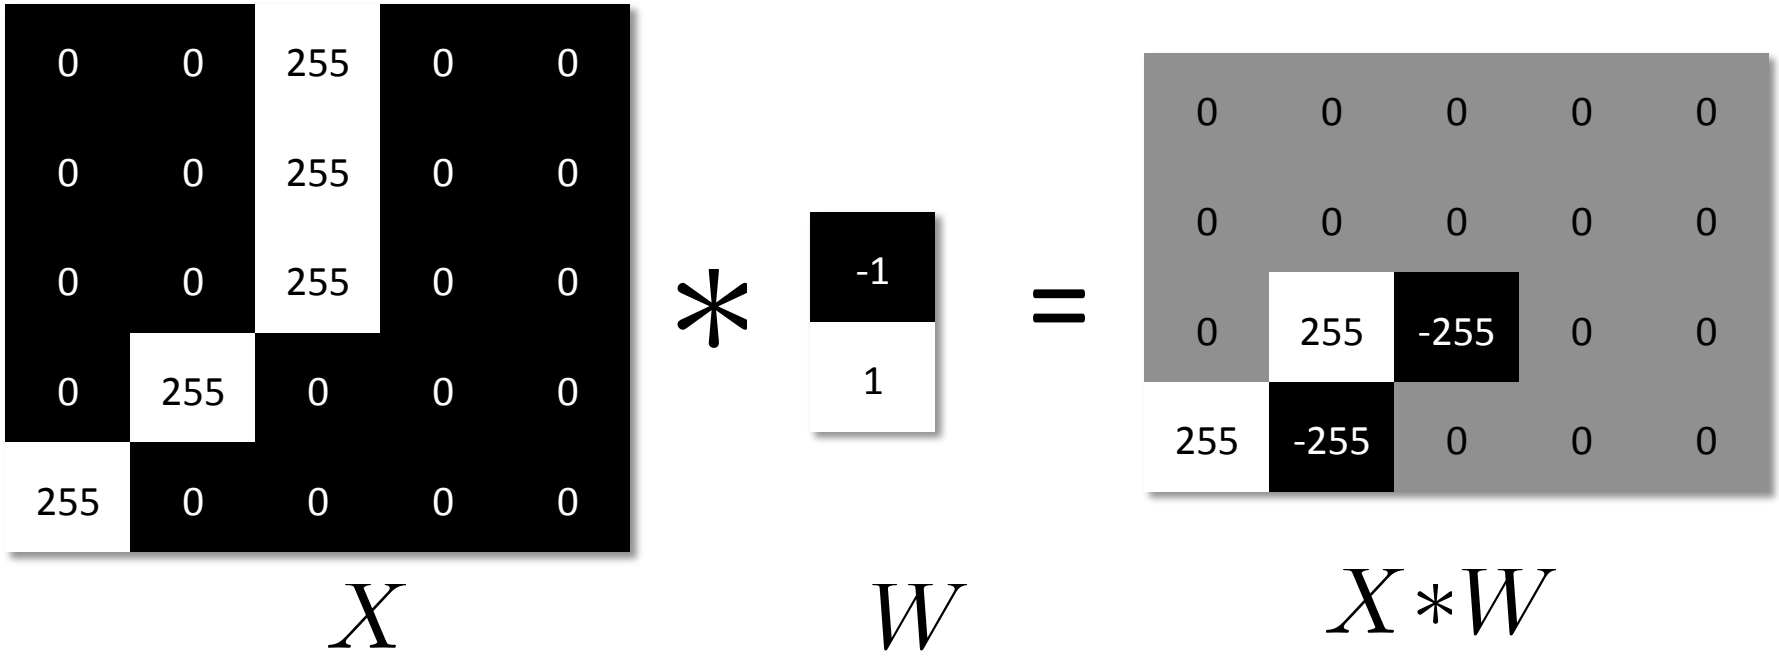

Convolution

- Afin d'appliquer le filtre à toutes les positions dans l'image, on ajoute parfois les zéros nécessaires autour de l'image (*zero padding*)

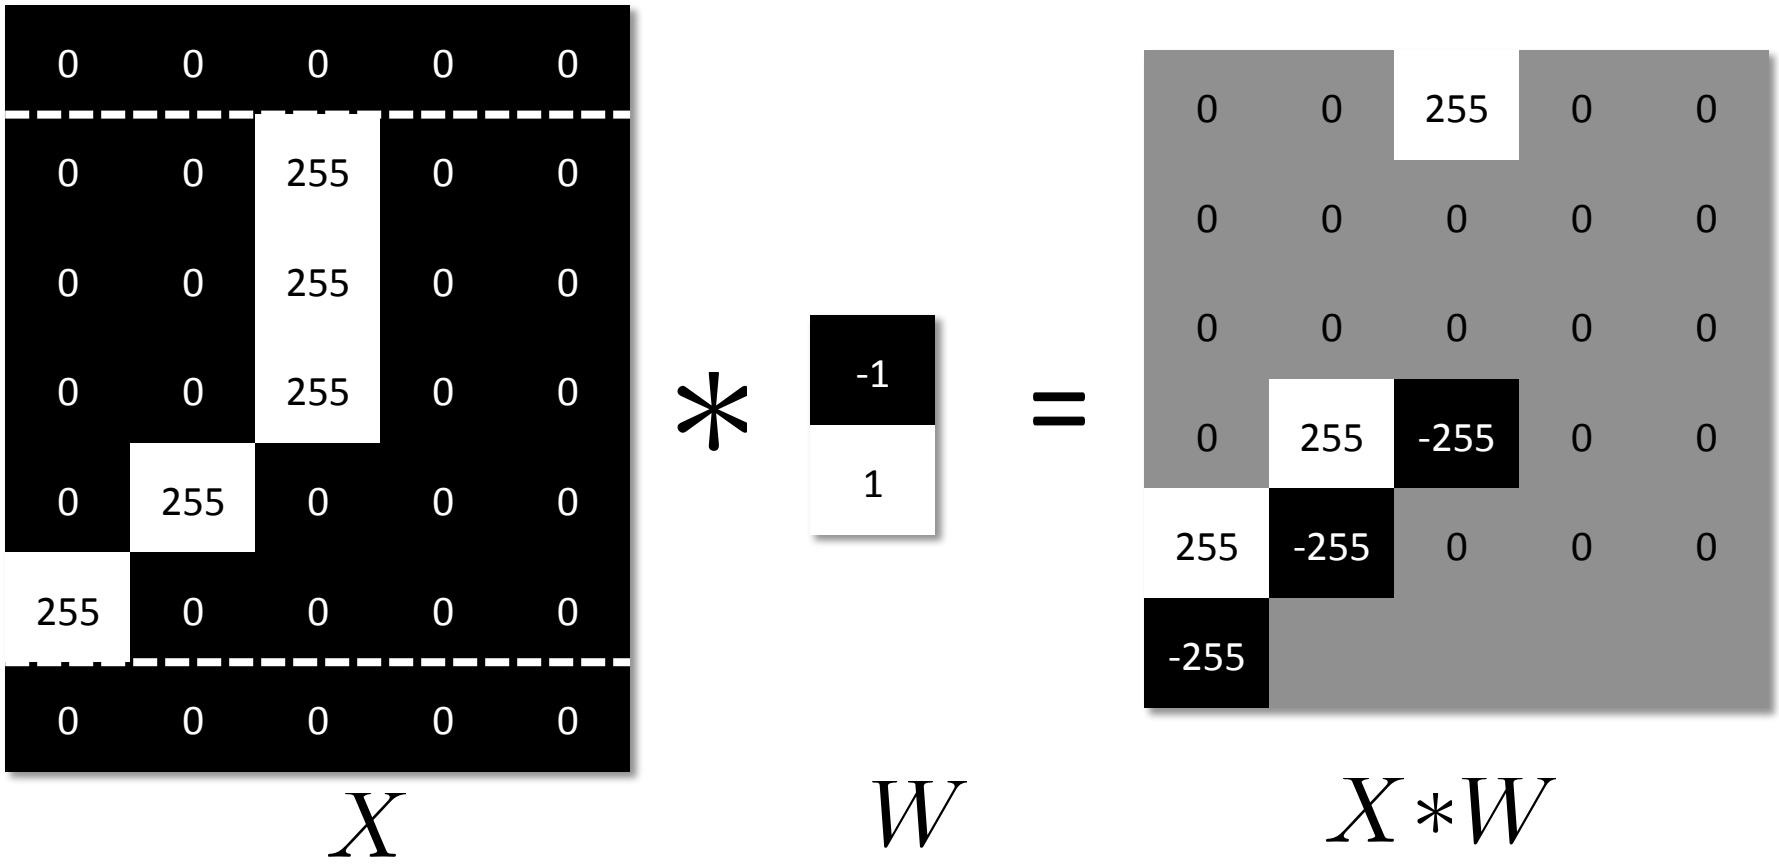

Bruit dans le calcul du gradient d'image

- Sur de vraies images, l'estimation des variations sera bruitée

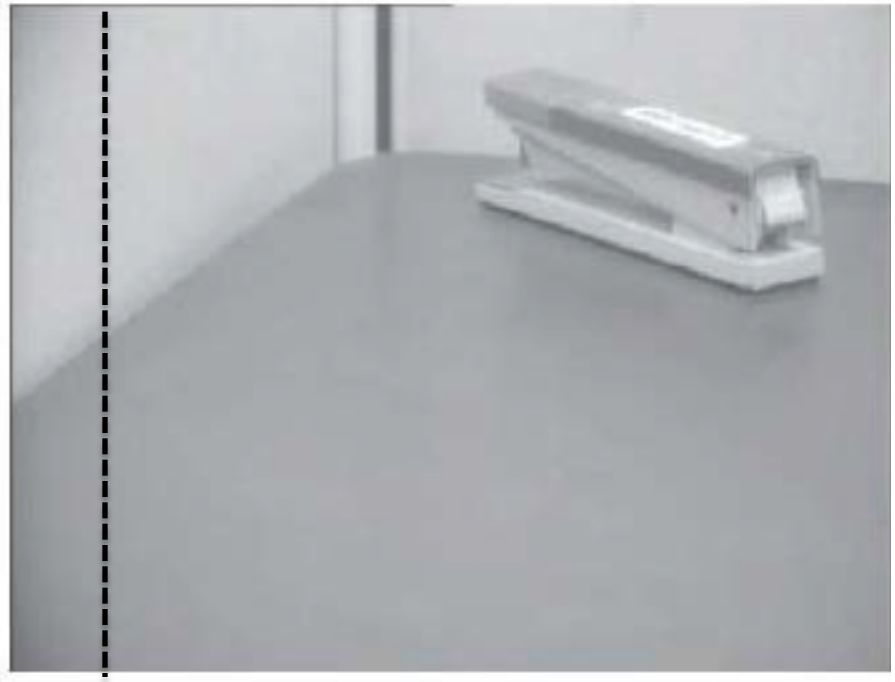

Bruit dans le calcul du gradient d'image

- Sur de vraies images, l'estimation des variations sera bruitée

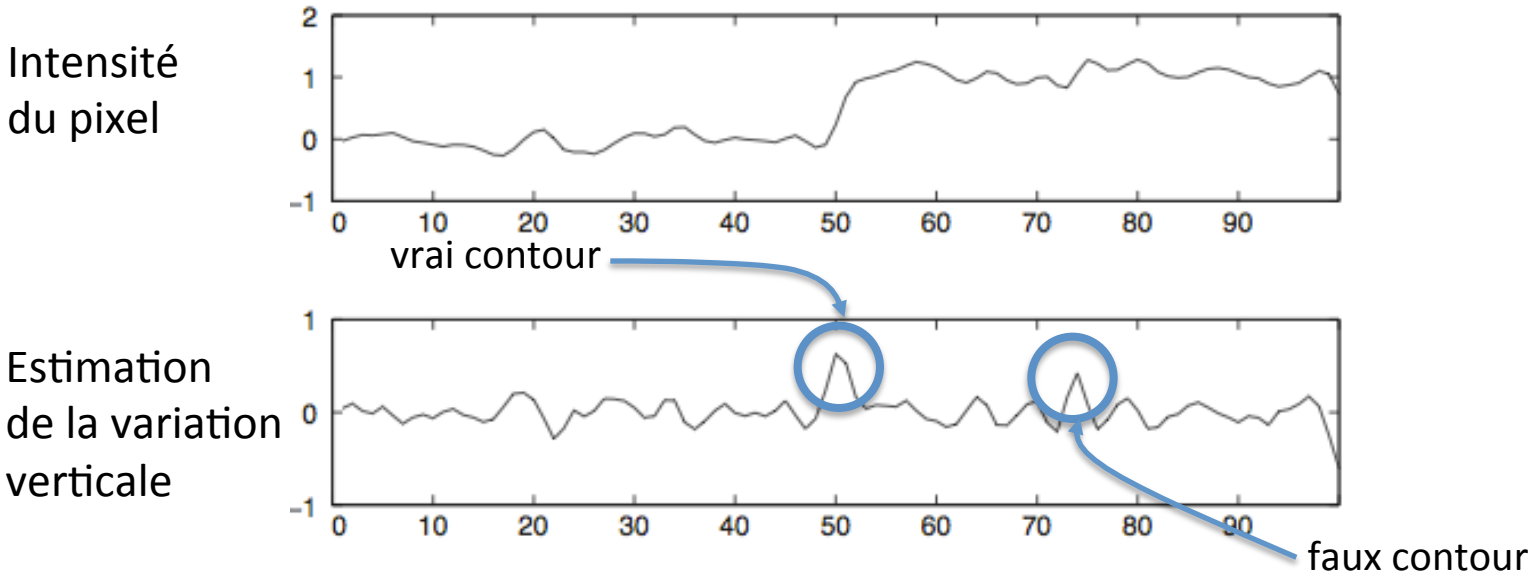

Bruit dans le calcul du gradient d'image

- Pour éliminer la détection de ces faux contours, on applique une deuxième convolution pour **lisser** le résultat

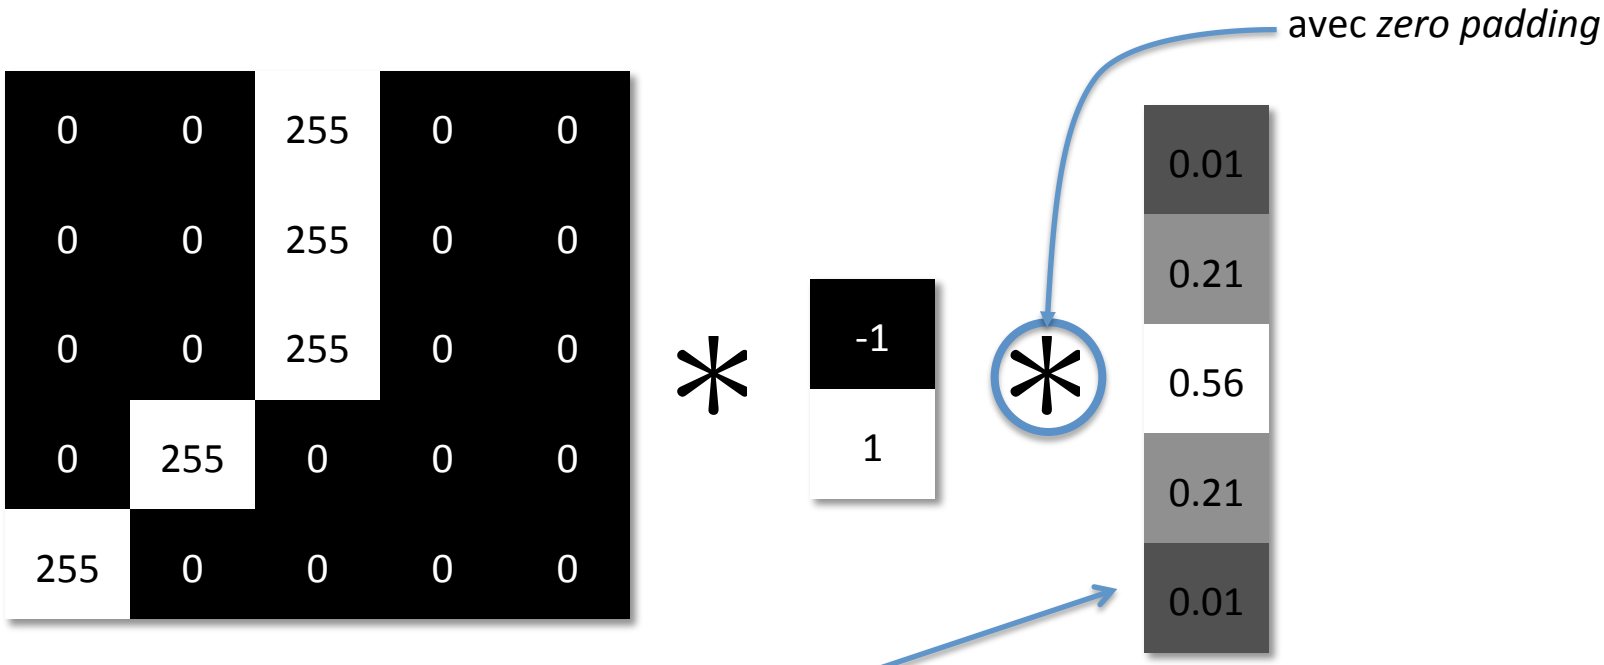

- Le filtre utilisé est appelé **filtre gaussien**

Bruit dans le calcul du gradient d'image

- Pour éliminer la détection de ces faux contours, on applique une deuxième convolution pour **lisser** le résultat

0.01	$= \exp(-2^2) / Z$
0.21	$= \exp(-1^2) / Z$
0.56	$= \exp(-0^2) / Z$
0.21	$= \exp(-1^2) / Z$
0.01	$= \exp(-2^2) / Z$

constante de normalisation

$$Z = \exp(-2^2) + \exp(-1^2) + \exp(-0^2) + \exp(-1^2) + \exp(-2^2)$$

Bruit dans le calcul du gradient d'image

- Pour éliminer la détection de ces faux contours, on applique une deuxième convolution pour **lisser** le résultat

0.01	= $\exp(-2^2) / Z$
0.21	= $\exp(-1^2) / Z$
0.56	= $\exp(-0^2) / Z$
0.21	= $\exp(-1^2) / Z$
0.01	= $\exp(-2^2) / Z$

Formule générale du filtre gaussien

$W[i,j] = \exp(-d(i,j)^2/sigma^2)/Z$

$d(i,j)$ = distance p/r au centre du filtre

$sigma$ = paramètre de lissage
(plus il est grand, plus on lisse)

Bruit dans le calcul du gradient d'image

- Sur de vrais images, l'estimation des variations sera bruitée

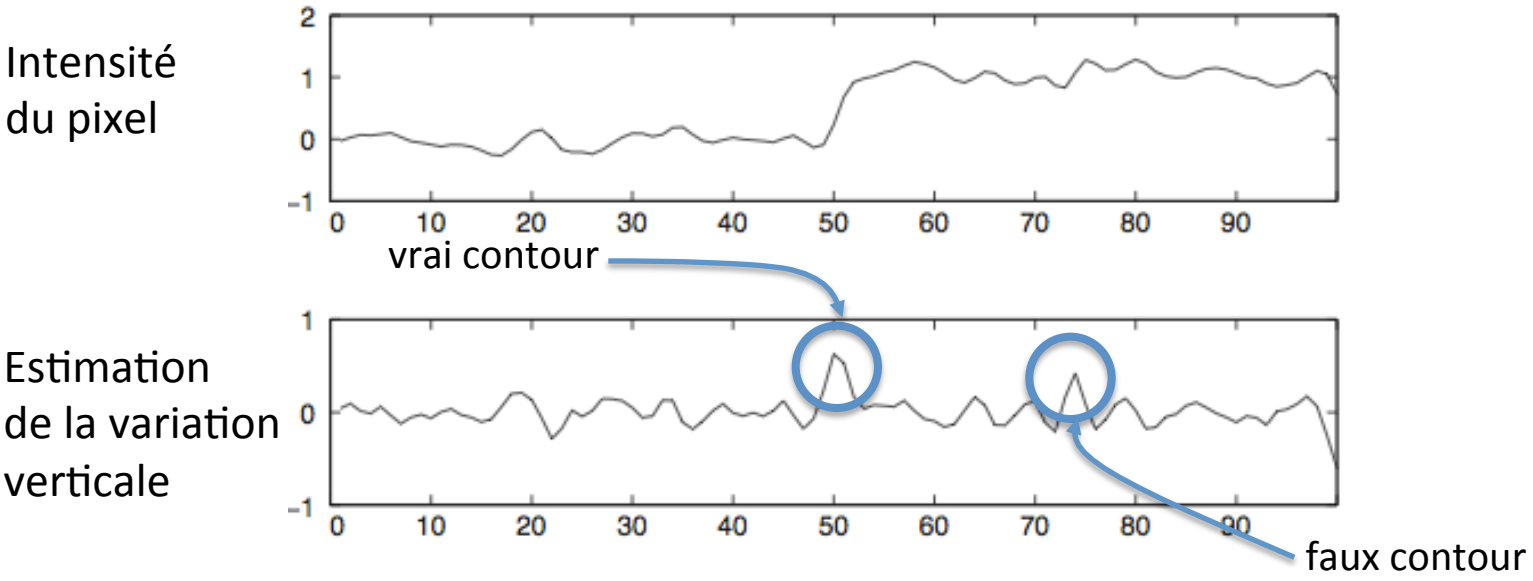

Si on va plus loin...

- L'estimation des gradients tel que présentée (`X[i,j+1] – X[i,j]`) peut être améliorée
  - voir les filtres de Sobel (*Sobel operator*) http://en.wikipedia.org/wiki/Sobel_operator

- La détection des contours à l'aide d'un simple seuil peut être améliorée
  - voir le filtre de Canny (*Canny edge detector*) http://en.wikipedia.org/wiki/Canny_edge_detector

- On peut extraire à partir des contours l'information sur la présence de lignes droites ou de cercles (ex.: un robot qui veut détecter les limites d'une pièce)
  - http://en.wikipedia.org/wiki/Hough_transform

Caractéristiques d'images

- En plus de servir à détecter des contours, les gradients d'image peuvent servir à **extraire des caractéristiques** d'une image

- On a vu que l'orientation des gradients ne varie pas en fonction de l'intensité
  - on pourrait utiliser cette propriété pour obtenir des caractéristiques invariantes p/r à l'intensité d'une image (ex.: l'illumination)

Histogramme de gradients

- Un type de caractéristiques populaire est **l'histogramme de gradients** (***histogram of gradients*** **ou HoG**)
  - calculer le **champ de gradients** de l'image
  - partitionner (diviser) l'image en plusieurs **segments (*cells*)**
  - dans chaque segment, faire un **histogramme** des orientations des gradients contenus dans ce segment
  - le vecteur de caractéristiques pour l'image est la concaténation de tous ces histogrammes

Histogramme de gradients

- Pour calculer un histogramme d'orientations
  - on partitionne les orientations possibles en quelques cases (ex. 4 cases à 0^o, 90^o, 180^o et 270^o, ou 8 cases à 0^o, 45^o, ..., 315^o)
  - la valeur de chaque case est le compte du nombre de gradients qui tombent dans chaque case
    - » chaque gradient « vote » pour l'orientation la plus proche

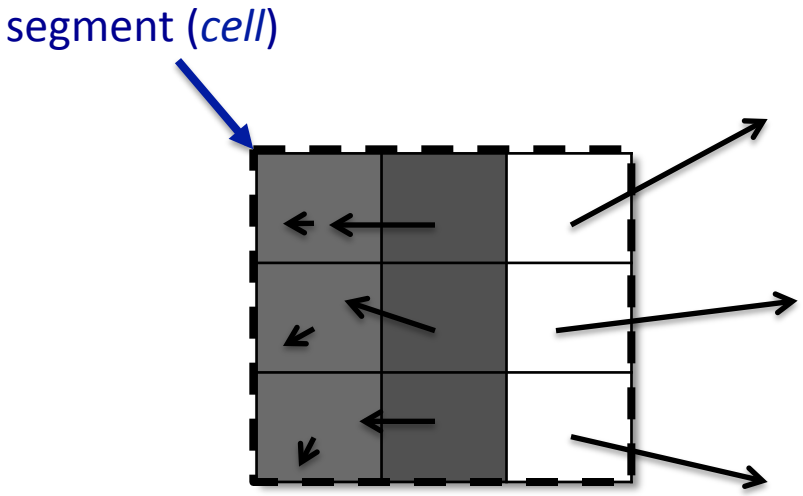

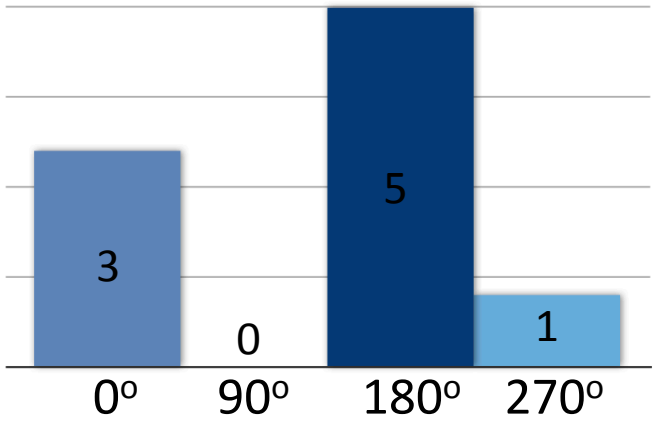

Histogramme de gradients

- Façon de tenir compte de la grandeur (norme) du gradient
  - on peut ajouter une case additionnelle pour les gradients dont la norme est sous un seuil donné
  - on utilise un poids `c` du vote d'un gradient `G[i,j,:]` comme suit

```
c[i,j] = sqrt(sum(G[i,j,:]**2)) / N
```

où `N` est la somme des normes dans le segment où se trouve `G[i,j,:]`

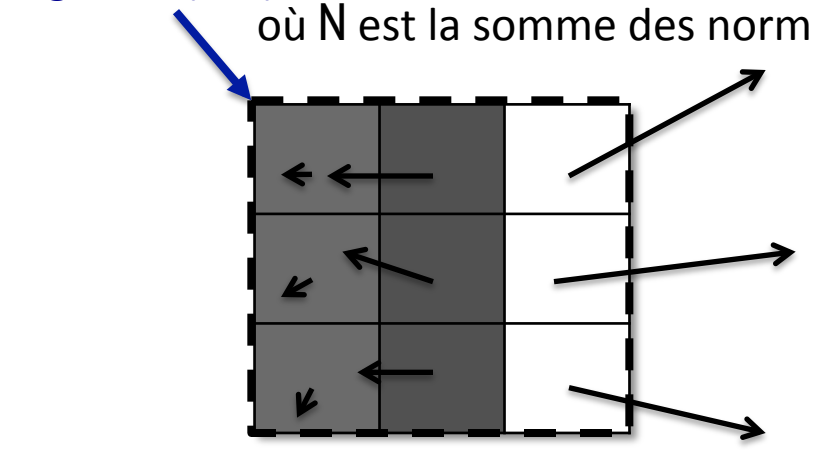

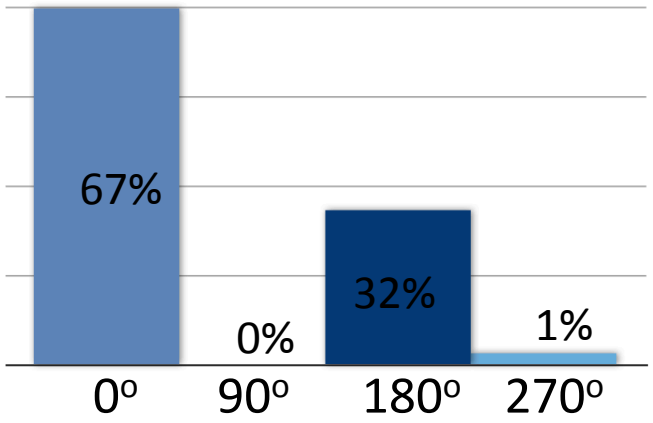

Histogramme de gradients

- Avoir une case pour les gradients trop petits permet de mieux représenter les régions uniformes (où tous les gradients sont petits)
- Utiliser un vote normalisé par la somme des normes de gradient donne une représentation plus invariante p/r à l'illumination
- Les deux idées peuvent être combinées

Histogramme de gradients

- Exemple sur une image de personne

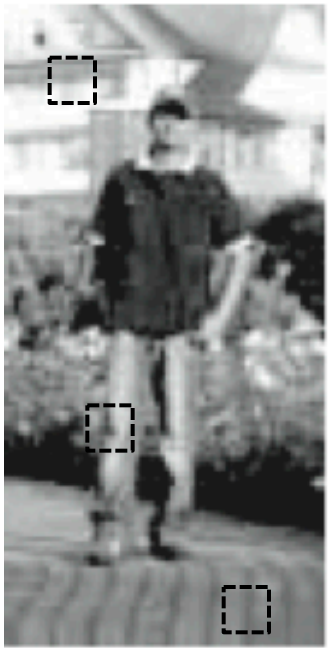

Image

Orientation histograms

illustre la perpendiculaire du gradient, pour faciliter la visualisation

Histogramme de gradients

- On peut alors traiter le problème de reconnaissance d'objets comme un problème de classification standard en apprentissage automatique
  - entrée x_t: représentation HoG d'une image
  - cible y_t: présence (y_t=1) ou absense (y_t=0) d'un objet à reconnaître

- On peut ainsi collecter un ensemble d'entraînement à donner à un algorithme d'apprentissage pour la classification

  (Perceptron, régression linéaire, réseau de neurones, etc.)

Histogramme de gradients

- Visualisation des orientations importantes, apprises par un classifieur linéaire

Image

Orientation histograms

Visualisation des poids du classifieur

poids positifs

poids négatifs

De la classification à la détection

- Quoi faire si ce que l'on cherche n'est pas au centre de l'image?
- **Idée générale:** on applique le même classifieur à plusieurs positions et échelles dans l'image

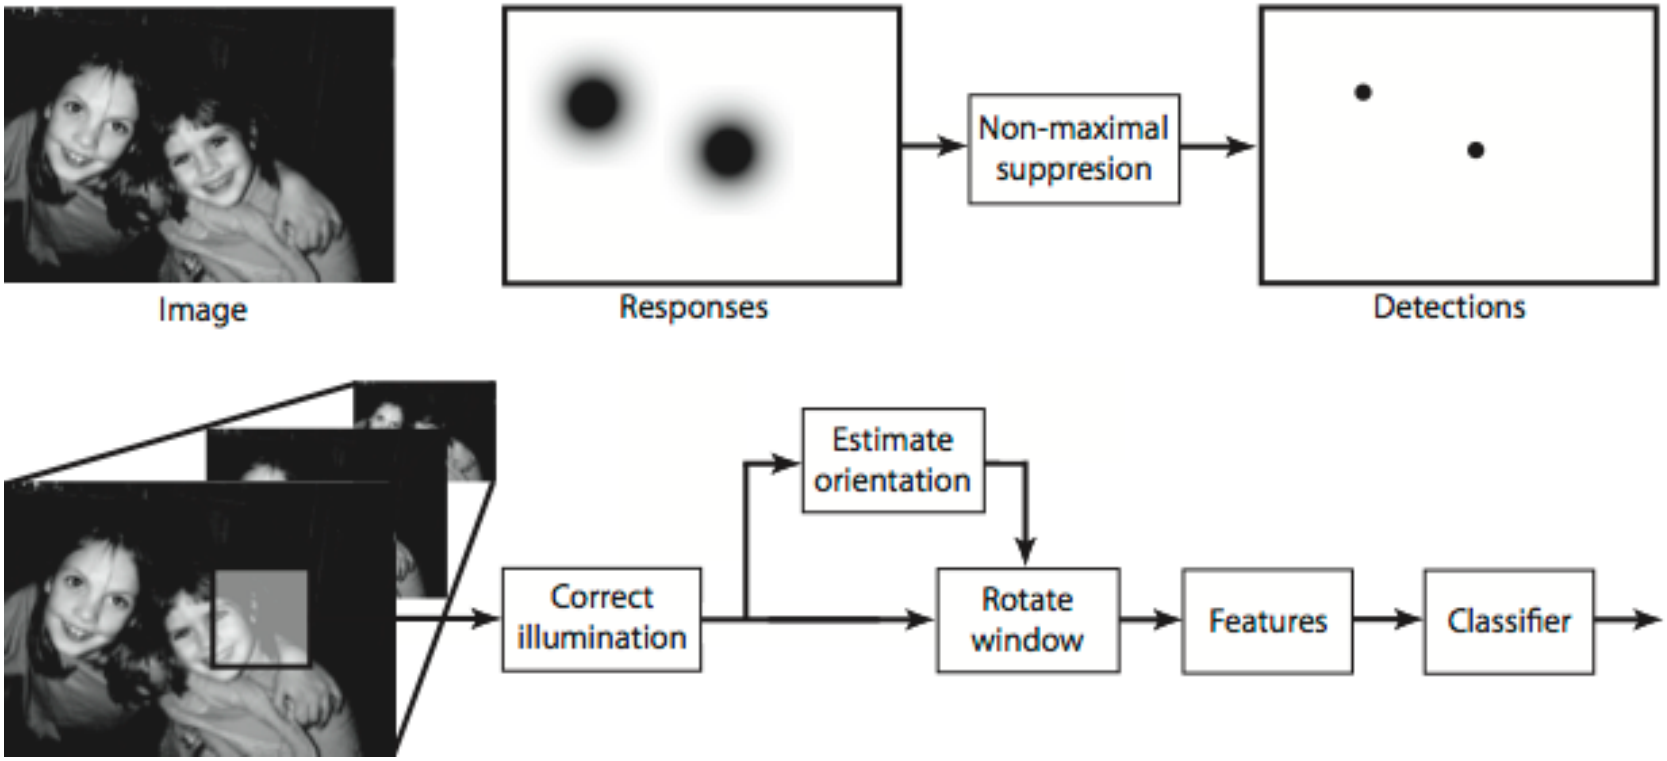

Le système visuel humain

- Pourquoi ne pas s'inspirer du cerveau pour faire de la vision!

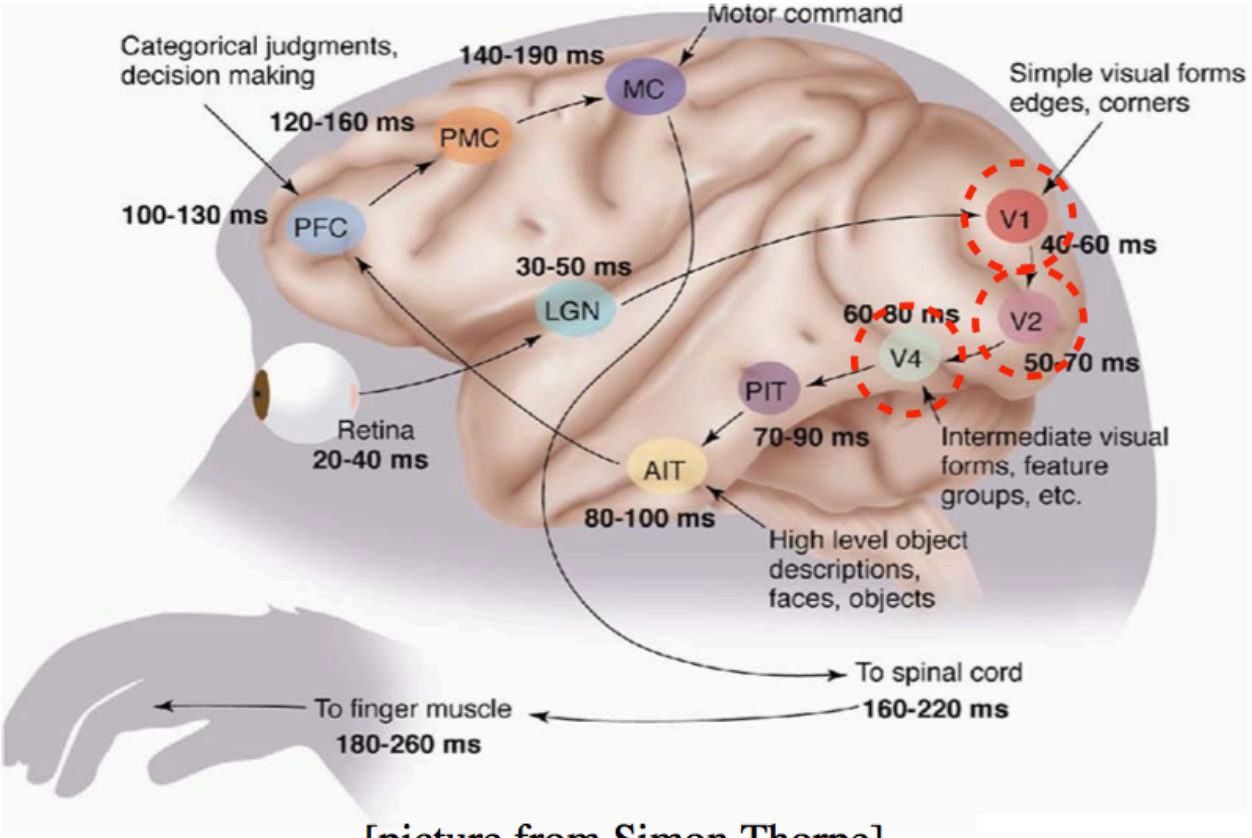

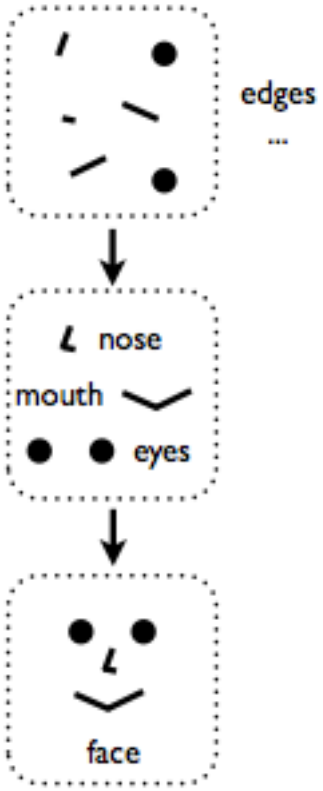

[picture from Simon Thorpe]

Réseau de neurones à convolution

- Un **réseau de neurones à convolution** est un cas spécial de réseau de neurones
  - Neocognition (Fukushima, 1980)
  - LeNet (LeCun, 1989)

- Comme un réseau de neurones standard, on l'entraîne par descente de gradient stochastique à l'aide de la rétropropagation des gradients

- Spécificité: ils implémentent **3 idées**:
  - connectivité parcimonieuse («sparse»)
  - connectivité locale
  - partage de paramètres

Réseau de neurones à convolution: structure des couches cachées

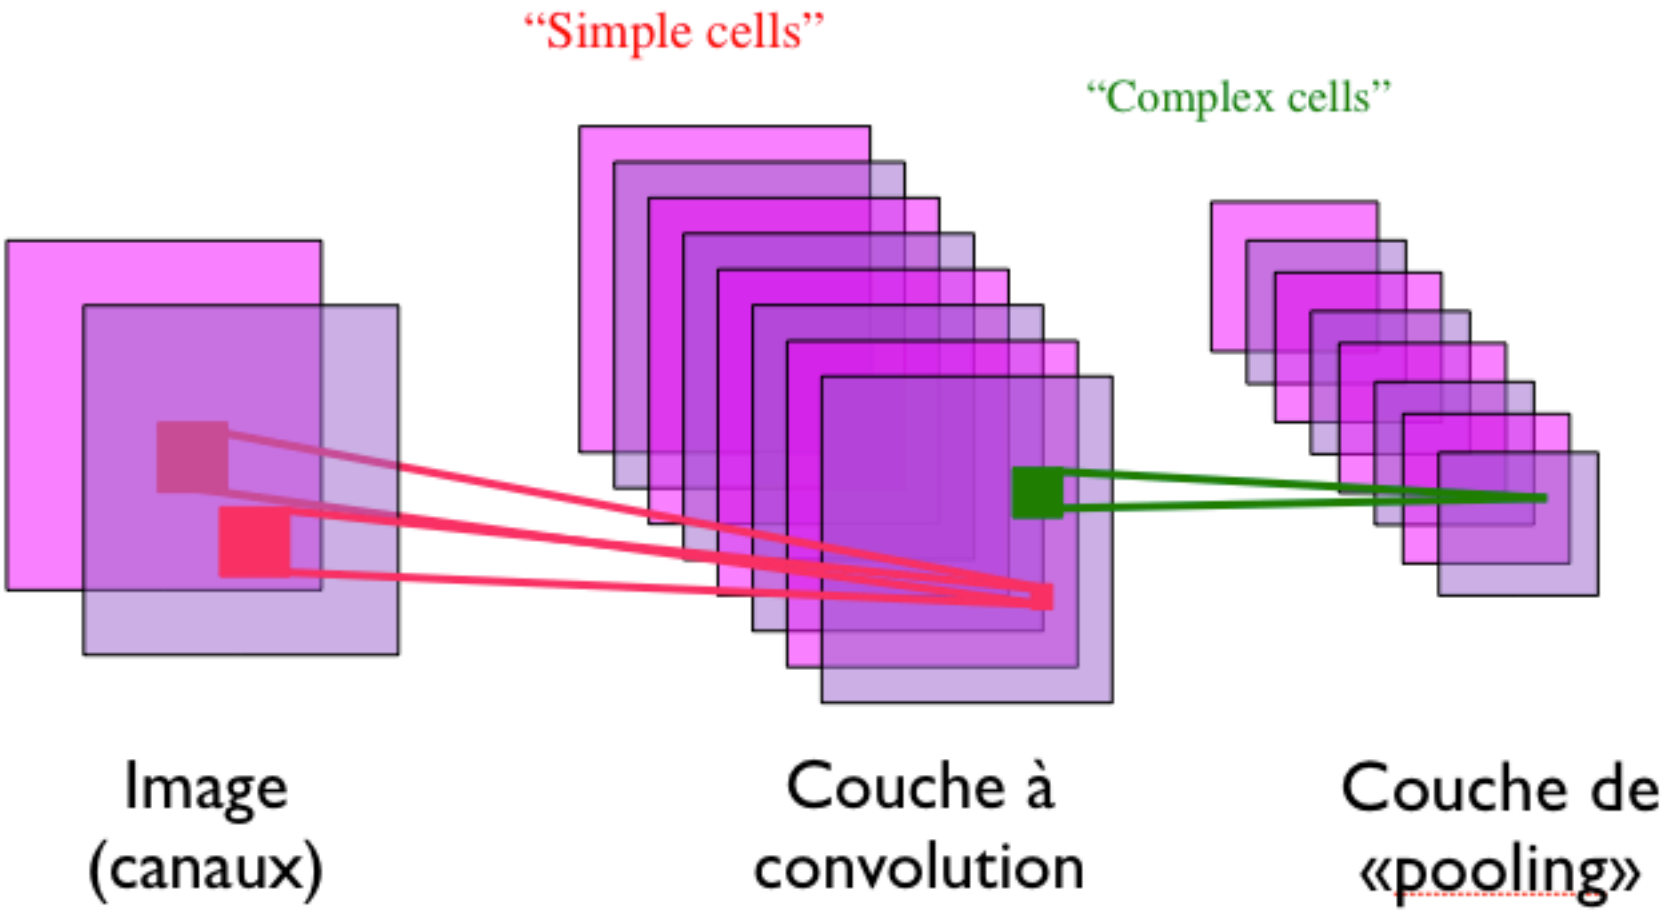

Inspiration de la neuroscience

Hubel & Wiesel video

http://www.youtube.com/watch?v=8VdFf3egwfg&feature=related

Réseau de neurones à convolution: couche à convolution

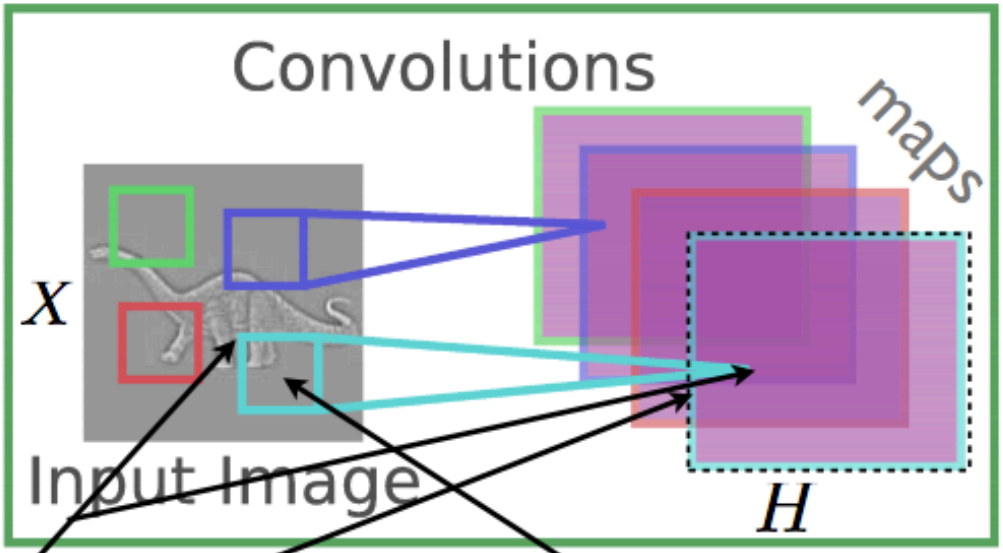

$$H_{i,j,k} = \tanh\left(b_k + \sum_{s=1}^{K}\sum_{t=1}^{K} w_{s,t,k}\ X_{i-1+s,j-1+t}\right)$$

$$\tanh(a) = \frac{e^a - e^{-a}}{e^a + e^{-a}}$$

noyau
«kernel»
filtre

Réseau de neurones à convolution: couche à « pooling »

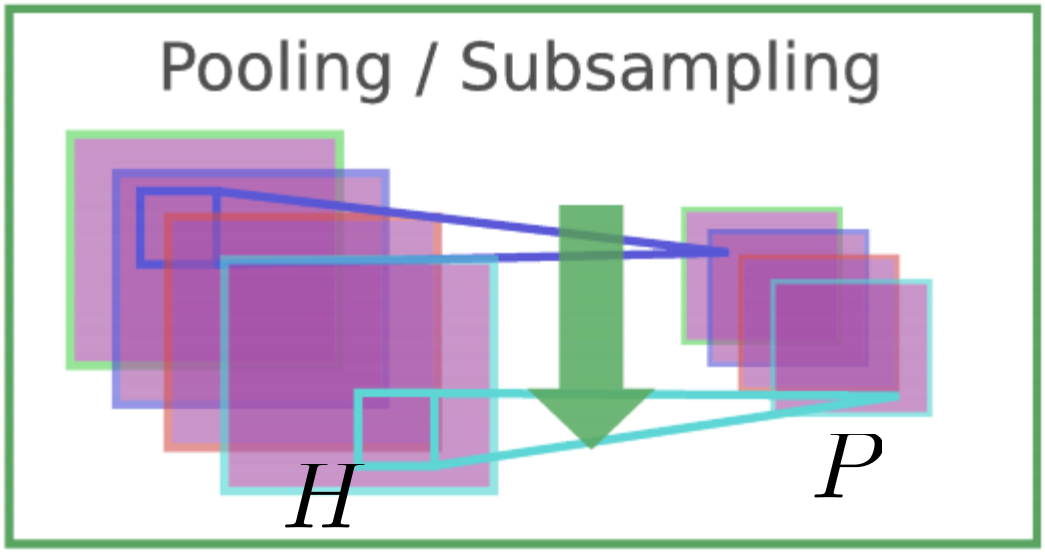

- Deux étapes
  - «max pooling»: $P_{i,j,k} = \max_{(i',j') \in N(i,j)} H_{i',j',k}$
  - «downsampling»: garde seulement une fraction des neurones

Example

- Calcul d'une couche « simple cell »
  - première étape : calcul de la convolution

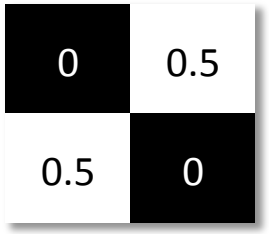

connexions vers les neurones cachés

W

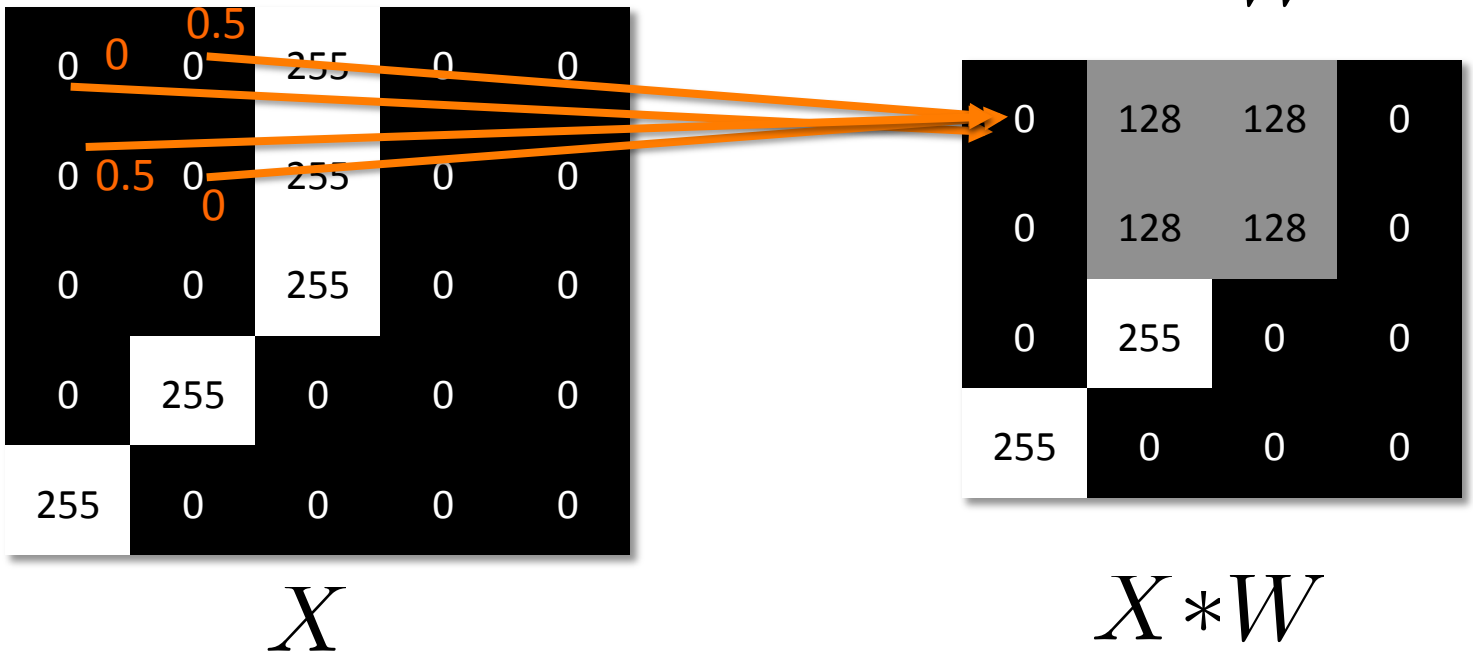

X $X * W$

couche d'entrée **couche « simple cell »**

Example

- Calcul d'une couche « simple cell »
  - première étape : calcul de la convolution
  - deuxième étape : calcul de la non-linéarité (ex.: *Logistic*((*x*-200)/50))

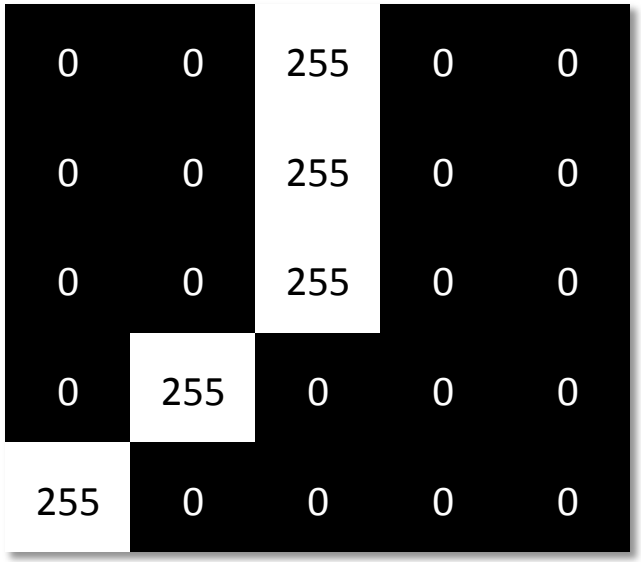

X

couche d'entrée

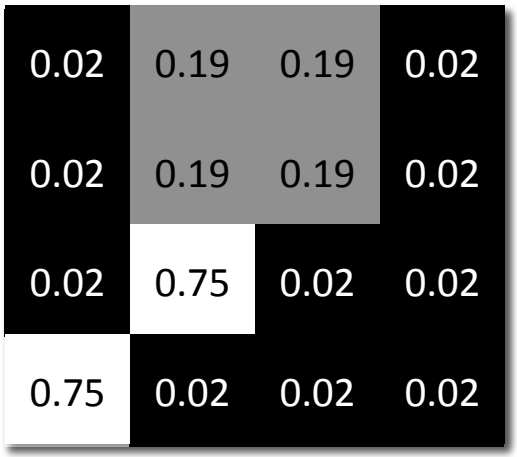

$Logistic((X * W - 200) / 50)$

couche « simple cell »

Example

- Calcul d'une couche « complex cell »
  - maximum dans plusieurs segments

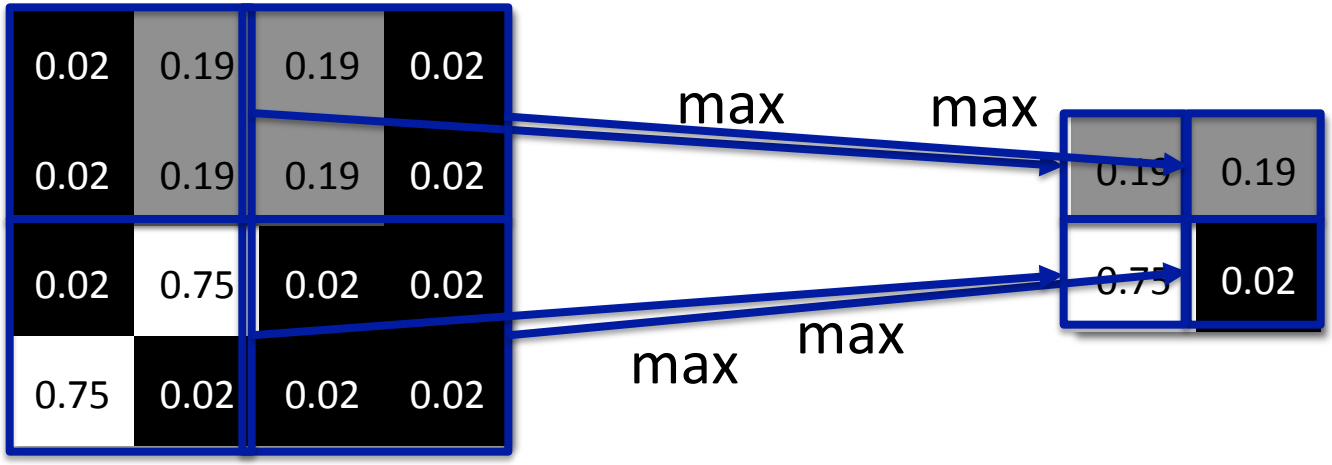

$$Logistic((X * W - 200) / 50)$$

couche « simple cell » **couche « complex cell »**

Example

- La couche « complex cell » est invariante aux translations locales

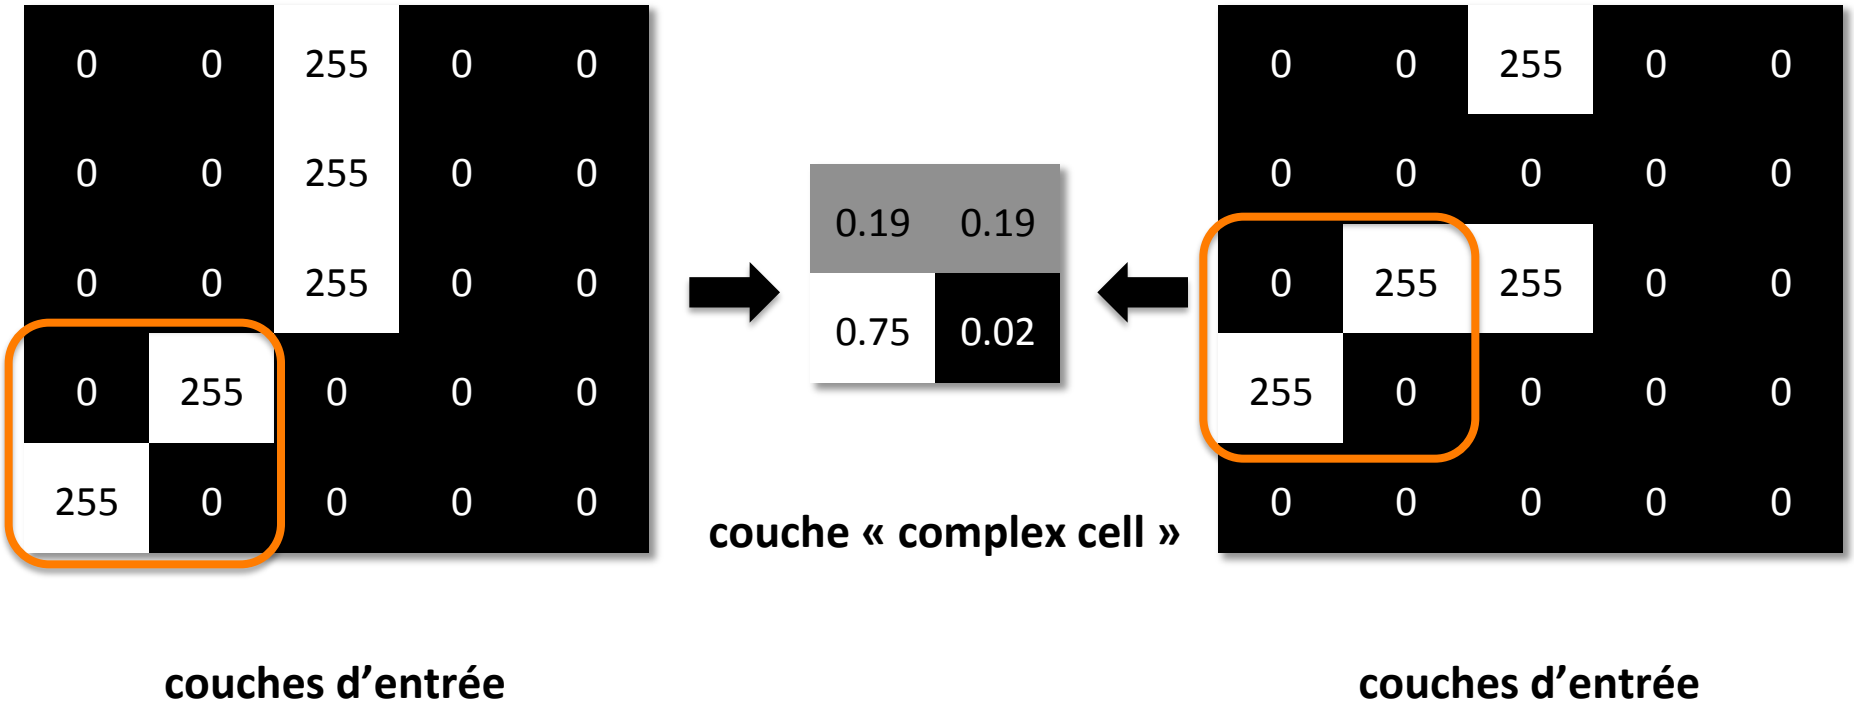

Réseau de neurones à convolution: réseau complet

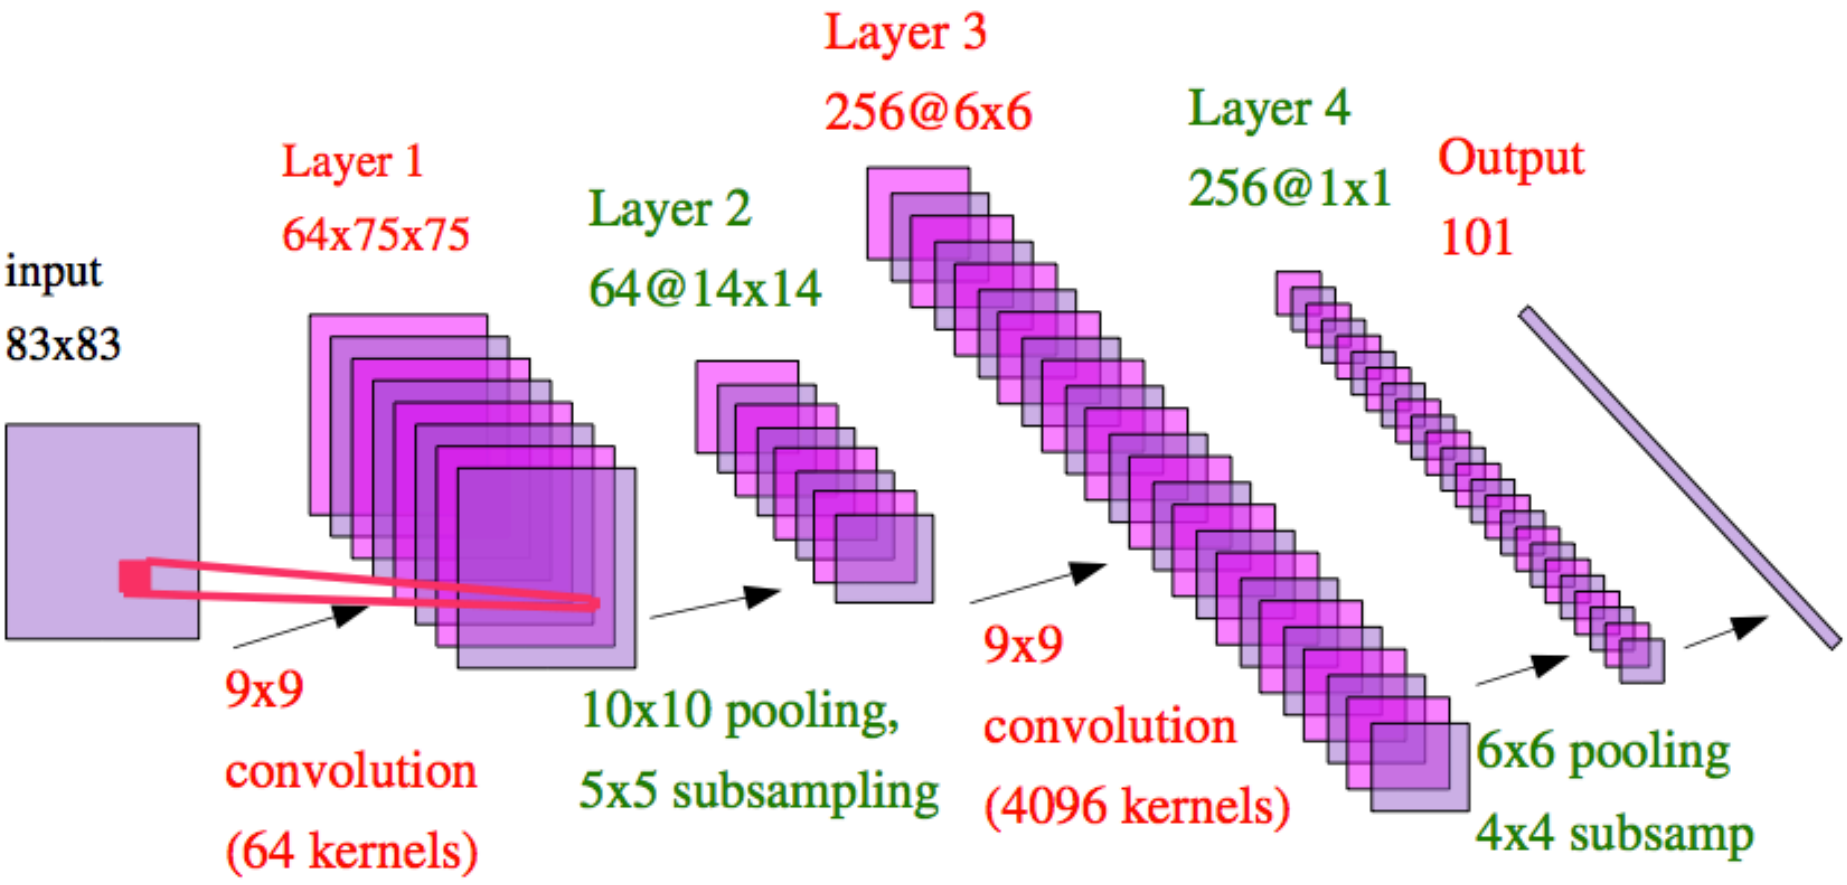

Application: conduite automatique d'une voiture téléguidée

http://www.cs.nyu.edu/~yann/research/dave/index.html

Application: conduite automatique d'une voiture téléguidée

http://www.cs.nyu.edu/~yann/research/dave/index.html

Application: et plusieurs autres

- Reconnaissance de caractères

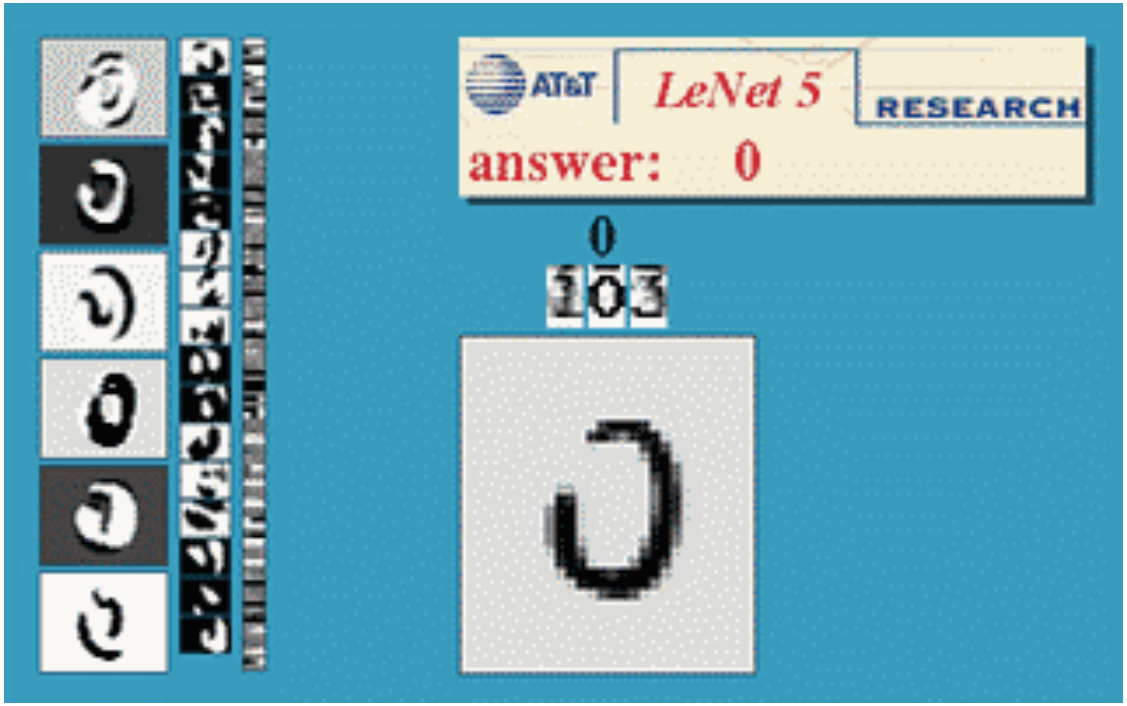

http://yann.lecun.com/exdb/lenet/

Application: et plusieurs autres

- Détection de visages et plaques d'immatriculation
  - utilisé dans Google Streetview pour masquer les visages automatiquement

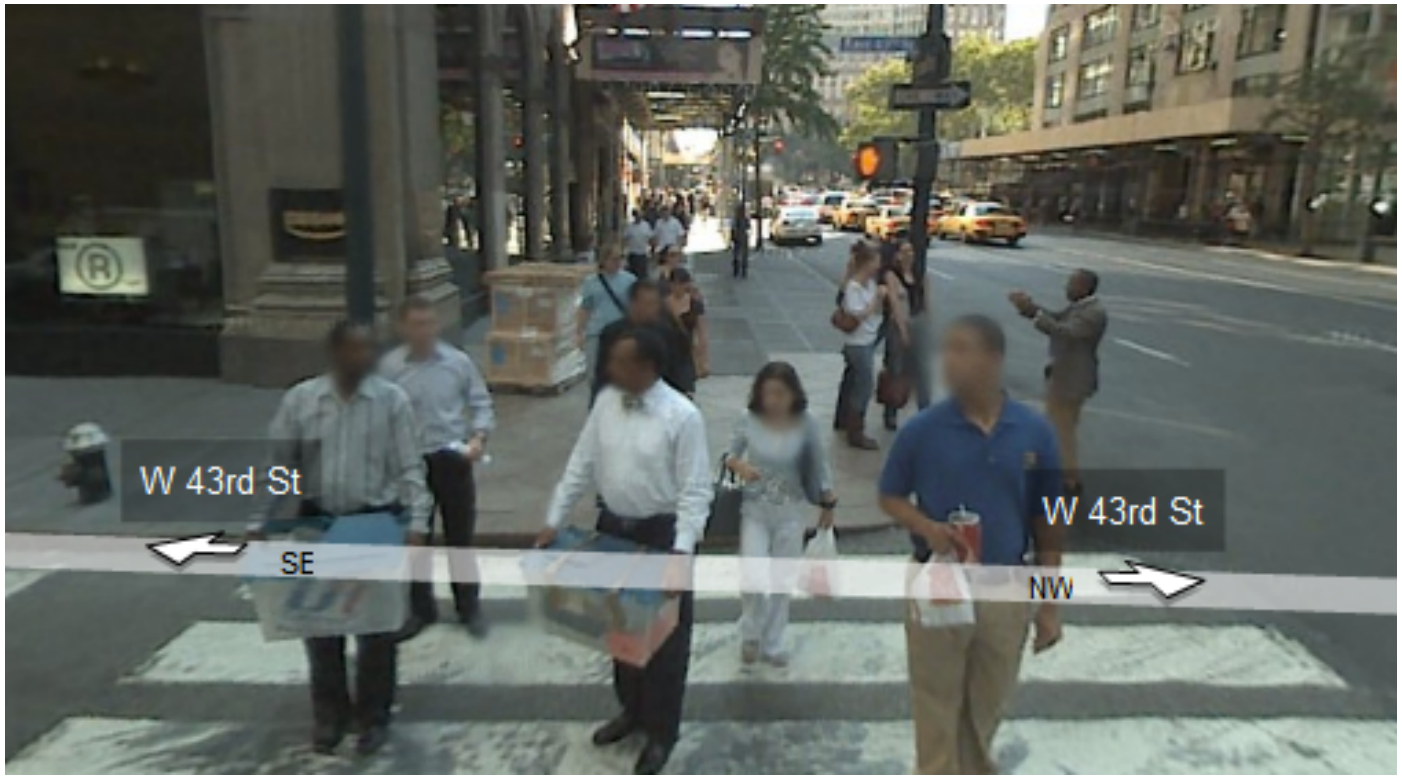

En rafale: autres concepts en vision par ordinateur

- Extraction de caractéristiques pour des images de couleur
  - en plus des histogrammes de gradients, on peut extraire des histogrammes des couleurs
    - » on détermine des intervalles de valeurs pour R, G et B individuellement (ex.: 4 intervalles pour chaque canal)
    - » on considère chaque combinaison d'intervalle R, G et B comme une case (ex.: $4^3 = 64$ cases)

En rafale: autres concepts en vision par ordinateur

- Extraction de caractéristiques pour la vidéo
  - on peut estimer le mouvement dans une image à l'aide du **flot optique**
  - à chaque pixel d'une image (*frame*), trouver le pixel dans l'image suivante qui est le plus « similaire » (c.-à-d. entouré de pixels similaires)

image *t*

image *t*+1

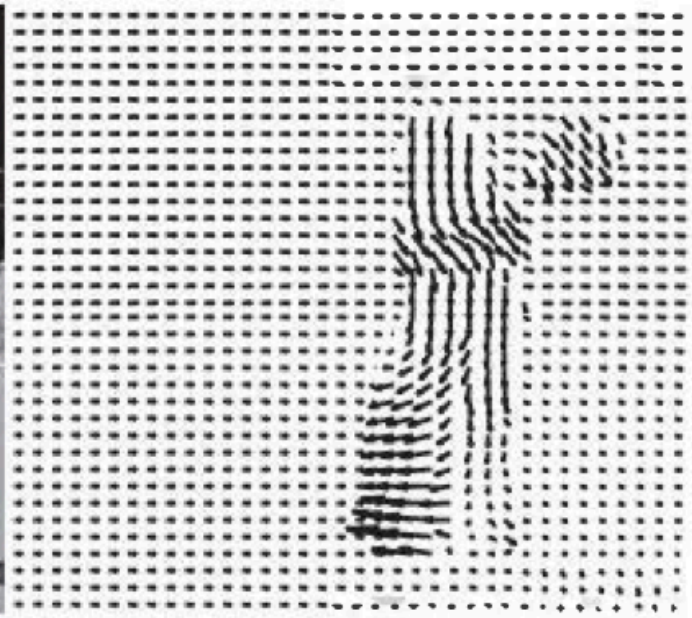

flot optique

Conclusion

- Les technologies de vision par ordinateur sont de plus en plus performantes et de plus en plus répandues
  - détection de visage
  - détection de mouvements (*Microsoft Kinect*)

- Comme pour le traitement automatique de la langue, l'apprentissage automatique est de plus en plus au centre des technologies de vision par ordinateur
- Ce cours ne donne qu'une vue globale de la vision par ordinateur
  - le bacc en imagerie offre plusieurs cours sur le sujet (ex.: **IMN 559 - Vision par ordinateur**)
    - » ces cours peuvent être suivis à la maîtrise...
  - **IFT 725 – Réseaux neuronaux** : couvre les réseaux à convolution avec plus de détails (cours de maîtrise)

Conclusion

OpenCV (Open Source Computer Vision)

- librairie de vision par ordinateur
- interfaces C++, C, Python
- compatible avec Windows, Linux, Android et Mac
- implémentations de la plupart des algorithmes mentionnés
- http://docs.opencv.org/

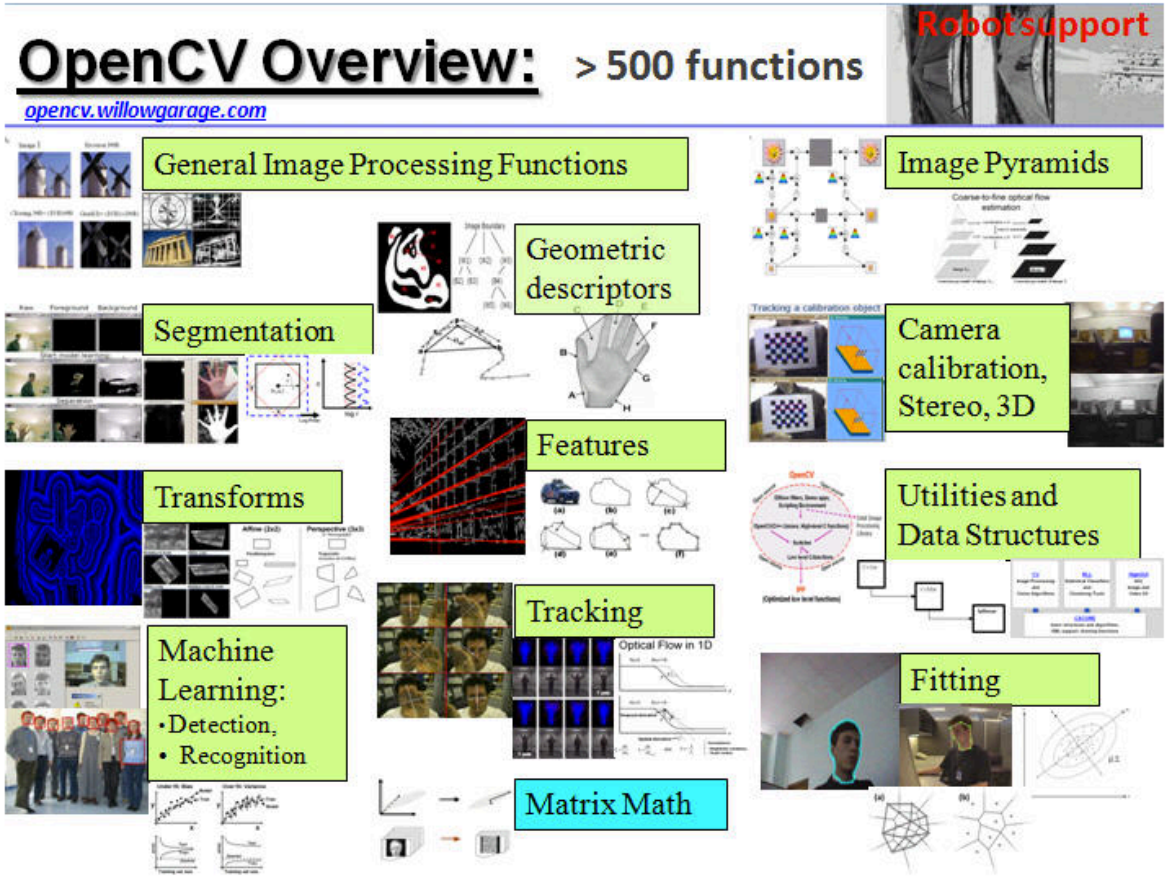

Objectifs du cours

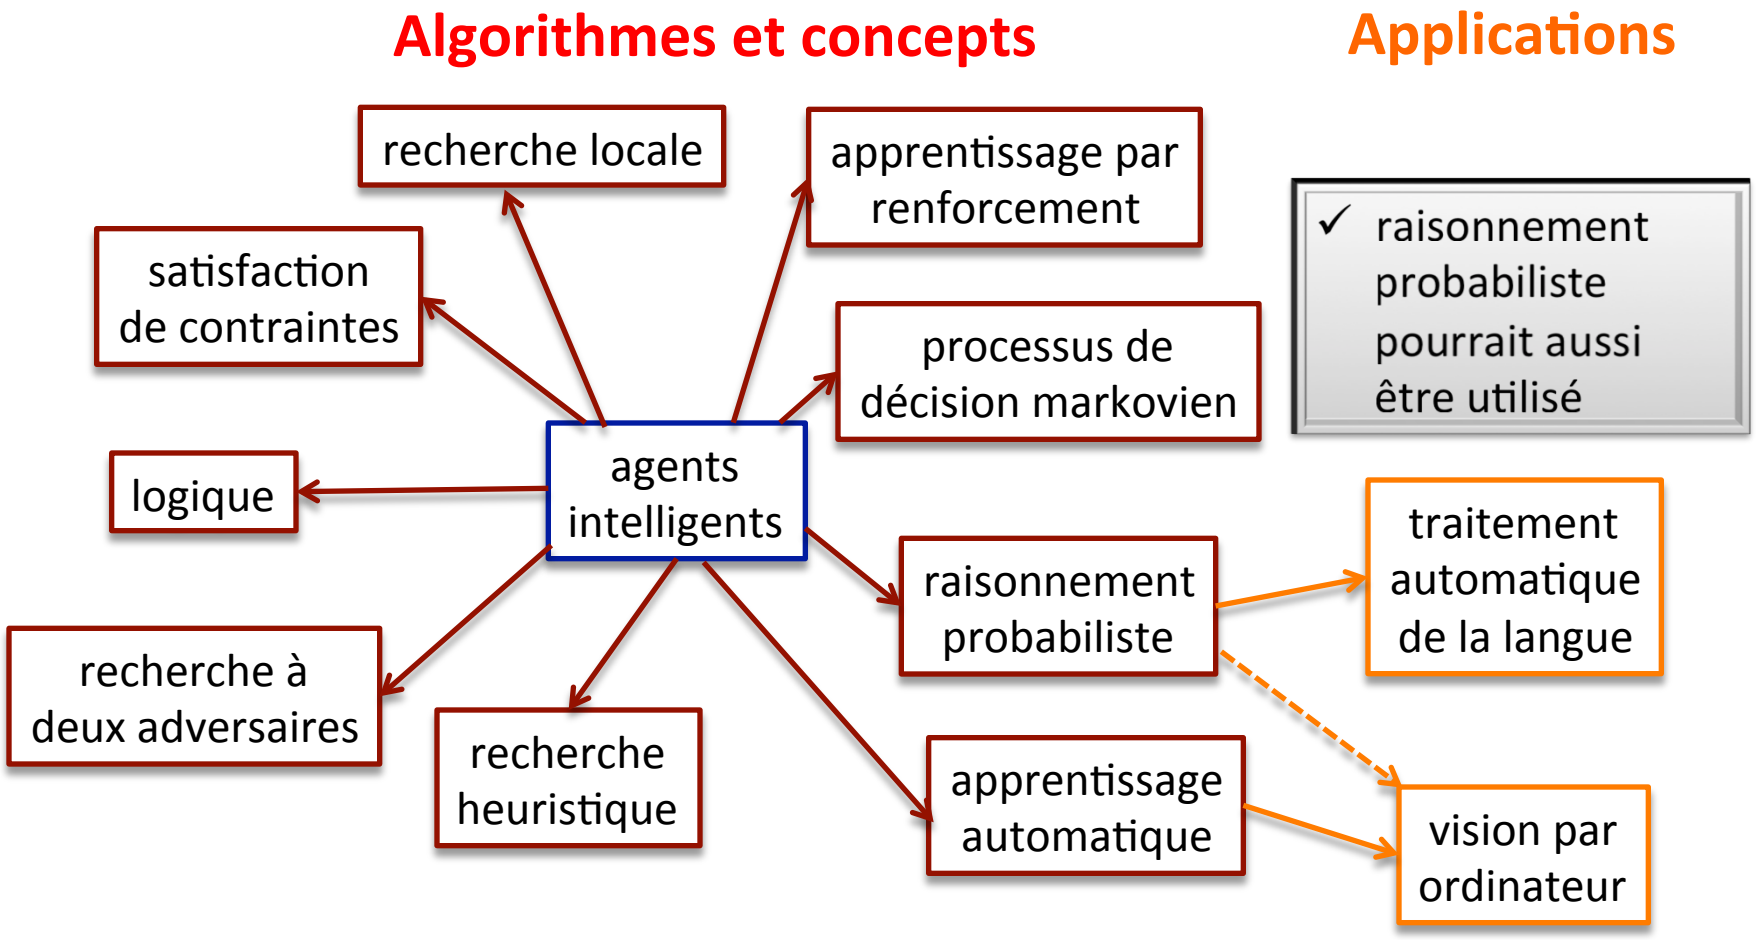

Vous devriez être capable de...

- Calculer une convolution
- Décrire globalement ce qu'est un contour et comment on peut les détecter
- Décrire ce qu'est un gradient d'image et connaître ses propriétés (norme vs. orientation)
- Décrire comment on extrait des caractéristiques d'une image à partir de ses gradients
- Savoir ce qui distingue un réseau de neurones à convolution d'un réseau de neurones standard