

IFT 615 – Intelligence Artificielle

Formes d'apprentissage

Algorithme des K plus proches voisins

Professeur: Froduald Kabanza


Assistants: D'Jeff Nkashama

Sujets couverts



- Formes d'apprentissage
- Classification avec l'algorithme des K plus proches voisins

Types de problèmes d'apprentissage


Apprentissage supervisé



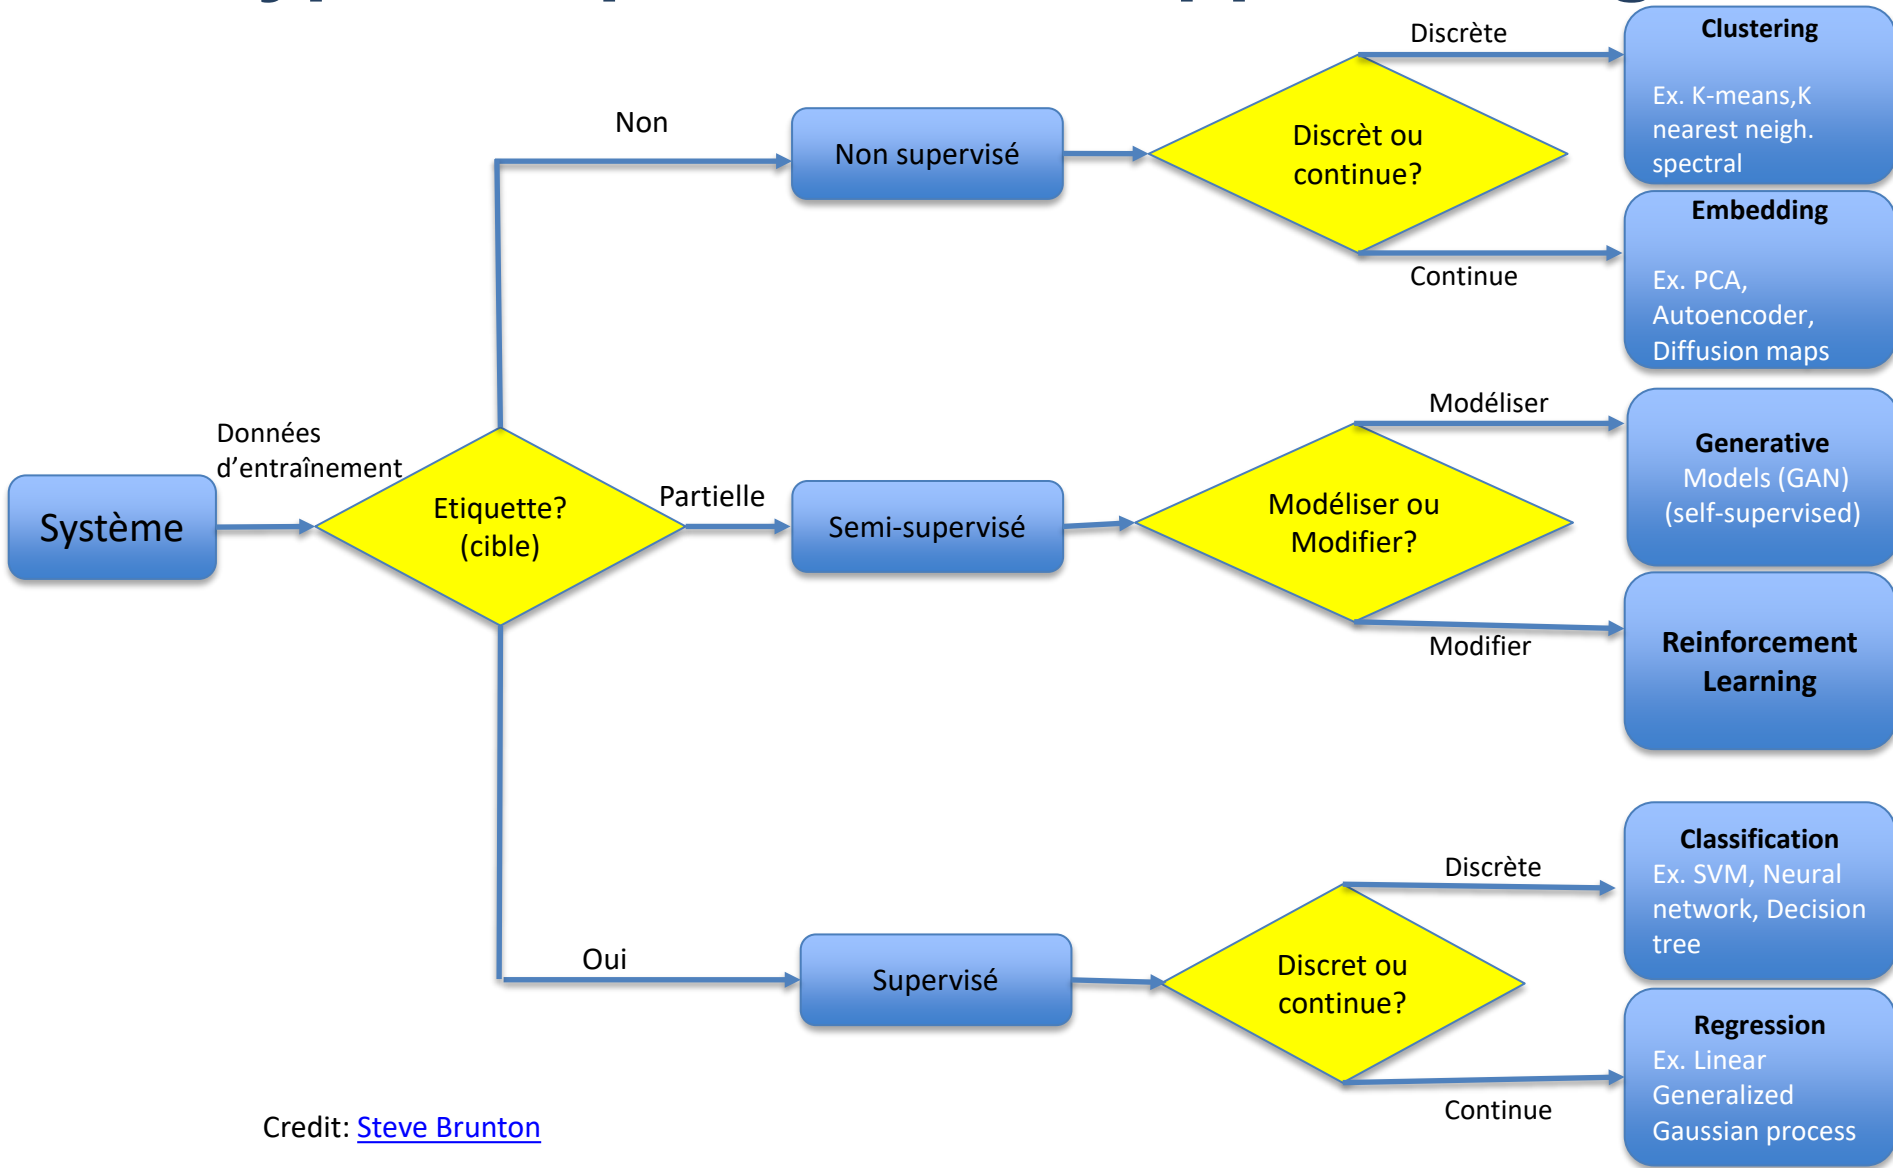
Apprentissage non supervisé



Apprentissage par renforcement




Types de problèmes d'apprentissage



Credit: [Steve Brunton](#)

APPRENTISSAGE SUPERVISÉE

Motivation – Classification d'images



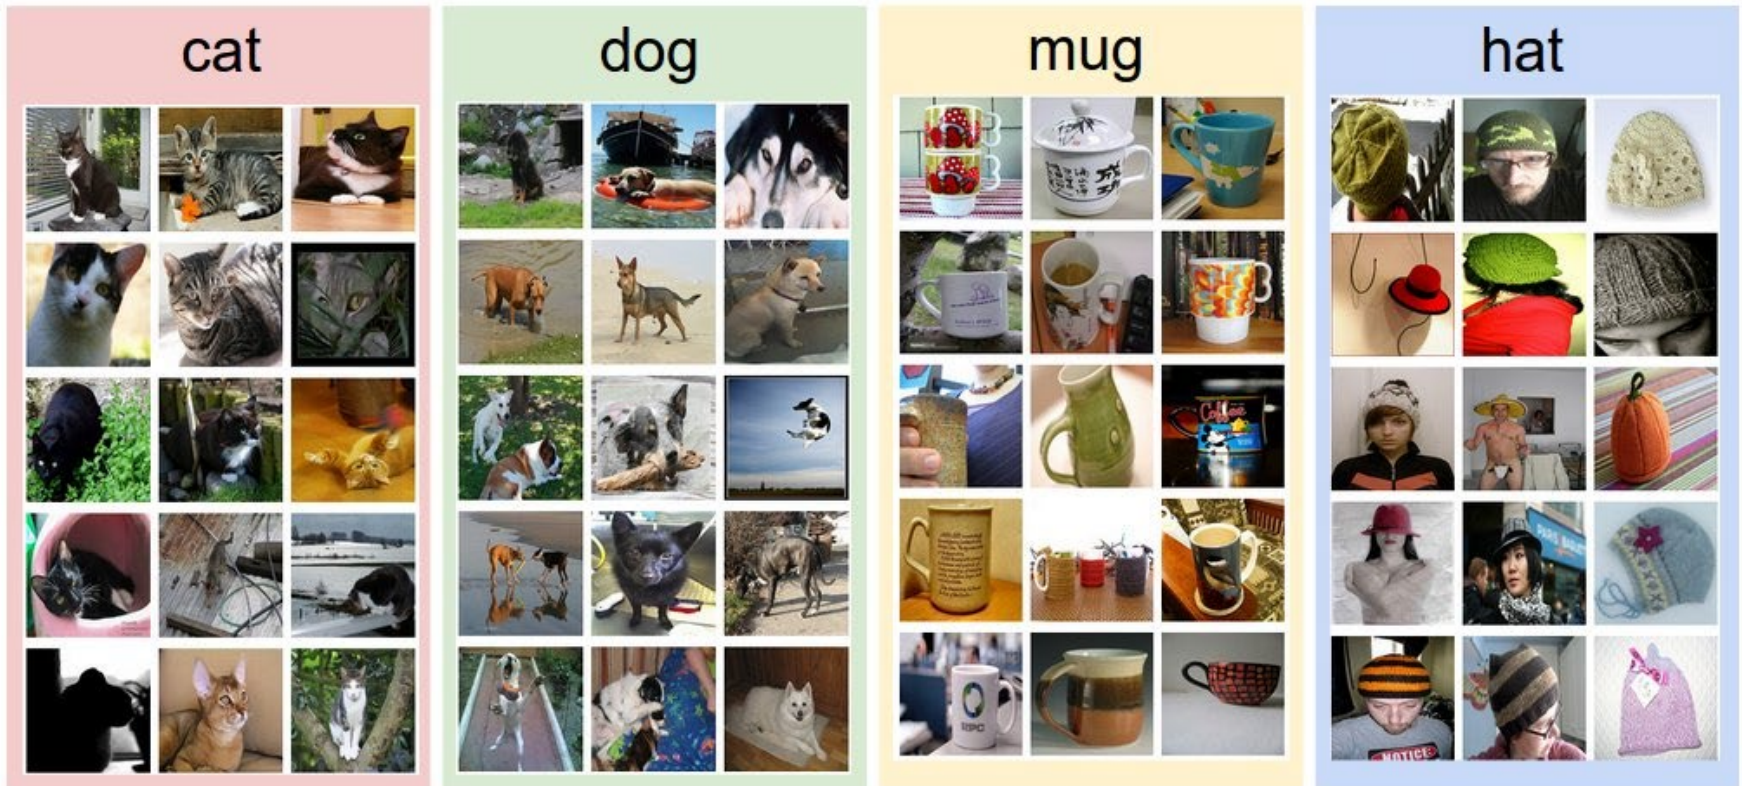
<http://cs231n.github.io/assets/classify.png>

Motivation – Classification d'images

Principales étapes

- **Éntrée** : N images, chacune étiquetée par l'une des K classes. C'est l'ensemble de **données d'entraînement**.
- **Apprentissage** : On utilise les données d'entraînement pour apprendre à quoi ressemble chacune des classes. C.à-d., on entraîne un classifieur, autrement dit, on **apprend le modèle**.
- **Évaluation**: Finalement, on évalue la qualité du classifieur en lui demandant de prédire les étiquettes pour un ensemble d'images vues pour la première fois.

Exemple 1 – Classification d'images



<http://cs231n.github.io/assets/trainset.jpg>

Exemple 2 – Reconnaissance de caractères

- Reconnaissance de caractères manuscrits

Ensemble d'entraînement

(100 exemples d'apprentissage par classe)



Classe 'e'



Classe 'o'

APPRENTISSAGE SUPERVISÉ : FORMULATION DU PROBLÈME

Apprentissage supervisé

Un problème d'apprentissage supervisé est formulé comme suit.

Étant donné un ensemble d'entraînement de N exemples:

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N) \} D$$

où chaque y_j a été généré par une fonction inconnue $y = f(\mathbf{x})$,

Trouve une nouvelle fonction h (modèle ou hypothèse)

qui sera une bonne approximation de f (c'est à dire $f(\mathbf{x}) \approx h(\mathbf{x})$) »



Apprentissage supervisé

- Étant donné un ensemble de données d'entraînement, l'apprentissage est un problème de **recherche** de l'hypothèse h **dans un espace d'hypothèses** H , tel que h minimise la **distance** à $f(x)$



- Les données sont souvent bruitées et disponibles en quantité limitée. Il y a donc une variation dans les données et dans les modèles (représentations).
- L'erreur dépend de la qualité des données d'entraînements et de la méthode utilisée pour sélectionner/chercher la bonne hypothèse

Apprentissage supervisé

- Données : **ensemble d'entraînement** de N exemples:

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N) \} D \quad \text{avec} \quad y = f(\mathbf{x})$$

- Problème : trouver $h(x)$ tel que $f(\mathbf{x}) \approx h(\mathbf{x})$
- Un algorithme d'apprentissage peut donc être vu comme étant une fonction A à laquelle on donne un ensemble d'entraînement et qui donne en retour la fonction h

$$A(D) = h$$


Modèles et approche pour chercher la fonction h

- Dépendamment des approches d'apprentissage, la fonction h peut être représentée de différente manière.
- Dans ce cours, nous voyons:
 - ◆ K plus proches voisins
 - ◆ Perceptron
 - ◆ Régression logistique
 - ◆ Réseau de neurones
 - ◆ Arbre de décision
- Le livre couvre différentes autres approches

REPRÉSENTATION DES DONNÉES

Représentation des données

- L'**entrée** \mathbf{X} est représentée par un vecteur de valeurs d'attributs réels (représentation factorisée)
 - ◆ ex.: une image est représentée par un vecteur contenant la valeur de chacun des pixels



```
array([ 0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  
        0.,  0.,  0.,  0.,  0.,  0.,  1.,  1.,  0.,  0.,  0.,  0.,  0.,  
        1.,  1.,  1.,  1.,  0.,  0.,  0.,  1.,  1.,  0.,  0.,  1.,  0.,  
        0.,  0.,  1.,  0.,  0.,  0.,  1.,  0.,  0.,  0.,  1.,  0.,  0.,  
        1.,  1.,  0.,  0.,  1.,  1.,  0.,  1.,  1.,  0.,  0.,  0.,  1.,  
        1.,  1.,  1.,  0.,  0.,  0.,  0.,  0.,  1.,  0.,  0.,  0.,  0.,  
        0.,  0.,  0.,  1.,  0.,  0.,  0.,  0.,  0.,  0.,  1.,  0.,  1.,  0.,  
        0.,  0.,  0.,  0.,  1.,  0.,  1.,  1.,  1.,  1.,  1.,  1.,  1.,  
        0.,  0.,  0.,  1.,  1.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  
        0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.,  0.]
```

- La **sortie désirée** ou **cible** y aura une représentation différente selon le problème à résoudre:
 - ◆ problème de classification en C classes: valeur discrète (index de 0 à $C-1$)
 - ◆ problème de régression: valeur réelle ou continue

K PLUS PROCHES VOISINS

Illustration: 3 plus proches voisins

- Reconnaissance de caractère: est-ce un 'e' ou un 'o'?

Ensemble d'entraînement

(100 exemples d'apprentissage par classe)



Classe 'e'



Classe 'o'

Illustration: 3 plus proches voisins

- Reconnaissance de caractère: est-ce un 'e' ou un 'o'?

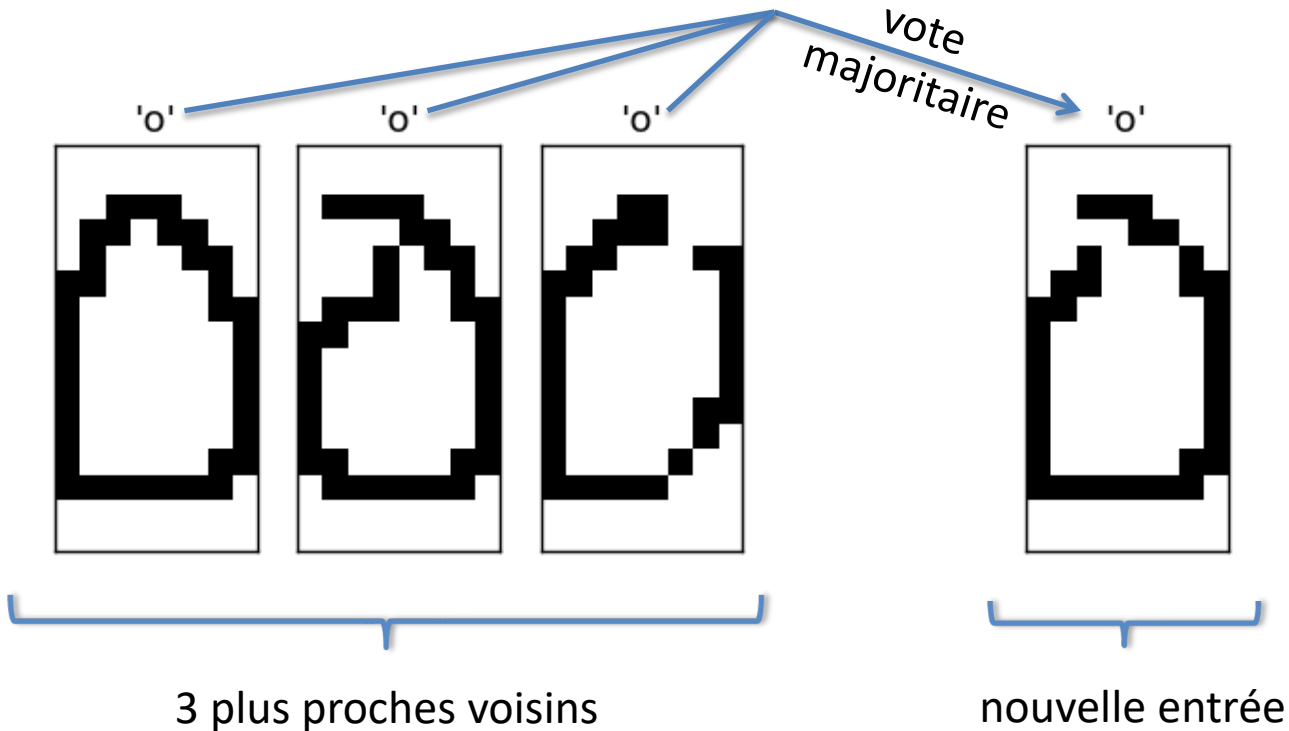


Illustration: 3 plus proches voisins

- Reconnaissance de caractère: est-ce un 'e' ou un 'o'?

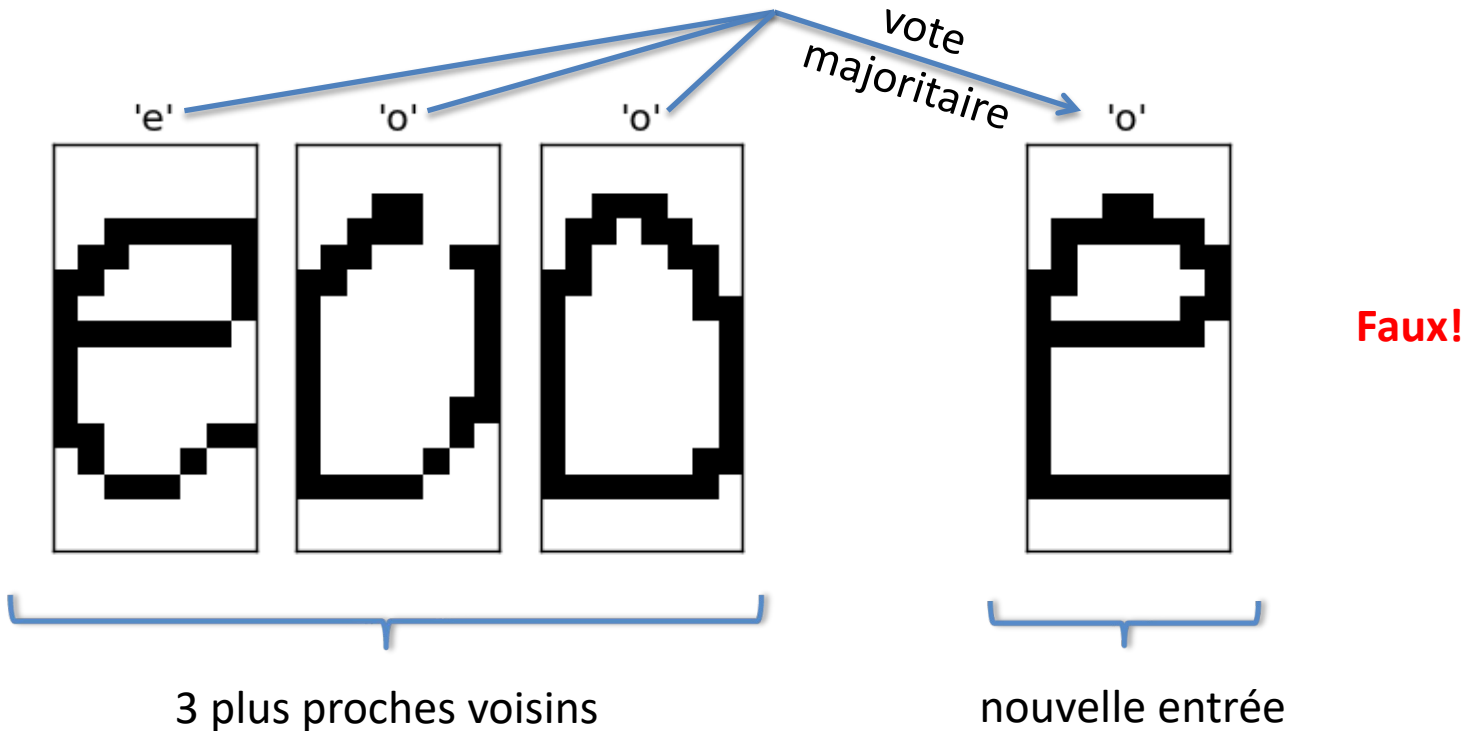
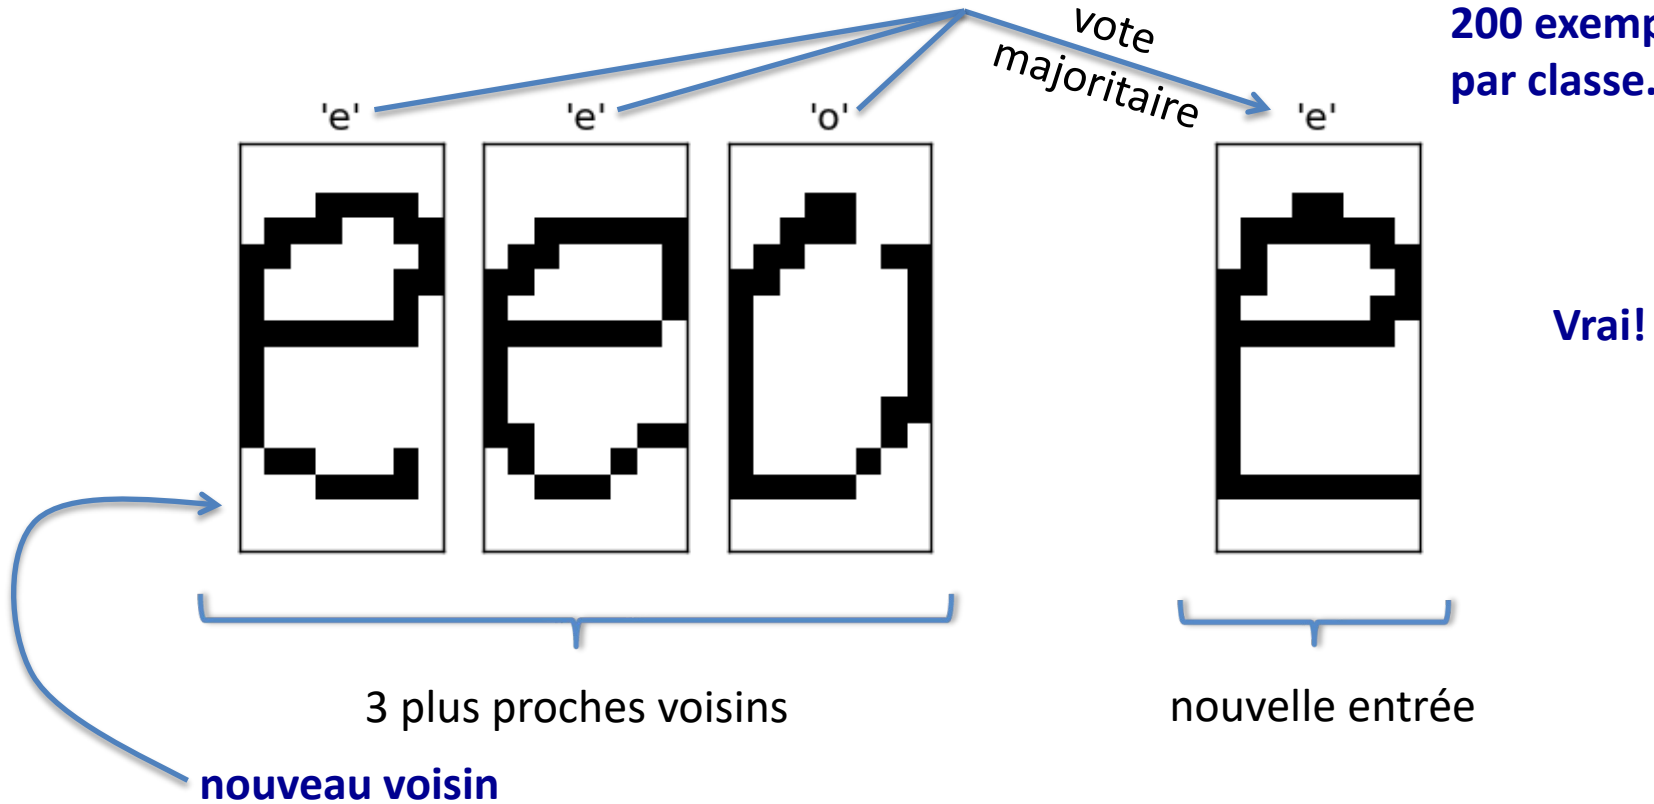


Illustration: 3 plus proches voisins

- Reconnaissance de caractère: est-ce un 'e' ou un 'o'?

Si on ajoute
200 exemples
par classe...



Exemple: classifieur k plus proches voisins

- Possiblement l'algorithme d'apprentissage de classification le plus simple
- **Idée:** étant donnée une entrée \mathbf{x}
 1. trouver les k entrées \mathbf{x}_t parmi les exemples d'apprentissage qui sont les plus « proches » de \mathbf{x}
 2. faire voter chacune de ces entrées pour leur classe associée y_t
 3. retourner la classe majoritaire
- Le succès de cet algorithme va dépendre de deux facteurs
 - ◆ la quantité de données d'entraînement (plus il y en a, meilleure sera la performance)
 - ◆ la qualité de la mesure de distance (est-ce que deux entrées jugées similaires sont de la même classe?)
 - » en pratique, on utilise souvent la distance Euclidienne:

$$d(\mathbf{x}_1, \mathbf{x}_2) = \sqrt{\sum_k (x_{1,k} - x_{2,k})^2}$$

\mathbf{X} = vecteur
 x = scalaire

Rappel - Apprentissage supervisé

- Un problème d'apprentissage supervisé est formulé comme suit:
« Étant donné un **ensemble d'entraînement** de N exemples:

$$(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N) \} D$$

où chaque y_j a été généré par une **fonction inconnue** $y = f(\mathbf{x})$,
découvrir une nouvelle fonction h (**modèle** ou **hypothèse**)
qui sera une bonne approximation de f (c'est à dire $f(\mathbf{x}) \approx h(\mathbf{x})$) »

- Un algorithme d'apprentissage peut donc être vu comme étant une fonction A à laquelle on donne un ensemble d'entraînement et qui donne en retour cette fonction h

$$A(D) = h$$

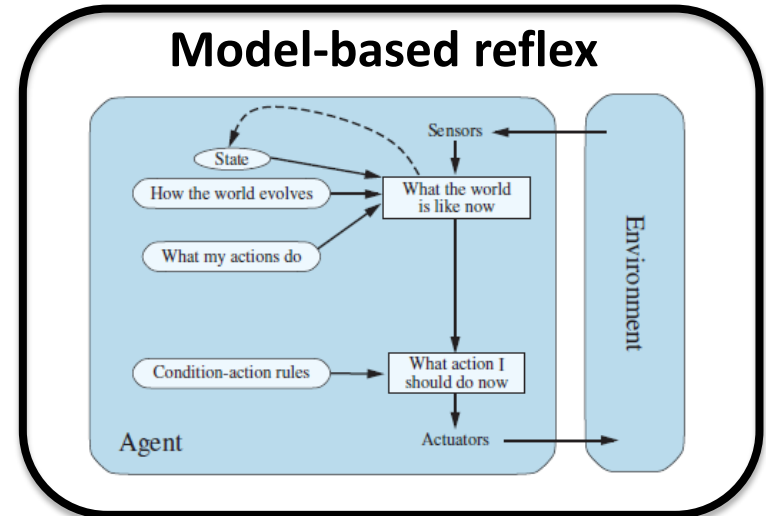
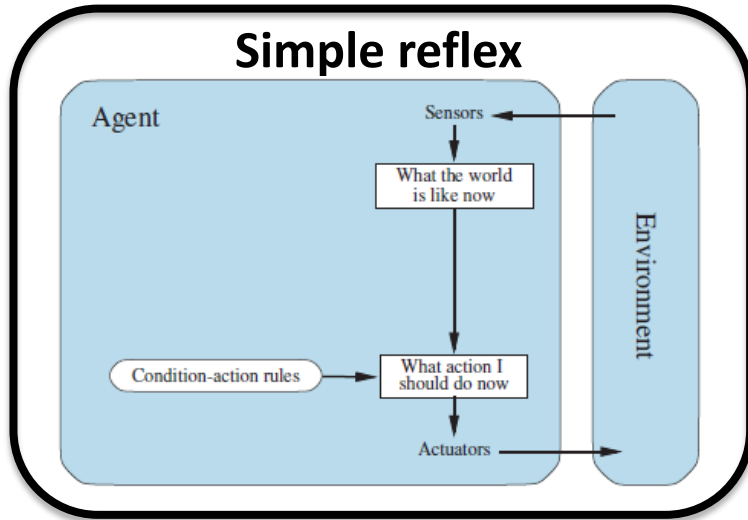
Retour sur classifieur k plus proches voisins

- Dans le cas de l'algorithme k plus proches voisins:
 - ◆ A est un programme qui produit lui-même un programme, soit celui qui fait une prédiction à l'aide de la procédure k plus proches voisins
 - ◆ $h = A(D)$ est le programme qui fait voter les k plus proches voisins dans D d'une entrée donnée
 - ◆ $h(\mathbf{x})$ est la sortie du programme pour l'entrée \mathbf{x} , c'est à dire une prédiction de la classe de \mathbf{x}
 - ◆ f est la « fonction » qui a généré nos données d'entraînement
 - ex.: l'être humain qui a étiqueté les images de caractères
- On peut démontrer que plus D est grand, plus h sera une bonne approximation de f
 - ◆ intuition: en augmentant la taille de l'ensemble d'entraînement, les k plus proches voisins ne peuvent changer qu'en étant encore plus proches (plus similaires) à l'entrée


Mesure de la performance d'un algorithme d'apprentissage

- Comment évaluer le succès d'un algorithme?
 - ◆ on pourrait regarder l'erreur moyenne commise sur les exemples d'entraînement, mais cette erreur sera nécessairement optimiste
 - » h a déjà vu la bonne réponse pour ces exemples!
 - » on mesure donc seulement la capacité de l'algorithme à **mémoriser**
- Ce qui nous intéresse vraiment, c'est la capacité de l'algorithme à **généraliser** sur de **nouveaux exemples**
 - ◆ ça reflète mieux le contexte dans lequel on va utiliser h
- Pour mesurer la généralisation, on met de côté des exemples étiquetés, qui seront utilisés seulement à la toute fin, pour calculer l'erreur
 - ◆ on l'appelle l'**ensemble de test**
 - ◆ on y reviendra de façon plus approfondie plus tard

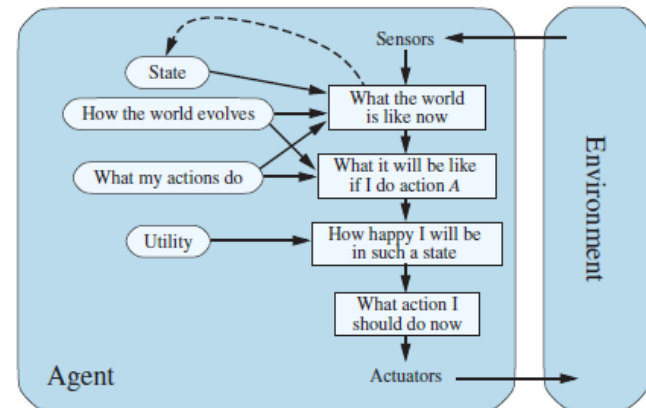
Algorithme des K plus proches voisins pour quel type d'agent?



Goal-based



Utility-based



Vous devriez être capable de...

- Nommer les trois formes d'apprentissage: supervisé, non supervisé, par renforcement
- Expliquer et simuler l'algorithme des K plus proches voisins