

Classification robuste et apprentissage faiblement supervisé

Apprendre à partir de données avec des labels incertains

Charles Bouveyron

**SAMOS-MATISSE, CES, UMR CNRS 8174
Université Paris 1 Panthéon-Sorbonne
Paris, France**

*Travail commun avec Stéphane Girard
INRIA Rhône-Alpes, France*

Plan de l'exposé

- 1 Introduction
- 2 Le problème du bruit de labels en classification
- 3 Un modèle de mélange pour la classification robuste
- 4 Procédure d'estimation
- 5 Résultats expérimentaux
- 6 Application : localisation d'objets faiblement supervisé
- 7 Conclusion

Plan de l'exposé


- 1 Introduction
- 2 Le problème du bruit de labels en classification
- 3 Un modèle de mélange pour la classification robuste
- 4 Procédure d'estimation
- 5 Résultats expérimentaux
- 6 Application : localisation d'objets faiblement supervisé
- 7 Conclusion

Introduction


La classification est devenue **un problème récurrent** :

- qui intervient dans toutes les applications nécessitant une prise de décision,
- et l'approche probabiliste permet de quantifier le risque d'erreur de classement.

Exemple 1 : reconnaissance optique de caractères



Exemple 2 : reconnaissance d'objets à partir d'images



Introduction

En **classification supervisée** :

- la supervision humaine est requise pour associer des labels à un jeu de données dit d'apprentissage,
- ces données sont ensuite utilisées pour construire un classifieur supervisé.

Cependant, dans de nombreuses applications :

- la supervision humaine peut s'avérer **imprécise** ou **difficile** (données complexes, fatigue de l'expert, ...),
- et le coût de la supervision peut limiter le nombre d'observation étiquetées.

Par conséquent :

- quelques **erreurs humaines** dans la supervision peuvent avoir une grande importance dans la classification finale,
- ce, en particulier, si la taille du jeu d'apprentissage est limité.

Exemples introductifs

Détection automatique de cellules pathologiques (cancer) :




Fig. – Cytologie en couche mince

- proportion (très) faible de données de la classe «cancer» par rapport à la classe «sain»,
- détection difficile des cellules en mutation (sain \rightarrow cancer),
- tâche de supervision très fatigante.

Exemples introductifs




Fig. – Comparaison des performances humaine et de l'ordinateur

Exemples introductifs

Localisation d'objets dans des images :




Fig. – Localisation de l'objet «vélo»

- domaine en forte croissance : reconnaissance de visages, détection de piétons, ...
- qui nécessite la supervision manuelle d'un grand nombre d'images,

Les problèmes :

- nombre potentiellement infini de catégories d'objets,
- segmentation des objets fastidieuse et imprécise.

Exemples introductifs

Reconnaissance / localisation d'objets dans des images :



Fig. – Supervision faible grâce à Google Image

Plan de l'exposé

- 1 Introduction
- 2 Le problème du bruit de labels en classification**
- 3 Un modèle de mélange pour la classification robuste
- 4 Procédure d'estimation
- 5 Résultats expérimentaux
- 6 Application : localisation d'objets faiblement supervisé
- 7 Conclusion

Le problème de la classification

Le **problème de la classification** est :


- à partir d'un jeu d'apprentissage \mathcal{A} :

$$\mathcal{A} = \{(x_1, z_1), \dots, (x_n, z_n)\} \in \mathbb{R}^p \times \{1, \dots, K\}$$

- construire une **règle de décision** δ :

$$\delta : \mathbb{R}^p \rightarrow \{1, \dots, K\}.$$

$$x \rightarrow z.$$



La règle optimale δ^* est celle qui affecte x à la classe la plus probable a posteriori (règle du MAP) :

$$\delta^*(x) = \operatorname{argmax}_{i=1, \dots, K} P(Z = i | X = x).$$

La classification probabiliste

Le modèle de mélange :

- on suppose classiquement que les observations x_1, \dots, x_n sont des réalisations indépendantes,
- d'un vecteur aléatoire $X \in \mathbb{R}^p$ dont la densité s'écrit :

$$f(x) = \sum_{k=1}^K \pi_k f(x, \theta_k).$$

La règle du MAP s'écrit dans ce cas :

$$\begin{aligned} \delta^*(x) &= \operatorname{argmax}_{k=1, \dots, K} P(Z = k | X = x) \\ &= \operatorname{argmax}_{k=1, \dots, K} P(Z = k) P(X = x | Z = k) \\ &= \operatorname{argmax}_{k=1, \dots, K} \pi_k f(x, \theta_k). \end{aligned}$$

Remarque : la construction de la règle de décision consiste à
(i) estimer les paramètres θ_k et (ii) calculer la valeur de $H_k(x)$.

Le problème du bruit de labels

En apprentissage statistique :

- il est très commun de supposer que les données sont bruitées,
- le problème du bruit sur les variables explicatives a été étudié largement dans la littérature,
- alors que le bruit sur la variable à prédire a reçue nettement moins d'attention (excepté en régression).

En classification supervisée :

- le bruit sur les labels est un problème important puisque toutes les méthodes supervisées font une **confiance totale** aux labels,
- et leur règle de décision sont par conséquent très sensibles à ce type de bruit :
 - les approches discriminatives de part la construction de la frontière,
 - les approches génératives de part l'estimation des paramètres.

Méthodes de «nettoyage des données» :

- ce sont les approches les plus anciennes : Gates (1972), Dasarathy (1980), ...
- l'idée est d'enlever les observations mal étiquetées en se basant sur des recherches d'*outliers*,
- cela induit cependant un biais dans la procédure d'apprentissage.

Estimation robuste des paramètres :

- dans le contexte des méthodes génératives, quelques travaux ont portés sur l'estimation robuste des paramètres du modèle,
- mais la réduction du taux de mauvaise classification s'est avérée faible.

Solutions existantes

Prise en compte de l'incertitude sur les labels :

- Côme *et al.* ont proposé récemment une approche basée sur le modèle de mélange pour classer des données avec labels imprécis,
- mais la méthode requiert de connaître l'incertitude de chacun des labels.

Modélisation du bruit de labels :

- Lawrence et Sholköpf ont proposé récemment un algorithme construisant un classifieur à noyau et incluant une modélisation explicite du bruit de labels,
- Li *et al.* ont étendu ce travail en permettant la modélisation de chaque classe par un mélange de gaussiennes,
- cependant, ces approches considèrent uniquement le cas de la [classification binaire](#).

Plan de l'exposé

- 1 Introduction
- 2 Le problème du bruit de labels en classification
- 3 Un modèle de mélange pour la classification robuste**
- 4 Procédure d'estimation
- 5 Résultats expérimentaux
- 6 Application : localisation d'objets faiblement supervisé
- 7 Conclusion

L'idée du modèle

L'idée de notre approche est :

- de comparer l'information supervisée portée par les données d'apprentissage,
- avec une modélisation non supervisée par modèle de mélange des données .

Avec une telle approche :

- la comparaison de l'information supervisée avec le modèle non supervisé devrait permettre de détecter les **labels inconsistants**,
- et il sera ainsi possible de construire un **classifieur supervisé robuste** en donnant une faible importance aux observations d'apprentissage ayant des labels inconsistants.

Un modèle de mélange pour la classification robuste

Nous considérons un **modèle de mélange** avec :

- une structure non supervisée de K groupes représentée par la variable aléatoire discrète S ,
- et une structure supervisée de k classes représentée par la variable aléatoire discrète C .

Avec les hypothèses et notations du modèle de mélange :

- les données (x_1, \dots, x_n) sont des réalisations indépendantes d'un vecteur aléatoire $X \in \mathbb{R}^p$ dont la densité est :

$$p(x) = \sum_{j=1}^K P(S = j)p(x|S = j), \quad (1)$$

- où $P(S = j)$ et $p(x|S = j)$ sont respectivement la probabilité *a priori* et la densité conditionnelle du j ème groupe.

Un modèle de mélange pour la classification robuste

Nous introduisons à présent l'**information supervisée** :

- puisque $\sum_{i=1}^k P(C = i|S = j) = 1$ pour tout $j = 1, \dots, K$, nous pouvons introduire cette quantité dans (1) pour obtenir :

$$p(x) = \sum_{i=1}^k \sum_{j=1}^K P(C = i|S = j)P(S = j)p(x|S = j), \quad (2)$$

- où $P(C = i|S = j)$ peut être interprété comme la probabilité que le j ème groupe appartienne à la i ème classe.

En utilisant les notations classiques :

- l'équation (2) peut être reformulée :

$$p(x) = \sum_{i=1}^k \sum_{j=1}^K r_{ij}\pi_j f(x, \theta_j), \quad (3)$$

- où $r_{ij} = P(C = i|S = j)$, $\pi_j = P(S = j)$ et f est la densité conditionnelle du j ème groupe de paramètre θ_j .

Choix du modèle de mélange

Ce choix dépend de la nature des données :

- données quantitatives :
 - modèle gaussien classique,
 - modèle gaussien parcimonieux,
 - modèle gaussien pour les données de grande dimension.
- données qualitatives :
 - modèle multinomial
 - les données ne doivent pas être de trop grande dimension.

Le choix du modèle :

- est laissé à la discrétion du praticien,
- qui pourra s'aider d'outils comme le critère BIC si besoin.

Règle de classification

De façon classique, nous utilisons la **règle du MAP** :

- qui affecte une nouvelle observation x à la classe la plus probable *a posteriori*,
- ainsi, l'étape de classification consiste principalement à calculer $P(C = i|X = x)$ pour chaque classe $i = 1, \dots, k$.

Dans le cas du modèle présenté :

- la **probabilité a posteriori** $P(C = i|X = x)$ vaut :

$$P(C = i|X = x) = \sum_{j=1}^K r_{ij}P(S = j|X = x),$$

- nous avons donc pour ce faire à estimer les paramètres r_{ij} et les probabilités *a posteriori* $P(S = j|X = x)$.

Liens avec Mixture Discriminant Analysis

Mixture Discriminant Analysis:

- chaque classe est modélisée par un mélange de K_i gaussiennes,
- MDA suppose que la densité conditionnelle de chaque classe est :

$$p(x|C = i) = \sum_{j=1}^K \pi_{ij} \phi(x; \mu_j, \Sigma_j),$$

Par conséquent :

- nous pouvons réécrire la densité $p(x)$:

$$p(x) = \sum_{i=1}^k \sum_{j=1}^K r_{ij} \pi_j \phi(x; \mu_j, \Sigma_j),$$

- où $r_{ij} = P(C = i|S = j)$ est connu et vaut $r_{ij} = 1$ si le j ème groupe appartient à la i ème classe et $r_{ij} = 0$ sinon.

Plan de l'exposé

- 1 Introduction
- 2 Le problème du bruit de labels en classification
- 3 Un modèle de mélange pour la classification robuste
- 4 Procédure d'estimation**
- 5 Résultats expérimentaux
- 6 Application : localisation d'objets faiblement supervisé
- 7 Conclusion

Estimation des paramètres du mélange

Du fait de la nature du modèle présenté :

- la procédure d'estimation est faite de deux étapes,
- correspondant respectivement aux parties non supervisée et supervisée de la comparaison.

Estimation des paramètres du mélange :

- dans cette première étape, les labels ne sont pas utilisés pour former K groupes homogènes,
- l'algorithme EM est utilisé pour estimer les paramètres du mélange par maximisation de la vraisemblance,
- les formules de mise à jour de l'algorithme EM dépendent du modèle choisi (gaussien, gaussien HD, multinomial, ...).

Estimation des paramètres r_{ij}

Estimation des paramètres r_{ij} par MV :

- la log-vraisemblance du modèle proposé est :

$$\ell(R) = \sum_{i=1}^k \sum_{x \in \mathcal{C}_i} \log \left(\sum_{j=1}^K r_{ij} P(S = j | X = x) \right) + C^{ste}.$$

- ce qui conduit au problème d'optimisation sous contraintes :

$$\left\{ \begin{array}{l} \text{maximiser :} \quad \sum_{i=1}^k \sum_{x \in \mathcal{C}_i} \log (R_i \Psi(x)), \\ \text{sous la contrainte :} \quad r_{ij} \in [0, 1], \forall i = 1, \dots, k, \forall j = 1, \dots, K, \\ \text{et la contrainte :} \quad \sum_{i=1}^k r_{ij} = 1, \forall j = 1, \dots, K, \end{array} \right.$$

où $\Psi(x) = (P(S = 1 | X = x), \dots, P(S = K | X = x))^t$ et R_i est la i ème ligne de $R = (r_{ij})$.

Choix du nombre de groupes

Choix de K :

- nous pouvons utiliser les outils classiques du modèle de mélange,
- en particulier le critère BIC est tout à fait adapté à la situation.

Remarque :

- le choix du nombre de composantes par classe dans RMDA est beaucoup plus simple que le choix des K_i dans MDA,
- pour RMDA, il suffit de choisir K et le nombre de composantes par classe s'adaptent automatiquement de part l'estimation des paramètres r_{ij} .

Plan de l'exposé

- 1 Introduction
- 2 Le problème du bruit de labels en classification
- 3 Un modèle de mélange pour la classification robuste
- 4 Procédure d'estimation
- 5 Résultats expérimentaux**
- 6 Application : localisation d'objets faiblement supervisé
- 7 Conclusion


Simulation du bruit de labels :

- nous considérons le cas de l'échange de labels,
- les labels des observations sont échangés selon une loi de Bernoulli de paramètre $\eta \in [0, 1]$,
- η représente donc le taux de contamination.


Méthodes comparées :

- Linear Discriminant Analysis (LDA),
- Mixture Discriminant Analysis (MDA),
- Robust Linear Discriminant Analysis (RLDA),
- Robust Mixture Discriminant Analysis (RMDA),

Classification binaire (données simulées)



MDA avec $\eta = 0$




RMDA avec $\eta = 0$


Données simulées :

- deux classes formées par un mélange de 2 gaussiennes,
- dans un espace de dimension $p = 2$.

Classification binaire (données simulées)




MDA avec $\eta = 0.15$




RMDA avec $\eta = 0.15$

Classification binaire (données simulées)




MDA avec $\eta = 0.30$




RMDA avec $\eta = 0.30$

Classification binaire (données simulées)




MDA avec $\eta = 0.45$



RMDA avec $\eta = 0.45$


Classification binaire (données simulées)



Données simulées :

- deux classes formées par un mélange de 2 gaussiennes,
- dans un espace de dimension $p = 50$,
- 750 obs. pour l'apprentissage, le bruit de label $\eta = 0, \dots, 0.5$,
- l'expérience a été répétée 25 fois pour moyenner les résultats.


Classification binaire (données réelles)



Données réelles :

- données de reconnaissance optique de caractères (USPS),
- 2 classes (caractères '2' et '4') en dimension 256,
- 7250 obs. pour l'apprentissage et 25 rép. de l'expérience.

Classification multi-classes (données simulées)



Données simulées :

- 3 classes formées par un mélange de 2 gaussiennes
- dans un espace de dimension 50,
- 750 obs. pour l'apprentissage, le bruit de label $\eta = 0, \dots, 2/3$,
- l'expérience a été répétée 25 fois pour moyenner les résultats.

Plan de l'exposé

- 1 Introduction
- 2 Le problème du bruit de labels en classification
- 3 Un modèle de mélange pour la classification robuste
- 4 Procédure d'estimation
- 5 Résultats expérimentaux
- 6 Application : localisation d'objets faiblement supervisé**
- 7 Conclusion

Classification faiblement supervisée

La **classification faiblement supervisée** :

- nouveau type de classification supervisée (\neq semi-supervisée),
- qui utilise comme supervision des informations disponibles facilement et à faible coût,
- exemples :
 - informations de contexte \rightarrow images, documents,
 - segmentation rapide \rightarrow images.

L'**idée de l'extension** :


- utiliser des sources d'information pour associer un label à des groupes d'observations,
- en ayant conscience que l'on commet des erreurs de labels,
- et utiliser RMDA pour discriminer les classes présentes dans les données.

Localisation d'objets dans des images

La localisation d'objets dans des images naturelles :

- est un des problèmes les plus difficiles en vision par ordinateur,
- du fait du très grand nombre de catégories d'objets,
- et de la grande variété des objets considérés.

L'approche classique :



- chaque image est représentée par des **points d'intérêt**,
- qui sont décrits grâce à des **descripteurs locaux** de grande dimension ($p = 128$),
- puis ces descripteurs sont affectés à la classe «objet» ou à la classe «fond».

Localisation faiblement supervisée

Localisation supervisée :

- segmentation manuelle des objets dans les images d'apprentissage,
- descripteurs locaux x_i :
 - x_i sur l'objet : $z_i = 1$,
 - x_i sur le fond : $z_i = 0$,

Localisation faiblement supervisée :

- on utilise un moteur de recherche pour trouver des images contenant l'objet étudié,
- descripteurs locaux x_i :
 - $x_i \in$ à une image contenant l'objet : $z_i = 1$,
 - $x_i \in$ à une image ne contenant pas l'objet : $z_i = 0$,
- les labels 0 sont tous justes alors qu'une partie des labels 1 sont faux.

Protocole expérimental

Les données :

- nous avons choisi d'utiliser le *Pascal dataset* (www.pascal-network.org),
- qui a servi à une compétition de localisation d'objets,
- comparaison des meilleures méthodes actuelles.

Le *Pascal dataset* :

- 684 images pour l'apprentissage,
- 2 jeux de test : 689 et 956 images resp. pour *test1* et *test2*,
- quatre catégories d'objets : moto, vélo, voiture et humains.

Évaluation des résultats :

- nous avons utilisé la mesure $AP \in [0, 1]$ proposée lors de la compétition,
- qui mesure l'adéquation entre la localisation proposée et réelle de l'objet.

Protocole expérimental

Learning



Test 1



Test 2



Bicycle

Human

Car

Motorbike

Résultats

Database	Pascal test 1		Pascal test 2	
	full	weak	full	weak
RMDA $[a_{ij}b_iQ_id_i]$	0.302	0.273	0.172	0.145
RMDA $[a_{ij}bQ_id_i]$	0.318	0.287	0.181	0.147
RMDA $[a_ib_iQ_id_i]$	0.313	0.285	0.183	0.142
RMDA $[a_ibQ_id_i]$	0.318	0.283	0.176	0.148
RMDA $[a_ib_iQ_id]$	0.314	0.287	0.179	0.130
RMDA spherical	0.271	0.216	0.149	0.106
RMDA diagonal	0.276	0.227	0.161	0.110
RMDA common	0.267	0.246	0.164	0.116
Best method of [9]	0.279	/	0.112	/

Résultats




Fig. Localisation d'une instance d'un objet.



Fig. Localisation de plusieurs instances d'un objet..

Plan de l'exposé

- 1 Introduction
- 2 Le problème du bruit de labels en classification
- 3 Un modèle de mélange pour la classification robuste
- 4 Procédure d'estimation
- 5 Résultats expérimentaux
- 6 Application : localisation d'objets faiblement supervisé
- 7 Conclusion

Conclusion

Nous avons donc proposé un **classifieur supervisé robuste** :

- qui prend en compte l'incertitude sur les labels,
- en comparant l'information portée par les labels à une modélisation non supervisée des données,
- qui s'adapte aux différents types de données par le choix du modèle de mélange.

Extension à la **classification faiblement supervisée** :

- nous avons montré qu'il est possible d'étendre la classification à partir de labels incertains,
- à une classification supervisée par des informations disponibles facilement,
- en acceptant qu'une partie des labels soient erronés.

Perspectives

D'un point de vue théorique :

- estimation du pourcentage d'incertitude par classe,
- incorporation de l'incertitude sur les labels donnée par l'expert,
- travail sur le cas des données qualitatives.

Du point de vue des applications :

- application à la cytologie et à la spectrométrie de masse,
- application en Biologie au DNA barcoding.