

Calibration et fusion évidentielles de classifieurs: application au cas de l'anonymisation de visages

Pauline Minary^{1,2}

1) Université d'Artois - LGL2A (Béthune)

2) SNCF Réseau (Saint Denis)

Sous la direction de Eric Lefèvre¹, David Mercier¹, Frédéric
Pichon¹ et Benjamin Droit²

Vendredi 8 Décembre 2017

Application SNCF : système EAS

- Système EAS : permet au conducteur de fermer les portes du train en toute sécurité.
- Vidéos enregistrées pour vérifier la bonne implantation des caméras.

Problème

SNCF voudrait stocker ces vidéos, mais la réglementation française sur le droit à l'image l'interdit.

⇒ Nouveau règlement européen sur la protection des données personnelles (mai 2018).

Application SNCF : système EAS

- Système EAS : permet au conducteur de fermer les portes du train en toute sécurité.
- Vidéos enregistrées pour vérifier la bonne implantation des caméras.

Problème

SNCF voudrait stocker ces vidéos, mais la réglementation française sur le droit à l'image l'interdit.

⇒ Nouveau règlement européen sur la protection des données personnelles (mai 2018).


Solution envisagée

Obtenir un système (semi) automatique d'anonymisation de visages sur vidéos.

Idée générale

Exemples de problèmes rencontrés :

- Qualité de l'image
- Taille et orientation des visages
- Etc.




Utiliser différents détecteurs et les fusionner pour améliorer les performances.

Idée générale

Exemples de problèmes rencontrés :

- Qualité de l'image
- Taille et orientation des visages
- Etc.




Utiliser différents détecteurs et les fusionner pour améliorer les performances.

Dans le domaine de la classification : **méthodes d'ensemble.**

Méthodes d'ensemble

Approche disjointe


- 1 **Calibration** des sorties de classifieurs et combinaison avec **une règle de fusion**.



Méthodes d'ensemble

Approche disjointe

- 1 **Calibration** des sorties de classifieurs et combinaison avec **une règle de fusion**.




- Calibration : apprendre comment interpréter ce que la sortie représente par rapport à la vraie classe.

Méthodes d'ensemble

Approche conjointe

- ② **Concaténation** des sorties de classifieurs et combinaison avec un classifieur additionnel.



Ma proposition

- Approche disjointe : Xu *et al.* (2016) ont étudié l'extension de la calibration grâce à la **théorie de l'évidence**, dans le cas d'un seul classifieur.
- Approche conjointe : peut être vue comme une **calibration conjointe**.

Ma proposition

- Approche disjointe : Xu *et al.* (2016) ont étudié l'extension de la calibration grâce à la **théorie de l'évidence**, dans le cas d'un seul classifieur.
- Approche conjointe : peut être vue comme une **calibration conjointe**.

Ce que l'on propose :

- 1 Étendre les techniques de calibrations conjointes au formalisme évidentiel.
- 2 Les appliquer au problème d'anonymisation de visages.

Outline

- 1 Théorie de l'évidence
- 2 Calibration évidentielle
- 3 Application : anonymisation de visages
- 4 Conclusion et perspectives

Outline

- 1 Théorie de l'évidence
 - Concepts fondamentaux
 - Inférence statistique et prédiction
- 2 Calibration évidentielle
- 3 Application : anonymisation de visages
- 4 Conclusion et perspectives

Qu'est ce que c'est ?

- Informations imparfaites : incertaines et/ou imprécises.
⇒ **Théorie de l'évidence** : formalisme permettant de représenter et gérer ces données imparfaites.
- Introduite par Dempster (1968) et Shafer (1976), développée par Smets (1990).
- De nombreuses applications : médical, robotique, etc.

Représentation de l'information

- **Cadre de discernement** Ω : ensemble fini de réponses possibles à une certaine question.

Fonction de Masse (FM)

Une FM (normalisée) sur Ω est une fonction $m^\Omega : 2^\Omega \rightarrow [0, 1]$ t.q.

$$m^\Omega(\emptyset) = 0 \text{ et } \sum_{A \subseteq \Omega} m^\Omega(A) = 1. \quad (1)$$

$m^\Omega(A)$: quantifie la croyance allouée exactement à l'hypothèse $\omega_0 \in A$ et à aucune autre proposition plus spécifique.

- $A \subseteq \Omega$ tq $m^\Omega(A) > 0$: **élément focal** de m^Ω .
- $m^\Omega(\Omega) = 1$: m^Ω est dite **vide**.
- $A_1 \subseteq A_2 \subseteq \dots \subseteq A_N$: m^Ω est dite **consonante**.

Représentation de l'information

Fonction de croyance

$$Bel^{\Omega}(A) = \sum_{B \subseteq A} m^{\Omega}(B), \quad \forall A \subseteq \Omega. \quad (2)$$

Degré avec lequel les informations disponibles accréditent l'hypothèse $\omega_0 \in A$.

Fonction de plausibilité

$$Pl^{\Omega}(A) = \sum_{B \cap A \neq \emptyset} m^{\Omega}(B), \quad \forall A \subseteq \Omega. \quad (3)$$

Degré avec lequel les informations disponibles ne discréditent pas l'hypothèse $\omega_0 \in A$.

- Fonction de contour : $pl^{\Omega}(\omega) = Pl^{\Omega}(\{\omega\})$, $\forall \omega \in \Omega$.

Combinaison des informations

Règle de Dempster

- Soient m_1^Ω et m_2^Ω deux FM's issues de sources indépendantes.

Règle de Dempster

$$\begin{aligned} m_{1 \oplus 2}^\Omega(A) &= (m_1^\Omega \oplus m_2^\Omega)(A), \\ &= \frac{1}{1 - \kappa} \sum_{B \cap C = A} m_1^\Omega(B) m_2^\Omega(C), \quad \forall A \neq \emptyset, \end{aligned} \quad (4)$$

où $\kappa = \sum_{B \cap C = \emptyset} m_1^\Omega(B) m_2^\Omega(C)$: degré de conflit entre m_1^Ω et m_2^Ω .

- $m_{1 \oplus 2}^\Omega(\emptyset) = 0$.
- $\oplus$ est commutative, associative et la FM vide est l'unique élément neutre.

Prise de décision

[Chow 94, Denœux 97]

- But : prendre une décision sur la valeur ω_0 de ω , étant donnée la connaissance sur ω_0 représentée par la FM m^Ω .
- Risques :

$$R^*(\omega) = \sum_{A \subseteq \Omega} m^\Omega(A) \max_{\omega' \in A} c(\omega, \omega'), \quad (\text{Pessimiste})$$

$$R_*(\omega) = \sum_{A \subseteq \Omega} m^\Omega(A) \min_{\omega' \in A} c(\omega, \omega'), \quad (\text{Optimiste})$$

avec $c(\omega, \omega')$: coût de décider ω quand la vraie réponse est ω' .

- Cas particulier coûts 0-1 : $c(\omega, \omega') = \begin{cases} 0 & \text{si } \omega = \omega', \\ 1 & \text{sinon} \end{cases}$

Prise de décision

[Chow 94, Denœux 97]

- But : prendre une décision sur la valeur ω_0 de ω , étant donnée la connaissance sur ω_0 représentée par la FM m^Ω .
- Risques :

$$R^*(\omega) = \sum_{A \subseteq \Omega} m^\Omega(A) \max_{\omega' \in A} c(\omega, \omega'), \quad (\text{Pessimiste})$$

$$R_*(\omega) = \sum_{A \subseteq \Omega} m^\Omega(A) \min_{\omega' \in A} c(\omega, \omega'), \quad (\text{Optimiste})$$

avec $c(\omega, \omega')$: coût de décider ω quand la vraie réponse est ω' .

- Cas particulier coûts 0-1 : $c(\omega, \omega') = \begin{cases} 0 & \text{si } \omega = \omega', \\ 1 & \text{sinon} \end{cases}$
- Cas “risqués” : on introduit coût de rejet R_{rej} .

Inférence statistique dans le cadre évidentiel

- Soient $\theta \in \Theta$ un paramètre inconnu, $x \in \mathbb{X}$ une donnée observée et $f_{\theta}(x)$ la fonction de densité qui génère les données.

Inférence statistique dans le cadre évidentiel

- Soient $\theta \in \Theta$ un paramètre inconnu, $x \in \mathbb{X}$ une donnée observée et $f_{\theta}(x)$ la fonction de densité qui génère les données.

L'inférence (estimation) statistique consiste à estimer θ sachant x .

Inférence statistique dans le cadre évidentiel

- Soient $\theta \in \Theta$ un paramètre inconnu, $x \in \mathbb{X}$ une donnée observée et $f_\theta(x)$ la fonction de densité qui génère les données.

L'inférence (estimation) statistique consiste à estimer θ sachant x .

- On peut représenter la connaissance sur θ par une croyance consonante Bel_x^Θ dont la fonction contour est [Shafer 76, Denœux 14] :

$$pl_x^\Theta(\theta) = \frac{L_x(\theta)}{\sup_{\theta' \in \Theta} L_x(\theta')}, \quad \forall \theta \in \Theta. \quad (5)$$

où $L_x : \theta \rightarrow f_\theta(x)$ la fonction de vraisemblance.

Inférence statistique dans le cadre évidentiel

Exemple

Trains qui partent de Gare du Nord : à l'heure ou non.

- θ : probabilité qu'un train soit à l'heure.
- n trains observés, et $x \leq n$ de ces trains étaient à l'heure.
- Hypothèse : un train en retard n'a pas d'impact sur les autres.

$\Rightarrow X \sim \mathcal{B}(n, \theta)$. La vraisemblance de $\theta \in [0, 1]$ est

$$L_x(\theta) = \binom{n}{x} \theta^x (1 - \theta)^{n-x}. \quad (6)$$


Donc la fonction de contour est :

$$p_{|x}^{\Theta}(\theta) = \frac{\theta^x (1 - \theta)^{n-x}}{\hat{\theta}^x (1 - \hat{\theta})^{n-x}}, \quad (7)$$

pour tout $\theta \in \Theta = [0, 1]$, où $\hat{\theta} = \frac{x}{n}$.

Inférence statistique dans le cadre évidentiel

Exemple, $n = 30$, $x = 10$



Prédiction

- Supposons à présent qu'ayant observé x , des informations sont disponibles sur θ sous la forme d'une fonction contour $p|_x^\Theta$.

La prédiction consiste à donner des éléments sur une donnée non encore observée $Y \in \mathbb{Y}$, dont la distribution étant donné $X = x$ dépend de θ .

Prédiction

- Supposons à présent qu'ayant observé x , des informations sont disponibles sur θ sous la forme d'une fonction contour pl_x^Θ .

La prédiction consiste à donner des éléments sur une donnée non encore observée $Y \in \mathbb{Y}$, dont la distribution étant donné $X = x$ dépend de θ .


- Kanjanatarakul *et al.* (2014) ont montré que quand $Y \in \mathbb{Y} = \{0, 1\}$ tel que $Y \sim \mathcal{B}(\theta)$, on a

$$Bel_x^{\mathbb{Y}}(\{1\}) = \hat{\theta} - \int_0^{\hat{\theta}} pl_x^\Theta(u) du, \quad Pl_x^{\mathbb{Y}}(\{1\}) = \hat{\theta} + \int_{\hat{\theta}}^1 pl_x^\Theta(v) dv, \quad (8)$$

où $\hat{\theta}$ maximise pl_x^Θ .


Prédiction

Exemple, $n = 30$, $x = 10$



Prédiction

Exemple, $n = 30$, $x = 10$



Outline

- 1 Théorie de l'évidence
- 2 **Calibration évidentielle**
 - Calibration d'un classifieur
 - Extension au cas évidentiel
 - Calibration conjointe évidentielle de classifieurs
 - Tests expérimentaux
- 3 Application : anonymisation de visages
- 4 Conclusion et perspectives

Calibration d'un classifieur

- Considérons un objet dont la vraie classe y est tq $y \in \mathbb{Y} = \{0, 1\}$, et un score $s \in \mathbb{R}$ donné par un classifieur après avoir observé l'objet.

Définition


La calibration d'un score s consiste à estimer $p^{\mathbb{Y}}(1|s)$ en utilisant un ensemble d'apprentissage $\mathcal{X}$.

- $\mathcal{X} = \{(s_1, y_1), \dots, (s_n, y_n)\}$: s_i score retourné par le classifieur pour le $i^{\text{ème}}$ objet qui a pour vraie classe y_i .
- Trois principales calibrations : binning, isotonique, logistique.

Binning probabiliste

- Consiste à diviser l'espace des scores en plusieurs bins (intervalles contigus).
- Pour chaque bin j ,
 - k_j : nombre de paires $(s_i, y_i) \in \mathcal{X}$ tq $y_i = 1$ et s_i dans le bin j ,
 - n_j : nombre de paires $(s_i, y_i) \in \mathcal{X}$ tq s_i dans le bin j .
- Pour un nouveau score s , tq s contenu par le bin j , on a

$$P^{\mathbb{Y}}(y = 1|s) = \frac{k_j}{n_j}.$$



Extension au cas évidentiel

- Certaines valeurs de scores peuvent être moins présentes que d'autres dans $\mathcal{X} \Rightarrow$ certaines probabilités moins précises.
- **Calibration évidentielle** [Xu et al., 16] : étant donné un nouveau score s , un intervalle $[Bel^{\mathbb{Y}}(1|s), Pl^{\mathbb{Y}}(1|s)]$ est obtenu.

Extension au cas évidentiel

- Certaines valeurs de scores peuvent être moins présentes que d'autres dans $\mathcal{X} \Rightarrow$ certaines probabilités moins précises.
- **Calibration évidentielle** [Xu et al., 16] : étant donné un nouveau score s , un intervalle $[Bel^{\mathbb{Y}}(1|s), Pl^{\mathbb{Y}}(1|s)]$ est obtenu.

Calibration d'un score s

Problème de prédiction d'une variable de Bernoulli $Y \in \mathbb{Y} = \{0, 1\}$ avec paramètre θ , où l'incertitude sur θ dépend de s .

- Différents modèles existent pour estimer l'incertitude sur θ [Xu et al., 16] $\Rightarrow$ **modèle basé sur la vraisemblance**.

Binning évidentiel

- Pour un bin j donné, le binning peut être vu comme un tirage binomial, avec n_j le nombre d'essais et k_j le nombre de succès.
- La fonction de contour est alors :

$$p_{\mathcal{X}}^{\Theta}(\theta|s) = \frac{\theta^{k_j}(1 - \theta)^{n_j - k_j}}{\hat{\theta}^{k_j}(1 - \hat{\theta})^{n_j - k_j}}. \quad (9)$$

Binning évidentiel

- Pour un bin j donné, le binning peut être vu comme un tirage binomial, avec n_j le nombre d'essais et k_j le nombre de succès.
- La fonction de contour est alors :

$$p_{\mathcal{X}}^{\ominus}(\theta|s) = \frac{\theta^{k_j}(1-\theta)^{n_j-k_j}}{\hat{\theta}^{k_j}(1-\hat{\theta})^{n_j-k_j}}. \quad (9)$$


- On obtient [Xu et al., 16] :

$$Bel_x^{\mathbb{Y}}(\{1\}) = \begin{cases} 0, & \text{if } \hat{\theta} = 0, \\ \hat{\theta} - \frac{B(\hat{\theta}; x+1, n-x+1)}{\hat{\theta}^x(1-\hat{\theta})^{n-x}}, & \text{if } 0 < \hat{\theta} < 1, \\ \frac{n}{n+1}, & \text{if } \hat{\theta} = 1, \end{cases} \quad (10)$$


où $\underline{B}$ et $\overline{B}$ sont les fonctions beta incomplètes.

Binning évidentiel : illustration

Données Australian, classifieur SVM



(a) 200 exemples.



(b) 50 exemples.

Régression logistique probabiliste


La calibration basée sur la régression logistique [Platt, 99] est basée sur une fonction sigmoïde h tq

$$P^Y(y = 1|s) \approx h_s(\sigma) = \frac{1}{1 + e^{-(\sigma_0 + \sigma_1 s)}}, \quad (11)$$

où $\sigma = (\sigma_0, \sigma_1) \in \mathbb{R}^2$ maximise la fonction de vraisemblance :

$$L_{\mathcal{X}}(\sigma) = \prod_{i=1}^n p_i^{y_i} (1 - p_i)^{1-y_i},$$

$$\text{avec } p_i = \frac{1}{1 + e^{-(\sigma_0 + \sigma_1 s_i)}}.$$



Régression logistique évidentielle

- Problème de prédiction d'une variable de Bernoulli Y de paramètre θ , avec $\theta = h_s(\sigma)$.

Régression logistique évidentielle

- Problème de prédiction d'une variable de Bernoulli Y de paramètre θ , avec $\theta = h_s(\sigma)$.
- On obtient [Xu et al., 16] :


$$p|_{\mathcal{X}}^{\Theta}(\theta|s) = \sup_{\sigma_1 \in \mathbb{R}} p|_{\mathcal{X}}^{\Sigma}(-\ln(\theta^{-1} - 1) - \sigma_1 s_1, \sigma_1),$$

pour tout $\theta \in [0, 1]$.


- Le paramètre σ_1 qui maximise $p|_{\mathcal{X}}^{\Sigma}$ approximé via un algorithme de maximisation itératif.

Régression logistique évidentielle : illustration

Données Australian, classifieur SVM




(a) 200 exemples.




(b) 50 exemples.



Calibration conjointe de classifieurs





Calibration conjointe de classifieurs



Calibration conjointe de classifieurs



Calibration conjointe de classifieurs



$\mathcal{X}' = \{(s_{11}, \dots, s_{J1}, y_1), \dots, (s_{1n}, \dots, s_{Jn}, y_n)\}$, où s_{ji} le score donné par le $j^{\text{ème}}$ classifieur pour le $i^{\text{ème}}$ objet.

Binning conjoint

- Binning conjoint : diviser l'espace des scores en **bins multi-dimensionnels** ($\Rightarrow$ bins J -dimensionnels).
- Création de ces multi-dimensionnels bins (cellule) :





Fig – Espace des scores avec $J = 2$, $B_M = 5$, $\mathbf{s} = (0.5, -1)$.


- Dans chaque cellule, on calcule probabilité/croyances de manière similaire au cas d'un seul classifieur.

Binning conjoint : illustration

Données Diabetes, classifieurs SVM



(a) 200 exemples.



(b) 50 exemples.

Régression logistique conjointe probabiliste

La calibration basée sur la régression logistique multiple est définie par

$$P^{\mathbb{Y}}(y = 1|\mathbf{s}) \approx h_{\mathbf{s}}(\sigma) = \frac{1}{1 + \exp^{-(\sigma_0 + \sigma_1 s_1 + \sigma_2 s_2 + \dots + \sigma_J s_J)}},$$

Régression logistique conjointe probabiliste

La calibration basée sur la régression logistique multiple est définie par

$$P^{\mathbb{Y}}(y = 1|\mathbf{s}) \approx h_{\mathbf{s}}(\sigma) = \frac{1}{1 + \exp^{-(\sigma_0 + \sigma_1 s_1 + \sigma_2 s_2 + \dots + \sigma_J s_J)}},$$

où $\sigma = (\sigma_0, \dots, \sigma_J) \in \mathbb{R}^{J+1}$ est obtenu par la maximisation de la fonction de vraisemblance L , définie par

$$L(\sigma) = \prod_{i=1}^n p_i^{Y_i} (1 - p_i)^{1-Y_i}, \text{ avec } p_i = \frac{1}{1 + \exp^{-(\sigma_0 + \dots + \sigma_J s_{ji})}}.$$

Régression logistique conjointe évidentielle

- De manière similaire au cas d'un seul classifieur, on obtient :


$$p_{\mathcal{X}'}^{\Theta}(\theta|\mathbf{s}) = \sup_{\sigma_1, \dots, \sigma_J \in \mathbb{R}} p_{\mathcal{X}'}^{\Sigma}(-\ln(\theta^{-1}-1) - \sigma_1 s_1 - \dots - \sigma_J s_J, \sigma_1, \dots, \sigma_J),$$

pour tout $\theta \in [0, 1]$.


- Le vecteur de paramètres $(\sigma_1, \sigma_2, \dots, \sigma_J)$ maximisant $p_{\mathcal{X}'}^{\Sigma}$ peut être approximé avec un algorithme de maximisation itératif (montée de gradient).

Régression logistique conjointe : illustration

Données Diabetes, classifieurs SVM



(a) 200 exemples.



(b) 50 exemples.

Expérimentations, données et classifieurs

- 3 expériences :
 - ① Approches **conjointes** vs approches **disjointes**,
 - ② Approches **conjointes évidentielles** vs autre **classifieur évidentiel**,
 - ③ Approche **conjointe évidentielle** vs approche **conjointe probabiliste**.

Expérimentations, données et classifieurs

- 3 expériences :
 - 1 Approches **conjointes** vs approches **disjointes**,
 - 2 Approches **conjointes évidentielles** vs autre **classifieur évidentiel**,
 - 3 Approche **conjointe évidentielle** vs approche **conjointe probabiliste**.
- Ensembles de données :
 - 1 Simulées : distribution normale bivariee, avec $\mu_0 = (-1, 0)$ pour la classe 0 et $\mu_1 = (1, 1)$ pour la classe 1, et avec $\Sigma_0 = \Sigma_1 = \begin{bmatrix} 1 & 0.5 \\ 0.5 & 1 \end{bmatrix}$ pour les 2 classes.
 - 2 UCI : Australian, Diabetes, Heart, Ionosphere, Sonar.
- Classifieurs SVM entraînés avec LIBSVM.

Expérience 1

Calibrations conjointes vs disjointes


- Répartition des données :

Base	SVM 1	SVM 2	SVM 3	Test
Simulées	20	40	10-50-200	100
<i>Australian</i>	30	70	10-60-190	400
<i>Diabetes</i>	30	70	10-50-200	468
<i>Heart</i>	20	40	10-50-140	70
<i>Ionosphere</i>	20	40	10-80-190	101
<i>Sonar</i>	20	40	10-40-90	58


- Décision : coûts 0-1.

Expérience 1

Résultats obtenus




(a) Données Ionosphère.



(b) Données Sonar.


Expérience 2

Classifieur évidentiel



Expérience 2


Classifieur évidentiel



- Classifieur évidentiel [Denœux et Smets, 06] basé sur le Théorème de Bayes Généralisé (GBT) [Smets, 93].


Expérience 2

Présentation du GBT : illustration - données Diabetes




Expérience 2

Résultats obtenus




(a) *Données simulées.*




(b) *Données Diabetes.*

Expérience 2

Influence du rayon et nombre de bins - Données Diabetes



(a) Taille du rayon de la boule.



(b) Nombre de bins/classifieur.

Expérience 3

Évaluation des performances

Répartition des données :

- 3 classifieurs entraînés avec 30 exemples. La taille de l'ensemble d'apprentissage de la calibration conjointe est variable.

Expérience 3

Évaluation des performances

Répartition des données :


- 3 classifieurs entraînés avec 30 exemples. La taille de l'ensemble d'apprentissage de la calibration conjointe est variable.

Décision :


- Coûts 0-1, avec possibilité de rejeter un exemple test (en utilisant un cout de rejet R_{rej}).
- 2 stratégies sont considérées :
 - Stratégie optimiste (réponse minimisant le risque inférieur),
 - Stratégie pessimiste (réponse minimisant le risque supérieur).

Expérience 3

Données simulées, classifieurs SVM, frontières de décision pour $R_{rej} = 0.15$




(a) 200 exemples.




(b) 15 exemples.

Expérience 3

Données Australian, classifieurs SVM



(a) 45 exemples d'apprentissage



(b) 15 exemples d'apprentissage

Outline

- 1 Théorie de l'évidence
- 2 Calibration évidentielle
- 3 Application : anonymisation de visages
 - Entrées du système
 - Approche de la littérature
 - Approche proposée
 - Suivi des visages
- 4 Conclusion et perspectives

Rappel du problème

Anonymiser les visages sur des vidéos de manière (semi) automatique.

- Anonymiser = flouter ou mettre un “rectangle de couleur” sur les visages.
- Aucun taux de faux positifs/faux négatifs à atteindre n'a été indiqué par la SNCF.
- Le temps réel n'était pas une contrainte demandée.
- Logiciel à appliquer sur des vidéos EAS et peut être dans le futur sur d'autres types de vidéos.

Idée principale

Utiliser différents détecteurs de visages et fusionner leurs sorties.



Détecteurs de visages

But

Détecter la présence ou non d'un (ou des) visage(s) dans une image et le cas échéant donner position(s) et taille(s).

- Avant les années 2000 : méthodes basées sur les caractéristiques locales du visage.

Détecteurs de visages

But

Détecter la présence ou non d'un (ou des) visage(s) dans une image et le cas échéant donner position(s) et taille(s).

- Avant les années 2000 : méthodes basées sur les caractéristiques locales du visage.
- Différentes avancées capitales : [Viola et Jones, 01] et réseaux de neurones profonds [Farfadi et al., 15].

Détecteurs de visages

But

Détecter la présence ou non d'un (ou des) visage(s) dans une image et le cas échéant donner position(s) et taille(s).

- Avant les années 2000 : méthodes basées sur les caractéristiques locales du visage.
- Différentes avancées capitales : [Viola et Jones, 01] et réseaux de neurones profonds [Farfadi *et al.*, 15].
- Choix des détecteurs :
 - ① Adaboost avec Haar
 - ② Adaboost avec Local Binary Patterns (LBP)
 - ③ Support Vector Machine (SVM) avec Histogram of Oriented Gradient (HOG)
 - ④ Réseau de neurones profond

Détecteurs de visages



Approche disjointe

[Xu *et al.* 14, 16]

- Récupère les sorties des détecteurs puis 3 étapes :
 - 1 Calibration
 - 2 Clustering
 - 3 Fusion





Image initiale

Approche disjointe

[Xu *et al.* 14, 16]

- Récupère les sorties des détecteurs puis 3 étapes :
 - 1 Calibration
 - 2 Clustering
 - 3 Fusion




Calibration


Approche disjointe

[Xu et al. 14, 16]

- Récupère les sorties des détecteurs puis 3 étapes :
 - 1 Calibration
 - 2 Clustering
 - 3 Fusion



Calibration




Clustering

Approche disjointe


[Xu *et al.* 14, 16]

- Récupère les sorties des détecteurs puis 3 étapes :

- 1 Calibration
- 2 Clustering
- 3 Fusion



Calibration



Clustering



Fusion

Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.

Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.
- Idée 2 : appliquer la **calibration conjointe évidentielle** à ce problème.

Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.
- Idée 2 : appliquer la **calibration conjointe évidentielle** à ce problème.




Image initiale

Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.
- Idée 2 : appliquer la **calibration conjointe évidentielle** à ce problème.





Image initiale




Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.
- Idée 2 : appliquer la **calibration conjointe évidentielle** à ce problème.



Image initiale



Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.
- Idée 2 : appliquer la **calibration conjointe évidentielle** à ce problème.



Image initiale

- 1 Calibration conjointe
- 2 Clustering
- 3 Fusion

Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.
- Idée 2 : appliquer la **calibration conjointe évidentielle** à ce problème.



Image initiale

- 1 Calibration conjointe
- 2 ~~Clustering~~
- 3 Fusion

Approche proposée

Schéma global

- Idée 1 : **floutage** $\neq$ **détection** $\Rightarrow$ étude basée au niveau **pixel**.
- Idée 2 : appliquer la **calibration conjointe évidentielle** à ce problème.



Image initiale

- 1 Calibration conjointe
- 2 ~~Clustering~~
- 3 ~~Fusion~~

Tests expérimentaux

Données et décision

- Base de données SNCF :
 - 600 images annotées (1089 visages), extraites des vidéos EAS.
 - 100 images pour calibration, 500 images pour tests.

Tests expérimentaux

Données et décision


- Base de données SNCF :
 - 600 images annotées (1089 visages), extraites des vidéos EAS.
 - 100 images pour calibration, 500 images pour tests.
- Décision :
 - Coûts $c(0, 1) \geq c(1, 0) = 1$.
 - Pour différentes valeurs de $c(0, 1)$, on calcule :

$$\text{Rappel} = \frac{\text{\#pixels correctement floutés}}{\text{\#pixels à flouter}}, \quad (12)$$

$$\text{Précision} = \frac{\text{\#pixels correctement floutés}}{\text{\#pixels floutés}}. \quad (13)$$


Tests expérimentaux

Approche proposée vs détecteurs pris seuls



Tests expérimentaux

Approche proposée vs approche de Xu *et al.*



Avantages/Inconvénients de l'approche proposée

Avantages	Inconvénients
Évite l'utilisation d'un paramètre λ	Nécessité de ré-entraîner la calibration pour ajouter un classifieur
Évite l'utilisation d'une règle de fusion	N'isole pas les visages
Ajout facile d'une information basée niveau pixel	A une complexité plus importante
Meilleures performances	

Suivi des visages

- Données d'entrée : ~~images~~

Suivi des visages

- Données d'entrée : vidéos $\Rightarrow$ donnent des informations temporelles.

Suivi des visages

- Données d'entrée : vidéos $\Rightarrow$ donnent des informations temporelles.
- Intérêt d'un algorithme de **suivi** de visages : "lissage".




Image t




Image t+1



Image t+2

Suivi des visages

- Données d'entrée : vidéos $\Rightarrow$ donnent des informations temporelles.
- Intérêt d'un algorithme de **suivi** de visages : "lissage".



Image t



Image t+1




Image t+2

- Choix d'un algorithme classique de suivi de cibles : **Kalman**.
- Principe général : étapes de **prédiction** et **correction**.


Suivi des visages

Architecture globale du système



Tests expérimentaux

Comparaison entre les systèmes avec et sans suivi



Outline

- 1 Théorie de l'évidence
- 2 Calibration évidentielle
- 3 Application : anonymisation de visages
- 4 Conclusion et perspectives

Conclusion

But de la thèse

Étudier et développer un système de fusion de plusieurs classifieurs, dans le but d'anonymiser des visages sur des vidéos SNCF.

Deux principales contributions :

- Calibration évidentielle conjointe.
- Application à l'anonymisation de visages (incluant un outil).

Quelques perspectives

- Étude de la calibration conjointe basée sur la régression choquistique.
- Extension au problème multi-classes.
- Appliquer l'approche de calibration conjointe différemment (informations spatio-temporelles) ou à d'autres problèmes.

Publications

Revue internationale :

- P. Minary, F. Pichon, D. Mercier, E. Lefèvre, B. Droit. A pixel-based face blurring approach using evidential calibration and fusion. *International Journal of Approximate Reasoning*, pp 202-215, Vol. 91, Décembre 2017.

Conférences internationales :

- P. Minary, F. Pichon, D. Mercier, E. Lefèvre, B. Droit. Evidential joint calibration of binary SVM classifiers using logistic regression. *Proceedings of the 11th International Conference on Scalable Uncertainty Management, Grenade, Espagne, 4-6 Octobre*, pages 405-411, Springer, 2017.
- P. Minary, F. Pichon, D. Mercier, E. Lefèvre, B. Droit. An Evidential Pixel-Based Face Blurring Approach. *Proceedings of the 4th International Conference on Belief Functions, Prague, Rép. Tchèque, 21-23 Septembre, 2016*, volume 9861 of Lecture Notes in Computer Science, pages 222-230, Springer, 2016. **(Prix du meilleur article étudiant)**.
- P. Minary, B. Droit, F. Pichon, D. Mercier, E. Lefèvre. A fusion method for blurring faces on platforms using belief functions. *11th World Congress on Railway Research, Milan, Italie, 29 Mai-2 Juin*, 2016.

Conférence nationale :

- P. Minary, F. Pichon, D. Mercier, E. Lefèvre, B. Droit. Calibration évidentielle conjointe de classifieurs SVM binaires fondée sur la régression logistique. Les Rencontres Francophones sur la Logique Floue et ses Applications (LFA), Amiens, France, 19-20 Octobre 2017. **(Prix du meilleur article étudiant)**.

Merci pour votre attention