



RÉPUBLIQUE  
FRANÇAISE

*Liberté  
Égalité  
Fraternité*

ONERA

THE FRENCH AEROSPACE LAB

# Empoisonnement de données

23/09/2022

Adrien CHAN-HON-TONG

ONERA



RÉPUBLIQUE  
FRANÇAISE

*Liberté  
Égalité  
Fraternité*

ONERA

THE FRENCH AEROSPACE LAB

Ce document est la propriété de l'ONERA. Il ne peut être communiqué à des tiers et/ou reproduit sans l'autorisation préalable écrite de l'ONERA, et son contenu ne peut être divulgué.  
This document and the information contained herein is proprietary information of ONERA and shall not be disclosed or reproduced without the prior authorization of ONERA.

# IA de confiance à l'ONERA

---



# Objectif

---

→ l'objectif de cette présentation est de présenter une cartographie des risques d'empoisonnement mais aussi des contre-mesures

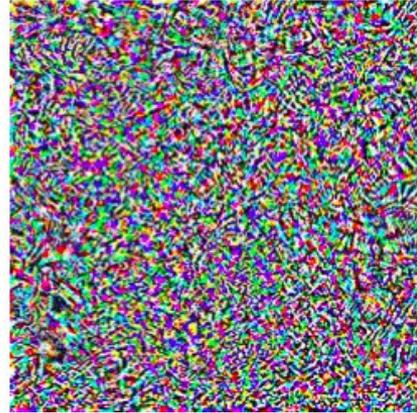
# Exemple 1

La dangerosité des exemples adversaires invisibles ?

“pig”



+ 0.005 x



=

“airliner”



# Exemple 1

## La dangerosité des exemples adversaires invisibles ?

1 → Ce type d'attaque semble difficilement réalisable dans le monde physique

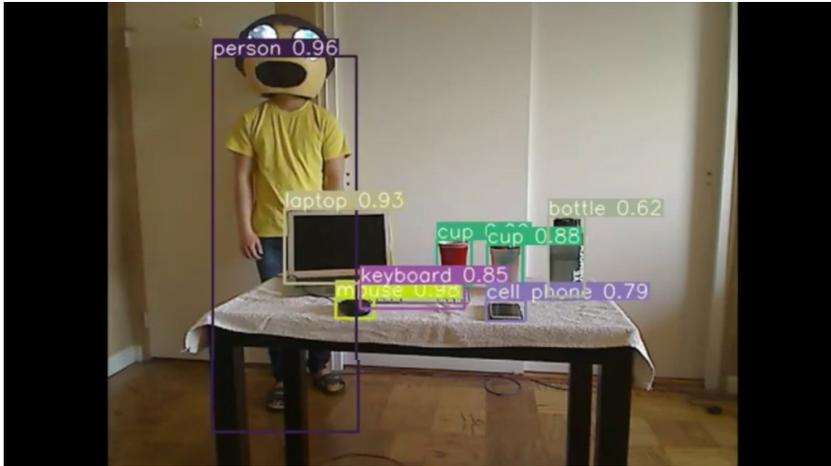
malgré



2 → Un réentraînement avec PGD donne une robustesse non négligeable

# Exemple 2

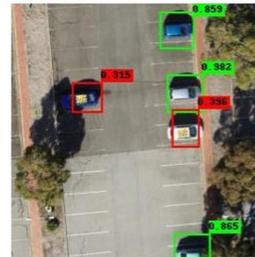
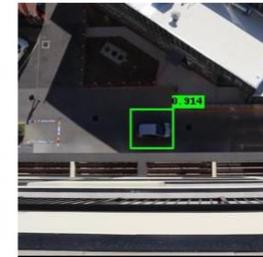
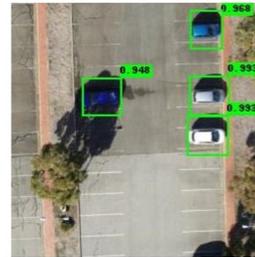
## La dangerosité des exemples adversaires patches ?



(a) Adversarial patch on the roof of a car.



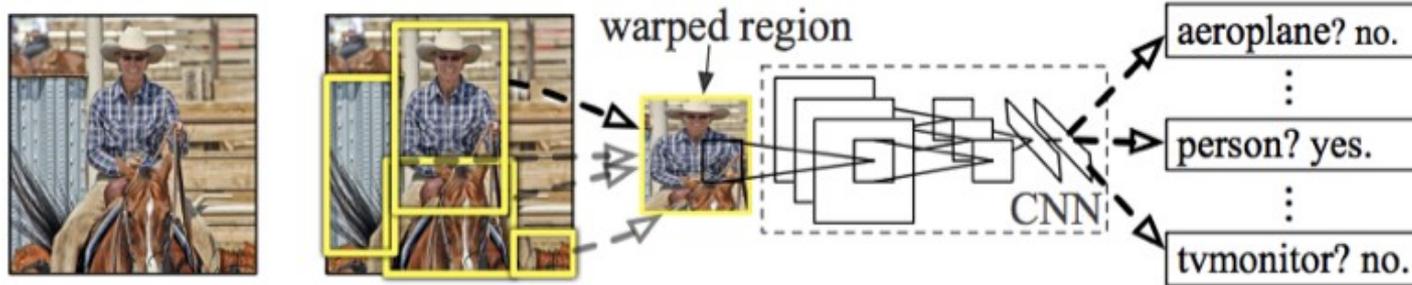
(b) Adversarial patch off-and-around a car.



## Exemple 2

La dangerosité des exemples adversaires patches ?

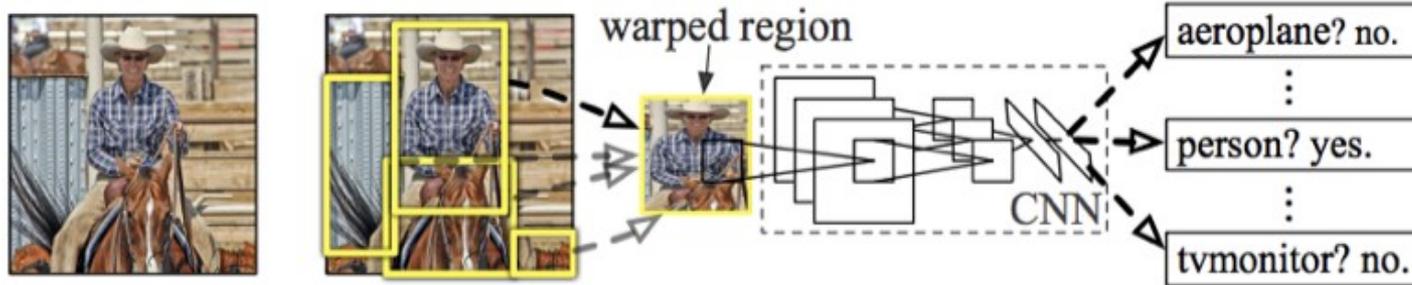
### R-CNN: *Regions with CNN features*



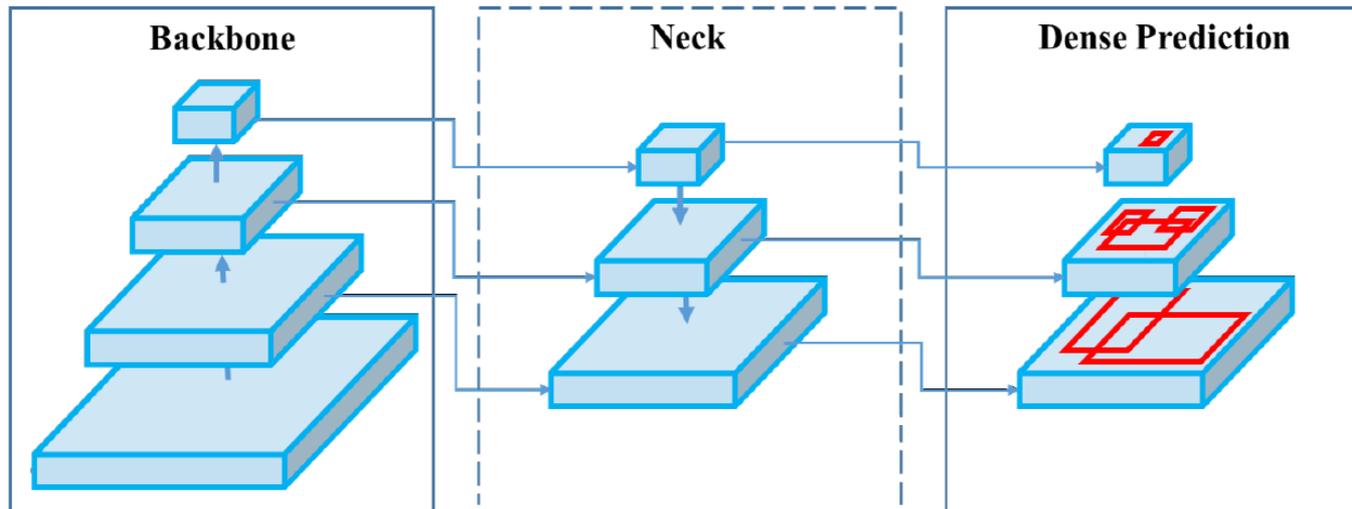
# Exemple 2

La dangerosité des exemples adversaires patches ?

## R-CNN: *Regions with CNN features*

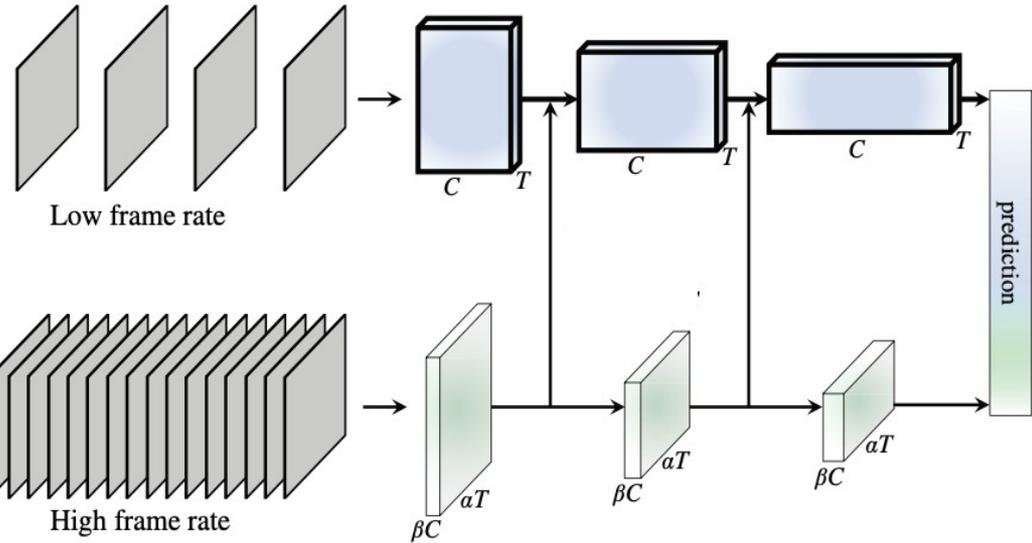
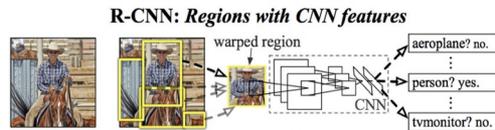


medium.com



# Exemple 2

## La dangerosité des exemples adversaires patches ?



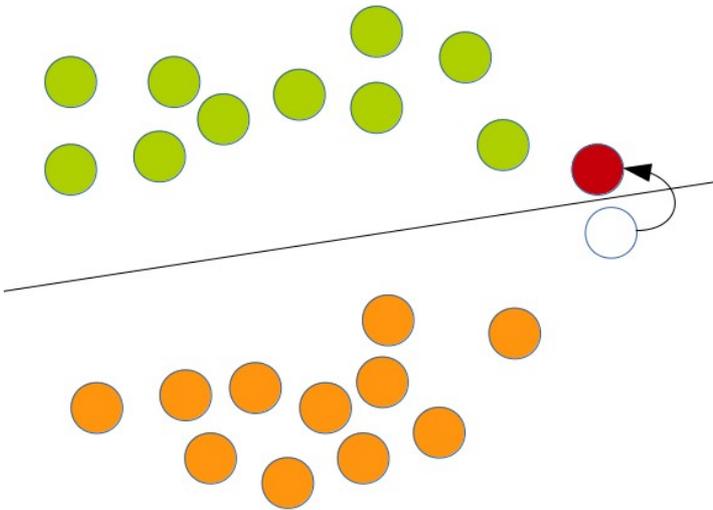
# Plan

---

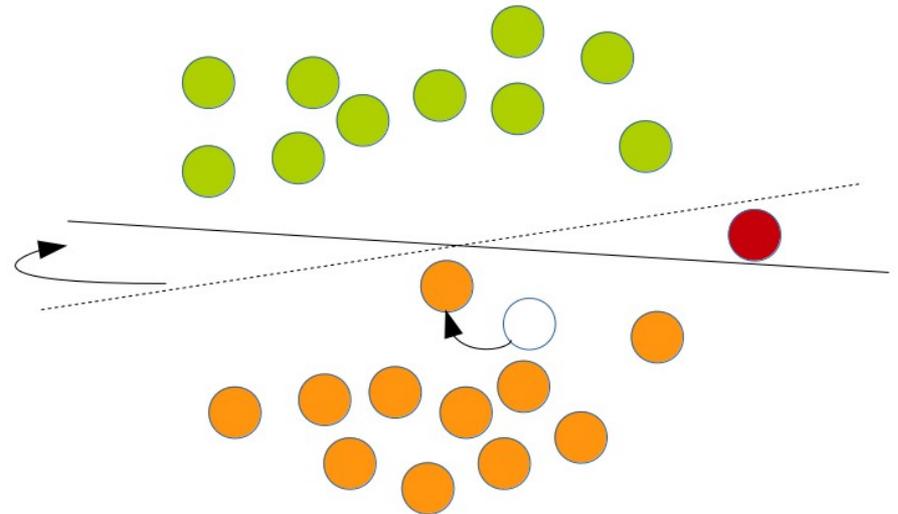
- scénario d'empoisonnement
- contre-mesure à une empoisonnement invisible
- perspectives

# empoisonnement vs attaque évasion

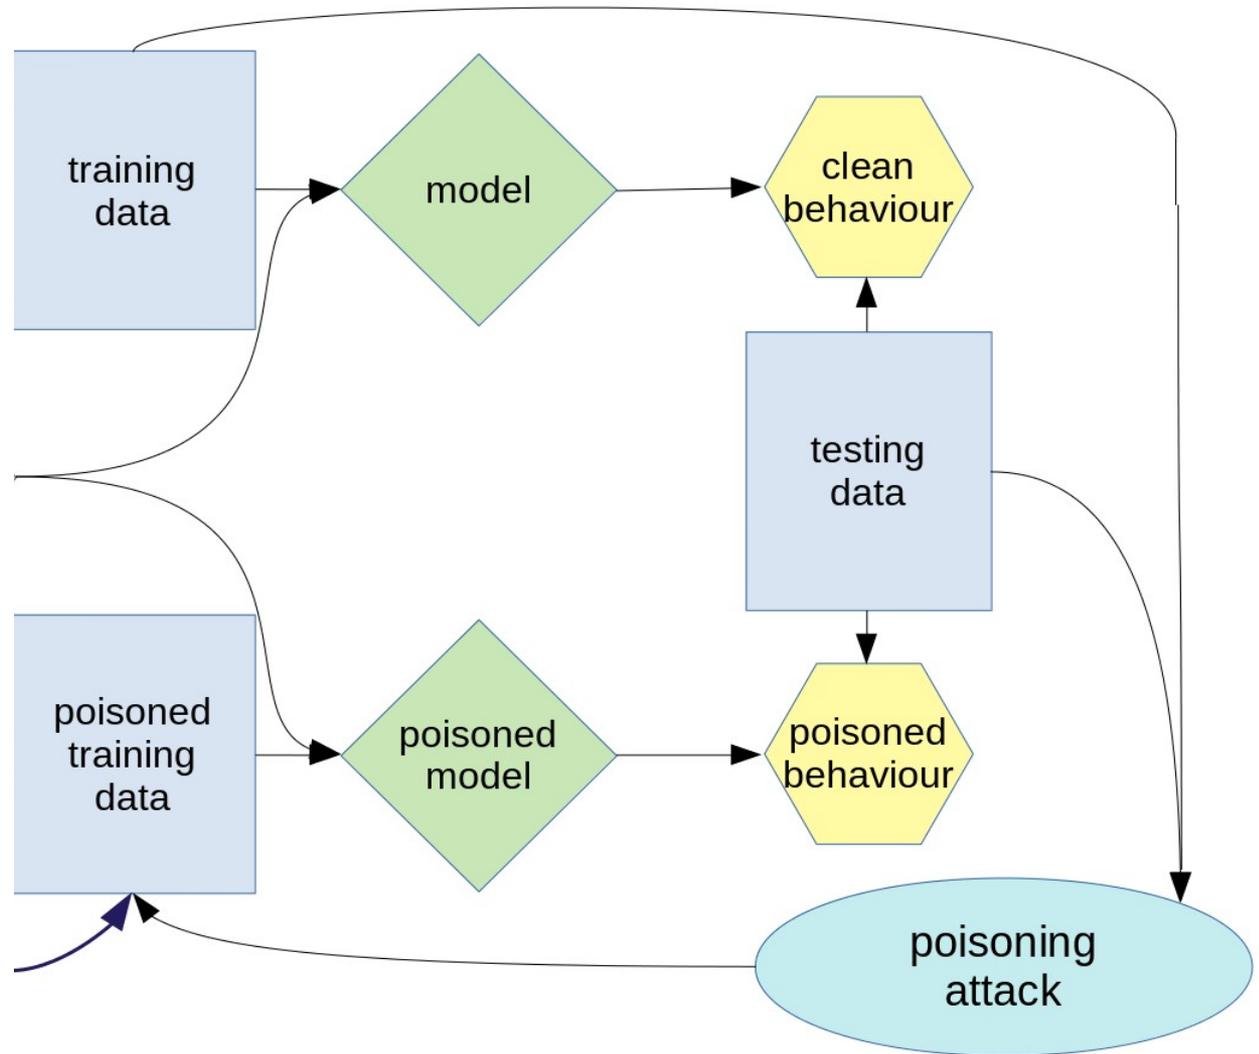
Attaque adversaire



Empoisonnement



# empoisonnement

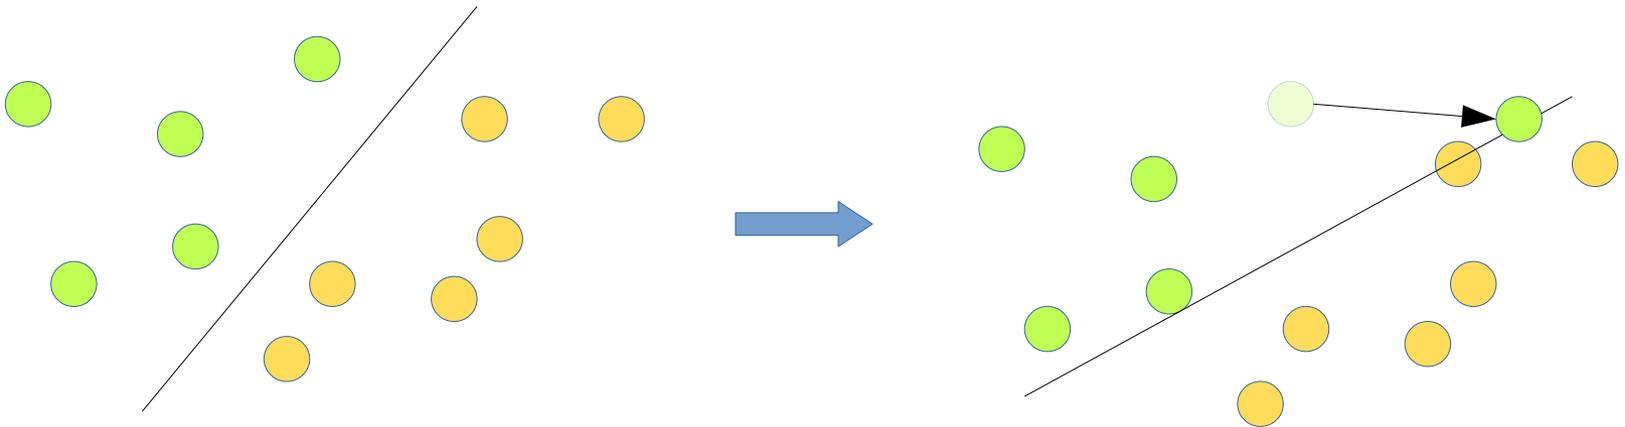
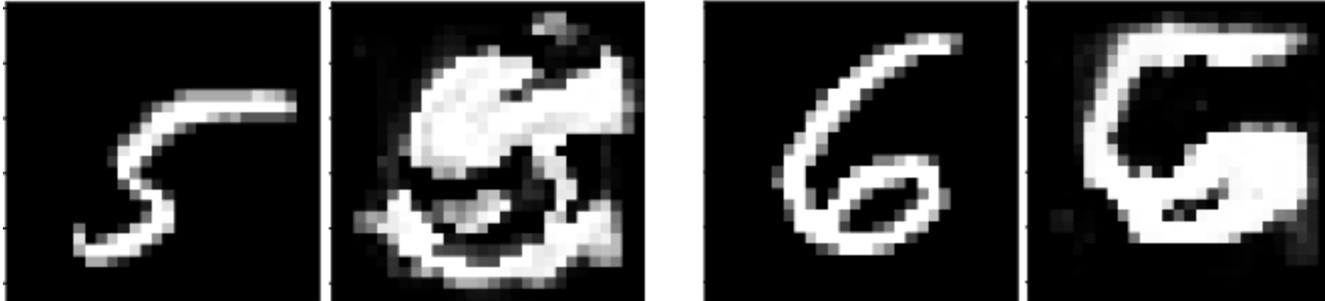


# empoisonnement vs attaque évasion

	Attaque adverse	Empoisonnement
Avantages	Facilité d'exécution	Modifie le comportement de la cible <b>partout</b>
Inconvénients	Modification du comportement locale	Nécessite un accès aux données d'apprentissage.

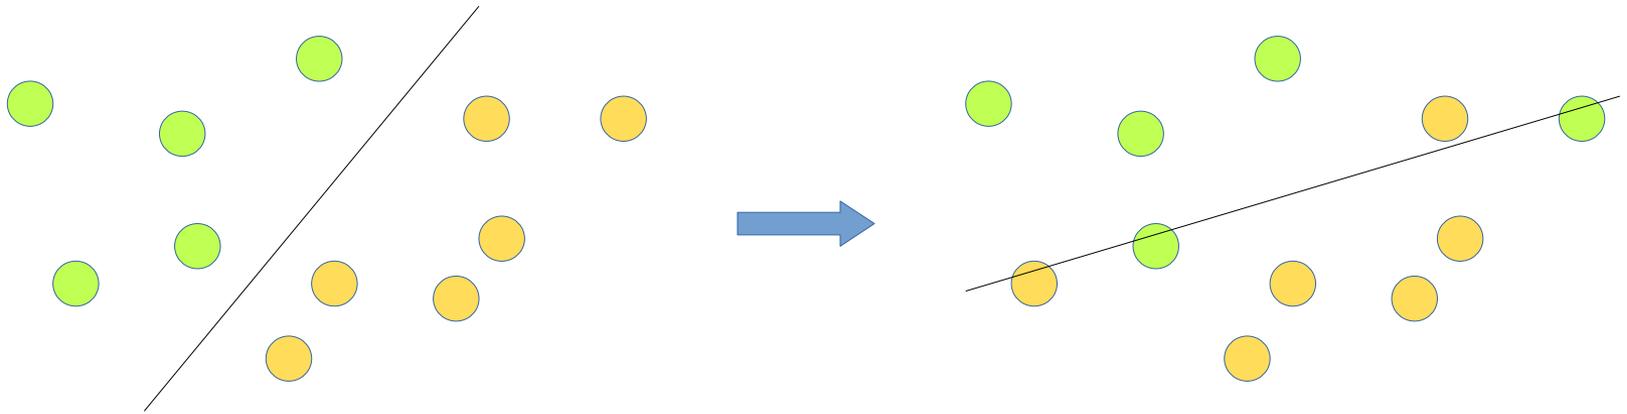
# empoisonnement classique vs empoisonnement invisible

Image corruption



# empoisonnement classique vs empoisonnement invisible

Label flip

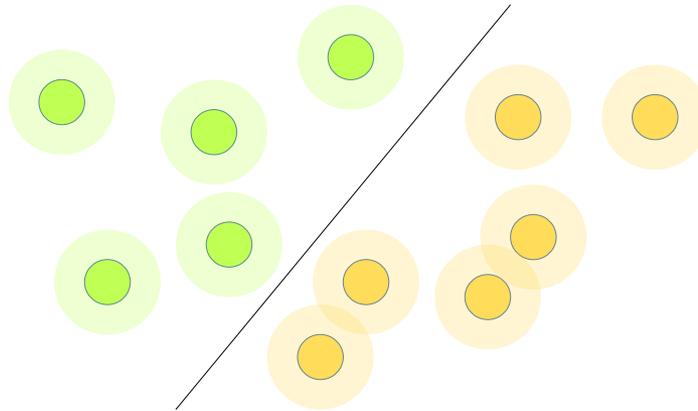


# empoisonnement classique vs empoisonnement invisible

---

## Clean label

Modification des images contraintes à être indétectable à l'oeil



# Scénarios d'empoisonnement

---

**Soit l'apprentissage est fait sans contrôle**

**Soit la modification doit passer inaperçue**

# Scénarios d'empoisonnement

---

**Soit l'apprentissage est fait sans contrôle**

Ce qui paraît pas très réaliste

**Soit la modification doit passer inaperçue**

# Scénarios d'empoisonnement

---

## Soit l'apprentissage est fait sans contrôle

Ce qui paraît pas très réaliste

(Sauf pseudo labeling, online learning, watermarking, falsification)

**Soit la modification doit passer inaperçue**

# Scénarios d'empoisonnement

---

## Soit l'apprentissage est fait sans contrôle

Ce qui paraît pas très réaliste

(Sauf pseudo labeling, online learning, watermarking, falsification)

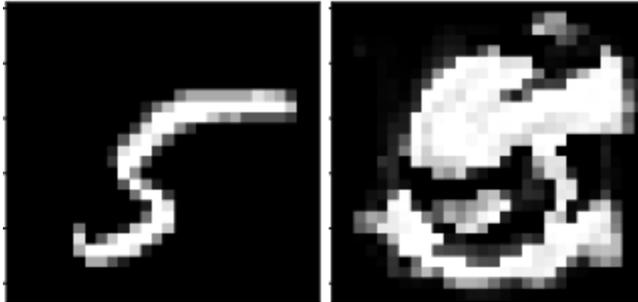
## Soit la modification doit passer inaperçue

→ faible nombre de modification

→ OU modification invisible

# Scénarios d'empoisonnement

---



Modifications fortes mais peu nombreuses



Modifications invisibles

# Modifications fortes mais minoritaires vs partition

Training data

Partitionnement

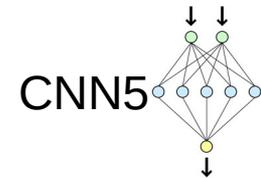
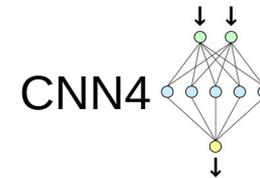
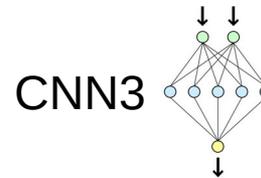
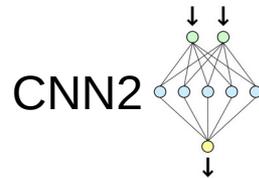
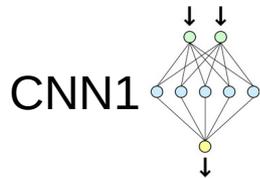
P1

P2

P3

P4

P5



# Modifications fortes mais minoritaires vs partition

Training data

Partitionnement

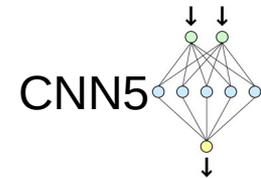
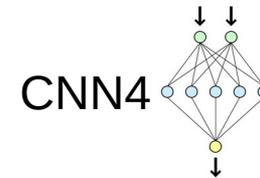
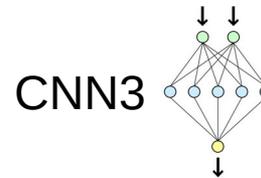
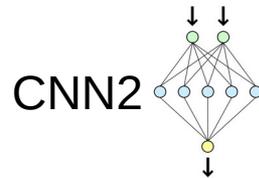
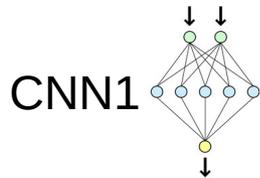
P1

P2

P3

P4

P5



Si on modifie 1 données, seul 1 des CNN est modifié

→ Si au moins 4 CNN sont d'accord sur la classe, alors cet accord n'a pas pu être influencé par la présence d'1 donnée empoisonnée

# Modifications fortes mais minoritaires vs partition

Training data

Partitionnement

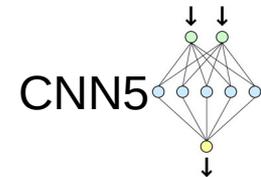
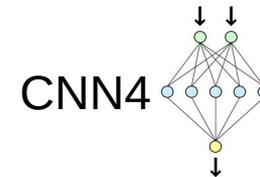
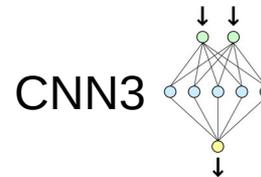
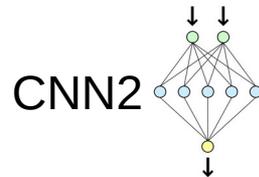
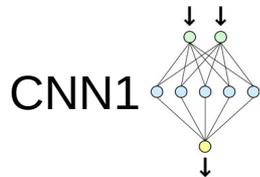
P1

P2

P3

P4

P5



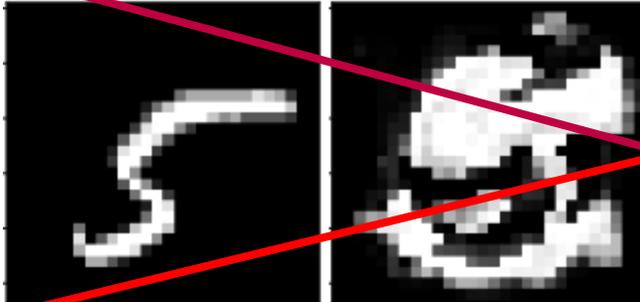
Si on modifie 1 données, seul 1 des CNN est modifié

→ Si au moins 4 CNN sont d'accord sur la classe, alors cet accord n'a pas pu être influencé par la présence d'1 donnée empoisonnée

→ bien entendu cette défense est difficile mais peut s'implémenter de façon souple  
**(RANSAC)**

# Scénarios d'empoisonnement

---



Modifications fortes mais peu nombreuses



Modifications invisibles

# Plan

---

- scénario d'empoisonnement
- contre-mesure à une empoisonnement invisible
- perspectives

# empoisonnement invisible

---

## Poison Frog

### 2.1 Crafting poison data via feature collisions

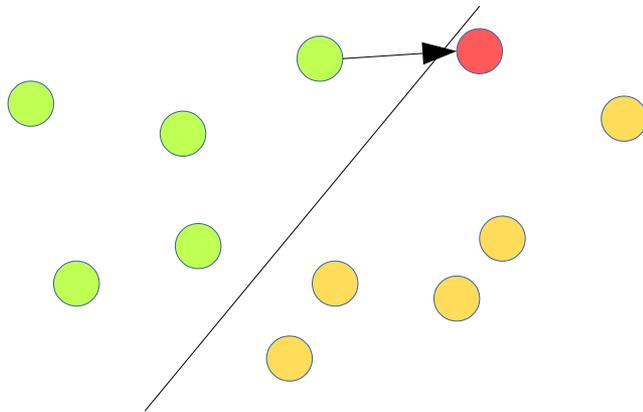
Let  $f(\mathbf{x})$  denote the function that propagates an input  $\mathbf{x}$  through the network to the penultimate layer (before the softmax layer). We call the activations of this layer the *feature space* representation of the input since it encodes high-level semantic features. Due to the high complexity and nonlinearity of  $f$ , it is possible to find an example  $\mathbf{x}$  that “collides” with the target in feature space, while simultaneously being close to the base instance  $\mathbf{b}$  in input space by computing

$$\mathbf{p} = \underset{\mathbf{x}}{\operatorname{argmin}} \quad \|f(\mathbf{x}) - f(\mathbf{t})\|_2^2 + \beta \|\mathbf{x} - \mathbf{b}\|_2^2 \quad (1)$$

# empoisonnement invisible

---

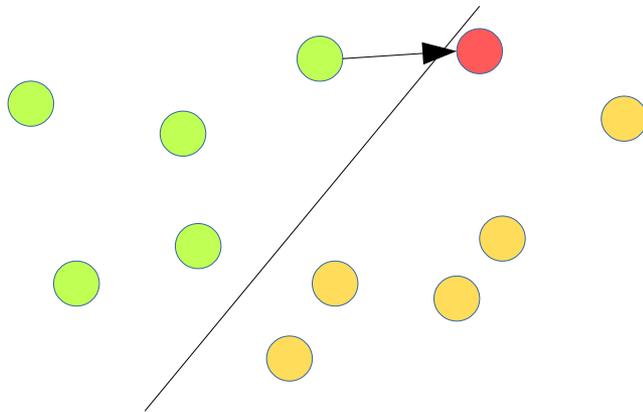
## Poison Frog



# empoisonnement invisible

---

**Poison Frog**

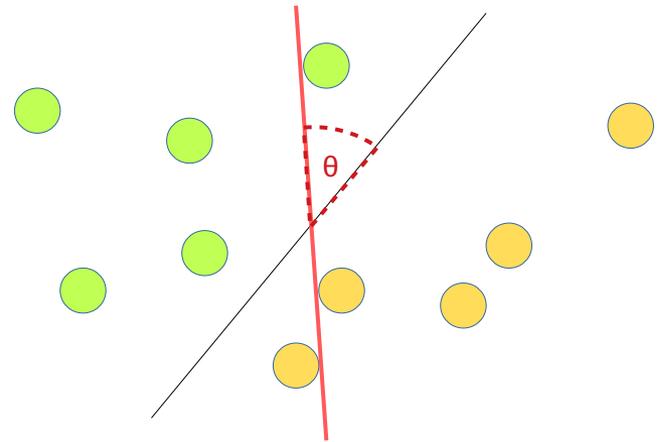


Success rate 100 %  
(Inception v3 + svm, Imagenet dog vs fish)

# empoisonnement invisible

---

*Proxy based*



# empoisonnement invisible

---

**Proxy based**

$$u \rightarrow u + \tau(\theta_{fair}^T u)\theta_{poison} - \tau(\theta_{poison}^T u)\theta_{fair}$$

$$\theta_{hack} \approx \theta_{fair} + \tau(\theta_{fair}^T \theta_{fair})\theta_{poison} - \tau(\theta_{poison}^T \theta_{fair})\theta_{fair}$$

# empoisonnement invisible

---

*Proxy based*

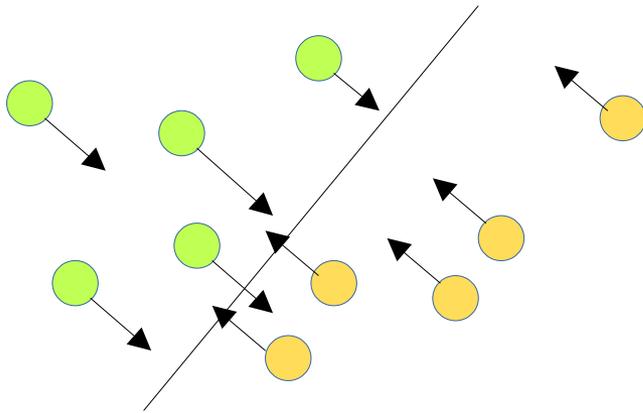
$$u \rightarrow u + \tau(\theta_{fair}^T u)\theta_{poison} - \tau(\theta_{poison}^T u)\theta_{fair}$$

$$\theta_{hack} \approx \theta_{fair} + \tau(\theta_{fair}^T \theta_{fair})\theta_{poison} - \tau(\theta_{poison}^T \theta_{fair})\theta_{fair}$$

CIFAR 75 %  $\rightarrow$  63 % accuracy (vgg + svm)

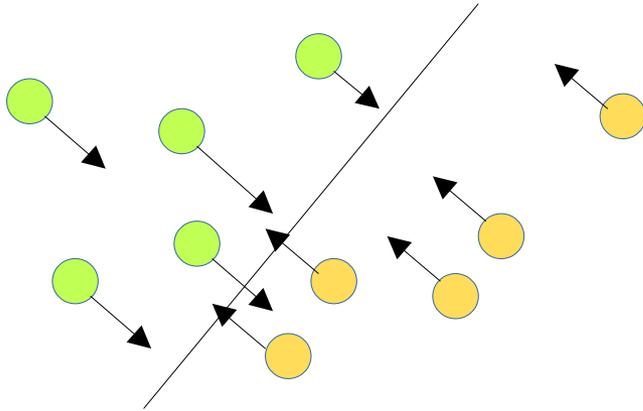
# empoisonnement invisible

---



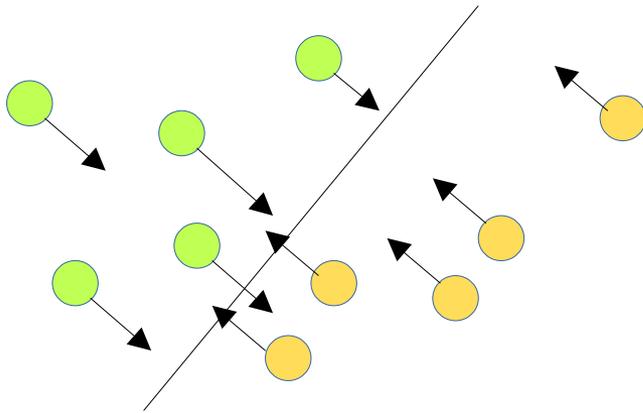
# empoisonnement invisible

---



Un empoisonnement non coordonné ne conduit à une modification de comportement

# empoisonnement invisible

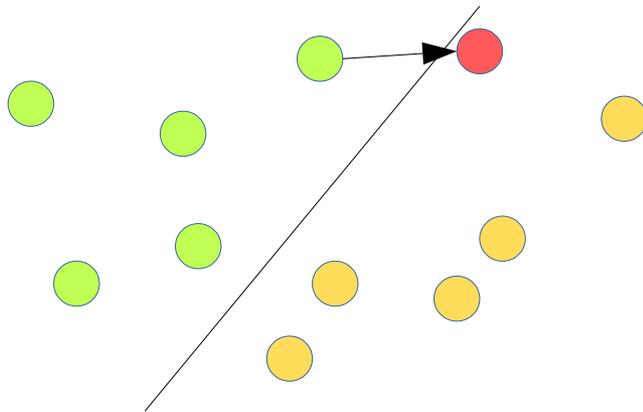


$\text{SGD}_\theta(f, T_{\text{Test}})$	$\ll 87\%$ (-31% in [18])
$\text{SGD}_\theta(f, T_{\text{Train}})$	$\approx 87\%$ (0% in [18])
$-w_{\text{imagenet}}$	$\approx 87\%$
$w_{\text{imagenet}}$	$\approx 87\%$
$-\text{SGD}_\theta(f, T_{\text{Train}})$	$\approx 87\%$ (-1% in [18])
$-\text{SGD}_\theta(f, T_{\text{Test}})$	$\gg 87\%$ (+7% in [18])

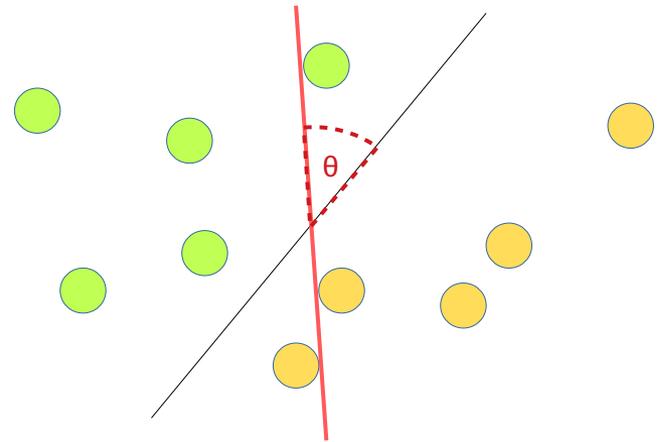
Un empoisonnement non coordonné ne conduit à une modification de comportement

# empoisonnement invisible

**Poison Frog**



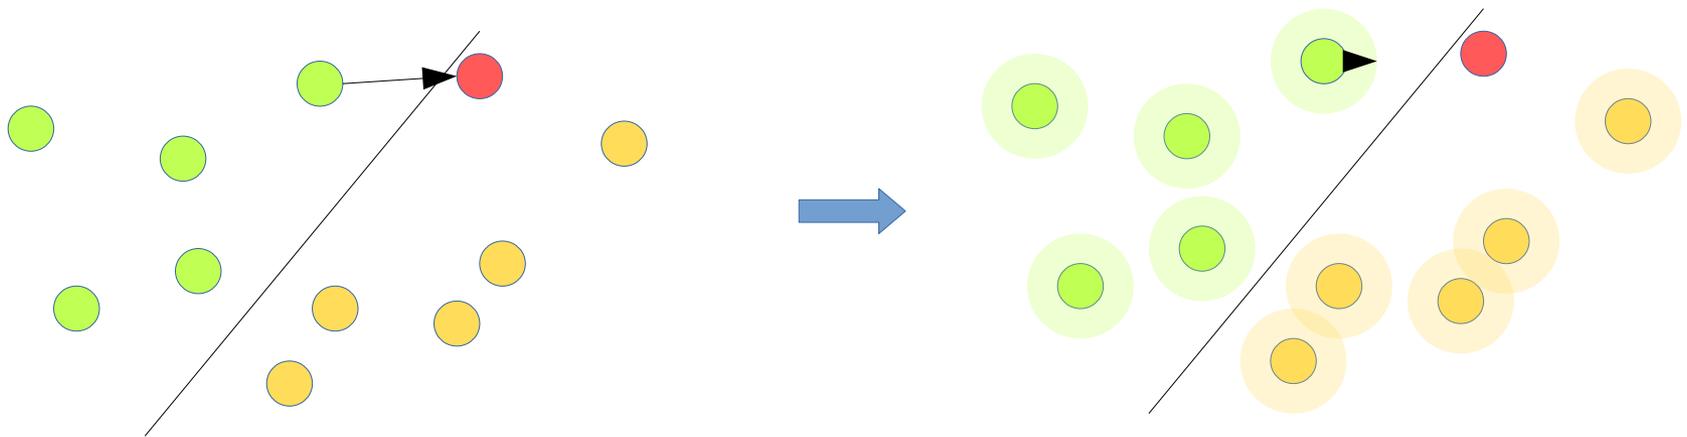
**Proxy based**



# empoisonnement invisible

## Clean label

Modification des images contraintes à être indétectable à l'oeil

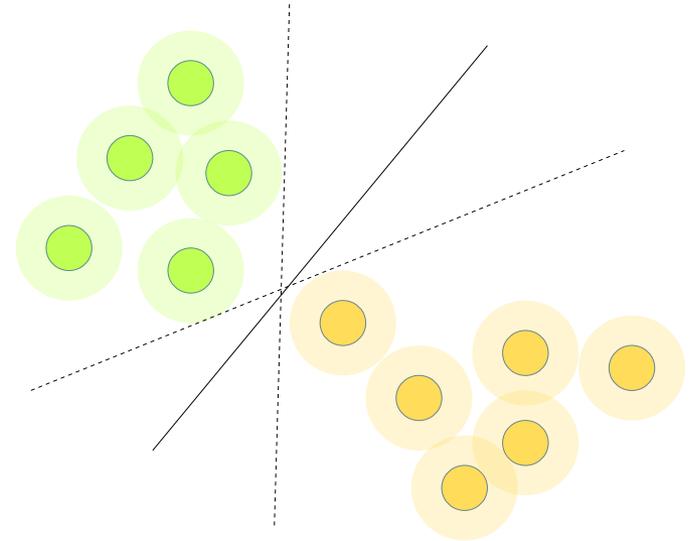
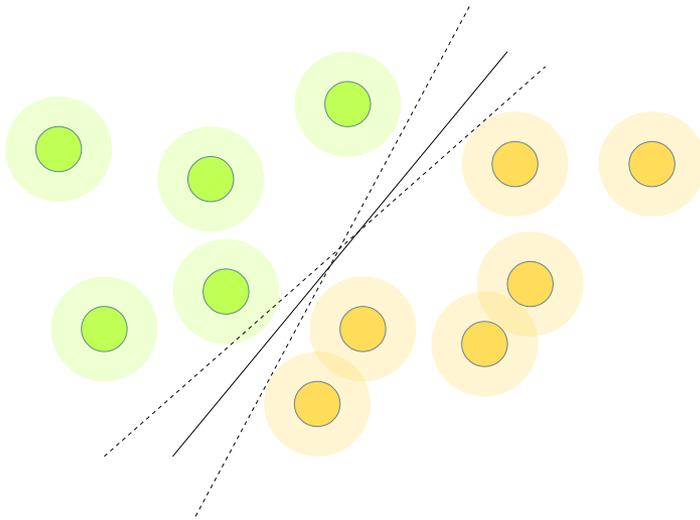


→ Si l'apprentissage est robuste, y a-t-il toujours sensibilité à cet empoisonnement ?

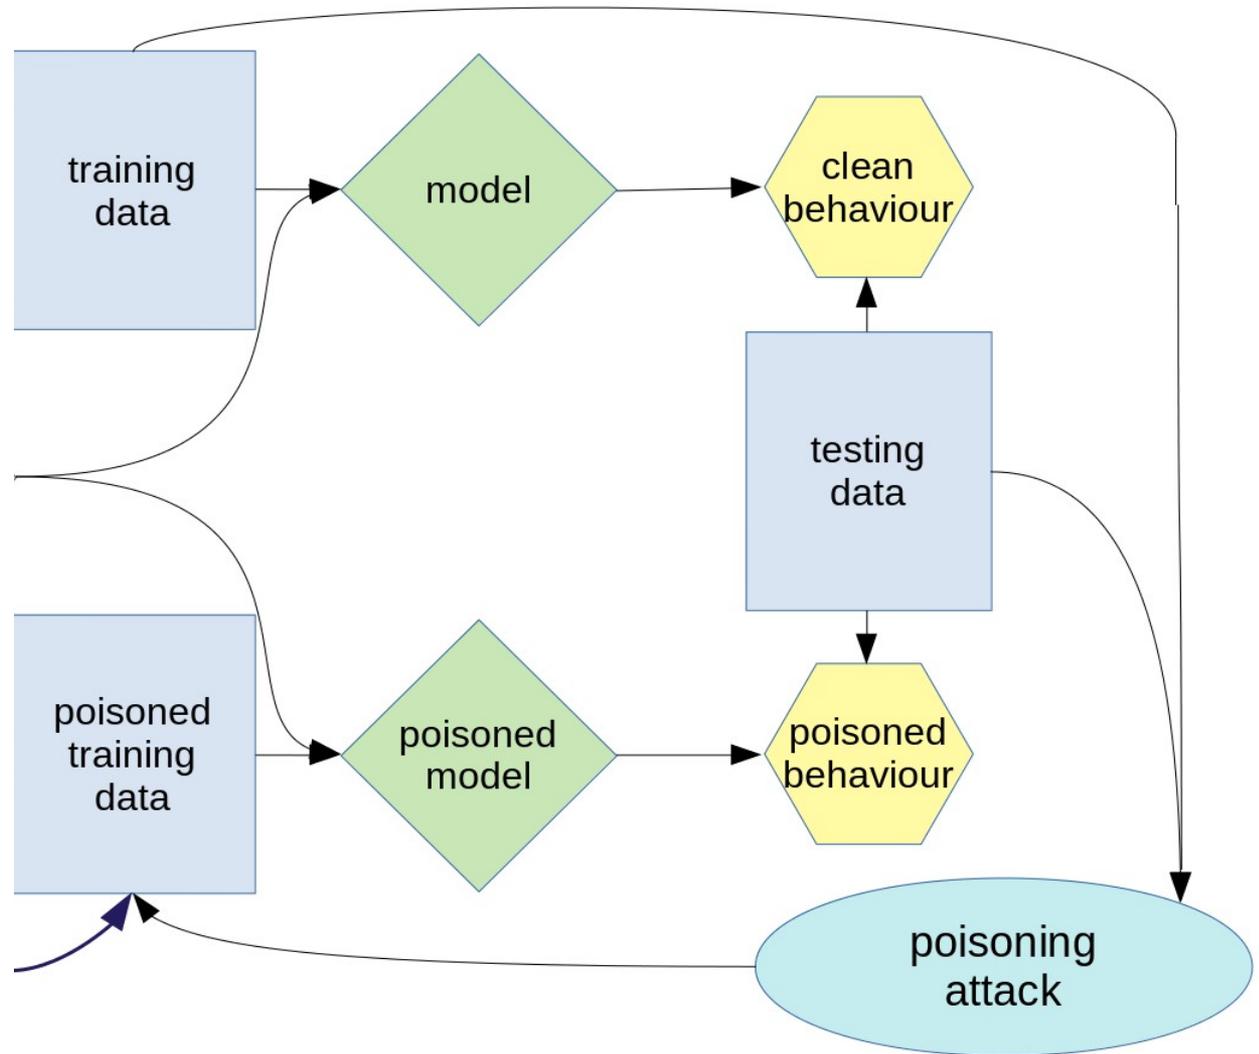
# empoisonnement invisible et apprentissage robuste

→ Si l'apprentissage est robuste, y a-t-il toujours sensibilité à cet empoisonnement ?

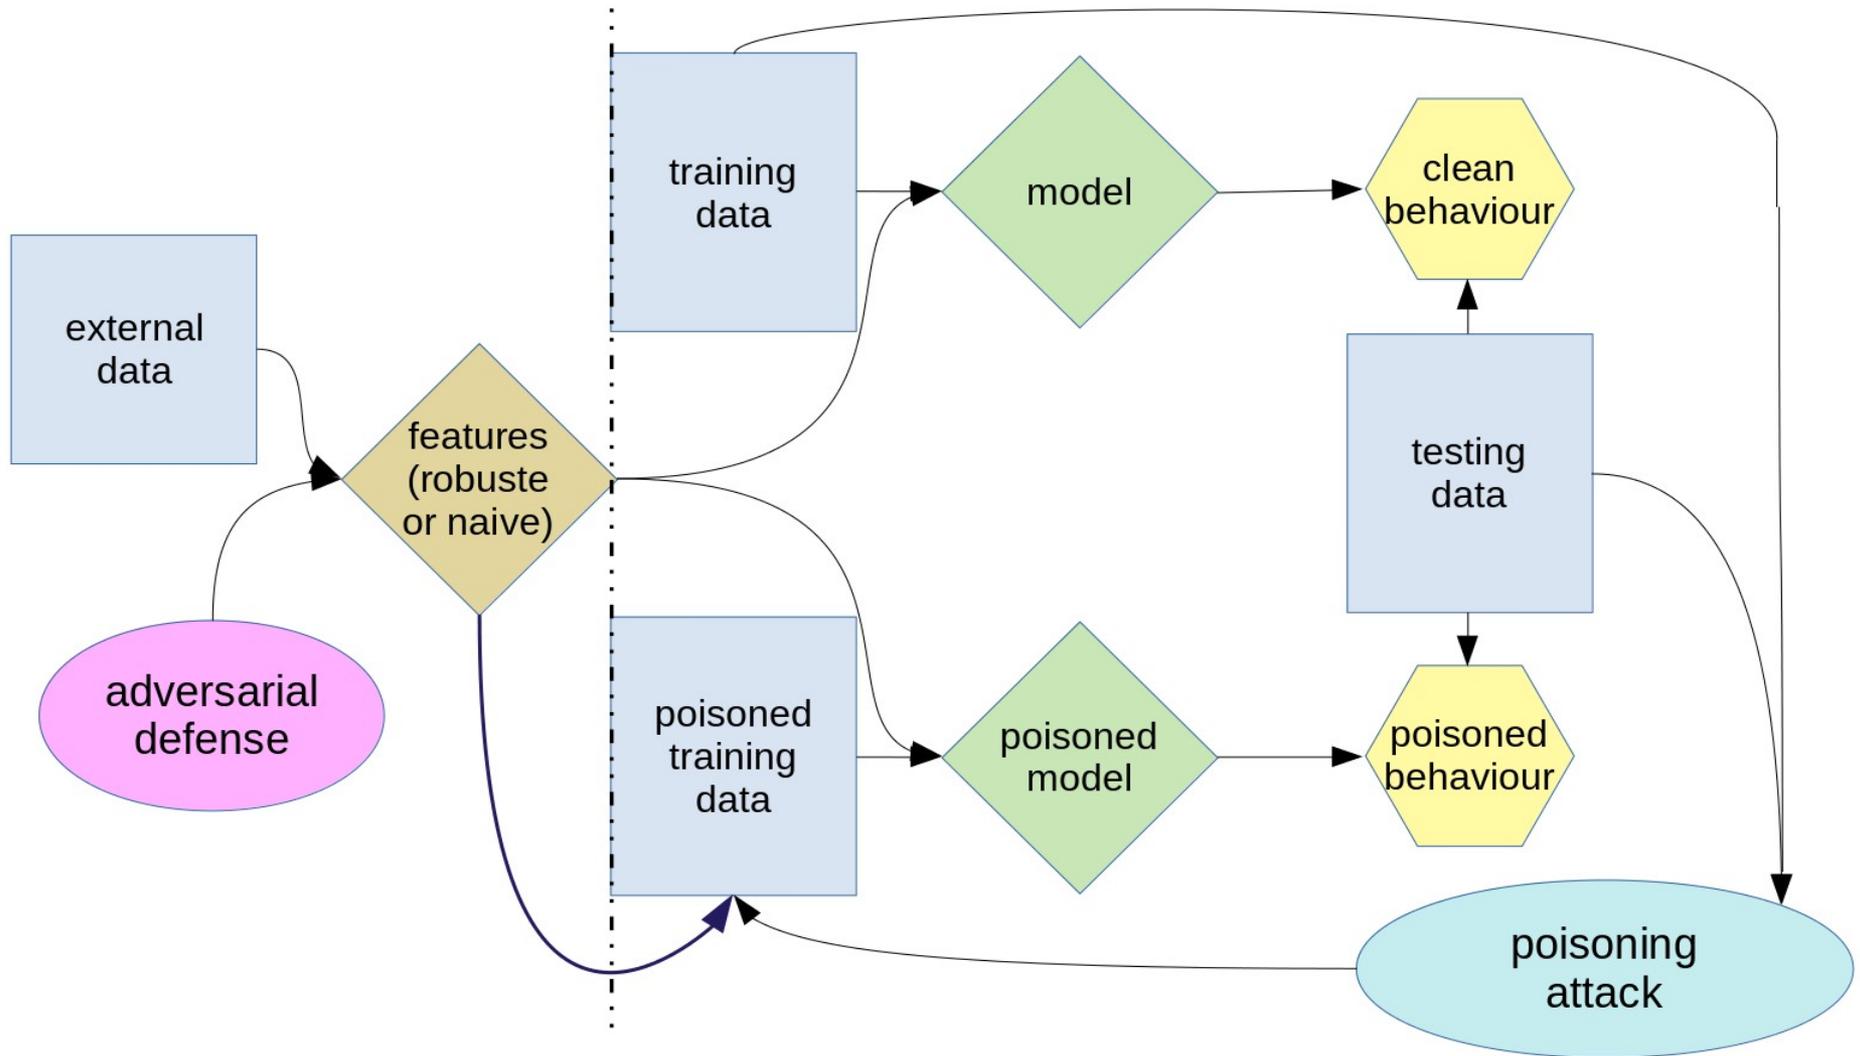
La question n'est pas tout à fait triviale :  
on peut avoir des points margés mais plus ou moins dispersés



# empoisonnement



# empoisonnement invisible et apprentissage robuste



# empoisonnement invisible et apprentissage robuste

Dataset	CIFAR	MNIST
AD on naive feature	24%	68%
AD on FSGM feature	30%	93%
AD on PGD feature	<b>34%</b>	<b>95%</b>

feature	CIFAR
PF on naive feature	85%
PF on FSGM feature	53%
PF on PGD feature	<b>16%</b>

Poison Frog (reimplémentation) passe de 85 % de succès à 16 % (CIFAR)

L'accuracy sous attaque AD qui avait chuté à 68 % remonte à 95 % (MNIST)

Relecture de la base + « RANSAC » + caractéristique robuste

**Relecture** → protection contre trop de données fortement corrompues

**RANSAC** → protection contre peu de données fortement corrompues

**Robuste** → protection contre des données faiblement corrompues

# Conclusion

---

**Quelque soit le scénario, l'empoisonnement ne paraît pas un risque majeur.**

# Conclusion

---

**Quelque soit le scénario, l'empoisonnement ne paraît pas un risque majeur.**

Sauf si l'apprentissage a lieu sans relecture de la base !

# Perspectives

## Les dangers du pseudo-labelling

PASCAL airplane



SUN airplane



Caltech101 airplane



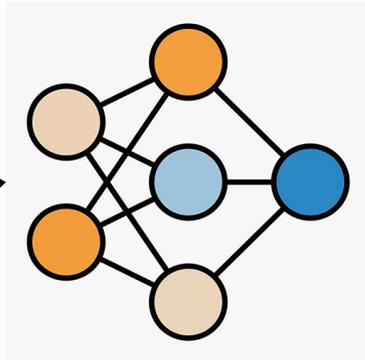
ImageNet airplane



# Perspectives

## Les dangers du pseudo-labelling

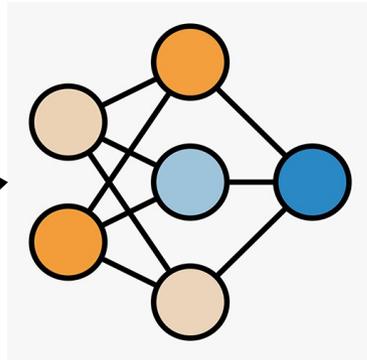
Domaine 1



# Perspectives

## Les dangers du pseudo-labelling

Domaine 1



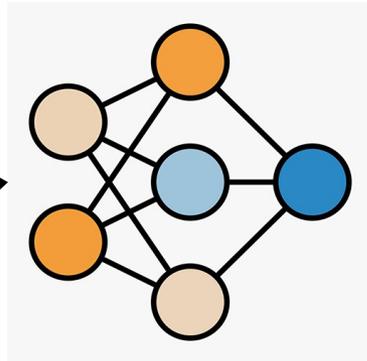
Domaine 2



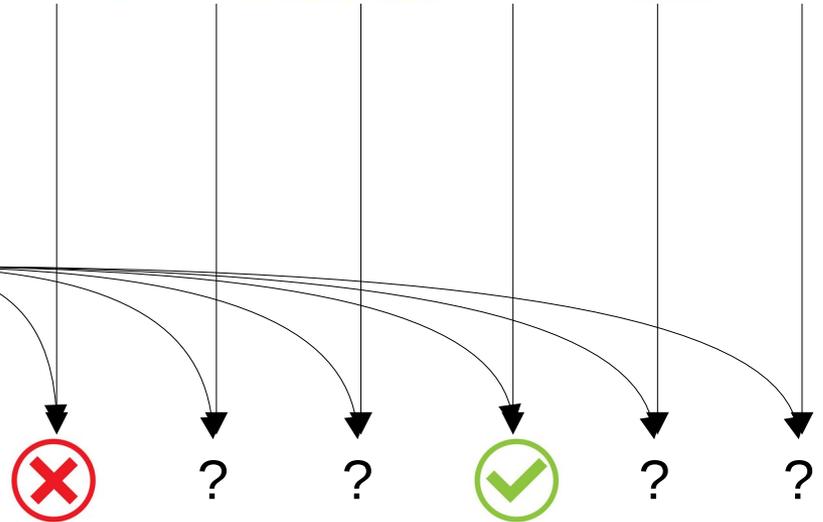
# Perspectives

## Les dangers du pseudo-labelling

Domaine 1



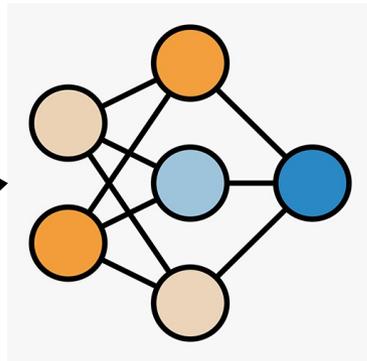
Domaine 2



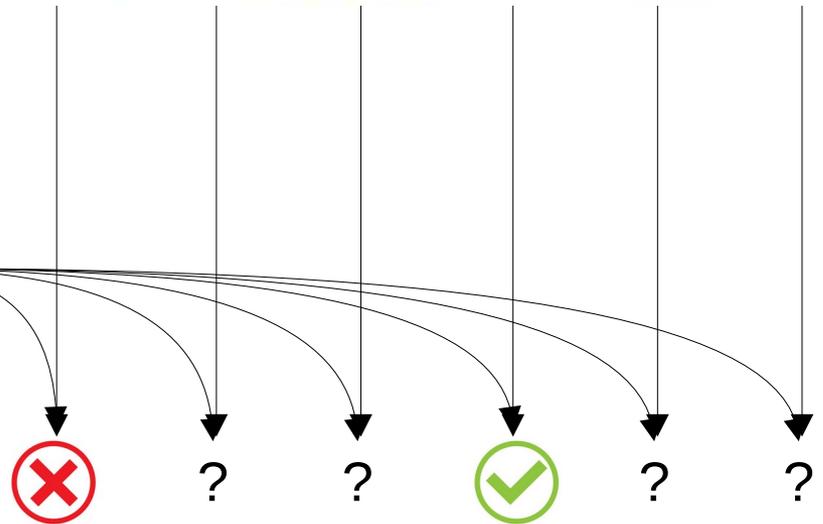
# Perspectives

## Les dangers du pseudo-labelling

Domaine 1



Domaine 2

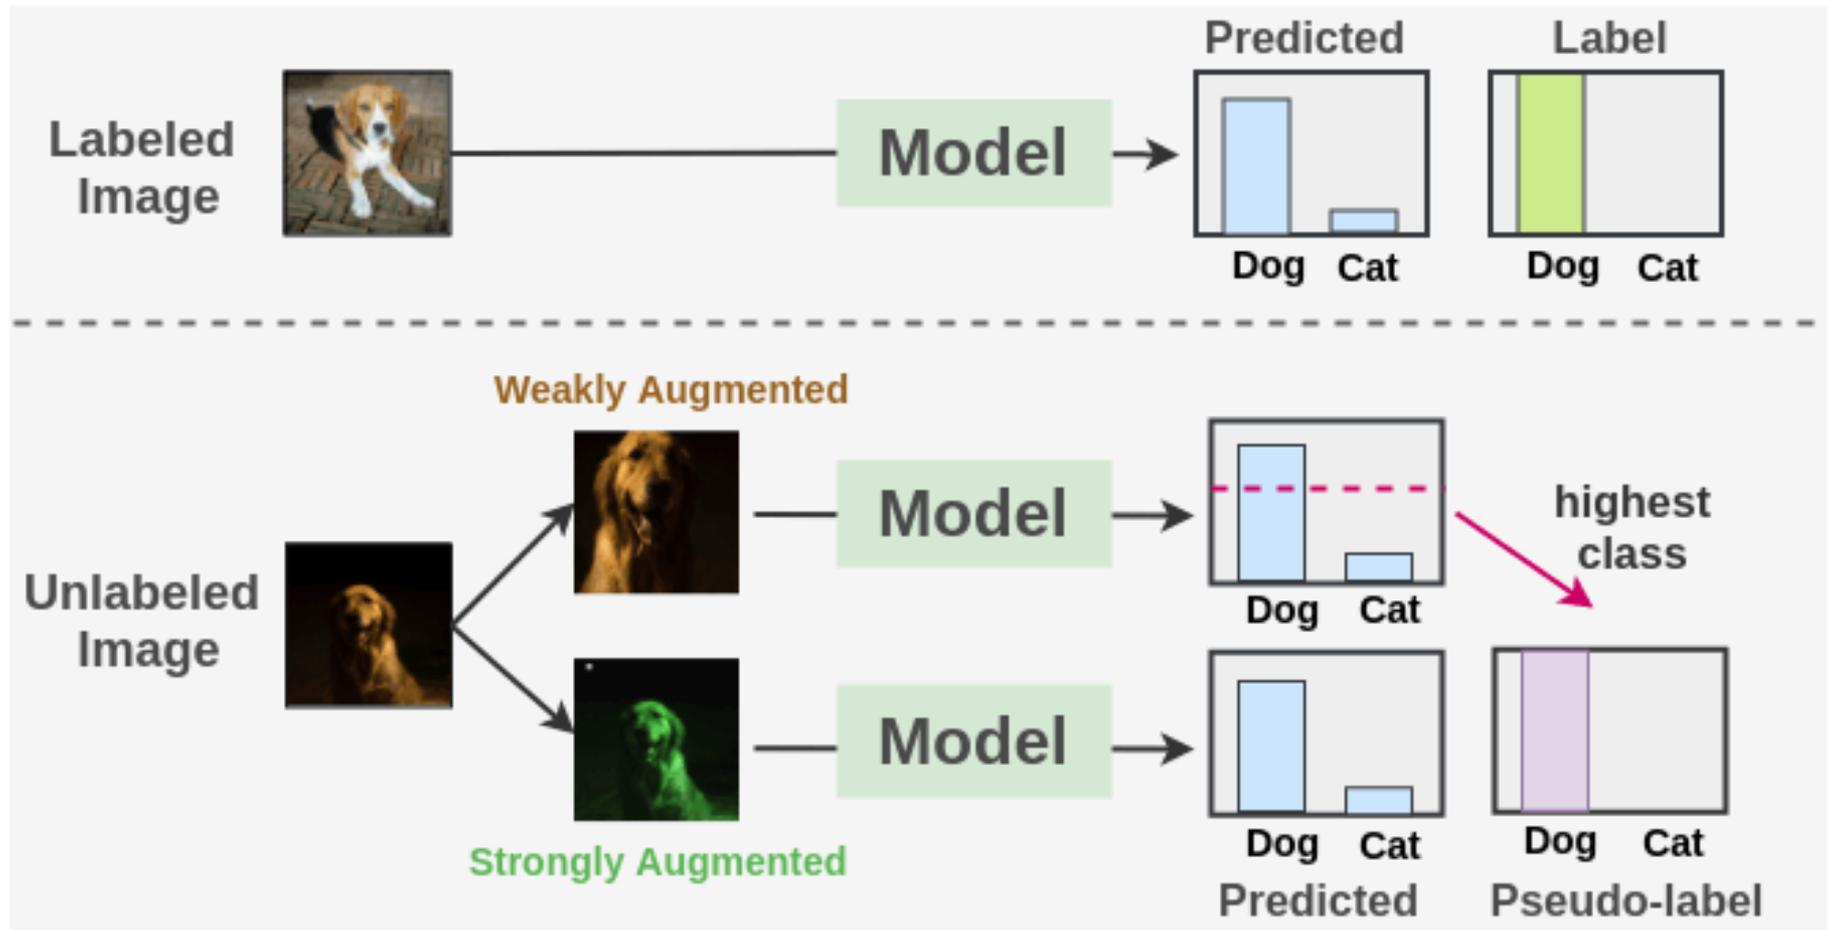


Confiance + consistance !

# Perspectives

## Les dangers du pseudo-labelling

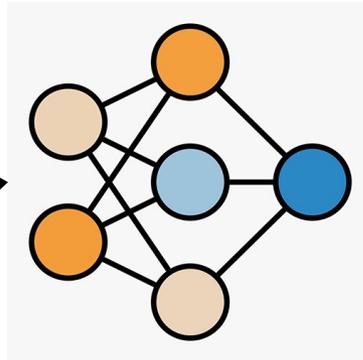
### FixMatch Pipeline



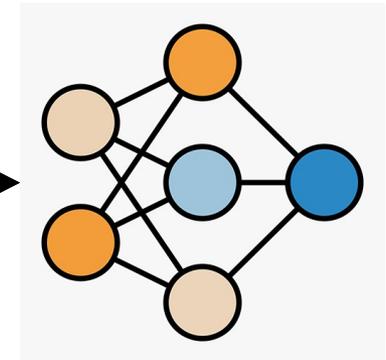
# Perspectives

## Les dangers du pseudo-labelling

Domaine 1



Domaine 2



# Perspectives

## Les dangers du pseudo-labelling

---

Est-il possible de créer une perturbation qui

Augmente la confiance

Résiste à un test de consistance

# Perspectives

## Les dangers du pseudo-labelling

---

Est-il possible de créer une perturbation qui

Augmente la confiance

Résiste à un test de consistance

**Et qui une fois dans la base d'apprentissage provoque un empoisonnement ???**

# Perspectives

## Les dangers du pseudo-labelling

---

Est-il possible de créer une perturbation qui

Augmente la confiance

Résiste à un test de consistance

**Et qui une fois dans la base d'apprentissage provoque un empoisonnement ???**

À suivre !

# Perspectives

## Les limites de ne considérer que « deep feature + SVM »

---

Là où les attaques adversaires sont apparues avec le DL,  
l'empoisonnement est plus facile avec une approche type SVM !

# Perspectives

## Les limites de ne considérer que « deep feature + SVM »

---

Là où les attaques adversaires sont apparues avec le DL,  
l'empoisonnement est plus facile avec une approche type SVM !

→ typiquement une approche SVM est beaucoup plus sensible au bruit des labels !  
(en fonction de « C »)

# Perspectives

## Les limites de ne considérer que « deep feature + SVM »

---

Là où les attaques adversaires sont apparues avec le DL,  
l'empoisonnement est plus facile avec une approche type SVM !

→ typiquement une approche SVM est beaucoup plus sensible au bruit des labels !  
(en fonction de « C »)

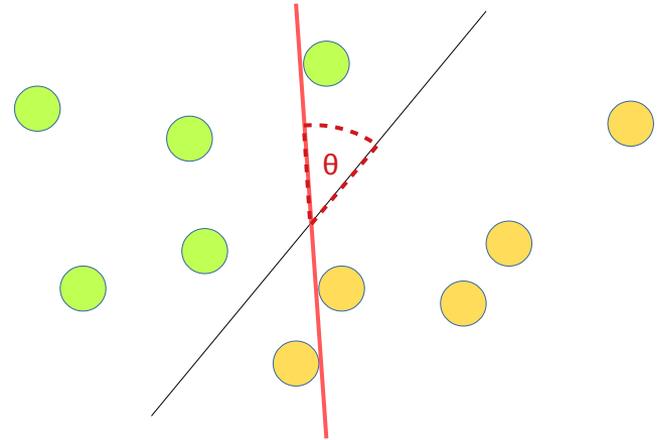
→ empoisonner un CNN est « plus difficile »  
mais ouvre potentiellement la porte à d'autres conclusions ...

# Perspectives

## Les limites de ne considérer que « deep feature + SVM »

---

*Proxy based*



# Perspectives

## Les limites de ne considérer que « deep feature + SVM »

proxy used Eq.3	testing accuracy	desired
$SGD_{\theta}(f, Test)$	27%	$\ll 87\%$ (-31% in [18])
$SGD_{\theta}(f, Train)$	34%	$\approx 87\%$ (0% in [18])
$-w_{imagenet}$	64%	$\approx 87\%$
$w_{imagenet}$	58%	$\approx 87\%$
$-SGD_{\theta}(f, Train)$	73%	$\approx 87\%$ (-1% in [18])
$-SGD_{\theta}(f, Test)$	77%	$\gg 87\%$ (+7% in [18])
Original accuracy	87%	-

# Perspectives

## Les limites de ne considérer que « deep feature + SVM »

proxy used Eq.3	testing accuracy	desired
$SGD_{\theta}(f, Test)$	27%	$\ll 87\%$ (-31% in [18])
$SGD_{\theta}(f, Train)$	34%	$\approx 87\%$ (0% in [18])
$-w_{imagenet}$	64%	$\approx 87\%$
$w_{imagenet}$	58%	$\approx 87\%$
$-SGD_{\theta}(f, Train)$	73%	$\approx 87\%$ (-1% in [18])
$-SGD_{\theta}(f, Test)$	77%	$\gg 87\%$ (+7% in [18])
Original accuracy	87%	-

Mais depuis Imagenet seulement (sinon ça marche comme prévu) !

# Perspectives

## Les limites de ne considérer que « deep feature + SVM »

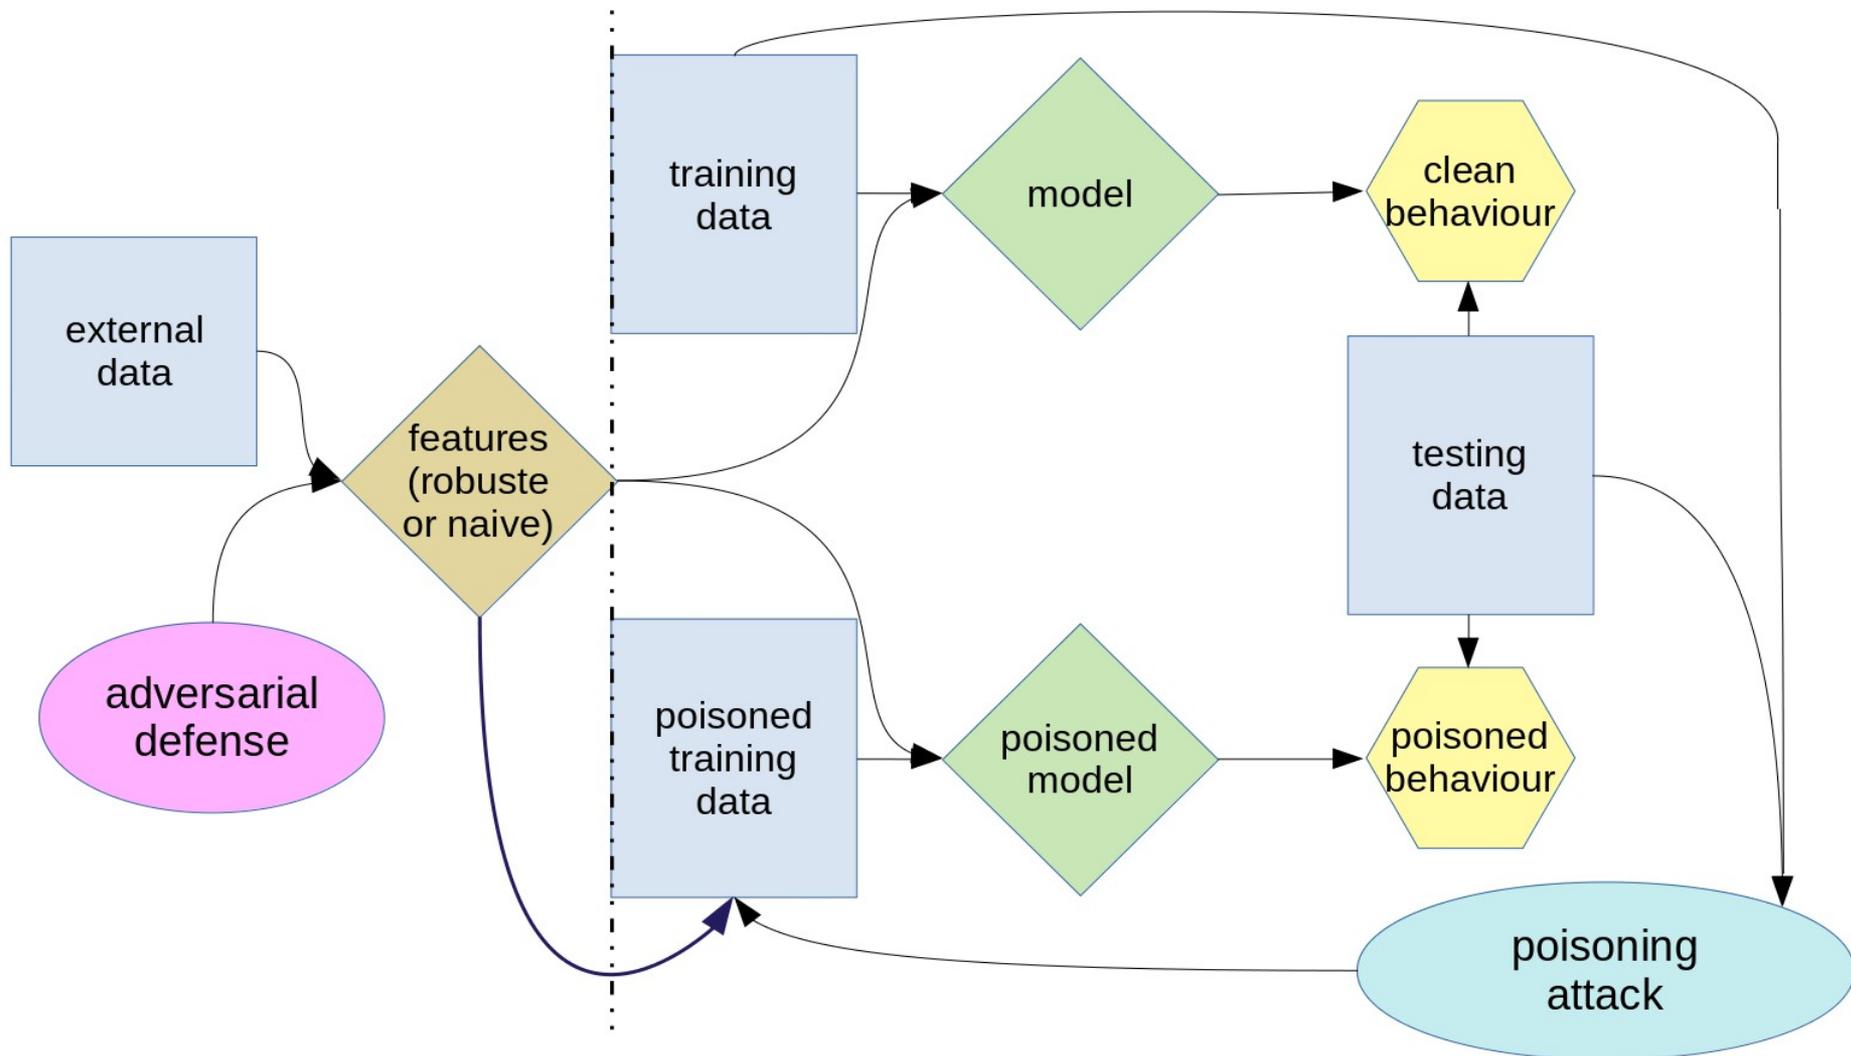
proxy used Eq.3	testing accuracy	desired
$SGD_{\theta}(f, Test)$	27%	$\ll 87\%$ (-31% in [18])
$SGD_{\theta}(f, Train)$	34%	$\approx 87\%$ (0% in [18])
$-w_{imagenet}$	64%	$\approx 87\%$
$w_{imagenet}$	58%	$\approx 87\%$
$-SGD_{\theta}(f, Train)$	73%	$\approx 87\%$ (-1% in [18])
$-SGD_{\theta}(f, Test)$	77%	$\gg 87\%$ (+7% in [18])
Original accuracy	87%	-

Mais depuis Imagenet seulement (sinon ça marche comme prévu) !

(l'impact sur le trajet est plus important que l'impact sur l'arrivé)

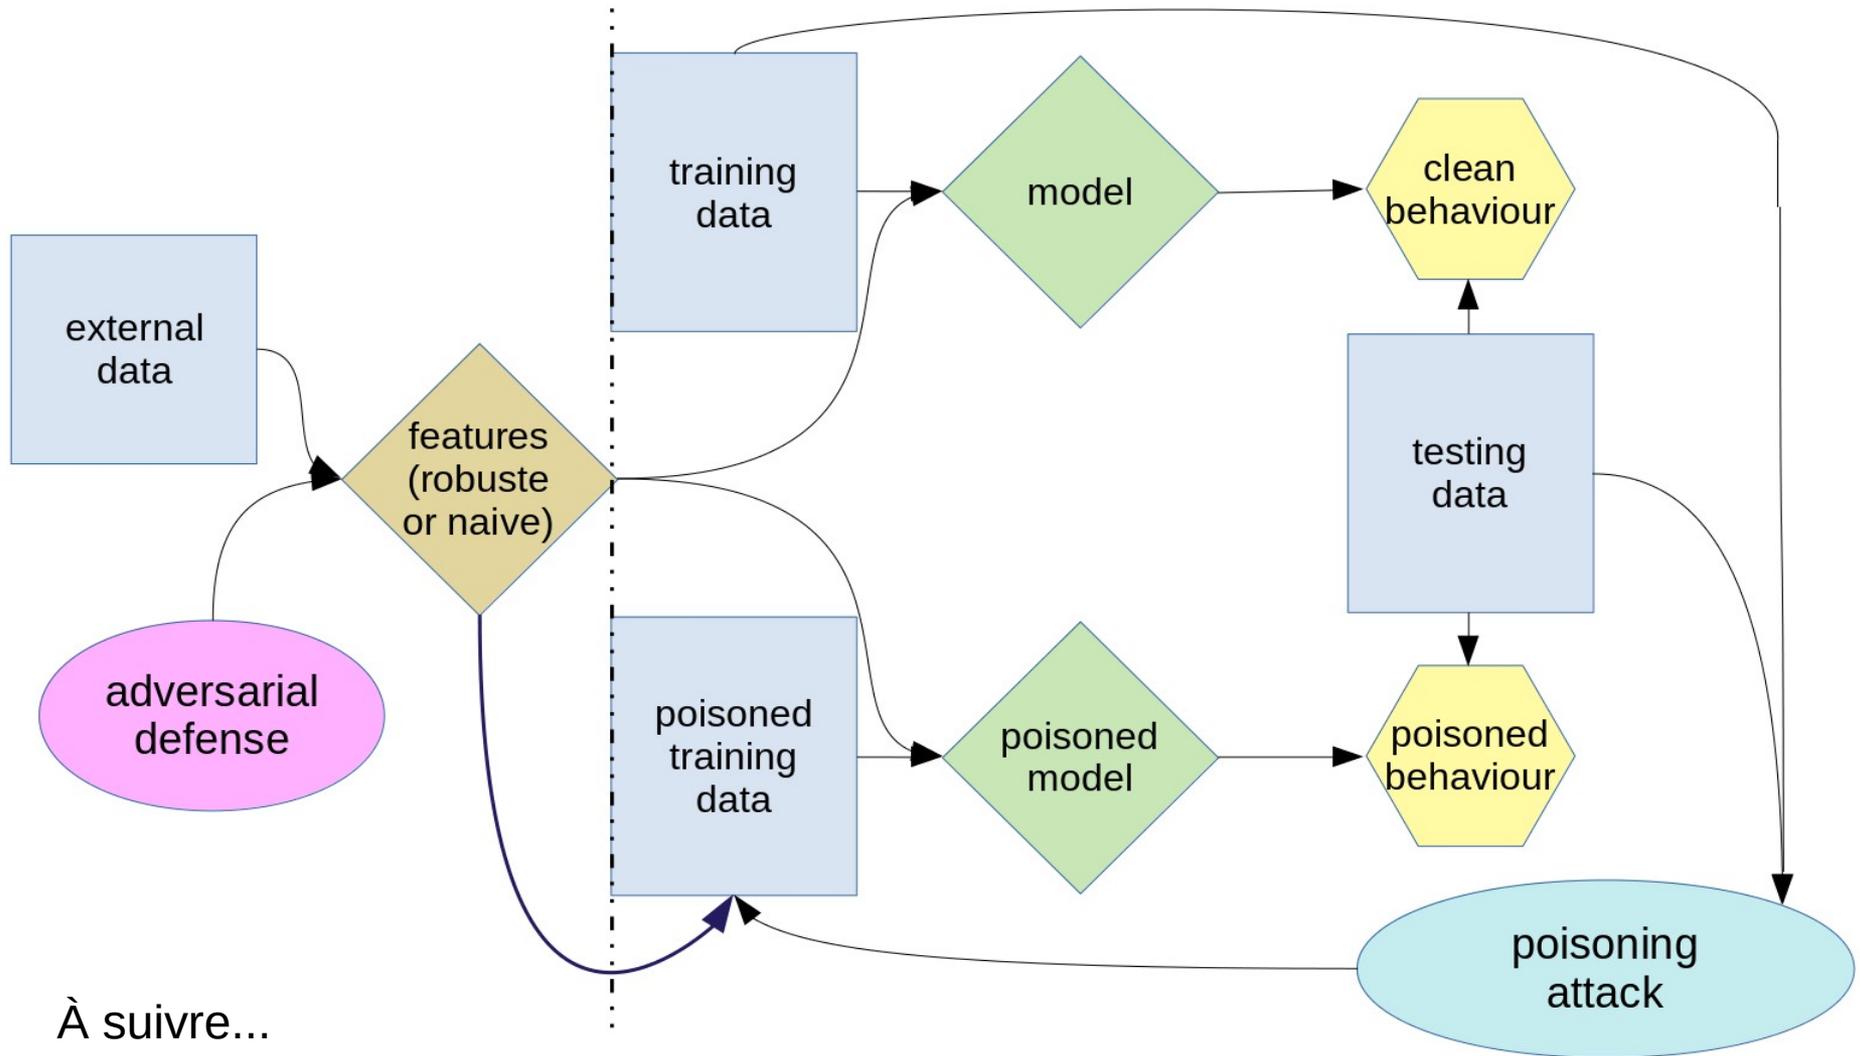
# Perspectives

## Les limites de ne considérer que « deep feature + SVM »



# Perspectives

## Les limites de ne considérer que « deep feature + SVM »



---

Merci pour votre attention.

Les codes sont disponibles à [github.com/achanhon/AdversarialModel](https://github.com/achanhon/AdversarialModel)