



La confiance avec le contrôle : spécification et vérification d'hyperpropriétés sur réseaux de neurones

Journées Francophones des Langages Applicatifs, Oberbronn 2026

Guilhem Ardouin, Michele Alberti, Julien Girard-Satabin

27 janvier 2026


Vérifier formellement des réseaux de neurones

$$f : \mathbb{R}^n \longrightarrow \mathbb{R}^m$$




Vérifier formellement des réseaux de neurones

$$f : \mathbb{R}^n \longrightarrow \mathbb{R}^m$$




Vérifier formellement des réseaux de neurones

$$f : \mathbb{R}^n \longrightarrow \mathbb{R}^m$$




Quelles propriétés vérifier ?

Robustesse locale = la classification d'une entrée est la même pour une entrée « proche »




Quelles propriétés vérifier ?

Robustesse locale = la classification d'une entrée est la même pour une entrée « proche »



Quelles propriétés vérifier ?

Robustesse locale = la classification d'une entrée est la même pour une entrée « proche »



Quelles propriétés vérifier ?

Robustesse locale = la classification d'une entrée est la même pour une entrée « proche »



$$f\left(\text{image of cat with hat and chain}\right) = \begin{bmatrix} 5.57 \\ 5.56 \end{bmatrix}$$

f n'est **pas** localement robuste

$$\text{class}(f(\text{image of cat})) \neq \text{class}(f(\text{image of dog}))$$


chien

chat

Quelles propriétés vérifier ?

Robustesse locale = $\forall \mathbf{x}' \in \mathbb{R}^n. \|\mathbf{x} - \mathbf{x}'\| \leq \varepsilon \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$


($\mathbf{x}$ fixé)



$$\|\mathbf{x}\| = \max_i x_i$$

Quelles propriétés vérifier ?

Robustesse locale = $\forall \mathbf{x}' \in \mathbb{R}^n. \|\mathbf{x} - \mathbf{x}'\| \leq \varepsilon \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$ ($\mathbf{x}$ fixé)




$$\|\mathbf{x}\| = \max_i x_i$$

$$\forall \mathbf{x}'. \|\mathbf{x} - \mathbf{x}'\| \leq \varepsilon, \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

f robuste en $\mathbf{x}$

Quelles propriétés vérifier ?

Robustesse locale = $\forall \mathbf{x}' \in \mathbb{R}^n. \|\mathbf{x} - \mathbf{x}'\| \leq \varepsilon \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$ ($\mathbf{x}$ fixé)




$$\|\mathbf{x}\| = \max_i x_i$$

$$\|\mathbf{y} - \bullet\| \leq \varepsilon \wedge \text{class}(f(\mathbf{y})) \neq \text{class}(f(\bullet))$$

contre-exemple : f non robuste en $\mathbf{y}$

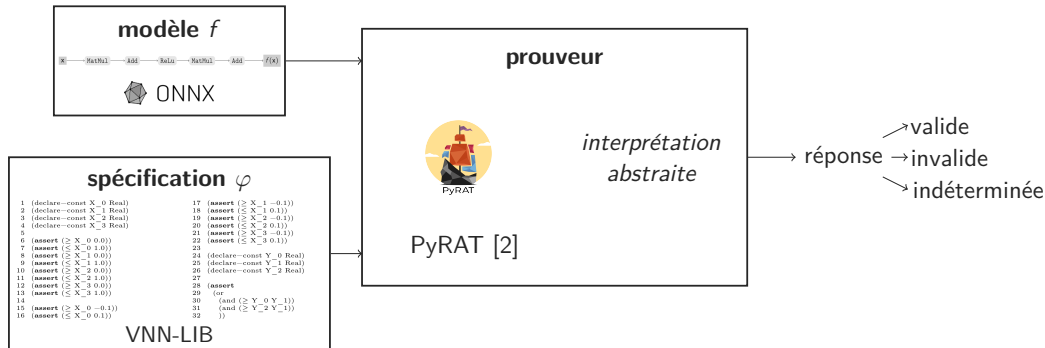
Comment vérifier cette propriété ?

Via différents **prouveurs** spécialisés :



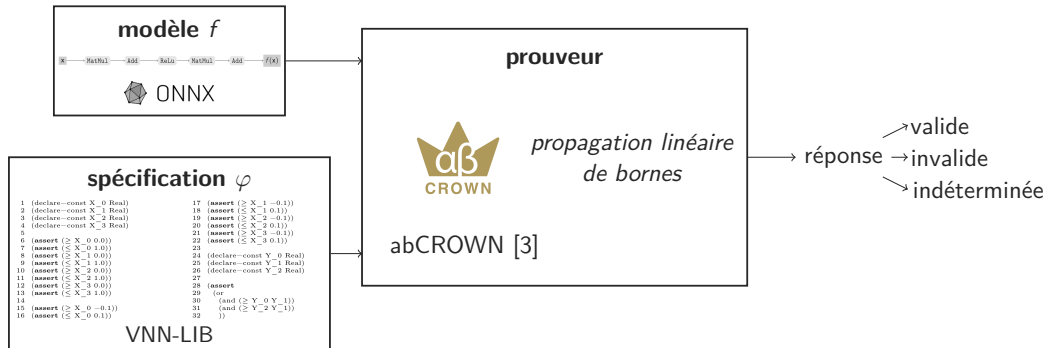
Comment vérifier cette propriété ?

Via différents **prouveurs** spécialisés :



Comment vérifier cette propriété ?

Via différents **prouveurs** spécialisés :



Vérifier formellement des réseaux de neurones

Quelles propriétés vérifier ?

robustesse locale

Comment les vérifier ?

prouveurs spécialisés

Vérifier formellement des réseaux de neurones

Quelles propriétés vérifier ?

robustesse locale

propriétés plus générales ?

Comment les vérifier ?




robustesse basée sur la confiance

prouveurs spécialisés

Robustesse basée sur la confiance

Notion de *confiance* : mesure de la confiance sur la prédiction du réseau




→ seules les entrées dont $\text{conf}(f(\mathbf{x})) > \kappa$ sont considérées



Robustesse basée sur la confiance

Notion de *confiance* : mesure de la confiance sur la prédiction du réseau




→ seules les entrées dont $\text{conf}(f(\mathbf{x})) > \kappa$ sont considérées



Robustesse basée sur la confiance

Notion de *confiance* : mesure de la confiance sur la prédiction du réseau




→ seules les entrées dont $\text{conf}(f(\mathbf{x})) > \kappa$ sont considérées



Robustesse basée sur la confiance

Notion de *confiance* : mesure de la confiance sur la prédiction du réseau




→ seules les entrées dont $\text{conf}(f(\mathbf{x})) > \kappa$ sont considérées



Robustesse basée sur la confiance

Notion de *confiance* : mesure de la confiance sur la prédiction du réseau

→ seules les entrées dont $\text{conf}(f(\mathbf{x})) > \kappa$ sont considérées



Vérifier la robustesse basée sur la confiance ?

Quelles propriétés vérifier ?

robustesse locale

propriétés plus générales ?

Comment les vérifier ?

robustesse basée sur la confiance

prouveurs spécialisés

Vérifier la robustesse basée sur la confiance ?

Quelles propriétés vérifier ?

robustesse locale

propriétés plus générales ?



robustesse basée sur la confiance

Comment les vérifier ?

prouveurs spécialisés

pas de support pour la robustesse
basée sur la confiance...

Preuve de concept existante [4]
Mais...

- implémentation non générale
- version antérieure de Marabou (bugs)



Vérifier la robustesse basée sur la confiance ?

Objectif : pouvoir *spécifier* et *vérifier* la robustesse basée sur la confiance

Vérifier la robustesse basée sur la confiance ?

Objectif : pouvoir *spécifier* et *vérifier* la robustesse basée sur la confiance



CAISAR

Vérifier la robustesse basée sur la confiance ?

Objectif : pouvoir *spécifier* et *vérifier* la robustesse basée sur la confiance



CAISAR

Questions de recherche :

- quels sont les verrous scientifiques pour le support de cette propriété dans les outils actuels ?
- quelles solutions peuvent-être mises en place ?

CAISAR [5]

CAISAR = **C**haracterizing **A**rtificial **I**ntelligence **S**afety **A**nd **R**obustness

Plateforme pour la spécification et vérification de modèles d'apprentissage automatique

→ utilise des prouveurs *externes* pour la vérification




CAISAR [5]


CAISAR = **C**haracterizing **A**rtificial **I**ntelligence **S**afety **A**nd **R**obustness

Plateforme pour la spécification et vérification de modèles d'apprentissage automatique

→ utilise des prouveurs *externes* pour la vérification




CAISAR : vérifier la robustesse basée sur la confiance ?



Rappel : la robustesse basée sur la confiance n'est **pas supportée** par les prouveurs

CAISAR : vérifier la robustesse basée sur la confiance ?



Rappel : la robustesse basée sur la confiance n'est **pas supportée** par les prouveurs

Enjeux :

1. spécifier la robustesse basée sur la confiance dans CAISAR
2. appliquer des transformations pour la rendre vérifiable (**sans modifier** les prouveurs)

Spécifier la robustesse (globale) basée sur la confiance ?

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

Spécifier la robustesse (globale) basée sur la confiance ?

contrainte arithmétique sur
plusieurs variables d'entrée

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n \overbrace{|x_i - x'_i| \leq \varepsilon_i} \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

Spécifier la robustesse (globale) basée sur la confiance ?

contrainte arithmétique sur
plusieurs variables d'entrée

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n \overbrace{|x_i - x'_i| \leq \varepsilon_i} \wedge \underbrace{\text{conf}(f(\mathbf{x})) > \kappa}_{\text{contrainte d'entrée sur une variable de sortie}} \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

contrainte d'entrée sur
une variable de sortie

Spécifier la robustesse (globale) basée sur la confiance ?

contrainte arithmétique sur
plusieurs variables d'entrée

plusieurs exécutions

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n \overbrace{|x_i - x'_i| \leq \varepsilon_i} \wedge \underbrace{\text{conf}(f(\mathbf{x})) > \kappa}_{\text{contrainte d'entrée sur une variable de sortie}} \Rightarrow \text{class}(\overbrace{f(\mathbf{x})}) = \text{class}(\overbrace{f(\mathbf{x}')})$$

contrainte d'entrée sur
une variable de sortie

Spécifier la robustesse (globale) basée sur la confiance ?

contrainte arithmétique sur
plusieurs variables d'entrée

plusieurs exécutions

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n \overbrace{|x_i - x'_i| \leq \varepsilon_i} \wedge \underbrace{\text{conf}(f(\mathbf{x})) > \kappa}_{\text{contrainte d'entrée sur une variable de sortie}} \Rightarrow \text{class}(\overbrace{f(\mathbf{x})}) = \text{class}(\overbrace{f(\mathbf{x}')})$$

contrainte d'entrée sur
une variable de sortie

En quoi est-ce un problème ?

Spécifier la robustesse (globale) basée sur la confiance ?

contrainte arithmétique sur plusieurs variables d'entrée

plusieurs exécutions

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n \overbrace{|x_i - x'_i| \leq \varepsilon_i}^{\text{contrainte d'entrée sur une variable de sortie}} \wedge \underbrace{\text{conf}(f(\mathbf{x})) > \kappa}_{\text{contrainte arithmétique sur plusieurs variables d'entrée}} \Rightarrow \text{class}(\overbrace{f(\mathbf{x})}^{\text{plusieurs exécutions}}) = \text{class}(\overbrace{f(\mathbf{x}')}^{\text{plusieurs exécutions}})$$

contrainte d'entrée sur une variable de sortie

non spécifiable dans les outils (VNN-LIB)

Spécifier la robustesse (globale) basée sur la confiance ?

contrainte arithmétique sur
plusieurs variables d'entrée

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n \overbrace{|x_i - x'_i| \leq \varepsilon_i}^{\text{contrainte d'entrée sur une variable de sortie}} \wedge \underbrace{\text{conf}(f(\mathbf{x})) > \kappa}_{\text{plusieurs exécutions}} \Rightarrow \text{class}(\overbrace{f(\mathbf{x})}) = \text{class}(\overbrace{f(\mathbf{x}')})$$

contrainte d'entrée sur
une variable de sortie

hyperpropriétés non supportées (VNN-LIB)

Spécifier des hyperpropriétés ?

Hyperpropriété [6] = propriété qui concerne *plusieurs exécutions* du modèle

spécification :

```
1 (declare-const X_0 Real)
2 (declare-const X_1 Real)
3 (declare-const X_2 Real)
4 (declare-const X_3 Real)
5
6 (assert (> X_0 0.0))
7 (assert (<= X_0 1.0))
8 (assert (> X_1 0.0))
9 (assert (<= X_1 1.0))
10 (assert (> X_2 0.0))
11 (assert (<= X_2 1.0))
12 (assert (> X_3 0.0))
13 (assert (<= X_3 1.0))
14
15 (assert (>= X_0 -0.1))
16 (assert (<= X_0 0.1))
17 (assert (>= X_1 -0.1))
18 (assert (<= X_1 0.1))
19 (assert (>= X_2 -0.1))
20 (assert (<= X_2 0.1))
21 (assert (>= X_3 -0.1))
22 (assert (<= X_3 0.1))
23
24 (declare-const Y_0 Real)
25 (declare-const Y_1 Real)
26 (declare-const Y_2 Real)
27
28 (assert
29   (or
30     (and (>= Y_0 Y_1))
31     (and (>= Y_2 Y_1))
32   ))
```

$f(\mathbf{x})$

modèle :



1 spécification VNN-LIB = 1 seul modèle

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

Spécifier des hyperpropriétés ?

Hyperpropriété [6] = propriété qui concerne *plusieurs exécutions* du modèle

spécification :

```
1 (declare-const X_0 Real)
2 (declare-const X_1 Real)
3 (declare-const X_2 Real)
4 (declare-const X_3 Real)
```

x

```
5
6 (assert (> X_0 0.0))
7 (assert (< X_0 1.0))
8 (assert (> X_1 0.0))
9 (assert (< X_1 1.0))
10 (assert (> X_2 0.0))
11 (assert (< X_2 1.0))
12 (assert (> X_3 0.0))
13 (assert (< X_3 1.0))
14
15 (assert (>= X_0 -0.1))
16 (assert (<= X_0 0.1))
```

f(x)

```
17 (assert (>= X_1 -0.1))
18 (assert (<= X_1 0.1))
19 (assert (>= X_2 -0.1))
20 (assert (<= X_2 0.1))
21 (assert (>= X_3 -0.1))
22 (assert (<= X_3 0.1))
23
24 (declare-const Y_0 Real)
25 (declare-const Y_1 Real)
26 (declare-const Y_2 Real)
27
28 (assert
29   (or
30     (and (>= Y_0 Y_1))
31     (and (>= Y_2 Y_1))
32   ))
```

modèle :



1 spécification VNN-LIB = 1 seul modèle

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

Reformulation de la propriété (1)

Début de solution : reformuler la propriété

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

Reformulation de la propriété (1)

Début de solution : reformuler la propriété

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

$\Leftrightarrow$

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \\ \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

avec : $\text{clip}(\mathbf{x} + \boldsymbol{\delta})$ qui ramène $\mathbf{x} + \boldsymbol{\delta}$ dans le « bon intervalle » ($\mathbf{x} + \boldsymbol{\delta} \in \mathbb{R}^n$)

Reformulation de la propriété (1)

Début de solution : reformuler la propriété

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

$\Leftrightarrow$

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \\ \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

avec : $\text{clip}(\mathbf{x} + \boldsymbol{\delta})$ qui ramène $\mathbf{x} + \boldsymbol{\delta}$ dans le « bon intervalle » ($\mathbf{x} + \boldsymbol{\delta} \in \mathbb{R}^n$)

Reformulation de la propriété (1)

Début de solution : reformuler la propriété

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

$\Leftrightarrow$

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \\ \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

avec : $\text{clip}(\mathbf{x} + \boldsymbol{\delta})$ qui ramène $\mathbf{x} + \boldsymbol{\delta}$ dans le « bon intervalle » ($\mathbf{x} + \boldsymbol{\delta} \in \mathbb{R}^n$)

Reformulation de la propriété (1)

Début de solution : reformuler la propriété

$$\forall \mathbf{x}, \mathbf{x}' \in \mathbb{R}^n. \bigwedge_{i=1}^n |x_i - x'_i| \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$$

$\Leftrightarrow$

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \\ \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

avec : $\text{clip}(\mathbf{x} + \boldsymbol{\delta})$ qui ramène $\mathbf{x} + \boldsymbol{\delta}$ dans le « bon intervalle » ($\mathbf{x} + \boldsymbol{\delta} \in \mathbb{R}^n$)

Reformulation de la propriété (2)

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \\ \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

Reformulation de la propriété (2)

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa \\ \Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

$\Leftrightarrow$

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \\ \Rightarrow \neg(\text{conf}(f(\mathbf{x})) > \kappa) \vee \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

Reformulation de la propriété (2)

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \wedge \text{conf}(f(\mathbf{x})) > \kappa$$

$$\Rightarrow \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

$$\Leftrightarrow$$

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i$$

$$\Rightarrow \neg(\text{conf}(f(\mathbf{x})) > \kappa) \vee \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

Spécification dans CAISAR (WhyML)

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \\ \Rightarrow \neg(\text{conf}(f(\mathbf{x})) > \kappa) \vee \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

Spécification dans CAISAR (WhyML)

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i \\ \Rightarrow \neg(\text{conf}(f(\mathbf{x})) > \kappa) \vee \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

WhyML

```
theory ConfidenceMeasure
> let function softmax_confidence (m: model) ...
end

theory ClassGlobalRobustConf
> predicate unconfident_prediction (m: model) ...
> predicate same_prediction (label_bounds: Label.bounds) ...
> predicate confidence_globally_robust (valid_input_bounds: FeatureVector.t ...
end
```

Spécification dans CAISAR (WhyML)

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i$$

$$\Rightarrow \neg(\text{conf}(f(\mathbf{x})) > \kappa) \vee \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

WhyML

```
theory ConfidenceMeasure
> let function softmax_confidence (m: model) ...
end

theory ClassGlobalRobustConf
> predicate unconfident_prediction (m: model) ...
> predicate same_prediction (label_bounds: Label.bounds) ...
> predicate confidence_globally_robust (valid_input_bounds: FeatureVector.t ...
end
```

φ

```
goal conf_global_robustness:
  let nn = read_model model_filename in
  let len = 5 in
  let bounds = (fun x -> valid_input_bounds x) in
  let conf_measure = (fun m x -> softmax_confidence m x) in
  confidence_globally_robust bounds
  label_bounds
  lbounds
  ubounds
  len
  nn
  eps
  threshold
  conf_measure
```

Spécification dans CAISAR (WhyML)

$$\forall \mathbf{x} \in \mathbb{R}^n, \forall \boldsymbol{\delta} \in \mathbb{R}^n. \bigwedge_{i=1}^n -\varepsilon_i \leq \delta_i \leq \varepsilon_i$$

$$\Rightarrow \neg(\text{conf}(f(\mathbf{x})) > \kappa) \vee \text{class}(f(\mathbf{x})) = \text{class}(f(\text{clip}(\mathbf{x} + \boldsymbol{\delta})))$$

WhyML

```
theory ConfidenceMeasure
> let function softmax_confidence (m: model) ...
end

theory ClassGlobalRobustConf
> predicate unconfident_prediction (m: model) ...
> predicate same_prediction (label_bounds: Label.bounds) ...
> predicate confidence_globally_robust (valid_input_bounds: FeatureVector.t ...
end
```

φ

```
goal conf_global_robustness:
  let nn = read_model model_filename in
  let len = 5 in
  let bounds = (fun x -> valid_input_bounds x) in
  let conf_measure = (fun m x -> softmax_confidence m x) in
  confidence_globally_robust bounds
  label_bounds
  lbounds
  ubounds
  len
  nn
  eps
  threshold
  conf_measure
```


Lever les derniers verrous ? → **interprétation**

Interprétation de la spécification : confiance ?

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$

Interprétation de la spécification : confiance ?

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$




Interprétation de la spécification : confiance

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$



Interprétation de la spécification : confiance

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$



Spécification :

$$\neg(\text{conf}(f(\mathbf{x})) > \kappa)$$


↓ spécification (interprétée)

$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa$$


softmax : vector $\longrightarrow$ vector

Interprétation de la spécification : confiance

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$




Modèle :



Interprétation de la spécification : confiance

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$



Spécification :


$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa \quad \text{X}$$

Modèle :



Interprétation de la spécification : confiance

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$



Spécification :


$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa \quad \text{X}$$

Modèle :



Interprétation de la spécification : confiance

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$




Spécification :

$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa \quad \text{X}$$


$$\downarrow$$
$$\varphi' : \forall i \in \{1, \dots, m\}, g(\mathbf{x})[i] \leq \kappa \quad \checkmark$$

Modèle :



Interprétation de la spécification : confiance

$$\text{conf}(f(\mathbf{x})) = \max(\text{softmax}(f(\mathbf{x})))$$




Spécification :

$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa \quad \text{X}$$

$$\downarrow$$
$$\varphi' : \forall i \in \{1, \dots, m\}, g(\mathbf{x})[i] \leq \kappa \quad \checkmark$$

Modèle :




Interprétation de la spécification : édition de graphe

Spécification :

$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa \quad \text{X}$$

$$\downarrow$$
$$\forall i \in \{1, \dots, m\}, g(\mathbf{x})[i] \leq \kappa \quad \checkmark$$

Modèle :




Interprétation de la spécification : édition de graphe

Spécification :

$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa \quad \text{X}$$

$$\downarrow$$
$$\forall i \in \{1, \dots, m\}, g(\mathbf{x})[i] \leq \kappa \quad \checkmark$$

Modèle :



Édition de graphe $\rightarrow$ *réduire* le problème d'expressivité (spécification $\mapsto$ modèle)


Interprétation de la spécification : édition de graphe

Spécification :

$$\forall i \in \{1, \dots, m\}, \text{softmax}(f(\mathbf{x}))[i] \leq \kappa \quad \text{X}$$

$$\downarrow$$
$$\forall i \in \{1, \dots, m\}, g(\mathbf{x})[i] \leq \kappa \quad \checkmark$$


Modèle :




Édition de graphe $\rightarrow$ *réduire* le problème d'expressivité (spécification $\mapsto$ modèle)

Limitation : support des opérateurs ONNX pour un prouveur
 $\rightarrow$ seulement PyRAT et Maraboupy supportent Softmax

Interprétation de la spécification : édition de graphe



Interprétation de la spécification : édition de graphe





Évaluation

Différents cas d'usage testés (dont reproduction des résultats de [4])

Évaluation

Différents cas d'usage testés (dont reproduction des résultats de [4])

Cas d'usage *industriel* : $f : [0, 1]^7 \rightarrow \mathbb{R}^5$ ($\varepsilon = 0.001$)
1630 paramètres (justesse : 98%)

	$\kappa = 0.999$	$\kappa = 0.998$	$\kappa = 0.9$	$\kappa = 0.8$	$\kappa = 0.7$	$\kappa = 0.33$	$\kappa = 0.32$	$\kappa = 0.31$	$\kappa = 0.25$
Maraboupy	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
PyRAT	✓(38s)	✓(42s)	✓(25min15)	✓(71min6)	⌚	⌚	✗(26s)	✗(26s)	✗(24s)

✓ = “Valide”, ✗ = “Invalide”, ⌚ = Hors temps (2h)

Évaluation

Différents cas d'usage testés (dont reproduction des résultats de [4])

Cas d'usage *industriel* : $f : [0, 1]^7 \rightarrow \mathbb{R}^5$ ($\varepsilon = 0.001$)
1630 paramètres (justesse : 98%)

	$\kappa = 0.999$	$\kappa = 0.998$	$\kappa = 0.9$	$\kappa = 0.8$	$\kappa = 0.7$	$\kappa = 0.33$	$\kappa = 0.32$	$\kappa = 0.31$	$\kappa = 0.25$
Maraboupy	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚	⌚
PyRAT	✓(38s)	✓(42s)	✓(25min15)	✓(71min6)	⌚	⌚	✗(26s)	✗(26s)	✗(24s)

✓ = “Valide”, ✗ = “Invalide”, ⌚ = Hors temps (2h)

Observations :

- preuve de validité difficile pour petits κ
- contre-exemples trouvés pour petits κ
- passage à l'échelle difficile $\rightarrow \#v$ quadratique dans φ'

Conclusion

Contributions :

- mise en évidence des limitations des outils actuels pour la spécification et vérification de la robustesse basée sur la confiance
- méthodes pour contourner ces limitations
- support pour la spécification et vérification de cette propriété dans CAISAR (Maraboupy et PyRAT)

Conclusion

Contributions :

- mise en évidence des limitations des outils actuels pour la spécification et vérification de la robustesse basée sur la confiance
- méthodes pour contourner ces limitations
- support pour la spécification et vérification de cette propriété dans CAISAR (Maraboupy et PyRAT)

Futurs travaux :

- améliorations pour le passage à l'échelle : encoder l'égalité des classes via Argmax
- support de nouvelles propriétés basées sur la confiance (*fairness*, équivalence)



CAISAR

Site web de CAISAR : <https://caisar-platform.com/>

Code open-source : <https://git.frama-c.com/pub/caisar/>

Nous recrutons : <https://caisar-platform.com/positions/>



References I

- [1] H. Wu, O. Isac, A. Zeljic, T. Tagomori, M. L. Daggett, W. Kokke, I. Refaeli, G. Amir, K. Julian, S. Bassan, P. Huang, O. Lahav, M. Wu, M. Zhang, E. Komendantskaya, G. Katz, and C. W. Barrett, “Marabou 2.0 : A versatile formal analyzer of neural networks,” in *Computer Aided Verification - 36th International Conference, CAV 2024, Montreal, QC, Canada, July 24-27, 2024, Proceedings, Part II* (A. Gurfinkel and V. Ganesh, eds.), vol. 14682 of *Lecture Notes in Computer Science*, pp. 249–264, Springer, 2024.
- [2] A. Lemesle, J. Lehmann, T. L. Gall, and Z. Chihani, “Verifying neural networks with pyrat,” in *Static Analysis - 32nd International Symposium, SAS 2025, Singapore, October 13-14, 2025, Proceedings* (H. Oh and Y. Sui, eds.), vol. 16100 of *Lecture Notes in Computer Science*, pp. 11–33, Springer, 2025.

References II

- [3] S. Wang, H. Zhang, K. Xu, X. Lin, S. Jana, C. Hsieh, and J. Z. Kolter, “Beta-crown : Efficient bound propagation with per-neuron split constraints for complete and incomplete neural network verification,” *CoRR*, vol. abs/2103.06624, 2021.
- [4] A. Athavale, E. Bartocci, M. Christakis, M. Maffei, D. Nickovic, and G. Weissenbacher, “Verifying global two-safety properties in neural networks with confidence,” in *Computer Aided Verification - 36th International Conference, CAV 2024, Montreal, QC, Canada, July 24-27, 2024, Proceedings, Part II* (A. Gurfinkel and V. Ganesh, eds.), vol. 14682 of *Lecture Notes in Computer Science*, pp. 329–351, Springer, 2024.

References III

- [5] M. Alberti, F. Bobot, J. Girard-Satabin, A. Grastien, A. Varasse, and Z. Chihani, “The CAISAR platform : Extending the reach of machine learning specification and verification,” in *Integrated Formal Methods - 20th International Conference, iFM 2025, Paris, France, November 19-21, 2025, Proceedings* (F. Damiani and M. Farrell, eds.), vol. 16194 of *Lecture Notes in Computer Science*, pp. 290–309, Springer, 2025.
- [6] M. R. Clarkson and F. B. Schneider, “Hyperproperties,” *J. Comput. Secur.*, vol. 18, no. 6, pp. 1157–1210, 2010.



Annexes

Spécification WhyML (1/4)

Encoder $\neg(\text{conf}(f(\mathbf{x})) > \kappa)$

```
1  let function softmax_confidence (m: model)
2                                     (x: FeatureVector.t) =
3      let output = (m @@ x) in
4      softmax output
```

Spécification WhyML (2/4)

```
1  predicate unconfident_prediction (m: model)
2                                     (conf_measure: model
3                                     → FeatureVector.t
4                                     → FeatureVector.t)
5                                     (x: FeatureVector.t)
6                                     (threshold: t)
7                                     (label_bounds: Label.bounds) =
8    let conf = conf_measure m x in
9    forall i: Label.t. Label.valid label_bounds i →
10   conf[i] .≤ threshold
```

Spécification WhyML (3/4)

Encoder $\text{class}(f(\mathbf{x})) = \text{class}(f(\mathbf{x}'))$

```
1  predicate same_prediction (label_bounds: Label.bounds)
2                                (lbounds:  $\alpha$ )
3                                (ubounds:  $\alpha$ )
4                                (m: model)
5                                (x: FeatureVector.t)
6                                (delta: FeatureVector.t) =
7    forall l: Label.t. Label.valid label_bounds l  $\rightarrow$ 
8    let y = clip (x + delta) lbounds ubounds in
9    let pred_x = advises label_bounds m l x in
10   let pred_y = advises label_bounds m l y in
11   ( $\neg$  pred_x  $\vee$  pred_y)  $\wedge$  (pred_x  $\vee$   $\neg$  pred_y)
```

Spécification WhyML (4/4)

```
1  predicate confidence_globally_robust (valid_input_bounds: FeatureVector.t
2                                     → bool)
3                                     (label_bounds: Label.bounds)
4                                     (lbounds:  $\alpha$ )
5                                     (ubounds:  $\alpha$ )
6                                     (len: int)
7                                     (m: model)
8                                     (eps: t)
9                                     (threshold: t)
10                                    (conf_measure: model
11                                    → FeatureVector.t
12                                    → FeatureVector.t) =
13  forall x: FeatureVector.t.
14  has_length x len →
15  forall delta: FeatureVector.t.
16  has_length delta len →
17  valid_input_bounds x →
18  bounded_by_epsilon delta eps →
19  unconfident_prediction m conf_measure x threshold label_bounds  $\vee$ 
20  same_prediction label_bounds lbounds ubounds m x delta
```

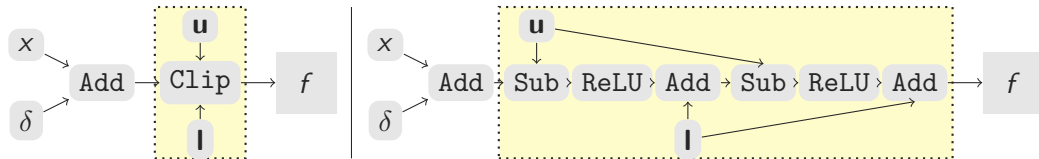
Spécification cas d'usage

```
1  theory GERMAN_CREDIT
2
3  use ieee_float.Float64
4  use caesar.model.Model
5  use caesar.types.IntWithBounds as Label
6  use caesar.types.Vector
7  use caesar.types.VectorFloat64 as FeatureVector
8  use caesar.confidence.ClassGlobalRobustConf
9  use caesar.confidence.ConfidenceMeasure
10
11  constant model_filename: string
12  constant eps: Float64.t
13  constant threshold: Float64.t
14
15  constant label_bounds: Label.bounds = Label.{ lower = 0;
16                                              upper = 1 }
17
18  type bounds = {
19    b0: Float64.t;
20    b1: Float64.t;
21    b2: Float64.t;
22    b3: Float64.t;
23    b4: Float64.t;
24  }
25
26  constant lbounds: bounds = {
27    b0 = (4.0:t); b1 = (250.0:t); b2 = (1.0:t); b3 = (1.0:t); b4 = (19.0:t);
28  }
29
30  constant ubounds: bounds = {
31    b0 = (72.0:t); b1 = (18424.0:t); b2 = (4.0:t); b3 = (4.0:t); b4 = (75.0:t);
32  }
33
34  predicate valid_input_bounds (x: FeatureVector.t) =
35    (x[0] .≥ lbounds.b0 ∧ x[0] .≤ ubounds.b0) ∧
36    (x[1] .≥ lbounds.b1 ∧ x[1] .≤ ubounds.b1) ∧
37    (x[2] .≥ lbounds.b2 ∧ x[2] .≤ ubounds.b2) ∧
38    (x[3] .≥ lbounds.b3 ∧ x[3] .≤ ubounds.b3) ∧
39    (x[4] .≥ lbounds.b4 ∧ x[4] .≤ ubounds.b4)
40
41  goal conf_global_robustness:
42    let nn = read_model model_filename in
43    let len = 5 in
44    let bounds = (fun x → valid_input_bounds x) in
45    let conf_measure = (fun m x → softmax.confidence m x) in
46    confidence_globally_robust bounds label_bounds lbounds ubounds len
47    nn eps threshold conf_measure
48  end
```


Édition du Clip

$$\text{clip}(\mathbf{x}, \mathbf{l}, \mathbf{u})_i = \begin{cases} x_i & \text{si } x_i \in [l_i, u_i] \\ l_i & \text{si } x_i < l_i \\ u_i & \text{si } x_i > u_i \end{cases} \quad \rightarrow \quad \text{clip}(\mathbf{x}, \mathbf{l}, \mathbf{u})_i = \max(l_i, \min(x_i, u_i))$$

$$\text{clip}(\mathbf{x}, \mathbf{l}, \mathbf{u}) = \text{ReLU}(\mathbf{u} - (\mathbf{l} + \text{ReLU}(\mathbf{u} - \mathbf{x}))) + \mathbf{l}$$




Réécriture softmax

Pour tout $\mathbf{z} \in \mathbb{R}^n$, $i \in \{1, \dots, n\}$,

$$\text{softmax}(\mathbf{z})_i = \text{Sig} \left(z_i - \log \left(\sum_{j=1, j \neq i}^n e^{z_j} \right) \right)$$

où $\text{Sig}(x) = \frac{1}{1+e^{-x}}$.



Support opérateurs (softmax)



Prover	Gather	Concat	Sub	Exp	Log	ReduceSum	Sigmoid
Marabou	✗	✗	✓	✗	✗	✗	✗
Maraboupy	✓	✓	✓	✗	✗	✗	✓
PyRAT	✓	✓	✓	✓	✓	✓	✓
nnenum	✓	✓	✓	✗	✗	✗	✗
abcrown	✗	✓	✓	✗	✗	✗	✗

VNN-LIB (confiance)

```
1 (declare-const X_0 Real)
2 (declare-const X_1 Real)
3 (declare-const X_2 Real)
4 (declare-const X_3 Real)
5 (declare-const X_4 Real)
6 (declare-const X_5 Real)
7 (declare-const X_6 Real)
8 (declare-const X_7 Real)
9 (declare-const X_8 Real)
10 (declare-const X_9 Real)
11
12 (declare-const Y_0 Real)
13 (declare-const Y_1 Real)
14 (declare-const Y_2 Real)
15 (declare-const Y_3 Real)
16 (declare-const Y_4 Real)
17 (declare-const Y_5 Real)
18
19 (assert (≥ X_0 4.0))
20 (assert (≤ X_0 72.0))
21 (assert (≥ X_1 250.0))
22 (assert (≤ X_1 18424.0))
23 (assert (≥ X_2 1.0))
24 (assert (≤ X_2 4.0))
25 (assert (≥ X_3 1.0))
26 (assert (≤ X_3 4.0))
27 (assert (≥ X_4 19.0))
28 (assert (≤ X_4 75.0))
29 (assert (≥ X_5 -0.001000000047497451305389404296875))
30 (assert (≤ X_5 0.0010000000047497451305389404296875))
31 (assert (≥ X_6 -0.001000000047497451305389404296875))
32 (assert (≤ X_6 0.0010000000047497451305389404296875))
33 (assert (≥ X_7 -0.001000000047497451305389404296875))
34 (assert (≤ X_7 0.0010000000047497451305389404296875))
35 (assert (≥ X_8 -0.001000000047497451305389404296875))
36 (assert (≤ X_8 0.0010000000047497451305389404296875))
37 (assert (≥ X_9 -0.001000000047497451305389404296875))
38 (assert (≤ X_9 0.0010000000047497451305389404296875))
39
40 (assert (or (and (≥ Y_0 0.5))
41             (and (≥ Y_1 0.5))
42             ))
43 (assert
44   (or
45     (and (≤ Y_5 Y_4)
46           (≥ Y_3 Y_2))
47     (and (≥ Y_5 Y_4)
48           (≤ Y_3 Y_2))
49     (and (≤ Y_4 Y_5)
50           (≥ Y_2 Y_3))
51     (and (≥ Y_4 Y_5)
52           (≤ Y_2 Y_3))
53   ))
```

Évaluation (Athavale)

<i>COMPAS</i>	$\varepsilon = 0.001$	$\varepsilon = 0.01$	$\varepsilon = 0.1$	$\varepsilon = 0.2$	$\varepsilon = 0.3$	$\varepsilon = 0.4$	$\varepsilon = 0.5$	$\varepsilon = 0.6$	$\varepsilon = 0.7$	$\varepsilon = 0.8$	$\varepsilon = 0.9$	$\varepsilon = 1.0$
$\kappa = 0.5$	?/✓	?/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓
$\kappa = 0.6$	?/✓	?/✓	?/✓	?/✓	?/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓
$\kappa = 0.7$	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	X/✓	X/✓	X/✓
$\kappa = 0.8$	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	X/✓
$\kappa = 0.9$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
<i>German Credit</i>	$\varepsilon = 0.001$	$\varepsilon = 0.01$	$\varepsilon = 0.1$	$\varepsilon = 0.2$	$\varepsilon = 0.3$	$\varepsilon = 0.4$	$\varepsilon = 0.5$	$\varepsilon = 0.6$	$\varepsilon = 0.7$	$\varepsilon = 0.8$	$\varepsilon = 0.9$	$\varepsilon = 1.0$
$\kappa = 0.5$	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X
$\kappa = 0.6$	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X
$\kappa = 0.7$	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X	✓/X
$\kappa = 0.8$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
$\kappa = 0.9$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
<i>Law School</i>	$\varepsilon = 0.001$	$\varepsilon = 0.01$	$\varepsilon = 0.1$	$\varepsilon = 0.2$	$\varepsilon = 0.3$	$\varepsilon = 0.4$	$\varepsilon = 0.5$	$\varepsilon = 0.6$	$\varepsilon = 0.7$	$\varepsilon = 0.8$	$\varepsilon = 0.9$	$\varepsilon = 1.0$
$\kappa = 0.5$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
$\kappa = 0.6$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
$\kappa = 0.7$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
$\kappa = 0.8$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
$\kappa = 0.9$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓
<i>Adult</i>	$\varepsilon = 0.001$	$\varepsilon = 0.01$	$\varepsilon = 0.1$	$\varepsilon = 0.2$	$\varepsilon = 0.3$	$\varepsilon = 0.4$	$\varepsilon = 0.5$	$\varepsilon = 0.6$	$\varepsilon = 0.7$	$\varepsilon = 0.8$	$\varepsilon = 0.9$	$\varepsilon = 1.0$
$\kappa = 0.5$	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓	X/✓
$\kappa = 0.6$	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓
$\kappa = 0.7$	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓
$\kappa = 0.8$	✓/✓	✓/✓	✓/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓	?/✓
$\kappa = 0.9$	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓	✓/✓