






Entrainement robuste et quantification dans Aidge

Augustin Lemesle, Julien Lehmann, Zakaria Chihani

Contexte

- Obtenir des **garanties fortes** de sûreté dans des systèmes critiques (nucléaire, spatial, aéro, ...)
 - Sur des **composants IA embarqués**
 - **Preuve** de sûreté de fonctionnement, robustesse, ...
 - Avec un objectif de **certification** du système



Problème

- Les IA statistiques ne sont pas robustes par construction
 - Attaques adverses,
 - Sensibilité aux entrées,...
- Les IA sont différentes des logiciels classiques
 - Souvent très gros et plus difficiles à vérifier

Classical software

```
#include <stdio.h>
#include <stdlib.h>
#include <sys/types.h>
#include <unistd.h>

void server(int sockfd) {
    int sockclient, sockserver, sockl, sockr;
    struct sockaddr_in maddr, addrClient, addrServer;
    socklen_t lenaddClient = sizeof(maddr);

    if ((sockclient = socket(AF_INET, SOCK_STREAM, 0)) == -1) {
        perror("error socket");
        exit(1);
    }

    if ((sockserver = socket(AF_INET, SOCK_STREAM, 0)) == -1) {
        perror("error socket");
        exit(1);
    }

    bzero(&maddr, sizeof(maddr));
    maddr.sin_family = AF_INET;
    maddr.sin_port = htons(gport, port);
    maddr.sin_addr.s_addr = INADDR_ANY;
    if (bind(sockfd, &maddr, sizeof(maddr)))
```

- Loops
- If/then/else
- Memory allocation


Idée

- Utiliser conjointement :
 - des techniques de **quantification de modèle** (en entier 8 bit par exemple),
 - des techniques **d'entraînement robuste**,
 - et de la **vérification formelle**,
- pour avoir des modèles optimisés pour l'embarqué et vérifiés robustes




Plateforme open source souveraine pour optimiser et déployer des IA sur des cibles embarquées

- Optimisation et compression des IA (**quantification PTQ** en entiers de 1 à 8 bits)
- **Edition et simplification du graphe de calcul**
- Génération de code pour différentes cibles (C, C++, NVIDIA, FPGA, ...)




Quantification

Post Training Quantification




- Normalisation des poids selon le type d'entier choisi (ici 8 bits [-128, 127])
- Deux types de quantification possibles
 - *Fake quantize* : Normalisation mais poids gardés en flottants
 - *True quantize* : Poids en entiers





Garanties formelles de la sûreté d'un réseau de neurone

- Créé en 2019, PyRAT utilise l'interprétation abstraite et le calcul matriciel pour passer à l'échelle sur des gros réseaux de neurones
- A l'état de l'art et sur le podium de la VNNCOMP depuis 2023




Propriétés vérifiées

- **Robustesse locale**


- Stabilité de classification face à des perturbation d'intensité ϵ
- Sensibilité des capteurs
- Attaques adverses

- **Sûreté globale**

- Si $X > 0$ alors la sortie devrait être Y
- Si temperature $> 18^\circ\text{C}$ alors anomalie détectée,
- ...



$$\forall x', \|x - x'\|_\infty \leq \epsilon, \arg \max N(x) = \arg \max N(x').$$



Aircraft Collision Avoidance System


$$\forall \theta \in \left[0, \frac{\pi}{2}\right], v_{int} \in [0, 10], v_{own}, \rho, \psi \Rightarrow \text{Turn left}$$

03/07/2026

Entraînement robuste


- Si un modèle n'est pas robuste
 - Inclure des méthodes formelles dès l'entraînement avec une loss basée sur l'arithmétique des intervalles

$$L_{total} = \lambda * L_{classic} + (1 - \lambda) * L_{robust}$$



Entrainement robuste dans Aidge

- Utilisation de la réécriture de graph de Aidge pour calculer des intervalles




Entrainement robuste dans Aidge

- La réécriture ajoute des intervalles de autour de chaque sortie sur le modèle

Aidge prediction = 5
Output: 8.327168
Lower bound: 6.71582
Upper bound: 10.044268


- et peut être **exportée sur différentes cibles**
- Permet d'obtenir un gradient et une loss robuste




Loss robuste



Label de sortie : 2



Après l'entraînement




$$L_{robust} = CE(Y_{robust} = [u_1, l_2, u_3])$$

Points clefs de l'entraînement robuste


- Pas de **changement d'architecture** nécessaire, contrairement à des réseaux Lipschitz par exemple
- Trade-off robustesse / précision et temps à configurer
 - Dépend du cas d'usage
 - Généralement l'entraînement est plus long
- Modèles obtenus plus robustes mais aussi plus facilement vérifiés comme robuste

Mise en commun

- Sur le dataset MNIST




Résultats



	Précision	Robustesse ($\epsilon = 4/256$)		
		Robuste	Non Robuste	Inconnu
Classique	97,4%	13,0%	23,7%	63,3%
Robuste	96,2%	92,6%	6,8%	0,6%

Résultats



	Précision	Robustesse ($\epsilon = 4/256$)		
		Robuste	Non Robuste	Inconnu
Classique	97,4%	13,0%	23,7%	63,3%
Robuste	96,2%	92,6%	6,8%	0,6%
Classique 8 bits	97,5%	0,0%	3,8%	96,2%
Robuste 8 bits	96,0%	82,9%	4,4%	12,7%

Conclusion et perspectives

- La quantification dans Aidge **préserve la robustesse** du modèle
- Aidge et PyRAT permettent d'obtenir **un modèle certifié robuste** et de petite taille ($\leq 8\text{bits}$), facile à embarquer
- **Des bornes formelles sur les sorties** peuvent être obtenues sur cible avec le modèle

Prochaines étapes :

- Application à d'autres dataset / cas d'usages
 - Modèle robuste et quantifié sur l'ACAS-Xu
 - Suite des travaux « **A study of an ACAS-Xu exact implementation using ED-324/ARP6983** »
- Approfondir le lien avec l'implémentation sur cible et la specification
 - Groupe de travail Safety ONNX

