

Calibration de modèle pour le véhicule autonome

Clara CARLIER

15 septembre 2020

Plan

- 1 Introduction**
- 2 Les données**
 - Scénario et contexte
 - Les paramètres
 - Les données réelles
 - Les données simulées
- 3 Modèle de substitution**
 - Quantités d'intérêt
 - Forêts aléatoires
 - Réseaux de neurones
- 4 Inférence des paramètres**
 - Évaluation de l'inférence
 - Méthode ABC : Monte Carlo séquentiel
- 5 Conclusion**

Introduction

Présentation du sujet

- **Expansion et évolution** du monde de l'automobile : véhicules autonomes
 - ▶ grande quantité de capteurs embarqués
- **Fiabilité et validation** des véhicules : réglementations multiples et strictes
 - ▶ réalisation d'un grand nombre de tests
- Logiciel développé par Renault pour **simuler les données** nécessaires à la validation

⇒ CRÉATION DE BASES DE DONNÉES SIMULÉES GIGANTESQUES

Encore faut-il prouver que les simulations retracent bien la réalité...

Les données

Un scénario et un contexte spécifique

- Véhicule lancé face à un obstacle à une vitesse donnée :
10, 20, 30, 40 ou 50 km/h
- Intérêt : vérifier le comportement de la voiture face à un arrêt d'urgence

Les données :

- 10 expériences **réelles** : 2 par vitesse initiale
- 500 expériences **simulées** : similaires aux réelles, 100 par vitesse initiale
- 2 **paramètres** pour chaque expérience simulée : EgoSpeed **et** Overlap
 - ▶ *inconnus pour les expériences réelles*

Paramètre EgoSpeed

Vitesse initiale de l'expérience : répartition clairement uniforme




FIGURE – Histogramme du paramètre EgoSpeed

Paramètre Overlap

Décalage de la voiture selon l'axe du milieu :




FIGURE – Présentation du paramètre latéral Overlap

Paramètre Overlap

Répartition à peu près uniforme




FIGURE – Histogrammes représentant le paramètre Overlap avant et après mapping

Données brutes

- la position (non représentée ici), la vitesse et l'accélération du véhicule
- la distance restante avec l'obstacle (Bumper Distance) et le temps avant collision (TTC)
- **Mauvaise synchronisation**, accélérations trop **bruitées** et valeurs **aberrantes** pour le TTC




FIGURE – Représentation graphique des variables d'intérêt des données réelles avant modification et synchronisation

Données finales

- Synchronisation des données selon l'accélération
- Filtrage de l'accélération avec le filtre de Butterworth¹
- Découpage du TTC² sur la zone qui nous intéresse
- Découpage de la fin des expériences




FIGURE – Représentation graphique des variables d'intérêt des données réelles après modification et synchronisation

1. utilisé par les organismes de certification
2. TTC = Bumper Distance / speed_x

Données brutes

- Courbes **non similaires** à celles des données réelles
→ conserver uniquement la fin des simulations
- La synchronisation semble correcte
- Accélération pas trop bruitée
- Valeurs aberrantes pour le TTC également




FIGURE — Représentation graphique des variables d'intérêt des données simulées avant modification et synchronisation

Données finales




FIGURE – Représentation graphique des variables d'intérêt des données simulées après modification et synchronisation

- ▶ Les courbes sont maintenant **très similaires** à celles des données réelles.

Superposition des données réelles et simulées




FIGURE – Représentation graphique des données réelles et simulées après modification et synchronisation

Modèle de substitution

Objectif

- Permet d'estimer la **vraisemblance** du modèle lors de l'étape d'inférence
 - Construire un modèle de substitution **à partir des simulations**
 - Prédire la position, la vitesse, l'accélération, la bumper distance et le ttc à partir d'EgoSpeed et d'Overlap
- Utilisation de forêts aléatoires puis de réseaux de neurones

Quantités d'intérêt

On souhaite **minimiser** :

- Erreur quadratique moyenne globale
- Erreur quadratique moyenne de la position au dernier pas de temps
- La quantité Q définie par :

$$Q = 0.5 \times \|s\|_{q_1} + \|a\|_{q_2} \quad (1)$$

avec : s le vecteur vitesse et a le vecteur accélération

$$\|x\|_{q_1} = \|x\|_1 + \|x\|_2 + 0.5 \times \|x\|_{+\infty}$$

$$\|y\|_{q_2} = \|y\|_1 + \|y\|_2 + \|y\|_{+\infty}$$

Forêts aléatoires : choix du paramètre B

- On a fait varier le **nombre d'arbres** B dans la forêt :




FIGURE – Évolution des quantités d'intérêt pour différents paramètres B

Forêts aléatoires : résultats obtenus

- ▶ Résultats obtenus pour $B = 91$:

données	RMSE position x	quantité Q	RMSE globale
<i>train</i>	0.0874	1.8151	0.0431
<i>test</i>	0.0893	3.6361	0.0903

TABLE – Quantités d'intérêts obtenues à l'aide d'une forêt aléatoire

Comparaison de deux réseaux de neurones

- ▶ Résultats obtenus avec un **premier réseau** de 300 neurones par couche :

nb. epochs	données	RMSE pos. x	Q	RMSE glob.
300	<i>train</i>	1.2274	31.5462	0.6803
	<i>test</i>	1.2394	34.3152	0.7056
400	<i>train</i>	0.7068	35.0264	0.5097
	<i>test</i>	0.7062	37.1387	0.5394

- ▶ Résultats obtenus avec un **deuxième réseau** avec 500 epochs :

nb. epochs	données	RMSE pos. x	Q	RMSE glob.
500 epochs	<i>train</i>	0.6958	14.5039	0.3796
	<i>test</i>	0.7196	14.7249	0.3981

Conclusion sur le modèle de substitution

- Résultats **peu satisfaisants** avec les réseaux de neurones
- Avec les **forêts aléatoires** : meilleures valeurs d'un facteur 10




FIGURE – Illustration des prédictions réalisées avec le modèle de forêt aléatoire

Inférence des paramètres

Objectif, mise en œuvre et prior (1/2)

- Construire un modèle à partir des **données réelles** (position, vitesse, accélération, bumper distance et ttc) afin d'inférer les paramètres EgoSpeed et Overlap qui sont **inconnus**
- Par le théorème de Bayes, pour une réalisation y , le **posterior** est donné par :

$$P(\theta|Y = y) \propto P(Y = y|\theta)P(\theta) \quad (2)$$

- $\theta = (\text{EgoSpeed}, \text{Overlap})^T$ et Y les données expérimentales
- $P(Y = y|\theta)$ la vraisemblance obtenue par le modèle de substitution
- $P(\theta)$ le prior, on prend des lois normales

- Appliquer la méthode expérience par expérience en inférant les paramètres deux à deux :
Prior : $\text{EgoSpeed} \sim \mathcal{N}(30, \sigma_{es})$ et $\text{Overlap} \sim \mathcal{N}(0, \sigma_o)$
- Appliquer la méthode de manière globale en inférant les 20 paramètres :
Prior : $\text{EgoSpeed} \sim \mathcal{N}(\{10, 20, 30, 40, 50\}, \sigma_{es})$
 $\text{Overlap} \sim \mathcal{N}(0, \sigma_o)$

Évaluation de l'inférence et valeurs naïves

- La vraie valeur des paramètres **inconnue** : comment vérifier que l'inférence est correcte ou non ?
 - ⇒ Chercher la simulation **la plus ressemblante** à chaque expérience réelle puis comparer les paramètres inférés à ceux sélectionnés
- Choix de la simulation la plus proche en **minimisant** :

$$\min_{k=1, \dots, 500} \left(\frac{1}{n} \sum_{i=1}^n \left((a_{x,k}^{simu})_i - (a_{x,I}^{real})_i \right)^2 \right)^{1/2} \quad (3)$$

- $a_{x,k}^{simu}$ vecteur correspondant à l'accélération selon le premier axe de la $k^{\text{ième}}$ expérience simulée
- de même pour $a_{x,I}^{real}$ mais de la $I^{\text{ième}}$ expérience réelle

- Avec **valeurs naïves** (10, 10, 20, 20, 30, 30, 40, 40, 50, 50) pour EgoSpeed et (0, 0, 0, 0, 0, 0, 0, 0, 0, 0) pour Overlap : **0.6116** et **0.0661**

Méthode ABC - Monte Carlo séquentiel : théorie

- ▶ **Avantage** : permet d'inférer le posterior bien que la vraisemblance soit difficile ou coûteuse à évaluer

Algorithme :

- 1 Échantillonner un paramètre θ^* selon le prior $P(\theta)$
- 2 Simuler une base de données y^* à l'aide d'une fonction qui associe à θ des données de la même dimension que les données observées y_0 (avec le modèle de substitution)
- 3 Comparer les données simulées y^* avec les données expérimentales y_0 en utilisant une distance d et un seuil de tolérance ε

- ▶ **Méthode ABC** : transforme itérativement le prior en posterior en propageant les paramètres échantillonnés à travers une série de distributions

Résultats obtenus avec le Monte Carlo séquentiel

- ▶ Résultats obtenus en inférant **expérience par expérience** :

EgoSpeed			Overlap			tps. d'exéc.
σ prior	RMSE	σ post.	σ prior	RMSE	σ post.	
0.5	14.1176	0.3446	0.03	0.0661	0.0302	37 min
0.05	14.2417	0.0499	0.01	0.0660	0.0100	29 min

- ▶ Résultats obtenus en inférant de **manière globale** :

EgoSpeed			Overlap			tps. d'exéc.
σ prior	RMSE	σ post.	σ prior	RMSE	σ post.	
0.05	0.6116	0.0499	0.05	0.0654	0.0499	3min 20sec

Conclusion

Conclusion

- Étape de **calibrage des données** : importante et longue
- Pour le modèle de substitution : très satisfaits des **forêts aléatoires**, réseaux de neurones un peu décevant mais...
- Pour l'inférence : **résultats plutôt positifs**, petit bémol sur les méthodes ABC

Perspectives et améliorations :

- Tester différents calibrages des données
- Passer plus de temps sur les réseaux de neurones pour améliorer la précision du modèle de substitution
- Inférence meilleure si le modèle de substitution est plus précis ?
- Inférence faite sans ajout d'erreur : permettrait de modéliser l'erreur du simulateur et ainsi réduire l'écart-type des posterior

Bilan : ce que j'ai fait

- Modification et synchronisation des données réelles et simulées
- Construction d'un modèle de substitution à l'aide de différentes méthodes déjà implémentées :
 - Forêts aléatoires (`scikit.learn`)
 - Réseau de neurones simple (`keras`)
 - Réseau de neurones convolutionnel un peu plus complexe (`keras`)
- Inférence des paramètres à l'aide de plusieurs méthodes déjà implémentées :
 - Étape de Metropolis-Hastings adaptatif (`PyMC3`)
 - Algorithme de Monte Carlo séquentiel (`PyMC3`)