UNIVERSITÉ DE SHERBROOKE Faculté de génie Département de génie mécanique

UTILISATION DU THÉORÈME DE BUCKINGHAM POUR LE TRANSFERT D'APPRENTISSAGE MULTISYSTÈMES: UNE ÉTUDE DE CAS AVEC TROIS VÉHICULES PARTAGEANT LA MÊME BASE DE DONNÉES

Mémoire de maitrise Spécialité : génie mécanique

William THERRIEN

Sherbrooke (Québec) Canada

Août 2023

MEMBRES DU JURY

Alexandre GIRARD Directeur

François FERLAND Évaluateur

François GRONDIN Rapporteur

RÉSUMÉ

Avec l'intérêt grandissant pour les algorithmes d'apprentissage, de nombreux efforts ont été déployés pour utiliser cette technologie pour des planificateurs et des contrôleurs de différents systèmes pour que ceux-ci puissent tirer des enseignements de leurs expériences et s'améliorer au fil du temps. Cependant, des difficultés majeures limitent le succès de ces modèles d'apprentissage lorsqu'il s'agit de contrôler des plateformes physiques réelles puisque cette méthode nécessite un nombre considérable de tests expérimentaux ou doit se baser sur des simulations à haute fidélité. Le projet de recherche dont traite ce mémoire explore le potentiel d'une architecture d'apprentissage qui exploite des nombres adimensionnels basés sur le théorème π de Buckingham afin d'accélérer et d'améliorer la précision de cet apprentissage et de faciliter le partage des connaissances entre des systèmes similaires pour pallier à ces différents problèmes.

Ce mémoire présente une étude de cas utilisant trois véhicules de tailles réduites pour comparer les résultats de modèles d'apprentissage traditionnels avec les résultats obtenus grâce à la méthode adimensionnelle proposée. Le problème étudié est la prédiction de la position et de l'orientation relative finale d'un véhicule roulant à vitesse initiale v_i après une manœuvre soudaine de changement de direction combiné au freinage sur différents types de chaussée. Cette prédiction pourrait alors être utilisée dans un pipeline de contrôle pour sélectionner la meilleure manœuvre dans une situation d'urgence. D'abord, la comparaison est faite grâce à des données recueillies à l'aide d'une simulation cinématique simplifiée. Ensuite, la méthode proposée est validée grâce à des valeurs expérimentales obtenues avec les trois plateformes robotiques étudiées. Les résultats en simulation montrent non seulement que cette nouvelle approche peut accélérer le taux d'apprentissage et améliorer la précision du modèle, mais aussi que l'apprentissage traditionnel. Les tests expérimentaux ont toutefois généré des résultats moins concluant dut à la complexité de capturer tous les phénomènes dynamiques reliés à une manœuvre d'urgence.

Mots-clés : Transfert de l'apprentissage, Apprentissage pour le contrôle de robots, Prévention de collisions

TABLE DES MATIÈRES

1 INTRODUCTION

2	L'UTILISATION DES NOMBRES ADIMENSIONNELS DANS L'AP- PRENTISSAGE ET LE PARTAGE DES CONNAISSANCES POUR				
	DE	S SYTÈMES D'ASSITANCE À LA CONDUITE	, 		
	21	Le partage de l'apprentissage	4		
	$\frac{2.1}{2.2}$	Nombres adimensionnels dans l'apprentissage et le contrôle	4		
	$\frac{2.2}{2.3}$	Modélisation de véhicules pour la simulation	5		
	2.0	2.3.1 Modèle cinématique du véhicule	5		
		2.3.2 Modélisation de la propulsion	6		
		2.3.2 Modeles de preus	7		
		2.3.4 Modèle dynamique du véhicule	9		
	2.4	Les systèmes d'assistance à la conduite (SAAC)	10		
	2.1	2.4.1 Utilisation de nombres adimensionnels dans les SAAC	12		
	CA NÉ	S AVEC 3 VÉHICULES PARTAGEANT LA MÊME BASE DE DON ES	- 14		
	3.1	Abstract	16		
	3.2	Introduction	16		
	3.3	Background	17		
	3.4	Problem definition for the case-study	18		
	3.5	Learning with simulated data	21		
		3.5.1 Simulator presentation	21		
		3.5.2 Learning model types for the simulation	22		
		3.5.3 Results	23		
	3.6	Learning with experimental data	27		
		3.6.1 Tests used for generating the data	27		
		3.6.2 Learning model types for the experimental validation	28		
	0.7	3.6.3 Results	30		
	3.1	Conclusion and outreach	31		
4	CO	NCLUSION	32		
LI	STE	DES RÉFÉRENCES	34		

1

LISTE DES FIGURES

2.1	Modèle bicyclette cinématique. [Adaptée de Liu et coll. [1]]	6
2.2	Diagramme de corps libre d'une roue propulsée du véhicule. [Illustration	-
	adaptée de Liu et coll. [1]]	6
2.3	Modélisation d'une propulsion avec moteur électrique DC	7
2.4	Illustration de la relation utilisée pour déterminer les forces longitudinales appliquées au véhicule : a) pour différentes surfaces par méthode expérimen-	
	tale; b) pour la comparaison entre les données expérimentales et le modèle	
	linéaire de pneus. [Illustration adaptée de : Tire-Road Friction-Coefficient	
	Estimation [2]]	8
2.5	Diagramme de corps libre du modèle dynamique	9
2.6	Index adimensionnel caractérisant la décélération nécessaire d'un régulateur	
	de vitesse adaptatif avec système anticollision [Tiré de [3]]	12
2.7	Choix de manoeuvres grâce à des nombres a dimensionnels [Tiré de [4]]	13
3.1	Platforms of various dimensions used for experimental validation. (1) Small	
	vehicle based on a 1:10 scale Traxxas car. (2) Long vehicle based on a 1:10	
	scale Traxxas car. (3) Large vehicle based on a 1 :5 scale Traxxas car	17
3.2	Baseline learning scheme for simulated data	22
3.3	Buckingham's π theorem based model for simulated data	23
3.4	Augmented Buckingham's π theorem based model for simulated data	23
3.5	MAE convergence according to training size for the simulated data of the	
	large vehicle	27
3.6	Baseline learning scheme for experimental data	28
3.7	Buckingham's π theorem based model for experimental data	29
3.8	Augmented Buckingham's π theorem based model for experimental data .	29
3.9	MAE convergence according to training size for the experimental data of	
	the large vehicle	31

LISTE DES TABLEAUX

2.1	Travaux de SAAC utilisant des techniques d'apprentissage. [Tableau traduit	
	de Machine Learning Techniques in ADAS : A Review [5]]	11
3.1	Variables used throughout this paper	20
3.2	Specifications of all vehicles	21
3.3	Values for the simulations for all 3 vehicles	21
3.4	MAEs for the traditional dimensionalized model (X and Y are in meters	
	and θ in rad)	24
3.5	MAEs for the Buckingham's π theorem based model (X and Y are in meters	
	and θ in rad)	25
3.6	MAEs for the Augmented Buckingham's π theorem based model (X and Y	
	are in meters and θ in rad)	25
3.7	MAEs comparison for all models trained with simulated data (X and Y are	
	in meters and θ in rad)	26
3.8	Values for the experimental tests for all 3 vehicles	28
3.9	MAE comparison for all models trained with experimental data (X and Y	
	are in meters and θ in rad)	30

CHAPITRE 1

L'approche typique pour résoudre les problèmes de contrôle de mouvement pour les véhicules autonomes et d'autres types de systèmes robotiques consiste à utiliser un modèle cinématique ou dynamique du système basé sur la physique pour planifier les trajectoires et établir des lois de rétroaction [6] [7] [8]. Avec l'intérêt grandissant pour les algorithmes d'apprentissage, de nombreux efforts ont été déployés pour utiliser cette technologie pour des planificateurs et des contrôleurs de différents systèmes pour que ceux-ci puissent tirer des enseignements de leurs expériences et s'améliorer au fil du temps [9] [10] [11]. Cependant, des difficultés majeures limitent le succès de ces modèles d'apprentissage lorsqu'il s'agit de contrôler des plateformes physiques réelles. L'un des principaux défis est la difficulté de collecter la grande quantité de données expérimentales requises pour entraîner les modèles d'apprentissage [11] [12]. Une solution populaire consiste à générer des données à l'aide de simulations à haute fidélité au lieu d'utiliser des tests expérimentaux. Néanmoins, cette approche présente également de multiples défis, tels que la difficulté de capturer certains comportements physiques dans un simulateur et de transférer les résultats dans le monde réel [13]. Le partage de l'apprentissage entre plusieurs systèmes pourrait contribuer à résoudre le problème de la collecte d'énormes quantités de données. Par exemple, une base de données centralisée pour une flotte de véhicules permettrait au véhicule nouvellement déployé d'utiliser des connaissances basées sur des milliers d'heures de données de mouvement collectées par des centaines de véhicules. Toutefois, cela est difficile à réaliser lorsque les systèmes étudiés ne partagent pas exactement les mêmes caractéristiques car leurs comportements diffèrent.

Le projet de recherche dont traite ce mémoire explore le potentiel d'une architecture d'apprentissage qui exploite des nombres adimensionnels basés sur le théorème π de Buckingham afin d'accélérer et d'améliorer la précision de cet apprentissage et de faciliter le partage des connaissances entre des systèmes similaires pour pallier à ces différents problèmes. Ce concept mène à la question de recherche suivante : est-ce que l'adimensionnalisation des entrées et des sorties d'un algorithme de régression pourrait permettre d'obtenir des résultats qui convergent plus rapidement vers les valeurs réelles et permettre de partager cet apprentissage entre divers systèmes similaires?

L'objectif principal de ce projet de recherche est de valider si un modèle d'apprentissage peut bénéficier d'une adimensionnalisation de ses entrées et ses sorties. Ces avantages pourraient prendre la forme d'une augmentation de la vitesse d'apprentissage, d'une réduction de l'erreur absolue moyenne (EAM) et de la possibilité de transférer des connaissances entre des systèmes similaires. Pour atteindre cet objectif principal, les sous-objectifs suivants sont ciblés :

- 1. Créer un modèle d'apprentissage a dimensionnel basé sur le théorème de π de Buckingham.
- 2. Comparer les résultats d'un modèle d'apprentissage traditionnel avec ceux obtenus avec la méthode proposée en simulation.
- 3. Comparer les résultats d'un modèle d'apprentissage traditionnel avec ceux obtenus avec la méthode proposée expérimentalement.

Les résultats du projet de recherche présenté dans ce mémoire démontrent la pertinence de l'utilisation de nombres adimensionnels en entrées et en sorties d'un algorithme de régression. Cette méthode permet d'obtenir des résultats supérieurs à ceux obtenus avec un modèle traditionnel. De cette contribution principale découlent les contributions secondaires suivantes :

- 1. Une nouvelle façon de décrire un système en utilisant un modèle basé sur le théorème de π de Buckingham et sur les équations physiques décrivant ce système est présentée.
- 2. Une démonstration de la façon dont ce modèle adimensionnel peut permettre de partager l'apprentissage entre différents systèmes similaires est effectuée.
- 3. Une étude de cas avec des véhicules robotisés est utilisée pour montrer, à travers des simulations et des expérimentations, que cette architecture d'apprentissage adimensionnelle est plus précise et prend moins de temps à converger que les modèles traditionnels basés sur des paramètres dimensionnalisés.

Ce mémoire présente une étude de cas utilisant trois véhicules de tailles réduites pour comparer les résultats de modèles d'apprentissage traditionnels avec les résultats obtenus grâce à la méthode adimensionnelle proposée. Le problème étudié est la prédiction de la position et de l'orientation relative finale d'un véhicule roulant à vitesse initiale v_i après une manœuvre soudaine de changement de direction combiné au freinage sur différents types de chaussée. Cette prédiction pourrait alors être utilisée dans un pipeline de contrôle pour sélectionner la meilleure manœuvre dans une situation d'urgence. D'abord, la comparaison est effectuée grâce à des données recueillies à partir d'une simulation cinématique simplifiée. Ensuite, la méthode proposée est testée à l'aide de valeurs expérimentales obtenues avec les trois plateformes robotiques étudiées. L'état de l'art est présenté au chapitre 2 de ce mémoire en passant par les travaux portant sur le partage de l'apprentissage, l'utilisation de nombres adimensionnels dans l'apprentissage et le contrôle, la simulation de véhicules et l'utilisation de l'intelligence artificielle dans les systèmes d'assistance à la conduite (SAAC). Le chapitre 3 présente l'article soumis à la revue *IEEE Robotics and Automation Letters (RA-L)* recueillant les efforts de recherche menés dans le cadre de ma maîtrise. Finalement, un retour sur la question de recherche et sur les objectifs présentés marque la conclusion de ce mémoire au chapitre 4.

CHAPITRE 2

L'UTILISATION DES NOMBRES ADIMEN-SIONNELS DANS L'APPRENTISSAGE ET LE PARTAGE DES CONNAISSANCES POUR DES SYTÈMES D'ASSITANCE À LA CONDUITE

Le projet présenté se base sur quatre aspects fondamentaux soient le partage de l'apprentissage, l'utilisation de nombres adimensionnels dans l'apprentissage et le contrôle, la simulation de véhicules et les systèmes d'assistance à la conduite (SAAC). Ce chapitre est une revue de la littérature sur ces différents sujets.

2.1 Le partage de l'apprentissage

Le projet mis de l'avant dans ce mémoire porte principalement sur le transfert de l'apprentissage multisystèmes, dont l'objectif est de partager les connaissances entre des systèmes similaires qui accomplissent la même tâche. Le transfert multitâches, concept dans lequel le système étudié demeure le même, mais l'apprentissage est partagé pour accomplir différentes tâches avec ce système, a récemment fait l'objet d'une attention particulière de la part des chercheurs [14] [15]. Les techniques utilisées présentent de nombreux points communs avec le projet présenter dans ce mémoire. En ce qui concerne spécifiquement le transfert multi-systèmes, une approche intéressante est présentée dans [16] où une base de données est partagée entre une flotte de robots. Cette approche a permis de diminuer le nombre de données nécessaires pour obtenir un modèle fonctionnel contrairement à l'approche spécifique à un robot qui utilise 4 à 20 fois plus de données.

2.2 Nombres adimensionnels dans l'apprentissage et le contrôle

L'utilisation de nombres adimensionnels dans le contrôle du mouvement est assez rare. En effet, à notre connaissance, seulement quelques recherches ont été basées sur ce concept. Dans le cas d'un système de prévention des collisions, [17] a créé des indices adimensionnels basés sur la vitesse longitudinale relative d'un véhicule, les conditions de surface de la route et l'espace latérale disponible. Ces indices ont été utilisés dans la sélection de la

manœuvre et du moment le plus adéquat pour débuter cette manoeuvre. L'utilisation de ces indices a permis d'obtenir des temps de calculs plus rapides et donc des temps réactions plus petits. Les auteurs de [18] se sont attaqués à l'un des problèmes les plus difficiles pour le contrôle des robots parallèles, à savoir leur précision. Les auteurs ont proposé une méthode améliorée d'étalonnage cinématique basée sur des matrices de mappage d'erreurs adimensionnelles (MME). Les résultats de la simulation montrent que les erreurs de positions résiduelles avec les MME adimensionnelles proposées étaient inférieures à celles des MME conventionnelles dimensionnalisées. Dans ces deux travaux, les nombres adimensionnels sont utilisés comme indices de performance et non directement dans le contrôle du véhicule comme c'est le cas dans cet article.

2.3 Modélisation de véhicules pour la simulation

Pour acquérir une grande quantité de données permettant la réalisation de modèle appris grâce à de l'apprentissage machine, il est important de créer un modèle assez précis pour représenter le comportement d'un véhicule. La modélisation d'un véhicule peut être divisée en plusieurs catégories : la modélisation cinématique, la modélisation de la propulsion, les modèles de pneus et le choix du modèle dynamique de véhicule.

2.3.1 Modèle cinématique du véhicule

Le modèle bicyclette cinématique fréquemment utilisé dans la littérature, entre autres par Liu et coll. [1], est illustré à la figure 2.1 et les équations qui en découlent se retrouvent à l'équation 2.1 sous la forme d'un modèle d'espace d'états. Comme il est possible de le voir, ce modèle bicyclette utilise l'hypothèse que l'on peut décrire le comportement du véhicule en combinant les roues avant ensemble et les roues arrières ensemble pour obtenir un véhicule avec seulement deux roues dans l'axe longitudinal du véhicule. Cette hypothèse permet de simplifier grandement le modèle qui permet de déterminer la position cartésienne X,Y et l'orientation θ en fonction de la décélération longitudinale a, la vitesse longitudinale v, la longueur du véhicule l et l'angle de la direction δ .



FIGURE 2.1 Modèle bicyclette cinématique. [Adaptée de Liu et coll. [1]]

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\theta} \\ \dot{v} \end{bmatrix} = \begin{bmatrix} v\cos(\theta) \\ v\sin(\theta) \\ \frac{v\tan(\delta)}{l} \\ a \end{bmatrix}$$
(2.1)

2.3.2 Modélisation de la propulsion

Tout d'abord, Liu et coll. [1] proposent de développer la dynamique des roues propulsées du véhicule. La figure 2.2 illustre le diagramme de corps libre d'une de ces roues et l'équation 2.2 représente la relation dynamique reliée à la rotation de ces roues.



FIGURE 2.2 Diagramme de corps libre d'une roue propulsée du véhicule. [Illustration adaptée de Liu et coll. [1]]

$$\dot{\omega} = \frac{\tau(V,\omega) - F_x r - \operatorname{sgn}(\omega)\tau_b}{J}$$
(2.2)

La variation de la vitesse angulaire des roues ω peut donc être obtenue en divisant la somme des couples appliqués sur la roue par l'inertie de la roue J. Les différents couples en jeu sont le couple du moteur $\tau(V, \omega)$ qui dépend de la tension aux bornes du moteur V et de la vitesse angulaire des roues ω pour un moteur électrique DC, le couple de propulsion qui s'obtient en multipliant la force de propulsion F_x par le rayon de la roue r et le couple de friction τ_b qui est considéré constant dans le sens inverse à la vitesse angulaire des roues ω comme le montre l'équation 2.2. La représentation schéma-bloc de ce modèle est illustrée à la figure 2.3.



FIGURE 2.3 Modélisation d'une propulsion avec moteur électrique DC.

2.3.3 Modèles de pneus

Pour déterminer les forces de propulsion longitudinales F_{xf} et F_{xr} , il est nécessaire de calculer les coefficients de rapport de glissement S_x . Ce ratio compare la vitesse longitudinale du véhicule V_x avec la vitesse de rotation des roues du véhicule ω pour quantifier l'adhérence des roues sur la chaussée. Il s'agit d'une pratique courante dans la littérature [1]. L'équation 2.3 montre cette relation.

$$S_x = \frac{\omega r - V_x}{\max(|\omega r, V_x|)} \tag{2.3}$$

Rajamani et coll. [2] proposent ensuite de trouver expérimentalement la relation entre la force normalisée ρ et le rapport de glissement S_x . Des données obtenues grâce à un accéléromètre, un GPS et l'odométrie du véhicule ont permis de recueillir l'accélération a_x , la vitesse longitudinale V_x et la vitesse des roues propulsées du véhicule ω . Connaissant la masse m du véhicule et la force normale F_z à chaque roue, il a été possible de calculer la force normalisée ρ comme le montre l'équation 2.4. La figure 2.4 a) illustre la relation entre le rapport de glissement S_x et la force normalisée ρ obtenus expérimentalement pour différentes chaussées.

$$\rho_i = \frac{ma_i}{F_z} \qquad \forall \ i \in \{x, y\}$$
(2.4)

Il est ensuite possible de modéliser très précisément ce comportement entre la chaussée et les pneus en utilisant la *Magic Formula* de Pacejka [19] ou le modèle de Dugoff [20] couramment utilisés dans la littérature. Toutefois, ces deux modèles demandent une connaissance exhaustive des propriétés du pneu qui peut compliquer grandement la création de tels modèles. Kissai et coll. [21] proposent un modèle simplifié linéaire à trois sections tel qu'illustré à la figure 2.4 b).



FIGURE 2.4 Illustration de la relation utilisée pour déterminer les forces longitudinales appliquées au véhicule : a) pour différentes surfaces par méthode expérimentale ; b) pour la comparaison entre les données expérimentales et le modèle linéaire de pneus. [Illustration adaptée de : Tire-Road Friction-Coefficient Estimation [2]].

Les angles de glissement avant et arrière α_f et α_r peuvent être calculés grâce aux équations 2.5 et 2.6. Ces angles de glissement représentent l'angle entre le vecteur de vitesse de la roue à l'étude et le vecteur de vitesse longitudinale V_x du véhicule. Ces valeurs permettent de quantifier l'adhérence latérale du véhicule. Les forces latérales normalisées ρ_y peuvent ensuite être calculées grâce à l'équation 2.4 et un modèle de pneu similaire à la figure 2.4 peut être construit par rapport aux angles de glissement α_f et α_r à la place du rapport de glissement S_x .

$$\alpha_f = \arctan(\frac{V_y + a\dot{\theta}}{V_x}) - \delta \tag{2.5}$$

$$\alpha_r = \arctan(\frac{V_y - b\dot{\theta}}{V_x}) \tag{2.6}$$

2.3.4 Modèle dynamique du véhicule

Un modèle dynamique a été développé à partir du modèle bicyclette utilisé fréquemment dans la littérature. Ce modèle est basé sur les travaux de Liu et coll. [1]. La représentation schématique de ce modèle est affichée à la figure 2.5.



FIGURE 2.5 Diagramme de corps libre du modèle dynamique.

Les équations non-linéaires décrivant ce système ont été développées sous la forme $\underline{\dot{x}} = f(\underline{x}, \underline{u})$ tel qu'affiché à la l'équation 2.7. Les entrées u du système sont la tension aux bornes du moteur électrique de la propulsion V et l'angle de la direction δ .

$$\begin{bmatrix} \dot{V}_{x} \\ \dot{V}_{y} \\ \ddot{\theta} \\ \dot{\theta} \\ \dot{\theta} \\ \dot{X} \\ \dot{Y} \\ \dot{\omega} \end{bmatrix} = \begin{bmatrix} \frac{F_{xf}cos\delta - F_{yf}sin\delta + F_{xr}}{m} + V_{y}\dot{\theta} \\ \frac{F_{yf}cos\delta + F_{xf}sin\delta + F_{yr}}{m} - V_{x}\dot{\theta} \\ \frac{F_{yf}cos\delta + F_{xf}sin\delta + F_{yr}}{m} - V_{x}\dot{\theta} \\ a\frac{(F_{yf}cos\delta + F_{xf}sin\delta + F_{xr}) - b(F_{yr})}{I_{vehi}} \\ \dot{\theta} \\ V_{x}cos\theta - V_{y}sin\theta \\ V_{x}sin\theta + V_{y}cos\theta \\ \frac{(V - \omega kN)kN}{R} - F_{xr}r}{J} \end{bmatrix}$$
(2.7)

2.4 Les systèmes d'assistance à la conduite (SAAC)

Les SAAC couramment retrouvés dans la littérature peuvent être divisés en quatre catégories : le contrôle longitudinal, le contrôle latéral, le suivi de l'attitude du conducteur et l'aide au stationnement.

De nos jours, il n'est pas rare que des véhicules soient équipés de régulateur de vitesse adaptatif [3] et de système de freinage d'urgence [22]. Ces deux systèmes sont reliés au contrôle longitudinal. Deux exemples de SAAC ayant un contrôle latéral sont l'assistance au changement de voie [23] et le suivi d'une voie sur autoroute [24]. Plusieurs travaux ont été menés sur l'attitude du conducteur. Pohl et coll. [25] proposent de suivre en temps réel le visage d'un conducteur et de sa tendance de conduite pour déterminer son niveau de distraction et entreprendre des manoeuvres pour un suivi de trajectoire. Finalement, le SAAC le plus mature dans la littérature est forcement l'assistance au stationnement [26].

L'apprentissage machine a permis dans les plus récentes années d'améliorer la performance de certains de ces SAAC, voir même d'en créer de nouveaux. L'apprentissage machine au coeur même de la recherche dans le domaine automobile peut être attaqué sous trois angles différents : l'apprentissage supervisé, l'apprentissage non supervisé et l'apprentissage par renforcement.

Moujahid et coll. [5] proposent un intéressant survol de différents types de SAAC utilisant des concepts touchants à plusieurs sphères de l'apprentissage machine. Le tableau 2.1 liste certains de ces SAAC. Il est important de noter que toutes les méthodes utilisées ci-bas utilisent un véhicule ayant des paramètres physiques particuliers dans des environnements complexes et que les apprentissages faits grâce à ces algorithmes sont directement dépendants de ces paramètres. Les modèles qui en découlent sont donc difficilement généralisables et tendent à être beaucoup moins performants lorsqu'utilisés sur d'autres véhicules ou dans des environnements relativement différents. TABLEAU 2.1Travaux de SAAC utilisant des techniques d'apprentissage.[Ta-bleau traduit de Machine Learning Techniques in ADAS : A Review [5]]

Type de Machine Learning	Travaux	Ce qui a été fait	Résultats
Supervised Learning	"Using Machine Learning to Predict the Driving Context whilst Driving" [27]	Modélisation du contexte de conduite et des distractions du conducteur. Cinq volontaires ont conduit sur une distance de 6.5 km sur une route de deux voies. Les données ont été collectées grâce à des capteurs de téléphone cellulaire standard.	Modélisation du contexte de conduite précis à 95.16%.
	"Learning-Based Driving Events Recognition and Its Application to Digital Roads" [28]	Reconnaissance de différentes situations de conduite. Les données ont été acquises grâce aux capteurs de bases d'un camion Volvo via CAN et d'un GPS. Une phase d'apprentissage a permis d'établir un arbre de décision permettant de caractériser une situation de conduite.	80-90% des situations de conduites ont été caractérisées adéquatement.
Reinforce- ment Learning	"A decision-making method for autonomous vehicles based on simulation and reinforcement learning" [29]	Création d'un algorithme de prise de décision pour des scénarios de conduite sur autoroute. Un modèle dynamique de véhicule à 14 ddls a été créé. Les sorties du modèle ont été utilisées pour créer le MDP qui a été résolu par LSPI.	Le modèle de prise de décision développé a été capable de déterminer la fonction de coût du MDP.
Unsupervised Learning	"Applying Machine Learning Techniques to Transportation Mode Recognition Using Mobile Phone Sensor Data" [30]	Reconnaissance de différents modes de transport : automobile, bicyclette, piéton, autobus, etc. Environ 300 heures de vidéo ont été accumulées. L'objectif des tests était de comparer les résultats de l'apprentissage supervisé versus ceux de l'apprentissage non-supervisé.	L'apprentissage non-supervisé a permis de passer de 165 critères pour l'apprentissage supervisé à 80.
	"Driver Modeling Based on Driving Behavior and Its Evaluation in Driver Identification" [31]	Création de deux modèles : un pour la vitesse optimale et l'autre pour la relation entre l'accélérateur et le frein. Des données ont été recueillies sur 20 conducteurs suivant un véhicule sans jamais le dépasser pendant 20 minutes. Les modèles ont été créés grâce à un GMM.	89.6% de compatibilité entre le comportement des modèles et l'attitude d'un conducteur en simulation et 76.8% pour les tests sur la route avec 276 conducteurs.

2.4.1 Utilisation de nombres adimensionnels dans les SAAC

L'adimensionnalisation des équations décrivant le comportement d'un véhicule et de ce dernier avec l'environnement pourrait permettre de diminuer considérablement le nombre d'entrées d'un modèle devant être appris grâce à de l'apprentissage machine tout en réduisant la complexité de la manipulation de ces équations. De plus, un modèle appris grâce à des indices adimensionnels pourrait permettre de partager plus facilement l'apprentissage acquis entre différents véhicules par cette nature adimensionnelle.

La caractérisation d'une scène d'urgence liée à une collision potentielle grâce à des nombres adimensionnels a été ciblée à quelques reprises dans la littérature. Les travaux de Moon et coll. [3] visaient a créer un régulateur de vitesse adaptatif (ACC) avec un système anticollision (CA) se basant sur un index d'avertissement adimensionnel et des valeurs temps avant collision (TTC). Cet index était calculé grâce à l'équation 2.8.

$$INDEX = \frac{d - d_{br}}{d_w - d_{br}} \tag{2.8}$$

Où d est la distance entre le véhicule et l'obstacle directement mesurée, d_{br} est la distance critique de frein lorsque la force de freinage maximale et d_w est la distance critique d'avertissement. Plus l'index est grand, moins la situation est critique. La figure 2.6 illustre la relation entre l'index adimensionnel et la décélération nécessaire pour éviter une collision. Ici, l'utilisation d'un index adimensionnel n'a servi qu'à alléger le fardeau de l'utilisation de nombreuses équations dynamiques pour déterminer la force de freinage reliée à la décélération nécessaire propre à l'index adimensionnel.



FIGURE 2.6 Index adimensionnel caractérisant la décélération nécessaire d'un régulateur de vitesse adaptatif avec système anticollision [Tiré de [3]].

Singh et coll. [4] ont aussi utilisé le concept d'adimensionalisation pour leur contrôle optimal par retour d'états dans une situation d'évitement d'obstacle. En faisant l'hypothèse que le véhicule peut être représenté par une masse ponctuelle et que les forces appliquées sur le véhicule sont constantes pendant la manoeuvre, ils ont créé cinq variables adimensionnelles grâce au théorème de π basé sur des équations dynamiques simples. En utilisant la méthode de bissection et les variables adimensionnelles déterminées, ils ont été capables de déterminer la manoeuvre optimale par retour d'états. La figure 2.7 illustre leurs résultats. La raison principale de l'utilisation de nombres adimensionnels est la simplification des manipulations mathématiques. Cependant, aucun test expérimental n'a été mené dans cette voie.



FIGURE 2.7 Choix de manoeuvres grâce à des nombres adimensionnels [Tiré de [4]].

CHAPITRE 3

UTILISATION DU THÉORÈME DE BUCKIN-GHAM POUR LE TRANSFERT D'APPREN-TISSAGE MULTISYSTÈMES : UNE ÉTUDE DE CAS AVEC 3 VÉHICULES PARTAGEANT LA MÊME BASE DE DONNÉES

Avant-propos

Auteurs et affiliations :

William Therrien : auteur principal, étudiant à la maîtrise, Université de Sherbrooke, Faculté de génie, Département de génie mécanique.

Alexandre Girard : coauteur, professeur, Université de Sherbrooke, Faculté de génie, Département de génie mécanique.

Olivier Lecompte : coauteur, étudiant au doctorat, Polytechnique Montréal, Faculté de génie, Département de génie mécanique.

Date de soumission : 16 juillet 2023

Revue : IEEE Robotics and Automation Letters (RA-L)

- **Titre anglais :** Using Buckingham's π Theorem for Multi-System Learning Transfer : a Case-study with 3 Vehicles Sharing a Data-base
- **Titre en français :** Utilisation du théorème de Buckingham pour le transfert d'apprentissage multisystèmes : une étude de cas avec 3 véhicules partageant la même base de données.
- Contribution au document : Cet article est la principale contribution de ce mémoire. Une preuve de concept utilisant trois plateformes robotiques de véhicules à échelles réduites pour répondre aux objectifs présentés à la section 1 y est présentée. D'abord, une revue de la littérature pour des travaux similaires est discutée. Ensuite, la présentation de l'étude de cas et des différentes hypothèses est amenée. Finale-

ment, la comparaison entre un modèle d'apprentissage traditionnel et la méthode adimensionnelle proposée est évaluée en simulation et expérimentalement.

Résumé français : Les performances de modèles d'apprentissage pour la planification et le contrôle sont limitées par la difficulté de collecter de grandes quantités de données expérimentales ou de s'appuyer sur des simulations de haute fidélité. Cet article explore le potentiel d'une architecture d'apprentissage qui exploite des nombres adimensionnels basés sur le théorème π de Buckingham afin d'accélérer et d'améliorer la précision de cet apprentissage et de faciliter le partage des connaissances entre des systèmes similaires. Une étude de cas utilisant trois véhicules de tailles réduites compare les résultats de modèles d'apprentissage traditionnels avec les résultats obtenus grâce à la méthode adimensionnelle proposée sur des données simulées et expérimentales. Les résultats montrent que cette nouvelle approche peut accélérer le taux d'apprentissage et améliorer la précision du modèle.

Using Buckingham's π Theorem for Multi-System Learning Transfer : a Case-study with 3 Vehicles Sharing a Data-base

3.1 Abstract

Learning schemes for planning and control are limited by the difficulty of collecting large amounts of experimental data or having to rely on high-fidelity simulations. This paper explores the potential of a proposed learning scheme that leverages dimensionless numbers based on Buckingham's π theorem to improve data efficiency and facilitate knowledge sharing between similar systems. A case study using car-like robots compares traditional and dimensionless learning models on simulated and experimental data to validate the benefits of the new dimensionless learning approach. Results show that this new approach could accelerate the learning rate and improve the accuracy of the model.

3.2 Introduction

The typical approach to solving motion control problems for autonomous vehicles and other types of robotic systems is to use a physics-based kinematic or dynamic model of the system to plan trajectories and establish feedback laws [6] [7] [8]. With the rise of efficient machine learning algorithms, much effort has gone into using learning in planners and controllers so that autonomous vehicles can learn from experience and improve over time [9] [10] [11]. However, major difficulties limit the success of the learning scheme when it comes to controlling real physical platforms.

One of the major challenges is the difficulty of collecting the large amount of experimental data required for advanced learning schemes such as deep-learning [11] [12]. A popular solution is to generate data using high-fidelity simulations instead of experiments. This approach also has multiple challenges, such as the difficulty of capturing certain behaviors in a simulator and transferring the results to the real world [13]. Data efficiency is a critical bottleneck.

Sharing learned data and policies across multiple systems could help solve the problem of collecting huge amounts of data. For example, instead of learning from scratch, a centralized database for a fleet of vehicles would enable the newly deployed vehicle to use knowledge based on thousands of hours of motion data collected by hundreds of vehicles. However, this is difficult to achieve when the studied systems do not share identical characteristics as their behavior, and therefore the appropriate control policy, differs. This paper investigates the potential of leveraging dimensionless number and the Buckingham's π theorem to improve generalization. Section 3.3 presents some related work and discusses the original contribution of this paper. Section 3.4 defines the problem used as the case study in this paper. Section 3.5 presents the learning results based on simulated data and section 3.6 presents the learning results based on an experimental validation with three small scale vehicles shown at Fig. 3.1 .



FIGURE 3.1 Platforms of various dimensions used for experimental validation. (1) Small vehicle based on a 1 :10 scale Traxxas car. (2) Long vehicle based on a 1 :10 scale Traxxas car. (3) Large vehicle based on a 1 :5 scale Traxxas car.

3.3 Background

This paper focuses on multi-system transfer where the objective is to share knowledge between similar systems that accomplish the same task. Multi-task transfer, which received significant research attention recently [14] [15], has a lot in common with multi-system transfer. In fact, in both cases, the task and the system, are learned through the same policy.

Specifically for multi-system transfer, an interesting approach is presented in [16] where a shared database can outperform a robot-specific training approach that uses 4 to 20 times more data. In [32], the authors address the problem of inappropriate transfer, which can result in a decrease in performance. By assessing how similar two systems are, it is possible to know with which systems the transfer learning would be most beneficial. The authors in [33] rather tackle the problem directly by guiding the policies network with a representation vector built from information regarding the hardware. This approach is similar to the one presented in this work, but instead of two vectors, one containing the states and the other containing the characteristics of the hardware, a single vector is built based on these features with the intention of reducing the dimensions of the system to zero by using the Buckingham's π theorem. To our knowledge, only a few researches are based on dimensionless numbers in the context of motion control. In the case of an in-lane collision avoidance system, [17] created nondimensionalized indices, based on a vehicle's relative longitudinal velocity, road surface conditions and terminal lateral distance, which were used in the selection of the most efficient maneuver and timing for an intervention. The use of these indices was shown to be computationally efficient. [18] tackled one of the most challenging issues for parallel robots control which is their accuracy. The authors proposed an improved method for kinematic calibration based on dimensionless error mapping matrixes (EMMs). Simulation results show that the residual pose errors with the proposed dimensionless EMMs were lower than with the conventional EMM in various units. In both of these works, the dimensionless numbers are used as indices of performance and not directly in the control of the vehicle as is the case in this article.

This work differs from the presented references in three ways : 1) a new way to describe a system using an Augmented Buckingham's π theorem based model is presented; 2) a demonstration of how that dimensionless model can be a way to generalize learning in the context of motion control by being able to share knowledge with different systems is made; 3) a case study with robotic vehicles is used to show through simulation and experimentations that this dimensionless learning scheme is more accurate and less time consuming than traditional parameters driven models.

3.4 Problem definition for the case-study

The main goal of this paper is to validate whether a learning scheme can benefit from a dimensionless mapping of its inputs and outputs. These benefits could take the form of an increase in learning speed, a reduction in mean absolute error (MAE) and the possibility of sharing knowledge between similar systems. To do so, different extreme gradient boosting (XGBoost [34]) models have been trained with simulated and experimental data and compared using their respective MAE. Two dimensionless learning schemes have been created and compared with a baseline traditional dimensionalized model. The first one is based on Buckingham's π theorem. The second, called the *Augmented Buckingham's* π theorem based model, is also based on that same theorem but with other dimensionless inputs created arbitrarily with the knowledge of the system's physics.

Inspired by the challenges of learning good control policies for emergency braking maneuvers on various ground conditions (snow, ice, etc.) [35], the problem for this case-study is the prediction of the final relative position of a vehicle traveling at initial speed v_i after a sudden braking and steering maneuver. That outcome could then be used in a control

pipeline to select the best maneuver in an emergency braking situation. To simplify the simulations, only the kinematics are studied and a few assumptions are made. Firstly, the control inputs are constant throughout a maneuver, i.e. the steering angle δ and braking action (constant deceleration rate *a* imposed on both rear wheels) are decided once at the start of the maneuver and remain constant until the vehicle comes to a complete stop. Also, only the final position of the vehicle is predicted. Furthermore, the environment is always a horizontal surface and only 2D planar motion is taken into account. For the experimental data, the same scenario is studied except that we take into account the dynamics of the system. We assume that we can neglect any roll or pitch effects. Finally, the complex soil-tire relationship for the experimental data is simplified to the coefficient of friction μ . Table 3.1 shows the main variables involved in this case study.

Variables	Descriptions	Units [Dimensions]		
	State variables			
X	Position of the vehicle in X-axis of world frame	m [L]		
Y	Position of the vehicle in Y-axis of world frame	m [L]		
θ	Yaw of the vehicle in world frame	rad		
	Environment related variables			
μ	Friction coefficient wheels/road	-		
v	Longitudinal velocity of the vehicle	$m/s \ [LT^{-1}]$		
<i>g</i>	Gravitational acceleration	$m/s^2 \ [LT^{-2}]$		
	maneuvers related variables			
a	Deceleration of the wheel	$m/s^2 \ [LT^{-2}]$		
δ	Steering angle of front wheels	rad		
Vehicles related variables				
N_f	Normal force on front wheels	N $[MLT^{-2}]$		
N_r	Normal force on rear wheels	N $[MLT^{-2}]$		
l	Length between vehicle's axles	m [L]		

TABLEAU 3.1	Variables used	l throughout this	paper
-------------	----------------	-------------------	-------

Three small-scale car-like vehicles of various dimensions are used for both validation processes (simulation and experimentation). Vehicle 1, shown in figure 3.11, is a modified 1/10 scale platform based on a Traxxas SLASH. The vehicle 2, shown in figure 3.12, is also a modified 1/10 scale platform based on a Traxxas SLASH with the chassis modified to have a longer wheelbase. Finally, vehicle 3, shown in figure 3.13, is a modified 1/5 scale platform based on a Traxxas X-MAXX. From now on, they will be referred to as *small vehicle*, *long vehicle* and *large vehicle* respectively. Their specifications are summarized in table 3.2. Since the simulation only takes kinematics into account, only the wheelbase length l of these vehicles is used to describe them in that particular section.

Vehicle	<i>l</i> (m)	N_f (N)	N_r (N)
Small	0.345	37.77	28.84
Long	0.853	22.74	52.89
Large	0.475	71.12	71.12

 TABLEAU 3.2
 Specifications of all vehicles

3.5 Learning with simulated data

3.5.1 Simulator presentation

This section presents an analysis in which the proposed learning approach is evaluated using data generated in a simplified simulated environment. The simulation was based on the kinematic bicycle model frequently used in the literature. The non-linear equations for the bicycle model are shown at 3.1.

$$\begin{bmatrix} \dot{X} \\ \dot{Y} \\ \dot{\theta} \\ \dot{v} \end{bmatrix} = \begin{bmatrix} v\cos(\theta) \\ v\sin(\theta) \\ \frac{v\tan(\delta)}{l} \\ a \end{bmatrix}$$
(3.1)

For all three vehicles presented at figure 3.1, 5 500 simulations were conducted with the initial values and maneuvers shown at table 3.3

$v_i \ ({ m m/s})$	$a \ ({ m m/s^2})$	δ (rad)
From 0.1	From -0.1 g	From 0.0000
to 5.0	to -1.0 g $$	to 0.7854
by 0.1	by -0.1 g $$	by 0.0785
50 values	10 values	11 values

TABLEAU 3.3 Values for the simulations for all 3 vehicles

All simulations start with the vehicle at position [X, Y] = (0,0), orientation $\theta = 0$ rad and initial speed v_i . The maneuver starts right away with deceleration a and steering angle δ . The simulation stops when the vehicle reach zero velocity and the final position and orientation are noted.

3.5.2 Learning model types for the simulation

Traditional dimensionalized learning model

The nonlinear equations describing the kinematic bicycle model used for the simulation presented at 3.1 can be written in the form of 3.2.

$$\left[X, Y, \theta\right] = f(v_i, a, \delta, l) \tag{3.2}$$

Thus, the dimensionalized parameters for the initial velocity v_i , the deceleration a, the steering angle δ and the length of the wheelbase l are used as inputs to the XGBoost algorithm to predict the final pose $[X, Y, \theta]$ of the vehicle. This traditional dimensionalized learning scheme is illustrated at figure 3.2



FIGURE 3.2 Baseline learning scheme for simulated data

Buckingham's π theorem based model

According to Buckingham's π theorem, with N dimensionalized variables and P independent dimensions, we obtain m = N - P dimensionless numbers. Here, N = 7 [X, Y, θ , v_i , a, δ , l] and P = 2 [L,T]. We thus have five dimensionless numbers. By using the distance between the two axles l [M] and the initial velocity of the vehicle v_i [MT⁻¹] as repeated variables, we can create the five dimensionless numbers. The inputs and ouputs of the XGBoost algorithm used to predict the outcome of a maneuver are shown on figure 3.3.



FIGURE 3.3 Buckingham's π theorem based model for simulated data

Augmented Buckingham's π theorem based model

Based on the mathematical shape of the nonlinear equation for $\dot{\theta}$ presented at equation 3.1, we obtain the arbitrary dimensionless number π_6 derived at 3.3. The inputs and ouputs of the Augmented Buckingham's π theorem based model used to predict the outcome of a maneuver are shown on figure 3.4.

$$\dot{\theta} = \frac{vtan(\delta)}{l}; \quad \pi_6 = \frac{v^2 tan(\delta)}{al}$$
(3.3)



FIGURE 3.4 Augmented Buckingham's π theorem based model for simulated data

3.5.3 Results

The results for the three model types will be examined from two perspectives. On the one hand, we will study the MAEs of self-predictions, cross-predictions and shared-predictions for each model type. On the other hand, we will examine the effect of the size of the training set on the convergence of the MAEs for self-predictions, or the so-called the learning rate of the models.

Mean absolute error

The MAE is one of the most widely used metrics for regression algorithms since it has the same units as the model's dependent variables which makes the results easier to understand. Equation 3.4 shows how MAE is calculated, where N is the number of tests used, y_i are the actual result values and \hat{y}_i are the predicted values. Since the output values for both dimensionless models are $\pi_1 = \frac{X}{l}$, $\pi_2 = \frac{Y}{l}$ and $\pi_3 = \theta$, π_1 and π_2 are multiplied by the wheelbase l of the tested vehicle before computing the MAE so that all results share the same units.

$$MAE = \frac{1}{N} \sum_{i=1}^{N} |(y_i - \hat{y}_i)|$$
(3.4)

80% of the simulated data were used to train a model of each type for the three vehicles. The remaining 20% is used to test the models. Table 3.4 contains the results of the traditional dimensionalized model, the results of the model based on Buckingham's π theorem are presented in table 3.5 and table 3.6 shows the results of the Augmented Buckingham model. For all three tables, the light gray cells correspond to the results of what we call self-predictions, i.e. predictions that use a vehicle's test set in its own trained model. The white cells correspond to the results of a vehicle's test set in another vehicle's trained model, known as cross-predictions. Finally, the dark gray cells are the results of shared predictions. For shared predictions, the test set of a particular vehicle is ran in a model that has been trained with data from all three vehicles.

Models	Data Vehicle 1	Data Vehicle 2	Data Vehicle 3
	(Small)	(Long)	(Large)
Model	X: 0.0494	X : 0.3703	X : 0.1601
Vehicle 1	Y: 0.0466	Y: 0.3071	Y: 0.1459
(Small)	$\theta: 0.0587$	θ : 0.9851	$\theta: 0.4502$
Model	X : 0.3653	X : 0.0316	X : 0.2622
Vehicle 2	Y : 0.3032	Y : 0.0257	Y : 0.2061
(Long)	heta : 0.9919	θ : 0.0238	heta : 0.5369
Model	X : 0.1667	X : 0.2679	X : 0.0414
Vehicle 3	Y: 0.1440	Y : 0.2125	Y : 0.0362
(Large)	θ : 0.4599	θ : 0.5324	θ : 0.0422
Model	X: 0.0467	X : 0.0433	X: 0.0514
MERGED	Y: 0.0465	Y: 0.0368	Y : 0.0498
(All 3)	$\theta: 0.0457$	$\theta: 0.0302$	θ : 0.0431

TABLEAU 3.4 MAEs for the traditional dimensionalized model (X and Y are in meters and θ in rad)

Models	Data Vehicle 1	Data Vehicle 2	Data Vehicle 3
	(Small)	(Long)	(Large)
Model	X : 0.0204	X : 0.0144	X : 0.0125
Vehicle 1	Y : 0.0261	Y : 0.0102	Y : 0.0099
(Small)	θ : 0.0331	θ : 0.0109	heta: 0.0159
Model	X : 0.0354	X: 0.0145	X : 0.0303
Vehicle 2	Y : 0.0394	Y : 0.0176	Y : 0.0262
(Long)	heta : 0.2007	heta : 0.0127	$\theta: 0.0917$
Model	X : 0.0153	X : 0.0103	X : 0.0190
Vehicle 3	Y : 0.0162	Y : 0.0095	Y : 0.0182
(Large)	θ : 0.0666	heta : 0.0097	$\theta: 0.0241$
Model	X : 0.0080	X: 0.0087	X : 0.0083
MERGED	Y : 0.0086	Y: 0.0087	Y : 0.0083
(All 3)	$\theta: 0.0143$	θ : 0.0080	$\theta: 0.0115$

TABLEAU 3.5 MAEs for the Buckingham's π theorem based model (X and Y are in meters and θ in rad)

TABLEAU 3.6 MAEs for the Augmented Buckingham's π theorem based model (X and Y are in meters and θ in rad)

Models	Data Vehicle 1	Data Vehicle 2	Data Vehicle 3
	(Small)	(Long)	(Large)
Model	X : 0.0126	X : 0.0117	X : 0.0104
Vehicle 1	Y : 0.0121	Y: 0.0090	Y : 0.0077
(Small)	θ : 0.0131	θ : 0.0043	θ : 0.0063
Model	X : 0.0271	X : 0.0103	X: 0.0219
Vehicle 2	Y: 0.0286	Y: 0.0134	Y : 0.0222
(Long)	$\theta: 0.1407$	θ : 0.0052	θ : 0.0591
Model	X : 0.0130	X : 0.0090	X : 0.0117
Vehicle 3	Y : 0.0133	Y: 0.0091	Y : 0.0129
(Large)	θ : 0.0389	θ : 0.0038	θ : 0.0098
Model	X: 0.0045	X: 0.0055	X: 0.0046
MERGED	Y : 0.0050	Y : 0.0061	Y: 0.0051
(All 3)	θ : 0.0060	$\theta: 0.0028$	θ : 0.0035

Table 3.7 summarizes the three previous tables (3.4, 3.5 and 3.6). For self-predictions, we can see that the Buckingham's π theorem based model and the Augmented Buckingham model are respectively 1.93 times and 3.60 times more precise than the traditional model. These numbers climb to 11.76 times and 15.80 times for cross-predictions. Finally, the Buckingham's π theorem based model and the Augmented Buckingham model are respectively 4.80 times and 9.17 times more precise than the traditional model in shared-predictions.

Prediction	Traditional	Buckingham's	Augmented
types	dimensionalized	$\pi {f theorem}$	Buckingham's
	model	based model	$\pi \operatorname{\mathbf{model}}$
SELF	X : 0.0408	X : 0.0180	X: 0.0115
Predictions	Y : 0.0362	Y : 0.0206	Y: 0.0128
	θ : 0.0416	θ : 0.0233	θ : 0.0094
CROSS	X: 0.2654	X : 0.0197	X : 0.0155
Predictions	Y : 0.2198	Y : 0.0186	Y : 0.0128
	θ : 0.6594	$\theta: 0.0659$	θ : 0.0422
SHARED	X: 0.0471	X : 0.0083	X: 0.0049
Predictions	Y: 0.0444	Y: 0.0085	Y: 0.0054
	$\theta: 0.0397$	θ : 0.0113	$\theta: 0.0041$

TABLEAU 3.7 MAEs comparison for all models trained with simulated data (X and Y are in meters and θ in rad)

Learning rate

The amount of data required to obtain an operational predictive function for self-predictions for all model types is then investigated. Figure 3.5 shows the MAE convergence for the final longitudinal position X, final lateral position Y and final yaw θ of the three model types with the large vehicle's self-predictions. For all outputs, the Augmented Buckingham model converges the fastest, followed by the Buckingham's π theorem based model. More data would be required to achieve full convergence of the final X and Y positions for the traditional dimensionalized model. Only the data for the large vehicle is presented to avoid any redundancy since all curves were alike.



FIGURE 3.5 MAE convergence according to training size for the simulated data of the large vehicle

3.6 Learning with experimental data

3.6.1 Tests used for generating the data

For all three vehicles, 540 experimental tests were carried out with the initial values and maneuvers shown in table 3.8. All tests start with the vehicle in position (0,0), orientation 0 rad, initial speed v_i and ground/tire friction coefficient μ . The maneuver begins immediately with deceleration a and steering angle δ . The test stops when the vehicle has come to a complete stop, and the final position and orientation are recorded using a VICON triangulation camera system.

μ	$v_i \ ({ m m/s})$	ag (9.81 m/s ²)	δ (rad)
0.2	From 1.0	From 0.1	0.0000
0.4	to 3.5	to 1.0	0.3927
0.9	by 0.5	by 0.1	0.7854
3 values	6 values	10 values	3 values

TABLEAU 3.8 Values for the experimental tests for all 3 vehicles

3.6.2 Learning model types for the experimental validation Traditional dimensionnalized learning model

With the assumptions made in section 3.4 and based on table 3.1, the equation 3.5 can be written for the experimental end position $[X, Y, \theta]$. The baseline learning scheme for the experimental validation is illustrated at figure 3.6.

$$\left[X, Y, \theta\right] = f(\mu, v_i, g, a, \delta, N_f, N_r, l)$$
(3.5)



FIGURE 3.6 Baseline learning scheme for experimental data

Buckingham π theorem based model

According to Buckingham π theorem, $N = 11 [\mu, v_i, g, a, \delta, N_f, N_r, l, X, Y, \theta]$ and P = 3 [M,L,T]. We thus have eight dimensionless numbers. By using the distance between the two axles l [M], the initial velocity of the vehicle v_i [MT⁻¹] and the normal force on front wheels N_f [MLT⁻²] as repeated variables, we get the eight dimensionless numbers. The inputs and ouputs of the XGBoost algorithm used to predict the outcome of a maneuver are shown on figure 3.7.



FIGURE 3.7 Buckingham's π theorem based model for experimental data

Augmented Buckingham π theorem based model for experimental data

By simple manipulations of the same physical variables used in previous models, the limits in longitudinal force π_9 and lateral force π_{10} before sliding can be introduced using equations 3.6 and 3.7. An infinite number of corrective dimensionless numbers could be created depending on the system under study to minimize the output error of the Augmented Buckingham model. However, these two numbers have been arbitrarily chosen for their high dynamic significance.

$$\pi_9 = \frac{F_{limit}}{F_{x_{maneuver}}} = \frac{N_r \mu}{ma} = \frac{N_r \mu g}{(N_f + N_r)a}$$
(3.6)

$$\pi_{10} = \frac{F_{limit}}{F_{y_{maneuver}}} = \frac{N_r \mu}{\frac{mv^2}{R}} = \frac{g\mu R}{v^2} = \frac{g\mu l}{v^2 \tan \delta}$$
(3.7)



FIGURE 3.8 Augmented Buckingham's π theorem based model for experimental data

3.6.3 Results

Mean Absolute Error

To avoid any redundancy, only the summarizing table 3.9 for self, cross and sharedpredictions is presented for the experimental data. For self-predictions, we can see that the Buckingham's π theorem based model and the Augmented Buckingham model are respectively 1.11 times and 1.14 times more precise than the traditional model on average. These numbers drop to 1.05 times and 1.07 times more precise for cross-predictions. Finally, the Buckingham's π theorem based model and the Augmented Buckingham model are respectively 1.11 times and 1.28 times more precise than the traditional model in shared-predictions.

TABLEAU 3.9 MAE comparison for all models trained with experimental data (X and Y are in meters and θ in rad)

Prediction	Traditional	Buckingham's	Augmented
\mathbf{types}	dimensionalized	π theorem	Buckingham's
	model	based model	$\pi \operatorname{\mathbf{model}}$
SELF	X: 0.1229	X: 0.1228	X: 0.1197
Predictions	Y: 0.0488	Y : 0.0321	Y : 0.0335
	θ : 0.0482	$\theta: 0.0596$	$\theta: 0.0554$
CROSS	X : 0.3027	X : 0.3752	X: 0.3775
Predictions	Y: 0.2198	Y : 0.0186	Y : 0.0128
	θ : 0.2007	θ : 0.1494	$\theta: 0.1454$
SHARED	X : 0.0539	X: 0.0507	X : 0.0400
Predictions	Y : 0.0130	Y: 0.0105	Y: 0.0089
	$\theta: 0.0193$	heta: 0.0187	heta: 0.0187

Learning rate

Figure 3.9 shows the MAE convergence for the final longitudinal position X, final lateral position Y and final yaw θ of the three model types with the large vehicle's experimental self-predictions. For all outputs, all three models follow a similar learning curve. More training data would be required to fully converge since all curves keep on improving at a relatively high rate.



FIGURE 3.9 MAE convergence according to training size for the experimental data of the large vehicle

3.7 Conclusion and outreach

To conclude, this paper presents a new dimensionless learning scheme using Bucking's π theorem. The results with data based on kinematic simulations of the three studied small-scale vehicles show that the proposed models are more accurate and have faster learning rates than a traditional dimensionalized model. The experimental validation was inconclusive due to sensor noise and the discrepancy between the assumptions made and the high complexity of the dynamics involved in the experimentation.

Nevertheless, the discovery presented in this paper is promising since it could minimize the experimental data required to train a learning algorithm. Finally, a successful experimental validation with a simpler case-study could be interesting.

CHAPITRE 4 CONCLUSION

Ce projet de recherche visait à valider si un modèle d'apprentissage pouvait bénéficier d'une adimensionnalisation de ses entrées et ses sorties en démontrant une augmentation de la vitesse d'apprentissage, une réduction de l'erreur absolue moyenne et une amélioration de la capacité à partager des connaissances entre des systèmes similaires.

Pour atteindre cet objectif, un modèle d'apprentissage adimensionnel basé sur le théorème de π de Buckingham a été étudié. Une simulation cinématique des trois plateformes expérimentales a permis de comparer les résultats d'un modèle d'apprentissage traditionnel avec ceux obtenus avec la méthode proposée. Ensuite, grâce à des tests expérimentaux effectués avec ces trois véhicules à échelle réduite, les résultats d'un modèle d'apprentissage traditionnel expérimentalement.

Les résultats en simulation montrent que le modèle adimensionnel proposé est en mesure d'obtenir des résultats supérieurs à ceux obtenus avec un modèle d'apprentissage traditionnel. En effet, le modèle adimensionnel avait une vitesse d'apprentissage supérieure ainsi que des erreurs absolues moyennes inférieures autant pour un système étudié de manière isolé que lorsqu'on tente de partager l'apprentissage entre différents systèmes. Les erreurs absolues moyennes pouvaient afficher des valeurs jusqu'à 15 fois plus petites pour le modèle adimensionnel que pour le modèle dimensionnalisé. Malheureusement, les résultats expérimentaux n'ont pas été aussi concluants. En effet, aucune amélioration ni détérioration des résultats n'a pu être notée en comparant les deux types de modèles. Ce phénomène a probablement été causé par de mauvaises hypothèses posées lors de la création du modèle adimensionnelle ne reflétant pas la dynamique complexe d'une manoeuvre d'évitement de collision brusque. En effet, les hypothèses en lien avec le modèle bicyclette négligeant les effets du roulis et du tangage, la simplification de la relation très complexe entre la chaussée et le pneu ainsi que l'absence de modélisation de la suspension sont tous des pistes possibles permettant d'expliquer la disparité entre les résultats obtenus en simulation et ceux grâce à la méthode expérimentale. Ces éléments sont tous critiques pour déterminer une position et une orientation finale précise lors d'une manoeuvre brusque, donc hautement dynamique. Un modèle haute fidélité plus complexe reflétant la dynamique réelle des

véhicules pourrait permettre de faire tendre les résultats expérimentaux vers ceux obtenus en simulation.

Étant donnée la performance supérieure marquée du modèle adimensionnel proposé lors des tests en simulation, il serait intéressant de pousser davantage la validation expérimentale. Si de tels résultats se reflètent grâce à des tests expérimentaux, cette méthode pourrait être prometteuse pour pallier aux problématiques reliées à l'acquisition importante de données pour entraîner des algorithmes d'apprentissage. Un système ayant une dynamique moins complexe qu'un véhicule pratiquant une manoeuvre d'urgence pourrait être un bon point de départ pour obtenir une validation expérimentale concluante.

LISTE DES RÉFÉRENCES

- G. Liu, H. Ren, S. Chen, et W. Wang, "The 3-DoF bicycle model with the simplified piecewise linear tire model," dans *Proceedings of the International Conference on Mechatronic Sciences*, pp. 3530–3534, 2013.
- [2] R. Rajamani, N. Piyabongkarn, J. Lew, K. Yi, et G. Phanomchoeng, "Tire-road friction-coefficient estimation," *IEEE Control Systems Magazine*, vol. 30, pp. 54–69, 2010.
- [3] S. Moon, I. Moon, et K. Yi, "Design, tuning, and evaluation of a full-range adaptive cruise control system with collision avoidance," *Control Engineering Practice*, vol. 17, pp. 442–455, 2009.
- [4] A. S. P. Singh et O. Nishihara, "Nondimensionalized univariate equation characterizing optimal state feedback control for collision avoidance," *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, pp. 3344–3359, 2018.
- [5] A. Moujahid, M. ElAraki Tantaoui, M. D. Hina, A. Soukane, A. Ortalda, A. ElKhadimi, et A. Ramdane-Cherif, "Machine learning techniques in ADAS : A review," dans *Proceedings of the International Conference on Advances in Computing and Communication Engineering*, pp. 235–242, 2018.
- [6] N. H. Amer, H. Zamzuri, K. Hudha, et Z. A. Kadir, "Modelling and control strategies in path tracking control for autonomous ground vehicles : A review of state of the art and challenges," *Journal of Intelligent Robotic Systems*, vol. 86, pp. 225–254, 2017.
- [7] B. Paden, M. Čáp, S. Z. Yong, D. Yershov, et E. Frazzoli, "A survey of motion planning and control techniques for self-driving urban vehicles," *IEEE Transactions* on *Intelligent Vehicles*, vol. 1, pp. 33–55, 2016.
- [8] C. Katrakazas, M. Quddus, W.-H. Chen, et L. Deka, "Real-time motion planning methods for autonomous on-road driving : State-of-the-art and future research directions," *Transportation Research Part C : Emerging Technologies*, vol. 60, pp. 416–442, 2015.
- S. Aradi, "Survey of deep reinforcement learning for motion planning of autonomous vehicles," *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, pp. 740– 759, 2022.
- [10] R. H. Crites et A. G. Barto, "Improving elevator performance using reinforcement learning," Advances in Neural Information Processing Systems 8, p. 7, 1995.
- [11] X. Di et R. Shi, "A survey on autonomous vehicle control in the era of mixedautonomy : From physics-based to AI-guided driving policy learning," *Transportation Research Part C : Emerging Technologies*, vol. 125, article 103008, 2021.
- [12] B. M. Lake, T. D. Ullman, J. B. Tenenbaum, et S. J. Gershman, "Building machines that learn and think like people," *Behavioral and Brain Sciences*, vol. 40, pp. 1–72, 2017.
- [13] Y. Liu, H. Xu, D. Liu, et L. Wang, "A digital twin-based sim-to-real transfer for deep reinforcement learning-enabled industrial robot grasping," *Robotics and Computer-Integrated Manufacturing*, vol. 78, article 102365, 2022.

- [14] O. M. Andrychowicz, B. Baker, M. Chociej, R. Józefowicz, B. McGrew, J. Pachocki, A. Petron, M. Plappert, G. Powell, A. Ray, J. Schneider, S. Sidor, J. Tobin, P. Welinder, L. Weng, et W. Zaremba, "Learning dexterous in-hand manipulation," *The International Journal of Robotics Research*, vol. 39, pp. 3–20, 2020.
- [15] A. Nagabandi, I. Clavera, S. Liu, R. S. Fearing, P. Abbeel, S. Levine, et C. Finn, "Learning to adapt in dynamic, real-world environments through meta-reinforcement learning," *Proceedings of the International Conference on Learning Representations*, pp. 1–17, 2019.
- [16] S. Dasari, F. Ebert, S. Tian, S. Nair, B. Bucher, K. Schmeckpeper, S. Singh, S. Levine, et C. Finn, "RoboNet : Large-scale multi-robot learning," *Proceedings of Machine Learning*, vol. 100, p. 885–897, 2019.
- [17] A. S. P. Singh et N. Osamu, "Nondimensionalized indices for collision avoidance based on optimal control theory," dans *Proceedings of FISITA World Automotive Congress*, 2016.
- [18] X. Luo, F. Xie, X.-J. Liu, et Z. Xie, "Kinematic calibration of a 5-axis parallel machining robot based on dimensionless error mapping matrix," *Robotics and Computer-Integrated Manufacturing*, vol. 70, article 102115, 2021.
- [19] H. B. Pacejka et I. J. M. Besselink, "Magic formula tyre model with transient properties," Vehicle System Dynamics, vol. 27, pp. 234–249, 1997.
- [20] H. Dugoff, P. S. Fancher, et L. Segel, "Tire performance characteristics affecting vehicle response to steering and braking control inputs," *Tire System Section Office of Vehicle Systems Research*, pp. 1–105, 1969.
- [21] M. Kissai, B. Monsuez, A. Tapus, et D. Martinez, "A new linear tire model with varying parameters," dans *Proceedings of the IEEE International Conference on Intelligent Transportation Engineering*, pp. 108–115, 2017.
- [22] O. Garcia-Bedoya, S. Hirota, et J. Ferreira, "Control system design for an automatic emergency braking system in a sedan vehicle," dans *Proceedings of the Latin American Conference on Intelligent Transportation Systems*, pp. 1–6, 2019.
- [23] J. Q. Wang, R. Chai, et N. Cao, "Modeling highway lane changing using bayesian networks," *Applied Mechanics and Materials*; Zurich, vol. 505-506, pp. 1143–1147, 2014.
- [24] O. Töro, T. Bécsi, et S. Aradi, "Design of lane keeping algorithm of autonomous vehicle," *Periodica Polytechnica. Transportation Engineering*; *Budapest*, vol. 44, pp. 60–68, 2016.
- [25] J. Pohl, W. Birk, et L. Westervall, "A driver-distraction-based lane-keeping assistance system," Proceedings of the Institution of Mechanical Engineers : Journal of Systems and Control Engineering, Part I; London, vol. 221, pp. 541–552, 2007.
- [26] K. Jiang et L. Seneviratne, "A sensor guided autonomous parking system for nonholonomic mobile robots," dans *Proceedings of the IEEE International Conference on Robotics and Automation*, vol. 1, pp. 311–316, 1999.
- [27] P. Tchankue, J. Wesson, et D. Vogts, "Using machine learning to predict the driving context whilst driving," dans Proceedings of the South African Institute for Computer Scientists and Information Technologists Conference, pp. 47–55, 2013.

- [28] C. D'Agostino, A. Saidi, G. Scouarnec, et L. Chen, "Learning-based driving events recognition and its application to digital roads," *Proceedings of the IEEE Transactions* on Intelligent Transportation Systems, vol. 16, pp. 2155–2166, 2015.
- [29] R. Zheng, C. Liu, et Q. Guo, "A decision-making method for autonomous vehicles based on simulation and reinforcement learning," dans *Proceedings of the International Conference on Machine Learning and Cybernetics*, vol. 01, pp. 362–369, 2013.
- [30] A. Jahangiri et H. A. Rakha, "Applying machine learning techniques to transportation mode recognition using mobile phone sensor data," *Proceedings of the IEEE Transactions on Intelligent Transportation Systems*, vol. 16, pp. 2406–2417, 2015.
- [31] C. Miyajima, Y. Nishiwaki, K. Ozawa, T. Wakita, K. Itou, K. Takeda, et F. Itakura, "Driver modeling based on driving behavior and its evaluation in driver identification," *Proceedings of the IEEE*, vol. 95, pp. 427–437, 2007.
- [32] M. J. Sorocky, S. Zhou, et A. P. Schoellig, "Experience selection using dynamics similarity for efficient multi-source transfer learning between robots," *Proceedings of* the IEEE International Conference on Robotics and Automation, pp. 2739–2745, 2020.
- [33] T. Chen, A. Murali, et A. Gupta, "Hardware conditioned policies for multi-robot transfer learning," dans Advances in Neural Information Processing Systems, vol. 31, 2018.
- [34] T. Chen et C. Guestrin, "XGBoost : A scalable tree boosting system," dans Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, pp. 785–794, 2016.
- [35] O. Lecompte, W. Therrien, et A. Girard, "Experimental investigation of a maneuver selection algorithm for vehicles in low adhesion conditions," *Proceedings of the IEEE Transactions on Intelligent Vehicles*, vol. 7, pp. 407–412, 2022.