



HAL
open science

amélioration de la précision de structures sérielles poly-articulées par des méthodes d'apprentissage automatique économes en données

Maxime Selingue

► **To cite this version:**

Maxime Selingue. amélioration de la précision de structures sérielles poly-articulées par des méthodes d'apprentissage automatique économes en données. Automatique / Robotique. HESAM Université, 2023. Français. NNT : 2023HESAE085 . tel-04485222

HAL Id: tel-04485222

<https://pastel.hal.science/tel-04485222v1>

Submitted on 1 Mar 2024

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

**ÉCOLE DOCTORALE SCIENCES ET MÉTIERS DE L'INGÉNIEUR
LISPEN - Campus de Lille**

THÈSE DE DOCTORAT

présentée par : **Maxime SELINGUE**
pour obtenir le grade de : **Docteur d'HESAM Université**

préparée à : **École Nationale Supérieure d'Arts et Métiers**
Spécialité : **Robotique**

**Amélioration de la précision de structures sérielles
poly-articulées par des méthodes d'apprentissage
automatique économes en données**

THÈSE dirigée par :
Mr. BEAREE Richard

et co-encadrée par :
Mr. OLABI Adel
Mr. THIERY Stéphane

Jury

M. Stéphane CARO	Dir. de recherche - HDR, CNRS, LS2N	Président du jury
M. Stéphane LECOEUICHE	Professeur, IMT Lille Douai	Rapporteur
M. David DANAY	Chercheur Senior - HDR, INRIA	Rapporteur
Mme. Catherine BIDARD	Expert Senior, CEA LIST	Examinatrice
M. Richard BEAREE	Professeur, LISPEN, ENSAM	Examineur
M. Adel OLABI	Maître de Conférences, LISPEN, ENSAM	Examineur
M. Stéphane THIERY	Maître de Conférences, LISPEN, ENSAM	Examineur

Remerciements

En premier lieu, je tiens à remercier Mr Stéphane Caro d'avoir accepté de présider mon jury de thèse. Je remercie également Mr Stéphane Lecoche et Mr David Daney pour leurs commentaires constructifs et pertinent sur mes travaux. Je tiens à remercier Mme Catherine Bidard d'avoir accepté de participer à la présentation de ces travaux.

Je souhaite ensuite remercier tout particulièrement Richard Béarée, Adel Olabi et Stéphane Thiery, pour leur encadrement, leurs conseils, leur disponibilité. Ce manuscrit n'a pu voir le jour que grâce à leurs relectures attentive.

Ensuite, je tiens à remercier l'ensemble de l'équipe du LISPEN : mes collègues doctorants Eddy, Marielle, Lei, Shuhan, Marguerite, Hugo, Arthur, Guillaume, Dorian, Floriane, Vincent et Tiphaine, François, Lamine, Mathieu, qui sont aujourd'hui de véritables amis. Les pauses cafés du matin, pauses promenade de l'après-midi et pauses bière du soir m'ont bien souvent changé les idées. Je remercie également Adrien Florit, Vincent Iori et Vincent Deschodt pour l'aide et le support qu'ils m'ont apportés.

Enfin, je souhaite remercier chaleureusement mes parents, pour m'avoir toujours encouragé à poursuivre mes études, et m'avoir donné l'envie d'apprendre. Un immense merci également à mon frère, ma soeur, mes beaux-parents, beaux-frères et belles-soeurs pour leur soutien au cours de ces trois années.

Pour finir, je remercie infiniment Marine, pour m'avoir aidé à traverser toutes ces années d'études, et plus particulièrement ces trois années de thèses.

REMERCIEMENTS

Table des matières

Remerciements	III
Table des matières	V
Liste des Figures	IX
Liste des Tables	XIII
Introduction	1
1 Calibration analytique des robots industriels	7
1.1 Introduction	8
1.2 Modélisation	9
1.2.1 Modèle Géométrique Direct	9
1.2.2 Modèle Géométrique Inverse	11
1.2.3 Modélisation des défauts géométriques	12
1.2.4 Modélisation de la compliance des articulations	13
1.2.5 Modélisation des erreurs de transmission	16
1.2.5.1 Le <i>backlash</i>	16
1.2.5.2 Les irrégularités cinématiques	17
1.2.6 Modélisation de la dérive thermique	18
1.3 Identification des paramètres	19
1.3.1 Principe mathématique des moindres carrés	19

TABLE DES MATIÈRES

1.3.2	Intervalles de confiance	21
1.4	Mesures	21
1.4.1	Instruments de mesures	21
1.4.2	Identification du repère de base	23
1.4.2.1	Méthodes existantes	23
1.4.2.2	Comparaisons des différentes méthodes	26
1.4.3	Précision et répétabilité	28
1.4.4	Bilan des sources d'erreurs	30
1.4.4.1	Défauts géométriques	30
1.4.4.2	Compliance des articulations	31
1.4.4.3	Dérive thermique	32
1.4.4.4	Erreurs de transmissions	33
1.4.4.5	Bilan	34
1.5	Compensation	34
1.6	Conclusion	36
2	Amélioration de la reconfigurabilité des méthodes de calibration hybrides	41
2.1	Introduction	42
2.1.1	Calibration analytique, calibration "boîte-noire"	42
2.1.2	Etat de l'art des méthodes de calibration hybrides	42
2.1.3	Contributions	45
2.2	Calibration hybride	46
2.2.1	Modèle analytique	46
2.2.2	Modèle d'apprentissage	47
2.3	Analyse expérimentale des méthodes de calibration hybrides	49
2.3.1	Application sur un robot collaboratif (<i>iiwa</i>)	49
2.3.1.1	Évaluation des modèles directs	50
2.3.1.2	Étude du nombre de données d'entraînement requis	51

TABLE DES MATIÈRES

2.3.1.3	Évaluation des performances de l'algorithme de compensation	52
2.3.2	Application sur un robot industriel "moyen porteur" (KR300)	53
2.4	Adaptabilité à une variation de la charge utile	55
2.4.1	Méthode 1 : apprentissage par transfert	56
2.4.1.1	L'apprentissage par transfert	56
2.4.1.2	Description de la méthode	57
2.4.2	Méthode 2 : interpolation de deux prédictions	59
2.4.2.1	Considérations mathématiques	59
2.4.2.2	Description de la méthode	60
2.5	Validation des méthodes	61
2.5.1	Évaluation de la performance des modèles proposés	61
2.5.2	Validation expérimentale	63
2.5.3	Discussion	65
2.6	Conclusion	66
3	Calibration hybride optimisée et autonome par apprentissage actif	73
3.1	Introduction	74
3.2	Description de la méthode	76
3.2.1	Régresseurs par processus gaussiens	76
3.2.2	Algorithme d'apprentissage actif	77
3.2.2.1	Application à un cas simple	78
3.2.2.2	Généralisation à la calibration de robots	78
3.2.3	Calibration hybride active	79
3.3	Design de l'algorithme d'apprentissage actif	80
3.3.1	Choix du noyau	81
3.3.2	Influence du noyau de bruit	83
3.3.3	Méthode d'initialisation	84
3.3.4	Influence de l'identification des paramètres géométriques	85

TABLE DES MATIÈRES

3.3.5	Choix du critère d'arrêt	86
3.3.6	Évaluation du modèle hybride	87
3.4	Validation expérimentale de l'algorithme d'apprentissage actif	89
3.4.1	Application sur robot industriel	89
3.4.1.1	Protocole expérimental	90
3.4.1.2	Mise en oeuvre de la méthode	90
3.4.1.3	Résultats	92
3.4.2	Application sur robot collaboratif	93
3.4.2.1	Protocole expérimental	93
3.4.2.2	Mise en oeuvre de la méthode	94
3.4.2.3	Résultats	94
3.5	Conclusion	96
	Conclusion	101
	Bibliographie	107

Liste des Figures

1	Précision et répétabilité	1
2	Illustration des sources principales de défauts de positionnement d'un robot industriel.	2
3	Principe d'utilisation d'un modèle fidèle au robot réel pour la compensation d'erreur de positionnement.	3
4	Robots étudiés	6
1.1	Repères associés à chacune des articulations du KR300	11
1.2	Principe du modèle élasto-statique	14
1.3	Déformation angulaire en fonction du couple appliqué sur des engrenages [Tuttle, 1992]	15
1.4	Phénomène de <i>backlash</i>	16
1.5	Irrégularités cinématiques sur l'articulation 2 d'un robot Staübli TX90 [Olabi, 2011] .	18
1.6	Tête active, asservie pour conserver le faisceau du laser tracker dans le cône de réflexion	23
1.7	Identification des repères de bases et effecteur. Les axes \vec{x} , \vec{y} , \vec{z} des repères robot et Laser Tracker sont respectivement représentés en rouge, vert et bleu.	24
1.8	Méthode <i>L-path</i> pour l'identification de repère de base robot	25
1.9	Méthode <i>2-cercles</i> pour l'identification de repère de base robot	26
1.10	Répartition des <i>points mobiles</i> dans l'espace de travail du KR300	27
1.11	Répartition des points de validations dans l'espace de travail du robot.	28
1.12	Déviations des repères de base robot identifiés pour chaque test par rapport au barycentre	29
1.13	Précision et répétabilité du KR300	30
1.14	Distribution de l'erreur de positionnement sur un ensemble de 50 points et vue 3D du champs des vecteurs d'erreurs de positionnement après calibration géométrique	32

LISTE DES FIGURES

1.15	Distribution de l'erreur de positionnement due à une différence de charge utile sur un ensemble de 50 points et vue 3D du champs des vecteurs d'erreurs de positionnement.	33
1.16	Localisation des 6 points de la trajectoire de test	34
1.17	Température de chacune des articulations en fonction du temps	35
1.18	Configurations articulaires et déviations de l'effecteur au cours du temps pour les points 2, 4 et 5.	38
1.19	Observation du backlash sur une diagonale du cube ISO	39
1.20	Algorithme de compensation et illustration sur un cas 2D.	39
2.1	Principe des méthodes de calibration hybrides	43
2.2	Sous-espaces de travail définis dans [Zhao et al., 2019, Gadringer et al., 2020].	44
2.3	Repères associés à chacune des articulations de l' <i>iiwa</i> [Busson, 2018]	48
2.4	Architecture du réseau de neurones	49
2.5	Montage expérimental utilisé pour la calibration hybride de l' <i>iiwa</i>	50
2.6	Distribution des erreurs de positionnement de l'effecteur de l' <i>iiwa</i> sur les 100 données de validation pour les 4 modèles étudiés.	53
2.7	Influence du nombre de données sur l'erreur de positionnement moyenne et maximale de l'effecteur de l' <i>iiwa</i>	54
2.8	Algorithme de compensation utilisant le modèle hybride	56
2.9	Distribution des erreurs de positionnement de l'effecteur de l' <i>iiwa</i> en appliquant l'algorithme de compensation sur 100 positions cartésiennes pour les 4 modèles étudiés.	57
2.10	Répartition des points de mesures pour la calibration hybride du KR300. Les points bleus ont servi à l'identification des paramètres géométriques; les points verts à l'entraînement des poids du réseau de neurones.	58
2.11	Distribution de l'erreur de positionnement de l'effecteur du KR300 pour les 4 modèles étudiés, dans les deux sous-espaces de travail S_1 et S_2 , avec les charges $P_1 = 4kg$ et $P_2 = 120kg$	68
2.12	Influence du nombre de données sur l'erreur de positionnement moyenne et maximale.	69
2.13	Principe de la méthode 1	69
2.14	Principe de la méthode 2	70

LISTE DES FIGURES

2.15	Distribution de l'erreur de positionnement (mm) (sur 100 points de validation extraits aléatoirement du dataset d'entraînement avant l'entraînement) pour une nouvelle charge $P_{new} = 72 \text{ kg}$. La ligne verticale représente l'erreur moyenne.	70
2.16	Distribution de l'erreur de positionnement (mm) sur 100 points de validation, en utilisant l'algorithme de compensation. La ligne verticale représente l'erreur moyenne.	71
3.1	Description de la méthode de calibration hybride active	76
3.2	Apprentissage actif appliqué à un cas simple.	79
3.3	Algorithme de compensation utilisant le modèle décrit par l'équation (3.5).	81
3.4	Champ de vecteurs d'erreur dans l'ensemble du sous-espace calibré. Toutes les erreurs ont été amplifiées par le même facteur, pour être rendues visibles.	82
3.5	Comparaison des différents noyaux pour l'approximation de l'erreur de positionnement. Les lignes pleines montrent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés montrent l'évolution de l'erreur maximale.	83
3.6	Comparaison des différents réglages du noyau de bruit. Les lignes pleines représentent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés représentent l'évolution de l'erreur maximale.	84
3.7	Comparaison des différentes méthodes d'initialisation. Les lignes pleines représentent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés représentent l'évolution de l'erreur maximale.	85
3.8	Comparaison de la calibration <i>sans modèle</i> et de la calibration <i>hybride</i> . Les lignes pleines représentent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés représentent l'évolution de l'erreur maximale.	86
3.9	Comparaison de deux conditions d'arrêt censées correspondre à l'erreur moyenne sur l'ensemble de test. Le coefficient de corrélation de Pearson est indiqué en légende.	87
3.10	Évolution de l'écart-type de l'incertitude de prédiction au fil des itérations de l'algorithme d'apprentissage actif.	88
3.11	Évolution de l'incertitude de prédiction sur le maillage \mathcal{G} en utilisant les données issues de la section 2.3.	89

LISTE DES FIGURES

3.12	Application de la calibration hybride par apprentissage actif au KR300. Les axes \vec{x} , \vec{y} , \vec{z} des repères robot et Laser Tracker sont respectivement représentés en rouge, vert et bleu.	91
3.13	Évolution de l'écart-type de l'incertitude de prédiction sur \mathcal{G}_{KR300} au cours de l'application de la méthode de calibration par apprentissage actif sur le KR300.	92
3.14	Évolution de l'incertitude de prédiction au cours de l'application de la méthode de calibration par apprentissage actif sur le KR300.	93
3.15	Distribution de l'erreur de positionnement du KR300, calculé sur 30 points de validations, utilisant l'algorithme de compensation.	95
3.16	Application de la calibration hybride par apprentissage actif à l' <i>iiwa</i>	96
3.17	Évolution de l'écart type de l'incertitude de prédiction sur \mathcal{G}_{iiwa}	97
3.18	Évolution de l'incertitude de prédiction au cours du processus de calibration par apprentissage actif sur l' <i>iiwa</i>	98
3.19	Distribution de l'erreur de position et d'orientation de l'effecteur de l' <i>iiwa</i> après calibration géométrique, sur l'ensemble de poses ayant servies à l'entraînement du GPR.	99
3.20	Distribution de l'erreur de position et d'orientation de l'effecteur de l' <i>iiwa</i> après application du processus de calibration par apprentissage actif, sur l'ensemble de 30 poses de validation.	100

Liste des Tables

1.1	Paramètres géométriques du KR300	10
1.2	Erreur moyenne sur 10 points de tests des repères de base robot	30
1.3	Paramètres géométriques identifiés du KR300	31
1.4	Bilan de l'effet de certaines sources d'erreur par rapport à l'erreur de positionnement du modèle géométrique nominal.	36
2.1	Paramètres géométriques nominaux de l' <i>iiwa</i>	47
2.2	Paramètres géométriques identifiés de l' <i>iiwa</i>	47
2.3	Comparaison des performances du modèle hybride par rapport aux modèles analytiques et "boîte-noire" pour l' <i>iiwa</i>	52
2.4	Évaluation de la précision des 4 modèles en utilisant l'algorithme de compensation pour l' <i>iiwa</i>	55
2.5	Comparaison des performances du modèle hybride par rapport aux modèles analytiques et "boîte-noire" pour le KR300, avec une charge $P = 4kg$	59
2.6	Comparaison des performances du modèle hybride par rapport aux modèles analytiques et "boîte-noire" pour le KR300, avec une charge $P = 120kg$	60
2.7	Erreur moyenne et maximale de différents modèles pour une charge $P_{new} = 72 kg$ dans les deux sous-espaces de travail $S = S_1$ et $S = S_2$	62
2.8	Résultat de la validation expérimentale des modèles proposés, appliqués sur le KR300 dans S_1 en utilisant l'algorithme de compensation, pour différentes charges.	64
3.1	Comparaison entre différents modèles hybrides utilisant des réseaux de neurones ou un GPR, avec apprentissage actif ou passif.	90

LISTE DES TABLES

3.2	Performances de la méthode de calibration hybride active comparée au modèle géométrique direct avec les paramètres géométriques nominaux et identifiés sur le KR300.	94
3.3	Erreurs moyennes et maximales de positionnement et d'orientation de l' <i>iiwa</i> après application du processus de calibration hybride par apprentissage actif, calculées sur un ensemble de validation de 30 poses cartésiennes.	96
3.4	Erreurs moyennes et maximales de positionnement et d'orientation avant calibration géométrique, calculées sur l'ensemble des poses cartésiennes ayant servies à l'entraînement du GPR.	98
3.5	Erreurs moyennes et maximales de positionnement et d'orientation après identification des paramètres géométriques de l' <i>iiwa</i> , calculées sur l'ensemble des poses cartésiennes ayant servies à l'entraînement du GPR.	98

Introduction

Au début des années 70, les premiers robots industriels sont apparus pour accomplir des tâches pénibles, parfois dangereuses, et surtout répétitives (peinture, manutention, ... etc). Les robots industriels ont été conçus à l'origine pour être très répétables, et programmés par apprentissage : la trajectoire qu'ils doivent effectuer est programmée manuellement, directement sur le boîtier de commande du robot. Le robot reproduit la trajectoire ainsi apprise pour effectuer sa tâche. Ce mode de programmation est intuitif, mais ne permet pas des trajectoires complexes, et est long et fastidieux à mettre en place. Les fabricants de robots se sont attachés à concevoir des robots très répétables (de l'ordre de 0,05 à 0,15mm), mais ces robots sont en général peu précis. Les notions de répétabilité et de précision sont illustrées sur la figure 1.




FIGURE 1 – Précision et répétabilité

La 4e révolution qui secoue l'industrie actuellement est celle de l'internet des objets et du *Big Data*. Son objectif est d'apporter plus de flexibilité, d'autonomie et de robustesse aux moyens de productions. Elle repose sur une numérisation des lignes de production : grâce à des capteurs indiquant en temps réel l'état de la ligne de production, il est possible de surveiller la qualité des produits, réapprovisionner les stocks, et adapter la production à la demande rapidement. Ces besoins de flexibilité et d'adaptation conduisent les industriels à élargir les applications des robots à des tâches de plus en plus complexes, requérant plus de précision. En particulier, la flexibilité des robots, leur adaptabilité, et leurs espaces de travail étendus les conduisent à être de plus en plus utilisés pour des applications d'usinage, d'assemblage, voire de contrôle. De ce fait, le nombre de robots industriels en activité dans

le monde croît de 14% par an en moyenne depuis 2016, atteignant ainsi son plus haut niveau en 2021, avec plus de 3.4 millions de robots industriels, d’après le dernier rapport annuel (publié en 2022) de la fédération internationale de robotique [Muller, 2022]. En particulier, le nombre de robots industriels en France a augmenté de 11% en 2021.

Pour répondre aux exigences de l’industrie 4.0, les cellules robotiques sont donc entièrement numérisées et contrôlées en temps réel. Ainsi, le mode de programmation des robots a lui aussi évolué : de plus en plus, ils sont programmés hors-ligne, à partir d’un modèle de leur comportement. De cette manière, ils peuvent être reprogrammés facilement, pour s’adapter rapidement à la demande. Leur précision dépend alors de la fidélité de ce modèle par rapport au robot réel. Le modèle géométrique nominal, couramment utilisé, ne présente qu’une précision de 1 à 2mm [Elatta et al., 2004] : plusieurs phénomènes physiques affectant la position de l’effecteur du robot ne sont pas pris en compte dans ce modèle, comme illustré sur la figure 2. Afin de permettre l’utilisation des robots industriels pour des tâches d’usinage, ou de perçage (dont les exigences de précision se situent généralement entre 0,1 et 0,5mm), des méthodes de calibration¹ ont été développés. Ces méthodes, dont le principe est illustré sur la figure 3, visent à établir un modèle plus représentatif du robot réel, dans le but d’en améliorer la précision, en intégrant notamment un algorithme de compensation (dont le fonctionnement sera décrit ultérieurement en section 1.5). Ainsi, l’avantage des méthodes de calibration est de ne modifier que la commande d’un robot, une fois que le modèle est établi, contrairement à une éventuelle modification structurelle du robot pour le rendre plus précis, ou une correction ”en ligne” qui requiert l’utilisation d’un instrument de mesure précis en continu.

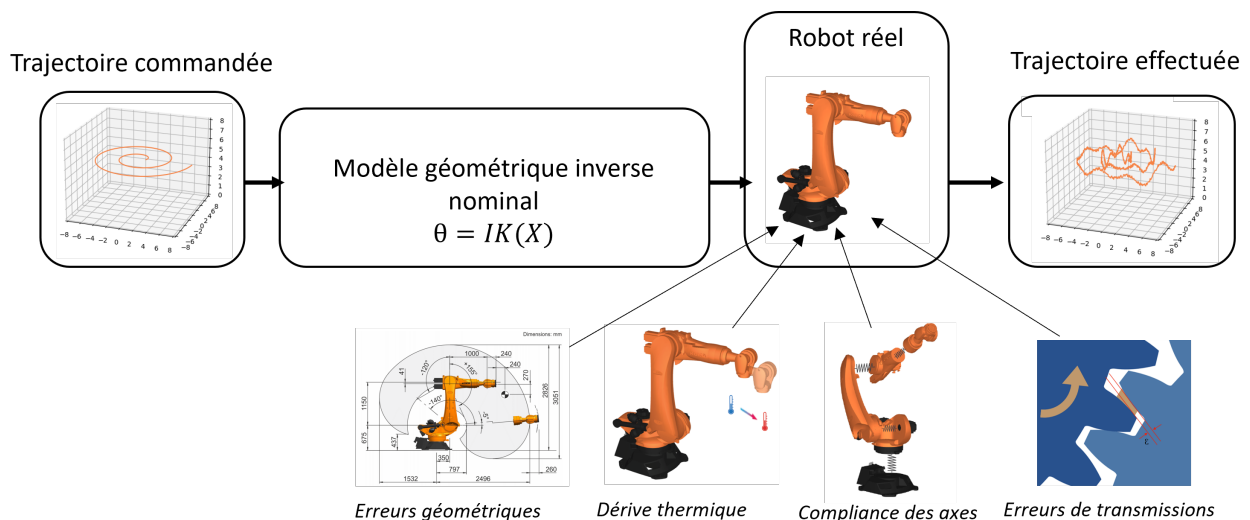


FIGURE 2 – Illustration des sources principales de défauts de positionnement d’un robot industriel.

1. Dans ce manuscrit, le terme ”étalonnage” sera remplacé par le terme ”calibration”, communément utilisé dans la communauté robotique francophone.

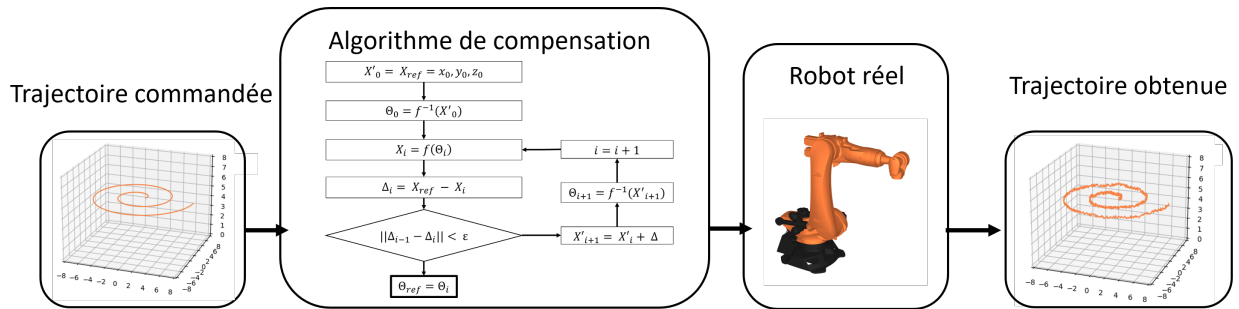


FIGURE 3 – Principe d’utilisation d’un modèle fidèle au robot réel pour la compensation d’erreur de positionnement.

Depuis les années 80, des méthodes de calibration ”analytiques” ont été développés [Salisbury, 1980, Khalil and Besnard, 2002, Le Reun et al., 2022]. Ces méthodes visent à proposer un modèle analytique des phénomènes dégradant la précision d’un robot, puis d’en identifier les paramètres à travers des mesures (position de l’effecteur, température des moteurs, couple appliqué à chaque articulation etc.). En parallèle, des méthodes de calibration ”boîte-noire” ont aussi été développés à partir des années 90. Ces méthodes se basent sur un modèle d’apprentissage automatique qui supporte (voire remplace complètement) le modèle géométrique nominal du robot [Takanashi, 1990, Zhong et al., 1996, Kumar et al., 2018].

Afin d’être appliquées dans un contexte industriel de manière efficace, les méthodes de calibration se doivent de prendre en compte les spécifications suivantes :

- **La précision du modèle** : sur un ensemble de test, quel est l’erreur de positionnement moyenne et maximale de l’effecteur du robot ?
- **Le nombre de données** : combien de mesures ont été nécessaires pour calibrer le robot ?
- **Le temps nécessaire à la calibration** : combien de temps faut-il pour calibrer le robot ?
- **La complexité de la méthode** : quelles connaissances sur le robot et quels instruments de mesures sont nécessaires pour appliquer la méthode ?
- **La reconfigurabilité de la méthode** : dans le cas où la tâche ou les paramètres du robot (limites cinématiques, charge utile...) évoluent, dans quelle mesure le modèle utilisé est-il toujours valide ?

De manière générale, les méthodes de calibration analytiques sont économes en terme de nombre de données, mais peuvent prendre beaucoup de temps à être appliquées, en particulier pour compenser les phénomènes thermiques par exemple. De plus, la précision offerte par le modèle dépend de la finesse de ce dernier : plus le modèle intègre des défauts, plus la précision après calibration sera élevé. En contrepartie, le protocole de calibration sera de plus en plus difficile à appliquer. En effet,

la réalisation d'un modèle analytique fin est très chronophage en terme de développement et les bénéfices des méthodes de calibration sont limités par le manque de certaines connaissances sur les robots (modèle de masse, type d'engrenage, matériaux). Quant aux méthodes de calibration "boîte-noire", elles sont relativement moins complexes à mettre en oeuvre que les modèles analytiques les plus avancés : elles ne nécessitent généralement qu'un instrument de mesure, et aucune connaissance *a priori* du comportement du robot. En revanche, elles nécessitent d'acquérir beaucoup de données pour obtenir un modèle d'apprentissage précis. Elles sont donc également chronophages en temps d'immobilisation du robot et de ressources allouées.

Afin de bénéficier des avantages des deux méthodes sans souffrir de leurs inconvénients, des méthodes de calibration hybrides ont récemment été développées [Nguyen et al., 2015, Zhao et al., 2019, Gadringer et al., 2020]. Elles combinent un modèle analytique qui rend compte du comportement global du robot et un modèle d'apprentissage automatique qui prédit l'erreur résiduelle entre le modèle analytique et les données mesurées. Ainsi, ces méthodes se veulent plus économes en terme de nombre de données que les méthodes "boîte-noire", tout en gardant un haut niveau de précision et une complexité de mise en oeuvre minime. En revanche, cette économie du nombre de données requise n'a pas été quantifiée dans la littérature. Par ailleurs, les méthodes hybrides ne sont pas plus adaptables que les méthodes "boîte-noire". Par exemple, si la charge utile manipulée par le robot varie (ce qui est souvent le cas pour des applications de pick-and-place, d'assemblage ou d'usinage), la méthode hybride doit être appliquée pour chaque charge utile.

Ainsi, si les méthodes hybrides sont capables de répondre aux exigences de précisions, elles ne remplissent pas les critères d'adaptabilité et de frugalité en terme de nombre de données. Les travaux présentés dans ce manuscrit visent à apporter de nouvelles méthodes de calibration hybrides permettant de remplir ces spécifications. En particulier, deux méthodes de calibration hybrides permettant d'adapter un modèle existant à une nouvelle charge utile seront présentés : la première se base sur l'apprentissage par transfert pour réutiliser des connaissances précédemment acquises, permettant alors d'entraîner un réseau de neurones avec un nombre très réduit de données ; la seconde se base sur l'interpolation des prédictions de ce réseau précédemment entraîné pour deux charges utiles différentes (i.e. inférence avec les deux jeux de poids respectifs), ne nécessitant alors pas de nouvelles mesures pour une nouvelle charge utile. Le développement et l'étude de ces méthodes ont fait l'objet d'une publication dans un journal scientifique [Selingue et al., 2023b]. Ensuite, une méthode de calibration hybride par apprentissage actif sera développée. Cette méthode permet de réduire fortement le nombre de données nécessaires, tout en étant totalement autonome : l'algorithme d'apprentissage actif détermine itérativement les données les plus pertinentes à acquérir pour calibrer un sous-espace de travail prédéfini jusqu'à la vérification d'une condition d'arrêt marquant la fin de l'apprentissage. Un article scientifique présentant cette méthode et ses résultats est en cours de rédaction. Enfin, ce manuscrit a adopté une approche expérimentale des méthodes de calibration. Ainsi, un bilan des contributions des

différentes sources d'erreurs sur un robot industriel sera présenté. De même, une étude expérimentale de l'apport des méthodes hybrides par rapport aux méthodes analytiques et "boîte-noire" a été réalisée et présentée lors d'une conférence internationale [Selingue et al., 2022]. Une étude pragmatique des différentes méthodes d'identification du repère de base robot dans le repère de base de l'instrument de mesure, étape essentielle à toutes les méthodes de calibration, a également été effectuée, et sera présenté prochainement lors d'une conférence internationale [Selingue et al., 2023a]. Enfin, les données récoltées dans ce manuscrit ont été rendues accessibles en ligne², dans le but d'accélérer les recherches dans ce domaine et de permettre des études comparatives de différentes méthodes existantes sur un base commune de données.


Ce manuscrit est organisé en trois chapitres. Le premier présente les méthodes de calibration analytiques, qui s'articulent en général en quatre étapes : modélisation, mesure, identification, compensation. Chacune de ces étapes sera revue en détail, pour en identifier les limites. La mise en oeuvre de ces méthodes sera également étudié, en particulier l'identification du repère de base robot dans le repère du laser tracker, instrument de mesure largement utilisé pour la calibration des robots industriels. Un bilan des contributions de chaque source d'erreurs sera également établi sur un robot industriel. Ce premier chapitre permet alors d'éclairer le choix à la fois du modèle analytique dans les méthodes de calibration hybrides présentées par la suite, et des dispositifs expérimentaux mis en oeuvre, au regard des spécifications énoncées précédemment. Le deuxième chapitre porte sur la mise en oeuvre des méthodes de calibration hybrides, et proposera deux méthodes permettant d'adapter un modèle hybride existant à une nouvelle charge utile. Ce chapitre proposera également une étude expérimentale comparative sur le nombre de données requises pour une calibration "boîte-noire", une calibration hybride "classique" (i.e. les méthodes développés dans la littérature) et les deux méthodes proposées, afin de souligner les bénéfices de ces dernières. Enfin, le troisième chapitre détaillera la méthode de calibration hybride par apprentissage actif développée. Les données récoltées au cours du chapitre 2 serviront à tester et valider cette méthode "hors-ligne" (régler ses hyperparamètres, montrer sa robustesse et juger de ses performances), puis elle sera validée expérimentalement sur deux robots différents.

Au cours de ces études, deux robots aux caractéristiques différentes seront considérés : le KUKA Quantec KR300 R2500, abrégé en KR300 dans la suite du manuscrit ; et le KUKA lbr *iiwa* 14R820, dénommé *iiwa* ci-après. Le KR300 (illustré sur la figure 4a) est un robot industriel "moyen porteur", destiné à des tâches de manutention d'objet allant jusqu'à 300kg, ou d'usinage, perçage, assemblage de grande dimensions. Il présente un rayon d'action de 2,5m. L'*iiwa* (illustré sur la figure 4b) est un robot collaboratif destiné à des opérations de pick-and-place, assemblage de faible dimensions, et de collaboration homme-machine. Il a un rayon d'action de 820mm, peut porter une charge utile de 14kg


2. <https://doi.org/10.57745/DWUCOH>

INTRODUCTION

et est moins rigide que le KR300. Les résultats obtenus sur ces deux robots aux caractéristiques bien différentes permettent ainsi de valider la pertinence des méthodes de calibration hybrides développées au cours de cette thèse, pour une large gamme de robots et d'applications.



(a) KUKA Quantec KR300 R2500



(b) KUKA lbr *iiwa* 14R820

FIGURE 4 – Robots étudiés

Chapitre 1

Calibration analytique des robots industriels

Contenu

1.1	Introduction	8
1.2	Modélisation	9
1.2.1	Modèle Géométrique Direct	9
1.2.2	Modèle Géométrique Inverse	11
1.2.3	Modélisation des défauts géométriques	12
1.2.4	Modélisation de la compliance des articulations	13
1.2.5	Modélisation des erreurs de transmission	16
1.2.6	Modélisation de la dérive thermique	18
1.3	Identification des paramètres	19
1.3.1	Principe mathématique des moindres carrés	19
1.3.2	Intervalles de confiance	21
1.4	Mesures	21
1.4.1	Instruments de mesures	21
1.4.2	Identification du repère de base	23
1.4.3	Précision et répétabilité	28
1.4.4	Bilan des sources d'erreurs	30
1.5	Compensation	34
1.6	Conclusion	36

1.1 Introduction

La demande croissante des industriels pour une production plus agile a poussé les intégrateurs de robots à programmer les robots "hors-ligne". Dans ce mode de programmation, la trajectoire cartésienne de l'effecteur est commandée au robot. Ce dernier transforme cette trajectoire cartésienne en trajectoire articulaire, au travers d'un modèle géométrique nominal.

Par ailleurs, le spectre d'utilisation des robots industriels s'est élargi. Auparavant, ils étaient principalement utilisés pour des tâches de peinture ou de manutention ; aujourd'hui, ils sont de plus en plus utilisés pour des tâches d'usinage, de perçage, d'assemblage. Ces nouvelles tâches nécessitent une grande précision, par conséquent les modèles utilisés pour la programmation hors ligne se doivent d'être de plus en plus fiables, pour refléter le comportement du robot réel. Or, le modèle géométrique nominal utilisé classiquement ne permet pas de rendre compte de certains phénomènes physiques affectant la précision du robot, à savoir les défauts géométriques, la compliance des articulations, les erreurs de transmissions et les effets thermiques. Afin que ces défauts soient pris en compte et compensés, des méthodes de calibration ont été développées.

Dans ce chapitre, nous nous intéressons aux méthodes de calibration analytiques. Ces méthodes suivent généralement 4 étapes : modélisation, identification, mesure, compensation. L'étape de modélisation consiste à décrire par des équations les phénomènes physiques dégradants la précision. Les modèles nominaux, ainsi que les modèles présentés dans la littérature pour chacune des sources d'erreurs de positionnement (défauts géométriques, compliance des articulations, erreurs de transmissions et effets thermiques) sont définis dans la section 1.2. Les méthodes d'identification des paramètres introduits dans les modèles sont détaillées dans la section 1.3, en particulier la méthode des moindres carrés. L'identification des paramètres se fait à partir de données réelles mesurées sur le robot. Le plus souvent, les paramètres sont identifiés à partir de la mesure de la position de l'effecteur du robot par rapport à la base de ce dernier. Or, le Laser Tracker (instrument de mesure le plus couramment utilisé pour la calibration de robots industriels) mesure, dans un repère qui lui est propre, la position de l'effecteur. Ainsi, la section 1.4 propose une étude comparative des différentes méthodes d'identification du repère de base robot dans le repère du laser tracker, et dresse un bilan des contributions de chaque source d'erreur de positionnement sur l'erreur totale. La section 1.5 présente un algorithme de compensation, s'appuyant sur les modèles présentés pour établir la relation entre position cartésienne de l'effecteur et configuration articulaire. Enfin, la section 1.6 conclue sur les avantages et les inconvénients des méthodes de calibration analytiques.

1.2 Modélisation

La programmation hors ligne suppose que la relation entre le vecteur contenant les variables de commande du robot $\vec{\theta} = \begin{bmatrix} \theta_1 & \theta_2 & \dots & \theta_i & \dots & \theta_n \end{bmatrix}^T$ et le vecteur des variables opérationnelles $\vec{X} = \begin{bmatrix} x_1 & x_2 & \dots & x_i & \dots & x_m \end{bmatrix}^T$ est connue. Ainsi, on note :

$$\vec{X} = f(\vec{\theta}) \quad (1.1)$$

le modèle géométrique direct, et :

$$\vec{\theta} = f^{-1}(\vec{X})^1 \quad (1.2)$$

le modèle géométrique inverse. Dans le cas de robots industriels et collaboratifs, nous pouvons considérer que le repère de base du robot $\mathcal{R}_0 = (O, \vec{x}_0, \vec{y}_0, \vec{z}_0)$ est fixe, et que les variables opérationnelles se résument à la position et à l'orientation de l'effecteur exprimées dans ce repère de base du robot (i.e. $m = 6$). Ainsi, on a $\vec{X} = \begin{bmatrix} x & y & z & R_x & R_y & R_z \end{bmatrix}^T$ avec R_x, R_y, R_z les rotations autour des axes $\vec{x}, \vec{y}, \vec{z}$, respectivement. L'équation (1.1) peut donc se réécrire :

$$\begin{aligned} x &= f_1(\theta_1, \theta_2, \dots, \theta_i, \dots, \theta_n) \\ y &= f_2(\theta_1, \theta_2, \dots, \theta_i, \dots, \theta_n) \\ &\dots \\ R_z &= f_6(\theta_1, \theta_2, \dots, \theta_i, \dots, \theta_n) \end{aligned} \quad (1.3)$$

On note que $n \geq m$. Si $n > m$, le robot est dit "redondant", comme c'est le cas pour l'*iiwa*, car il dispose de 7 articulations. En revanche, pour le KR300, nous avons $n = m$, puisqu'il ne dispose que de 6 articulations.

D'après l'équation (1.1), le problème du modèle géométrique direct revient à connaître la position et l'orientation de l'effecteur dans la base du robot, en fonction des variables de commande. Les deux robots à l'étude étant des manipulateurs sériels poly-articulés, les variables de commande représentent les angles des articulations.

1.2.1 Modèle Géométrique Direct

Pour établir le modèle géométrique direct, il est supposé que les segments reliant les articulations entre elles sont infiniment rigides, et que les transmissions sont sans jeu mécanique ni flexibilité. La méthode la plus utilisée pour caractériser le modèle géométrique direct consiste à définir pour

1. Ici, la notation communément utilisée dans les ouvrages de robotique est adoptée, bien que mathématiquement f^{-1} ne soit pas correct : f n'est pas bijective dans le cas de robot sériels poly-articulés, plusieurs solutions peuvent exister pour atteindre une même position cartésienne.

chacune des articulations un repère $R_i(O_i, \vec{x}_i, \vec{y}_i, \vec{z}_i)$. Ensuite, plusieurs conventions existent pour définir le passage d'un repère au suivant [Denavit and Hartenberg, 1995, Stone et al., 1986]. Dans ce manuscrit, nous utiliserons la convention de Khalil-Kleinfinger (appelée également convention de Denavit-Hartenberg modifiée) [Khalil and Kleinfinger, 1986], qui est la plus utilisée dans l'industrie : elle ne nécessite que 4 paramètres ($\alpha_i, a_i, r_i, \theta'_i$) pour définir le passage d'un repère au suivant, et permet de décrire la géométrie d'une plus large gamme de robots, comme les robots parallèles par exemple. Le modèle géométrique direct se construit alors en suivant ces règles :

- le repère de base $(O_0, \vec{x}_0, \vec{y}_0, \vec{z}_0)$ est défini arbitrairement. En pratique, le repère de base $(O_0, \vec{x}_0, \vec{y}_0, \vec{z}_0)$ est souvent choisi tel que \vec{z}_0 soit colinéaire à \vec{z}_1 , \vec{y}_0 colinéaire à \vec{z}_2 et O_0 soit sur \vec{z}_1 .
- \vec{z}_i est situé selon l'axe de rotation ou de translation de l'articulation i .
- \vec{x}_i est la normale commune entre \vec{z}_{i-1} et \vec{z}_i .
- a_i est la distance de \vec{z}_{i-1} à \vec{z}_i selon \vec{x}_{i-1} .
- α_i est l'angle de \vec{z}_{i-1} à \vec{z}_i selon \vec{x}_{i-1} .
- r_i est la distance de \vec{x}_{i-1} à \vec{x}_i selon \vec{z}_i .
- θ'_i est l'angle de \vec{x}_{i-1} à \vec{x}_i selon \vec{z}_i . Il est important de noter que θ'_i est l'angle réel entre les deux repères, il peut se décomposer en la somme de la variable de commande θ_i et d'un terme constant $\theta_{0,i}$. Le terme $\theta_{0,i}$ peut provenir du décalage entre la configuration initiale du robot à partir duquel le modèle DH-modifié est établi et la configuration initiale prévue par le constructeur.

La figure 1.1 montre le positionnement des repères pour chacune des articulations du KR300.

Articulation	a (mm)	α (°)	r (mm)	θ' (°)
1	0	0	675	$-\theta_1$
2	350	-90	0	θ_2
3	1150	0	0	$\theta_3 - 90$
4	-41	-90	1000	$-\theta_4$
5	0	90	0	θ_5
6	0	-90	240	$-\theta_6 + 180$

TABLE 1.1 – Paramètres géométriques du KR300

D'après cette convention, la matrice de transformation entre le repère associé à l'articulation $i - 1$

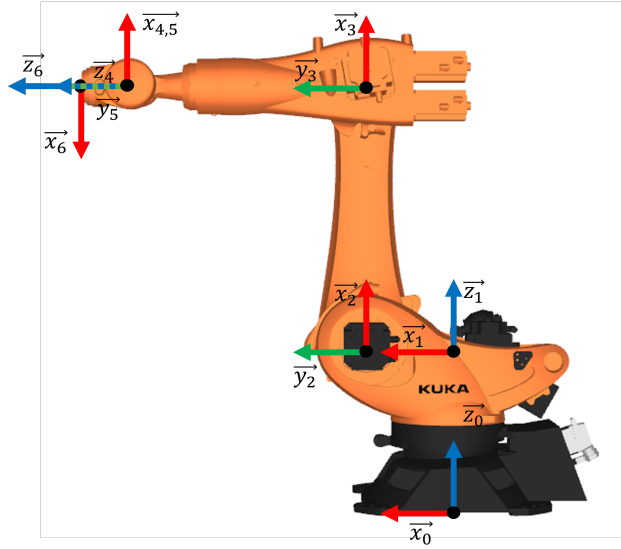


FIGURE 1.1 – Repères associés à chacune des articulations du KR300

et le repère associé à l'articulation i s'écrit :

$$T_{i-1}^i = \mathbf{Rot}(\vec{x}_{i-1}, \alpha_i) * \mathbf{Trans}(\vec{x}_{i-1}, a_i) * \mathbf{Rot}(\vec{z}_i, \theta^i) * \mathbf{Trans}(\vec{z}_i, r_i) \quad (1.4)$$

avec $\alpha_i, a_i, r_i, \theta_i$ les paramètres de l'articulation i . Le modèle géométrique direct s'obtient en multipliant successivement les matrices de transformations. Ainsi, nous pouvons réécrire l'équation (1.1) :

$$X = f(\xi, \theta) = T_{base\ robot}^1 * T_1^2 * T_2^3 * \dots * T_{n-1}^n * T_n^{effecteur} \quad (1.5)$$

avec ξ le vecteur rassemblant les paramètres géométriques du robot. Pour le KR300, en se basant sur les conventions de repères énoncées précédemment, le modèle DH-modifié obtenu est décrit dans la table 1.1.

1.2.2 Modèle Géométrique Inverse

Pour connaître la relation inverse, c'est à dire connaître la position articulaire menant à une position cartésienne de l'effecteur donnée, plusieurs méthodes existent, pouvant être classées en deux catégories : les méthodes analytiques et les méthodes numériques.

Les méthodes analytiques reposent sur l'inversion du modèle géométrique direct, proposant la résolution d'un système à au plus 6 équations (3 positions et 3 orientations de l'effecteur) pour $n_{articulations}$ inconnues. Pour des robots non redondants, il existe un nombre fini de solutions. En revanche, dans le cas de robots redondants, il existe une infinité de solutions. Ces solutions peuvent, au cas par cas, être paramétrées pour obtenir une expression analytique, comme c'est le cas pour l'*iiwa* par exemple

[Kuhlemann et al., 2016]. Dans [Paul, 1981], une méthode de calcul de géométrie inverse générique est développée pour les poignets sphériques : si les axes de rotations des trois dernières articulations d'un robot sont sécants en un même point, il est possible de calculer la position de ce point à partir de la position cartésienne désirée. Les valeurs des angles des 3 dernières articulations sont calculées pour correspondre à l'orientation commandée ; tandis que les valeurs des angles des 3 premières articulations sont calculées pour atteindre la position du poignet.

Les méthodes numériques reposent pour la plupart sur l'utilisation de la matrice Jacobienne J du modèle géométrique direct pour trouver une solution (parmi plusieurs possibles). Rappelons l'équation (1.5) $\vec{X} = f(\xi, \theta)$ et introduisons la matrice jacobienne cinématique $J(\theta)$:

$$J(\theta) = \begin{bmatrix} \frac{\partial f_1}{\partial \theta_1} & \frac{\partial f_1}{\partial \theta_2} & \dots & \frac{\partial f_1}{\partial \theta_n} \\ \frac{\partial f_2}{\partial \theta_1} & \frac{\partial f_2}{\partial \theta_2} & \dots & \frac{\partial f_2}{\partial \theta_n} \\ \dots & \dots & \dots & \dots \\ \frac{\partial f_6}{\partial \theta_1} & \frac{\partial f_6}{\partial \theta_2} & \dots & \frac{\partial f_6}{\partial \theta_n} \end{bmatrix} \quad (1.6)$$

Afin de simplifier les notations, la matrice jacobienne cinématique $J(\theta)$ sera notée J ci-après. Un petit déplacement de l'effecteur $\delta\vec{X}$ peut alors s'exprimer en fonction d'une petite variation de la position articulaire $\delta\vec{\theta}$ par l'équation :

$$\delta\vec{X} = J * \delta\vec{\theta} \quad (1.7)$$

A partir de cette équation, le modèle géométrique inverse d'un robot peut être calculé numériquement [Siciliano and Khatib, 2007]. Cela revient à un problème d'optimisation, dans lequel le critère à minimiser correspond à la distance entre d'une part la position cartésienne à atteindre $X_{commande}$ et d'autre part la position cartésienne $X_{initiale}$ correspondant à la position articulaire du robot $\theta_{initial}$:

$$X_{commande} - X_{initiale} = J(\vec{\theta}) * (\theta_{solution} - \theta_{initial}) \quad (1.8)$$

Cette équation peut se résoudre en utilisant la méthode des moindres carrés, explicitée en section 1.3, et ce, même si le robot est redondant.

1.2.3 Modélisation des défauts géométriques

Le modèle géométrique direct utilise les paramètres géométriques nominaux du robot, donnés par le constructeur. Or, les tolérances de fabrication et d'assemblage des composants du robot induisent des défauts géométriques : les longueurs réelles des liens et leurs orientations relatives peuvent être différentes de leurs valeurs nominales, ce qui a pour effet de provoquer des erreurs de positionnement. Pour identifier les paramètres géométriques réels, la plupart des méthodes que l'on peut trouver dans

la littérature peuvent être exprimées par un problème d'optimisation. En effet, estimer les paramètres géométriques réels revient à trouver le vecteur ξ minimisant l'écart entre les positions cartésiennes mesurées et le résultat de l'équation (1.5). Pour se faire, la méthode la plus couramment utilisée est celle des moindres carrés (explicitée en détail dans la section 1.3), basée sur la matrice jacobienne "généralisée" J_G avec :

$$J_G = \begin{bmatrix} \frac{\partial f_1}{\partial \alpha_1} & \frac{\partial f_1}{\partial a_1} & \frac{\partial f_1}{\partial \theta_{0,1}} & \frac{\partial f_1}{\partial r_1} & \frac{\partial f_1}{\partial \alpha_2} & \cdots & \frac{\partial f_1}{\partial r_n} \\ \frac{\partial f_2}{\partial \alpha_1} & \frac{\partial f_2}{\partial a_1} & \frac{\partial f_2}{\partial \theta_{0,1}} & \frac{\partial f_2}{\partial r_1} & \frac{\partial f_2}{\partial \alpha_2} & \cdots & \frac{\partial f_2}{\partial r_n} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \frac{\partial f_6}{\partial \alpha_1} & \frac{\partial f_6}{\partial a_1} & \frac{\partial f_6}{\partial \theta_{0,1}} & \frac{\partial f_6}{\partial r_1} & \frac{\partial f_6}{\partial \alpha_2} & \cdots & \frac{\partial f_6}{\partial r_n} \end{bmatrix} \quad (1.9)$$

Ainsi, la différence entre la position mesurée \vec{X}_{mes} et la position théorique \vec{X}_{th} correspondante s'écrit :

$$\vec{X}_{mes} - f(\xi_{nominal}, \vec{\theta}_{commande}) = J_G * (\vec{\xi}_{reel} - \vec{\xi}_{nominal}) \quad (1.10)$$

avec ξ_{reel} les paramètres géométriques identifiés et $\xi_{nominal}$ les paramètres géométriques nominaux. La méthode des moindres carrés impose que le rang de J_G soit égal au nombre de paramètres identifiés. Par conséquent, il faut suffisamment de points de mesure pour que la dimension de J_G le permette, et qu'aucune des colonnes de J_G ne soit une combinaison linéaire des autres. En pratique, cela rend certains paramètres géométriques non identifiables. Par exemple, si deux articulations consécutives i et $i + 1$ sont parallèles, les deux paramètres a_i et a_{i+1} ne peuvent pas être identifiés simultanément.

1.2.4 Modélisation de la compliance des articulations

Le modèle géométrique direct du robot suppose que les articulations et les segments sont infiniment rigides. Or, plusieurs travaux font état d'une déformation de la structure du robot due d'une part à son propre poids, d'autre part à la masse de l'effecteur qu'il manipule [Klimchik et al., 2015, Olabi et al., 2012, Khalil and Besnard, 2002]. Cette déformation est principalement due à la déformation des engrenages dans les articulations ; la déformation des segments étant négligeable par rapport aux exigences de précision. Pour modéliser ce comportement, le modèle le plus utilisé est le modèle élasto-statique [Salisbury, 1980]. Il suppose que la déformation provient des articulations, les segments étant plus rigides [Khalil and Besnard, 2002]. Chacune des articulations est modélisée par un ressort de torsion de raideur K , comme illustré sur la figure 1.2. De cette manière, la déformation angulaire de l'articulation i peut être exprimée en fonction du couple appliqué à l'articulation :

$$\delta\theta_i = K_i^{-1} * \tau_i \quad (1.11)$$

1.2. MODÉLISATION

avec $\delta\theta_i$ la déformation angulaire résultante de l'articulation i , K_i sa raideur et τ_i le couple appliqué. Ce modèle n'ajoute donc qu'un seul paramètre par articulation. En généralisant pour toutes les articulations, nous obtenons :

$$\delta\vec{X}_{compliance} = J * K^{-1} * \vec{\tau} \quad (1.12)$$

avec J la Jacobienne cinématique, K la matrice (diagonale) des raideurs, et $\vec{\tau}$ le vecteur des couples appliqués à chacune des articulations. Le vecteur $\vec{\tau}$ peut se décomposer comme suit :

$$\vec{\tau} = \vec{\tau}_{robot} + \vec{\tau}_{payload} \quad (1.13)$$

avec

$$\vec{\tau}_{payload} = J^T * \vec{P} \quad (1.14)$$

où $\vec{P} = [F_x \ F_y \ F_z \ C_x \ C_y \ C_z]^T$ est le vecteur de charge appliqué à l'organe terminal (*flange*) du robot et exprimé dans le repère de base du robot.




FIGURE 1.2 – Principe du modèle élasto-statique

Pour identifier les raideurs, l'équation (1.11) suppose de connaître le couple appliqué à chacune des articulations $\vec{\tau}$. Dans [Besset et al., 2016], les raideurs des articulations d'un robot collaboratif ont pu être identifiées grâce à la présence de capteurs de couple internes sur chacune des articulations. Dans [Nguyen et al., 2015], le modèle de masse du robot, donné par le constructeur, a été utilisé pour estimer le couple appliqué à chacune des articulations, permettant finalement l'identification des raideurs. En revanche, la plupart des robots ne sont pas équipés de capteurs de couple internes, et leur modèle de masse est rarement connu. Dans ce cas, l'équation (1.11) peut être différenciée : en mesurant deux fois la position de l'effecteur, dans la même position articulaire, pour deux masses portées différentes,

1.2. MODÉLISATION

nous obtenons l'équation :

$$\Delta\delta\vec{X} = J * K^{-1} * \Delta\vec{\tau} \quad (1.15)$$

où $\Delta\vec{\tau}$ représente la différence de couple appliqué entre les deux mesures. Le robot étant dans la même configuration articulaire pendant les deux mesures, seule la différence de charge appliquée au *flange* du robot provoque la différence de position de l'effecteur [Dumas et al., 2011]. Néanmoins, identifier les raideurs via l'équation (1.15) ne permet de compenser que l'effet de $\vec{\tau}_{payload}$, puisque $\vec{\tau}_{robot}$ n'est pas connu.

De manière générale, le modèle élasto-statique présente deux inconvénients. D'abord, il suppose que la relation entre la déformation de l'articulation et le couple appliqué est linéaire, ce qui n'est pas toujours le cas. En effet, le terme $\delta\vec{\theta}$ provient principalement de la déformation des dents d'engrenages en contact. Or, cette déformation n'évolue pas linéairement : à faible couple, le contact entre deux dents est quasi-linéaire, mais à mesure que le couple augmente, la surface de contact augmente, ainsi la raideur augmente et la déformation évolue plus lentement. Ce phénomène est mis en évidence sur la figure 1.3, qui montre l'évolution de la déformation angulaire sur des engrenages en fonction du couple appliqué [Tuttle, 1992]. Nous observons une non-linéarité de la relation, ainsi qu'un phénomène d'hysteresis. Dans [Kircanski et al., 1993], un modèle élasto-statique non linéaire à été proposé. L'identification des deux paramètres par articulations nécessite alors d'avoir plusieurs valeurs de couple bien différentes pour mettre en lumière la non-linéarité. Le protocole expérimental devient alors très complexe.




FIGURE 1.3 – Déformation angulaire en fonction du couple appliqué sur des engrenages [Tuttle, 1992]

Le deuxième inconvénient du modèle représenté par l'équation (1.11) est le fait qu'il suppose que la déformation due au couple se fait uniquement dans la direction de l'axe de rotation. Pour pallier à ce second inconvénient, les méthodes d'analyse structurelle matricielles ajoutent des degrés de liberté

possibles dans les déformations dues à la charge [Klimchik et al., 2019, Rezaei and Akbarzadeh, 2018]. Ce modèle est plus complet, mais il nécessite l'identification de beaucoup plus de paramètres (jusqu'à 6 par articulations), et ne prends pas en compte le premier inconvénient de la méthode précédente (l'augmentation de la raideur dans la direction de l'axe à mesure que le couple appliqué augmente).

Enfin, les méthodes d'analyse par éléments finis permettent une modélisation très précise des phénomènes de déformation dus au poids propre du robot et au poids de l'effecteur [Klimchik et al., 2013, Wang et al., 2006, ao Cao et al., 2018]. En revanche, elles nécessitent d'avoir un modèle CAO complet du robot, ce qui n'est que très rarement le cas.

1.2.5 Modélisation des erreurs de transmission

L'erreur de transmission désigne la différence entre la position réelle de la roue menée et sa position théorique si le réducteur à engrenage était parfait. Dans la littérature, on distingue deux sources d'erreurs de transmission : le *backlash* et les irrégularités cinématiques [Tuttle, 1992].

1.2.5.1 Le *backlash*

Les erreurs de transmission (*backlash*) correspondent à un écart entre les dents de deux engrenages supposés être en contact. Comme illustré sur la figure 1.4, en fonction du couple appliqué, l'écart sera de l'un ou de l'autre coté de la dent en question. Cette écart induit une différence angulaire : la roue motrice est actionnée et est en mouvement alors qu'elle n'entraîne pas la roue menée, ce qui peut causer plusieurs dixièmes de millimètres d'erreur de positionnement de l'effecteur, en particulier sur des robots de grande taille. En effet, un déplacement de $143 \mu\text{m}$ de l'effecteur d'un robot industriel causé par le phénomène de *backlash* a été mesuré dans [Slamani and Bonev, 2013].




FIGURE 1.4 – Phénomène de *backlash*

Pour compenser ce défaut, un modèle polynomial du backlash a été proposé dans [Slamani et al., 2012] où l'ordre du polynôme a été déterminé empiriquement. Les coefficients du modèle varient en fonction

de la configuration, de la vitesse et de la charge utile. Pour chaque re-configuration du robot, il faut donc ré-établir le modèle. Dans [Mazzini and Dubowsky, 2012], les paramètres du backlash sont identifiés sur un robot à 4 degrés de liberté via les capteurs de couple du robot : l'effecteur force un contact entre une surface primitive préalablement identifiée, et provoque volontairement le backlash en augmentant la force de contact, et donc le couple sur chacune des articulations. Dans [Burkus et al., 2020], des modèles dynamiques de friction, de backlash et de *self-lock* pour un robot hexapode ont été établis, et les paramètres de ces modèles ont été identifiés simultanément. Dans [Vakilinejad et al., 2019], un modèle non linéaire de défaut de transmission a été proposé pour compenser les défauts périodiques de positionnement lors de trajectoires réalisées à faible vitesse. L'analyse de la méthode d'identification a permis de définir une seule trajectoire à mesurer pour identifier les paramètres du modèle sur les 3 premières articulations du robot. Enfin, [Le Reun et al., 2022] ont développés un modèle de backlash pour la première articulation d'un robot industriel à 6 articulations, les 5 dernières étant soumis à un couple dont la direction ne varie pas. Par conséquent, seul l'actionnement de l'articulation 1 induit une variation de couple sur cet articulation, et donc provoque du backlash. Après identification des paramètres et compensation, le robot présente une erreur moyenne de $0,07mm$, proche de sa répétabilité. Pour cela, le backlash est modélisé par :

$$\theta_{i, backlash} = \theta_i + \text{sign}(\tau_i) * \delta\theta_{i, backlash} \quad (1.16)$$

avec $\theta_{i, backlash}$ la position angulaire de l'articulation i en prenant en compte le backlash, θ_i la position angulaire de l'articulation i mesurée via les encodeurs, τ_i le couple appliqué à l'articulation i , et $\delta\theta_{i, backlash}$ le décalage angulaire produit par le backlash. L'erreur de positionnement peut alors être déduite par :

$$\Delta\vec{X}_{backlash} = J * (\text{sign}(\vec{\tau}) * \delta\vec{\theta}_{backlash}) \quad (1.17)$$

Toutefois, il est nécessaire de connaître les couples τ_i appliqués, ce qui est rarement le cas en pratique.

1.2.5.2 Les irrégularités cinématiques

Les irrégularités cinématiques proviennent de défauts de fabrication et d'assemblages des roues menantes et menées d'un système d'engrenages. Ces défauts ont été mis en évidence expérimentalement dans [Tuttle, 1992], où un banc de test comportant uniquement deux engrenages a été utilisé, puis le mécanisme d'apparition de ces défauts a été expliqué dans [Ghorbel et al., 1998]. Ainsi, il est apparu que ces défauts sont périodiques, avec une fréquence égale à deux fois la vitesse de rotation de la roue menante.

Plus tard, il a été montré que ces défauts sont aussi présents dans les chaînes de transmission utilisés dans les robots [Olabi et al., 2012, Olabi, 2011]. Ainsi, la figure 1.5 montre le défaut de transmission en fonction de la valeur d'angle commandée à l'articulation 2 d'un robot Staübli TX90, et son

1.2. MODÉLISATION




FIGURE 1.5 – Irrégularités cinématiques sur l’articulation 2 d’un robot Staübli TX90 [Olabi, 2011]

approximation par une fonction de type $a * \sin(b\theta + c)$. Cependant, l’identification des paramètres de ce modèle a requis un protocole long et complexe, devant être appliqué à chaque réducteur présent dans le robot. Pour faciliter l’identification, [Vakilinejad et al., 2019] propose une méthode permettant d’identifier simultanément les paramètres de ce modèle pour chacune des articulations du robot, en projetant une trajectoire cartésienne complexe dans l’espace articulaire. En revanche, la trajectoire a été discrétisée avec un pas très fin pour les besoins de la méthode, menant tout de même à un protocole long.

1.2.6 Modélisation de la dérive thermique

Dans un scénario d’utilisation classique, les robots industriels sont employés pour des tâches répétitives. La notion de répétition est source d’échauffement des moteurs à l’intérieur du robot. Cette augmentation de la température induit des déformations de la structure du robot. Pour compenser cette dérive thermique, il existe plusieurs méthodes. D’abord, on peut simplement programmer un cycle de chauffe, pour utiliser le robot uniquement lorsque le phénomène s’est stabilisé. Cette méthode présente plusieurs inconvénients. Premièrement, le temps de stabilisation dépend du robot (en particulier des matériaux qui le constituent : acier ou aluminium). Il faut donc connaître au préalable le temps de stabilisation de la dérive thermique, ce qui requiert un instrument de mesure de la position de l’effecteur. Deuxièmement, à chaque arrêt du robot (maintenance, utilisation ponctuelle etc.), le cycle de chauffe doit être itéré, ce qui conduit donc à des temps d’immobilisation du robot importants, difficilement compatible avec des contraintes industrielles.

Une autre méthode de compensation de la dérive thermique consiste à mesurer directement cette dérive au cours de la tâche à réaliser. Pour un robot dont la tâche va être répétitive, avec peu de variations, on cherche à connaître quel sera le déplacement cartésien de l’effecteur en fonction du temps ou de la température [Le Reun et al., 2022, Eastwood and Webb, 2009, Gong et al., 2000]. L’inconvénient majeur est que si la tâche du robot est amenée à changer, il faut recommencer le protocole.

En particulier, si la trajectoire change, ou si les vitesses et accélérations des articulations du robots changent, le protocole doit être refait entièrement.

Dans [Santolaria et al., 2009, Li and Zhao, 2016], un terme dépendant de la température est ajouté à chacun des paramètres géométriques d'un robot. Ce terme dépend de la température du lien ou de l'articulation en question, or le plus souvent seul les articulations sont équipés de capteurs de température. Il faut donc un moyen de mesure externe pour mesurer la température des liens [Chen et al., 1991, Yuan and Ni, 1998]. De plus, identifier le terme dépendant de la température requiert donc plusieurs mesures de positions avec plusieurs températures différentes, ce qui impose un montage expérimental complexe. Il est également possible de calculer la déformation due à la température via une méthode par éléments finis, en utilisant le modèle CAO du robot [Li and Zhao, 2016, Cristoiu et al., 2020]. En revanche, cette méthode est très peu appliquée en pratique, les modèles CAO des robots n'étant jamais communiqués par les constructeurs.

1.3 Identification des paramètres

Les modèles explicités dans la section précédente se basent sur des paramètres (longueur des bras, compliance des articulations, coefficients de dilatation thermique...) dont les valeurs sont initialement inconnues : ces paramètres doivent être identifiés. Le problème de l'identification des paramètres peut s'écrire sous la forme d'un problème d'optimisation consistant à minimiser l'écart entre la prédiction du modèle analytique et l'observation des résultats en fonction des paramètres du modèle. Bien que plusieurs chercheurs aient utilisé d'autres méthodes, telles que les algorithmes génétiques [Fan et al., 2015, Sun et al., 2018], les filtres de Kalman [Nguyen et al., 2015] ou encore les méthodes basées sur l'estimation de la vraisemblance [Ma et al., 2018], la méthode la plus largement utilisée est celle des moindres carrés [Björck, 1990]. Cette approche vise à minimiser la somme des carrés des écarts entre les valeurs mesurées et les valeurs prédites par le modèle. Lorsque les estimations des paramètres ont été obtenues à l'aide des moindres carrés, il est également important d'évaluer leur précision. Les intervalles de confiance fournissent une estimation de l'incertitude associée à ces estimations.

1.3.1 Principe mathématique des moindres carrés

La méthode des moindres carrés repose sur le principe de minimiser la somme des carrés des résidus, c'est-à-dire les différences entre les valeurs observées et les valeurs prédites par le modèle. Soit un modèle non-linéaire avec m observations et p paramètres, représenté par la fonction $f(\mathbf{x}, \beta)$, où $\mathbf{x} = (x_1, x_2, \dots, x_m)$ est le vecteur des variables indépendantes et $\beta = (\beta_1, \beta_2, \dots, \beta_p)$ est le vecteur des paramètres à estimer. La méthode des moindres carrés cherche à trouver une estimation $\hat{\beta}$ des

1.3. IDENTIFICATION DES PARAMÈTRES

paramètres qui minimise la somme des carrés des résidus r_i :

$$S(\beta) = \sum_{i=1}^m r_i^2 \quad (1.18)$$

avec

$$r_i = y_i - f(\mathbf{x}_i, \beta) \quad (1.19)$$

La valeur minimale de $S(\beta)$ s'obtient lorsque les p gradients des paramètres β s'annulent :

$$\frac{\partial S}{\partial \beta_j} = 2 \sum_i r_i \frac{\partial r_i}{\partial \beta_j} = 0, \quad (j = 1, \dots, n) \quad (1.20)$$

Dans le cas de modèles non-linéaires, une première initialisation des paramètres β^0 est nécessaire. Ensuite, les paramètres sont affinés numériquement :

$$\beta^{\mathbf{k}+1} = \beta^{\mathbf{k}} + \Delta\beta \quad (1.21)$$

Pour calculer $\Delta\beta$, la fonction $f(\mathbf{x}, \beta)$ est linéarisée par une série de Taylor du premier ordre en β :

$$f(\mathbf{x}_i, \beta) \cong f(\mathbf{x}_i, \beta^{\mathbf{k}}) + \sum_j J_{ij} \Delta\beta_j \quad (1.22)$$

avec $J_{ij} = -\frac{\partial r_i}{\partial \beta_j}$. En injectant l'équation (1.22) dans l'équation (1.19), le problème revient à résoudre l'équation :

$$r_i = y_i - f(\mathbf{x}_i, \beta^{\mathbf{k}}) - \sum_j J_{ij} \Delta\beta_j \quad (1.23)$$

puis, en réinjectant cette équation dans l'équation (1.20), il suit :

$$\frac{\partial S}{\partial \beta_j} = -2 \sum_i J_{ij} * (y_i - f(\mathbf{x}_i, \beta^{\mathbf{k}}) - \sum_s J_{is} \Delta\beta_s) = 0 \quad (1.24)$$

En réarrangeant cette équation, et en écrivant sous forme matricielle le système des n équations, nous obtenons :

$$(J^T J) \Delta\beta = J^T \Delta y \quad (1.25)$$

avec $\Delta y = y - f(x, \beta^{\mathbf{k}})$ et $\Delta\beta$ donné par l'équation (1.21). Il est alors possible d'obtenir, itérativement, le vecteur des paramètres estimés $\hat{\beta}$ qui minimise $S(\beta)$. Notons que l'équation (1.25) n'est solvable que si $(J^T J)$ est inversible, ce qui n'est possible que si le rang de J est égal au nombre de paramètres à identifier. Puisque J est de dimension m, p avec m le nombre d'observations et p le nombre de paramètres, l'équation (1.25) n'est solvable que si J est de rang plein. En pratique, cela peut limiter le nombre de paramètres identifiables.

1.3.2 Intervalles de confiance

Une fois que les estimations des paramètres $\hat{\beta}$ ont été obtenues, il est possible de calculer les intervalles de confiance, qui fournissent une estimation de la plage de valeurs plausibles pour les vrais paramètres inconnus.

Les intervalles de confiance se calculent via une estimation de la matrice de covariance des paramètres. Cette matrice de covariance est donnée par :

$$\text{Cov}(\hat{\beta}) = \hat{\sigma}^2(\mathbf{J}^T \mathbf{J})^{-1} \quad (1.26)$$

où $\hat{\sigma}^2$ est l'estimation de la variance des résidus, calculée en divisant la somme des carrés des résidus par le nombre de degrés de liberté :

$$\hat{\sigma}^2 = \frac{S}{m - p} \quad (1.27)$$

L'intervalle de confiance à 95% pour le paramètres β_i est donné par :

$$\hat{\beta}_i \pm 2 \cdot \sqrt{\text{Var}(\hat{\beta}_i)} \quad (1.28)$$

D'après l'équation (1.27), l'intervalle de confiance se resserre à mesure que le nombre d'observations est grand par rapport aux nombres de paramètres à estimer.

1.4 Mesures

Les méthodes d'identifications explicitées dans la section précédente se ramènent toutes à minimiser l'écart entre un modèle théorique et un ensemble d'observations. Ces observations s'obtiennent via un protocole de mesures expérimental, dont les spécificités sont présentées dans les deux premières parties de cette section : d'abord, le choix de l'instrument de mesure sera justifié, puis les méthodes permettant d'identifier le repère de base robot dans le repère de l'instrument de mesure seront présentées et comparées. Enfin, la dernière partie de cette section présentera une mesure de la précision avant calibration et de la répétabilité du KR300, pour quantifier la marge de progression possible en terme d'erreur de positionnement, ainsi qu'un bilan des sources d'erreurs. Cette étude comparative des méthodes d'identification de repère de base robot et l'étude de précision et répétabilité ont fait l'objet d'un article de conférence [Selingue et al., 2023a].

1.4.1 Instruments de mesures

Le rôle de l'instrument de mesure est d'obtenir des observations pour identifier les paramètres du modèle géométrique direct. Il existe plusieurs instruments de mesure pouvant être utilisés pour la

calibration de robots industriels. L'un des systèmes de mesure le plus précis est la machine à mesurer tri-dimensionnelle : sa répétabilité de mesure est de l'ordre de $1\mu m$. Elle permet des mesures de grande précision pour un coût relativement élevé (environ 50 000€), mais son espace de mesure est restreint, et ne permet donc pas une calibration globale du robot (c'est-à-dire une calibration valable dans tout l'espace de travail) mais une calibration locale (c'est-à-dire valable dans un sous-espace de travail défini au préalable) [Driels et al., 1993, Nubiola et al., 2014].

De plus en plus de travaux sur la calibration des robots industriels utilisent un système de *ballbar*, issu des protocoles de qualification classiquement exploités pour les machines-outils : le principe est d'attacher une extrémité de la barre au robot, l'autre sur un support fixe, puis d'effectuer des mouvements circulaires avec le robot [Nubiola and Bonev, 2014, Wu et al., 2020]. La barre mesure les petites variations de déplacement des billes, situées à l'intérieur. Ce système offre une précision de l'ordre de $2\mu m$, mais souffre du même inconvénient que la machine à mesurer tri-dimensionnelle : il ne permet qu'une calibration locale. De plus, sa faible étendue de mesure (quelques millimètres) et la nécessité d'avoir des barres de différentes longueurs pour disposer de plus de mesures contraignent davantage son application. En revanche, son prix (environ 10 000€) est bien moins élevé que celui d'une machine à mesurer tri-dimensionnelle.

Il est également possible d'utiliser des systèmes de scan laser [Mazzoni et al., 2022], disponibles pour environ 15 000€ : en scannant des objets métrologiques (billes, cubes...), dont les positions sont connues, avec un scan laser fixé sur le *flange* du robot, la position du scan laser par rapport à la base du robot peut être calculée. Cette méthode nécessite de connaître la matrice de transformation entre le *flange* du robot et le scan laser, qu'il est possible de retrouver en utilisant la méthode des 4 points, explicitée dans [Shiu and Ahmad, 1989].

Plusieurs travaux utilisent des caméras pour calibrer des robots industriels [Zhuang et al., 1995, Bobby and Saha, 2016]. Le principe est d'estimer la position d'un objet identifiable (QR-code, plaque de calibration de caméra etc.) à partir d'une image capturée par la caméra, pour une configuration articulaire du robot donnée. Cette méthode permet de calibrer facilement l'ensemble de l'espace du travail du robot en utilisant plusieurs objets identifiables. En revanche, la précision de l'estimation de la position de l'objet à identifier dépend de la résolution de la caméra (ce qui peut faire grimper le prix de la caméra à plus de 20 000€), et des algorithmes d'estimation de position d'objets. De plus, il faut aussi identifier la transformation entre le *flange* du robot et la caméra, en suivant la méthode des 4 points [Shiu and Ahmad, 1989].

Le système de mesure le plus largement utilisé pour la calibration des robots est le laser tracker, bien que son coût soit élevé (50 à 80 000 €). Il mesure la distance entre la tête de mesure et une bille réfléchissante (appelée SMR), avec une précision de $15\mu m + 5\mu m/m$. Ainsi, il est nécessaire d'avoir un faisceau laser continu entre la tête de mesure et le SMR. Néanmoins, le SMR ne peut réfléchir qu'un

1.4. MESURES

faisceau compris dans un cône de 30° , ce qui contraint l'utilisation du laser tracker. Il est cependant possible d'utiliser une tête active (montrée sur la figure 1.6), asservie pour conserver le faisceau dans le cône. De la même manière que précédemment, la transformation entre le SMR (ou la tête active) et le *flange* du robot doit être identifiée avec la méthode des 4-points [Shiu and Ahmad, 1989]. Ainsi, c'est le système qui offre le plus de précision avec une utilisation moins contrainte que les systèmes *ball-bar* ou les machines à mesurer tri-dimensionnelles. C'est l'instrument qui sera utilisé dans la suite des expériences décrites dans ce manuscrit.



FIGURE 1.6 – Tête active, asservie pour conserver le faisceau du laser tracker dans le cône de réflexion

1.4.2 Identification du repère de base

Le laser tracker mesure la position du SMR dans un repère de référence associé à la tête de mesure. Or, pour effectuer la calibration d'un robot industriel, il faut connaître la position du *flange* dans le repère de base du robot, comme illustré sur la figure 1.7. Si la transformation entre le *flange* et le SMR est habituellement identifiée en utilisant la méthode des 4 points [Shiu and Ahmad, 1989], il n'y a pas de consensus sur les méthodes d'identification du repère de base robot. Il paraît donc nécessaire de recenser les méthodes existantes, et de les comparer d'abord qualitativement, puis en terme de répétabilité et de précision de mesure.

1.4.2.1 Méthodes existantes

Pour identifier le repère de base du robot dans le repère de mesure du laser tracker, il existe plusieurs méthodes dans la littérature :





FIGURE 1.7 – Identification des repères de bases et effecteur. Les axes \vec{x} , \vec{y} , \vec{z} des repères robot et Laser Tracker sont respectivement représentés en rouge, vert et bleu.


- L-frame path : l'effecteur du robot se déplace à partir d'une origine définie arbitrairement selon deux axes, par exemple \vec{x}_{world} et \vec{z}_{world} . Le repère robot est défini selon les axes ainsi parcouru, en faisant translater l'origine définie arbitrairement. Cette méthode à été présentée dans [Yuan et al., 2018], et est décrite sur la figure 1.8.
- Mesure de 2 cercles : une rotation de l'articulation 1, puis de l'articulation 2, est commandée au robot, toutes deux à partir d'une même configuration articulaire de référence (dans laquelle l'articulation 1 est à 0°). A partir des deux cercles obtenus, les vecteurs normaux sont déduits. Ils représentent le plus souvent l'axe \vec{z}_{world} et l'axe \vec{y}_{world} (d'après le choix le plus courant du repère de base, comme expliqué dans la section 1.2.1). L'intersection des deux axes, projetée sur l'axe \vec{z}_{world} , donne l'origine du repère de base du robot [Besset et al., 2016]. Cette méthode est illustrée sur la figure 1.9.
- Mesure de 3 cercles : cette méthode à été présentée dans [Zeng et al., 2017]. Sur le robot à l'étude,

à partir de la configuration "HOME" du robot (définie par le constructeur), les déplacements respectifs de l'effecteur lorsque le robot tourne autour des axes de rotation des articulations 1, puis 2, puis 4 sont mesurés. A partir de ces mesures, 3 cercles sont définis. L'axe du cercle 1 définit \vec{z}_{world} ; l'axe du cercle 4 définit \vec{x}_{world} ; et l'origine du repère est défini par l'intersection entre d'une part, le plan parallèle au plan contenant le cercle 1 et passant par l'axe du cercle 2, et d'autre part \vec{z}_{world} .

- Mesure de 2 plans : dans [Placzek and Piszczek, 2018], deux plans sont mesurés en commandant le robot manuellement, et permettent de définir \vec{z}_{world} et \vec{x}_{world} , via leurs normales respectives. L'origine du repère est définie via une position articulaire arbitraire du robot.
- Identification à partir de points mobiles : dans [Kleinkes and Loser, 2011, Morozov et al., 2016], le repère de base est identifié en mesurant la position de l'effecteur dans plusieurs configurations articulaires. Pour cela, la méthode des moindres carrés est appliquée à partir de l'équation (1.25) ($(J^T J)\Delta\beta = J^T \Delta y$). Ici, β est le vecteur rassemblant les 6 paramètres décrivant la transformation entre le repère de base robot théorique et le repère réel, et Δy représente la différence entre les positions cartésiennes commandées et celles observées avec le laser tracker. Le repère de base est identifié comme celui qui minimise les résidus i.e. l'écart entre les positions cartésiennes réellement atteintes et les positions commandées. Cette méthode est habituellement faite conjointement avec la calibration géométrique. En revanche, le repère de base étant souvent choisi parallèle au repère de la 1^{ère} articulation (voir section 1.2.1), certains paramètres géométriques ne sont plus identifiables.




(a) Trajectoire planifiée via le logiciel RoboDK

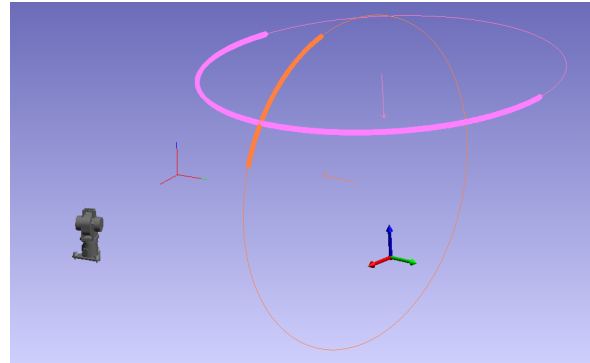


(b) Trajectoire mesurée via le Laser Tracker sur le logiciel Spatial Analyzer

FIGURE 1.8 – Méthode *L-path* pour l'identification de repère de base robot



(a) Trajectoire planifiée via le logiciel RoboDK



(b) Trajectoire mesurée via le Laser Tracker sur le logiciel Spatial Analyzer

FIGURE 1.9 – Méthode *2-cercles* pour l'identification de repère de base robot

1.4.2.2 Comparaisons des différentes méthodes

Qualitativement, nous pouvons noter que les méthodes 2-cercles et 3-cercles sont très similaires. La différence majeure est que l'articulation 4 permet d'identifier l'axe \vec{x}_{world} dans la méthode 3-cercles alors que l'articulation 2 permet d'identifier l'axe \vec{y}_{world} dans la méthode 2-cercles. Cette dernière méthode met en jeu moins d'articulations, et serait donc moins sensible à certains défauts comme les offsets des articulations 2 et 3, par rapport à la méthode 3-cercles. L'avantage de ces méthodes est qu'elles mettent en jeu des articulations individuellement. La méthode *L-path* et la méthode 2-plans sont similaires et présentent le même inconvénient : l'origine du repère est déterminé via le modèle géométrique inverse du robot, qui est imprécis. Néanmoins, ces méthodes sont très rapides à mettre en oeuvre : la méthode *L-path* par exemple est efficace pour mettre en place rapidement un repère local dans un sous-espace de travail.

A partir des éléments donnés précédemment, il paraît pertinent d'évaluer la répétabilité et la précision de 3 de ces méthodes : la méthode 2-cercles, car elle ne met pas en jeu le modèle géométrique du robot ; la méthode *L-path*, car elle est rapide à mettre en oeuvre, et permet de construire des repères locaux là où c'est nécessaire (puisque l'origine est choisie arbitrairement à partir d'une position de référence commandée au robot, il paraît aussi pertinent de quantifier l'influence qu'a ce choix), et la méthode des points mobiles, pour sa mise en pratique conjointe avec l'identification des paramètres géométriques.

Pour étudier la répétabilité des méthodes, le test suivant a été conduit sur le KR300 : chacune des méthodes a été appliquée 5 fois, successivement. La méthode 2-cercles est appliquée en effectuant une mesure continue de la position de l'effecteur du robot. L'articulation 1 décrit une trajectoire de 180° , et l'articulation 2 décrit une trajectoire de 60° . A partir des nuages de points correspondants aux

deux trajectoires, les caractéristiques des cercles sont extraites via la méthode des moindres carrés. La méthode *L-path* a été appliquée en deux points différents, pour étudier l'influence de l'origine arbitrairement choisie. Les résultats seront présentés sous les noms *L-path* (1) et *L-path* (2). Après avoir mesuré la position de l'effecteur à l'origine du repère, le robot décrit une ligne droite selon \vec{x}_{world} et \vec{z}_{world} de $30cm$ à vitesse faible. Au cours de ces trajectoires, la position de l'effecteur est mesurée en continue. De la même manière, les caractéristiques des lignes droites sont extraites via la méthode des moindres carrés. La méthode des points mobiles a été appliquée avec 10 points répartis dans tout l'espace de travail du robot, représentés sur la figure 1.10. Le repère de base du robot est aussi retrouvé grâce à une méthode des moindres carrés. L'ensemble du test a duré moins de trois heures, au cours desquels la température de la pièce et des articulations du robot n'a pas varié significativement.

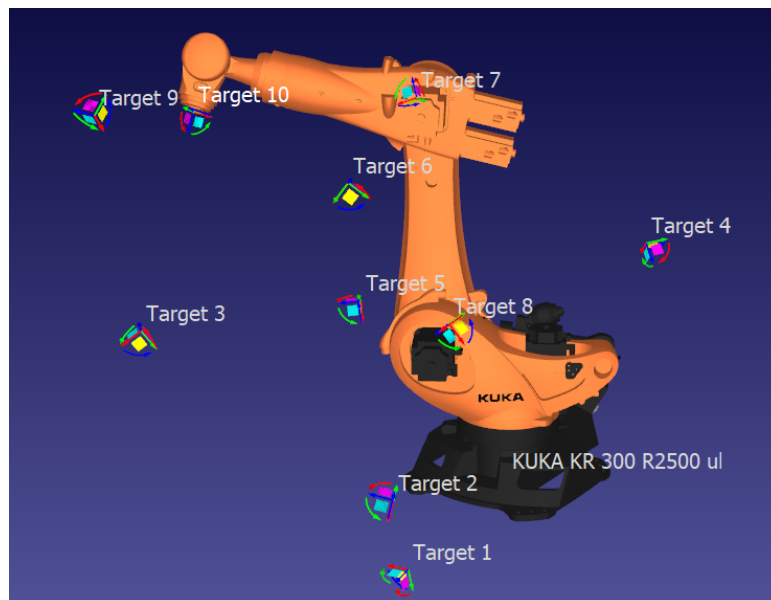


FIGURE 1.10 – Répartition des *points mobiles* dans l'espace de travail du KR300

L'objectif du test est de comparer les performances de chacune de ces méthodes, à la fois en terme de réduction de l'erreur de positionnement et de répétabilité. Les résultats obtenus sur un ensemble de points de validation (représentés sur la figure 1.11) sont présentés en figure 1.12 et dans la table 1.2. Sur la figure 1.12, la méthode *L-path* apparaît comme la moins performante, avec de plus une sensibilité notable provenant de l'origine arbitrairement choisie. Cela peut s'expliquer par le fait que lorsque le robot effectue les lignes droites pour identifier les axes \vec{x}_{world} et \vec{z}_{world} , la dynamique du robot est mise en jeu, bien que la vitesse et l'accélération de chaque articulation ont été limités à 10% de leurs valeurs maximales respectives. De plus, le robot et le Laser Tracker n'étant pas synchronisés, il revient à l'opérateur de lancer l'acquisition au bon moment, ce qui est source de non-répétabilité de la méthode. Par ailleurs, pour éviter de trop mettre en jeu des effets non désirés (erreurs de transmission, déformation de la structure du robot due à son poids), les trajectoires sont courtes ($30cm$). En revanche,

nous observons que les autres méthodes ne présentent pas de déviation significative. La table 1.2 montre l'erreur moyenne de positionnement entre des positions théoriques de l'effecteur, calculées par le contrôleur du robot avec le modèle géométrique nominal, et les positions mesurées avec le Laser Tracker, en fonction des méthodes d'identification de base. Nous retrouvons la plus faible répétabilité des méthodes *L-path* (écart type plus grand), et en outre elles sont moins performantes pour réduire l'erreur de positionnement (moyenne plus grande). Enfin, nous pouvons constater qu'identifier la base robot avec la méthode des points mobiles permet les meilleurs résultats, à la fois en terme de réduction de l'erreur de positionnement moyenne et de répétabilité. Néanmoins, il n'est pas possible d'identifier à la fois le repère de base robot et les 4 premiers paramètres du modèle géométrique, car ils sont redondants : la matrice jacobienne généralisée n'est alors pas de rang plein, et la méthode des moindres carrés ne peut aboutir. Pour cette raison, la méthode *2-cercles*, dont les performances sont assez proches de la méthode des points mobiles, sera préférée dans la suite du manuscrit pour identifier le repère de base robot.




FIGURE 1.11 – Répartition des points de validations dans l'espace de travail du robot.

1.4.3 Précision et répétabilité

Avec le choix d'un instrument de mesure adapté et son repérage par rapport à la base robot effectué, il est maintenant possible d'évaluer la précision et la répétabilité du KR300. La précision et la répétabilité d'un robot se mesurent selon la norme ISO 9283 [ISO 9283 :2012, 2012], établie en 2012. D'après cette norme, la répétabilité est "l'étroitesse de l'accord entre les poses atteintes pour la même pose commandée répétée", et la précision (ou exactitude) est "l'écart entre une pose commandée et la moyenne des poses atteintes". Pour mesurer ces deux valeurs, il faut d'abord définir un cube (dénommé

1.4. MESURES




FIGURE 1.12 – Déviation des repères de base robot identifié pour chaque test par rapport au barycentre

ci-après "cube ISO") dans l'espace de travail du robot, remplissant les conditions suivantes :

- le cube ISO doit être le plus grand possible dans l'espace du travail du robot
- les arêtes du cube ISO doivent être parallèles aux axes du repère de base robot

La répétabilité et la précision se mesurent sur 4 des sommets et sur le point central du cube ISO. Le protocole est le suivant : le robot doit visiter chacun de ces points, tour à tour et dans le même ordre, 30 fois consécutives, sans porter de charge ni être restreint en vitesse ou accélération maximale. Ensuite, la précision du point i , notée AP_i , est calculée comme suit :

$$AP_i = \sqrt{(\bar{x} - x_c)^2 + (\bar{y} - y_c)^2 + (\bar{z} - z_c)^2} \quad (1.29)$$

avec \bar{x} , \bar{y} , \bar{z} les coordonnées du barycentre du nuage de points mesurés et x_c , y_c , z_c les coordonnées de la position cartésienne commandée. Quant à la répétabilité du point i , elle est calculée par :

$$RP_i = \bar{l} + 3\sigma_X \quad \text{avec} \quad \bar{l} = \frac{\sum_{i=1}^{30} \sqrt{(\bar{x} - x_i)^2 + (\bar{y} - y_i)^2 + (\bar{z} - z_i)^2}}{n} \quad (1.30)$$

où x_i , y_i , z_i sont les coordonnées de la i -ième position atteinte et σ_X l'écart type des positions mesurées. La figure 1.13 montre le résultat du test. La précision et la répétabilité globale du robot sont les valeurs les plus élevées parmi les 5 calculées pour chacun des points visités lors du test. Ainsi, le KR300 présente donc une répétabilité de $0,056mm$, tandis que sa précision est de $1,91mm$.

1.4. MESURES

Méthode	Itération					Moyenne	Écart-type
	1	2	3	4	5		
2-cercles	1,345	1,332	1,369	1,359	1,353	1,351	0,0125
<i>L-path</i> (1)	1,692	1,702	1,754	1,706	1,679	1,707	0,0255
<i>L-path</i> (2)	2,224	2,206	2,214	2,181	2,252	2,215	0,0231
Points mobiles	1,043	1,034	1,025	1,017	1,035	1,031	0,0088

TABLE 1.2 – Erreur moyenne sur 10 points de tests des repères de base robot




FIGURE 1.13 – Précision et répétabilité du KR300

1.4.4 Bilan des sources d'erreurs

Après avoir quantifié la précision du KR300, nous quantifions à présent l'influence de chaque source d'erreur sur la précision. Ainsi, pour chacune des sources d'erreurs, un protocole expérimental a été mis en oeuvre. Afin d'obtenir un bilan équitable, tous les protocoles ont été réalisés dans le même cube ISO, montré sur la figure 1.13.

1.4.4.1 Défauts géométriques

Les défauts géométriques peuvent être observés en regardant la différence entre l'erreur de positionnement avant calibration géométrique et après calibration géométrique. Pour cela, la calibration géo-

métrique du KR300 a été effectuée en mesurant un ensemble de 70 points répartis équitablement dans l'ensemble de l'espace de travail du robot, et suivant le protocole défini dans [Dombre and Khalil, 2007], via la méthode des moindres carrés. Les paramètres géométriques ainsi obtenus sont décrits dans la table 1.3. Cette table est à mettre en comparaison avec les paramètres géométriques nominaux donnés dans la table 1.1. En particulier, nous faisons remarquer que les valeurs identifiées de a_3 et $\theta_{0,2}$ sont éloignées de $0,5mm$ et $0,2^\circ$ respectivement de leurs valeurs nominales.

TABLE 1.3 – Paramètres géométriques identifiés du KR300


Articulation	a (mm)	α ($^\circ$)	d (mm)	θ ($^\circ$)
1	-0,164	0,0008	675,14	$-\theta_1 + 0,0250$
2	349,63	-89,9987	0,29	$\theta_2 + 0,2043$
3	1150,50	0,0183	0 ^a	$\theta_3 - 90,0461$
4	-41,23	-90,0072	999,91	$-\theta_4 - 0,0006$
5	0,06	90,0073	0,03	$\theta_5 + 0,0027$
6	0,05	-90,0169	240,09	$-\theta_6 + 179,928$

^a. Ce paramètre ne peut pas être identifié en raison d'une perte de rang dans la matrice jacobienne généralisée J_G , comme expliqué dans la section 1.3

Sur un ensemble de 50 points sélectionnés dans le cube ISO, l'erreur de positionnement avant calibration géométrique s'élève à $1,88mm$ en moyenne, tandis que l'erreur de positionnement après calibration géométrique a été réduite à $0,4mm$ en moyenne. La distribution de l'erreur de positionnement sur l'ensemble de 50 points ainsi qu'une vue 3D du champs des vecteurs d'erreurs de positionnement sont représentés sur la figure 1.14

1.4.4.2 Compliance des articulations

Pour observer ce phénomène, il a été commandé au robot 50 positions articulaires, situées dans le cube ISO, avec une charge utile de 4 kg. Ensuite, ces mêmes 50 positions articulaires ont été commandées à nouveau, avec cette fois-ci une charge utile de 120 kg. Si le robot était infiniment rigide, il ne devrait pas y avoir de différence (aux incertitudes de mesures près) entre les positions cartésiennes mesurées avec une charge de 4 kg et celles mesurées avec une charge de 120 kg. Or, cette différence s'élève en réalité à $0,4mm$ en moyenne, ce qui met en lumière la déformation de la structure du robot due à la charge portée. La figure 1.15 montre la distribution de l'erreur de positionnement due à la charge utile sur les 50 points de tests, ainsi que les vecteurs d'erreurs de positionnement.



(a) Distribution de l'erreur de positionnement après (b) Vecteurs d'erreurs de positionnement. Les erreurs calibration géométriques calculée sur 50 points sélectionnés dans le cube ISO. ont toutes été multipliés par un facteur commun, afin d'être visibles.

FIGURE 1.14 – Distribution de l'erreur de positionnement sur un ensemble de 50 points et vue 3D du champs des vecteurs d'erreurs de positionnement après calibration géométrique

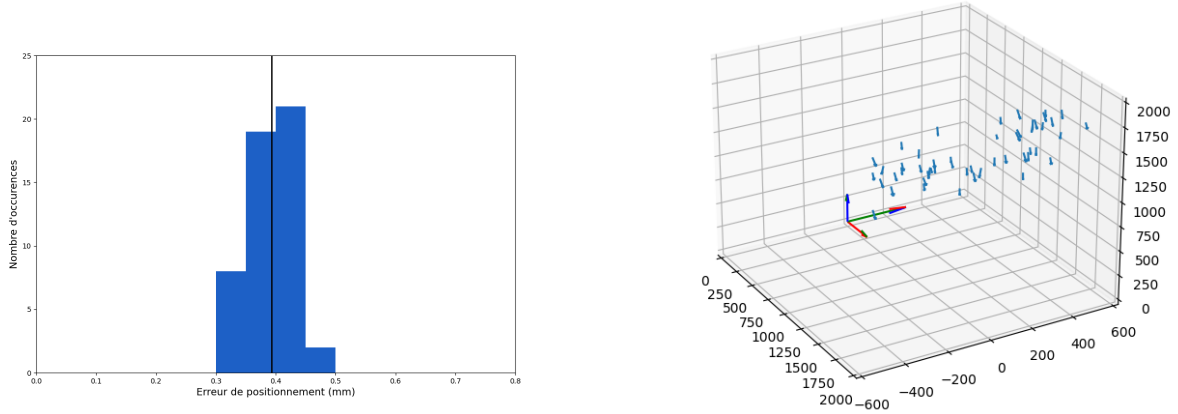
1.4.4.3 Dérive thermique

Pour quantifier la dérive thermique, il a été commandé au robot de visiter 6 points, situés sur les arêtes du cube ISO, les uns à la suite des autres, comme illustré sur la figure 1.16. Cette opération a été répétée en continu pendant 9h. A chacun des points, le robot s'arrête 3 secondes, pour que le Laser Tracker mesure la position du SMR, puis repart vers le point suivant. A la fin de chaque cycle de 6 points, la température de chacune des articulations est enregistrée via les capteurs thermiques internes. Pour des raisons de sécurité, la vitesse et l'accélération angulaire ont été réduites à 40% de leurs capacités maximales respectives au cours de la trajectoire.

La figure 1.17 montre l'évolution de la température de chacune des articulations en fonction du temps. Nous observons, pour chacune des articulations, une adéquation visuelle avec la réponse indicelle d'un système du premier ordre :

$$T(t) = A_T * (1 - e^{-\frac{t}{\tau_T}}) + T_0 \quad (1.31)$$

En faisant correspondre ce type de modèle avec les courbes obtenus, et en fixant la constante de temps égale pour toutes les articulations, nous obtenons les modèles explicités sur chacune des courbes de la figure 1.17. La constante de temps est de 1h40min, ce qui signifie que le temps de réponse à 5%, que nous considérons comme temps de stabilisation, est d'environ 5h. Nous observons aussi que certaines articulations s'échauffent plus que d'autres, en fonction de leurs sollicitations. Ainsi, l'articulation 2 s'échauffe de presque 20°, tandis que l'articulation 6 de seulement 8°.



(a) Distribution de l'erreur de positionnement due à une différence de charge utile calculée sur 50 points sélectionnés dans le cube ISO. (b) Vecteurs d'erreurs de positionnement due à une différence de charge utile. Les erreurs ont toutes été multipliées par un facteur commun, afin d'être visibles.

FIGURE 1.15 – Distribution de l'erreur de positionnement due à une différence de charge utile sur un ensemble de 50 points et vue 3D du champs des vecteurs d'erreurs de positionnement.

De même, la déviation totale de 3 des 6 points visités est montrée sur la figure 1.18. Nous pouvons également considérer que la dérive en position de l'effecteur en fonction du temps peut être décrite par une équation de la forme :

$$\Delta X_T(t) = A_X * (1 - e^{-\frac{t}{\tau_X}}) + X_0 \tag{1.32}$$

En identifiant les paramètres avec les données mesurées, et en fixant à nouveau la constante de temps comme étant la même pour tout les modèles, nous observons que l'amplitude du déplacement peut atteindre $0,2mm$, alors que la constante de temps est de l'ordre de 3h. Ainsi, le temps de stabilisation est de 9h environ. Ce temps de stabilisation n'est pas en adéquation avec les préconisations du constructeur, qui recommande un cycle de chauffe de 30 min par défaut avant utilisation du robot. Par ailleurs, la dérive observée n'est pas homogène : certains points sont plus affectés que d'autres. En particulier, le point n°5 ne souffre presque pas d'erreur de positionnement au cours du temps (amplitude de $0,071mm$) tandis que le point n°4 a une amplitude de déplacement au cours du temps de $0,3mm$.

1.4.4.4 Erreurs de transmissions

Pour observer les erreurs de transmissions, il a été commandé au robot de parcourir une diagonale du cube ISO, dans un sens puis dans l'autre, sans arrêt intermédiaire. La figure 1.19 montre une vue 3D de cette trajectoire. Nous observons clairement un saut de la position, explicable par le *backlash* :




FIGURE 1.16 – Localisation des 6 points de la trajectoire de test

pour parcourir la trajectoire en sens inverse, les couples appliqués à chacun des articulations changent de signe. L'écart relevé entre les deux trajectoires (sens direct et sens inverse) est de $0,3mm$.

1.4.4.5 Bilan

La table 1.4 présente le bilan de l'effet des différentes sources d'erreurs, relativement à la précision du modèle géométrique nominale (obtenue en section 1.4.4.1). Il est important de noter que la précision du modèle géométrique nominale a été mesurée alors que la température des articulations du robot étaient faibles, et que le robot ne portait pas de charge utile. Ainsi, l'erreur de positionnement avant calibration géométrique est provoquée par les défauts géométriques, la déformation des articulations due au poids propre du robot et aux erreurs de transmissions. A la lumière de ce bilan, on observe que les défauts géométriques induisent l'erreur de positionnement la plus élevée. De plus, on constate que pour une charge utile de 120 kg (35% de la charge maximale), l'erreur de positionnement augmente de 20%. De la même manière, pour des trajectoires courtes situés dans le cube ISO, à 40% de la vitesse maximale, avec des arrêts réguliers, la dérive thermique peut augmenter l'erreur de positionnement de 10%.

1.5 Compensation

Les méthodes de calcul du modèle géométrique inverse discutées précédemment reposent sur le modèle géométrique direct. Compléter le modèle géométrique direct avec les modèles des erreurs explicités en section 1.2 interdit l'utilisation des modèles géométriques inverses classiques. En effet, après

1.5. COMPENSATION




FIGURE 1.17 – Température de chacune des articulations en fonction du temps

identification des paramètres géométriques, les articulations (initialement supposées parfaites) ne sont plus nécessairement perpendiculaires, parallèles ou sécantes. De ce fait, il n'est plus forcément possible de calculer analytiquement le modèle géométrique inverse du robot.

Pour remplacer le modèle géométrique inverse, [Dombre and Khalil, 2007] ont proposé un algorithme de compensation. Cet algorithme est décrit dans la figure 1.20a, avec une illustration sur 2 itérations sur un cas 2D en figure 1.20b. Il prend pour entrée la position cartésienne désirée. Via le modèle géométrique inverse nominal, une première configuration articulaire $\vec{\theta}_{i=0}$ est calculée. En utilisant un modèle géométrique inverse (plus précis que le nominal, par exemple), une position cartésienne théoriquement atteinte X_i est calculée. La différence entre X_{ref} et X_i (notée Δ_i) est alors déduite, et ajoutée à X_{ref} pour donner une position cartésienne virtuelle X'_i . A partir de cette position cartésienne, une nouvelle configuration articulaire est déduite via le modèle géométrique inverse, et les étapes précédentes sont répétées jusqu'à ce que Δ_i n'évolue plus. Cela veut alors dire que d'après le

1.6. CONCLUSION

	Valeur (mm)	%
Erreur de positionnement du modèle géométrique nominale	1,88	100 %
Répétabilité	0,051	3%
Défauts géométriques	1,2	65%
Compliance des articulations (charge utile de 120 kg)	0,4	20%
<i>Backlash</i>	0,3	15%
Dérive thermique	0,3	15%

TABLE 1.4 – Bilan de l’effet de certaines sources d’erreur par rapport à l’erreur de positionnement du modèle géométrique nominal.

modèle employé, la configuration articulaire θ_{finale} correspond parfaitement à la position cartésienne désirée X_{ref} . Cet algorithme peut être utilisé quel que soit le modèle employé, et nécessite en pratique moins de 10 itérations pour converger.

1.6 Conclusion

Dans ce chapitre, les méthodes de calibration analytiques ont été étudiées. Après avoir établi le modèle géométrique nominal, qui permet de calculer le modèle géométrique direct et inverse, les phénomènes physiques à l’origine des défauts de positionnements ont été décrits, ainsi que les méthodes de compensations associées. La mise en oeuvre de ces méthodes implique d’une part l’utilisation d’algorithmes d’identification de paramètres, le plus souvent la méthode des moindres carrés ; d’autre part un protocole expérimental permettant de mesurer la position de l’effecteur du robot par rapport à son repère de base. Ensuite, le protocole expérimental nécessaire pour obtenir des observations permettant l’identification de paramètres a été décrit. Les différents moyens de mesures ont été présentés, et le choix s’est porté sur le Laser Tracker pour la précision et l’étendue de mesure dont il dispose. En revanche, l’utilisation du Laser Tracker impose d’identifier la transformation entre le repère de base robot et le repère propre au Laser Tracker. Une étude expérimentale a été conduite [Selingue et al., 2023a] afin de comparer les différentes méthodes d’identification du repère de base robot présentées dans la littérature. Cette étude a montré que la méthode *2-cercles*, présenté dans [Besset et al., 2016], propose une bonne répétabilité, et est rapide à mettre en oeuvre. Par conséquent, cette méthode sera adoptée dans la suite du manuscrit.

Ce chapitre comporte également un bilan des sources d’erreurs du robot à l’étude. Ce bilan permet de mieux apprécier les avantages et inconvénients des méthodes de calibration analytiques, selon les


1.6. CONCLUSION

critères évoqués dans l'introduction de ce manuscrit, à savoir le nombre de données requises, le temps de mise en oeuvre, la complexité de mise en oeuvre, la précision du modèle et l'adaptabilité à de nouvelles tâches. A travers le bilan d'erreur, il apparaît que l'erreur de positionnement compensée par les différentes méthodes est inversement proportionnelle à la complexité de mise en oeuvre. En effet, les défauts géométriques sont responsables de la majeure partie des erreurs de positionnement, et les méthodes d'identifications des paramètres géométriques sont relativement simples à mettre en oeuvre. Compenser la compliance des articulations nécessite en revanche des connaissances sur le robot qui ne sont pas toujours disponibles, comme son modèle de masse, ou une mesure du couple sur chacune des articulations. De même, prédire les défauts de transmissions requiert également de connaître la direction du couple appliqué à chaque articulation, ce qui est rarement le cas. Enfin, les défauts thermiques nécessitent plusieurs heures de mesures afin de pouvoir être observés pleinement.


Ces éléments montrent que les méthodes de calibration analytiques pourraient permettre d'obtenir une précision satisfaisante pour des opérations nécessitant une précision élevée (comme l'usinage, le perçage ou l'assemblage) mais au prix d'une grande complexité de mise en oeuvre. Par ailleurs, ces méthodes ne sont pas toujours adaptables à une nouvelle tâche. En effet, la non-linéarité de la relation entre le couple appliqué et la déformation articulaire produite peut conduire à devoir identifier à nouveau les valeurs des raideurs pour la charge utile considérée. En outre, les modèles présentés dans ce chapitre sont non-stationnaires : un changement de l'un des paramètres d'utilisation du robot (charge utile, température environnante, trajectoire effectuée) peut affecter l'ensemble des phénomènes physiques dégradant la précision du robot.

Ces constats font émerger le besoin de méthodes de calibration à la fois performantes, simples et rapides à mettre en oeuvre, et reconfigurables. Pour l'ensemble de ces raisons, cette thèse s'est concentrée sur des méthodes de calibration hybride combinant le modèle analytique intégrant l'identification des paramètres géométriques, et un modèle d'apprentissage autonome. Le rôle de l'apprentissage autonome est de prédire l'erreur de positionnement résiduelle, et ainsi pouvoir améliorer la précision par l'algorithme de compensation (correction par anticipation). Les méthodes hybrides actuelles permettent des performances satisfaisantes en termes de précision, mais sont difficilement applicables dans un contexte industriel, car gourmandes en terme de données et peu reconfigurables. La suite de ce manuscrit se concentre sur la facilité d'application de ces méthodes dans un contexte industriel.


1.6. CONCLUSION




(a) Configuration articulaire correspondant au point 2



(b) Déviation de l'effecteur par rapport à la position initiale en fonction du temps pour le point 2




(c) Configuration articulaire correspondant au point 4



(d) Déviation de l'effecteur par rapport à la position initiale en fonction du temps pour le point 4



(e) Configuration articulaire correspondant au point 5



(f) Déviation de l'effecteur par rapport à la position initiale en fonction du temps pour le point 5

FIGURE 1.18 – Configurations articulaires et déviations de l'effecteur au cours du temps pour les points 2, 4 et 5.


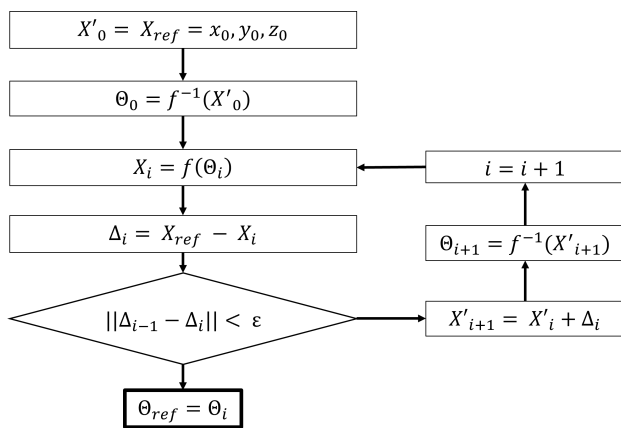



FIGURE 1.19 – Observation du backlash sur une diagonale du cube ISO



(a) Algorithme de compensation



(b) Exemple d'application de l'algorithme de compensation sur un cas 2D.

FIGURE 1.20 – Algorithme de compensation et illustration sur un cas 2D.

1.6. CONCLUSION

Chapitre 2

Amélioration de la reconfigurabilité des méthodes de calibration hybrides

Contenu

2.1	Introduction	42
2.1.1	Calibration analytique, calibration "boîte-noire"	42
2.1.2	Etat de l'art des méthodes de calibration hybrides	42
2.1.3	Contributions	45
2.2	Calibration hybride	46
2.2.1	Modèle analytique	46
2.2.2	Modèle d'apprentissage	47
2.3	Analyse expérimentale des méthodes de calibration hybrides	49
2.3.1	Application sur un robot collaboratif (<i>iiwa</i>)	49
2.3.2	Application sur un robot industriel "moyen porteur" (KR300)	53
2.4	Adaptabilité à une variation de la charge utile	55
2.4.1	Méthode 1 : apprentissage par transfert	56
2.4.2	Méthode 2 : interpolation de deux prédictions	59
2.5	Validation des méthodes	61
2.5.1	Évaluation de la performance des modèles proposés	61
2.5.2	Validation expérimentale	63
2.5.3	Discussion	65
2.6	Conclusion	66

2.1 Introduction

2.1.1 Calibration analytique, calibration "boîte-noire"

Les méthodes de calibration permettent à un robot industriel d'améliorer sa précision lorsqu'il est programmé "hors-ligne", c'est-à-dire à partir d'un modèle de son comportement. Dans le chapitre précédent, les méthodes de calibration analytiques ont été présentés. Elles ont pour objectif est d'améliorer la précision des robots industriels, afin d'élargir le spectre de leurs utilisations vers des applications d'usinage, de perçage ou d'assemblage. En effet, les méthodes de calibration analytiques permettent d'atteindre des précisions jusqu'à $0,2mm$ [Olabi, 2011, Le Reun et al., 2022], au prix d'un protocole expérimental lourd et de modèles analytiques complexes. En particulier, les méthodes de calibration analytiques requièrent souvent des informations non communiquées par les fabricants de robots, comme le modèle de masse ou les chaînes de transmissions utilisées.

Afin de simplifier le protocole expérimental, des méthodes de calibration "boîte-noire" ont été développées au début des années 1990. Le principe de ces méthodes "boîte-noire" est d'utiliser des modèles d'apprentissage automatique (*machine learning*) pour obtenir un modèle géométrique direct plus représentatif. Le plus souvent, les modèles d'apprentissage automatique en questions sont des réseaux de neurones. Ils peuvent être utilisés pour prédire la configuration articulaire à commander pour atteindre la position cartésienne désirée [Takanashi, 1990] ; prédire la position cartésienne qui sera atteinte pour une position cartésienne commandée donnée [Kumar et al., 2018] ou même prédire la position cartésienne qui sera atteinte en fonction de la configuration articulaire [Zhong et al., 1996]. En revanche, ces méthodes nécessitent un grand nombre de mesures, et sont peu reconfigurables : chaque changement de l'environnement du robot (charge utile, température), le modèle d'apprentissage doit être ré-entraîné avec de nouvelles données.

2.1.2 Etat de l'art des méthodes de calibration hybrides

Pour bénéficier des avantages des méthodes analytiques et "boîte-noire" sans souffrir de leurs inconvénients, les méthodes de calibration hybrides (ou "boîte-grise") sont apparues [Aoyagi et al., 2010, Nguyen et al., 2015, Gao et al., 2017, Nguyen et al., 2019, Zhao et al., 2019, Gadringer et al., 2020, Hsiao et al., 2020]. Ces méthodes sont illustrées sur la figure 2.1. Elles se basent sur le principe de la calibration analytique, mais ajoutent au modèle géométrique direct un réseau de neurones dont le rôle est de prédire l'erreur résiduelle (c'est-à-dire l'erreur de positionnement entre le modèle analytique et la position mesurée de l'effecteur). Ainsi, dans [Aoyagi et al., 2010], les paramètres géométriques d'un robot ont été identifiés, puis un réseau de neurones a été entraîné pour prédire la compensation à appliquer à la position articulaire pour atteindre une position cartésienne désirée. Plus tard,

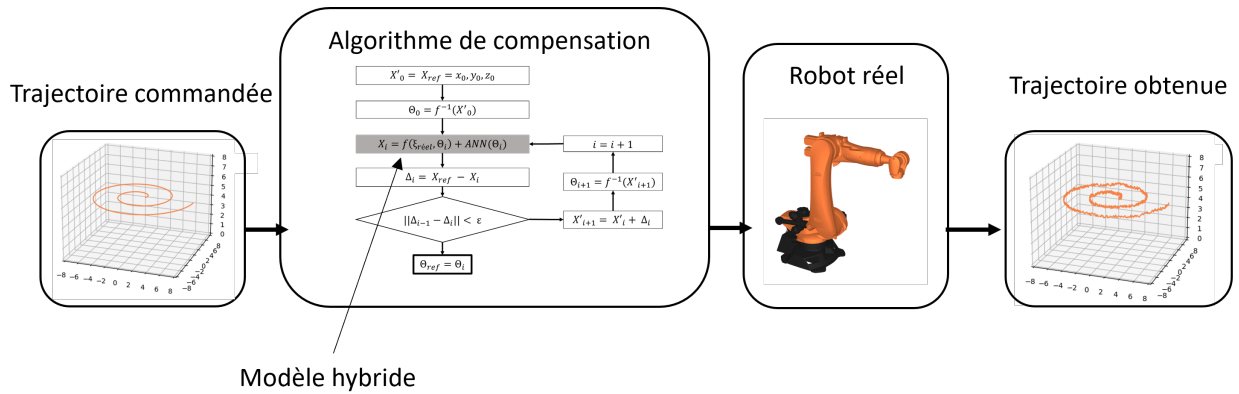


FIGURE 2.1 – Principe des méthodes de calibration hybrides

[Zhao et al., 2019] ont suivi une méthode similaire, mais en utilisant un nombre plus important de données d’entraînement. Leur méthode a été validée expérimentalement en utilisant l’algorithme décrit dans la section 1.5, et montre que le robot atteint une erreur moyenne proche de sa répétabilité. De la même manière, [Gao et al., 2017] ont entraîné un réseau de neurones pour prédire à la fois l’erreur de positionnement et l’erreur d’orientation, en utilisant de même un grand nombre de données. Dans [Nguyen et al., 2021] combinent un algorithme de Levenberg-Marquardt et une optimisation par essaims de particules (*Particle Swarm Optimization*) pour entraîner un réseau de neurones destiné à prédire l’erreur de positionnement après calibration géométrique d’un robot 5-barres parallèle.

La motivation première des méthodes de calibration hybrides, par rapport à une calibration boîte noire, est de réduire le nombre de données et le temps d’entraînement des réseaux de neurones en simplifiant la tâche qui leur incombe : après calibration géométrique, l’erreur résiduelle qui doit être prédite par le réseau de neurones serait plus facile à prédire, et nécessiterait moins de données [Zhao et al., 2019]. Cependant, cela n’a pas été établi dans la littérature scientifique. Par ailleurs, la plupart des applications de calibration hybride dans la littérature obtenant une précision proche de la répétabilité du robot considéré utilisent un nombre important de données par rapport à l’espace de travail du robot. En effet, [Zhao et al., 2019] utilisent 10 198 points de mesures dans un sous-espace de travail du robot, chacun des points étant espacé de 45mm ; tandis que [Gadringer et al., 2020] utilisent 11 136 mesures de la position et de l’orientation de l’effecteur pour calibrer un sous-espace de travail du robot. D’après les informations fournies dans [Zhao et al., 2019, Gadringer et al., 2020], il n’est pas possible de déterminer le volume des sous-espaces définis, mais ils sont représentés dans la figure 2.2. Face à la complexité des protocoles expérimentaux, en particulier liés à l’utilisation d’un SMR qui contraint l’orientation de l’effecteur du robot pour conserver le contact avec le laser tracker, [Zhao et al., 2019] ont développé un algorithme de planification de trajectoire spécifique pour faciliter le protocole expérimental.

2.1. INTRODUCTION

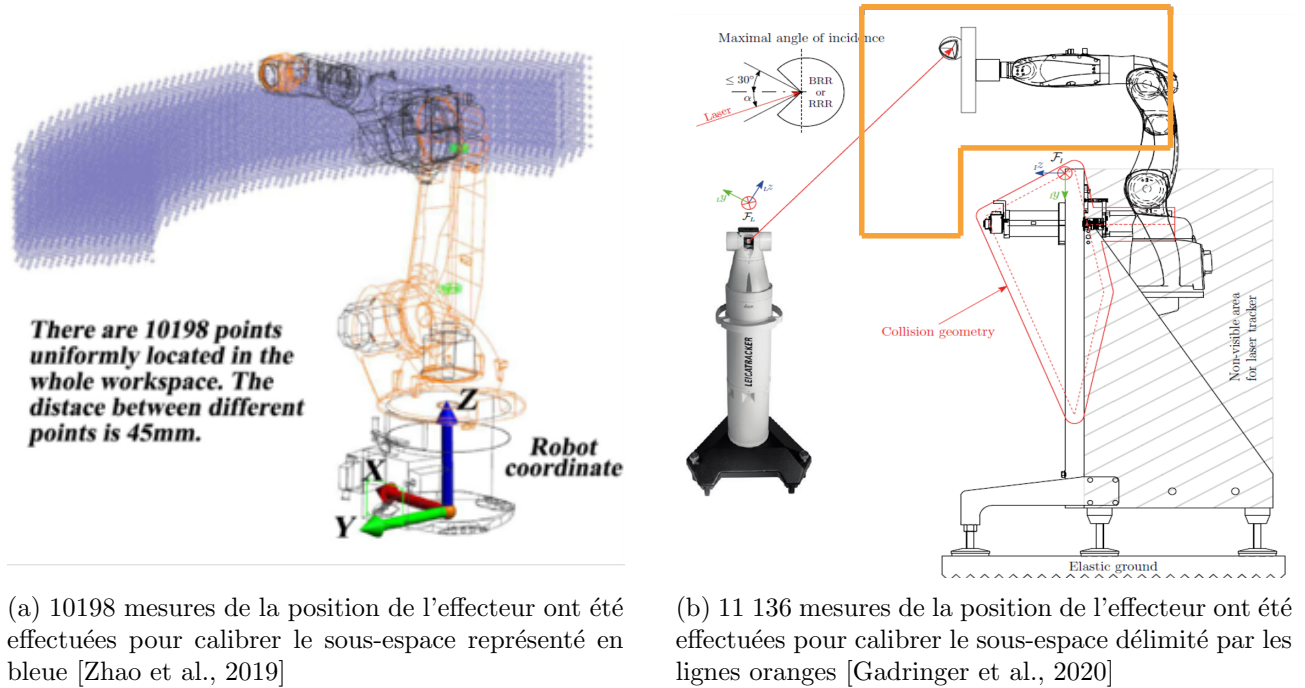


FIGURE 2.2 – Sous-espaces de travail définis dans [Zhao et al., 2019, Gadringer et al., 2020].

Nous notons que dans les méthodes précédentes, la variabilité de la charge utile n'est prise en compte ni dans le modèle analytique, ni dans le modèle d'apprentissage, alors que la section 1.4.4 du chapitre précédent a montré l'influence de la charge utile sur l'erreur de positionnement. En effet, la complianse des articulations induit une erreur de positionnement de $0,4\text{mm}$ sur le KR300, ce qui représente 20% de sa précision naturelle (i.e. de son défaut de positionnement avant calibration) d'après la section 1.4.4. Pour pallier ce manque, [Nguyen et al., 2015], [Nguyen et al., 2019] ont proposé d'identifier les raideurs des articulations en plus des paramètres géométriques, avant d'entraîner un réseau de neurones pour prédire l'erreur de positionnement. L'identification des raideurs des articulations a été effectuée selon la méthode décrite dans [Khalil and Besnard, 2002]. Cependant, le modèle de masse du robot sur lequel leur méthode a été appliquée est connu, ce qui facilite grandement l'identification des raideurs des articulations. Pour passer outre les difficultés d'identification, [Hsiao et al., 2020] proposent un réseau de neurones pour l'approximation d'erreur résiduelle prenant pour entrée à la fois la position articulaire et la charge. En revanche, cela a pour effet de complexifier le protocole expérimental, puisque l'entraînement du modèle d'apprentissage requiert des données avec plusieurs charges différentes.

2.1.3 Contributions

Pour effectuer une tâche industrielle, un robot est souvent amené à travailler dans différentes zones de son espace de travail et à porter différentes charges utiles (connues ou mesurables). Pour améliorer la précision d'un robot via une méthode de calibration hybride de manière efficace (en terme de données et de temps), il est donc préférable d'entraîner plusieurs jeux de poids d'un même modèle d'apprentissage automatique avec des données issues de chacun des sous-espaces dans lequel le robot est amené à travailler plutôt que dans l'espace complet. De même, dans chacun des sous-espaces, le modèle d'apprentissage doit pouvoir être reconfiguré aisément et à moindre coût (en termes de données et de temps) pour les différentes charges utiles qu'il est amené à manipuler. A chaque changement de zone de travail et/ou de charge utile au cours de la tâche, il suffira alors de charger dynamiquement le jeu de poids correspondant. La méthode hybride doit donc permettre, avec la même architecture de réseau de neurones, de pouvoir entraîner le réseau dans un sous-espace donnée pour une charge utile donnée, avec une spécification d'avoir acquérir le moins de données possibles pour réduire le temps d'immobilisation du robot. C'est dans cette finalité que se placent les travaux présentés dans ce chapitre. D'abord, une méthode de calibration hybride sera appliquée aux deux robots considérés dans ce manuscrit, à savoir le KR300 et l'*iiwa*. Pour chacun des deux robots, la méthode sera appliquée dans deux sous-espaces de travail pré-défini, afin de refléter au mieux l'application de ces méthodes dans un cadre industriel. Une description détaillée de la mise en oeuvre de cette méthode est donnée dans la section 2.2. La section 2.3 présente une analyse expérimentale comparative des méthodes de calibration hybrides, boîte-noire et analytiques. En particulier, l'apport des méthodes de calibration hybrides est quantifié : la corrélation entre le nombre de données requises et la précision du modèle est montrée empiriquement pour les méthodes *boîte-noire* et hybrides, et il sera mis en évidence que les méthodes hybrides permettent d'être plus efficaces. Enfin, la section 2.4 apporte une contribution sur l'adaptabilité des méthodes de calibration hybrides, sous la forme de deux nouvelles méthodes permettant d'adapter un modèle de calibration hybride à une nouvelle charge. La première méthode se base sur une méthode d'apprentissage par transfert pour n'utiliser que peu de points pour ré-entraîner un réseau de neurones à compenser une nouvelle charge. La seconde méthode interpole directement les prédictions de ce même réseau de neurones avec deux jeux de poids différents, obtenus après entraînement pour deux précédentes charges utiles, ne requérant ainsi aucune nouvelle données pour une nouvelle charge. Ces deux méthodes sont validées expérimentalement dans la section 2.5, et la section 2.6 conclue sur les performances des méthodes proposées.

2.2 Calibration hybride

Dans ce chapitre, une méthode de calibration hybride similaire à celle de [Zhao et al., 2019] a été appliquée à deux robots industriels : le KR300 et l'*iiwa*. Cette méthode consiste d'abord à identifier les paramètres géométriques du robot en question, en utilisant un ensemble de points de mesure répartis dans l'ensemble de l'espace de travail du robot. Puis, dans des sous-espaces de travail préalablement définis, un grand nombre de points de mesure sont acquis pour entraîner un réseau de neurones. Le réseau de neurones prend pour entrée la configuration articulaire du robot et doit prédire l'erreur résiduelle, c'est-à-dire la différence entre la position cartésienne mesurée et celle calculée par le modèle géométrique direct, qui utilise les paramètres géométriques identifiés.

2.2.1 Modèle analytique

Dans le modèle hybride appliqué ici, seuls ont été identifiés les paramètres géométriques du robot : les modèles analytiques permettant de compenser la compliance des articulations, les erreurs de transmissions ou la dérive thermique (voir section 1.2.4, 1.2.5 et 1.2.6, respectivement) n'ont pas été utilisés. Cela s'explique par la complexité des protocoles expérimentaux à mettre en oeuvre pour identifier les paramètres de ces modèles. En effet, pour identifier la compliance des articulations dans un cas générique (i.e. le modèle de masse du robot n'est pas connu, et il n'est pas équipé de capteurs de couple), il est nécessaire de mesurer plusieurs fois les mêmes points avec différentes charges ; identifier les paramètres des modèles thermiques nécessite plusieurs heures de mesures ; et prédire les erreurs de transmission requiert de connaître le couple appliqué à chaque articulation, afin d'en connaître les changements de sens. De plus, au vu de l'étude de l'influence de chacune des sources d'erreurs sur l'erreur de positionnement finale (étude menée dans la section 1.4.4), il apparaît que les défauts géométriques sont responsables de la majeure partie de l'erreur de positionnement finale du KR300 (table 1.4). En d'autres termes, les défauts géométriques sont à la fois la plus importante source d'erreurs des robots industriels, mais aussi les moins complexes à compenser. Pour l'ensemble de ces raisons, le modèle analytique utilisé se résume au modèle géométrique direct, avec les paramètres géométriques identifiés :

$$X = f(\xi_{réel}, \theta) \tag{2.1}$$

Le protocole d'identification des paramètres géométriques du KR300 a été décrit précédemment, dans la section 1.4.4.1. Pour l'*iiwa*, le protocole suivi est similaire. En suivant la convention de Khalil-Kleininger [Khalil and Kleininger, 1986], un repère est associé à chaque articulation de l'*iiwa*, comme illustré sur la figure 2.3. Ainsi, les paramètres géométriques nominaux sont présentés dans la table 2.1. Un ensemble de 70 points a été mesuré dans l'espace de travail de l'*iiwa*, et les paramètres géométriques ont pu être identifiés. Après identification, les paramètres géométriques décrits dans la table 2.2 sont

obtenus.

Articulation	a (mm)	α (°)	r (mm)	θ (°)
1	0	0	360	θ_1
2	0	-90	0	θ_2
3	0	90	420	θ_3
4	0	90	0	θ_4
5	0	-90	400	θ_5
6	0	-90	0	θ_6
7	0	90	152	θ_7

TABLE 2.1 – Paramètres géométriques nominaux de l'*iiwa*

Articulation	a (mm)	α (deg)	r (mm)	θ (deg)
1	-0,199	0,004	358,687	$\theta_1 + 0^1$
2	-0,265	-90,005	0,109	$\theta_2 + 0,032$
3	-0,012	90,031	420,498	$\theta_3 - 0,027$
4	0,004	89,976	-0,292	$\theta_4 + 0,006$
5	0,146	-89,982	400,417	$\theta_5 + 0,025$
6	0,015	-90,013	-0,066	$\theta_6 + 0,007$
7	0 ¹	90 ¹	152 ¹	$\theta_7 + 0^1$

TABLE 2.2 – Paramètres géométriques identifiés de l'*iiwa*

2.2.2 Modèle d'apprentissage

L'objectif du modèle d'apprentissage est de prédire l'erreur résiduelle (après identification des paramètres géométriques). Dans ce chapitre, le modèle d'apprentissage utilisé est un réseau de neurones dense. Son architecture a été choisie en suivant les recommandations présentées dans [Zhao et al., 2019], où une étude sur les hyper-paramètres a été conduite. En effet, les architectures testées produisent toutes des résultats très similaires ; seul le temps d'entraînement du réseau de neurones diffère. Or, le temps d'entraînement du réseau de neurones utilisé dans [Zhao et al., 2019] n'excède pas deux minutes sur un ordinateur classique. Ce temps d'entraînement est donc acceptable dans un contexte industriel.




FIGURE 2.3 – Repères associés à chacune des articulations de l'*iiwa* [Busson, 2018]

La finalité des méthodes proposées dans ce chapitre sera de réduire drastiquement le nombre de données nécessaires et donc le temps requis pour reconfigurer le robot. A titre d'exemple, le temps requis pour effectuer les 10 198 mesures [Zha+19] est d'environ 5h, ce qui ne permet pas une reconfiguration rapide (pour une nouvelle charge utile notamment).

Dans ce chapitre, l'architecture utilisée est illustrée sur la figure 2.4 : le réseau de neurones est composé d'une couche d'entrée ayant un nombre de neurones égal au nombre d'articulations du robot (7 pour l'*iiwa*, 6 pour le KR300) ; de deux couches cachées comportant respectivement 80 et 40 neurones, et d'une couche de sortie comportant 3 neurones qui correspondent à l'erreur de positionnement selon chacune des articulations cartésiennes (Δ_x , Δ_y , Δ_z). Les deux couches cachées ont pour fonction d'activation les fonctions *tanh* et *elu*, respectivement. Plusieurs hyper-paramètres ont été étudiés (nombre de neurones par couches, nombre de couches, fonctions d'activations, fonction de coût) empiriquement. Conformément à [Zhao et al., 2019], les mais les différentes architectures testées ont toutes produits des résultats très similaires.

Avec cette approche hybride, le modèle géométrique direct devient :

$$X = f(\xi_{réel}, \theta) + ANN(w_{P,S}, \theta) \quad (2.2)$$

avec $w_{P,S}$ les poids du réseau de neurones entraînés pour prédire l'erreur résiduelle pour une charge P dans un sous-espace de travail S .

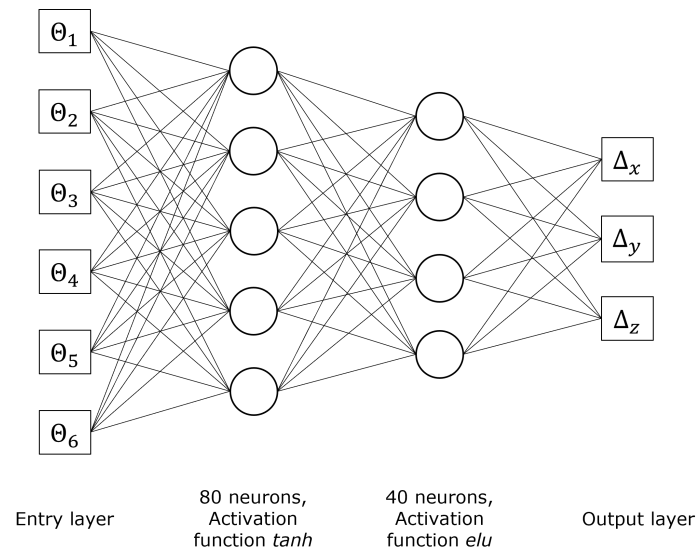


FIGURE 2.4 – Architecture du réseau de neurones

2.3 Analyse expérimentale des méthodes de calibration hybrides


Dans cette section, nous nous intéressons aux performances du modèle hybride (équation (2.2)), tant en terme de précision qu'en terme de consommation de données. Ces critères de performances seront évalués d'abord sur l'*iiwa*, puis sur le KR300. Pour chacun des deux robots, les paramètres géométriques sont identifiés en utilisant un ensemble de points répartis équitablement dans l'espace de travail du robot. Ensuite, deux sous-espaces de travail sont définis. Un ensemble de positions cartésiennes (2100 positions pour l'*iiwa*, 1100 positions pour le KR300) sont mesurées dans chacun de ces sous-espaces, et serviront à l'entraînement, i.e. au réglage du jeu de poids correspondant $w_{P,S}$. Le modèle hybride sera évalué et comparé à trois autres modèles : le modèle nominal, un modèle analytique et un modèle "boîte-noire". Sur un ensemble de test, la position cartésienne mesurée sera comparée à la position cartésienne théorique donnée par les modèles étudiés. Une comparaison sera également faite entre les modèles hybrides et "boîte-noire" en fonction du nombre de données utilisés pour l'entraînement du réseau de neurones. Les performances de l'algorithme de compensation présenté dans la section 1.5 seront également évaluées sur l'*iiwa*. Les données utilisées dans cette section sont accessibles via le lien suivant : <https://doi.org/10.57745/DWUCOH>.

2.3.1 Application sur un robot collaboratif (*iiwa*)


La méthode de calibration hybride présentée dans la section 2.2 a été appliquée d'abord à l'*iiwa*, dans deux sous-espaces de travail, alors qu'il porte une masse de 5 kg. Le montage expérimental utilisé est décrit sur la figure 2.5. Conformément aux recommandations de la section 1.4, un Laser Tracker

2.3. ANALYSE EXPÉRIMENTALE DES MÉTHODES DE CALIBRATION HYBRIDES

sera utilisé pour les mesures. Le repère de base du robot sera identifié via la méthode *2-cercles*, décrite dans la section 1.4.2. La transformation entre le *flange* de l'*iiwa* et la bille réfléchissante (SMR) a été identifiée au cours de la calibration géométrique, ce qui explique pourquoi les paramètres géométriques de la dernière articulation n'ont pas pu être identifiés dans la table 2.2. Le premier sous-espace de travail est délimité par $(x = 400, y = -300, z = 700 \text{ mm})$ et $(x = 650, y = 300, z = 900 \text{ mm})$, tandis que le second est délimité par $(x = -300, y = -600, z = 350 \text{ mm})$ et $(x = 300, y = -300, z = 550 \text{ mm})$.



(a) Matériel utilisé pour la calibration hybride de l'*iiwa*



(b) Répartition des mesures dans l'espace de travail de l'*iiwa*. Les points bleus sont utilisés pour la calibration géométrique, les points verts pour l'entraînement des réseaux de neurones.

FIGURE 2.5 – Montage expérimental utilisé pour la calibration hybride de l'*iiwa*

2.3.1.1 Évaluation des modèles directs

Pour quantifier l'apport des réseaux de neurones dans les protocoles de calibration, le test suivant a été réalisé : 2100 points ont été mesurés dans chaque sous-espace de travail. Parmi ces 2100 points, 100 ont été aléatoirement extraits pour servir d'ensemble de test. Les 2000 points restants ont été utilisés pour l'entraînement du réseau de neurones. Pour évaluer l'apport des méthodes de calibration hybride par rapport aux autres méthodes (calibration analytique et calibration boîte-noire), l'erreur de positionnement moyenne et maximale sur l'ensemble de test a été comparée pour 4 modèles :

- le modèle géométrique direct nominal, qui représente la précision native du robot

$$X = f(\xi_{nominal}, \theta)$$

2.3. ANALYSE EXPÉRIMENTALE DES MÉTHODES DE CALIBRATION HYBRIDES

- le modèle géométrique direct avec les paramètres géométriques identifiés

$$X = f(\xi_{réel}, \theta)$$

- le modèle géométrique direct nominal couplé avec un réseau de neurones, ce qui correspond aux modèles "boîte-noire" discutés précédemment

$$X = f(\xi_{nominal}, \theta) + ANN(w_P, S, \theta)$$

- le modèle géométrique direct avec les paramètres géométriques identifiés couplé avec un réseau de neurones, ce qui correspond au modèle hybride présenté dans la section précédente

$$X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$$

Les résultats sont présentés dans la table 2.3, et sur la figure 2.6. La calibration géométrique permet de réduire l'erreur de positionnement moyenne et maximale, quelque soit le sous-espace de travail. En revanche, elle a été plus efficace dans le sous-espace 1. Les réseaux de neurones permettent d'atteindre une erreur moyenne faible, comparable à la répétabilité du robot (qui est de $0,15mm$ d'après le constructeur). Par ailleurs, l'identification des paramètres géométriques au préalable de l'entraînement du réseau de neurones ne semble pas avoir un impact significatif sur l'erreur finale : le modèle "boîte-noire" est tout aussi précis que le modèle hybride.

2.3.1.2 Étude du nombre de données d'entraînement requis

Désormais, le nombre de données requises pour l'entraînement des réseaux de neurones est étudié. En effet, [Zhao et al., 2019] motivent leur modèle de calibration hybride par le fait qu'il nécessite moins de données qu'une calibration boîte-noire, tout en étant plus performant qu'une méthode de calibration analytique. En revanche, le gain en terme de données et de précision n'est pas quantifié. Pour étudier l'intérêt de la calibration hybride en terme de nombre de données requises, des sous-ensembles de données ont été créés, en extrayant aléatoirement des données parmi les deux ensembles de données d'entraînement. Ensuite, les performances en termes d'erreur moyenne et maximale sur le même set de validation ont été comparés pour les deux méthodes (calibration "boîte-noire" et hybride) en fonction du nombre de données d'entraînement. Nous remarquons, qu'à un même niveau de précision (erreur moyenne et maximale), l'identification des paramètres géométriques au préalable de l'entraînement d'un réseau de neurones permet de réduire le nombre de données nécessaires à l'entraînement, dans les deux sous-espaces de travail à l'étude. En revanche, le sous-espace de travail 1 nécessite moins de données que le sous-espace de travail 2, alors même que la calibration géométrique n'a pas permis un gain aussi important dans le sous-espace de travail 2 que dans le sous-espace de travail 1. Il semble alors que le nombre de données nécessaires à l'entraînement d'un réseau de neurones pour la prédiction de l'erreur résiduelle dépende de la qualité du modèle géométrique direct.

2.3. ANALYSE EXPÉRIMENTALE DES MÉTHODES DE CALIBRATION HYBRIDES

(a) Sous-espace de travail 1

Modèle	Erreur moyenne (mm)	Erreur max (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	3,18	4,53	0,52
$X = f(\xi_{réel}, \theta)$	0,98	1,43	0,18
$X = f(\xi_{nominal}, \theta) + ANN(w_P, S, \theta)$	0,093	0,234	0,04
$X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$	0,089	0,233	0,04

(b) Sous-espace de travail 2

Modèle	Erreur moyenne (mm)	Erreur max (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	1,98	2,65	0,30
$X = f(\xi_{réel}, \theta)$	1,62	2,07	0,20
$X = f(\xi_{nominal}, \theta) + ANN(w_P, S, \theta)$	0,092	0,211	0,03
$X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$	0,076	0,181	0,03

TABLE 2.3 – Comparaison des performances du modèle hybride par rapport aux modèles analytiques et "boîte-noire" pour l'*iiwa*.

2.3.1.3 Évaluation des performances de l'algorithme de compensation

Enfin, les performances de l'algorithme de compensation décrit dans la section 1.5 ont été évaluées pour chacun des 4 modèles présentés ici, dans les deux sous-espaces de travail. L'algorithme de compensation (présenté dans la section 1.5) est rappelé sur la figure 2.8 : il prend pour entrée la position cartésienne désirée, et il utilise le modèle géométrique inverse et un modèle direct pour trouver la configuration articulaire qui permet d'atteindre la position cartésienne désirée selon le modèle direct employé. Ainsi, plus le modèle direct est précis et fiable, plus l'algorithme de compensation le sera aussi. Pour un même ensemble de 100 poses cartésiennes à atteindre, l'algorithme de compensation a fourni 4 ensembles de 100 positions articulaires, chacune d'entre elles étant censée atteindre les poses cartésiennes selon les modèles utilisés. Les écarts entre les positions commandées et les positions mesurées sont résumés dans la table 2.4 et dans la figure 2.9.

Ces résultats sont en adéquation avec ceux présentés dans la table 2.3, la légère différence entre les résultats s'explique par la répétabilité du robot et la précision du laser tracker. Cela indique que la précision du calcul de géométrie inverse dépend uniquement de la précision du modèle direct : l'algorithme de compensation ne dégrade pas les performances.

2.3. ANALYSE EXPÉRIMENTALE DES MÉTHODES DE CALIBRATION HYBRIDES

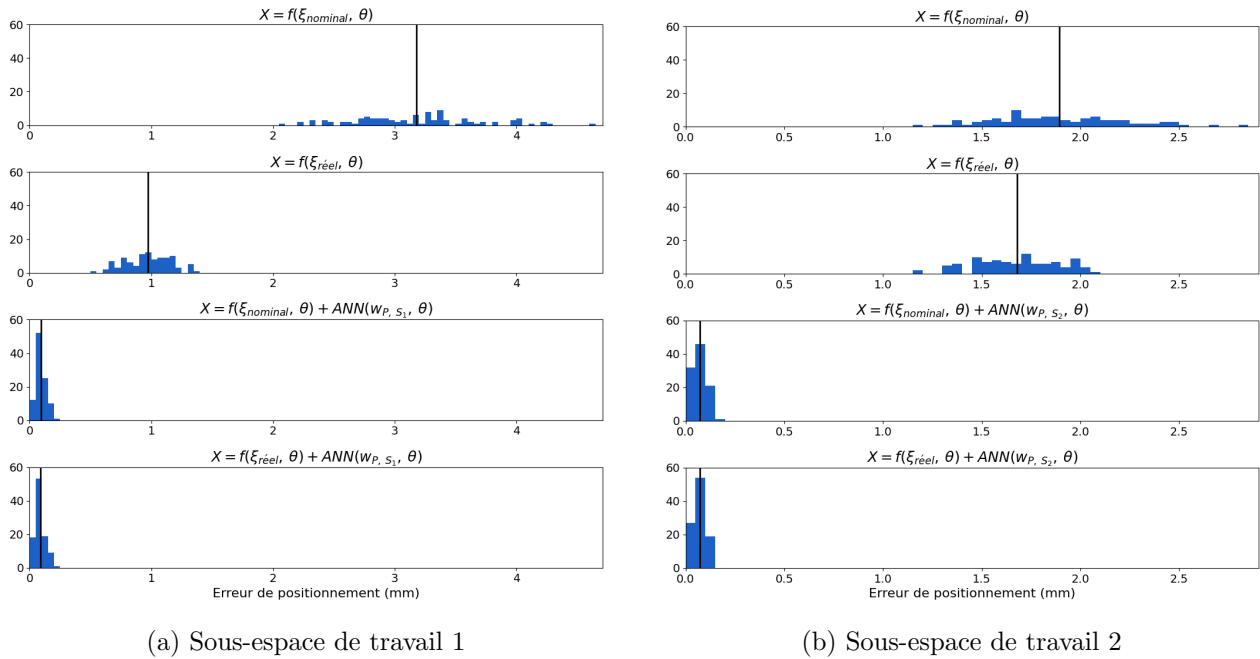


FIGURE 2.6 – Distribution des erreurs de positionnement de l'effecteur de l'iwa sur les 100 données de validation pour les 4 modèles étudiés.

Ces éléments montrent d'une part qu'il est possible de compenser la déformation d'un robot due à la charge qu'il manipule avec des méthodes de calibration hybrides (en utilisant des données d'entraînement acquises alors que le robot manipule cette charge), d'autre part que les méthodes de calibration hybrides permettent de réduire le nombre de données requises pour l'entraînement de neurones.

2.3.2 Application sur un robot industriel "moyen porteur" (KR300)

Un test similaire a été réalisé sur le KR300 : deux sous-espaces de travail ont été définis, et 1100 points ont été mesurés dans chaque, pour deux masses portées différentes $P_1 = 4kg$ et $P_2 = 120kg$. Le premier sous-espace de travail est délimité par $(x = 1200, y = -500, z = 1450)$ mm et $(x = 1600, y = 500, z = 1900)$ mm dans le repère de base robot, tandis que le second est délimité par $(x = -250, y = 1050, z = 1000)$ mm et $(x = 300, y = 1400, z = 1600)$ mm. Les deux sous-espaces de travail du KR300 sont représentés sur la figure 2.10. De la même manière, 100 points ont été extraits de chaque dataset pour servir de données de validation, et les 4 mêmes modèles (avec les paramètres géométriques correspondant à ceux du KR300) ont été évalués. L'ensemble de ces points a été mesuré en suivant le même montage expérimental que dans la section 1.4 : l'instrument de mesure utilisé est un laser tracker mesurant la position d'un SMR fixé sur le *flange* du robot. La transformation entre le *flange* du robot et le SMR a été identifiée via la méthode 4-points [Shiu and Ahmad, 1989], et la

2.3. ANALYSE EXPÉRIMENTALE DES MÉTHODES DE CALIBRATION HYBRIDES

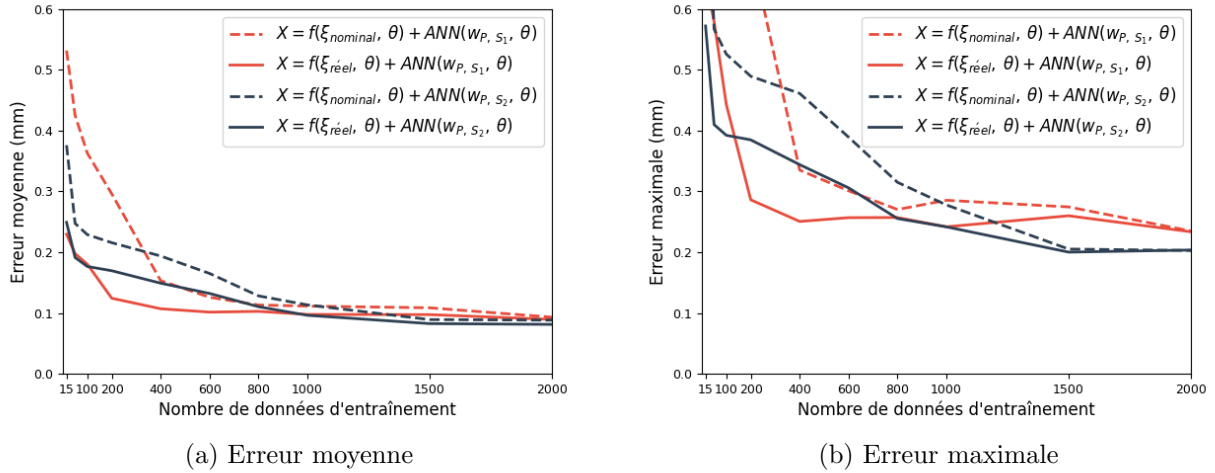


FIGURE 2.7 – Influence du nombre de données sur l’erreur de positionnement moyenne et maximale de l’effecteur de l’*iiwa*.

transformation entre le repère du laser tracker et le repère de base robot a été identifié via la méthode *2-cercle* présentés dans la section 1.4.2.

Les résultats sont présentés dans les tables 2.5 et 2.6; et dans la figure 2.11. Une étude sur le nombre de données nécessaires a aussi été conduite, dont les résultats sont présentés sur la figure 2.12. L’ensemble de ces résultats mènent à des conclusions similaires à celles pour l’*iiwa* : la calibration hybride ne permet pas d’avoir des résultats meilleurs que la calibration ”boîte-noire”, mais permet d’atteindre la même précision avec un nombre réduit de données d’entraînement. Par ailleurs, nous observons aussi que le modèle hybride ne nécessite pas plus de données d’entraînement pour prédire l’erreur résiduelle après calibration géométrique lorsque le robot manipule une charge de 4 ou de 120 kg. En revanche, en comparant les figures 2.7 et 2.12 pour un niveau de précision égale, le nombre de données d’entraînement requis apparaît plus faible pour le KR300 que pour l’*iiwa*, alors que les sous-espaces de travail du KR300 sont significativement plus grands. Cela pourrait s’expliquer par le fait que le KR300 a une structure plus rigide que celle de l’*iiwa* [Dumas et al., 2011, Besset et al., 2016], avec une allonge plus grande : de ce fait, le KR300 est plus sensible aux défauts géométriques (pris en compte dans le modèle analytique) mais moins sensible aux défauts de compliance des articulations. Ainsi, le réseau de neurones doit compenser une erreur plus faible pour le KR300 que pour l’*iiwa*, ce qui nécessiterait moins de données d’entraînement. De même, l’identification des paramètres géométriques du KR300 réduit plus fortement l’erreur de positionnement que pour l’*iiwa*, ce qui confirme l’observation faite précédemment pour l’*iiwa* : plus le modèle analytique est précis, moins le nombre de données nécessaires est important.

2.4. ADAPTABILITÉ À UNE VARIATION DE LA CHARGE UTILE

(a) Sous-espace de travail 1

Modèle	Erreur moyenne (mm)	Erreur maximale (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	3,10	4,12	0,48
$X = f(\xi_{réel}, \theta)$	0,97	1,38	0,17
$X = f(\xi_{nominal}, \theta) + ANN(w_P, S, \theta)$	0,15	0,27	0,06
$X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$	0,13	0,26	0,05

(b) Sous-espace de travail 2

Modèle	Erreur moyenne (mm)	Erreur maximale (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	1,81	2,48	0,21
$X = f(\xi_{réel}, \theta)$	1,74	2,04	0,16
$X = f(\xi_{nominal}, \theta) + ANN(w_P, S, \theta)$	0,13	0,20	0,04
$X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$	0,16	0,29	0,05

TABLE 2.4 – Évaluation de la précision des 4 modèles en utilisant l’algorithme de compensation pour l’*iiva*.

2.4 Adaptabilité à une variation de la charge utile

La section précédente a montré que le modèle hybride peut compenser l’effet dû à la charge sans nécessiter de données supplémentaires, sous réserve que les mesures servant à l’entraînement du réseau de neurones aient été faites alors que le robot manipule la charge en question. Cependant, lors d’un changement de charge (ce qui intervient régulièrement lors d’opération de *pick-and-place*, ou d’usinage avec un changeur d’outil par exemple), il faudrait recommencer le processus de calibration hybride, désigné comme *approche classique* ci-après, pour une nouvelle charge. Ceci implique d’installer à nouveau le montage expérimental nécessaire : il faut alors installer le laser tracker, identifier la transformation entre le laser tracker et le robot selon l’une des méthodes décrits dans la section 1.4.2, identifier la transformation entre le *flange* et la bille réfléchissante, mesurer un grand nombre de points dans le sous-espace de travail à calibrer.

Dans un souci d’efficacité en termes de données et de temps, deux nouvelles méthodes de compensation de charge sont proposées. L’objectif de ces méthodes est de réduire autant que possible la complexité du montage expérimental lors de la re-calibration d’un robot industriel pour une nouvelle charge utile. La première méthode repose sur l’utilisation de poids pré-entraînés avec une autre charge

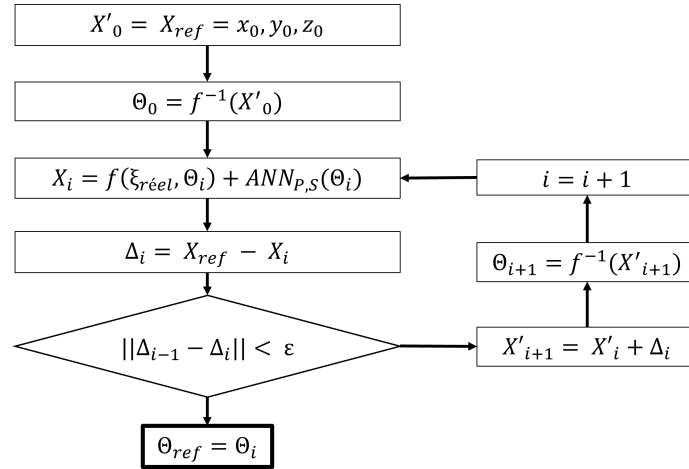


FIGURE 2.8 – Algorithme de compensation utilisant le modèle hybride

pour initialiser les poids du réseau de neurones, selon un apprentissage par transfert, afin de réduire le nombre de données nécessaires et ainsi diminuer la complexité expérimentale. La deuxième méthode interpole directement deux prédictions d'un réseau de neurones en utilisant deux ensembles distincts de poids obtenus à partir d'entraînements avec des charges différentes, en supposant que le centre de gravité de l'effecteur ne varie pas de manière significative. De cette manière, l'effet d'une nouvelle charge peut être compensé sans aucune mesure supplémentaire, ce qui rend la mise en œuvre dans des scénarios industriels réels rapide et facile.

2.4.1 Méthode 1 : apprentissage par transfert

2.4.1.1 L'apprentissage par transfert

L'apprentissage par transfert fait souvent références aux méthodes permettant d'extraire des caractéristiques de haut niveau en tronquant un réseau de neurones "*backbone*" (par exemple VGG16, ResNet50 etc.), entraîné sur de très larges bases d'images pour un problème de classification comportant un grand nombre de classes. Ces caractéristiques extraites sont alors utilisées pour entraîner un nouveau réseau de neurones léger pour répondre à un nouveau problème de classification [Guerin, 2018]. De manière plus générale, l'apprentissage par transfert est un champ de l'apprentissage automatique (*Machine learning*) dont le but est de transférer des connaissances d'une tâche source vers une tâche cible. En d'autres termes, les méthodes d'apprentissage par transfert visent à réutiliser des connaissances précédemment acquises par le modèle d'apprentissage pour effectuer une nouvelle tâche, partageant des similitudes avec la tâche pour laquelle le modèle avait été entraîné initialement.

L'une des motivations de l'apprentissage par transfert est de réduire le temps d'entraînement et le coût en données pour une nouvelle tâche. Certains utilisent l'apprentissage par transfert pour spéciali-

2.4. ADAPTABILITÉ À UNE VARIATION DE LA CHARGE UTILE

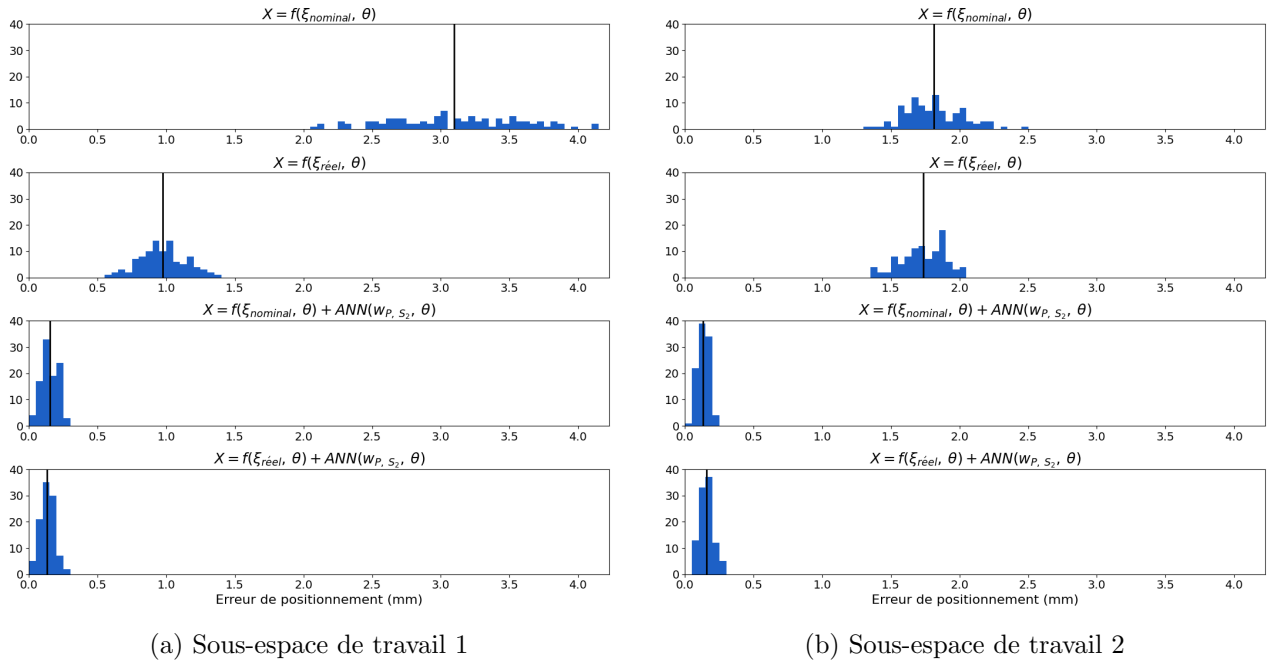


FIGURE 2.9 – Distribution des erreurs de positionnement de l'effecteur de l'iiwa en appliquant l'algorithme de compensation sur 100 positions cartésiennes pour les 4 modèles étudiés.

ser un modèle d'apprentissage vers une tâche plus précise [Jiang et al., 2022]. D'autres transfèrent des connaissances acquises en simulations vers un système réel : on parle de *sim-to-real transfer learning*. Les méthodes *sim-to-real* sont utilisées pour le contrôle dynamique de robots [Tan et al., 2018], mais ont aussi été utilisées pour la calibration de robots industriels [Yu et al., 2019, Ye et al., 2022]. Cependant, pour simuler les défauts de transmission, la dérive thermique ou la compliance des articulations, il est nécessaire d'utiliser les modèles présentés dans la section 1.2, et donc d'identifier les paramètres de ces modèles. Or, l'objectif initial des méthodes de calibration hybride est d'utiliser l'apprentissage automatique pour éviter l'identification de paramètres dans des modèles jugés trop complexes.

2.4.1.2 Description de la méthode

Dans la méthode proposée ici, lorsque le robot manipule une nouvelle charge P_{new} , le processus d'entraînement du réseau de neurones est allégé. Les poids du réseaux de neurones sont initialisés avec ceux provenant de l'entraînement avec une charge précédente P dans le même sous-espace S . De cette manière, le réseau de neurones peut réutiliser les connaissances déjà acquises, ne nécessitant que quelques mesures avec la nouvelle charge pour entraîner efficacement les poids. Contrairement à l'apprentissage par transfert *sim-to-real*, le réseau de neurones a d'abord été initialisé avec des données réelles (et non simulées), puis a été ré-entraîné avec de nouvelles données réelles : c'est une approche




FIGURE 2.10 – Répartition des points de mesures pour la calibration hybride du KR300. Les points bleus ont servi à l’identification des paramètres géométriques; les points verts à l’entraînement des poids du réseau de neurones.

d’apprentissage par transfert *real-to-real*.

Les poids obtenus avec l’approche classique dans un sous-espace S avec une charge P sont notés $w_{P,S}$. Comme $w_{P,S}$ s’adaptent déjà à la configuration articulaire pour l’erreur cartésienne avec une charge P_1 , l’initialisation des poids pour une nouvelle charge P_{New} avec $w_{P_1,S}$ permet au modèle de commencer la phase d’apprentissage avec une précision plus élevée. En effet, les poids $w_{P_1,S}$ sont capables de compenser l’erreur de positionnement provenant des erreurs d’identifications des paramètres géométriques, du poids propre du robot, et des erreurs de transmission; et ils n’ont besoin d’être mis à jour qu’avec quelques nouvelles données pour compenser $\Delta X_{payload}$.

Cette méthode est illustrée par la figure 2.13. En pratique, après la formation conduisant à w_{P_1,S_1} et w_{P_1,S_2} , deux nouveaux ensembles de poids, notés $w_{P_1 \rightarrow new,S_1}$ et $w_{P_1 \rightarrow new,S_2}$, sont initialisés avec w_{P_1,S_1} et w_{P_1,S_2} respectivement. En utilisant $n_{data} \ll 1000$ mesures des ensembles de données (P_{new}, S_1) et (P_{new}, S_2) , l’entraînement est effectué pour obtenir de nouveaux poids adaptés. Le modèle hybride devient alors :

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_1 \rightarrow new,S}; S, \theta) \quad (2.3)$$

2.4. ADAPTABILITÉ À UNE VARIATION DE LA CHARGE UTILE

(a) Sous-espace de travail 1

Modèle	Erreur moyenne (mm)	Erreur max (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	4,230	5,125	0,47
$X = f(\xi_{réel}, \theta)$	0,399	0,57	0,17
$X = f(\xi_{nominal}, \theta) + ANN(w_P, S, \theta)$	0,083	0,155	0,04
$X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$	0,078	0,199	0,04

(b) Sous-espace de travail 2

Modèle	Erreur moyenne (mm)	Erreur max (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	2,831	3,975	0,33
$X = f(\xi_{réel}, \theta)$	0,299	0,408	0,21
$X = f(\xi_{nominal}, \theta) + ANN(w_P, S, \theta)$	0,084	0,261	0,04
$X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$	0,058	0,125	0,04

TABLE 2.5 – Comparaison des performances du modèle hybride par rapport aux modèles analytiques et "boîte-noire" pour le KR300, avec une charge $P = 4kg$.

2.4.2 Méthode 2 : interpolation de deux prédictions

2.4.2.1 Considérations mathématiques

Une variation de charge induit une variation du couple appliquée à chacune des articulations, ce qui provoque une déformation de la structure du robot et donc une erreur de positionnement. Considérons l'équation suivante pour modéliser de manière générale l'erreur de positionnement d'un robot :

$$\Delta X = g(\Delta X_{geometric} + \Delta X_{self\ mass} + \Delta X_{gearboxes} + \Delta X_{thermal\ effects} + \Delta X_{residual}) + \Delta X_{payload} \quad (2.4)$$

Cette équation suppose que l'erreur de positionnement due à la charge utile est indépendante des autres phénomènes dégradant la précision. Ainsi, selon notre hypothèse, une nouvelle charge utile influencerait uniquement le terme $\Delta X_{payload}$. Dans l'approche classique, l'objectif du réseau de neurones est de prédire ΔX en fonction de la position articulaire. Deux réseaux de neurones entraînés pour deux charges différentes compenseront de la même manière le premier terme de l'équation, mais leurs prédictions seront différentes puisque $\Delta X_{payload}$ est différent. D'après la section 1.2.4, en remaniant les équations (1.12) à (1.14), l'erreur de positionnement due à la charge est communément modélisée

2.4. ADAPTABILITÉ À UNE VARIATION DE LA CHARGE UTILE

(a) Sous-espace de travail 1

Modèle	Erreur moyenne (mm)	Erreur max (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	4,554	5,67	0,47
$X = f(\xi_{réel}, \theta)$	0,189	0,381	0,17
$X = f(\xi_{nominal}, \theta) + ANN(w_P, s, \theta)$	0,09	0,204	0,04
$X = f(\xi_{réel}, \theta) + ANN(w_P, s, \theta)$	0,083	0,17	0,04

(b) Sous-espace de travail 2

Modèle	Erreur moyenne (mm)	Erreur max (mm)	Écart-type (mm)
$X = f(\xi_{nominal}, \theta)$	3,090	4,43	0,33
$X = f(\xi_{réel}, \theta)$	0,483	0,611	0,21
$X = f(\xi_{nominal}, \theta) + ANN(w_P, s, \theta)$	0,124	0,401	0,04
$X = f(\xi_{réel}, \theta) + ANN(w_P, s, \theta)$	0,071	0,217	0,04

TABLE 2.6 – Comparaison des performances du modèle hybride par rapport aux modèles analytiques et "boîte-noire" pour le KR300, avec une charge $P = 120kg$.

par :

$$\Delta X_{payload} = J \times K_{\theta}^{-1} \times J^{-1} \times \vec{P} \quad (2.5)$$

Ainsi, pour deux charges différentes ayant le même centre de gravité, la variation de l'erreur de positionnement est proportionnelle à la différence entre les deux charges. En revanche, d'après la section 1.2.4, la relation entre $\Delta X_{payload}$ et \vec{P} n'est linéaire que jusqu'à un certain point [Tuttle, 1992, Kircanski et al., 1993]. Nous remarquons cependant sur la figure 1.3 que la relation entre la déformation angulaire d'un engrenage et le couple appliqué est linéarisable par morceaux.

2.4.2.2 Description de la méthode

Cette méthode repose sur l'interpolation de deux prédictions provenant de deux ensembles de poids différents du réseau de neurones, entraînés dans le même sous-espace avec deux charges différentes P_1 et P_2 . D'après les considérations précédentes, l'interpolation des prédictions du réseau de neurones est mathématiquement équivalente à l'interpolation de $\Delta X_{payload}$, tant que le vecteur de charge \vec{P} dans l'équation (2.5) évolue linéairement, c'est-à-dire que le centre de gravité de l'effecteur ne varie que selon \vec{z}_{world} . Cette contrainte est communément satisfaite pour des applications de *pick-and-place*, de

perçage ou d'usinage. Pour une nouvelle charge connue P_{new} , le modèle devient :

$$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S}, \theta) \quad \text{avec} \quad \alpha = \frac{(P_2 - P_{new})}{(P_2 - P_1)} \quad (2.6)$$

Cette méthode est illustrée par la figure 2.14.

2.5 Validation des méthodes

A des fins de comparaison et de validation de chacune des méthodes proposées, nous utiliserons ici les données et les entraînements obtenus pour le KR300 (section 2.3.2) dans les deux sous-espaces respectifs S_1 et S_2 , pour les deux charges utiles $P_1 = 4kg$ et $P_2 = 120kg$.

2.5.1 Évaluation de la performance des modèles proposés

Avant toute validation expérimentale en utilisant l'algorithme de compensation, les performances et la pertinence des méthodes 1 et 2 sont évaluées. À des fins de comparaison, deux nouveaux ensembles de données de 1100 mesures chacun ont été acquis dans chaque sous-espace $S = S_1$ et $S = S_2$ avec une nouvelle charge $P_{New} = 72kg$. Dans chaque sous-espace, une comparaison a été effectuée entre :

- l'approche classique, i.e. $w_{P_{new}, S}$ obtenus en entraînant le réseau de neurones sur l'ensemble du dataset.

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_{New}, S}, \theta)$$

- un ensemble de poids non mis-à-jour $w_{P_1, S}$, entraîné selon l'approche classique, pour mettre en évidence le besoin d'adapter le réseau de neurones à une nouvelle charge.

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_1, S}, \theta)$$

- l'approche classique en entraînant le réseau de neurones avec autant de données que pour la méthode 1, pour mettre en évidence le fait qu'une initialisation intelligente des poids est plus efficace qu'utiliser des poids générés pseudo-aléatoirement. En pratique, $n_{data} = 15$.

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_{New}, S}, \theta)$$

- la méthode 1, comme décrite dans la section 2.4.1, appliquée avec $n_{data} = 15$.

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_1 \rightarrow new}, S, \theta)$$

- la méthode 2, comme décrite dans la section 2.4.2, appliquée avec $\alpha = \frac{120-72}{120-4} \simeq 0,414$.

$$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S}, \theta)$$

2.5. VALIDATION DES MÉTHODES

Les résultats sont présentés dans la table 2.7 et la figure 2.15. Tout d'abord, les résultats de l'approche classique, dont l'entraînement des poids $w_{P,S}$ a été réalisé sur l'ensemble des données, sont similaires à ceux obtenus avec $P_1 = 4kg$ et $P_2 = 120kg$ (tables 2.5 et 2.6), dans les deux sous-espaces, ce qui est cohérent avec la conclusion de la section 2.2.

(a) Sous-espace de travail 1

Modèle	Erreur moyenne (mm)	Erreur maximale (mm)
$X = f(\xi_{réel}, \theta) + ANN(w_{P_{New}, S_1}, \theta)$ (approche classique)	0,083	0,179
$X = f(\xi_{réel}, \theta) + ANN(w_{P_1, S_1}, \theta)$	0,223	0,328
$X = f(\xi_{réel}, \theta) + ANN(w_{P_{New}, S_1}, \theta)$ (15 données d'entraînement)	0,113	0,239
$X = f(\xi_{réel}, \theta) + ANN(w_{P_1 \rightarrow new}, S_1, \theta)$ (Méthode 1)	0,084	0,183
$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S_1}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S_1}, \theta)$ (Méthode 2)	0,132	0,244

(b) Sous-espace de travail 2

Modèle	Erreur moyenne (mm)	Erreur maximale (mm)
$X = f(\xi_{réel}, \theta) + ANN(w_{P_{New}, S_2}, \theta)$ (approche classique)	0,062	0,167
$X = f(\xi_{réel}, \theta) + ANN(w_{P_1, S_2}, \theta)$	0,392	0,563
$X = f(\xi_{réel}, \theta) + ANN(w_{P_{New}, S_2}, \theta)$ (15 données d'entraînement)	0,105	0,286
$X = f(\xi_{réel}, \theta) + ANN(w_{P_1 \rightarrow new}, S_2, \theta)$ (Méthode 1)	0,085	0,200
$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S_2}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S_2}, \theta)$ (Méthode 2)	0,265	0,366

TABLE 2.7 – Erreur moyenne et maximale de différents modèles pour une charge $P_{new} = 72 kg$ dans les deux sous-espaces de travail $S = S_1$ et $S = S_2$

Sur la figure 2.15, la distribution des erreurs pour la méthode 1 est très similaire à celle de l'approche classique de calibration hybride décrite dans la section 2.2, ce qui montre l'intérêt de cette méthode en termes d'efficacité des données. De plus, la méthode 1 donne des résultats significativement meilleurs que l'approche classique en utilisant le même nombre de données que la méthode 1 (15 données

d'entraînement). Cela signifie qu'avec un nombre égal de données d'entraînement, la réutilisation d'ensembles de poids préalablement entraînés est préférable à l'initialisation de nouveaux poids avec les méthodes classiques [Glorot and Bengio, 2010], témoignant ainsi de la pertinence d'un transfert d'apprentissage d'une charge à une autre.

Dans les deux sous-espaces, les méthodes 1 et 2 donnent de meilleurs résultats que l'utilisation d'un modèle entraîné avec une charge différente, mettant en évidence la nécessité d'adapter le modèle à de nouvelles charges utiles. Cependant, la méthode 2 donne de meilleurs résultats dans S_1 que dans S_2 . Cela peut s'expliquer par le fait que la configuration du robot et des outils dans S_1 n'entraîne pas de couple supplémentaire dû à un changement de position du centre de gravité de l'outil. En effet, pour les trois charges utiles utilisées P_1 , P_2 et P_{new} , la position du centre de gravité se trouve le long de \vec{z}_{flange} . Dans le cas de S_1 , la configuration du robot fait que \vec{z}_{flange} et \vec{z}_{world} sont colinéaires, il n'y a donc pas de bras de levier qui induirait un couple supplémentaire, contrairement à la configuration du robot dans S_2 , où \vec{z}_{flange} est orthogonal à \vec{z}_{world} . Ainsi, la relation entre le couple appliqué à chaque articulation évolue linéairement avec la charge dans S_1 , tandis que dans S_2 , elle dépend à la fois de la charge et de la position du centre de gravité.

Dans les cas où il est possible de mesurer de nouvelles données avec une nouvelle charge, la méthode 1 permet un processus de mesure rapide, avec des performances similaires à l'approche classique, mais avec un nombre beaucoup plus faible de données. Dans les cas où aucun dispositif de mesure n'est disponible, la méthode 2 donne de meilleurs résultats que l'utilisation d'ensembles de poids non mis à jour, mais peut donner des résultats moins bons que l'approche classique en raison d'un déplacement du centre de gravité de l'outil.

2.5.2 Validation expérimentale

Les méthodes présentées précédemment ont été validées expérimentalement, en utilisant l'algorithme de compensation présenté dans 1.5. Ainsi, 5 modèles ont été évalués dans le sous-espace S_1 :

- l'approche classique avec une charge $P_1 = 4kg$

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_1, S}, \theta)$$

- l'approche classique avec une charge $P_2 = 120kg$

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_1, S}, \theta)$$

- la méthode 1 ($w_{P_1 \rightarrow New, S_1}$) avec une charge $P_{new} = 72kg$

$$X = f(\xi_{réel}, \theta) + ANN(w_{P_1 \rightarrow new, S}, \theta)$$

2.5. VALIDATION DES MÉTHODES

- la méthode 2 (avec w_{P_1, S_1} et w_{P_2, S_1}) pour une nouvelle charge $P_{new} = 72 kg$ avec $\alpha = \frac{120-72}{120-4} \simeq 0,414$ (interpolation)

$$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S}, \theta)$$

- la méthode 2 (avec w_{P_1, S_1} et w_{P_2, S_1}) pour une nouvelle charge $P_{new} = 128 kg$ avec $\alpha = \frac{120-128}{120-4} \simeq -0,07$ (légère extrapolation)

$$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S}, \theta)$$

Les résultats des validations expérimentales sont représentés dans la figure 2.16 et résumés dans la table 2.8. Toutes les approches proposées ont une distribution d'erreurs similaire et sont toutes cohérentes avec les résultats précédents (figures 2.11 et 2.15 ; tables 2.5, 2.6 et 2.7). En pratique, nous avons toujours eu à la condition d'arrêt de l'algorithme de compensation (figure 2.8), un écart δ_i de l'ordre de de l'ordre de grandeur de $10^{-4}mm$, si bien que la position articulaire de sortie atteint en théorie parfaitement la position cartésienne souhaitée selon le modèle utilisé. La légère différence entre ces résultats et ceux présentés dans la section 2.5.1 provient de la répétabilité du robot et de la précision du laser tracker.

Charge	Modèle	Erreur moyenne (mm)	Erreur maximale (mm)
$P_1 = 4kg$	$X = f(\xi_{réel}, \theta) + ANN(w_{P_1, S}, \theta)$ (Approche classique)	0,13	0,23
$P_2 = 120kg$	$X = f(\xi_{réel}, \theta) + ANN(w_{P_1, S}, \theta)$ (Approche classique)	0,10	0,19
$P_{new} = 72kg$	$X = f(\xi_{réel}, \theta) + ANN(w_{P_1 \rightarrow new}, S, \theta)$ (Méthode 1)	0,08	0,20
$P_{new} = 72kg$	$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S}, \theta)$ (Méthode 2)	0,12	0,22
$P_{new} = 128kg$	$X = f(\xi_{réel}, \theta) + \alpha \times ANN(w_{P_1, S}, \theta) + (1 - \alpha) \times ANN(w_{P_2, S}, \theta)$ (Méthode 2)	0,11	0,19

TABLE 2.8 – Résultat de la validation expérimentale des modèles proposés, appliqués sur le KR300 dans S_1 en utilisant l'algorithme de compensation, pour différentes charges.

Les résultats montrent que la calibration hybride réduit de 97% l'erreur de positionnement par rapport à la précision du robot avant toute calibration (tables 2.5 et 2.6). Les méthodes proposées sont plus précises (précision finale de 0,02 et 0,06mm par rapport à la répétabilité du robot

(i.e. $0,058mm$, valeur établie dans la section 1.4) pour les méthodes 1 et 2 respectivement, tandis que les méthodes dans la littérature se situent entre $0,1$ et $0,3mm$ de la répétabilité du robot considéré [Nguyen et al., 2015, Zhao et al., 2019, Gadringer et al., 2020]). Par ailleurs, les méthodes proposées ne nécessitent aucune information spécifique (comme le modèle de masse du robot [Khalil and Besnard, 2002, Nguyen et al., 2015]) ni aucun capteur autre qu’un instrument de mesure (comme par exemple des capteurs de couple [Besset et al., 2016]). En particulier, les méthodes proposées sont capables d’utiliser des connaissances acquises précédemment pour compenser de nouvelles charges utiles, réduisant ainsi le temps et les efforts nécessaires pour effectuer toutes les mesures. En effet, quatre heures de mesures étaient nécessaires pour l’approche classique, mais seulement une demi-heure pour la méthode 1 (après avoir appliqué au moins une fois l’approche classique).

2.5.3 Discussion

Les résultats présentés précédemment montrent que les deux méthodes proposées fournissent des résultats satisfaisants pour la compensation de nouvelles charges utiles. La méthode 1 donne des résultats cohérents dans chacun des deux sous-espaces de travail, que ce soit sur un ensemble de données de test ou en validation expérimentale, en utilisant seulement 15 données et l’algorithme de compensation. La méthode 2 donne des résultats satisfaisant dans le sous-espace de travail \mathcal{S}_1 , mais performe moins bien dans le sous-espace de travail \mathcal{S}_2 . En effet, dans \mathcal{S}_2 , l’hypothèse d’interpolation n’est plus valide, puisque de centre de gravité de l’outil s’est déplacé selon une autre direction que \vec{z}_{world} . Cependant, cette hypothèse est souvent vérifiée dans l’industrie : \vec{z}_{flange} est souvent colinéaire à \vec{z}_{world} pour des opérations de *pick-and-place*, d’usinage ou de perçage. Par ailleurs, il est important de noter que cette méthode a été efficace non seulement en interpolation, mais aussi en extrapolation pour une charge de $128kg$, comme montré dans la table 2.8. En effet, d’après [Tuttle, 1992, Kircanski et al., 1993], la relation entre la déformation d’une articulation et le couple qui lui est appliqué n’est linéaire que jusqu’à un certain point. Néanmoins, cette relation peut tout de même être linéarisée par morceau, ce qui rendrait la méthode 2 efficace même pour des charges importantes.

Par ailleurs, il est possible de combiner les deux méthodes proposées. En pratique, pour améliorer la précision d’un robot industriel dans un sous espace \mathcal{S} pour une charge P_{light} , la méthode de calibration hybride ”classique” peut être appliquée, en utilisant un nombre suffisamment important de données, pour obtenir un premier jeu de poids $w_{P_{light}, S}$. Ensuite, pour reconfigurer le robot pour une nouvelle charge P_{heavy} , la méthode 1 peut être appliquée pour obtenir un nouveau jeu de poids $w_{P_{light} \rightarrow heavy, S}$ en utilisant un faible nombre de données. Enfin, pour reconfigurer à nouveau le robot pour une troisième charge $P_{intermediary}$, il est possible d’appliquer la méthode 2 en utilisant les deux jeux de poids précédemment obtenus $w_{P_{light}, S}$ et $w_{P_{light} \rightarrow heavy, S}$, sans avoir besoin d’acquérir de nouvelles données.

2.6 Conclusion

Dans ce chapitre, une analyse expérimentale comparative a montré que la calibration hybride n’offre pas de meilleurs résultats qu’une méthode ”boîte-noire” sur deux robots aux caractéristiques différentes. En particulier, plus le modèle analytique est précis, moins le nombre de données nécessaires à l’entraînement du réseau de neurones sera grand. En revanche, cette analyse a montré que la calibration hybride permet d’atteindre le même résultat avec moins de données d’entraînement que la calibration ”boîte-noire” [Selingue et al., 2022, Selingue et al., 2023b]. Le nombre de données d’entraînement optimal semble être celui à partir duquel l’erreur de positionnement atteint son plateau sur les figures 2.7 et 2.12.

En revanche, dans le cas d’un changement de charge, ce qui intervient lors d’applications de *pick-and-place*, ou d’usinage par exemple, la calibration hybride doit être à nouveau effectuée, pour que le réseau de neurones puisse compenser l’effet de la nouvelle charge. Bien que la calibration hybride soit moins consommatrice de données que la calibration ”boîte-noire”, elle demande tout de même un protocole expérimental long et relativement gourmand en données. Dans un objectif de reconfigurabilité aisée et peu gourmande en termes de temps et de données, deux méthodes basées sur le modèle hybride (équation (2.2)) ont été décrites et évaluées [Selingue et al., 2023b]. La première méthode (section 2.4.1) se base sur l’apprentissage par transfert pour réutiliser des connaissances acquises avec une certaine charge. Ainsi, l’entraînement du réseau de neurones pour une nouvelle charge s’en retrouve allégé, sans compromis sur sa précision. En effet, cette méthode a réduit l’erreur moyenne de positionnement du KR300 à $0,08mm$ par rapport à l’erreur moyenne produite par le modèle géométrique nominal, soit une amélioration de 97% de la précision. La seconde méthode (section 2.4.2) interpole directement les prédictions (jeux de poids $w_{P_1, S}$ et $w_{P_2, S}$) de ce même réseau de neurones précédemment entraîné dans le même sous-espace S pour deux charges utiles P_1 et P_2 . Cette méthode ne requiert aucune nouvelle donnée pour une nouvelle charge, cependant le centre de gravité de cette nouvelle charge doit rester selon \vec{z}_{world} . Cette contrainte est communément satisfaite pour la plupart des applications de *pick-and-place*, de perçage ou d’usinage. Avec cette méthode, l’erreur de positionnement moyenne du KR300 a été réduite de 96%, pour atteindre une valeur de $0,11mm$. Les méthodes proposées dans ce chapitre rendent alors les méthodes de calibration hybrides reconfigurables et adaptables à de légers changements de leurs utilisations, améliorant ainsi leur applicabilité dans des contextes industriels.

Ce chapitre s’est concentré sur les méthodes de calibration hybrides reposant sur des réseaux de neurones artificiels. Ces méthodes permettent une réduction du nombre de données requises par rapport aux méthodes boîte-noire, pour atteindre le même niveau de précision. En revanche, il n’est pas possible de connaître à l’avance le nombre de données requises. Par ailleurs, certains travaux de la littérature scientifique portent sur les méthodes de calibration hybrides utilisant des régresseurs par

2.6. CONCLUSION

processus gaussiens (GPR) [Jing et al., 2016]. Ces méthodes seront étudiées dans le chapitre suivant, afin de proposer une méthode optimisant le nombre de données nécessaires.

2.6. CONCLUSION




FIGURE 2.11 – Distribution de l’erreur de positionnement de l’effecteur du KR300 pour les 4 modèles étudiés, dans les deux sous-espaces de travail S_1 et S_2 , avec les charges $P_1 = 4kg$ et $P_2 = 120kg$.

2.6. CONCLUSION

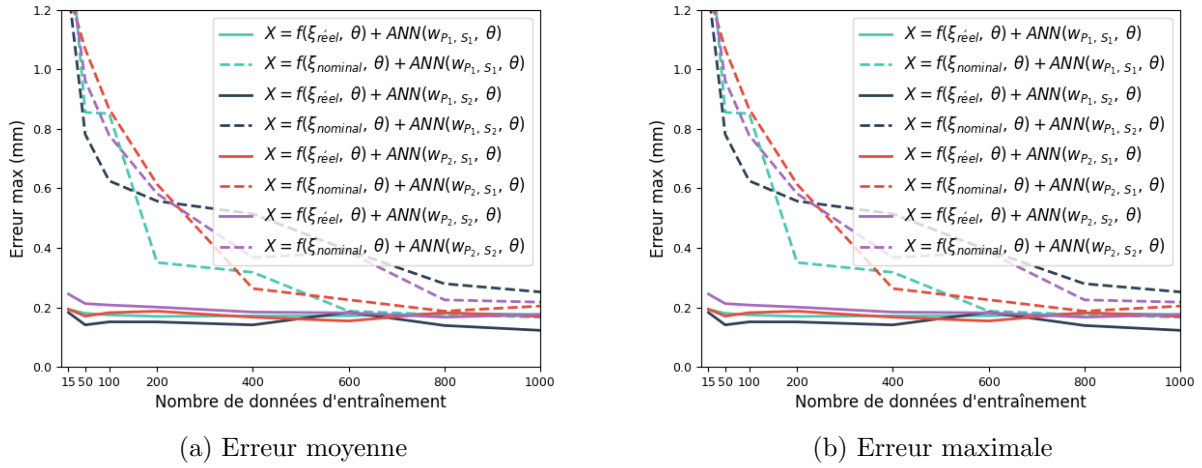


FIGURE 2.12 – Influence du nombre de données sur l’erreur de positionnement moyenne et maximale.




FIGURE 2.13 – Principe de la méthode 1

2.6. CONCLUSION




FIGURE 2.14 – Principe de la méthode 2




FIGURE 2.15 – Distribution de l'erreur de positionnement (mm) (sur 100 points de validation extraits aléatoirement du dataset d'entraînement avant l'entraînement) pour une nouvelle charge $P_{new} = 72\text{kg}$. La ligne verticale représente l'erreur moyenne.

2.6. CONCLUSION

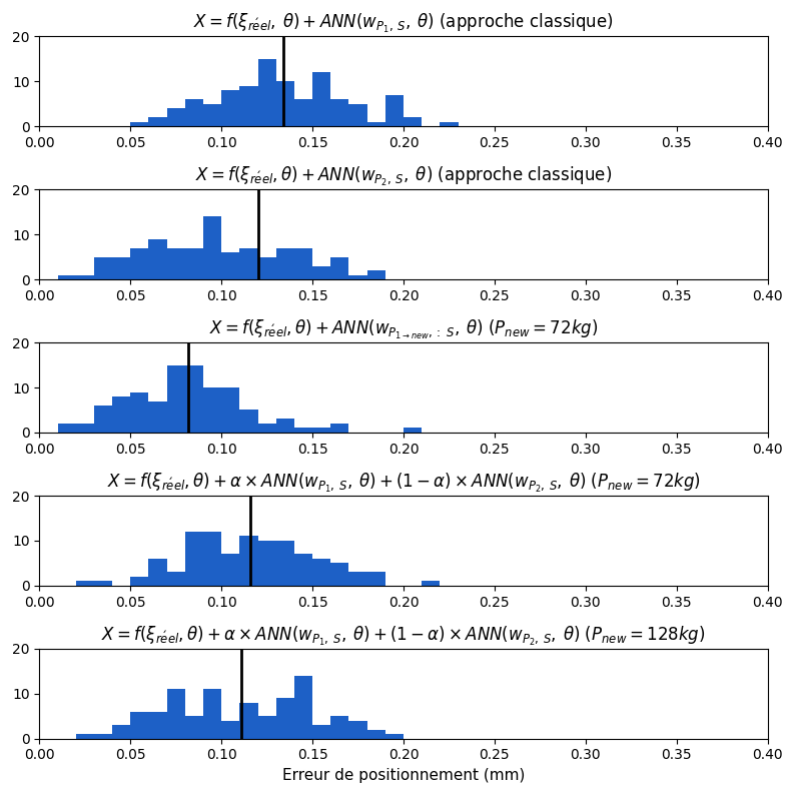


FIGURE 2.16 – Distribution de l’erreur de positionnement (mm) sur 100 points de validation, en utilisant l’algorithme de compensation. La ligne verticale représente l’erreur moyenne.

2.6. CONCLUSION

Chapitre 3

Calibration hybride optimisée et autonome par apprentissage actif

Contenu

3.1	Introduction	74
3.2	Description de la méthode	76
3.2.1	Régresseurs par processus gaussiens	76
3.2.2	Algorithme d'apprentissage actif	77
3.2.3	Calibration hybride active	79
3.3	Design de l'algorithme d'apprentissage actif	80
3.3.1	Choix du noyau	81
3.3.2	Influence du noyau de bruit	83
3.3.3	Méthode d'initialisation	84
3.3.4	Influence de l'identification des paramètres géométriques	85
3.3.5	Choix du critère d'arrêt	86
3.3.6	Évaluation du modèle hybride	87
3.4	Validation expérimentale de l'algorithme d'apprentissage actif	89
3.4.1	Application sur robot industriel	89
3.4.2	Application sur robot collaboratif	93
3.5	Conclusion	96

3.1 Introduction

Le chapitre précédent s’est concentré sur des méthodes de calibration hybrides, basées sur l’identification des paramètres géométriques et l’entraînement de réseaux de neurones, dans le but de les rendre plus agiles. Grâce aux deux méthodes proposées, la reconfiguration pour de nouvelles charges dans un même sous-espace de travail devient économe en données et en temps. La section 2.5.3 a présentée un bilan de ces deux méthodes.

Cependant, même si ce chapitre a montré que les réseaux de neurones couplés à l’identification des paramètres géométriques nécessitent beaucoup moins de données que la calibration ”boîte-noire”, il n’existe actuellement aucun moyen de déterminer combien de données sont suffisantes : il est nécessaire de collecter trop de données avant de réaliser que moins de données auraient été suffisantes, ce qui conduit à des processus de mesures non optimaux.

Par ailleurs, les réseaux de neurones artificiels sont connus pour pouvoir approcher des fonctions complexes, c’est la raison pour laquelle les travaux dans la littérature portant sur la calibration hybrides les ont principalement utilisés. Cependant, d’autres méthodes d’apprentissage automatique pourraient tenir le rôle qu’ont les réseaux de neurones artificiels dans la calibration hybride, comme les régresseurs par processus gaussiens (dénommés ci-après par leur acronyme anglais GPRs). Par exemple, [Jing et al., 2016] ont utilisé les GPRs pour prédire l’erreur de positionnement de l’effecteur d’un robot industriel dont les paramètres géométriques ont été identifiés. Leur méthode est très similaire à celle de [Zhao et al., 2019], mais utilise un GPR au lieu d’un réseau de neurones. Les GPRs sont aussi utilisés pour modéliser plus précisément la dynamique d’un robot [Camoriano et al., 2016, Romeres et al., 2016].

Les méthodes ci-dessus n’exploitent pas certaines possibilités offertes par les GPRs, comme par exemple l’intégration d’un modèle du bruit ou l’estimation de l’incertitude de prédiction. En revanche, [Pasolli and Melgani, 2011] ont utilisé ces possibilités pour proposer un algorithme d’apprentissage actif (*active learning*). L’algorithme proposé a été validé sur deux datasets publics (MERIS et SeaBAM) portants sur l’étude de la concentration en chlorophylle de l’océan par analyse spectrale. Le principe de l’apprentissage actif est de permettre à un modèle d’apprentissage automatique de sélectionner de manière active les données à partir desquelles il apprend, plutôt que de s’appuyer passivement sur des données fournies à l’avance. L’un des objectifs est de maximiser l’efficacité de l’apprentissage en choisissant les exemples qui apportent le plus d’informations au modèle, tout en minimisant le nombre total d’exemples nécessaires.

Le champ de l’optimisation des processus de mesure a déjà été investi dans la littérature scientifique. En effet, plusieurs méthodes ont été développées pour optimiser les points de mesures utilisés pour identifier les paramètres d’un modèle analytique. En se basant sur la matrice jacobienne

3.1. INTRODUCTION

des paramètres à identifier (voir section 1.3.1), il est possible de calculer des indices d'observabilité [Sun and Hollerbach, 2008, Joubair and Bonev, 2013, Joubair et al., 2016, Klimchik et al., 2012, Klimchik et al., 2015, Wang et al., 2017, Wu et al., 2015]. Ces indices se calculent sur la base des valeurs propres de la matrice jacobienne utilisée dans la méthode des moindres carrés. En revanche, il n'existe pas à ce jour de méthode permettant de réduire le nombre de données nécessaires à l'entraînement d'un modèle d'apprentissage automatique dans le contexte de la calibration de robots industriels et collaboratifs.

L'optimisation du processus de mesure, en vue de minimiser le nombre de points requis pour l'entraînement des modèles, présente deux avantages. D'une part, cela réduirait le coût en temps du processus de calibration : les ressources nécessaires à la calibration (robot, instrument de mesure, opérateur) sont moins immobilisées. D'autre part, cela pourrait permettre d'éviter des effets indésirables pendant le processus de calibration, en particulier la dérive thermique. En effet, comme montré dans la section 1.2.6, le temps de stabilisation du phénomène de dérive thermique peut atteindre plus de 10h. Ainsi, il serait nécessaire de pré-chauffer le robot pendant 10h avant toute calibration, pour éviter de biaiser les mesures par l'effet de la dérive thermique. En revanche, si le processus de calibration est suffisamment rapide, il ne laisse pas le temps au phénomène de dérive thermique de perturber les mesures et biaiser les données d'entraînement. Il est cependant important de noter que si les effets thermiques doivent être pris en compte dans le modèle, le GPR peut être entraîné avec des données acquises alors que le robot a atteint sa température nominale, ou un modèle analytique tel que celui présenté dans la section 1.2.6 peut être utilisé.

Dans ce chapitre, une méthode de calibration hybride active est présentée, s'inspirant des travaux de [Pasoli and Melgani, 2011]. L'objectif de cette méthode est d'une part de réduire drastiquement le nombre de données requises pour l'entraînement du modèle d'apprentissage, tout en conservant un haut niveau de performances, d'autre part de rendre le processus de calibration automatique et autonome. La méthode (illustrée par la figure 3.1) utilise l'indicateur d'incertitude de prédiction des GPRs pour construire itérativement l'ensemble de données d'entraînement : après une courte phase d'initialisation, l'algorithme choisit lui-même, de manière itérative, les données les plus pertinentes (à chaque itération celle pour laquelle la prédiction est la plus incertaine) et décide de la fin du processus. Étant donné que l'algorithme proposé dépend de plusieurs paramètres (par exemple, le noyau de régression utilisé ou la condition d'arrêt), leurs influences respectives sur l'efficacité de la méthode ont été étudiés, en utilisant les données issues du chapitre précédent. Cela nous permet d'éclairer des choix clés (comme la condition d'arrêt) de façon à obtenir un bon apprentissage de l'erreur résiduelle avec le minimum de données possibles. Une analyse et une évaluation plus complètes des performances et de l'apport de la méthode est ensuite faite un fois la méthode "réglée". Finalement, la méthode proposée, couplée à l'algorithme de compensation, a été validée sur le KR300. Ces paramètres ont été utilisés pour valider expérimentalement la méthode proposée sur le KR300 afin de compenser les erreurs de positionnement,

3.2. DESCRIPTION DE LA MÉTHODE

ainsi que sur l'*iiva* pour réduire à la fois les erreurs de positionnement et d'orientation de l'effecteur. Une vidéo illustrant le principe de la méthode et montrant son intégration et sa validation en condition réelle sur le KR300 est disponible via le lien suivant : https://youtu.be/u8NG4IJTOBA?si=TvoHq_fEaa_UFiR1.




FIGURE 3.1 – Description de la méthode de calibration hybride active

La section 3.2 décrit la méthode générale : la méthode de calibration hybride y est détaillée, et l'algorithme d'apprentissage actif pour l'approximation de l'erreur résiduelle y est présenté d'abord sur un cas simple, puis est portée au cas de la calibration de robot industriel. La section 3.3 ajuste empiriquement les paramètres de la méthode, en utilisant les ensembles de données issues du chapitre précédent. Le processus de calibration hybride actif est appliqué sur deux robots aux caractéristiques différentes : un robot collaboratif (KUKA *iiva*) et un robot industriel (KUKA KR300). L'application et les résultats du processus de calibration hybride actif sont présentés dans la section 3.4. Enfin, la section 3.5 conclue, et apporte des éléments de discussion.

3.2 Description de la méthode

3.2.1 Régresseurs par processus gaussiens

Un régresseur par processus gaussien (GPR) est un outil d'apprentissage automatique utilisé pour la régression par une approche bayésienne. Les GPRs traitent les données d'entraînement comme une distribution gaussienne à plusieurs variables (ainsi, un GPR est défini par ses fonctions de moyenne et de covariance, $m(x)$ et $k(x, x')$), de sorte qu'une prédiction puisse être faite pour n'importe quelle nouvelle entrée via une inférence bayésienne [Williams and Rasmussen, 2006].

Pour un ensemble d'entraînement (x_t, y_t) , la distribution gaussienne à plusieurs variables est la suivante :

$$y_t \sim \mathcal{N}(m(x_t), K(x_t, x_t)) \quad (3.1)$$

avec $K(x_t, x_t)$ la matrice de covariance des entrées. La moyenne $m(x)$ représente un tendance connue

3.2. DESCRIPTION DE LA MÉTHODE

autour de laquelle le GPR va apprendre la différence, et doit sortir un modèle de régression permettant des prédictions fidèles. Dans le cas étudié, le GPR sera entraîné avec :

$$GPR(\theta) \Leftarrow X_{mesuré} - f(\xi_{réel}, \theta) \quad (3.2)$$

où $X_{mesuré}$ est la position mesurée de l'effecteur et $f(\cdot)$ est le modèle analytique après identification des paramètres géométriques, c'est à dire la différences entre les mesures et le modèle analytique. Le modèle analytique f représentant déjà la tendance, nous choisirons donc $m(x) = 0$.

Pour toute nouvelle entrée x_{new} , la distribution gaussienne de moyenne $m(x) = 0$ devient :

$$\begin{pmatrix} y_t \\ y_{new} \end{pmatrix} \sim \mathcal{N}\left(0, \begin{pmatrix} K(x_t, x_t) & K(x_t, x_{new}) \\ K(x_{new}, x_t) & K(x_{new}, x_{new}) \end{pmatrix}\right) \quad (3.3)$$

A partir du principe d'inférence de Bayes, il suit :

$$y_{new}|y_t \sim \mathcal{N}(K(x_t, x_{new})K(x_t, x_t)^{-1}y_t, K(x_{new}, x_{new}) - K(x_t, x_{new})K(x_t, x_t)^{-1}K(x_{new}, x_t)) \quad (3.4)$$

À partir de l'équation (3.4), la moyenne et l'écart type pour n'importe quelle nouvelle entrée peuvent être prédites, par inférence bayésienne, à partir des observations précédentes. La moyenne est la prédiction, et l'écart-type peut être interprété comme un indicateur d'incertitude sur la prédiction : plus l'écart-type est faible, plus la prédiction est fiable. Cette incertitude peut être utilisée dans un algorithme d'apprentissage actif pour réduire le nombre de données d'observation nécessaires, comme présenté dans [Pasolli and Melgani, 2011].

La méthode proposée dans ce chapitre a été développée en Python en utilisant la bibliothèque *scikit-learn* [Pedregosa et al., 2011] pour l'entraînement des GPRs.

3.2.2 Algorithme d'apprentissage actif

L'apprentissage actif est une sous-partie de l'apprentissage automatique dans laquelle le modèle est capable de choisir activement les données les plus pertinentes à partir desquelles apprendre, plutôt que d'être passivement entraîné sur un ensemble de données pré-sélectionnées. Dans ce contexte, l'un des objectifs de l'apprentissage actif est d'entraîner un modèle d'apprentissage automatique avec la plus petite quantité de données labélisées tout en maintenant un haut niveau de performance. En commençant par très peu de données provenant de mesures espacées dans le sous-espace de travail, une cartographie d'incertitude fournie par le GPR est exploitée pour construire un processus itératif d'apprentissage actif autonome. Ainsi, seules les nouvelles données pertinentes sont acquises jusqu'à ce qu'une condition d'arrêt soit atteinte.

3.2.2.1 Application à un cas simple

Pour illustrer le fonctionnement de l'algorithme, nous allons l'appliquer sur un problème de régression simple à 1 dimension : l'approximation de la fonction $f(x) = x * \sin(x)$ pour $x \in [0; 10]$. Le GPR est entraîné sur un ensemble de mesures, $(x_i, x_i * \sin(x_i))$, et produit pour toute entrée $x \in [0, 10]$ une prédiction de $x * \sin(x)$ avec une valeur d'incertitude sur la prédiction $p(x)$ (écart-type $\sigma(x)$). Sur un cas simple comme celui de la fonction $f = x * \sin(x)$, pour chaque prédiction, nous avons ainsi la connaissance de l'intervalle de confiance à 95% (intervalle à $\pm 2\sigma$) de la prédiction du GPR. En discrétisant finement l'intervalle $[0; 10]$, et en y appliquant le GPR, nous pouvons alors obtenir un intervalle de confiance complet de la fonction à approximer. Sur la figure 3.2, la fonction à approximer est représentée par la ligne pointillée bleue ; les points bleus représentent les observations (i.e. les données d'entraînement du GPR), la ligne pointillée rouge est la prédiction sur l'intervalle discrétisé $[0; 10]$, et la plage orange l'intervalle de confiance à 95% correspondant.

Sur la figure 3.2a, nous pouvons voir que l'intervalle de confiance est très large autour de $x = 5$. Ceci est dû au fait que les observations sont assez éloignées de ce point. L'algorithme d'apprentissage actif va alors requérir une observation au point où l'intervalle de confiance est le plus grand, c'est-à-dire là où l'incertitude de prédiction est la plus grande. La figure 3.2b montre l'effet qu'a l'ajout de cette observation sur le comportement du GPR. L'intervalle de confiance aux abords de la nouvelle observation a fortement diminué. De plus, le comportement du GPR a été globalement amélioré, même loin de l'ajout du point d'observation. C'est pourquoi, dans un souci d'efficacité en données, les nouvelles données seront acquises une à une (à chaque itération la donnée où σ est maximum), puisque la cartographie d'incertitude change entre deux points de mesures, même loin du nouveau point de mesure. Sur la figure 3.2c, nous pouvons voir également que l'ajout d'une nouvelle observation, là où l'intervalle de confiance était le plus large sur la figure 3.2b, réduit à nouveau l'intervalle de confiance et améliore globalement les prédictions du GPR. De la même manière, sur la figure 3.2d, le GPR est en mesure de prédire assez fidèlement la fonction $f(x) = x * \sin(x)$ pour $x \in [0; 10]$ avec seulement 8 observations.

3.2.2.2 Généralisation à la calibration de robots

L'algorithme décrit précédemment pour un cas simple peut être appliqué à un cas multi-dimensionnel plus complexe. Dans le cadre de la calibration de robot industriel, le GPR doit prédire l'erreur de positionnement de l'effecteur du robot en fonction de sa configuration articulaire. Les étapes de la méthode d'apprentissage actif sont les mêmes que pour le cas précédent. D'abord, la phase d'initialisation consiste à mailler le sous-espace de travail qui doit être calibré. Plus le maillage (notée \mathcal{G}) est fin, plus le choix de nouvelles observations pertinentes sera précis. Ensuite, quelques échantillons doivent être

3.2. DESCRIPTION DE LA MÉTHODE

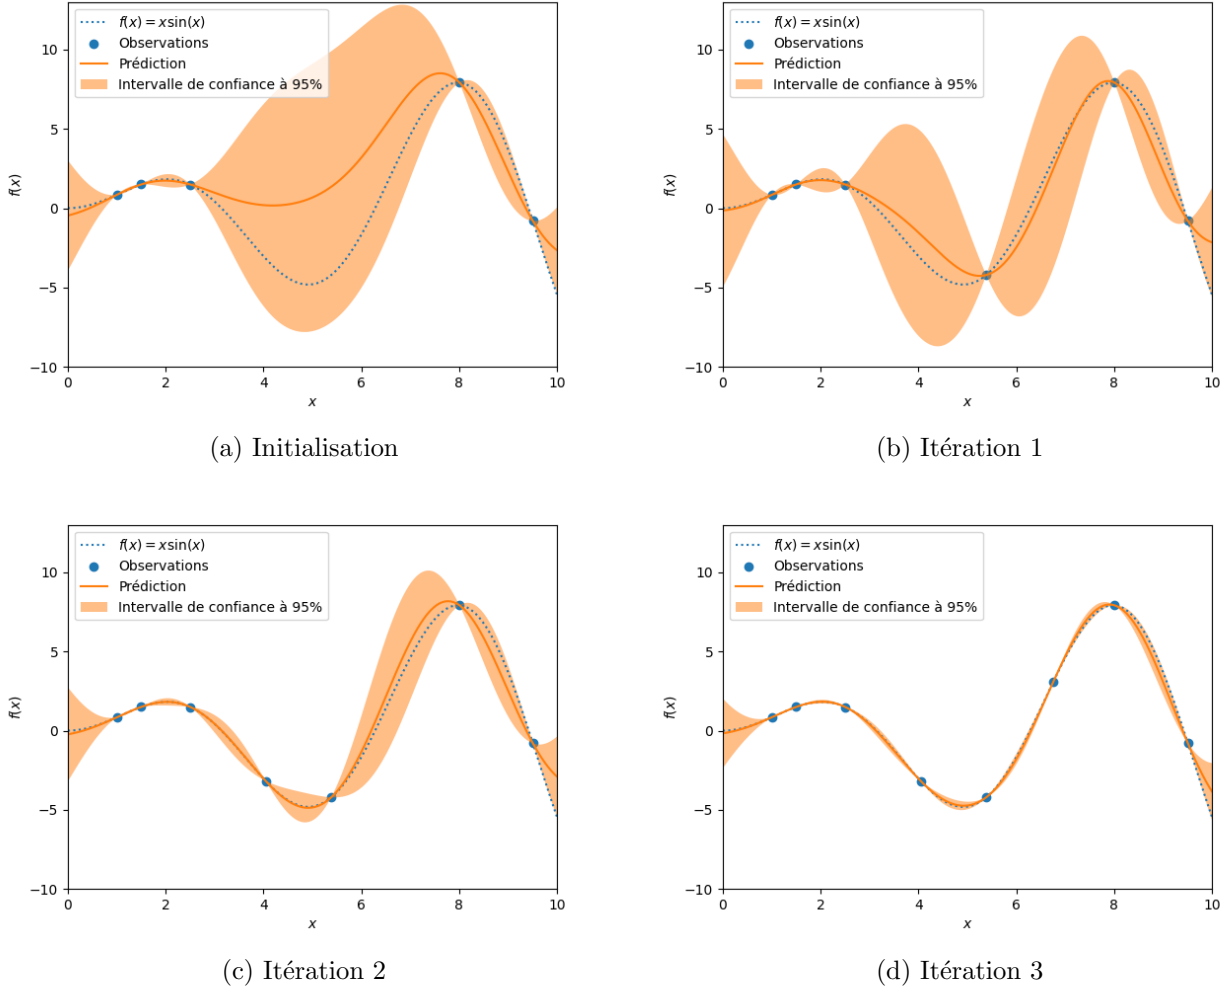


FIGURE 3.2 – Apprentissage actif appliqué à un cas simple.

sélectionnés parmi \mathcal{G} pour former l'ensemble d'entraînement initial. Après l'entraînement d'un GPR sur cet ensemble, le GPR construit une cartographie d'incertitude (par une prédiction sur l'ensemble des points du maillage \mathcal{G}) et choisit la prochaine donnée a à acquérir comme celle ayant l'écart-type le plus élevé (c'est-à-dire l'incertitude de prédiction la plus élevée). Cette dernière étape est répétée jusqu'à ce qu'une condition d'arrêt soit satisfaite. Ce processus est résumé dans l'algorithme 1, et la méthode globale proposée est illustrée à la figure 3.1.

3.2.3 Calibration hybride active

Le processus de calibration hybride actif décrit dans ce chapitre est similaire à celui du chapitre précédent. Le modèle analytique utilisé reste le modèle géométrique direct avec les paramètres géomé-

Algorithm 1 Algorithme d'apprentissage actif

Require: \mathcal{G} , $\theta_{measured}$, $X_{measured}$
fit $GPR(\theta_{measured}, X_{measured})$
repeat
 $m, \sigma \leftarrow GPR(\mathcal{G})$
 $\theta_{next} \leftarrow \mathcal{G}(max(\sigma))$
 $X_{next} \leftarrow measurement(\theta_{next})$
 $\theta_{measured}, X_{measured} \leftarrow append(\theta_{next}, X_{next})$
 fit $GPR(\theta_{measured}, X_{measured})$
until *stopping condition*

triques identifiés. En effet, d'après les résultats obtenus dans le chapitre 1 (section 1.4.4), l'identification des paramètres géométriques est la méthode présentant le meilleur compromis entre facilité de mise en oeuvre et réduction de l'erreur de positionnement. De plus, elle ne nécessite pas d'autres capteurs ou instrument de mesure qu'un Laser Tracker. La calibration géométrique est effectuée sur un ensemble de 70 points pour les deux robots, répartis dans l'ensemble de l'espace de travail du robot. Ensuite, autant de sous-espaces de travail que nécessaires sont définis. Dans ce chapitre, un seul sous-espace de travail est défini par robot, étant donné que le chapitre précédent a montré que les méthodes de calibration hybrides fournissent des performances très similaires quelle que soit la localisation du sous-espace de travail. De la même manière, ce chapitre se concentre sur l'optimisation du processus de mesure : l'effet de différentes charges utiles n'est pas pris en considération. Le processus d'entraînement du GPR se déroule comme décrit dans la section précédente : un faible nombre de mesures initiales est acquis dans le sous-espace en question, puis les itérations successives de l'algorithme d'apprentissage actif affinent l'entraînement du GPR de manière efficace. A la fin de l'algorithme d'apprentissage actif, le modèle hybride est :

$$X = f(\xi_{réel}, \theta) + GPR_S(\theta) \quad (3.5)$$

Ce modèle peut ainsi être utilisé dans l'algorithme de compensation décrit dans la section 1.5, pour calculer la configuration articulaire à commander au robot pour atteindre une position cartésienne désirée. Ainsi, l'algorithme de compensation utilisant le modèle précédent (équation (3.5)) est décrit dans la figure 3.3.

3.3 Design de l'algorithme d'apprentissage actif

Dans l'algorithme proposé, plusieurs paramètres doivent être réglés avec soin. Tout d'abord, comme indiqué dans la section 3.2.1, un GPR est défini par sa fonction moyenne et sa fonction de covariance, également appelée noyau. Les noyaux des GPRs peuvent être la somme de noyaux usuels, généralement un noyau de régression (comme le noyau Matérn ou encore la fonction de base radiale, dénotée RBF ci-




FIGURE 3.3 – Algorithme de compensation utilisant le modèle décrit par l'équation (3.5).

après) et un noyau de bruit, qui permet de modéliser le bruit de mesure. L'influence de différents noyau de bruit, et également celle de la distribution des données initiales, seront étudiés. Dans le contexte de la calibration hybride, l'influence de la calibration géométrique effectuée en premier lieu dans le processus global de calibration hybride sera également étudiée. Tous ces éléments seront étudiés à l'aide des données utilisées dans le chapitre précédent (section 2.3). Cet ensemble de données est composé de 2100 points de mesure, répartis uniformément dans un sous-espace de travail de l'*iiva*. Ainsi, l'ensemble de données (θ, X) issu du chapitre 2 constitue le maillage \mathcal{G} discuté précédemment. L'algorithme d'apprentissage actif peut donc être exécuté hors-ligne : pour chaque itération, le GPRs fera une prédiction sur l'ensemble des θ dont la position cartésienne à déjà été mesurée, et la prédiction la plus incertaine sera ajoutée au dataset d'entraînement, avec la position cartésienne mesurée correspondante. Enfin, les bénéfices de l'algorithme basé sur l'apprentissage actif utilisant les GPRs sont démontrés par comparaison avec d'autres modèles.

3.3.1 Choix du noyau

Comme indiqué précédemment, les noyaux des GPRs sont le plus souvent la somme de certains noyaux usuels : l'un à des fins de régression, l'autre pour la modélisation du bruit de mesure. Ici, quelques noyaux de régression couramment utilisés seront comparés.

En se basant sur les observations effectuées sur un graphique interactif (représenté à la figure 3.4), le champ de vecteurs d'erreur qui doit être approché par le GPR semble lisse et différentiable. Dans de tels cas, la famille de fonctions de covariance *Matérn* est communément utilisée. Elle est définie

comme suit :

$$k_\nu(x, y) = \frac{2^{1-\nu}}{\Gamma(\nu)} \left(\frac{\sqrt{2\nu}r}{\rho} \right)^\nu K_\nu \left(\frac{\sqrt{2\nu}r}{\rho} \right) \quad (3.6)$$

avec ρ le paramètre de portée, ν le paramètre de régularité, Γ la fonction gamma et K_ν la fonction de Bessel modifiée de deuxième espèce d'ordre ν . Le paramètre de portée ρ est automatiquement ajusté par le GPR. Le paramètre ν représente la différentiabilité de la fonction à approximer : $\nu = 1,5$ correspond à une fonction une fois différentiable, $\nu = 2,5$ à une fonction deux fois différentiable, et ainsi de suite. Le cas particulier $\nu \rightarrow \infty$ correspond à la Fonction de Base Radiale (RBF).

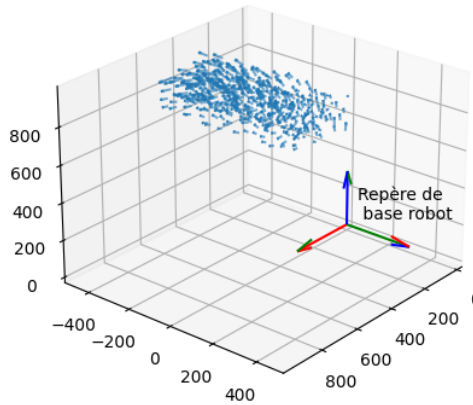


FIGURE 3.4 – Champ de vecteurs d’erreur dans l’ensemble du sous-espace calibré. Toutes les erreurs ont été amplifiées par le même facteur, pour être rendues visibles.

Ces trois noyaux (*Matérn*($\nu = 1,5$), *Matérn*($\nu = 2,5$), *RBF*) ont été comparés sur l’ensemble de test. Pour ce faire, 100 points ont été extraits au hasard de l’ensemble de données pour former l’ensemble de test. Ensuite, 5 autres points ont été extraits au hasard pour initialiser l’algorithme. Enfin, l’algorithme a été exécuté sur 45 itérations, de sorte que l’ensemble d’entraînement soit finalement composé de 50 points. Pour cette comparaison, aucune condition d’arrêt n’a été utilisée, afin d’étudier pleinement les performances de chacun des noyaux. Enfin, la précision du modèle hybride $X = f(\xi_{réel}, \theta) + GPR_S(\theta)$ (équation (3.5)) est comparée à la position cartésienne mesurée pour les positions articulaires correspondantes de l’ensemble de test. Les résultats sont résumés dans la figure 3.5. D’après cette figure, les performances ne sont pas très sensibles au choix du noyau parmi les trois étudiés. Comme l’initialisation est aléatoire, ce test a été exécuté plusieurs fois et les résultats sont toujours cohérents avec ceux présentés. Ainsi, le noyau *Matérn*($\nu = 1,5$) sera utilisé par la suite.

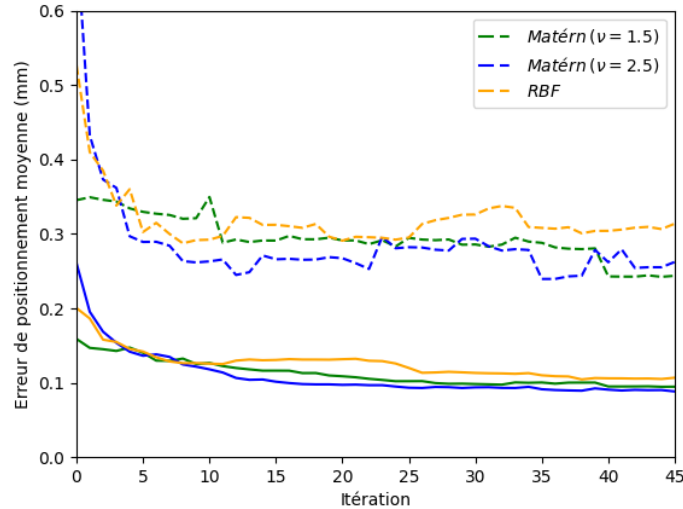


FIGURE 3.5 – Comparaison des différents noyaux pour l'approximation de l'erreur de positionnement. Les lignes pleines montrent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés montrent l'évolution de l'erreur maximale.

3.3.2 Influence du noyau de bruit

Étant donné que les données d'observation utilisées pour entraîner le GPR proviennent de mesures réelles, elles sont accompagnées d'un bruit de mesure. En supposant que ce bruit soit gaussien, avec une moyenne nulle et une variance σ^2 , le noyau utilisé dans le GPR pourrait être ajouté à un noyau de bruit qui prend en compte ce bruit de mesure. De cette manière, notre modèle n'interpolera pas exactement les données d'observations, mais distribuera les résidus selon la loi du modèle de bruit choisie $\mathcal{N}(0, \sigma)$, pour refléter des réalisations de bruits de mesure. Cependant, ce niveau de bruit n'est pas exactement connu, car la précision de l'appareil de mesure dépend d'une part de la distance entre le laser tracker et la bille réfléchissante (SMR), qui n'est donc pas constant, d'autre part de la répétabilité du robot (qui dépend elle aussi de la précision de l'appareil de mesure). Par conséquent, 5 scénarios différents ont été envisagés pour étudier l'influence de la valeur σ pour les réglages du noyau de bruit sur les performances du processus de calibration proposé :

- $\sigma = 0$, pour évaluer le besoin d'un noyau de bruit.
- $\sigma = 0,04$, dont le carré correspond à la somme de la variance de l'appareil de mesure, donnée par le logiciel d'acquisition, et de la variance des points mesurés lors d'un test de répétabilité, effectué sur le même robot dans le sous-espace calibré. Cela peut être considéré comme un niveau de bruit *bien évalué*, compte tenu des données disponibles et des différents tests effectués.

- $\sigma = 0,01$, correspondant à un niveau de bruit *sous-évalué*.
- $\sigma = 0,08$, correspondant à un niveau de bruit *sur-évalué*.
- σ *adaptatif*, correspondant à laisser le GPR ajuster automatiquement la valeur de σ pendant les phases d'entraînement.

L'algorithme a été évalué selon les mêmes conditions que le test précédent. Conformément à la section 3.3.1, le noyau de régression utilisé ici est *Matérn*($\nu = 1,5$). Le résultat de cette étude est représenté à la figure 3.6. Nous pouvons constater qu'un bruit surévalué ne profite pas à l'algorithme : l'erreur de positionnement moyenne est supérieure à tous les autres scénarios, en raison de résidus excessifs. Étant donné qu'il n'y a pas de grande différence entre les autres réglages, les réglages de bruit adaptatif sont préférés, car ils ne nécessitent aucune connaissance *a priori* sur le niveau de bruit.




FIGURE 3.6 – Comparaison des différents réglages du noyau de bruit. Les lignes pleines représentent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés représentent l'évolution de l'erreur maximale.

3.3.3 Méthode d'initialisation

La distribution initiale des données à travers \mathcal{G} est maintenant étudiée. Comme l'objectif est d'obtenir uniquement les données les plus pertinentes pour la phase d'entraînement, la taille de l'ensemble de données initial devrait être aussi petite que possible. Dans ce qui suit, le nombre de données d'initialisation est fixé à 5, ce qui semble être un compromis empirique entre la vitesse de convergence et le nombre de données requis. Étant donné que ce nombre est faible, le choix aléatoire des points pourrait

conduire à des résultats très différents d'une initialisation à l'autre. Au lieu de choisir aléatoirement, il est possible d'utiliser des suites à discrédance faible (comme les suites de Halton [Halton, 1964]), de sorte que les données soient choisies de manière déterministe et plus uniformément réparties dans le sous-espace. Les suites à discrédance faible sont des suites de nombres réels conçues pour fournir une répartition pseudo-uniforme dans un espace multidimensionnel.

Ces deux méthodes différentes d'initialisation sont comparées avec une expérience similaire à celle précédemment réalisée. Le noyau utilisé pour le GPR est le noyau *Matérn*($\nu = 1, 5$), ajouté à un noyau de bruit avec un niveau de bruit adaptatif. L'évolution de l'erreur moyenne et maximale sur l'ensemble de test au fil des itérations de l'algorithme est représentée à la figure 3.7. On peut constater que la suite de Halton donne de meilleurs résultats que l'initialisation aléatoire. De plus, l'expérience a été réalisée plusieurs fois, car l'initialisation aléatoire fournit des résultats différents d'une exécution à une autre, mais la suite de Halton donne constamment de meilleurs résultats.

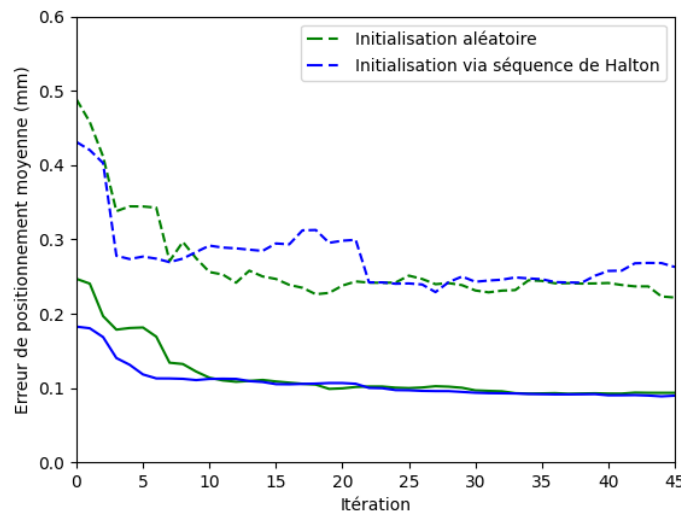


FIGURE 3.7 – Comparaison des différentes méthodes d'initialisation. Les lignes pleines représentent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés représentent l'évolution de l'erreur maximale.

3.3.4 Influence de l'identification des paramètres géométriques

Puisque l'objectif de la méthode proposée est d'être plus efficace en termes de données, il serait possible que la calibration géométrique nécessiterait plus de données qu'elle n'en économiserait pour l'entraînement des GPRs. Pour le vérifier, l'influence de l'identification des paramètres géométriques est étudiée : deux GPRs sont entraînés, suivant la même démarche que précédemment, mais l'un prédit l'erreur de positionnement à partir du modèle géométrique direct avec les paramètres géométriques

3.3. DESIGN DE L'ALGORITHME D'APPRENTISSAGE ACTIF

nominaux, tandis que l'autre utilise les paramètres géométriques identifiés. L'évolution de l'erreur moyenne et maximale sur l'ensemble de test au fil des itérations de l'algorithme basé sur l'apprentissage actif est représentée à la figure 3.8.

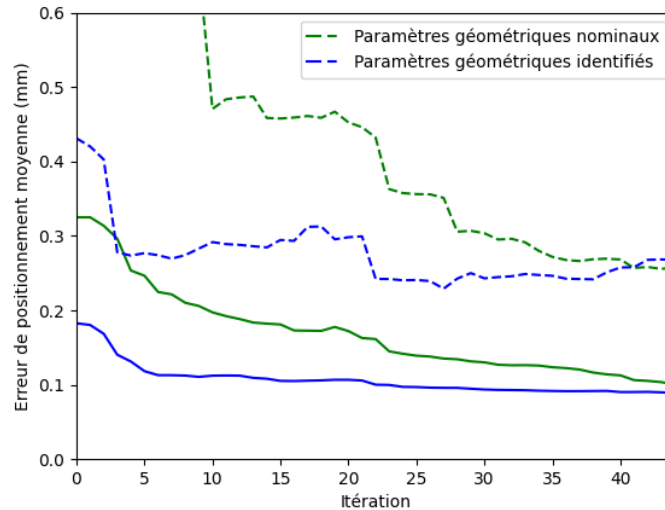


FIGURE 3.8 – Comparaison de la calibration *sans modèle* et de la calibration *hybride*. Les lignes pleines représentent l'évolution de l'erreur moyenne sur l'ensemble de test au fil des itérations de l'algorithme, les lignes en pointillés représentent l'évolution de l'erreur maximale.

Nous pouvons voir sur la figure 3.8 que l'utilisation des paramètres géométriques identifiés au lieu des paramètres nominaux conduit à une convergence plus rapide. Comme il est habituel de calibrer plusieurs sous-espaces pour plusieurs sous-tâches, il est généralement préférable de réaliser la calibration géométrique avant l'entraînement des GPRs. Cette conclusion rejoint celle du chapitre précédent : la calibration hybride permet de réduire le nombre de données nécessaires à l'entraînement du modèle d'apprentissage automatique.

3.3.5 Choix du critère d'arrêt

Maintenant que tous les autres paramètres de l'algorithme proposé ont été réglés, la condition d'arrêt peut être étudiée. L'objectif est de trouver une valeur intrinsèque qui suivrait l'évolution de l'erreur moyenne sur l'ensemble de test, de sorte que lors des expériences réelles, il n'est pas nécessaire de réaliser des mesures supplémentaires pour surveiller l'évolution des performances de l'algorithme au fil des itérations. En effet, dans toutes les expériences précédentes, l'erreur moyenne atteint rapidement un plateau, ce qui signifie que le nombre réel de données nécessaires est faible par rapport à celui fixé pour les besoins de l'expérience. Deux indicateurs sont proposés et étudiés. Le premier est l'évolution de l'incertitude maximale sur notre carte d'incertitude, qui correspond à une valeur seuil au-dessus

de laquelle la confiance du GPR dans ses prédictions est jugée insuffisante, de sorte que des données supplémentaires sont nécessaires. Le deuxième est l'écart-type de l'incertitude, de sorte que l'algorithme itère jusqu'à ce que l'incertitude soit homogène sur l'ensemble du sous-espace calibré.

La figure 3.9 montre l'évolution de l'erreur moyenne de prédiction sur l'ensemble de validation, de l'incertitude maximale et de la dispersion de l'incertitude au fil des itérations. Cette figure montre que l'erreur moyenne et l'écart-type de l'incertitude semblent fortement corrélées. Par conséquent, la condition d'arrêt repose sur l'écart-type de l'incertitude de prédiction : lorsque cette dernière n'évolue plus d'une itération à une autre, l'algorithme s'arrête et la phase d'apprentissage est complète.

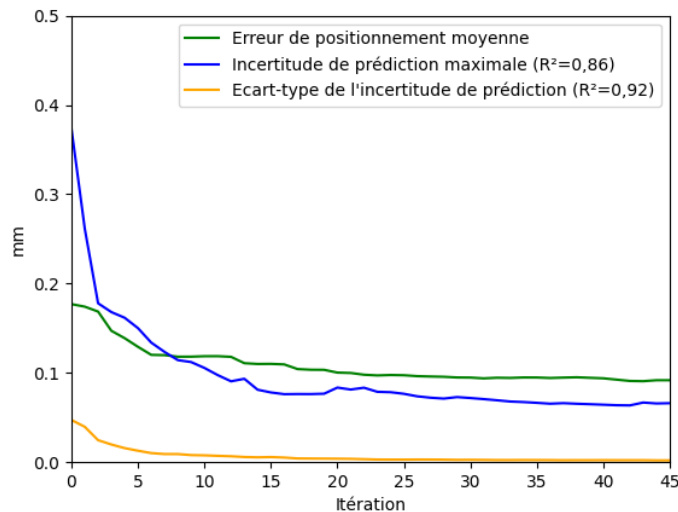


FIGURE 3.9 – Comparaison de deux conditions d'arrêt censées correspondre à l'erreur moyenne sur l'ensemble de test. Le coefficient de corrélation de Pearson est indiqué en légende.

3.3.6 Évaluation du modèle hybride

Maintenant que tous les paramètres ont été ajustés, les performances globales de la méthode proposée peuvent être évaluées sur l'ensemble de test. Grâce aux données acquises pour l'étude du nombre de données nécessaires à l'entraînement d'un réseau de neurones, la méthode de calibration par apprentissage actif peut être exécutée hors-ligne. Le maillage \mathcal{G} correspond à l'ensemble du dataset utilisé dans la section 2.3.

Ainsi, selon les sections précédentes, le GPR est composé d'un noyau *Matérn* avec $\nu = 1,5$ et d'un noyau de bruit avec un niveau de bruit adaptatif. Les données initiales sont sélectionnées à l'aide de la suite de Halton, une suite à discrédance faible. L'algorithme s'arrête automatiquement lorsque l'écart type de l'incertitude sur \mathcal{G} n'évolue plus, c'est-à-dire lorsque l'incertitude est homogène sur \mathcal{G} . En

3.3. DESIGN DE L'ALGORITHME D'APPRENTISSAGE ACTIF

utilisant ces paramètres, la méthode proposée a nécessité 21 itérations, ce qui a conduit à un ensemble d'entraînement final de 26 données. La figure 3.10 montre l'évolution de l'écart type de l'incertitude sur \mathcal{G} . Sur la figure 3.11, on peut voir que l'incertitude est homogène à la fin de la méthode.




FIGURE 3.10 – Évolution de l'écart-type de l'incertitude de prédiction au fil des itérations de l'algorithme d'apprentissage actif.


Pour évaluer l'efficacité de la méthode proposée, le modèle d'apprentissage automatique est modifié à des fins de comparaison. Le modèle hybride se compose alors du modèle géométrique avec les paramètres géométriques identifiés, et de :

- Un réseau de neurones artificiels entraîné avec exactement les mêmes données après la phase d'apprentissage actif d'un GPR.
- Un réseau de neurones artificiels entraîné avec 400 données choisies aléatoirement, ce qui constitue un bon compromis entre la précision et la taille de l'ensemble de données d'après la figure 2.7 et les observations de la section 2.3.
- Un GPR entraîné avec le même nombre de données qu'après la phase d'apprentissage actif de la méthode proposée, mais choisies de manière aléatoire plutôt qu'en fonction de la pertinence des données, mettant ainsi en évidence les avantages de l'apprentissage actif.

Le réseau de neurones en question sera celui utilisé dans le chapitre précédent, dont l'architecture est détaillée dans la section 2.2.2.

Les résultats sont résumés dans la table 3.1. La méthode de calibration hybride active offre de meilleures performances que toutes les autres méthodes avec lesquelles elle a été comparée. On peut voir

3.4. VALIDATION EXPÉRIMENTALE DE L'ALGORITHME D'APPRENTISSAGE ACTIF



(a) Cartographie d'incertitude après l'initialisation. (b) Cartographie d'incertitude à la fin du processus

FIGURE 3.11 – Évolution de l'incertitude de prédiction sur le maillage \mathcal{G} en utilisant les données issues de la section 2.3.

que le GPR entraîné avec des données aléatoires donne de meilleurs résultats qu'un réseau de neurones entraîné avec le même nombre de données. Cependant, les deux méthodes sont moins performantes que celle proposée. De plus, la méthode de calibration hybride active donne de meilleurs résultats que l'entraînement d'un réseau de neurones utilisant 15 fois plus de données.

D'une part, ces résultats mettent en lumière que les GPRs sont plus performants que les réseaux de neurones dans un contexte de calibration de robots. En effet, les GPRs sont connus pour être plus efficaces pour des problèmes de régression avec peu de données et de faibles dimensions. D'autre part, la table 3.1 souligne les performances de la méthode d'apprentissage actif : avec seulement 26 données, les résultats sont plus satisfaisants que ceux donnés par un réseau de neurones entraîné avec 400 données, ou qu'un GPR entraîné passivement avec 26 données sélectionnées aléatoirement.

3.4 Validation expérimentale de l'algorithme d'apprentissage actif

Pour évaluer l'efficacité de la méthode proposée dans des scénarios industriels réels, elle doit être testée sur différents robots en utilisant l'algorithme de compensation décrit dans la section 1.5.

3.4.1 Application sur robot industriel

L'algorithme d'apprentissage actif a été appliqué à un robot industriel, le KR300, pour corriger l'erreur de positionnement dans un sous-espace de travail. L'application sur le KR300 peut être vu sur

3.4. VALIDATION EXPÉRIMENTALE DE L'ALGORITHME D'APPRENTISSAGE ACTIF

TABLE 3.1 – Comparaison entre différents modèles hybrides utilisant des réseaux de neurones ou un GPR, avec apprentissage actif ou passif.

Modèle	Erreur moyenne (mm)	Erreur maximale (mm)
$X = f(\xi_{réel}, \theta) + GPR_S(\theta)$ (apprentissage actif avec 26 données)	0,1003	0,2079
$X = f(\xi_{réel}, \theta) + ANN(w_{P,S}, \theta)$ (avec données d'apprentissage actif)	0,2267	0,5098
$X = f(\xi_{réel}, \theta) + ANN(w_{P,S}, \theta)$ (apprentissage passif avec 400 données)	0,1091	0,2242
$X = f(\xi_{réel}, \theta) + GPR_S(\theta)$ (apprentissage passif avec 26 données)	0,1767	0,3818

la vidéo disponible via le lien suivant : https://youtu.be/u8NG4IJT0BA?si=TvoHq_fEaa_UFiR1.

3.4.1.1 Protocole expérimental

En premier lieu, la calibration géométrique du robot a été effectuée selon le protocole décrit dans la section 1.2.1. Pour identifier les paramètres géométriques du robot, 70 positions de l'effecteur ont été mesurées dans l'ensemble de l'espace de travail du robot. Les mesures ont été faites avec un Laser-Tracker API III, mesurant la position d'un SMR (Spherical Mounted Reflector) fixé au *flange* du robot. Conformément aux recommandations données dans la section 1.4.2, le repère de base du robot a été identifié avec la méthode *2-cercles* : une rotation successive des deux premières articulations du robot permettent de construire \vec{z}_{world} et \vec{y}_{world} respectivement, et la projection sur \vec{z}_{world} de l'intersection entre \vec{z}_{world} et \vec{y}_{world} donne l'origine du repère de base robot. Le montage expérimental est décrit sur la figure 3.12.

L'apprentissage actif est appliqué dans un sous-espace de travail délimité par $(x = -200, y = 1050, z = 600)mm$ et $(x = 1000, y = 1400, z = 1600)mm$ dans le repère de base du robot. Le maillage \mathcal{G}_{KR300} est réalisé avec un pas de 5 mm.

3.4.1.2 Mise en oeuvre de la méthode

Conformément à l'étude menée dans la section précédente, le GPR est composé d'un noyau Matérn avec $\nu = 1,5$ et d'un noyau de bruit adaptatif. La phase d'initialisation a été réalisée avec 10 données, extraits de \mathcal{G}_{KR300} via une suite de Halton, pour conserver un espacement régulier entre les points

3.4. VALIDATION EXPÉRIMENTALE DE L'ALGORITHME D'APPRENTISSAGE ACTIF




FIGURE 3.12 – Application de la calibration hybride par apprentissage actif au KR300. Les axes \vec{x} , \vec{y} , \vec{z} des repères robot et Laser Tracker sont respectivement représentés en rouge, vert et bleu.

initiaux.

Après la phase d'initialisation, la figure 3.13 montre que l'écart-type de l'incertitude a arrêté son évolution après la 14ème itération. Ainsi, le sous-espace de travail a été calibré en utilisant 24 points au total. Sur la figure 3.14, l'incertitude à la fin du processus est bien homogène sur tout le sous-espace calibré, avec, en outre, des valeurs bien inférieures à celle après la phase d'initialisation. Cependant, en regardant la figure 3.13, la variation de la condition d'arrêt pourrait être faible même pendant la convergence, de sorte qu'un arrêt précoce puisse malheureusement se produire. Pour éviter cela, la condition d'arrêt pourrait être appliquée sur plus d'itérations, i.e. sur une fenêtre glissante, ce qui aurait juste pour conséquence d'acquérir légèrement plus de données que le strict nécessaire.


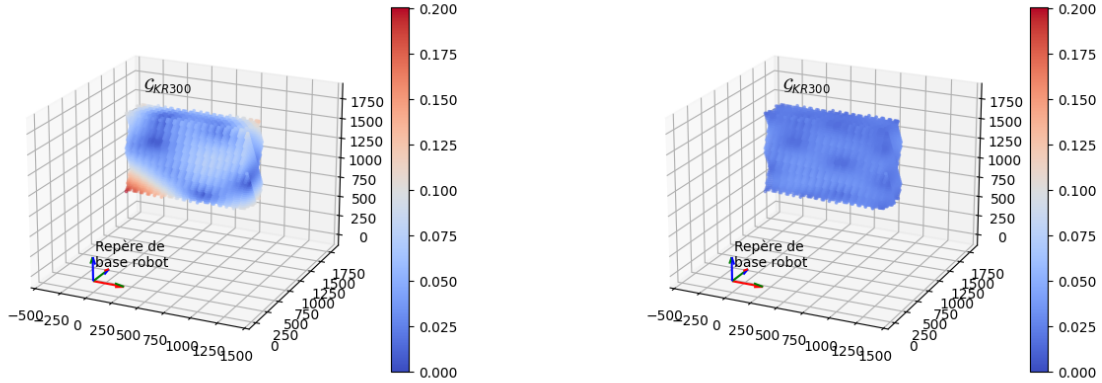


FIGURE 3.13 – Évolution de l'écart-type de l'incertitude de prédiction sur \mathcal{G}_{KR300} au cours de l'application de la méthode de calibration par apprentissage actif sur le KR300.

3.4.1.3 Résultats

Pour évaluer l'efficacité de la méthode proposée, 30 positions cartésiennes ont été générées aléatoirement et leurs positions articulaires correspondantes ont été calculées à l'aide de l'algorithme de compensation illustré dans la figure 1.20. Nous pouvons analyser dans la table 3.2 et la figure 3.15 que la méthode proposée permet de réduire l'erreur de positionnement moyenne de 97,4% par rapport au nominal et 82,6% par rapport au modèle géométrique direct calibré. Par ailleurs, le processus de calibration hybride actif a donné de meilleurs résultats que la méthode hybride classique, décrite dans le chapitre précédent. En effet, l'application du modèle hybride classique $X = f(\xi_{réel}, \theta) + ANN(w_P, S, \theta)$ dans l'algorithme de compensation laissait une erreur de positionnement moyenne de 0,13mm (erreur maximale de 0,23mm). Cela pourrait s'expliquer par la dérive thermique ayant pu intervenir lors de l'acquisition des 1100 points de mesure ayant servi à l'entraînement du réseau de neurones. Dans le cas de la calibration hybride active, seuls 24 points de mesure ont été nécessaires, ce qui a nécessité 4min d'utilisation du robot. En comparant cette durée avec la constante de temps de stabilisation de la dérive thermique, qui est de l'ordre de 3h, et l'amplitude du phénomène, toutes deux mesurés dans la section 1.4, l'effecteur ne s'est pas déplacé de plus de 30 μ m, ce qui est négligeable au vu de la précision recherchée.

3.4. VALIDATION EXPÉRIMENTALE DE L'ALGORITHME D'APPRENTISSAGE ACTIF



(a) Cartographie d'incertitude après initialisation

(b) Cartographie d'incertitude à la fin du processus d'apprentissage actif

FIGURE 3.14 – Évolution de l'incertitude de prédiction au cours de l'application de la méthode de calibration par apprentissage actif sur le KR300.

3.4.2 Application sur robot collaboratif

L'algorithme d'apprentissage actif présenté dans ce chapitre a aussi été appliqué à un robot collaboratif (*iiwa*). Contrairement à précédemment, l'objectif est de compenser à la fois l'erreur de positionnement et d'orientation de l'effecteur du robot, dans un sous-espace de travail prédéfini.

3.4.2.1 Protocole expérimental

Le protocole expérimental mis en place pour *iiwa* est similaire à celui du KR300. Les paramètres géométriques du robot ont été identifiés, en mesurant 70 positions de l'effecteur dans l'ensemble de l'espace de travail du robot. Les mesures ont été faites avec un Laser Tracker API III. Comme précédemment, le repère de base robot a été identifié avec la méthode *2-cercles* : les rotations successives des deux premières articulations du robot permettent de construire \vec{z}_{world} et \vec{y}_{world} respectivement, et la projection sur \vec{z}_{world} de l'intersection entre \vec{z}_{world} et \vec{y}_{world} donne l'origine du repère de base robot. La pose (i.e. position et orientation) de l'effecteur par rapport au repère de base robot est mesurée en utilisant 3 SMRs fixés sur le *flange* du robot [Gadringer et al., 2020]. L'un des 3 SMRs sert à mesurer la position, les deux autres l'orientation : pour une pose de référence donnée, la position relative de ces deux SMRs par rapport à celui servant à mesurer la position est mesurée et enregistrée. Par la suite, pour une nouvelle pose, la position de l'effecteur est mesurée via le SMR correspondant, et l'orientation est calculée (par la méthode des moindres carrés, décrite dans la section 1.3.1) en comparant la

3.4. VALIDATION EXPÉRIMENTALE DE L'ALGORITHME D'APPRENTISSAGE ACTIF

TABLE 3.2 – Performances de la méthode de calibration hybride active comparée au modèle géométrique direct avec les paramètres géométriques nominaux et identifiés sur le KR300.

	Erreur moyenne (mm)	Erreur maximale (mm)
$X = f(\xi_{nominal}, \theta)$ (évalué sur les données d'entraînement)	3,0603	5,2859
$X = f(\xi_{réel}, \theta)$ (évalué sur les données d'entraînement)	0,4607	0,8012
$X = f(\xi_{réel}, \theta) + GPRS(\theta)$ (évalué sur un ensemble de validation, utilisant l'algorithme de compensation)	0,0803	0,1819

position mesurée des deux autres SMRs et leurs positions théoriques, enregistrée précédemment. Le montage expérimental global est décrit dans la figure 3.16.

L'apprentissage actif est appliqué dans un sous-espace de travail délimité par $(x = 350, y = -300, z = 800)mm$ et $(x = 550, y = 300, z = 1000)mm$ dans le repère de base du robot. Comme pour le KR300, le maillage \mathcal{G}_{iwa} est réalisé avec un pas de 5 mm.

3.4.2.2 Mise en oeuvre de la méthode

De la même manière que pour le KR300 (section 3.4.1), le GPR est composé d'un noyau Matérn avec $\nu = 1,5$ et d'un noyau de bruit adaptatif. Le processus d'apprentissage actif est initialisé avec 5 points extraits de \mathcal{G}_{iwa} en utilisant une suite de Halton.

A l'issu de la phase d'initialisation, le processus d'apprentissage actif a réalisé 14 itérations également. En effet, la figure 3.17 montre l'évolution de l'écart-type de l'incertitude de prédiction au cours du processus. La condition d'arrêt est atteinte lorsque cet écart-type a cessé d'évoluer, ce qui se produit au bout de la 14ème itération. Ainsi, l'ensemble d'entraînement total est composé de 19 mesures. Nous pouvons voir sur la figure 3.18 que l'incertitude de prédiction est devenue homogène à la fin du processus.

3.4.2.3 Résultats

De la même manière que pour le KR300, 30 positions cartésiennes ont été générées aléatoirement et leurs positions articulaires correspondantes ont été calculées en utilisant l'algorithme de compensation illustré dans la figure 3.3. Il est important de noter que cet algorithme de compensation peut également être utilisé pour compenser les erreurs d'orientation : ici, X désigne à la fois la position et l'orientation de l'effecteur par rapport au repère de base robot en utilisant les angles d'Euler. En comparant la

3.4. VALIDATION EXPÉRIMENTALE DE L'ALGORITHME D'APPRENTISSAGE ACTIF




FIGURE 3.15 – Distribution de l’erreur de positionnement du KR300, calculé sur 30 points de validations, utilisant l’algorithme de compensation.

position et l’orientation atteintes mesurées et celles désirées, la précision du protocole est résumée dans la table 3.3. À titre de comparaison, les tables 3.4 et 3.5 montrent l’erreur de positionnement et d’orientation sur l’ensemble d’entraînement, respectivement avant et après la calibration géométrique. Bien que ces valeurs ont été calculées sur seulement 19 points, la tendance est claire : l’erreur de positionnement a été réduite de 90% après le protocole de calibration hybride actif, tandis que l’erreur d’orientation a été réduite de 92% à 98% (en fonction de l’axe). De plus, les figures 3.19 et 3.20 montrent que la distribution des erreurs est beaucoup plus resserrée après l’application de la méthode proposée qu’auparavant. Par ailleurs, on remarque que la calibration géométrique a réduit l’erreur de positionnement, mais pas amélioré l’erreur d’orientation. Cela s’explique par le fait qu’au cours de la calibration géométrique, seules des mesures de la position de l’effecteur (et non d’orientation) ont été mesurées. Ainsi, les paramètres géométriques identifiés sont ceux minimisant l’erreur de positionnement (au sens des moindres carrés) sur un ensemble de mesures (70 points, comme expliqué dans la section 2.2), mais ils n’ont pas été calculés pour minimiser l’erreur d’orientation.

Ces résultats peuvent être comparés avec ceux obtenus dans le chapitre précédent. En effet, la table 2.4 résume les performances de 4 modèles directs différents, utilisés dans l’algorithme de compensation. Nous remarquons que l’erreur de positionnement résiduelle après calibration hybride active est la plus faible de toutes celles présentées. En effet, le modèle de calibration hybride classique $X = f(\xi_{réel}, \theta) + ANN(w_{P,S}, \theta)$, entraîné avec 2000 données, laisse une erreur résiduelle moyenne de 0,13mm (et une

3.5. CONCLUSION




FIGURE 3.16 – Application de la calibration hybride par apprentissage actif à l'*iiwa*


TABLE 3.3 – Erreurs moyennes et maximales de positionnement et d'orientation de l'*iiwa* après application du processus de calibration hybride par apprentissage actif, calculées sur un ensemble de validation de 30 poses cartésiennes.

	Moyenne	Maximale
Erreur de positionnement	0,109 mm	0,266 mm
Erreur d'orientation selon \vec{x}_{flange}	0,006°	0,017°
Erreur d'orientation selon \vec{y}_{flange}	0,006°	0,022°
Erreur d'orientation selon \vec{z}_{flange}	0,007°	0,020°

erreur maximale de 0,26mm), soit une erreur moyenne légèrement plus élevée qu'après application de la méthode de calibration hybride par apprentissage actif. A nouveau, cela pourrait s'expliquer par la durée des mesures : les 2000 données nécessaires à l'entraînement du réseau de neurones ont été acquises en 2h30min, tandis que la méthode de calibration hybride active n'a nécessité que 7min. Ainsi, le phénomène de dérive thermique n'a pas pu se mettre en place de manière significative.

3.5 Conclusion

Dans ce chapitre, une méthode d'apprentissage actif efficace en termes de données, rapide et autonome est proposée pour la calibration hybride de robots. Elle repose d'une part sur l'identification des

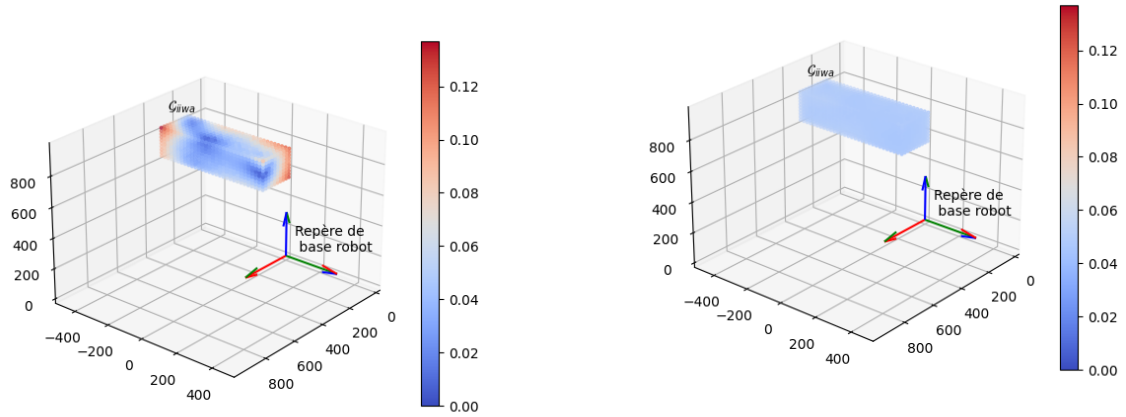
FIGURE 3.17 – Évolution de l'écart type de l'incertitude de prédiction sur \mathcal{G}_{iiwa} .

paramètres géométriques et d'autre part sur un GPR utilisé pour approximer les erreurs résiduelles, entraîné avec une approche d'apprentissage actif. À partir de très peu de données initiales utilisées pour entraîner une première fois le GPR, une cartographie d'incertitude peut être construite en se basant sur les prédictions du GPR sur le sous-espace de travail à calibrer. À partir de cette carte d'incertitude, les nouvelles données les plus pertinentes peuvent être sélectionnées de manière autonome, mesurées et ajoutées à l'ensemble d'entraînement, qui devient complet lorsque la cartographie d'incertitude est homogène.

La validation expérimentale à l'aide d'un algorithme de compensation montre que cette méthode permet de réduire l'erreur de positionnement sur un robot industriel traditionnel, le KR300, de 97% en n'utilisant que 24 données d'entraînement. La valeur moyenne de l'erreur après calibration a été réduite à 0,08 mm. De même, l'erreur de positionnement et d'orientation d'un robot collaboratif, le KUKA lbr *iiwa* R820, est réduite de 90%, en n'utilisant que 19 données pour l'entraînement du GPR.

Étant donné que le processus de mesure est rapide, aucune influence des effets thermiques ne biaise les données d'entraînement. Ainsi, par rapport aux méthodes de calibration hybrides utilisant des réseaux de neurones, la méthode proposée offre une meilleure précision. De plus, le processus d'apprentissage est entièrement autonome.

3.5. CONCLUSION



(a) Cartographie de l'incertitude de prédiction après l'initialisation (b) Cartographie de l'incertitude de prédiction à la fin du processus d'apprentissage actif.

FIGURE 3.18 – Évolution de l'incertitude de prédiction au cours du processus de calibration par apprentissage actif sur l'*iiwa*.

TABLE 3.4 – Erreurs moyennes et maximales de positionnement et d'orientation avant calibration géométrique, calculées sur l'ensemble des poses cartésiennes ayant servies à l'entraînement du GPR.

	Moyenne	Maximale
Erreur de positionnement	2,946 mm	3,816 mm
Erreur d'orientation selon \vec{x}_{flange}	0,102°	0,175°
Erreur d'orientation selon \vec{y}_{flange}	0,060°	0,108°
Erreur d'orientation selon \vec{z}_{flange}	0,026°	0,065°

TABLE 3.5 – Erreurs moyennes et maximales de positionnement et d'orientation après identification des paramètres géométriques de l'*iiwa*, calculées sur l'ensemble des poses cartésiennes ayant servies à l'entraînement du GPR.

	Moyenne	Maximale
Erreur de positionnement	0,644 mm	0,98 mm
Erreur d'orientation selon \vec{x}_{flange}	0,036°	0,089°
Erreur d'orientation selon \vec{y}_{flange}	0,100°	0,185°
Erreur d'orientation selon \vec{z}_{flange}	0,026°	0,063°

3.5. CONCLUSION

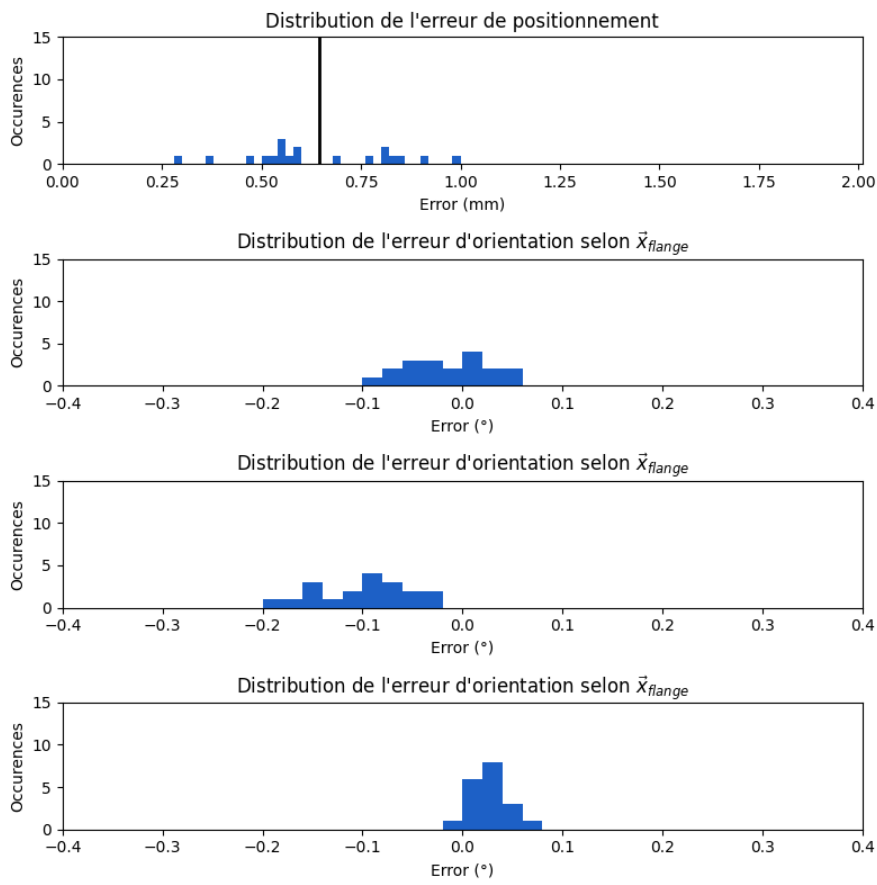


FIGURE 3.19 – Distribution de l'erreur de position et d'orientation de l'effecteur de l'*iiwa* après calibration géométrique, sur l'ensemble de poses ayant servies à l'entraînement du GPR.

3.5. CONCLUSION

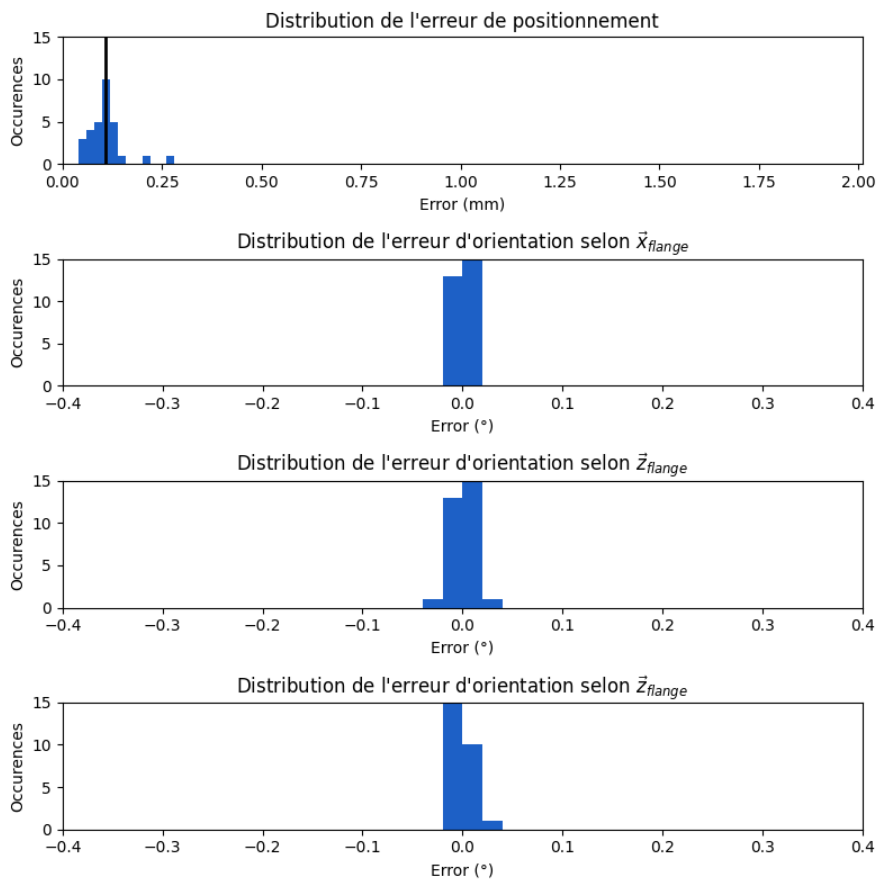


FIGURE 3.20 – Distribution de l'erreur de position et d'orientation de l'effecteur de l'*iiwa* après application du processus de calibration par apprentissage actif, sur l'ensemble de 30 poses de validation.

Conclusion

Synthèse des travaux

Depuis le début des années 80, des méthodes de calibration ont été développées afin de rendre certaines tâches (usinage, perçage, assemblage) réalisables par des robots industriels. Ces méthodes visent à établir un modèle fiable et représentatif du comportement du robot réel. Devant la difficulté pour établir un modèle analytique fiable, des méthodes de calibration hybrides se basant à la fois sur un modèle analytique et un modèle d'apprentissage automatique (modèle "boîte-noire"), afin de combiner les avantages de chacun des modèles, sont apparues. Les méthodes de calibration hybrides se veulent plus économes en terme de données que les méthodes "boîte-noire", plus simple à mettre en oeuvre que les méthodes analytiques (car ne nécessitant aucune connaissances sur le robot comme le modèle de masse, ou le type de réducteurs utilisés), tout en conservant un haut niveau de précision. Cependant, ces méthodes restent peu reconfigurables : en cas de changement des paramètres du robot (charge utile portée, limite cinématique), le modèle hybride n'est plus valide et doit être à nouveau établi. La difficulté de déterminer en amont le nombre de données requises pour l'entraînement du réseau de neurones rend les méthodes de calibration hybrides plus gourmandes que nécessaire. Ce manuscrit comporte plusieurs contribution visant proposer des méthodes peu gourmandes en termes de données ; reconfigurables ; relativement simples à appliquer ; tout en maintenant un haut niveau de précision. De cette manière, le temps d'immobilisations des robots et des instruments de mesures est fortement réduit.

Le chapitre 1 a introduit les différents modèles analytiques présentés dans la littérature scientifique pour la calibration des robots industriels. Ainsi, les modèles géométriques direct et inverse nominaux ont été introduits, et les modèles pour chacune des quatre sources d'erreurs usuellement considérées (défauts géométriques, compliance des articulations, erreurs de transmission et dérives thermiques) ont été présentés et discutés. De plus, différents instruments de mesures pour la mise en oeuvre de ces méthodes ont été présentés. Une attention plus particulière a été donnée au Laser Tracker, instrument de mesure le plus utilisé pour la calibration de robots industriels et utilisé dans ce manuscrit. Les méthodes existantes d'identification du repère de base robot dans le repère de mesure associé au Laser

CONCLUSION

Tracker ont été comparées expérimentalement. Cette étude a fait l'objet d'un article de conférence [Selingue et al., 2023a]. Enfin, un bilan de la contribution de chaque source d'erreur sur la précision a été réalisé sur un robot industriel classique, le KUKA Quantec KR300 R2500, dénommé KR300 ci-après.

Le chapitre 1 souligne que les modèles de calibration analytiques les plus simples permettent de compenser une grande partie des erreurs de positionnement, tandis que certains phénomènes complexes à modéliser ne permettent d'améliorer la précision que de quelques dixièmes de millimètres. En effet, les défauts géométriques sont responsables de la majeure partie de l'erreur de positionnement (plus de 50%), alors que leur compensation est relativement simple. A l'inverse, les défauts de transmissions sont très complexes à modéliser, et la dérive thermique nécessite plusieurs heures de mesures pour observer l'effet de la dilatation thermique des composants du robot sur la position de l'effecteur, alors que ces défauts provoquent une erreur de positionnement de l'ordre de 0,2 à 0,3mm. Ainsi, les méthodes analytiques pourraient permettre d'améliorer grandement la précision des robots industriels, au prix de modèles et de protocoles expérimentaux très complexes.

Pour compenser les inconvénients des méthodes de calibration analytiques, des méthodes de calibration dites "boîte-noire", utilisant le modèle nominal du robot couplé à un réseau de neurones, sont apparues. Ces méthodes utilisent des modèles d'apprentissage automatique pour améliorer la précision des robots industriels. Cependant, ces méthodes ont été délaissées au profit des méthodes de calibration hybrides, c'est-à-dire mêlant un modèle analytique calibré et un modèle d'apprentissage automatique. Les méthodes de calibration hybrides ont émergées car elles seraient moins gourmandes en terme de nombre de données d'entraînement requises par le modèle d'apprentissage par rapport aux méthodes "boîte-noire", cependant la corrélation entre le nombre de données requises pour l'entraînement d'un modèle d'apprentissage et la précision du modèle hybride n'a pas été clairement établie.

Le chapitre 2 comporte une étude expérimentale permettant de quantifier l'apport des méthodes de calibration hybrides, en particulier en terme de nombre de données requises, qui a fait l'objet d'un article de conférence [Selingue et al., 2022]. A la lumière des conclusions du chapitre 1, le modèle hybride développé dans le chapitre 2 combine un réseau de neurones artificiels et le modèle géométrique direct calibré du robot, car ce modèle permet de compenser la majeure partie de l'erreur de positionnement avec un protocole expérimental relativement simple à mettre en oeuvre. En premier lieu, une comparaison entre calibration analytique, calibration "boîte-noire" et calibration hybride a été faite pour deux robots aux caractéristiques bien différentes : le KR300, un robot industriel "moyen-porteur", qui est rigide, avec une allonge de 2,5m, et un robot collaboratif, le KUKA lbr *iiwa* 14R820, dénommé *iiwa* par la suite, qui est plus souple, avec une allonge de 820mm. Cette comparaison a mis en lumière le fait que la calibration hybride permet d'atteindre des performances très similaires à celles fournies par les méthodes "boîte-noires", mais avec moins de données d'entraînement. Ensuite, deux méthodes

CONCLUSION

ont également été proposées dans le chapitre 2 pour réduire davantage le nombre de données requises à la re-calibration d'un robot dans le cas d'un changement de charge utile. Ces deux méthodes ont fait l'objet d'un article de journal [Selingue et al., 2023b]. L'une de ces méthodes, désignée ci-après méthode 1, basée sur l'apprentissage par transfert, fournit des résultats comparables à une calibration hybride "classique" avec un nombre significativement réduit de données, en réutilisant les poids d'un réseau de neurones précédemment entraînés pour une charge utile. Ce réseau de neurones est ajusté pour une nouvelle charge avec très peu de données, en comparaison avec ce qui est requis pour l'entraînement d'un réseau de neurones dans la méthode hybride "classique". La seconde méthode, désignée ci-après méthode 2, porte sur l'interpolation de la prédiction d'un réseau de neurones utilisant deux jeux de poids, chacun étant entraîné pour une charge utile différente. Cette méthode présente l'avantage de ne requérir aucune nouvelle donnée pour être efficace pour compenser une nouvelle charge utile, mais n'est valide que si le centre de gravité de la charge utile demeure selon \vec{z}_{world} (usuellement défini comme étant opposé au vecteur directeur de la force de gravité). Cette condition est cependant rarement limitante dans des applications de perçage, d'usinage ou de pick-and-place, car le *flange* du robot est usuellement orienté selon \vec{z}_{world} . Les deux méthodes ont été validées expérimentalement sur le KR300, et ont permis d'obtenir une erreur de positionnement moyenne de $0,08mm$, pour la méthode 1 appliquée avec 15 nouvelles données d'entraînement et $0,11mm$ pour la méthode 2, réduisant ainsi l'erreur de positionnement de l'effecteur de plus de 96% par rapport au modèle géométrique nominal.

Si les méthodes précédentes permettent de re-configurer facilement un modèle d'apprentissage pour l'adapter à une variation de la charge utile, le premier entraînement de ce modèle nécessite toujours un nombre important de données. Pour pallier cet inconvénient, le chapitre 3 propose une méthode de calibration hybride par apprentissage actif. En utilisant des régresseurs par processus gaussien (désignés ci-après par son acronyme anglais GPR) comme modèle d'apprentissage, il est possible d'utiliser l'incertitude de prédiction donnée par le GPR pour construire itérativement l'ensemble de données d'entraînement. A partir d'un ensemble réduit de données, une première version du GPR est entraînée, et peut effectuer une prédiction sur le sous-espace à calibrer. Cette prédiction est accompagnée d'une mesure d'incertitude : là où l'incertitude de prédiction est maximale, le GPR est susceptible de fournir une prédiction éloignée de la réalité, c'est donc une donnée d'entraînement qui apporterait une grande valeur ajoutée à l'entraînement. Cette donnée est alors acquise via le Laser Tracker, et une nouvelle version du GPR est entraînée à la fois sur l'ensemble de données initiales et sur la nouvelle donnée acquise. Cette étape est répétée jusqu'à ce que l'incertitude de prédiction soit homogène sur le sous-espace calibré. La méthode de calibration hybride par apprentissage actif a été appliquée au KR300 pour corriger l'erreur de positionnement de l'effecteur dans un sous-espace de travail prédéfini avec seulement 24 points de mesures. Elle a aussi été appliquée à l'*iiwa* pour compenser à la fois les erreurs de positionnement et d'orientation, en utilisant à nouveau 24 points de mesures. Les résultats montrent que les erreurs de positionnement ont pu être réduites de 95% sur les deux robots, et les er-

reurs d'orientation de 98% sur l'*iiva*, par rapport à leurs modèles nominaux respectifs. En particulier, l'erreur de positionnement moyenne du KR300 après application de la méthode est de $0.08mm$.

L'ensemble des travaux développés dans cette thèse constituent une contribution visant à rendre les méthodes de calibration hybrides aisément applicables dans des contextes industriels. Dans ce sens, cette thèse s'est attachée à réduire la consommation en terme de nombre de données des méthodes de calibration hybrides, en maintenant un haut niveau de précision. En particulier, les méthodes proposées dans le chapitre 2 permettent d'adapter facilement un modèle hybride à un nouvel environnement, tandis que la méthode présentée dans le chapitre 3 permet d'établir un modèle hybride de manière autonome, avec très peu de données. La précision offerte par ces méthodes reste comparable avec la répétabilité des robots considérés, tout en étant plus simples à mettre en oeuvre que les méthodes analytiques ou hybrides présentées dans la littérature.

Perspectives

Application de la méthode de calibration par apprentissage actif aux modèle dynamique

Le présent manuscrit s'est concentré sur les méthodes de calibration hybrides pour réduire les erreurs de positionnement de robots industriels ou collaboratifs. Par conséquent, la vitesse et l'accélération de chacune des articulations ne sont pas considérées. Pour de nombreuses tâches dans l'industrie, les vitesses et accélérations des axes du robot sont faibles lors de l'exécution de la tâche en elle-même (assemblage, usinage), mais elles sont élevées lorsque le robot navigue d'un sous-espace de travail à un autre, alors qu'aucune précision n'est requise. Ainsi, les intégrateurs de robots se placent volontairement dans un cadre "statique" ou "quasi-statique" pour effectuer une tâche requérant de la précision, et utilisent le robot au maximum de ses capacités lorsqu'aucune précision n'est requise, afin que les modèles de calibrations présentés dans ce manuscrit soient effectifs. Cependant, certaines tâches requièrent à la fois de la précision et une vitesse ou une accélération élevée, ce qui nécessite alors non plus un modèle géométrique mais un modèle dynamique du robot.

Le modèle dynamique le plus courant est exprimé par l'équation suivante :

$$\Gamma = M(\theta)\ddot{\theta} + C(\theta, \dot{\theta})\dot{\theta} + G(\theta)\theta \quad (3.7)$$

où Γ représente le couple à appliquer à chacun des axes pour suivre la trajectoire représentée par $(\theta, \dot{\theta}, \ddot{\theta})$, $M(\theta)$ est la matrice d'inertie du robot, $C(\theta, \dot{\theta})\dot{\theta}$ est le vecteur des forces centrifuges et de Coriolis, et $G(\theta)\theta$ est le couple à appliquer pour compenser le poids propre du robot. Il est important de noter que ce modèle ne prends pas en compte le comportement élastique des transmissions, les phénomènes de frottements, ni le couplage entre les actionneurs et les articulations. Ainsi, de la même manière que le modèle géométrique, le modèle dynamique peut être étendu pour refléter au mieux le comportement

r el du robot, et les nombreux param etres doivent ˆtre identifi es. On parle alors de calibration dynamique *param etrique* [Siciliano and Khatib, 2007, Yamane, 2011, Traversaro et al., 2013]. De mˆme, certains travaux se sont concentr es sur des mod eles d’apprentissages automatique pour  tablir ce mod ele, ce sont les m ethodes *non-param etriques* [Gijsberts and Metta, 2011, Polydoros et al., 2015]. Cependant, en raison de la complexit  des ph enomenes, le nombre de variables d’entr ees, et la complexit  exp erimentale, ces mod eles *non-param etriques* sont tr es complexes   mettre en oeuvre dans un cadre industriel.

Pour profiter des avantages des deux types de m ethodes sans souffrir de leurs inconv enients, des m ethodes *semi-param etriques* sont apparues [Nguyen-Tuong and Peters, 2010, Wu and Movellan, 2012, de la Cruz et al., 2012, Romeres et al., 2016, Camoriano et al., 2016], faisant  cho aux m ethodes de calibration hybrides d velopp es dans ce manuscrit. Cependant, ces m ethodes restent gourmandes en terme de nombre de donn ees requises, et les protocoles exp erimentaux demeurent lourds. Certaines de ces m ethodes *semi-param etriques* se basent sur des GPRs, sans pour autant utiliser l’incertitude de pr ediction qui est naturellement calcul ee pour chaque pr ediction du GPR. Ainsi, une perspective d’ volution des travaux pr esent es dans ce manuscrit serait l’application la m ethodes de calibration hybride par apprentissage actif d velopp ee dans le chapitre 3 au cas de calibration dynamique *semi-param etrique*, afin d’all ger le protocole exp erimentale et rendre les m ethodes de calibration dynamiques plus applicables dans des contextes industriels.

G en eralisation de la m ethodes d’interpolation de la pr ediction de deux r eseaux de neurones

Dans le chapitre 2, deux m ethodes permettant d’adapter un mod ele hybride existant   une nouvelle charge utile ont  t  propos ees. En particulier, l’une d’entre elle consiste   interpoler les pr edictions d’un mˆme r eseau de neurones en utilisant deux jeux de poids diff erents provenant d’entraˆnements faits pr ec edemment pour deux charges utiles diff erentes. Cette m ethodes permet alors de prendre en compte une nouvelle charge utile sans mˆme avoir besoin d’acqu erir de nouvelles donn ees, contrairement   l’autre m ethodes propos ee; en revanche elle n’est pas applicable dans le cas ou le centre de gravit  de la nouvelle charge utile n’ volue pas selon \vec{z}_{world} . Une perspective d’ volution des travaux pr esent es dans le chapitre 2 serait alors de prendre en compte la position du centre de gravit  dans la m ethodes d’interpolation. Il serait alors n ecessaire de faire varier la position du centre de gravit  en plus de la charge utile pour entraˆner la mˆme architecture de r eseau pour r egler diff erents jeux de poids sp ecifiques $w_{S,P,C}$ o  C est la position du centre de gravit , et d’ tendre l’interpolation telle que pr esent ee dans la section 2.4.2   une interpolation multivariable, dont les param etres sont   la fois la charge utile et la position du centre de gravit  dans le rep ere du *flange*.

CONCLUSION

Bibliographie

- [ao Cao et al., 2018] ao Cao, W., Yang, D., and Ding, H. (2018). A method for stiffness analysis of overconstrained parallel robotic mechanisms with scara motion. *Robotics and Computer-Integrated Manufacturing*, 49 :426–435.
- [Aoyagi et al., 2010] Aoyagi, S., Kohama, A., Nakata, Y., Hayano, Y., and Suzuki, M. (2010). Improvement of robot accuracy by calibrating kinematic model using a laser tracking system-compensation of non-geometric errors using neural networks and selection of optimal measuring points using genetic algorithm-. In *2010 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pages 5660–5665.
- [Besset et al., 2016] Besset, P., Olabi, A., and Gibaru, O. (2016). Advanced calibration applied to a collaborative robot. In *2016 IEEE International Power Electronics and Motion Control Conference (PEMC)*, pages 662–667.
- [Björck, 1990] Björck, Å. (1990). Least squares methods. *Handbook of numerical analysis*, 1 :465–652.
- [Boby and Saha, 2016] Boby, R. A. and Saha, S. K. (2016). Single image based camera calibration and pose estimation of the end-effector of a robot. In *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pages 2435–2440.
- [Burkus et al., 2020] Burkus, E., Awrejcewicz, J., and Odry, P. (2020). A validation procedure to identify joint friction, reductor self-locking and gear backlash parameters. *Archive of Applied Mechanics*, 90.
- [Busson, 2018] Busson, D. (2018). *Gestion de robots mobiles et redondants et collaboratifs en environnement contraint et dynamique*. PhD thesis, HESAM université.
- [Camoriano et al., 2016] Camoriano, R., Traversaro, S., Rosasco, L., Metta, G., and Nori, F. (2016). Incremental semiparametric inverse dynamics learning. In *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pages 544–550. IEEE.
- [Chen et al., 1991] Chen, J.-S., Yuan, J., Ni, J., and Wu, S. (1991). Real-time compensation of time-variant volumetric error on a machining center. *American Society of Mechanical Engineers, Production Engineering Division (Publication) PED*, 55 :241–253.

BIBLIOGRAPHIE

- [Cristoiu et al., 2020] Cristoiu, C., Zapciu, M., Nicolescu, A. F., and Pupaza, C. (2020). Thermal deformation analysis of abb irb 140 industrial robot. *UPB Scientific Bulletin, Series D : Mechanical Engineering*, 82(2) :61 – 72. Cited by : 1.
- [de la Cruz et al., 2012] de la Cruz, J. S., Calisgan, E., Kulić, D., Owen, W., and Croft, E. A. (2012). On-line dynamic model learning for manipulator control. *IFAC Proceedings Volumes*, 45(22) :869–874. 10th IFAC Symposium on Robot Control.
- [Denavit and Hartenberg, 1995] Denavit, J. and Hartenberg, R. (1995). Notation for lower-pair mechanisms based on matrices. *A. Kinematic, ASME Journal of Applied Mechanics*, 22 :215–221.
- [Dombre and Khalil, 2007] Dombre, E. and Khalil, W. (2007). *Robot Manipulators : Modeling, Performance Analysis and Control*. Control Systems, Robotics and Manufacturing Series. ISTE Ltd, London.
- [Driels et al., 1993] Driels, M. R., Swayze, W., and Potter, S. (1993). Full-pose calibration of a robot manipulator using a coordinate-measuring machine. *The International Journal of Advanced Manufacturing Technology*, 8 :34–41.
- [Dumas et al., 2011] Dumas, C., Caro, S., Garnier, S., and Furet, B. (2011). Joint Stiffness Identification of Six-revolute Industrial Serial Robots. *Robotics and Computer-Integrated Manufacturing*, 27(4) :881–888.
- [Eastwood and Webb, 2009] Eastwood, S. and Webb, P. (2009). Compensation of thermal deformation of a hybrid parallel kinematic machine. *Robotics and Computer-Integrated Manufacturing*, 25(1) :81–90.
- [Elatta et al., 2004] Elatta, A., Gen, L., Zhi, F., Daoyuan, Y., and Fei, L. (2004). An overview of robot calibration. *Information Technology Journal*, 3 :74–78.
- [Fan et al., 2015] Fan, C., Zhao, G., Zhao, j., Zhang, L., and Sun, L. (2015). Calibration of a parallel mechanism in a serial-parallel polishing machine tool based on genetic algorithm. *The International Journal of Advanced Manufacturing Technology*, 81.
- [Gadringer et al., 2020] Gadringer, S., Gattringer, H., Müller, A., and Naderer, R. (2020). Robot calibration combining kinematic model and neural network for enhanced positioning and orientation accuracy. *IFAC-PapersOnLine*, 53(2) :8432–8437. 21st IFAC World Congress.
- [Gao et al., 2017] Gao, G., Zhang, H., San, H., Wu, X., and Wang, W. (2017). Modeling and error compensation of robotic articulated arm coordinate measuring machines using bp neural network. *Complexity*, 2017.
- [Ghorbel et al., 1998] Ghorbel, F. H., Gandhi, P. S., and Alpeter, F. (1998). On the Kinematic Error in Harmonic Drive Gears . *Journal of Mechanical Design*, 123(1) :90–97.

- [Gijsberts and Metta, 2011] Gijsberts, A. and Metta, G. (2011). Incremental learning of robot dynamics using random features. In *2011 IEEE International Conference on Robotics and Automation*, pages 951–956. IEEE.
- [Glorot and Bengio, 2010] Glorot, X. and Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In Teh, Y. W. and Titterton, M., editors, *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*, volume 9 of *Proceedings of Machine Learning Research*, pages 249–256, Chia Laguna Resort, Sardinia, Italy. PMLR.
- [Gong et al., 2000] Gong, C., Yuan, J., and Ni, J. (2000). Nongeometric error identification and compensation for robotic system by inverse calibration. *International Journal of Machine Tools and Manufacture*, 40(14) :2119–2137.
- [Guerin, 2018] Guerin, J. (2018). *Machine learning improvements for robotic applications in industrial context : Case study of autonomous sorting*. PhD thesis, Arts et Métiers ParisTech.
- [Halton, 1964] Halton, J. H. (1964). Algorithm 247 : Radical-inverse quasi-random point sequence. *Commun. ACM*, 7(12) :701–702.
- [Hsiao et al., 2020] Hsiao, J.-C., Shivam, K., Lu, I.-F., and Kam, T.-Y. (2020). Positioning accuracy improvement of industrial robots considering configuration and payload effects via a hybrid calibration approach. *IEEE Access*, 8 :228992–229005.
- [ISO 9283 :2012, 2012] ISO 9283 :2012 (2012). Robots manipulateurs industriels - critères de performance et méthodes d’essai correspondantes. Standard, International Organization for Standardization, Geneva, CH.
- [Jiang et al., 2022] Jiang, P., Ergu, D., Liu, F., Cai, Y., and Ma, B. (2022). A review of yolo algorithm developments. *Procedia Computer Science*, 199 :1066–1073.
- [Jing et al., 2016] Jing, W., Tao, P. Y., Yang, G., and Shimada, K. (2016). Calibration of industry robots with consideration of loading effects using product-of-exponential (poe) and gaussian process (gp). In *2016 IEEE International Conference on Robotics and Automation (ICRA)*, pages 4380–4385.
- [Joubair and Bonev, 2013] Joubair, A. and Bonev, I. A. (2013). Comparison of the efficiency of five observability indices for robot calibration. *Mechanism and Machine Theory*, 70 :254–265.
- [Joubair et al., 2016] Joubair, A., Tahan, A., and Bonev, I. (2016). Performances of observability indices for industrial robot calibration. In *2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 2477–2484.
- [Khalil and Besnard, 2002] Khalil, W. and Besnard, S. (2002). Geometric calibration of robots with flexible joints and links. *Journal of Intelligent and Robotic Systems*, 34 :357–379.

- [Khalil and Kleinfinger, 1986] Khalil, W. and Kleinfinger, J. (1986). A new geometric notation for open and closed-loop robots. In *Proceedings. 1986 IEEE International Conference on Robotics and Automation*, volume 3, pages 1174–1179.
- [Kircanski et al., 1993] Kircanski, N., Goldenberg, A. A., and Jia, S. (1993). An experimental study of nonlinear stiffness, hysteresis, and friction effects in robot joints with harmonic drives and torque sensors. *International Journal of Robotic Research - IJRR*, 16 :326–340.
- [Kleinkes and Loser, 2011] Kleinkes, M. and Loser, R. (2011). Laser tracker and 6dof measurement strategies in industrial robot applications. In *CMSC 2011 : Coordinate Metrology System Conference, Phoenix Arizona*.
- [Klimchik et al., 2015] Klimchik, A., Caro, S., and Pashkevich, A. (2015). Optimal pose selection for calibration of planar anthropomorphic manipulators. *Precision Engineering*, 40 :214–229.
- [Klimchik et al., 2013] Klimchik, A., Pashkevich, A., and Chablat, D. (2013). Cad-based approach for identification of elasto-static parameters of robotic manipulators. *Finite Elements in Analysis and Design*, 75 :19–30.
- [Klimchik et al., 2019] Klimchik, A., Pashkevich, A., and Chablat, D. (2019). Fundamentals of manipulator stiffness modeling using matrix structural analysis. *Mechanism and Machine Theory*, 133 :365–394.
- [Klimchik et al., 2012] Klimchik, A., Wu, Y., Pashkevich, A., Caro, S., and Furet, B. (2012). Optimal Selection of Measurement Configurations for Stiffness Model Calibration of Anthropomorphic Manipulators. *Applied Mechanics and Materials*, 162 :161–170.
- [Kuhlemann et al., 2016] Kuhlemann, I., Schweikard, A., Jauer, P., and Ernst, F. (2016). Robust inverse kinematics by configuration control for redundant manipulators with seven dof. In *2016 2nd International Conference on Control, Automation and Robotics (ICCAR)*, pages 49–55.
- [Kumar et al., 2018] Kumar, P. et al. (2018). Artificial neural network based geometric error correction model for enhancing positioning accuracy of a robotic sewing manipulator. *Procedia Computer Science*, 133 :1048–1055.
- [Le Reun et al., 2022] Le Reun, A., Subrin, K., Dubois, A., and Garnier, S. (2022). Thermal drift and backlash issues for industrial robots positioning performance. *Robotica*, 40(9) :2933–2952.
- [Li and Zhao, 2016] Li, R. and Zhao, Y. (2016). Dynamic error compensation for industrial robot based on thermal effect model. *Measurement*, 88 :113–120.
- [Ma et al., 2018] Ma, L., Bazzoli, P., Sammons, P. M., Landers, R. G., and Bristow, D. A. (2018). Modeling and calibration of high-order joint-dependent kinematic errors for industrial robots. *Robotics and Computer-Integrated Manufacturing*, 50 :153–167.

- [Mazzini and Dubowsky, 2012] Mazzini, F. and Dubowsky, S. (2012). Experimental Validation of the Tactile Exploration by a Manipulator With Joint Backlash. *Journal of Mechanisms and Robotics*, 4(1). 011009.
- [Mazzoni et al., 2022] Mazzoni, F., Olabi, A., Bearee, R., and Ernst-Desmulier, J.-B. (2022). Calibration methodology for multirobot assembly cell. In *IECON 2022 – 48th Annual Conference of the IEEE Industrial Electronics Society*, pages 1–5.
- [Morozov et al., 2016] Morozov, M., Riise, J., Summan, R., Pierce, S., Mineo, C., MacLeod, C., and Brown, R. (2016). Assessing the accuracy of industrial robots through metrology for the enhancement of automated non-destructive testing. *2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems (MFI)*, pages 335–340.
- [Muller, 2022] Muller, C. (2022). *World Robotics 2022 – Industrial Robots*. International Federation of Robotics (IFR).
- [Nguyen et al., 2019] Nguyen, H.-N., Le, P. N., and Kang, H.-J. (2019). A new calibration method for enhancing robot position accuracy by combining a robot model-based identification approach and an artificial neural network-based error compensation technique. *Advances in Mechanical Engineering*, 11 :168781401882293.
- [Nguyen et al., 2015] Nguyen, H.-N., Zhou, J., and Kang, H.-J. (2015). A calibration method for enhancing robot accuracy through integration of an extended kalman filter algorithm and an artificial neural network. *Neurocomputing*, 151 :996–1005.
- [Nguyen et al., 2021] Nguyen, H. X., Cao, H. Q., Nguyen, T. T., Tran, T. N.-C., Tran, H. N., and Jeon, J. W. (2021). Improving robot precision positioning using a neural network based on levenberg marquardt–apso algorithm. *IEEE Access*, 9 :75415–75425.
- [Nguyen-Tuong and Peters, 2010] Nguyen-Tuong, D. and Peters, J. (2010). Using model knowledge for learning inverse dynamics. In *2010 IEEE International Conference on Robotics and Automation*, pages 2677–2682.
- [Nubiola and Bonev, 2014] Nubiola, A. and Bonev, I. A. (2014). Absolute robot calibration with a single telescoping ballbar. *Precision Engineering*, 38(3) :472–480.
- [Nubiola et al., 2014] Nubiola, A., Slamani, M., Joubair, A., and Bonev, I. A. (2014). Comparison of two calibration methods for a small industrial robot based on an optical cmm and a laser tracker. *Robotica*, 32(3) :447–466.
- [Olabi, 2011] Olabi, A. (2011). *Amélioration de la précision des robots industriels pour des applications d’usinage à grande vitesse*. PhD thesis, HESAM université.
- [Olabi et al., 2012] Olabi, A., Damak, M., Bearee, R., Gibaru, O., and Leleu, S. (2012). Improving the accuracy of industrial robots by offline compensation of joints errors. In *2012 IEEE International Conference on Industrial Technology*, pages 492–497.

- [Pasolli and Melgani, 2011] Pasolli, E. and Melgani, F. (2011). Gaussian process regression within an active learning scheme. In *2011 IEEE International Geoscience and Remote Sensing Symposium*, pages 3574–3577. IEEE.
- [Paul, 1981] Paul, R. P. (1981). *Robot manipulators : mathematics, programming, and control : the computer control of robot manipulators*. Richard Paul.
- [Pedregosa et al., 2011] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., and Duchesnay, E. (2011). Scikit-learn : Machine learning in Python. *Journal of Machine Learning Research*, 12 :2825–2830.
- [Placzek and Piszczek, 2018] Placzek, M. and Piszczek, L. (2018). Testing of an industrial robot’s accuracy and repeatability in off and online environment. *Eksploatacja i Niezawodność – Maintenance and Reliability*, 20(3) :455–464.
- [Polydoros et al., 2015] Polydoros, A. S., Nalpantidis, L., and Krüger, V. (2015). Real-time deep learning of robotic manipulator inverse dynamics. In *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 3442–3448. IEEE.
- [Rezaei and Akbarzadeh, 2018] Rezaei, A. and Akbarzadeh, A. (2018). Compliance error modeling for manipulators considering the effects of the component weights and the body and joint flexibilities. *Mechanism and Machine Theory*, 130 :244–275.
- [Romeres et al., 2016] Romeres, D., Zorzi, M., Camoriano, R., and Chiuso, A. (2016). Online semi-parametric learning for inverse dynamics modeling. In *2016 IEEE 55th Conference on Decision and Control (CDC)*, pages 2945–2950. IEEE.
- [Salisbury, 1980] Salisbury, J. K. (1980). Active stiffness control of a manipulator in cartesian coordinates. *1980 19th IEEE Conference on Decision and Control including the Symposium on Adaptive Processes*, pages 95–100.
- [Santolaria et al., 2009] Santolaria, J., Yagiüe, J.-A., Jiménez, R., and Aguilar, J.-J. (2009). Calibration-based thermal error model for articulated arm coordinate measuring machines. *Precision Engineering*, 33(4) :476–485.
- [Selingue et al., 2022] Selingue, M., Olabi, A., Thiery, S., and Béarée, R. (2022). Experimental analysis of robot hybrid calibration based on geometrical identification and artificial neural network. In *IECON 2022 – 48th Annual Conference of the IEEE Industrial Electronics Society*.
- [Selingue et al., 2023a] Selingue, M., Olabi, A., Thiery, S., and Béarée, R. (2023a). Experimental analysis of robot base frame identification methods. In *Robot2023 Iberian Robotics Conference*.
- [Selingue et al., 2023b] Selingue, M., Olabi, A., Thiery, S., and Béarée, R. (2023b). Hybrid calibration of industrial robot considering payload variation. *Journal of Intelligent and Robotics Systems*.

- [Shiu and Ahmad, 1989] Shiu, Y. and Ahmad, S. (1989). Calibration of wrist-mounted robotic sensors by solving homogeneous transform equations of the form $ax=xb$. *IEEE Transactions on Robotics and Automation*, 5(1) :16–29.
- [Siciliano and Khatib, 2007] Siciliano, B. and Khatib, O. (2007). *Springer Handbook of Robotics*. Springer-Verlag, Berlin, Heidelberg.
- [Slamani and Bonev, 2013] Slamani, M. and Bonev, I. A. (2013). Characterization and experimental evaluation of gear transmission errors in an industrial robot. *Industrial Robot : An International Journal*, 40(5) :441–449.
- [Slamani et al., 2012] Slamani, M., Nubiola, A., and Bonev, I. (2012). Assessment of the positioning performance of an industrial robot. *Industrial Robot : An International Journal*, 39(1) :57–68.
- [Stone et al., 1986] Stone, H., Sanderson, A., and Neuman, C. (1986). Arm signature identification. In *Proceedings. 1986 IEEE International Conference on Robotics and Automation*, volume 3, pages 41–48.
- [Sun et al., 2018] Sun, T., Lian, B., Zhang, J., and Song, Y. (2018). Kinematic calibration of a 2-dof over-constrained parallel mechanism using real inverse kinematics. *IEEE Access*, 6 :67752–67761.
- [Sun and Hollerbach, 2008] Sun, Y. and Hollerbach, J. M. (2008). Observability index selection for robot calibration. In *2008 IEEE international conference on robotics and automation*, pages 831–836. IEEE.
- [Takanashi, 1990] Takanashi, N. (1990). 6 dof manipulators absolute positioning accuracy improvement using a neural-network. In *EEE International Workshop on Intelligent Robots and Systems, Towards a New Frontier of Applications*, pages 635–640 vol.2.
- [Tan et al., 2018] Tan, J., Zhang, T., Coumans, E., Iscen, A., Bai, Y., Hafner, D., Bohez, S., and Vanhoucke, V. (2018). Sim-to-real : Learning agile locomotion for quadruped robots. *Robotics : Science and Systems*.
- [Traversaro et al., 2013] Traversaro, S., Del Prete, A., Muradore, R., Natale, L., and Nori, F. (2013). Inertial parameter identification including friction and motor dynamics. In *2013 13th IEEE-RAS International Conference on Humanoid Robots (Humanoids)*, pages 68–73.
- [Tuttle, 1992] Tuttle, T. (1992). *Understanding and Modeling the Behavior of a Harmonic Drive Gear Transmission*. PhD thesis, Massachusetts Institute of Technology.
- [Vakilnejad et al., 2019] Vakilnejad, M., Olabi, A., and Gibaru, O. (2019). Identification and compensation of periodic gear transmission errors in robot manipulators. In *2019 IEEE International Conference on Industrial Technology (ICIT)*, pages 126–132.
- [Wang et al., 2017] Wang, H., Gao, T., Kinugawa, J., and Kosuge, K. (2017). Finding measurement configurations for accurate robot calibration : Validation with a cable-driven robot. *IEEE Transactions on Robotics*, PP :1–14.

- [Wang et al., 2006] Wang, Y., Huang, T., Zhao, X., Mei, J., Chetwynd, D., and Hu, S. (2006). Finite element analysis and comparison of two hybrid robots—the tricept and the trivariant. In *IEEE International Conference on Intelligent Robots and Systems*, page 490 – 495. IEEE.
- [Williams and Rasmussen, 2006] Williams, C. K. and Rasmussen, C. E. (2006). *Gaussian processes for machine learning*. MIT press Cambridge, MA.
- [Wu and Movellan, 2012] Wu, T. and Movellan, J. (2012). Semi-parametric gaussian process for robot system identification. In *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pages 725–731.
- [Wu et al., 2015] Wu, Y., Klimchik, A., Caro, S., Furet, B., and Pashkevich, A. (2015). Geometric calibration of industrial robots using enhanced partial pose measurements and design of experiments. *Robotics and Computer-Integrated Manufacturing*, 35.
- [Wu et al., 2020] Wu, Z., Guo, P., Zhang, Y., and Zhu, L. (2020). Kinematic calibration for industrial robot using a telescoping ballbar. In *Intelligent Robotics and Applications : 13th International Conference, ICIRA 2020, Kuala Lumpur, Malaysia, November 5–7, 2020, Proceedings 13*, pages 285–295. Springer.
- [Yamane, 2011] Yamane, K. (2011). Practical kinematic and dynamic calibration methods for force-controlled humanoid robots. In *2011 11th IEEE-RAS International Conference on Humanoid Robots*, pages 269–275.
- [Ye et al., 2022] Ye, C., Yang, J., and Ding, H. (2022). High-accuracy prediction and compensation of industrial robot stiffness deformation. *International Journal of Mechanical Sciences*, 233.
- [Yu et al., 2019] Yu, W., Kumar, V. C., Turk, G., and Liu, C. K. (2019). Sim-to-real transfer for biped locomotion. In *IEEE International Conference on Intelligent Robots and Systems*, page 3503 – 3510.
- [Yuan and Ni, 1998] Yuan, J. and Ni, J. (1998). The real-time error compensation technique for cnc machining systems. *Mechatronics*, 8(4) :359–380. Precision Machining.
- [Yuan et al., 2018] Yuan, P., Chen, D., Wang, T., Cao, S., Cai, Y., and Xue, L. (2018). A compensation method based on extreme learning machine to enhance absolute position accuracy for aviation drilling robot. *Advances in Mechanical Engineering*, 10(3) :1687814018763411.
- [Zeng et al., 2017] Zeng, Y., Tian, W., Li, D., He, X., and Liao, W. (2017). An error-similarity-based robot positional accuracy improvement method for a robotic drilling and riveting system. *The International Journal of Advanced Manufacturing Technology*, 88(9) :2745–2755.
- [Zhao et al., 2019] Zhao, G., Zhang, P., Ma, G., and Xiao, W. (2019). System identification of the nonlinear residual errors of an industrial robot using massive measurements. *Robotics and Computer-Integrated Manufacturing*, 59 :104–114.

BIBLIOGRAPHIE

- [Zhong et al., 1996] Zhong, X., Lewis, J., and N-Nagy, F. L. (1996). Inverse robot calibration using artificial neural networks. *Engineering Applications of Artificial Intelligence*, 9(1) :83–93.
- [Zhuang et al., 1995] Zhuang, H., Wang, K., and Roth, Z. (1995). Simultaneous calibration of a robot and a hand-mounted camera. *IEEE Transactions on Robotics and Automation*, 11(5) :649–660.

Résumé : L'évolution des méthodes de production, dans le contexte de l'industrie 4.0, conduit les robots collaboratifs et industriels à être utilisés pour des tâches telles que le perçage, l'usinage, ou l'assemblage. Ces tâches demandent une précision de l'ordre du dixième de millimètre, alors que la précision de ces robots est de l'ordre de un à deux millimètres. Cet état de fait conduit les intégrateurs robotiques à proposer des méthodes de calibration visant à établir un modèle de comportement du robot plus fiable et représentatif du robot réel. Ainsi, les méthodes de calibration analytiques modélisent les défauts affectant la précision des robots industriels, à savoir les défauts géométriques, la compliance des articulations, les erreurs de transmissions et la dérive thermique. Face à la complexité de l'identification expérimentale des paramètres de certains de ces modèles analytiques, des méthodes de calibration hybrides ont été développées. Ces méthodes hybrides couplent un modèle analytique simple avec une approche par apprentissage automatique dont le rôle est de prédire fidèlement les erreurs résiduelles de positionnement (engendrées par la non-exactitude du modèle analytique). Ces défauts peuvent alors être compensés par anticipation, au travers d'un algorithme de compensation. En revanche, ces méthodes demandent beaucoup de temps, de données, et ne sont plus valables lorsque la charge utile du robot change. L'objectif de cette thèse est d'améliorer les méthodes de calibration hybrides pour les rendre applicables dans des contextes industriels. Dans ce sens, plusieurs contributions ont été apportées. D'abord, deux méthodes basées sur des réseaux de neurones permettant, avec très peu de données, d'adapter le modèle hybride (i.e. le réglage d'un jeu de poids spécifique) à une nouvelle charge utile dans un sous-espace de travail du robot. Ces deux méthodes utilisent respectivement un apprentissage par transfert et une interpolation de prédictions. Puis, une méthode de calibration hybride par apprentissage actif utilisant une régression par processus gaussien est présentée. Via cette approche, dans un processus itératif, le système décide des données pertinentes à acquérir de manière autonome, ce qui permet une calibration optimisée en données et en temps.

Mots clés : Robotique, Apprentissage automatique, Calibration, Modélisation, Apprentissage par transfert, Apprentissage actif.

Abstract : The evolution of production methods in the context of Industry 4.0 has led to the use of collaborative and industrial robots for tasks such as drilling, machining, and assembly. These tasks require an accuracy of around a tenth of a millimeter, whereas the precision of these robots is in the range of one to two millimeters. Robotic integrators had to propose calibration methods aimed at establishing a more reliable and representative model of the robot's behavior in the real world. As a result, analytical calibration methods model the defects affecting the accuracy of industrial robots, including geometric defects, joint compliance, transmission errors, and thermal drift. Given the complexity of experimentally identifying the parameters of some of these analytical models, hybrid calibration methods have been developed. These methods combine an analytical model with a machine learning approach whose role is to accurately predict residual positioning errors (caused by the inaccuracies of the analytical model). These defects can then be compensated for in advance through a compensation algorithm. However, these methods require a significant amount of time and data and are no longer valid when the robot's payload changes. The objective of this thesis is to improve hybrid calibration methods to make them applicable in industrial contexts. In this regard, several contributions have been made. First, two methods based on neural networks that allow the adaptation of the hybrid model to a new payload within a robot's workspace with very little data. These two methods respectively rely on transfer learning and prediction interpolation. Then, a hybrid calibration method using active learning with Gaussian process regression is presented. Through this approach, in an iterative process, the system autonomously decides on relevant data to acquire, enabling optimized calibration in terms of data and time.

Keywords : Robotics, Machine learning, Calibration, Modelisation, Transfer learning, Active learning.